

Mark Stefan Henß

**Methodik zur Konzeption, Analyse
und Modellierung von Lösungen im
Prognostics and Health Management (PHM)**

D 93
ISBN 978-3-948308-04-9

Institut für Maschinenelemente

Antriebs-, Dichtungs-, Schienenfahrzeug- u. Zuverlässigkeitstechnik

Universität Stuttgart
Pfaffenwaldring 9
70569 Stuttgart
Tel. (0711) 685 – 66170

Prof. Dr.-Ing. B. Bertsche, Ordinarius und Direktor

**Methodik zur Konzeption, Analyse und Modellierung von Lösungen im
Prognostics and Health Management (PHM)**

**Von der Fakultät Konstruktions-, Produktions- und Fahrzeugtechnik
der Universität Stuttgart
zur Erlangung der Würde eines Doktor-Ingenieurs (Dr.-Ing.)
genehmigte Abhandlung**

Vorgelegt von

Mark Stefan Henß, M. Sc.

aus Fulda

Hauptberichter: Prof. Dr.-Ing. Bernd Bertsche
Mitberichter: Prof. Dr.-Ing. habil. Petra Winzer

Tag der mündlichen Prüfung: 17. November 2021

Institut für Maschinenelemente der Universität Stuttgart

2021

In Liebe und Dankbarkeit meiner Familie gewidmet

Vorwort

Diese Arbeit entstand während meiner Tätigkeit als akademischer Mitarbeiter im Fachbereich der Zuverlässigkeitstechnik am Institut für Maschinenelemente (IMA) der Universität Stuttgart.

Mein herzlicher Dank gilt meinem Doktorvater Herrn Prof. Dr.-Ing. Bernd Bertsche, Ordinarius und Direktor des IMA, für die Ermöglichung dieser Arbeit sowie das stets entgegengebrachte Vertrauen in meine Arbeit und Person. Seine fachliche und inhaltliche Unterstützung sowie die mir gewährte wissenschaftliche Freiheit trugen entscheidend zum Gelingen dieser Arbeit bei.

Frau Prof. Dr.-Ing. habil. Petra Winzer, emeritierte Leiterin des Fachgebiets für Produktsicherheit und Qualitätswesen an der Bergischen Universität Wuppertal, danke ich für die Übernahme des Mitberichts, die interessanten Impulse und die wertvollen Anmerkungen zur Arbeit.

Allen Mitarbeiter:innen des IMA danke ich für die gemeinsame Zeit und das stets familiäre Miteinander. Mein besonderer Dank gilt meinen Bürokollegen für die vielen konstruktiven und anregenden Diskussionen. Ebenso danke ich allen Kolleg:innen aus dem Team „Prognostics and Health Management“, für das gemeinsam Geschaffene und die gegenseitige Förderung.

Bedanken möchte ich mich ebenfalls bei Frau Samira Maleki-Pilevar, die mich als studentische Hilfskraft unterstützt und einen wertvollen Beitrag zu dieser Arbeit geliefert hat. Ebenso gilt mein Dank allen Student:innen, deren Abschlussarbeiten einen Teil zu dieser Arbeit beigetragen haben.

Mein herzlicher Dank gebührt meiner Familie, die mich immer unterstützt und gefördert hat. Für ihre verständnisvolle Unterstützung, die vielen wertvollen Impulse sowie die unendlich schönen Momente gilt mein herzlichster Dank meiner Ehefrau Iris und unserem Sohn Dante.

Inhaltsverzeichnis

Kurzfassung	I
Abstract	III
Notation	V
1 Einleitung	1
1.1 Problemstellung	3
1.2 Motivation und Zielsetzung	4
1.3 Aufbau der Arbeit	5
2 Stand von Wissenschaft und Technik	7
2.1 Stochastik	7
2.1.1 Wahrscheinlichkeitstheorie	7
2.1.2 Statistik	9
2.1.3 Ereignis-Zeit-Analyse	14
2.2 Kausale-Inferenz	15
2.2.1 Gerichtete Azyklische Graphen (DAG)	17
2.2.2 Struktur-Kausale-Modelle (SCM)	18
2.2.3 Kausaler Effekt	18
2.2.4 D-Separation und Do-Calculus	20
2.3 Maschinelles Lernen	22
2.3.1 Terminologie	23
2.3.2 Aufgaben	24
2.3.3 Leistungskennzahlen	25
2.3.4 Künstliche Neuronale Netze (KNN)	28
2.4 Zuverlässigkeitstechnik	30
2.4.1 Lebensdauerverteilungen	32
2.4.2 Lebensdauer- und Degradationsmodelle	34
2.4.3 Schadenshypothesen	35

2.5	Methoden	37
2.5.1	Cross-Industrie Standard Process for Data Mining	37
2.5.2	V-Modell	38
3	Forschungsmethodik	40
3.1	Abgrenzung der Forschungsaufgabe	41
3.1.1	Wissenschaftliche Kritik	41
3.1.2	Forschungsziele	42
3.2	Studien	43
3.2.1	Vergleich etablierter Literaturquellen	43
3.2.2	Empirische Metaanalyse	50
3.3	Zwischenfazit	52
3.3.1	Schlüsselfaktoren	52
3.3.2	Forschungsfragen	53
3.3.3	Evaluation	53
4	PHM: Grundlagen, Konzepte und Modellierung	54
4.1	Einführung	54
4.1.1	Terminologie	56
4.1.2	Einführungsbeispiel	58
4.1.3	Der Health eines technischen Systems	60
4.2	Konzepte	61
4.2.1	Prognostics Konzepte	63
4.2.2	Health Management Konzepte	71
4.3	Modellierung	79
4.3.1	System	80
4.3.2	Daten	82
4.3.3	Diagnose	83
4.3.4	Prognose	86
4.3.5	Optimierung	88
4.4	Einfluss der Prognosegenauigkeit auf die nutzbare Lebensdauer	89
4.4.1	Vorgehen	90
4.4.2	Ergebnisse	91
4.4.3	Schlussfolgerungen	91
5	Methodik im PHM	93
5.1	Konzeptauswahl (1.)	95
5.1.1	Lösungskonzept identifizieren (1.1)	96
5.1.2	PHM-Konzept definieren (1.2)	98
5.1.3	Projektplanung (1.3)	103
5.2	System- & Datenanalyse (2.)	104
5.2.1	Systemanalyse (2.1)	105

5.2.2	Datenanalyse (2.2)	107
5.2.3	Kombinierte Analyse (2.3)	111
5.3	Modellierung (3.)	121
5.3.1	Modellauswahl (3.1)	122
5.3.2	Evaluationskonzept definieren (3.2)	126
5.3.3	Modellerstellung (3.3)	127
5.3.4	Modellbewertung (3.4)	128
5.4	Evaluation (4.)	128
5.4.1	Ergebnisevaluation (4.1)	128
5.4.2	Review (4.2)	129
5.4.3	Planung nächste Schritte (4.3)	129
6	Anwendungsbeispiel AutoEncoder	130
6.1	Konzeptauswahl	131
6.2	System- & Datenanalyse	132
6.3	Modellierung	134
6.4	Evaluation	139
7	Zusammenfassung und Ausblick	140
	Literaturverzeichnis	143
A	Quellen Metaanalyse	155
A.1	Merkmale	155
A.2	Quellen	156

Kurzfassung

Digitalisierung, Konnektivität und Künstliche Intelligenz stellen aktuell drei der disruptivsten Trends im Produktlebenszyklus technischer Systeme dar. Mit Lösungen des Prognostics and Health Management (PHM) können nicht nur dem Kunden vollkommen neue Dienste angeboten werden, auch für den Hersteller (Betreiber) eröffnen sich eine Reihe neuer Möglichkeiten. Der zentrale Ansatz des PHM ist die Verwendung von Daten über Nutzung und Zustand aus dem Betrieb eines einzelnen Systems, um Störungen und Ausfälle frühzeitig zu erkennen und geeignete Gegenmaßnahmen zu definieren. Entscheidungen lassen sich so unter Berücksichtigung der gesamtwirtschaftlichen Interessen treffen. Beispielsweise lassen sich so gleichzeitig Kosten senken, Risiken minimieren, die nutzbaren Betriebsstunden maximieren und die Verfügbarkeit verbessern.

Die Problemstellung ist nicht, dass es keine Literatur oder Normen im PHM gäbe, sondern ihre über eine Vielzahl an Fachdisziplinen isolierte Betrachtung. Dazu kommt, dass dem PHM, als relativ junge Disziplin, eine grundlagenwissenschaftliche Basis fehlt. Der Anwender steht somit vor der Schwierigkeit einen Lösungsansatz zu identifizieren, der sowohl die individuellen Anforderungen erfüllt, Fehlentwicklungen vermeidet als auch die Potenziale ausschöpft. Ziel dieser Arbeit ist eine Methodik, die diese Schwierigkeiten löst und eine möglichst einfache, strukturierte und transparente Entwicklung von PHM-Lösungen erlaubt.

In einem ersten Schritt wird die zentrale Fragestellung, auf Basis der Design Research Methodology (DRM) wissenschaftlich vertieft. Dies umfasst die Abgrenzung der Forschungsaufgabe, die Definition von Forschungszielen sowie die Durchführung von zwei Studien. Neben einer Studie der Fachliteratur und Normung, wird eine empirische Metaanalyse von ca. 260 wissenschaftlichen Beiträgen durchgeführt. Wesentliche Ergebnisse der DRM sind Schlüsselfaktoren und Forschungsfragen. Für diese Arbeit sind die zentralen Forschungsfragen:

1. Wie lassen sich sowohl Konzepte als auch Modelle im PHM generisch und holistisch im Kontext der Technikwissenschaften beschreiben, sodass einerseits Einordnung und Abgrenzung gegenüber etablierter Anwendungswissenschaften und andererseits die Beherrschung der Komplexität möglich ist?
2. Wie lassen sich die Konzepte und Modelle in einer Methodik logisch verknüpfen, sodass die Entwicklung von PHM-Lösungen strukturiert und effizient abläuft?

Die zwei Forschungsfragen werden in separaten aufeinander aufbauenden Teilen bearbeitet. Teil 1 beschreibt Grundlagen, Terminologie, Konzepte und Modelle im PHM und adressiert Forschungsfrage 1. Basis sind klare Merkmale die etablierte Konzepte in eine gemeinsame Betrachtung einsortieren. Etablierte Konzepte sind z. B. die Rekonfiguration, das Predictive oder Prescriptive Maintenance. Dies reduziert sowohl Komplexität und ermöglicht gleichzeitig einen effizienten Vergleich der einzelnen Leistungsfähigkeiten. Das PHM-Modell wird in dieser Arbeit als Abbild des funktionalen Zusammenhangs einer PHM-Lösung verstanden. Dieses wird anhand von 19 Elementen beschrieben, die dem Anwender die Möglichkeit geben die individuell gewünschte Funktionalität durch Kombination einzelner Elemente umzusetzen. In der holistischen Perspektive, charakterisiert das Modell einen geschlossenen Wirkungskreis. Das heißt, jede am System umgesetzte Entscheidung besitzt Auswirkungen auf nachfolgende Messungen, die nach abgeschlossener Bewertung wiederum Basis der nächsten Entscheidung sind. In dieser Arbeit wird diese Eigenschaft durch den PHM-Regelkreis beschrieben.

Teil 2 verknüpft Konzepte und Modelle in der zentralen Methodik und adressiert somit Forschungsfrage 2. Kern ist ein Leitfaden von der Lösungsfindung, über die Auswahl des passenden Konzepts und die Analyse der Rahmenbedingungen bis hin zur konkreten Umsetzung der PHM-Lösung in einem evaluierten Modell. Anhand der Metaanalyse werden dem Anwender begleitend etablierte Lösungswege aufgezeigt. Einen weiteren Beitrag liefert die Integration einer kombinierten Analyse von Domänenwissen und Daten in die Methodik. Hiermit werden einerseits die Besonderheiten von Daten aus Beobachtungsstudien adressiert. Andererseits ist es möglich, Schwierigkeiten durch Störgrößen oder Stichprobenverzerrung frühzeitig zu erkennen und zu verhindern. Die prinzipielle Anwendbarkeit der Methodik wird anhand eines AutoEncoders, zur Bewertung von Wälzlagerschäden in verschiedenen Getrieben bei unterschiedlichen Betriebsmodi gezeigt.

Mit der „Methodik zur Konzeption, Analyse und Modellierung von Lösungen im Prognostics and Health Management“ wird ein Beitrag zur transparenten, strukturierten und effizienten Entwicklung von Lösungen im PHM geliefert. Somit werden einerseits die Barrieren dieser neuen Technologie reduziert und der Zugang einem breiten Anwenderkreis eröffnet. Andererseits können die Potenziale einfacher identifiziert, genutzt und Fehlentwicklungen frühzeitig erkannt werden.

Abstract

“Methodology for the conception, analysis and modelling of solutions in Prognostics and Health Management (PHM)“

Digitalisation, connectivity and artificial intelligence are currently three of the most disruptive trends in the product life cycle of technical systems. Prognostics and Health Management (PHM) solutions do not offer completely new services to the customer only, but also open up a range of new possibilities for the manufacturer (operator). The central approach of PHM is the use of data on usage and condition from the operation of an individual system in order to recognise malfunctions and failures at an early stage and to define suitable countermeasures. Decisions can thus be made taking into account the overall economic interest. For example, costs can be reduced, risks minimised, usable operating hours maximised and availability improved at the same time.

The problem is not that there is no literature or standards, but rather their isolated consideration across a multitude of disciplines. In addition, PHM, as a relatively young discipline, lacks a basic scientific foundation. The user is thus faced with the difficulty of identifying a solution approach that meets individual requirements, avoids undesirable developments and exploits the potential. The aim of this work is to develop a methodology that solves these difficulties and allows the simplest, most structured and most transparent development of PHM solutions.

In a first step, the central question is scientifically deepened on the basis of the Design Research Methodology (DRM). This includes the delineation of the research task, the definition of research objectives and the implementation of two studies. In addition to a study of the technical literature and standardisation, an empirical meta-analysis of approx. 260 scientific articles is carried out. Major findings of the DRM are key factors and research questions. For this paper, the research questions are:

1. How can both concepts and models in PHM be described generically and holistically in the context of engineering sciences, so that on one hand classification and differentiation from established application sciences and on the other hand mastery of complexity is possible?
2. How can the concepts and models be linked logically and plausibly in a methodology, so that the development of PHM solutions proceeds in a structured and effective manner?

The two research questions are addressed in separate parts that build on each other. Part 1 describes basics, terminology, concepts and models in PHM and addresses research question 1. The basis are clear characteristics that sort established concepts such as reconfiguration, predictive or prescriptive maintenance into a common view. This reduces complexity and at the same time enables an efficient comparison of the individual performance capabilities. In this work, the PHM model is understood as a representation of the functional context of a PHM solution. This is described on the basis of 19 elements, which give the user the possibility to implement the individually desired functionality by combining individual elements. In the holistic perspective, the model characterises a closed loop. This means that every decision implemented on the system has an impact on subsequent measurements, which in turn form the basis for the next decision after the evaluation has been completed. In this work, this property is described by the PHM Control Loop.

Part 2 links concepts and models in the central methodology and thus addresses research question 2. The core is a guideline from finding the solution, selecting the appropriate concept and analysing the framework conditions to the concrete implementation of the PHM solution in an evaluated model. On the basis of the meta-analysis, established solutions are shown as an accompaniment. Another contribution is the integration of a combined analysis of domain knowledge and data into the methodology. On one hand, this addresses the special needs of data from observational studies. On the other hand, it is possible to identify and prevent difficulties caused by confounding variables or sampling bias at an early stage. The applicability of the methodology in principle is demonstrated by means of an autoencoder for the evaluation of rolling bearing damage in various gearboxes in different operating modes.

With the “methodology for the conception, analysis and modelling of solutions in Prognostics and Health Management (PHM)” a contribution to the transparent, structured and efficient development of solutions in PHM is provided. Thus, on one hand, the barriers of this new technology are reduced and access is opened to a broad circle of users. On the other hand, the potentials can be identified and used more easily and undesirable developments can be recognised at an early stage.

Notation

Formelzeichen

Symbol	Bezeichnung
a	Ein Skalar
\mathbf{a}	Ein Vektor
\mathbf{A}	Eine Matrix
\mathbf{A}	Ein Tensor
Ψ	Ereignisraum
\emptyset	Leere Menge
X	Zufallsvariable
x	Wert der Zufallsvariablen
P	(Wahrscheinlichkeits-) Verteilung
P_X	Marginal Verteilung von X
$P_{Y,X}$	Multivariate Verteilung von Y und X
$P_{Y X}$	Bedingte Verteilung von Y , gegeben X
$P_{Y X=x}$	Bedingte Verteilung von Y , gegeben $X = x$
p	Dichte-Verteilung
p_X	Dichte der marginal Verteilung P_X
$p_{Y,X}$	Dichte der multivariaten Verteilung $P_{Y,X}$
$p_{Y X}$	Dichte der bedingten Verteilung $P_{Y X}$
$p_{Y X=x}$	Dichte der bedingten Verteilung $P_{Y X=x}$
x_m	Arithmetischer Mittelwert
x_{modal}	Modalwert
x_{median}	Median
$\mu_X = E[X]$	Erwartungswert der Zufallsvariable X
$var[X] = \sigma^2$	Varianz der Zufallsvariable X
σ	Standardabweichung
$cov(X, Y)$	Kovarianz der Zufallsvariablen X, Y

Symbol	Bezeichnung
$corr(X, Y)$	Korrelationskoeffizient der Zufallsvariablen X, Y
$\perp\!\!\!\perp$	Statistische Unabhängigkeit
$\not\perp\!\!\!\perp$	Statistische Abhängigkeit
$\mathcal{N}(\mu, \sigma^2)$	Normalverteilung mit Erwartungswert μ und Varianz σ^2
$Wbl(T, b, N_0)$	Weibullverteilung mit charakteristischer Lebensdauer T , Formparameter b und ausfallfreier Zeit N_0
f_N	Ausfalldichte von N
F_N	Ausfallwahrscheinlichkeit von N
R_N	Überlebenswahrscheinlichkeit von N
$\lambda_N = h_N$	Ausfallrate oder Hazardfunktion von N
G	Graph
$p_{Y do(X=x)}$	Interventions-Verteilung
\mathbf{PA}_X^G	Eltern der Zufallsvariablen X in Graph G
\mathbf{CH}_X^G	Kinder der Zufallsvariablen X in Graph G
\mathbf{AN}_X^G	Vorfahren der Zufallsvariablen X in Graph G
\mathbf{DE}_X^G	Nachkommen der Zufallsvariablen X in Graph G
θ	Modellparameter
α	Lernrate
\mathbb{L}	Verlustfunktion
J	Kostenfunktion
∇	Nabla-Operator

Abkürzungen

Abkürzung	Bezeichnung
AE	AUTOENCODER
AUC	AREA UNTER THE CURVE
CNN	CONVOLUTIONAL NEURONALE NETZE
CPS	CYBER-PHYSICAL SYSTEMS
CRISP-DM	CROSS-INDUSTRY STANDARD PROCESS FOR DATA MINING
DAE	DENOISING AUTOENCODER
DAG	DIRECTED ACYCLIC GRAPHS (dt. Gerichtete Azyklische Graphen)
DIN	DEUTSCHES INSTITUT FÜR NORMUNG
DoB	DEGREE OF BELIEF (dt. Grad des Dafürhaltens)
DRBFM	DESIGN-REVIEW BASED ON FAILURE MODE ANALYSE
DRM	DESIGN RESEARCH METHODOLOGY
EOL	END OF LIFE (dt. Lebensdauerende)
FEM	FINITE ELEMENTE METHODE
FFT	FAST-FOURIER-TRANSFORMATION
FMEA	FEHLER-MÖGLICHKEITS UND EINFLUSS-ANALYSE
FMMEA	FEHLER-MÖGLICHKEITS-MECHANISMEN UND EINFLUSS-ANALYSE
FNN	FEEDFORWARD NEURONALE NETZE
FNR	FALSE NEGATIVE RATE
FPR	FALSE POSITIVE RATE
FTA	FAULT TREE ANALYSIS (dt. Fehlerbaumanalyse)
IEEE	INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS
i. i. d.	INDEPENDENT AND IDENTICALLY DISTRIBUTED (dt. unabhängig und identisch verteilt)
IMA	INSTITUT FÜR MASCHINENELEMENTE, Universität Stuttgart
IMS	CENTER FOR INTELLIGENT MAINTENANCE SYSTEMS
ISO	INTERNATIONAL ORGANIZATION FOR STANDARIZATION
KI	KÜNSTLICHE INTELLIGENZ
KNN	KÜNSTLICHE NEURONALE NETZE
LSTM	LONG SHORT-TERM MEMORY
MAE	MEAN ABSOLUTE ERROR
MAPE	MEAN ABSOLUTE PERCENTAGE ERROR
MCS	MONTE-CARLO-SIMULATION
MKS	MEHRKÖRPERSIMULATION
ML	MASCHINELLES LERNEN
MSE	MEAN SQUARED ERROR

Abkürzung	Bezeichnung
NASA	NATIONAL AERONAUTICS AND SPACE ADMINISTRATION
PCoE	PROGNOSTICS CENTER OF EXCELLENCE
PEP	PRODUKTENTWICKLUNGSPROZESS
PH	PROGNOSTIC HORIZON
PHI	PHYSIKALISCHER HEALTHINDEX
PHM	PROGNOSTICS AND HEALTH MANAGEMENT
PLZ	PRODUKTLEBENSZYKLUS
PoF	PHYSICS OF FAILURE (dt. Schadensmechanismus)
RA	RELATIVE ACCURACY
RAMS	RELIABILITY, AVAILABILITY, MAINTAINABILITY, SAFETY
ReLU	RECTIFIED LINEAR UNIT
RMSE	ROOT MEAN SQUARED ERROR
RNN	RECURRENT NEURONALE NETZE
ROC	RECEIVER OPERATOR CURVE
ROI	RETURN OF INVESTMENT (dt. Kapitalrendite)
RUL	REMAINING USEFUL LIFE NUTZBARE RESTLEBENSDAUER (dt. Nutzbare Restlebensdauer)
SCM	STRUCTURAL CAUSAL MODELS (dt. Struktur-Kausale-Modelle)
SHI	SYNTHETISCHER HEALTHINDEX
STS	SOZIOTECHNISCHES SYSTEM
TNR	TRUE NEGATIVE RATE
TPR	TRUE POSITIVE RATE
VDA	VERBAND DER AUTOMOBILINDUSTRIE

Kapitel 1

Einleitung

Störungen und Ausfälle von Systemen können große ökonomische Schäden verursachen oder Menschenleben gefährden. Sie werden häufig durch mangelnde Beherrschung von Komplexität oder Unkenntnis der realen Zustände verursacht [BW18; Sch+20]. Traditionell liegt in der Entwicklungsphase das größte Potential um Störungen und Ausfällen kostengünstig vorzubeugen [BL04]. Im Betrieb liegen die Fehlerkosten meist weit höher und der reale Zustand ist zumeist unbekannt. Mit zunehmender Digitalisierung und Konnektivität verschiebt sich der technologische Rahmen und eine steigende Zahl an Systemen wird im Betrieb zugänglich [Sch+20]. Die Einbindung technischer Systeme in IT-Netzwerke bereitet den Weg für weitere Entwicklungen. Beispielsweise befähigt die hohe Verfügbarkeit von Daten den Einsatz des Maschinellen Lernens im technischen Umfeld. In Kombination ist es möglich effizient aus komplexen und großen Datenmengen Informationen zu gewinnen und zu nutzen. Aus den technologischen Fortschritten folgen in Konsequenz betriebswirtschaftliche und regulatorische Interessen. Im Fokus stehen vor allem Maßnahmen der Kostenoptimierung sowie normative Vorschriften zur Erhöhung der Sicherheit. Mit der Servitization lassen sich aber auch ganz neue Geschäftsfelder erschließen, bspw. mit dem Wechsel vom System- zum Service-Lieferanten.

Im Prognostics and Health Management (PHM) wird das Ziel verfolgt, den verschiedenen Stakeholdern relevante Informationen über den Systemzustand zum richtigen Zeitpunkt zur Verfügung zu stellen, als Basis optimaler Entscheidungen. Im Kern stehen die Prognose zukünftiger Zustände sowie die Definition geeigneter Maßnahmen zur Vermeidung unerwünschter Ereignisse (Störungen und Ausfälle). Mit dem Schritt von der Diagnose des aktuellen Zustands zur Prognose des zukünftig angenommenen Zustandsverlaufs wird es möglich, die verbleibende nutzbare Zeit

Tabelle 1.1 Potenziale von PHM in verschiedenen Branchen, nach einer Studie von [Con19]. *: Anteil der Instandhaltungskosten an den Betriebskosten. **: Potenziale zur Reduktion der Instandhaltungskosten.

	Luftfahrt	Schienen- verkehr	Automobil- technik	Windkraft
Instandhaltungskosten*	10%	21%	10%	23%
Sekundäre Kosten	400.000 € pro storniertem Langstreckenflug	25.000 € pro Stornierung	20.000 € pro Minute Bandstillstand	8.000 € pro Tag Stillstand
Einsparpotenziale**	30%	20%	20%	20%

bis zum Eintritt des Ereignisses zu quantifizieren. Der Betrieb des Systems wird somit maximal planbar und erlaubt die frühzeitige Definition optimaler Maßnahmen hinsichtlich Zuverlässigkeit, Instandhaltbarkeit, Verfügbarkeit, Sicherheit oder eine Kombination der Genannten. Bei den Instandhaltungskosten lassen sich so Einsparpotenziale von 20% bis 30% erreichen, siehe Tabelle 1.1. Aus dem ungeplanten Funktionsverlust folgen sekundäre Kosten, beispielsweise aus der Stornierung bereits verkaufter Mobilitätsdienstleistungen oder aufgrund des Stillstands einer Produktion. In anderen Worten liegt die Problematik in der Verfügbarkeit bzw. der nicht Verfügbarkeit des Systems. PHM-Lösungen indizieren über den Produktlebenszyklus ein Einsparpotenzial der Instandhaltungskosten von 30% [Con19]. Weitere Potenziale liegen in einer gesteigerten Systemsicherheit ([Joh+11]) sowie einer Maximierung der Betriebsstunden je System (Abschnitt 4.4). Maximierung der Betriebsstunden heißt, dass dasselbe System länger betrieben werden kann, bei gleicher Ausfallsicherheit und ohne Änderungen von Konstruktion oder Nutzung. Möglich ist dies alleine auf Basis der genaueren Kenntnis des systemindividuellen Zustands.

Langfristig eröffnet PHM Systemen die Möglichkeit, vollkommen autonom, d. h. selbstbestimmt, im Sinne ihres aktuellen Zustands und weiterer Zielgrößen zu verwalten, zu entscheiden und zu handeln. Beispielsweise prognostiziert ein Industrieroboter den Verschleiß seiner Getriebe selbst, passt darauf aufbauend die Arbeitsprozesse an und entscheidet über den optimalen Zeitpunkt des Austausches. Dabei beruhen seine Entscheidungen auf Nutzungsprognosen im Kontext von Wirtschaftlichkeit, Verfügbarkeit und Sicherheit. Der Roboter handelt dabei nicht autark, sondern steht in Abstimmung mit allen anderen Systemen, die zur Funktionserfüllung der gesamten Produktionsstraße beitragen. Darüber hinaus orientiert sich die Produktionsstraße an aktuellen Absatzprognosen und richtet aktuelle Entscheidungen anhand gesamtwirtschaftlicher Interessen des Unternehmens aus.

1.1 Problemstellung

Faktoren wie steigende Komplexität, Funktionalität sowie sinkende Reaktionszeiten treiben zunehmend die Entwicklung und den Betrieb technischer Systeme [BL04]. Quellen der steigenden Komplexität sind das technische System selbst, die Vielfalt des technologischen Lösungsraums und die unterschiedlichen Sichten beteiligter Fachdisziplinen [LDF14; RB15; HZB17]. Im Detail sind Störungen und Ausfälle auf eine Vielzahl an Komponenten mit sich teils überlagernden Mechanismen zurück zu führen, die wiederum durch eine Vielzahl von Einflussfaktoren bestimmt werden. Mit Digitalisierung und Konnektivität steigt der Anteil potenziell wechselwirkender Komponenten in Hard- und Software weiter. Dabei steht die Entwicklung unter hohem Zeit- und Kostendruck [BL04]. In der Entwicklung einer PHM-Lösung müssen all diese und weitere Faktoren berücksichtigt werden. Gleichzeitig steht technologisch eine wachsende Anzahl an Algorithmen und Modellierungsansätzen zur Verfügung. Insbesondere ohne Vorkenntnisse, ist die Identifikation der richtigen PHM-Lösung aus der Fülle des Lösungsraums nicht trivial [KAC17]. Falsche Lösungen führen im besten Fall zu einem Vertrauensverlust, im schlimmsten Fall wird ein sicherheitskritischer Ausfall nicht erkannt und Menschenleben gefährdet. Eine weitere Herausforderung ist die Abstimmung über die Grenzen einzelner Fachdisziplinen. Zu diesen gehören Zuverlässigkeitstechnik, Messtechnik, Systemdomäne, Statistik, Maschinelles Lernen, Regelungstechnik u. v. a. m.

Das Problem ist nicht, das es keine Beschreibungen oder Methoden gäbe, sondern ihre über eine Vielzahl an Fachdisziplinen isolierte Betrachtung. Dies äußert sich in einer Teils undurchsichtigen Vielzahl von Konzepten, Modellen und Methoden [RB15; HZB17]. Dazu kommt, dass in Technik und Wissenschaft eine Reihe angrenzender oder synonym verwendeter Begriffe existieren, wie Condition Based Maintenance, Predictive Maintenance, Prescriptive Maintenance, Predictive Asset Management, System Health Management oder Integrated Vehicle Health Management. Hier fehlt eine Gegenüberstellung auf Basis klarer Merkmale, mit der die Leistungsfähigkeit vergleichbar wird.

Komplexität, interdisziplinäre Barrieren, genauso wie isolierte Ansätze behindern den Einsatz von PHM-Lösungen, da eine einfache, strukturierte und effiziente Auswahl sowie Umsetzung der passenden Lösung nicht möglich ist. Gleichzeitig zeigen PHM-Lösungen erhebliche Potenziale, z. B. in der Einsparung von Instandhaltungskosten, einer gesteigerten Sicherheit oder einer Maximierung der Betriebsstunden. Dazu kommt, dass mit Digitalisierung und Konnektivität die technologische Voraussetzung geschaffen wird, PHM für eine immer größer werdende Anzahl an Systemen anzuwenden. Zur Ausschöpfung dieser Potenziale ist es daher erforderlich, dass PHM-Lösungen angemessen beschrieben und methodisch entwickelt werden können.

1.2 Motivation und Zielsetzung

Entscheidungen werden in der Regel auf Basis von zwei Faktoren getroffen: Der Eintrittswahrscheinlichkeit eines Ereignisses und den daraus resultierenden Risiken. Je unsicherer der Ereigniseintritt ist, desto konservativer werden Systeme ausgelegt und betrieben. Dies äußert sich beispielsweise in konstruktiver Überdimensionierung oder unnötigen Instandhaltungsmaßnahmen. Mit einer PHM-Lösung kann diesen Punkten entgegnet werden. Je nach Ansatz lässt sich die Eintrittswahrscheinlichkeit einer Störung oder eines Ausfalls mit sehr hohen Genauigkeiten bewerten. Zusätzlich lassen sich im Allgemeinen aus den Daten und Analysen wertvolle Erkenntnisse über die reale Belastung und Belastbarkeit des Systems im Betrieb gewinnen. Entscheidungen können somit weniger konservativ getroffen werden, was i.d.R. einen gesamtwirtschaftlichen Vorteil schafft. Konkret können z. B. Überdimensionierung, Stillstandszeiten, Lagerhaltung, Instandhaltungsressourcen, Wartungsintervalle und somit im Allgemeinen Kosten reduziert werden.

Mit dem Wechsel von der Diagnose des aktuellen Zustands zur Prognose des zukünftigen Zustandsverlaufs können nicht nur bessere Entscheidungen getroffen werden, diese sind auch im Voraus planbar. Dies eröffnet Potenziale z. B. in der Instandhaltungs-, Prozess- oder Einsatzplanung. Ersatzteile werden just in time bestellt und die Einsatzfreigabe erfolgt anhand der verbleibenden Lebensdauer. In einer Flotte können anstehende Einsätze mit ihren unterschiedlichen Systembeanspruchungen, entsprechend einer optimalen Nutzung aller Systeme koordiniert werden. Diesem Gedanken folgend, lässt sich der Ausfallzeitpunkt eines Systems gezielt steuern. Beispielsweise ist es möglich eine weniger belastende Nutzung zu wählen, um den Ausfallzeitpunkt bis zum nächsten Instandhaltungsintervall hinaus zu zögern. Genauso kann mit einer stärker belastenden Nutzung eine vollständigere Ausschöpfung der nutzbaren Systemlebensdauer zum Tauschzeitpunkt erzielt werden.

Ziel der Arbeit ist eine Methodik zur Konzeption, Analyse und Modellierung von PHM-Lösungen. Die Entwicklung von PHM-Lösungen soll dabei möglichst einfach, transparent und für einen möglichst großen Anwenderkreis zugänglich sein. Schwerpunkte liegen auf der Auswahl passender Lösungskonzepte, der Analyse von Rahmenbedingungen sowie der Überführung aller Funktionen in eine anwendbare Modellierung. Um die Ziele zu erreichen, müssen konsistente Beschreibungen und eine durchgängige Methodik geschaffen werden. Eine konsistente Beschreibung von Konzepten und Modellen umfasst vor allem vergleich- und abgrenzbare Eigenschaften, Abhängigkeiten sowie Leistungskennzahlen. Auf dieser Basis kann die individuell beste Lösung effizient ausgewählt und das volle Potential ausgeschöpft werden. Zur Umsetzung der gewählten Lösung bedarf es einer darauf aufbauenden durchgängigen Methodik. Mit dieser sollten die Entwicklungsschritte generisch, holistisch und in einer logischen Reihenfolge verknüpft werden, um die Komplexität und somit die Gefahr von Fehlentwicklungen auf ein Minimum zu reduzieren.

1.3 Aufbau der Arbeit

Mit diesem Abschnitt soll eine schnelle Orientierung innerhalb der Arbeit geschaffen werden. Die einzelnen Kapitel sowie deren Verknüpfung werden kurz vorgestellt, sodass der Leser je nach Interesse und Vorwissen direkt in einzelne Kapitel springen kann. Bild 1.1 zeigt den schematischen Aufbau dieser Arbeit.

Kapitel 1 führt kurz in das Themengebiet des PHM ein und zeigt wichtige Benefits, Herausforderungen und Ziele der Arbeit. Kapitel 2 zeigt den Stand von Wissenschaft und Technik und stellt die Grundlagen wichtiger Ansätze dar. An dieser Stelle werden insbesondere Grundlagen der Stochastik, der Kausalität, des Maschinellen Lernens, der Zuverlässigkeitstechnik sowie Methoden vorgestellt. PHM sowie die Benefits, Herausforderungen und Ziele dieser Arbeit werden in Kapitel 3 nochmals wissenschaftlich analysiert. Die Bearbeitung erfolgt dabei auf Basis der Design Research Methodology, eine der etabliertesten Forschungsmethodiken im Ingenieurwesen [Mar14]. Dabei werden sowohl Ziele als auch Erfolgskriterien zur zielorientierten und strukturierten Entwicklung der avisierten Methodik erarbeitet.

Kapitel 4 und 5 bilden das Herzstück dieser Arbeit. Ausgehend von der Forschungsmethodik werden hier die Ergebnisse erläutert. Die zwei Kapitel bilden eine autarke und im Sinne dieser Arbeit vollständige Beschreibung des PHM. Alle weiteren Kapitel vervollständigen den wissenschaftlichen Kontext. In Kapitel 4 werden einleitend die wichtigsten Begriffe vorgestellt und ein beispielhafter PHM-Ansatz erläutert. Kern des vierten Kapitels bilden die Beschreibungen der Konzepte (Abschnitt 4.2) und Modelle (Abschnitt 4.3). Abschließend untersucht Abschnitt 4.4 die Potenziale einer genaueren Zustandsprognose bezüglich der nutzbaren Lebensdauer eines Systems. Mit Kapitel 4 werden die folgenden Punkte adressiert:

- Bildung einer fundierten PHM-Wissensbasis.
- Charakterisierung wesentlicher Eigenschaften, Entwicklungsstufen und Abhängigkeiten der Konzepte und Modelle.
- Bewertung und Abgrenzung der Leistungsfähigkeit einzelner Ansätze.

Kapitel 5 beschreibt die Methodik zur Konzeption, Analyse und Modellierung von Lösungen im PHM. Begriffe und Beschreibungen des vorangegangenen Kapitels werden an dieser Stelle konsequent weiter geführt. Startpunkt der Methodik ist die Auswahl eines geeigneten PHM-Konzeptes (Abschnitt 5.1), das schrittweise in eine Modellierung (Abschnitt 5.3) überführt wird. Hierzu verzahnen die einzelnen Schritte etablierte Methoden des Data-Science und der Zuverlässigkeitstechnik. Die Analysen von System und Daten werden mit den Ansätzen der Kausalen Inferenz synchronisiert und in einer kombinierten Analyse verbunden (Abschnitt 5.2). Zusätzlich werden in einzelnen Schritten etablierte Lösungen als Orientierungshilfe

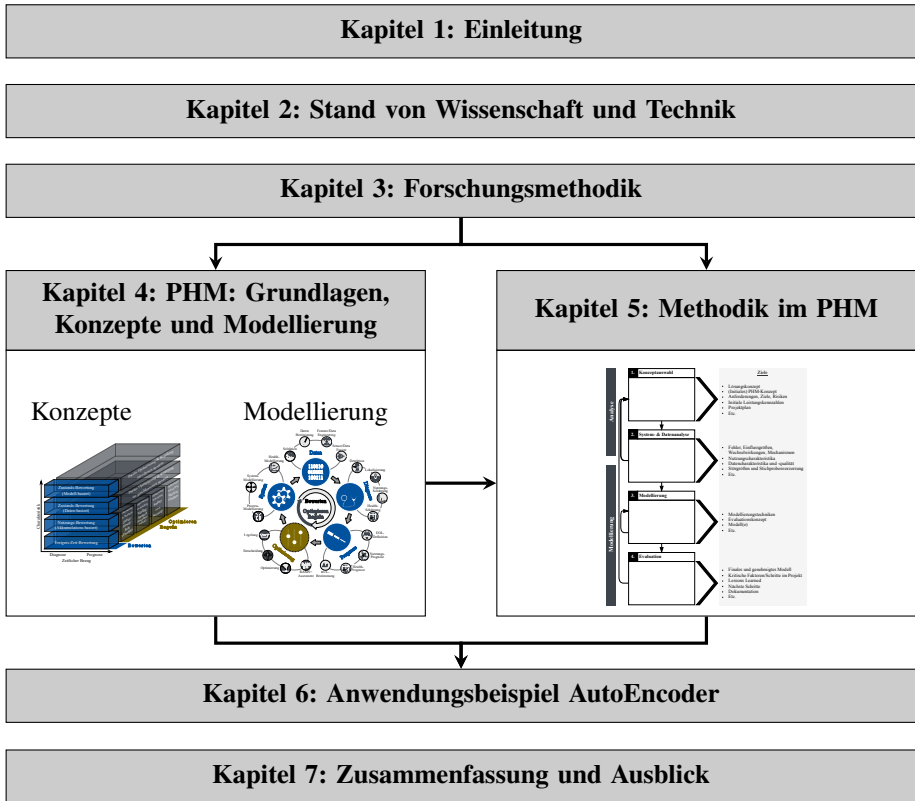


Bild 1.1 Schematischer Aufbau der Arbeit.

vorgelegt, aufbauend auf einer Analyse von ca. 260 wissenschaftlichen Beiträgen. Mit Kapitel 5 werden die folgenden Punkte adressiert:

- Ganzheitliche Charakterisierung allgemeiner Entwicklungsschritte mit Fokussierung der Konzeptauswahl, Analyse und Modellierung.
- Bereitstellung eines methodischen Leitfadens für Anwender.
- Orientierungshilfen auf Basis etablierter Lösungen.

Kapitel 6 zeigt die Anwendung der Methodik am Beispiel eines AutoEncoders, einem Daten-basierten Ansatz. In Kapitel 7 werden die Ergebnisse dieser Arbeit zusammengefasst und ein Ausblick auf weiterführende Forschungsfragen gegeben.

Kapitel 2

Stand von Wissenschaft und Technik

Dieses Kapitel beschreibt die wichtigsten Grundlagen im Sinne dieser Arbeit. Dazu gehören die Stochastik, die Kausale-Inferenz, Maschinelles Lernen, die Zuverlässigkeitstechnik sowie Methoden.

2.1 Stochastik

Die **Stochastik** umfasst die Teilgebiete der **Statistik** und **Wahrscheinlichkeitstheorie**. Sie ist „die Theorie der quantitativen Beschreibung unsicherer Ereignisse [...]“ [HS20]. In der Wahrscheinlichkeitstheorie werden allgemeine Rechenvorschriften sowie deren Interpretation formalisiert [BW18]. Im Vergleich ist Statistik „die Kunst, Daten zu gewinnen, darzustellen, zu analysieren und zu interpretieren, um zu neuem Wissen zu gelangen“ [HS20]. Konzepte der Stochastik bilden die Basis der technischen Zuverlässigkeit, der Kausalen-Inferenz, des Maschinellen Lernens und sind somit zentraler Bestandteil dieser Arbeit.

2.1.1 Wahrscheinlichkeitstheorie

In der Wahrscheinlichkeitstheorie werden mit den Axiomen von Kolmogorov die Rechenvorschriften (Syntax) formalisiert, während die darauf aufbauende Interpretation der Ergebnisse Klassisch oder nach Bayes erfolgen kann (Semantik) [BW18]. Sowohl Syntax als auch Semantik werden im Folgenden kurz vorgestellt.

Kolmogorovs Axiome: Zufallsexperimente bezeichnen Experimente, mit nicht deterministischem Ergebnis. Das heißt, dass Ergebnis eines Experiments ist vor dessen Ende nicht exakt prognostizierbar. Vielmehr gibt es eine Menge möglicher Ereignisse, die als Ereignisraum Ψ bezeichnet wird. Dabei ist jedem Ereignis X eine Wahrscheinlichkeit P_X zugeordnet. Für ein Ereignis gelten nach Kolmogorov die folgenden Axiome: [HS20]

1. Jedem Ereignis ist eine reelle Wahrscheinlichkeit zwischen 0 und 1 zugeordnet:

$$0 \leq P_X \leq 1 \quad (2.1)$$

2. Das sichere Ereignis hat die Wahrscheinlichkeit 1:

$$P_\Psi = 1 \quad (2.2)$$

3. Die Wahrscheinlichkeiten paarweise disjunkter Ereignisse ($P_X \cap P_Y \cap \dots = \emptyset$) sind Additiv:

$$P_{X \cup Y \cup \dots} = P_X + P_Y + \dots \quad (2.3)$$

Ein Ereignis X mit $P_X = 0$ lässt sich als fast unmöglich und ein Ereignis mit $P_X = 1$ als fast sicher bezeichnen. Zudem addiert sich die Summe der Wahrscheinlichkeiten aus zwei komplementären Ereignissen zu $P_X + P_{\bar{X}} = 1$. Der Begriff der **Zufallsvariablen** X wird verwendet, wenn der Ereignismenge Ψ eines Zufallsexperiments eine Zahl zugeordnet wird, sprich $X : \Psi \rightarrow \mathbb{R}$. Die Realisierung $X = x$ beschreibt, dass die Zufallsvariable X den Wert x angenommen hat. Zufallsvariablen können hierbei diskret oder stetig sein. Als Wahrscheinlichkeit für eine Realisierung folgt $P_{X=x}$. Neben einem Einzelwert x kann eine Zufallsvariable in einem Intervall $x_l \leq X \leq x_h$ liegen. Entsprechend ergibt sich für die Wahrscheinlichkeit $P_{x_l \leq X \leq x_h}$. [HS20]

Bedingte Wahrscheinlichkeit: Der Eintritt eines Ereignisses X kann mit dem Eintreten eines anderen Ereignisses Y verknüpft sein. In diesem Fall wird von einer bedingten Wahrscheinlichkeit gesprochen. Die Wahrscheinlichkeit des Ereignis P_X unter der Bedingung des Ereignis P_Y wird ausgedrückt durch $P_{X|Y}$ und ist gegeben durch Gleichung 2.4. Es wird auch von einer Konditionierung des Ereignisses X durch das Ereignis Y gesprochen. [HS20]

$$P_{X|Y} = \frac{P_{X,Y}}{P_Y} \quad (2.4)$$

Klassische Interpretation (Frequentistik): In dieser Interpretation wird Wahrscheinlichkeit als eine Größe gesehen, die ähnlich einer physikalischen Größe gemessen oder beobachtet werden kann [BW18]. Ein Beispiel ist das Zufallsexperiment des Münzwurfs. Beim idealen Münzwurf besitzt das Ereignis X zwei mögliche Realisierungen $X = \{Kopf, Zahl\}$. Wird das Experiment $N \rightarrow \infty$ mal wiederholt, wird die Wahrscheinlichkeit beider Realisierungen $P_{X=Kopf} = P_{X=Zahl} = 0,5$ entgegen streben. In anderen Worten, strebt die Anzahl der Wiederholungen N gegen unendlich, konvergiert die beobachtete Wahrscheinlichkeit gegen die tatsächliche Wahrscheinlichkeit. Dies ist auch bekannt unter dem **Gesetz der großen Zahlen**.

Bayes'sche Interpretation (Degree of Belief): Die objektive Interpretation von Wahrscheinlichkeiten der Frequentistik ist nicht immer möglich. Beispielsweise kann der Frage „ob es am Folgetag regnet“ nicht in einem Zufallsexperiment nachgegangen werden. Dennoch treffen Wetterdienste oder Einzelpersonen Aussagen über die Regenwahrscheinlichkeit. Dabei wird der individuelle „Grad des Dafürhaltens“ DoB (engl. Degree of Belief) beschrieben, der eine Verallgemeinerung der klassischen Interpretation darstellt. DoB's werden in objektiv und subjektiv unterschieden. Von objektiven DoB's wird gesprochen, wenn bei gleichen Fakten (und gleichen Modellen) immer die gleichen Wahrscheinlichkeiten berechnet werden. Im Beispiel trifft dies auf den Wetterdienst zu. Im Vergleich werden zwei Einzelpersonen vermutlich unterschiedliche Wahrscheinlichkeiten benennen, es wird von subjektiven DoB's gesprochen. [BW18]

Bayes'sche Theorem: Das Theorem von Bayes baut auf der bedingten Wahrscheinlichkeit auf und kann direkt aus Gleichung 2.4 abgeleitet werden. Gleichung 2.5 zeigt den speziellen Satz von Bayes, der eine direkte Möglichkeit bietet DoB's zu beschreiben. Der DoB (auch als Wissen oder Vorerfahrung bezeichnet) wird dabei über die a priori Wahrscheinlichkeit P_X eingebracht. A posteriori ergibt sich die bedingte Wahrscheinlichkeit $P_{X|Y}$. Diese kann als Update auf Basis der a priori Wahrscheinlichkeit verstanden werden. [HS20]

$$P_{X|Y} = \frac{P_X P_{Y|X}}{P_Y} \quad (2.5)$$

2.1.2 Statistik

Statistik ist „die Kunst, Daten zu gewinnen, darzustellen, zu analysieren und zu interpretieren, um zu neuem Wissen zu gelangen“ [HS20]. In diesem Abschnitt werden die wichtigsten Grundlagen und Konzepte der Statistik kurz vorgestellt.

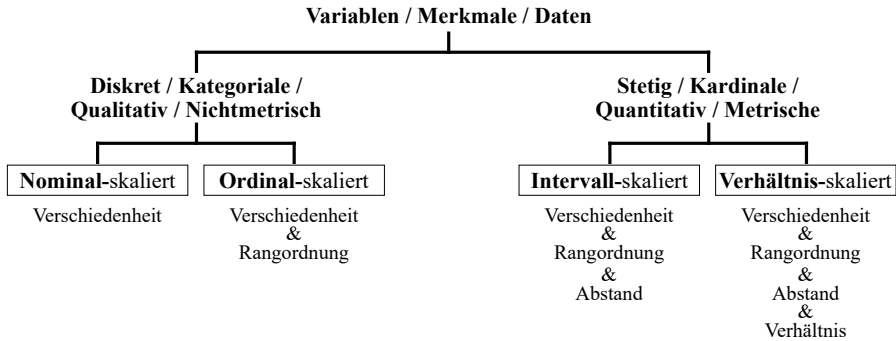


Bild 2.1 Skalentypen und Eigenschaften (in Anlehnung an [HS20])

Grundgesamtheit und Stichprobe: Zufallsvariablen der Wahrscheinlichkeitstheorie beschreiben das zahlenmäßige Ergebnis eines Zufallsexperiments. Im Vergleich, stehen statistische Variablen immer in Verbindung mit einer Grundgesamtheit oder Stichprobe. Als **Grundgesamtheit** oder **Population** wird die Gesamtheit aller Daten bezeichnet, d. h. die Menge aller möglichen Realisierungen x . In empirischen Befragungen wie auch in technischen Prozessen ist es i. d. R. nicht möglich die Grundgesamtheit zu erfassen. Beispielsweise ist eine Qualitätsprüfung (insbesondere zerstörende Prüfverfahren) aller Produkte oft zu aufwendig und nicht wirtschaftlich. Aus diesem Grund wird aus der Grundgesamtheit nur eine Teilmenge aller Daten ausgewählt, sprich eine **Stichprobe** gezogen. Es wird von empirischen Daten bzw. empirischen Untersuchungen gesprochen. Als Instanz i wird eine einzelne Ziehung aus der Stichprobe (Realisierung) bezeichnet. Im Folgenden werden diese im univariaten Fall als $x^{(i)}$ und im bivariaten Fall als $(x^{(i)}, y^{(i)})$ angegeben. [HS20]

Abhängige und unabhängige Variablen: Grundsätzlich unterscheidet die klassische Statistik Variablen, die einen Einfluss ausüben und Variablen die beeinflusst werden [HS20]. Beeinflussende Variablen, die nicht kontrollierbar sind, werden als **Störvariablen** (engl. Confounder) bezeichnet (siehe Abschnitt 2.2). Kontrollierbare Variablen werden hingegen als **unabhängige Variablen** und die beeinflussten Variablen als **abhängige Variablen** bezeichnet. Dabei werden verschiedene Arten von Skalentypen unterschieden, wie in Bild 2.1 dargestellt. Jeder Skalentyp impliziert zulässige Rechenvorschriften und grenzt somit das Anwendungsspektrum verschiedener statistischer Methoden ab.

Unabhängig und identisch verteilt: Die Annahme unabhängig und identisch verteilter Variablen i. i. d. (engl. independent and identically distributed) ist eine Grundvoraussetzung vieler Konzepte der Statistik. Mit dem i. i. d. Kriterium wird ausge-

drückt, dass alle Instanzen $(x^{(i)}, y^{(i)})$; $i = 1, \dots, n$ unabhängig voneinander erzeugt werden unter dem selben Zufallsexperiment. [PJS17]

Häufigkeit h : Als absolute Häufigkeit h_{abs} wird die Summe gleicher Repräsentationen $h_{abs}(X = x_i)$, bzw. die Anzahl aller Repräsentationen in einem definierten Intervall $h_{abs}(x_i \leq X \leq x_{i+t})$ verstanden. Die Intervalle werden auch als Klassen bezeichnet. Wird die absolute Häufigkeit in Verhältnis zur Gesamtzahl aller Repräsentationen N gesetzt (entspricht der Stichprobenzahl), ergibt sich die relative Häufigkeit h_{rel} . Eine grafische Darstellungsform der Häufigkeiten bietet das Histogramm. [BL04]

Wahrscheinlichkeitsdichtefunktion p_X : Die Wahrscheinlichkeitsdichtefunktion oder kurz Dichtefunktion bietet eine weitere Darstellungsform der Zufallsvariablen. Dabei wird zwischen der empirischen und der idealen Dichtefunktion unterschieden. Die empirische Dichtefunktion p_X^* verbindet die Mittelwerte der Histogramm-Intervalle, als abschnittsweise lineare Funktion. Strebt die Menge der Realisierungen $N \rightarrow \infty$, wird die Intervallbreite infinitesimal schmal und die empirische Dichtefunktion geht in die glatte, stetige „ideale“ Dichtefunktion p_X über. [BL04]

Wahrscheinlichkeitsverteilung P_X : Die Wahrscheinlichkeitsverteilung oder Verteilungsfunktion folgt aus der Integration der Dichtefunktion, Gleichung 2.6. Mit der Verteilungsfunktion wird somit die Fläche unter der Dichtefunktion beschrieben. In Abschnitt 2.4.1 werden Verteilungsfunktionen vorgestellt. [HS20]

$$P_X = \int p_X dx \tag{2.6}$$

Statistische Maßzahlen: Es gibt eine Vielzahl statistischer Maßzahlen. Maßzahlen der Lage sind bspw. der arithmetische Mittelwert, der Modalwert und der Median. Dabei beschreibt der Mittelwert x_m den Schwerpunkt oder Mittelpunkt aller Zufallszahlen, der Modalwert x_{modal} , die am häufigsten auftretende Zufallszahl und der Median x_{median} unterteilt die Anzahl der Zufallszahlen in zwei gleich große Mengen. Gleichung 2.7 beschreibt den empirischen Mittelwert. Der Modalwert liegt im Maximum der Dichtefunktion $p'_{x_{modal}} = 0$ und der Median bei $P_{x_{median}} = 0,5$. Alle drei Lageparameter können zusammenfallen, beispielsweise bei einer Normalverteilung. Dies ist allerdings nicht die Regel. Eine weitere wichtige Maßzahl ist der Erwartungswert $\mu_X = E[X]$, der sich für diskrete Zufallsvariablen nach Gleichung 2.8 berechnet. [BL04; HS20]

$$x_m^* = \frac{1}{N} \sum_{i=1}^N x_i \tag{2.7}$$

$$\mu_X = E[X] = \sum_{i=1}^N x_i \cdot P_{X=x_i} \quad (2.8)$$

Maßzahlen, die am Erwartungswert $E[X]$ zentriert sind, werden als „zentrale Momente“ bezeichnet. Allgemein gilt für das i -te zentrale Moment einer Variablen X Gleichung 2.9. Das zweite zentrale Moment beschreibt die Varianz σ^2 , bzw. deren Quadratwurzel die Standardabweichung σ . Aus dem dritten zentralen Moment folgt durch Normierung mit der Standardabweichung σ die Schiefe und in gleicherweise aus dem vierten zentralen Moment normiert die Wölbung (Gleichung 2.10). [Bro+15]

$$\mu_i = E \left[(X - E(X))^i \right] \quad (2.9)$$

$$\mu_i = E \left[\left(\frac{X - E(X)}{\sigma} \right)^i \right] \quad (2.10)$$

Ein Maß zur Beschreibung des Zusammenhangs zwischen zwei Zufallsvariablen X und Y ist die Kovarianz $cov(X, Y)$. Die Kovarianz für zwei Zufallsvariablen mit existierenden Erwartungswerten berechnet sich nach Gleichung 2.11. Mit der Kovarianz wird die Assoziation der beiden Zufallsvariablen in Form einer linearen statistischen Abhängigkeit dargestellt. [Bro+15]

$$cov(X, Y) = E[(X - E(X)) \cdot (Y - E(Y))] \quad (2.11)$$

Korrelationskoeffizient: Korrelation bezeichnet eine assoziative Beziehung zwischen Zufallsvariablen. Diese kann, muss aber nicht kausal sein, siehe Abschnitt 2.2. Als Korrelationskoeffizient $corr(X, Y)$ zweier Zufallsvariablen wird die mit der Standardabweichung normierte Kovarianz bezeichnet, siehe Gleichung 2.12. Dabei werden X und Y als unkorreliert bezeichnet bei $corr(X, Y) = 0$, eine starke positive Korrelation beschreibt $corr(X, Y) = 1$ und eine starke negative Korrelation $corr(X, Y) = -1$. Statistisch unabhängige Variablen ($X \perp\!\!\!\perp Y$) sind unkorreliert, während eine statistische Abhängigkeit durch $X \not\perp\!\!\!\perp Y$ ausgedrückt wird. Die bedingte Unabhängigkeit beschreibt die Unabhängigkeit zweier Variablen X und Y unter der Bedingung einer dritten Variablen Z , d. h. $X \perp\!\!\!\perp Y \mid Z$. [Bro+15; HS20; GBC16]

$$corr(X, Y) = \frac{cov(X, Y)}{\sigma_X \cdot \sigma_Y}; \quad corr(X, Y) \in [-1, \dots, 1] \quad (2.12)$$

Statistische Inferenz: Die Statistische-Inferenz beschäftigt sich mit Schlussfolgerungen von der Stichprobe auf die theoretischen Eigenschaften der Grundgesamtheit und vice versa [Wal15; HS20]. Der Schluss von der Grundgesamtheit (dem Allgemeinen) auf die Stichprobe (dem Besonderen) wird als Deduktion oder Reasoning bezeichnet. Umgekehrt wird von Induktion oder Learning gesprochen.

Punkt-, Intervallschätzung: In der Punktschätzung wird mit der Schätzfunktion ein skalarer Parameter bzw. eine skalare Maßzahl geschätzt. Im Vergleich ordnet die Schätzfunktion einer Intervallschätzung dem Parameter/der Maßzahl einen Bereich zu, d. h. eine Menge möglicher Werte. [HS20; Bro+15].

Konfidenzintervall: Konfidenzintervalle (Vertrauensbereiche) sind Intervallschätzer, mit denen Unsicherheiten der Stichprobe angegeben werden. Dabei gibt das Konfidenzintervall den Bereich an, der den Parameter/die Maßzahl mit einer gewissen Wahrscheinlichkeit P_A einschließt. In anderen Worten beschreibt das Konfidenzintervall einen Bereich, in dem der wahre Parameter mit einer Wahrscheinlichkeit von P_A liegt. In der Frequentistik ist der Stichprobenumfang N ein wesentlicher Faktor zur Schätzung der Konfidenzintervalle und die Intervalle werden präziser mit steigendem Stichprobenumfang. [Goe+17; HS20]

Vorhersageintervall: Vorhersageintervalle beschreiben Unsicherheiten in der Vorhersage von abhängigen Variablen. Dabei geben sie mit einer Wahrscheinlichkeit P_A ein Intervall an, dass die Beobachtung einschließt. Dies kann beispielsweise die Schätzung der Beobachtung zum Zeitpunkt der nächsten Messung sein. In diesem Fall werden die Intervalle unpräziser umso weiter die Beobachtung in der Zukunft liegt. [Goe+17; MR12]

Monte-Carlo-Simulation: Die Monte-Carlo-Simulation (MCS) ist ein numerisches Verfahren der Stochastik zur Lösung analytischer Problemstellungen, die sonst nicht oder nur sehr aufwendig lösbar sind. Dabei wird für ein gegebenes Modell eine Ergebnismenge generiert, indem k -Iterationen mit stochastisch verteilten unabhängigen Variablen durchgeführt werden. Der Fehler im Erwartungswert der Ergebnismenge, sinkt nach dem zentralen Grenzwertsatz der Wahrscheinlichkeitsrechnung mit steigender Iterationszahl. [Bro+15; HS20]

Bootstrap-Methode: Bei der Bootstrap-Methode existiert eine Originalstichprobe aus welcher eine oder mehrere Bootstrap-Stichproben durch „zufälliges Ziehen mit Zurücklegen“ gebildet werden. Es wird zwischen parametrischem und nichtparametrischem Bootstrap unterschieden. Während das nichtparametrische Bootstrap eine

Stichprobe nutzt, ist beim parametrischen Bootstrap die Ausgangsbasis eine Verteilungsfunktion. Die im Bootstrap-Resampling gewonnenen k Stichproben lassen sich anschließend beispielsweise zur Schätzung von Konfidenzintervallen nutzen. [HS20]

Kreuzvalidierung: Mit der Kreuzvalidierung werden Testverfahren der Statistik beschrieben, die zur Bewertung des Modellfehlers genutzt werden. Dabei wird die Gesamtstichprobe in eine Trainings-, Validierungs- und Testmenge aufgeteilt. Bei kleinem Stichprobenumfang wird ggf. auf die Testmenge verzichtet. Anhand der Trainingsmenge wird das Modell parametrisiert. Die Validierungsmenge bewertet den Modellfehler an bisher unbekanntem Daten. Im Falle von Algorithmen des Maschinellen Lernens, wiederholen sich Training und Validierung zur Optimierung der Hyperparameter (siehe Abschnitt 2.3.1) des Modells. Anhand der Testmenge wird die Performance abschließend, nach der letzten Hyperparameter Optimierung, bewertet. Die Art und Weise wie die Gesamtstichprobe auf die zwei bzw. drei Mengen verteilt wird, wird als Separierung bezeichnet. Wesentliche Verfahren zur Separierung sind die Randomisierung, das Matching, die Stratifizierung und die Standardisierung. Zu den bekanntesten Verfahren der Kreuzvalidierung gehören Holdout und k -fold ($k \cdot 1$ -fold). Es ist darauf zu achten, dass bei der Aufteilung des Datensatzes keine Stichprobenverzerrung induziert wird. [CT10; HS20]

2.1.3 Ereignis-Zeit-Analyse

Ereignis-Zeit-Analysen bezeichnen eine Reihe von Techniken, die sich mit der Analyse von Daten der Lebensdauer oder anderer Zeit-bis-Ereignis Daten beschäftigen. Die Techniken werden in verschiedenen Disziplinen unter verschiedenen Bezeichnungen eingesetzt. In der Analyse der Lebensdauer technischer Systeme, wird von der Zuverlässigkeitsanalyse gesprochen. Das Ereignis beschreibt hier eine Störung oder einen Ausfall. Der Zeitpunkt des Ereigniseintritts wird daher als Ausfallzeitpunkt bezeichnet. Das Zeitintervall bis zum Ausfall wird als Lebensdauer bezeichnet. Dabei kann die Zeit durch Betriebsstunden, Betriebskilometer, Lastwechsel oder eine andere Größe beschrieben werden. [KI19; BL04]

Ausfall- und Überlebenswahrscheinlichkeit: Bei der Auswertung von Lebensdauerdaten N (allg. Ereignis-Zeit-Daten) mittels Verteilungsfunktion P_N wird von der Ausfallwahrscheinlichkeit F_N gesprochen. Dabei beschreibt die Ausfallwahrscheinlichkeit, die Wahrscheinlichkeit eines Ausfalls über der Zeit. Die Überlebenswahrscheinlichkeit oder Zuverlässigkeit R_N bildet sich komplementär zur Ausfallwahrscheinlichkeit, siehe Gleichung 2.13. Im Vergleich beschreibt sie die Wahrscheinlichkeit, dass ein System zu einem bestimmten Zeitpunkt noch funktionsfähig ist. [BL04]




Bild 2.2 Bivariate Verteilung $p_{X,Y}$ und gesuchter Punkt $X = x^*$ (in Anlehnung an [PJS17]).

$$R_N = 1 - F_N \quad (2.13)$$

Ausfallrate: Mit der Ausfallrate λ_N , auch als Hazardfunktion h_N bezeichnet, wird die Wahrscheinlichkeit bzw. das Risiko eines unmittelbar bevorstehenden Ausfalls beschrieben, wenn der Zeitpunkt $N = n$ bereits erreicht wurde. Die Ausfallrate bildet sich als Quotient aus Dichtefunktion und Zuverlässigkeit nach Gleichung 2.14.

$$\lambda_N = h_N = \frac{f_N}{R_N} \quad (2.14)$$

2.2 Kausale-Inferenz

Aufbauend auf den Grundlagen der Stochastik (Kapitel 2.1) zeigt dieser Abschnitt ein Rahmenwerk zur Beschreibung, Analyse und Inferenz kausaler Beziehungen. Kausale Beziehungen beschreiben dabei Ursache-Effekt Zusammenhänge. Deren Bedeutung sowie die Abgrenzung zur Stochastik soll an einem Beispiel verdeutlicht werden. Gegeben seien zwei (Zufalls-)Variablen X und Y einer ungeplanten Messung (Beobachtungsstudie). Für einen neuen Punkt $X = x^*$ stellt sich die Frage nach dem dazugehörigen Wert y^* , siehe Bild 2.2. In Abhängigkeit der Art der Beziehung zwischen X und Y lässt sich diese Frage unterschiedlich beantworten [PJS17]:

1. Keine Beziehung zwischen X und Y : $y^* = p_Y$
2. Reine Korrelation zwischen X und Y : $y^* = p_{Y|X=x^*}$
3. Kausale Beziehung, mit X ist Ursache von Y : $y^* \approx f(x^*)$
4. Kausale Beziehung, mit Y ist Ursache von X : $y^* = \emptyset$

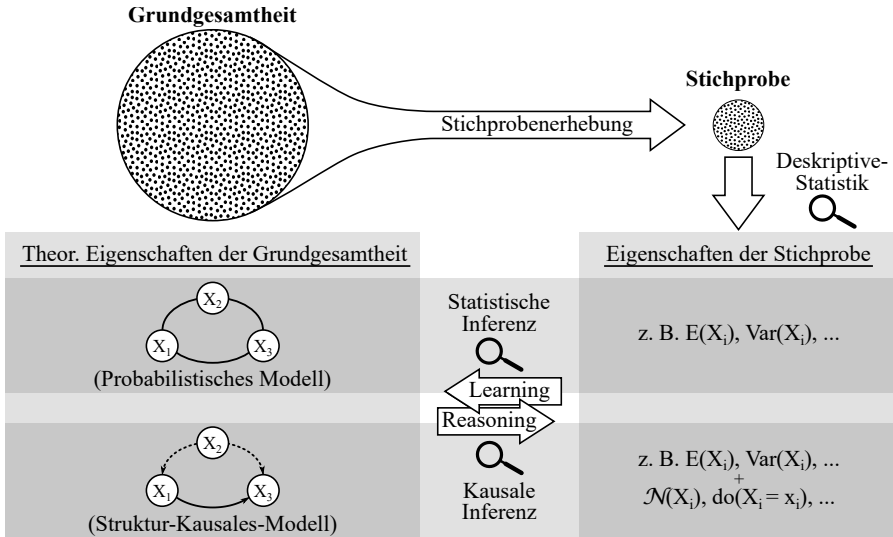



Bild 2.3 Verständnis von Begriffen der Statistik und Kausalität (in Anlehnung an [PJS17; HS20])

Besteht keine Beziehung zwischen den Variablen, dann folgt y^* seiner eigenen univariaten Verteilung p_Y . Im Vergleich, berechnet sich y^* über die bedingte Wahrscheinlichkeit, bei einer rein assoziativen Korrelation. Wenn X Ursache von Y (Effekt) ist, dann führt eine Änderung der Ursache $X = x^*$ zu einer Änderung des Effekts, der dem funktionalen Zusammenhang $f(\cdot)$ folgt. Ist X hingegen der Effekt, so besitzt eine aktive Änderung des Effekts keinen Einfluss auf die Ursache. Die vier Fälle zeigen, dass je nach Art der Beziehung unterschiedliche Interpretationen und unterschiedliche Werte für y^* folgen. Ebenfalls zeigt sich, dass die Frage auf Basis der Stochastik alleine nicht beantwortet werden kann.

Das (randomisierte) kontrollierte Experiment ist der Standard in Wissenschaft und Technik zur Identifikation kausaler Beziehungen. Diese finden beispielsweise in klinischen Studien Anwendung, um die Wirksamkeit einer Behandlung zu bewerten. Ein weiteres Beispiel sind geplante Experimente zur Ermittlung von Degradationsmodellen in der Zuverlässigkeitstechnik. Verschiedene Hilfsmittel wie Randomisierung, Vergleichsgruppen, Placebos etc. dienen dazu Ursache und Effekt von anderen Einflüssen zu isolieren. Bei korrekter Anwendung lassen sich so Ursache-Effekt-Beziehungen bewerten. Oft sind diese Experimente aber sehr teuer oder gar nicht durchführbar. Mit der Kausalen Inferenz ist es möglich Aussagen über kausale Beziehungen in reinen Beobachtungsstudien zu treffen. [Moo+16]

Die Fachdisziplin der Kausalität lässt sich ähnlich der Statistik klassifizieren, siehe Bild 2.3. Dabei beschäftigt sich die Kausale Inferenz mit dem Schluss der Stich-

Graph G :


$$\text{PA}_{X_1}^G : \emptyset; \quad \text{CH}_{X_1}^G : M; \quad \text{DE}_{X_1}^G : M, Y; \quad \text{AN}_{X_1}^G : \emptyset$$

$$\text{PA}_{X_2}^G : \emptyset; \quad \text{CH}_{X_2}^G : M, W; \quad \text{DE}_{X_2}^G : M, Y, W; \quad \text{AN}_{X_2}^G : \emptyset$$

$$\text{PA}_M^G : X_1, X_2; \quad \text{CH}_M^G : Y; \quad \text{DE}_M^G : Y; \quad \text{AN}_M^G : X_1, X_2$$

$$\text{PA}_W^G : X_2; \quad \text{CH}_W^G : \emptyset; \quad \text{DE}_W^G : \emptyset; \quad \text{AN}_W^G : X_2$$

$$\text{PA}_Y^G : M; \quad \text{CH}_Y^G : \emptyset; \quad \text{DE}_Y^G : \emptyset; \quad \text{AN}_Y^G : X_1, X_2, M$$

Bild 2.4 Beispiel DAG. Legende: PA_X^G : Eltern von X in Graph G , CH_X^G : Kinder von X in Graph G , DE_X^G : Nachkommen von X in Graph G , AN_X^G : Vorfahren von X in Graph G .

proben auf die theoretischen Eigenschaften der Grundgesamtheit und vice versa. Je nach Richtung wird zwischen Learning und Reasoning unterschieden. Im folgenden werden einige Grundlagen der Kausalität erläutert. Für weiterführende Themen wird auf die angegebenen Fachliteratur verwiesen (z. B. [Pea09; HB19b; PJS17]). Einige Definitionen sind aus dem Englischen übersetzt, für den korrekten Wortlaut wird ebenfalls auf die Originalliteratur verwiesen.

2.2.1 Gerichtete Azyklische Graphen (DAG)

Gerichtete Azyklische Graphen (DAGs, engl. Directed Acyclic Graphs) bieten eine mathematische Formalisierung zur Beschreibung kausaler Beziehungen. Im DAG wird eine Variable X durch einen Knoten (X) repräsentiert. Kanten verbinden zwei Variablen miteinander $X - Y$. In DAGs sind alle Kanten gerichtet und werden durch Pfeile repräsentiert. Dabei zeigt der Pfeil von der Ursache zum Effekt. Ist X Ursache von Y (Effekt), so lässt sich dies als $X \rightarrow Y$ darstellen. Dem liegt die generelle Ansicht zu Grunde, dass kausale Beziehungen unsymmetrisch sind. Das heißt, wenn X Ursache von Y ist, dann ist X nicht gleichzeitig Ursache von Y . [Pea09; HB19b]

Bild 2.4 zeigt ein Beispiel für einen DAG G . Als Pfad p wird eine Sequenz bezeichnet, die zwei Knoten miteinander verbindet. Im Beispiel ist der Pfad von X_1 zu W die folgende Sequenz $X_1 \rightarrow M \leftarrow X_2 \rightarrow W$. Ein Pfad von einem Knoten zu sich selbst, wird als gerichteter Zyklus oder Feedbackschleife bezeichnet. Diese Art von Pfad ist in DAGs durch die Bedingung der Azyklicität ausgeschlossen. Weitere wichtige Beziehungen im DAG sind Eltern (PA, engl. parents), Kinder (CH, engl. children), Vorfahren (AN, engl. ancestors) und Nachkommen (DE, engl. descendants). Alle genannten Beziehungen gelten innerhalb eines Graphen G und beziehen sich auf einen Knoten, siehe auch Bild 2.4. [KF09]

2.2.2 Struktur-Kausale-Modelle (SCM)

Struktur-Kausale-Modelle (SCMs, engl. Structural Causal Models) bieten eine weitere Möglichkeit zur Beschreibung kausaler Beziehungen. Der Zusammenhang zwischen Ursache X und Effekt Y wird hier über eine nichtparametrische Gleichung der Form $Y = f(X, \epsilon_Y)$ hergestellt. Allgemein folgt für eine beliebige Variable Z die folgende Form $Z = f(\mathbf{PA}_Z^G, \epsilon_Z)$. Dabei stellt $f(\cdot)$ eine beliebige nichtparametrische Funktion und ϵ eine unbeobachtete Störung dar. Alle Störungen innerhalb eines SCM sind voneinander unabhängig, z. B. $\epsilon_X \perp\!\!\!\perp \epsilon_Y$. Für den Beispiel DAG (Bild 2.4) folgt das SCM nach Gleichung 2.15. [PJS17; Pea09]

$$\begin{aligned} X_1 &= f(\epsilon_{X_1}) \\ X_2 &= f(\epsilon_{X_2}) \\ M &= f(X_1, X_2, \epsilon_M) \\ W &= f(X_2, \epsilon_W) \\ Y &= f(M, \epsilon_Y) \end{aligned} \tag{2.15}$$

2.2.3 Kausaler Effekt

In diesem Abschnitt wird das Verständnis einer kausalen Beziehung und die Abgrenzung zu einer rein statistischen Abhängigkeit (assoziative Beziehungen) beschrieben. Eine statistische Abhängigkeit kann über die bedingte Wahrscheinlichkeiten $P_{Y|X=x}$ modelliert und mittels Korrelationskoeffizient quantifiziert werden. Nach Reichenbach [Rei56] und in Anlehnung an Peters et al. [PJS17] gibt es drei Ursachen, die zu einer statistischen Abhängigkeit der Variablen X und Y führen können:

1. X ist (evtl. indirekte) Ursache von Y , sprich $X \rightarrow Y$
2. Y ist (evtl. indirekte) Ursache von X , sprich $Y \rightarrow X$
3. Es existiert eine (evtl. unbeobachtete) gemeinsame Ursache W , die sowohl (evtl. indirekte) Ursache von X als auch von Y ist, sprich $Y \leftarrow W \rightarrow X$

Direkter Effekt vs. Gesamteffekt: Während Eltern $\mathbf{PA}_Y^G = X$ die **direkte Ursache** ihres Kindes Y sind, sind Kinder $\mathbf{CH}_X^G = Y$ der **direkte Effekt** ihrer Eltern X . Neben den direkten Eltern-Kind Pfaden, können aber noch weitere Pfade zwischen den Variablen X und Y bestehen. Beispielsweise kann ein Effekt von X über einen sogenannten Mediator W auf Y ausgeübt werden, sprich $X \rightarrow W \rightarrow Y$. Die Gesamtheit aller Effekte wird als Gesamteffekt bezeichnet. Der direkte Effekt lässt sich beispielsweise extrahieren, indem alle Variablen auf anderen Pfaden konstant gehalten werden. [HS20; Pea09]

Intervention: Mit einer Intervention ist die aktive Beeinflussung einer Variablen gemeint, vergleichbar mit der Manipulation einer Variablen in einem geplanten Experiment. Das heißt es wird aktiv in das System eingegriffen, welches die Daten erzeugt und die Variable gezwungen den gewünschten Wert anzunehmen. Bei einer solchen Intervention wird X vom Einfluss des funktionalen Mechanismus $X = f(\mathbf{PA}_X^G, \epsilon_X)$ getrennt und es folgt $X := x$. Alle anderen Mechanismen bleiben hingegen unberührt. Eine solche Intervention wird als $do(X = x)$ oder kurz $do(x)$ bezeichnet. Dabei ergibt sich ein neues SCM*, welches das Verhalten des Systems unter der Intervention $do(x)$ beschreibt und eine neue Verteilung induziert. Definition 2.2.1 formalisiert die Intervention. [Pea09; PJS17]

Definition 2.2.1 (Kausaler Effekt [Pea09]) *Bei zwei disjunkten Mengen von Variablen, X und Y , ist die kausale Wirkung von X auf Y , entweder als $P_{y|\hat{x}}$ oder als $P_{y|do(X=x)}$ bezeichnet, eine Funktion von X zum Raum der Wahrscheinlichkeitsverteilungen auf Y . Für jede Realisierung x von X gibt $P_{y|\hat{x}}$ die Wahrscheinlichkeit von $Y := y$ an, die sich ergibt, wenn man aus dem Modell (SCM) alle Gleichungen löscht, die der Variablen in X entsprechen und in den verbleibenden Gleichungen $X := x$ einsetzt.*

Kontrafaktische Fragen: Eine kontrafaktische Frage ist ([PJS17]): „Was wäre gewesen, wenn in der Vergangenheit ein anderes Ereignis eingetreten bzw. eine andere Entscheidung getroffen worden wäre?“ Konkret könnte die Frage lauten: „Wäre das System ausgefallen, wenn die Komponente eines anderen Zulieferers verwendet worden wäre?“ Diese Art von Fragen lassen sich unter bestimmten Bedingungen mittels SCM beantworten, werden im Rahmen dieser Arbeit aber nicht weiter behandelt.

Einfache Taxonomie von Modellen: Tabelle 2.1 zeigt eine einfache Taxonomie von Modellen. Ein physikalisches Modell stellt die detaillierteste Form dar, basierend auf dem Verständnis der physikalischen Mechanismen. Mit dieser Art von Modell ist es sowohl möglich eine Prognose unter i. i. d. durchzuführen, eine Intervention zu bestimmen, kontrafaktische Fragen zu beantworten sowie physikalische Einblicke zu gewinnen. Mit rein statistischen Modellen, auf der anderen Seite, kann nur eine Prognose unter i. i. d. Bedingung durchgeführt werden. Im Gegenzug ist es aber auch möglich, das statistische Modell anhand von Daten zu lernen (Maschinelles Lernen). Ob und wie dies mit physikalischen Modellen möglich ist, ist eine offene Frage. SCMs und Kausal-Grafische-Modelle basierend auf DAGs liegen zwischen den beiden erstgenannten Modellen. Dabei erlauben beide eine Prognose von Interventionen und SCMs ebenfalls die Beantwortung kontrafaktischer Fragen. Ob und wie die Modelle anhand von Daten gelernt werden können und ob sie physikalische Einblicke bieten, ist ebenfalls eine offene Frage. [PJS17; Sch19]

Tabelle 2.1 Einfache Taxonomie von Modellen, nach [Sch19; PJS17].

Modell	Prognose unter i.i.d. Bedingung	Prognose einer Intervention	Beantwortung kontrafaktischer Fragen	Erwerb physikal. Einblicke	Lernen von Daten
Physikalisch	✓	✓	✓	✓	?
Struktur-Kausal	✓	✓	✓	?	?
Kausal-Grafisch	✓	✓	✗	?	?
Statistisch	✓	✗	✗	✗	✓

2.2.4 D-Separation und Do-Calculus

D-Separation: Die d-Separation verbindet Graph und bedingte Unabhängigkeit der Statistik. Im Detail, ist ein Pfad $X \rightarrow Y$ blockiert (d-separiert), dann sind die Variablen statistisch unabhängig $X \perp\!\!\!\perp Y$. Blockieren lässt sich ein Pfad von X zu Y über Variablen W , die auf diesem Pfad liegen. Zwei Variablen, die über eine Kante direkt verbunden sind, sind somit immer statistisch abhängig. Die d-Separation im Wortlaut beschreibt Definition 2.2.2: [HB19b]

Definition 2.2.2 (D-Separation [Pea09]) Ein Pfad p gilt als d-separiert (blockiert) durch die Menge von Knoten Z , wenn und nur wenn:

1. p eine Folge $X \rightarrow W \rightarrow Y$ oder eine Gabelung $X \leftarrow W \rightarrow Y$ enthält, sodass der mittlere Knoten W in Z ist, oder
2. p eine Kollision $X \rightarrow W \leftarrow Y$ enthält, sodass der mittlere Knoten W nicht in Z liegt und ebenfalls kein Nachkomme von W in Z liegt.

Eine Menge Z d-separiert X von Y , wenn und nur wenn Z jeden Pfad von einem Knoten in X zu einem Knoten in Y blockiert.

Do-Calculus: Der do-Calculus gibt Inferenzregeln zur Transformation von Verteilungen, die Interventionen und weitere Variablen enthalten. Häufiges Ziel ist, die Interventionsverteilung schrittweise in eine äquivalente Verteilung umzuformen, die ausschließlich Standardwahrscheinlichkeiten enthält und somit mittels Stochastik berechnet werden kann. Ist diese Reduktion möglich, ist der kausale Effekt bestimmbar. Die Regeln des do-Calculus sind durch Theorem 2.2.1 gegeben:

Theorem 2.2.1 (Regeln des do-Calculus [Pea09]) G sei ein gerichteter azyklischer Graph, der mit einem [Struktur]-Kausalen-Modell [...] assoziiert ist und $P_{\{ \cdot \}}$ sei die

Wahrscheinlichkeitsverteilung, die durch dieses Modell induziert wird. Für beliebige disjunkte Teilmengen der Variablen X , Y , Z und W gelten die folgenden Regeln.

Regel 1 (Einfügen/Löschen von Beobachtungen):

$$P_{y|do(x),z,w} = P_{y|do(x),w} \quad \text{if } (Y \perp\!\!\!\perp Z \mid X, W)_{G_{\overline{X}}} \quad (2.16)$$

Regel 2 (Interventions-/Beobachtungsaustausch):

$$P_{y|do(x),do(z),w} = P_{y|do(x),z,w} \quad \text{if } (Y \perp\!\!\!\perp Z \mid X, W)_{G_{\overline{XZ}}} \quad (2.17)$$

Regel 3 (Einfügen/Löschen von Interventionen):

$$P_{y|do(x),do(z),w} = P_{y|do(x),w} \quad \text{if } (Y \perp\!\!\!\perp Z \mid X, W)_{G_{\overline{XZ}(W)}} \quad (2.18)$$

wobei $Z(W)$ die Menge der Z -Knoten sind, die keine Vorfahren von irgendeinem W -Knoten in $G_{\overline{X}}$ sind.

Dabei kennzeichnet $G_{\overline{X}}$ den Graphen der folgt, wenn in G alle Kanten gelöscht werden, die in X gerichtet sind ($\rightarrow X \leftarrow$). Im Vergleich kennzeichnet $G_{\underline{X}}$ den Graphen der folgt, wenn in G alle Kanten gelöscht werden, die von X ausgehen ($\leftarrow X \rightarrow$). [Pea09]

Backdoor- und Frontdoor-Kriterium: Backdoor- und Frontdoor-Kriterium beschreiben zwei häufig auftretende Spezialfälle, abgeleitet aus den allgemeinen Regeln des do-Calculus. Trifft das jeweilige Kriterium zu, ist der kausale Effekt identifizierbar und kann mittels allgemeiner Gleichung bestimmt werden. Wichtiges Instrument dieser Gleichung ist das Einstellset (engl. Adjustmentset), welches über die enthaltenen Größen konditioniert. Im Folgenden sind die Definitionen und die Gleichungen für Backdoor- und Frontdoor-Kriterium gegeben:

Definition 2.2.3 (Backdoor-Kriterium [PGJ16]) Bei einem geordneten Paar von Variablen (X, Y) in einem gerichteten azyklischen Graphen G erfüllt eine Menge von Variablen Z das Backdoor-Kriterium in Bezug auf (X, Y) , wenn kein Knoten in Z ein Nachkomme von X ist und Z jeden Pfad zwischen X und Y blockiert, der einen Pfeil in X enthält.

$$P_{y|do(x)} = \sum_z P_{y|x,z} P_z \quad (2.19)$$

Definition 2.2.4 (Frontdoor-Kriterium [PGJ16]) Eine Menge von Variablen Z erfüllt das Frontdoor-Kriterium in Bezug auf ein geordnetes Paar von Variablen (X, Y) , wenn:

1. Z alle gerichteten Pfade von X nach Y unterbricht.
2. Es keinen unblockierten Pfad von X nach Z gibt.
3. Alle Backdoor-Pfade von Z nach Y durch X blockiert werden.

Theorem 2.2.2 (Frontdoor-Adjustment [PGJ16]) Wenn Z das Frontdoor-Kriterium relativ zu (X, Y) erfüllt und wenn $P_{X,Y} > 0$ ist, dann ist der kausale Effekt von X auf Y identifizierbar und gegeben durch folgende Gleichung:

$$P_{y|do(x)} = \sum_z P_{z|x} \sum_{x'} P_{y|z,x'} P_{x'} \quad (2.20)$$

2.3 Maschinelles Lernen

Maschinelles Lernen (ML) ist ein Teilgebiet der Künstlichen Intelligenz (KI). Ziel ist das Lernen eines statistischen Modells, alleine auf Basis der Daten, ohne explizite Programmierung. Es werden drei Arten des Lernens unterschieden:

- **Supervised Learning** (dt. Überwachtes Lernen): Der Algorithmus lernt die Abbildung des gegebenen Inputs X auf den gegebenen Output Y , sprich den Zusammenhang $Y = h(X, \theta)$.¹
- **Unsupervised Learning** (dt. Unüberwachtes Lernen): Anhand des gegebenen Inputs X lernt der Algorithmus selbst, verborgene und relevante Muster zu erkennen. Ein Output Y der diese Muster beschreibt, ist nicht gegeben.
- **Reinforcement Learning** (dt. Bestärkendes Lernen): Ein Agent interagiert mit seiner Umwelt und lernt eine Strategie, anhand der er Aktionen trifft. Dabei ist sein Ziel, die für seine Aktionen erhaltene Belohnung zu maximieren.

Neben den drei genannten Arten gibt es noch Mischformen und hybride Ansätze, wie das Semi-Supervised Learning. Das Lernen eines Modells wird auch als Training(sphase) oder Lernphase bezeichnet. An dessen Ende steht ein Modell $h(\cdot, \theta)$, das innerhalb des Trainings parametrisiert wird. Mit diesem Modell können anschließende neue bisher unbekannte Daten X^* bewertet und der zugehörige Output Y^* vorhergesagt werden. Nach Mitchell [Mit97] kann das Lernen wie folgt beschrieben werden: „Ein Computerprogramm lernt aus Erfahrung E , in Bezug auf eine Klasse von Aufgaben T und die Leistungskennzahl P , wenn sich seine Leistung in der Lösung der Aufgaben in T , gemessen an P , mit der Erfahrung E verbessert“. ML ist der Teilbereich der KI, in welchem die Erfahrung aus Daten besteht. Aufgaben und Leistungskennzahlen werden in den folgenden Abschnitten diskutiert, bevor Künstliche Neuronale Netze vorgestellt werden.

¹Outputs werden ebenfalls als Label, abhängige Variable oder Zielvariable bezeichnet. Der Parameter θ beschreibt die Parametrisierung des Modells.

2.3.1 Terminologie

Deep Learning bezeichnet einen Teilbereich des ML. Dabei lernt der Computer komplexe Abbildungen aus der Kombination vieler einfacherer Abbildungen. Ein Künstliches Neuronales Netz kombiniert im Deep Learning dazu eine Vielzahl an Layern. [GBC16]

Das **Shallow Learning** bezeichnet häufig den komplementären Teilbereich zum Deep Learning im ML [GBC16].

Daten lassen sich in **strukturiert und unstrukturiert** unterscheiden [GBC16]. Als strukturierte Daten werden solche bezeichnet, die sich in Form einer Tabelle darstellen lassen, beispielsweise einer Excel-Tabelle oder in SQL-Datenbanken. Solche Daten lassen sich i. d. R. vom Mensch ohne Konvertierung interpretieren. Im Vergleich, werden als unstrukturierte Daten solche bezeichnet, die ohne Konvertierung kaum interpretierbar sind, beispielsweise RGB-Werte eines Bildes oder Schwingungen einer Tonaufnahme.

Hyperparameter beschreiben eine Kategorie von Modellparametern, welche den Lernvorgang beeinflussen, selbst aber über die Lernphase unverändert bleiben. Je nach Algorithmus variieren Art und Anzahl der jeweiligen Hyperparameter. Ein häufiger Hyperparameter ist die Lernrate α , die bestimmt wie groß die Schritte beim Lernvorgang sind. Es ist vor dem Beginn des Lernprozesses nicht bekannt, mit welcher Kombination von Hyperparametern ein gutes Modell erreicht werden kann. [GBC16]

Ein **Epoch** bezeichnet einen Durchlauf des im Training verwendeten gesamten Datensatzes. Häufig wird ein Datensatz im Lernvorgang mehrmals durchlaufen, was über die Anzahl der Epochs beschrieben wird. [GBC16]

Die Größe des **Batch** gibt an, wie viele Instanzen $(x^{(i)}, y^{(i)})$ durchlaufen werden, bevor das Modell neu parametrisiert wird. [GBC16]

Mit **Bias** und **Varianz** werden zwei Fehlerquellen im ML bezeichnet, die häufig in Wechselwirkung stehen. Dabei bezeichnet Bias eine Unteranpassung (engl. Underfitting) des Modells an die Daten, beispielsweise bei Verwendung eines linearen Modells zur Schätzung eines quadratischen Zusammenhangs. Varianz bezeichnet die Überanpassung (engl. Overfitting) des Modells an die Daten, beispielsweise bei Verwendung eines höher polynomischen Modells bei einem linearen Zusammenhang. In diesem Fall lernt das Modell nicht nur den gesuchten linearen Zusammenhang, sondern ebenfalls unerwünschte Effekte, wie zufälliges Rauschen. [GBC16]

2.3.2 Aufgaben

Im ML bzw. im weiteren Kontext des Data-Mining gibt es eine Vielzahl von Aufgaben. Im Folgenden werden einige wichtige Aufgaben im Kontext dieser Arbeit vorgestellt. In Anlehnung an Murphy [Mur12] und Goodfellow et al. [GBC16] können diese wie folgt kategorisiert werden:

- **Regression:** Ziel der Regression ist die Abbildung des Inputs \mathbf{x} auf einen stetigen (kontinuierlichen) Output $y \in \mathbb{R}$. Diese Aufgabe wird dem Supervised Learning zugeordnet.
- **Klassifikation:** Im Vergleich zur Regression ist das Ziel der Klassifikation die Abbildung auf einen diskreten Output $y \in [1, \dots, C]$, mit der Klassenanzahl C . Bei zwei Klassen wird von Binärer-Klassifikation gesprochen und bei mehr als zwei Klassen von der Mehrklassen-Klassifikation. Diese Aufgabe gehört ebenfalls dem Supervised Learning an.
- **Clustering:** Ziel des Clustering ist die Einteilung der Daten in diskrete Gruppen. Im Vergleich zur Klassifikation sind die Gruppen nicht gegeben. Die Gruppen müssen daher anhand der Eigenschaften der gegebenen Daten \mathbf{x} „entdeckt“ werden. Diese Aufgabe wird dem Unsupervised Learning zugeordnet.
- **Dimensionalitätsreduktion:** Das Ziel der Dimensionalitätsreduktion ist es, einen Vektor $\mathbf{x} \in \mathbb{R}^n$ in einen Vektor $\mathbf{x} \in \mathbb{R}^k$ mit $k < n$ zu projizieren. Dabei werden die Daten komprimiert bzw. die Informationsdichte erhöht. Diese Aufgabe gehört ebenfalls dem Unsupervised Learning an.
- **Graphenstruktur aufdecken:** Das Ziel dieser Aufgabe ist es, Eigenschaften der Daten in Form von Graphen darzustellen. Beispielsweise das Lernen eines DAG oder die Abbildung korrelierter Variablen in einem Graph. Diese Aufgabe ist ebenfalls Teil des Unsupervised Learning.
- **Transkription:** Das Ziel der Transkription ist die Umformung der Daten in ein anderes standardisiertes Format. Beispielsweise die Umformung von unstrukturierten Audiodateien in Textform.
- **Maschinelle Übersetzung:** Das Ziel der maschinellen Übersetzung ist es, einen funktionalen Zusammenhang zwischen einem strukturierten Input und einem strukturierten Output zu erlernen. Beispielsweise die Übersetzung von einer in eine andere Sprache.
- **Strukturierter Output:** Diese Aufgabe umfasst Transkription, Maschinelle Übersetzung und Weitere. Das Ziel ist ein Outputvektor \mathbf{y} , wobei die einzelnen Elemente y in wichtiger Beziehung zueinander stehen.

- **Anomalie Detektion:** Das Ziel der Anomalie Detektion ist es, unübliche oder atypische Muster in den Daten zu finden. Zur weiteren Typisierung siehe Abschnitt 4.3.3 bzw. [CBK09].
- **Synthese und Sampling:** Das Ziel dieser Aufgabe ist es, neue Instanzen der Daten zu erzeugen, die ähnlich den Trainingsdaten sind. Dabei gibt es keinen einzelnen korrekten Output bei gegebenem Input.
- **Imputation von fehlenden Werten:** Das Ziel dieses Algorithmus ist es für eine Instanz $\mathbf{x}^{(i)} \in \mathbb{R}^n$ eine Vorhersage der fehlenden Werte $x_j^{(i)}$ zu treffen.
- **Denoising:** Das Ziel im Denoising (dt. Entrauschung) ist es, aus einem verrauschten Input $\tilde{\mathbf{x}} = f(\mathbf{x}, \epsilon)$ den unverrauschten Vektor \mathbf{x} zu reproduzieren.
- **Prognose:** Das Ziel der Prognose ist die Vorhersage des zukünftigen Verlaufs einer Variablen $y \in \mathbb{R}$ bzw. des Eintrittszeitpunkts eines Ereignisses $y = 1$. Hierbei handelt es sich um einen strukturierten Output. Zur weiteren Typisierung siehe Abschnitt 4.3.4 bzw. [Box+16; Goe+17].

2.3.3 Leistungskennzahlen

Ein Algorithmus lernt, wenn die Leistung in der Lösung der Aufgabe, gemessen anhand einer Leistungskennzahl, mit steigender Erfahrung zunimmt ([Mit97]). Die Vielzahl an Aufgaben (vorheriger Abschnitt), die Vielzahl an Algorithmen und die unterschiedlichen Daten sind drei Gründe, weshalb es ebenfalls eine Vielzahl an Leistungskennzahlen gibt. Dabei ist die Leistungskennzahl entscheidend, da sie die Zielfunktion der Optimierung definiert. In Anlehnung an [HS20; GBC16; Goe+17] werden im folgenden einige wichtige empirische Leistungskennzahlen vorgestellt. Dabei entspricht y dem wahren Wert, \hat{y} dem geschätzten Wert und n der Anzahl an Elementen.

Mean Absolute Error (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| \hat{y}^{(i)} - y^{(i)} \right| \quad (2.21)$$

Mean Absolute Percentage Error (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}^{(i)} - y^{(i)}}{y^{(i)}} \right| \quad (2.22)$$

Mean Squared Error (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}^{(i)} - y^{(i)})^2 \quad (2.23)$$

Root Mean Squared Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}^{(i)} - y^{(i)})^2} \quad (2.24)$$

Bestimmtheitsmaß (R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}^{(i)} - y^{(i)})^2}{\sum_{i=1}^n (y_m - y^{(i)})^2} \quad (2.25)$$

Prognostic Horizon (PH): Der PH definiert den Zeitraum $t_E - t_i$, zwischen dem Zeitpunkt der Prognose t_i und einem Event E , an dem der Algorithmus eine definierte Leistungskennzahl erfüllt. Die Leistungskennzahl kann beispielsweise ein bestimmtes Fehlerband, um den wahren Fehlerzeitpunkt t_E sein.

$\alpha - \lambda$ Accuracy: Die $\alpha - \lambda$ Accuracy ist eine binäre Größe, die den Wert 1 annimmt, wenn der Algorithmus zum Prognosezeitpunkt t_i eine Prognosegenauigkeit erreicht, die innerhalb vorgegebener α -Grenzen liegt. Dabei repräsentieren die α -Grenzen eine prozentuale Abweichung von der wahren Zeit bis zum Event t_E . Wird die Prognosegenauigkeit nicht erreicht, nimmt die $\alpha - \lambda$ Accuracy den Wert 0 an.

Relative Accuracy (RA): Im Vergleich zur $\alpha - \lambda$ Accuracy, gibt die RA die Prognosegenauigkeit zum Prognosezeitpunkt t_i direkt an.

Confusion Matrix: Die Confusion Matrix bietet eine Bewertungsbasis der Klassifizierung. Für den binären Fall, ist diese in Tabelle 2.2 dargestellt. Für ein binäres Ereignis ergeben sich vier mögliche Fälle, die als True Positive (TP), False Positive (FP), False Negative (FN) und True Negative (TN) bezeichnet werden. Aus der Confusion Matrix lassen sich eine Reihe von Leistungskennzahlen ableiten, die im Folgenden vorgestellt werden.

Accuracy:

$$Accuracy = \frac{TP + TN}{N} \quad (2.26)$$

Tabelle 2.2 Confusion Matrix binärer Klassen.

		Wahrer Wert y		Total
		Positiv	Negativ	
Geschätzter Wert \hat{y}	Positiv	True Positive (TP)	False Positive (FP)	TP + FP
	Negativ	False Negative (FN)	True Negative (TN)	FN + TN
	Total	TP + FN	FP + TN	N

Precision:

$$Precision = \frac{TP}{TP + FP} \quad (2.27)$$

Recall/True Positive Rate (TPR):

$$Recall = TPR = \frac{TP}{TP + FN} \quad (2.28)$$

Specificity/True Negative Rate (TNR):

$$Specificity = TNR = \frac{TN}{TN + FP} \quad (2.29)$$

False Positive Rate (FPR):

$$FPR = \frac{FP}{FP + TN} \quad (2.30)$$

False Negative Rate (FNR):

$$FNR = \frac{FN}{FN + TP} \quad (2.31)$$

Receiver Operator Curve (ROC): Die ROC trägt die TPR über der TNR auf. Mehrere Wertepaare, d. h. eine Kurve entsteht durch Variation der Entscheidungsebene.

Area Under the Curve (AUC): Die AUC bezeichnet die Fläche unter der ROC. Diese nimmt den Wert 1 an, wenn sich die Klassen durch die Entscheidungsebene vollständig separieren lassen.




Bild 2.5 Darstellung eines Perzeptron.

2.3.4 Künstliche Neuronale Netze (KNN)

Künstliche Neuronale Netze (KNN) bilden einen speziellen Algorithmus im ML. Grundsätzlich werden KNNs weiter in Feedforward Neuronale Netze (FNN), Convolutional Neuronale Netze (CNN) und Recurrent Neuronale Netze (RNN) unterschieden. Im Folgenden wird das FNN weiter erläutert, als Basis für Kapitel 6.

Perzeptron: Den Grundbaustein eines FNN bildet ein einzelnes Perzeptron, siehe Bild 2.5. Dabei ist $\mathbf{x}^{(i)}$ der Inputvektor einer Instanz i mit $i \in [1, \dots, m]$. Die Variablen, auch als Feature bzw. Merkmale bezeichnet, des Inputvektors sind $x_f^{(i)}$; $f \in [1, \dots, n_f]$. Den Output bildet $h_{\mathbf{w},b}(\mathbf{x}^{(i)}) = \hat{y} = f(\mathbf{w}^T \mathbf{x}^{(i)} + b)$. Weitere Elemente sind die Aktivierungsfunktion $f(\cdot)$ die Gewichte \mathbf{w} und der Bias b .

FNN: Ein FNN entsteht durch den Zusammenschluss mehrerer Perzeptren, siehe Bild 2.6. Die horizontale Verknüpfung der Perzeptren wird als Layer (dt. Schichten) bezeichnet und die Anzahl der Perzeptren je Layer als Units (dt. Einheiten). Die Notation der Parameter wird um zwei Symbole ergänzt, die Zuordnung zu einem Layer l hochgestellt in eckigen Klammern sowie die Zuordnung zur Unit u tiefgestellt an zweiter Stelle (z. B. $b_u^{[l]}$, $w_{f,u}^{[l]}$). Im Allgemeinen folgen für einen Layer l mit n_f Inputvariablen (Units des vorherigen Layers $l - 1$) und n_u Units die Parameterdimensionen: $\mathbf{W}^{[l]} \in \mathbb{R}^{n_u \times n_f}$, $\mathbf{A}^{[l-1]} \in \mathbb{R}^{n_f \times m}$ und $\mathbf{b}^{[l]} \in \mathbb{R}^{n_u \times 1}$. Dabei entspricht $\mathbf{A}^{[0]}$ der Inputmatrix \mathbf{X} . Das in Bild 2.6 dargestellte Beispiel besitzt drei Units im sogenannten Input Layer ($l = 0$), zwei im Output Layer sowie zwei Hidden-Layer zwischen Input- und Output-Layer.

Berechnungsgraph: Der Berechnungsgraph (engl. Computational Graph) formalisiert ein KNN als Graph. Das Ziel des Trainings ist es, Gewichte und Bias so zu wählen, dass der Fehler zwischen wahren und geschätztem Wert minimal wird. Im Folgenden wird ein einfaches und vollständig verknüpftes FNN angenommen, wie in Bild 2.6. Zu Beginn einer Berechnung müssen alle Gewichte $\mathbf{W}^{[l]}$ und Bias $\mathbf{b}^{[l]}$ initialisiert werden. Insbesondere bei den Gewichten ist eine geeignete Initialisierung wichtig um die Symmetrie zu brechen. Hierzu werden häufig normalverteilte




Bild 2.6 Feedforward Neuronales Netz.

Zufallszahlen erzeugt. Die eigentliche Berechnung besteht im Wesentlichen aus Forward- und Backward-Propagation. In der Forward-Propagation wird für einen Input \mathbf{X} der Output $h_{\mathbf{W},\mathbf{b}}(\mathbf{X})$ berechnet, siehe Gleichung 2.32. Die Abweichung zwischen wahrem Wert $\mathbf{y}^{(i)}$ und berechnetem Output $\hat{\mathbf{y}}^{(i)} = h_{\mathbf{W},\mathbf{b}}(\mathbf{x}^{(i)})$ wird in Form der Verlustfunktion (engl. Loss-Function) $\mathbb{L}(\hat{\mathbf{y}}^{(i)}, \mathbf{y}^{(i)})$ berechnet. Hier eignen sich beispielsweise bestimmte Leistungskennzahlen, wie MSE oder Kreuzentropie. Die Performance über einen Batch der Größe m wird mittels Kostenfunktion (engl. Cost-Function) $J_{\mathbf{W},\mathbf{b}}$ bewertet, bspw. als arithmetisches Mittel wie in Gleichung 2.33. Neben dem Teil der Verlustfunktion kann die Kostenfunktion, um Terme der Regularisierung ergänzt werden, die beispielsweise einer hohen Varianz entgegenwirken. Solche Modifikationen wirken sich entsprechend auf die folgenden Schritte der Back-Propagation aus. Ziel der Back-Propagation ist die Identifikation optimaler Parameter \mathbf{W} und \mathbf{b} , um den Fehler bzw. die Kostenfunktion zu minimieren. Hierfür kann das Gradientenverfahren genutzt werden, das ausgehend vom Gradienten des Outputlayers $\nabla J_{\mathbf{W},\mathbf{b}}$ in Kombination mit der Kettenregel die Berechnung der Gradienten aller Gewichte und Bias erlaubt. Im Update werden die Gewichte und der Bias mittels der berechneten Gradienten aktualisiert, siehe Gleichung 2.34. Dabei ist α der Hyperparameter Lernrate, der die Größe der Update Schritte definiert. Forward- und Backward-Propagation werden i. d. R. über mehrere Batch und Epochs durchlaufen, bis der Algorithmus die gewünschte Performance erreicht oder der Lernvorgang abgebrochen wird. [GBC16; Mur12; HS20]

$$h_{\mathbf{W},\mathbf{b}}(\mathbf{X}) = f^{[n_l]} \left(\dots \left(f^{[1]} \left(\mathbf{W}^{[1]} \mathbf{X} + \mathbf{b}^{[1]} \right) \right) \right) \quad (2.32)$$

$$J_{\mathbf{w}, \mathbf{b}} = \frac{1}{m} \sum_{i=1}^m \mathbb{L}(\hat{\mathbf{y}}^{(i)}, \mathbf{y}^{(i)}) \quad (2.33)$$

$$\begin{aligned} \mathbf{W}^{[l]} &:= \mathbf{W}^{[l]} - \alpha \nabla_{\mathbf{W}^{[l]}} J \\ \mathbf{b}^{[l]} &:= \mathbf{b}^{[l]} - \alpha \nabla_{\mathbf{b}^{[l]}} J \end{aligned} \quad (2.34)$$

Aktivierungsfunktion: Die Aktivierungsfunktionen $f(\cdot)$ bestimmt die Abbildung des Inputs auf den Output, siehe Gleichung 2.32. Ohne Aktivierungsfunktion folgt für das Perzeptron $h_{\mathbf{w}, b}(\mathbf{x}^{(i)}) = \mathbf{w}^T \mathbf{x}^{(i)} + b$, das heißt eine lineare Abbildung. Erst durch Wahl einer entsprechenden Aktivierungsfunktion wird die Abbildung nichtlinear und im FNN werden beliebig komplexe Abbildungen möglich. Prinzipiell eignet sich jede Abbildung, welche die Bedingung $f(\cdot) : \mathbb{R} \mapsto \mathbb{R}$ erfüllt. Die Wahl besitzt aber einen Einfluss auf die Forward- als auch die Backward-Propagation. Im Gradientenverfahren bestimmt die erste Ableitung der Aktivierungsfunktion den Gradienten und somit das Training des FNN. Wichtige Aktivierungsfunktionen sind die Lineare (Gleichung 2.35), die Sigmoid (Gleichung 2.36), der Tangens hyperbolicus (Gleichung 2.37), die Rectified Linear Unit (ReLU, Gleichung 2.38) und Softmax (Gleichung 2.39). [GBC16]

$$f(z) = cz \quad (2.35)$$

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2.36)$$

$$f(z) = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.37)$$

$$f(z) = \begin{cases} z & \text{für } z > 0 \\ 0 & \text{für } z < 0 \end{cases} \quad (2.38)$$

$$f(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{j=1}^{n_j} e^{z_n}} \text{ für } j = 1, \dots, n_j \quad (2.39)$$

2.4 Zuverlässigkeitstechnik

Die Zuverlässigkeitstechnik befasst sich mit der Zuverlässigkeit von technischen Systemen und Komponenten (Teilsysteme). Bertsche und Lechner [BL04] definiert Zuverlässigkeit als „die Wahrscheinlichkeit dafür, dass ein Produkt während einer definierten Zeitdauer unter gegebenen Funktions- und Umgebungsbedingungen nicht

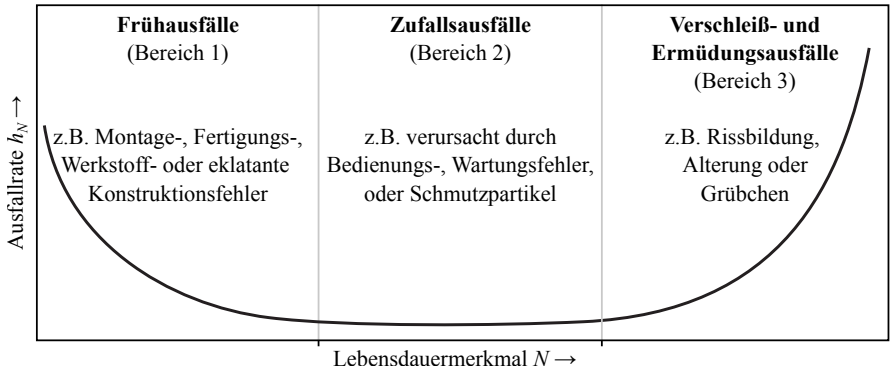


Bild 2.7 Badewannenkurve der Zuverlässigkeitstechnik (in Anlehnung an [BL04]).

ausfällt“. Auf der Zuverlässigkeit aufbauende und angrenzende Themen sind die Verfügbarkeit, Instandhaltbarkeit und Sicherheit. Um die Zuverlässigkeit eines Systems analysieren, planen und sicherstellen zu können, bedient sich die Zuverlässigkeitstechnik einer Reihe quantitativer und qualitativer Methoden, in allen Phasen des Produktlebenszyklus.

Ausfall: Ein Ausfall beschreibt den Zeitpunkt, an dem das System die von ihm geforderte Funktion nicht mehr erfüllt. Dabei charakterisiert die Ausfallart Symptome, unter denen der Ausfall beobachtet wird, beispielsweise Sprödbbruch oder Verschleiß. Die Ausfallursache wird in intrinsisch (z. B. Materialermüdung, Rissbildung) und extrinsisch (Fehler in Montage oder Bedienung) unterteilt. Als Ausfallmechanismus werden physikalische, chemische oder andere Prozesse bezeichnet, welche zum Ausfall führen. Mit der Ausfallfolge (Ausfallwirkung) werden die Effekte des Ausfalls auf das Gesamtsystem und dessen Umgebung bezeichnet. [Bir17]

Ausfallverhalten: Das Ausfallverhalten von Komponenten und Systemen kann mittels Ereignis-Zeit-Analyse (Abschnitt 2.1.3) quantitativ beschrieben werden. Dabei wird zwischen der Komponentenzuverlässigkeit und der Systemzuverlässigkeit unterschieden. Zweitere bildet sich aus den Zuverlässigkeiten ihrer Komponenten und kann beispielsweise mit der Systemtheorie nach Boole berechnet werden [BL04]. Typische Verteilungsfunktionen zur Beschreibung des Ausfallverhaltens zeigt Abschnitt 2.4.1.

Badewannenkurve: Die Badewannenkurve der Zuverlässigkeitstechnik charakterisiert drei Arten von Ausfallverhalten, Bild 2.7. Hier wird die Ausfallrate h_N über

dem Lebensdauermerkmal N aufgetragen. Den ersten Bereich bilden die Frühausfälle, der durch ein abnehmendes Ausfallrisiko charakterisiert wird. Dieses Ausfallverhalten lässt sich beispielsweise auf Montage-, Fertigungs-, Werkstoff- oder schwerwiegende Konstruktionsfehler zurückführen. Zufallsausfälle bilden den mittleren Bereich der Badewannenkurve, gekennzeichnet durch ein konstantes Ausfallrisiko. Ursachen sind z. B. Bedien-, Wartungsfehler oder Umwelteinflüsse wie Verschmutzung. Den dritten Bereich bilden die Verschleiß- und Ermüdungsausfälle, mit einem stetig steigenden Ausfallrisiko. Hierunter fallen typischerweise intrinsische Ausfallursachen, wie Rissbildung, Alterung, oder Grübchen. [BL04]

2.4.1 Lebensdauerverteilungen

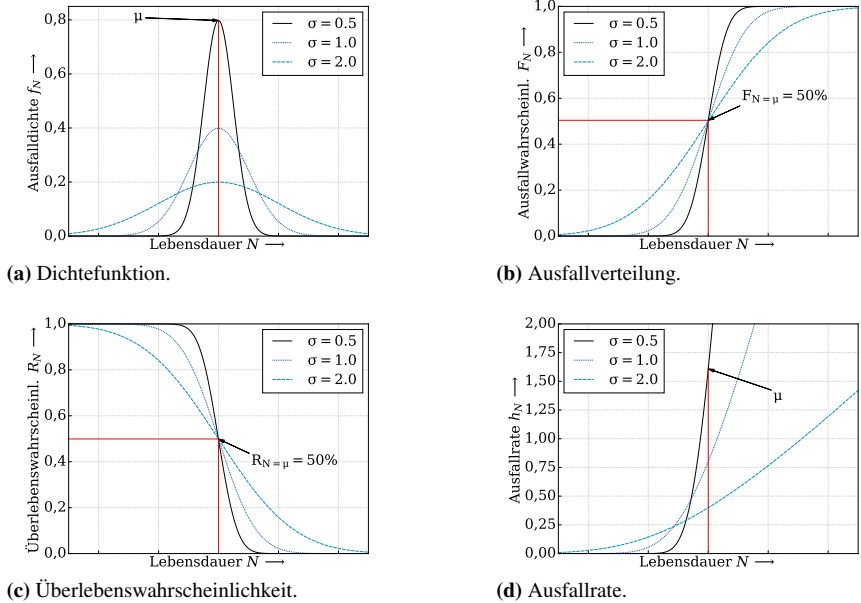
Lebensdauerverteilungen modellieren das Ausfallverhalten einer Stichprobe ausgefallener Systeme oder Komponenten. Häufig werden diese zur Beurteilung des Ausfallverhaltens der Grundgesamtheit herangezogen, beispielsweise zur Abschätzung von Garantie und Kulanz. Wichtige stetige Verteilungsfunktionen in der technischen Zuverlässigkeit sind die Normal- (Gauß-), Exponential-, Weibull- und die logarithmische Normalverteilung [BL04]. Im Rahmen dieser Arbeit werden Normal- und Weibullverteilung genutzt und im folgenden kurz vorgestellt:

Normalverteilung: Die univariate Normalverteilung wird charakterisiert durch Erwartungswert μ und Varianz σ^2 , auch geschrieben als $\mathcal{N}(\mu, \sigma^2)$. In Statistik und Maschinellem Lernen ist die Normalverteilung die am häufigsten genutzte Verteilung [Mur12]. Ein Grund ist, dass aus der Summe vieler unabhängig und beliebig verteilter Variablen gleicher Größenordnung eine Normalverteilung folgt [HS20]. Dichtefunktion (Gleichung 2.40), Ausfallverteilung (Gleichung 2.41), Überlebenswahrscheinlichkeit (Gleichung 2.42) und Ausfallrate (Gleichung 2.14) werden durch die angegebenen Gleichungen charakterisiert ([HS20; BL04]) und sind für verschiedene Varianzen in Bild 2.8 dargestellt.

$$f_N = \frac{1}{\sigma\sqrt{2\pi}} \cdot \exp\left(-\frac{(N - \mu)^2}{2\sigma^2}\right) \quad (2.40)$$

$$F_N = \frac{1}{\sigma\sqrt{2\pi}} \cdot \int_0^N \exp\left(-\frac{(\tau - \mu)^2}{2\sigma^2}\right) d\tau \quad (2.41)$$

$$R_N = \frac{1}{\sigma\sqrt{2\pi}} \cdot \int_N^\infty \exp\left(-\frac{(\tau - \mu)^2}{2\sigma^2}\right) d\tau \quad (2.42)$$


Bild 2.8 Normalverteilung

Weibullverteilung: Charakteristische Lebensdauer T (Lageparameter), Formparameter b sowie die ausfallfreie Zeit N_0 beschreiben die univariate dreiparametrische Weibullverteilung, auch als $Wbl(T, b, N_0)$ geschrieben. Dabei verschiebt die ausfallfreie Zeit die gesamte Verteilung entlang der Lebensdauerachse. Gibt es keine ausfallfreie Zeit, d. h. $N_0 = 0$, folgt die zweiparametrische Weibullverteilung $Wbl(T, b)$. Dichtefunktion (Gleichung 2.43), Ausfallverteilung (Gleichung 2.44), Überlebenswahrscheinlichkeit (Gleichung 2.45) und Ausfallrate (Gleichung 2.46) werden durch die angegebenen Gleichungen charakterisiert ([BL04]) und sind für verschiedene Formparameter in Bild 2.9 dargestellt.

$$f_N = \frac{b}{T - N_0} \cdot \left(\frac{N - N_0}{T - N_0} \right)^{b-1} \cdot \exp \left(- \left(\frac{N - N_0}{T - N_0} \right)^b \right) \quad (2.43)$$

$$F_N = 1 - \exp \left(- \left(\frac{N - N_0}{T - N_0} \right)^b \right) \quad (2.44)$$

$$R_N = \exp \left(- \left(\frac{N - N_0}{T - N_0} \right)^b \right) \quad (2.45)$$

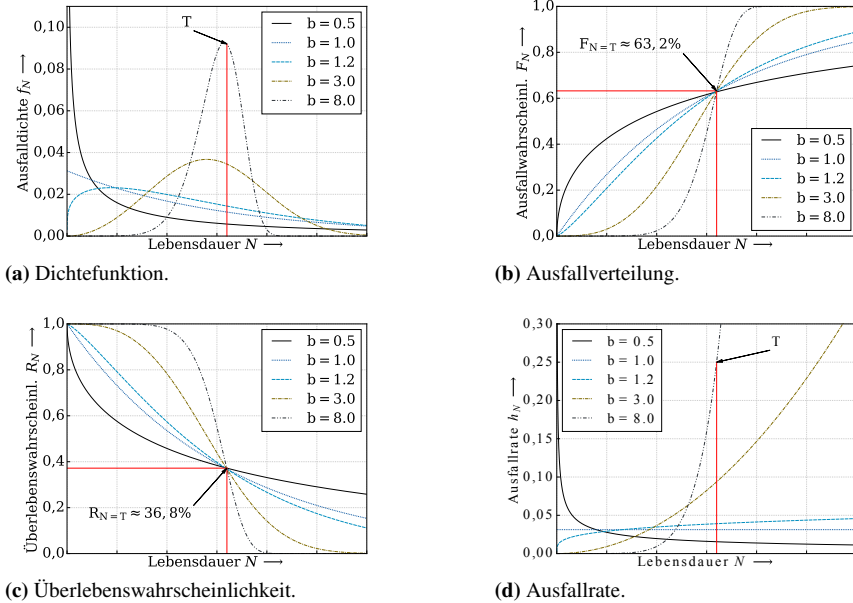


Bild 2.9 Weibullverteilung

$$h_N = \frac{b}{T - N_0} \cdot \left(\frac{N - N_0}{T - N_0} \right)^{b-1} \quad (2.46)$$

In Abhängigkeit des Formparameters b können mit der Weibullverteilung alle drei Arten des Ausfallverhaltens beschrieben werden. Bezüglich der Badewannenkurve folgt mit $b < 1$ Bereich 1, mit $b = 1$ Bereich 2 und mit $b > 1$ Bereich 3. Die wahrscheinlichkeitstheoretische Begründung der Weibullverteilung beschreibt „eine asymptotische Extremwertverteilung der kleinsten (ersten) Ranggröße einer Stichprobe vom Umfang N_S , falls N_S sehr groß wird ($N_S \rightarrow \infty$)“ [BL04]. In anderen Worten beschreibt die Weibullverteilung ein Verhalten, bei dem der Ausfall eintritt, wenn das schwächste Glied versagt. Sowohl die Flexibilität der Verteilungsfunktion, als auch die wahrscheinlichkeitstheoretische Begründung sind Ursache, für die häufige Nutzung der Weibullverteilung in der Zuverlässigkeitstechnik. [BL04]

2.4.2 Lebensdauer- und Degradationsmodelle

Im Rahmen dieser Arbeit wird die folgende Unterscheidung zwischen Degradations- und Lebensdauermodellen getroffen.

Degradationsmodelle: Mit einem Degradationsmodell wird ein Schadensmechanismus modelliert. Genauso wie es eine Vielzahl an Schadensmechanismen gibt, gibt es auch eine Vielzahl an Degradationsmodellen. Mit dem Degradationsmodell kann der Degradationspfad über der Lebensdauer N dargestellt werden. Auf der Ordinate wird die gesuchte Degradationsgröße oder allgemein der Schaden D (engl. Damage) aufgetragen. Die Degradation startet bei Initialwerten (N_0, D_0) , die beide nicht zwingend mit dem absoluten Nullpunkt $(N = 0, D = 0)$ zusammenfallen. Von einem Ausfall wird gesprochen, wenn der Degradationspfad ein EOL-Kriterium (End of Life Kriterium) erreicht. Meeker und Escobar [ME98] unterscheiden weiter in physikalische und Performance Degradation. Dabei ist der Effekt bei physikalischer Degradation direkt messbar, beispielsweise Verschleiß, Risslänge oder Korrosion. Bei der Performance Degradation ist der Effekt nicht direkt messbar, hier wird beispielsweise der Leistungsoutput oder die Spannung als Ersatzgröße genutzt. Neben den genannten, besitzt das Modell weitere Modellparameter θ , wie Belastungsgrößen, Materialkennwerte oder Geometriefaktoren. Ein deterministisches Degradationsmodell beschreibt somit den funktionalen Zusammenhang $D = f(N; \theta)$.

Lebensdauermodelle: Lebensdauermodelle sind eine Weitere, in der technischen Zuverlässigkeit häufig angewendete Modellierung. Im Vergleich zu Degradationsmodellen, modellieren Lebensdauermodelle den Ausfall N_{EOL} über einem Modellparameter θ (Belastungsgröße). Das heißt von Interesse ist die Ausfallverteilung in Abhängigkeit der Belastung. Ein deterministisches Lebensdauermodell beschreibt somit den funktionalen Zusammenhang $N_{EOL} = f(\theta)$. Häufiger bieten sich stochastische Verteilungsmodelle $(P_{N_{EOL}|\theta})$ an, da Ausfallverteilungen nicht deterministisch sind.

2.4.3 Schadenshypothesen

Während aus einem Degradationsmodell $D = f(N; \theta)$ durch Umformung und Gleichsetzen von $D = D_{EOL}$ ein Lebensdauermodell abgeleitet werden kann, ist dies vice versa nicht möglich. In diesem Fall können Schadenshypothesen genutzt werden, um von einem Lebensdauermodell auf den Verlauf des Schadens über der Lebensdauer zu schließen. Wie der Name sagt, wird hierbei eine Hypothese über den Schadensverlauf aufgestellt. Diese umfasst eine Regel zur Summation, die Annahme mit/ohne konstante(n) Amplituden sowie die Berücksichtigung von Interaktionen [Sch72].

Regel zur Summation: Es werden drei Regeln unterschieden: a) der inkrementelle Ansatz, b) der Ähnlichkeitsansatz und c) der Interpolationsansatz. Beim inkrementellen Ansatz wird angenommen, dass jeder Belastungszyklus ein bestimmtes Schädigungsinkrement ΔD verursacht. Der Schadensverlauf ergibt sich dann aus

der Addition der Inkremente. Im Ähnlichkeitsansatz wird angenommen, dass ähnliche Belastungsbedingungen an der schadensrelevanten Stelle zu ähnlichem Ausfallverhalten führen. Der Interpolationsansatz baut auf einer Vielzahl bekannter Degradationspfade für unterschiedliche Belastungsparameter auf. Der gesuchte Verlauf für einen neuen Belastungsparameter wird dann aus Interpolation der Bekannten gewonnen. [Sch72]

Annahme mit/ohne konstante(n) Amplituden: Es wird zwischen mit und ohne konstanter Amplituden der Belastung unterschieden. [Sch72]

Berücksichtigung von Interaktionen: In interaktionsfreien Theorien wird angenommen, dass die gesuchte Schädigung (D_i) unabhängig von allen vorherigen Schädigungen ($D_{i-k}; k \in [1, \dots, i]$) ist. Im Vergleich, besteht in Interaktionstheorien eine Abhängigkeit. [Sch72]

Palmgren-Miner: Die Schadenshypothese nach Palmgren-Miner wird in der Zuverlässigkeitstechnik am häufigsten genutzt. Diese verfolgt einen inkrementellen Ansatz mit der Annahme einer konstanten Amplitude und ohne Berücksichtigung von Interaktionen [Sch72]. Weitere Bedingungen sind ein sinusförmiger Beanspruchungsverlauf, keine Ver- oder Entfestigung im Werkstoff sowie die Definition des Ausfalls bei einsetzendem Rissbeginn [BL04]. Als Lebensdauermodell wird die Wöhlerlinie herangezogen, die den Zusammenhang zwischen Belastung σ und Lebensdauer N im Zeitfestigkeitsbereich nach Gleichung 2.47 beschreibt. Aufbauend auf der Arbeit von Palmgren-Miner folgt als Schadenshypothese Gleichung 2.48.

$$N_i = N_D \cdot \left(\frac{\sigma_i}{\sigma_D} \right)^{-k} \quad (2.47)$$

$$D = \sum_{i=1}^m \frac{n_i}{N_D} \cdot \left(\frac{\sigma_i}{\sigma_D} \right)^k \quad (2.48)$$

N_i beschreibt die maximal ertragbare Lebensdauer unter der Belastung σ_i . Mit (σ_D, N_D) wird der Dauerfestigkeitspunkt als Referenzpunkt beschrieben und k definiert die Steigung der Wöhlerlinie. Wird die tatsächlich ertragene Lebensdauer n_i ins Verhältnis zur maximal ertragbaren Lebensdauer N_i gesetzt, ergibt sich das Schädigungsinkrement ΔD . Mit der Summation über alle Schädigungsinkremente folgt die Gesamtschädigung nach Palmgren-Miner (Gleichung 2.48). Für den Bereich der Dauerfestigkeit gibt es verschiedene Ansätze, ob und wie Belastungen berücksichtigt werden. [Hai06; BL04]

2.5 Methoden

Im Folgenden werden die Vorgehensweise im Data-Mining CRISP-DM und das V-Modell aus der Entwicklungsmethodik für mechatronische Systeme kurz vorgestellt. Beide Methoden sind Basis der Ergebnisse in Kapitel 5.

2.5.1 Cross-Industrie Standard Process for Data Mining

Der Cross-Industry Standard Process for Data Mining (CRISP-DM) ist ein EU-Förderprojekt das 2000 als CRISP-DM 1.0 veröffentlicht wurde [CRISP-DM]. CRISP-DM zeichnet sich durch freie Nutzungsrechte und seine Anwendungs-, Branchen- und Werkzeugneutralität aus. Eine weiteres Merkmal des CRISP-DM Prozesses ist die Kontext Konfiguration (engl. Context-Mapping). Dies bezeichnet die Möglichkeit den CRISP-DM Prozess kurzfristig oder dauerhaft an einen bestimmten Kontext zu adaptieren. Diese Adaption wird als „mapping for the future“ bezeichnet und beinhaltet die Schritte der Kontext Analyse, Entfernen unnötiger Details, Hinzufügen benötigter Details, Kontext Spezialisierung aller Details sowie die Anpassung der Terminologie. [Bre18; CRISP-DM]

Im Folgenden werden die sechs Haupt-Phasen des CRISP-DM Prozesses beschrieben. Jeder Hauptschritt gliedert sich wieder in Detailschritte. Insgesamt werden alle Schritte in mehrmaliger Iterationen durchlaufen, bis das gewünschte Ergebnis erreicht ist.

Wirtschaftsaspekte Verstehen (engl. Business Understanding): Die erste Phase beinhaltet die Analyse und Festlegung von Zielen, Erfolgskriterien, Risiken und Anforderungen. Außerdem werden die konkreten Aufgaben in der Modellierung festgelegt, d.h. der restliche Prozess auf die nötigen Details fokussiert. Methoden dieser Phase sind die Kosten-Nutzen-Analyse, Risikobewertungen, Projektstrukturplanung u. v. a. m. [CRISP-DM]

Daten Verstehen (engl. Data Understanding): Das Verstehen der Daten ist eine wesentliche und zeitintensive Phase. Diese Phase beinhaltet von der Datenerhebung über die Datenbeschreibung und -exploration bis hin zur Verifikation der Datenqualität eine Vielzahl an Detailaufgaben [CRISP-DM].

Daten Aufbereitung (engl. Data Preparation): Als nächstes müssen die Daten für die Modellierung vorbereitet werden. Dies umfasst Aufgaben wie Datenauswahl, -bereinigung, -konstruktion, -integration und -formatierung. Während die Rohdaten Ausgangspunkt dieser Phase sind, steht am Ende der finale Datensatz. Wie alle Phasen des CRISP-DM ist es wahrscheinlich, dass die Daten Aufbereitung mehrfach durchlaufen wird. [CRISP-DM]

Modellierung (engl. Modeling): In dieser Phase wird auf Basis der vorbereiteten Daten ein Modell gebildet, welches die definierten Ziele und Anforderungen erfüllt. Typische Aufgaben dieser Phase beschäftigen sich mit der Auswahl, Analyse, Entwicklung und Verifikation des Modells [CRISP-DM]. Modelle beschreiben im allgemeinen Beziehungen zwischen Variablen. Dies umfasst physikalische Beziehungen (first principles) genauso wie Beziehungen die alleine auf Basis der Datenanalyse gebildet werden.

Evaluation: In der Evaluation wird das Modell begutachtet. Es wird überprüft ob die Anforderungen, Ziele und Erfolgskriterien aus der Phase „Business Verstehen“ eingehalten sind. Ebenfalls werden in dieser Phase der gesamte Prozess überprüft und die nächsten Schritte festgelegt [CRISP-DM].

Bereitstellung (engl. Deployment): Die Bereitstellung umfasst zum einen alle Schritte, die nötig sind um das Modell in Betrieb zu nehmen sowie im Betrieb zu halten (Wartung). Auf der anderen Seite umfasst die Bereitstellung ein finales Projekt Review sowie die Projektdokumentation. [CRISP-DM]

2.5.2 V-Modell

Die Richtlinie VDI 2206 [VDI2206] beschreibt ein Vorgehen für die Mechatronikentwicklung. Ursprünglich aus der Softwareentwicklung stammend, zeichnet sich die Richtlinie durch die Integration verschiedener Domänen aus. Dabei wird der Entwicklungsprozess zweigeteilt in Mikro- und die Makroebene. Während die Mikroebene einen allgemeinen Problemlösungszyklus beschreibt, wird die Makroebene durch das V-Modell charakterisiert.

Das V-Modell wird durch eine Reihe von Prozessbausteinen beschrieben, die sich wiederholende Teilschritte darstellen. Zu diesen gehören der „Systementwurf“, „Modellbildung und -analyse“, „domänenspezifischer Entwurf“, „Systemintegration“ und „Eigenschaftsabsicherung“. Bild 2.10 stellt das V-Modell mit seinen Prozessbausteinen dar. Das Ergebnis des V-Modells ist nicht zwangsläufig ein fertiges Produkt, sondern kann ein Produkt unterschiedlichen Reifegrades sein, wie beispielsweise ein Labormuster, ein Funktionsmuster oder ein Vorserienprodukt. Ein komplexes System entsteht selten in einem Durchlauf des V-Modells. Oft werden im ersten Durchlauf mehrere Lösungsprinzipien ausgewählt und grob dimensioniert, um ein Labormuster zu erhalten. Die gewonnenen Lösungsprinzipien werden anschließend in weiteren Zyklen zu Funktionsmustern konkretisiert und ausgewählt, um schließlich ein Vorserienprodukt zu entwickeln. Zu beachten ist, dass die zeitliche Reihenfolge von der logischen Reihenfolge abweichen kann. [VDI2206]

Zu Beginn steht ein Entwicklungsauftrag, von dem ausgehend die Aufgabenstellung präzisiert und die Anforderungen formuliert werden. Der darauf folgende

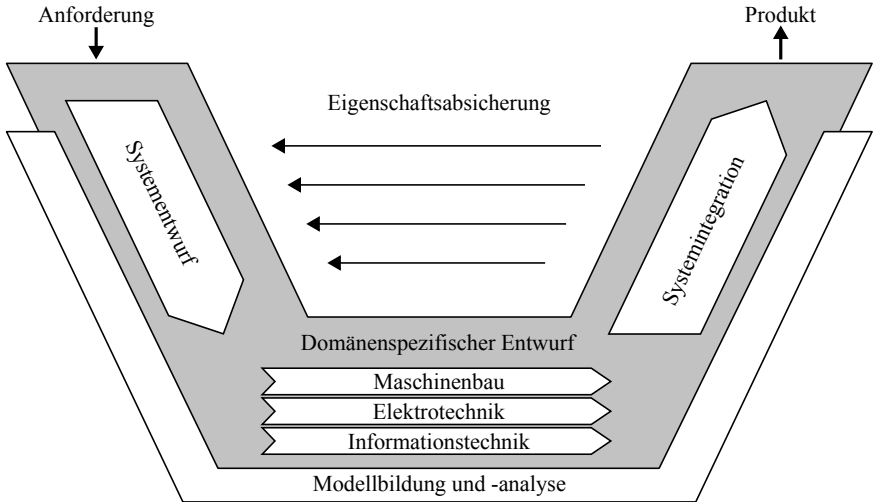


Bild 2.10 Das V-Modell nach [VDI2206].

erste Prozessbaustein ist der Systementwurf. Ziel ist die Festlegung eines domänenübergreifenden Zielkonzepts, auf Basis physikalischer und logischer Wirkprinzipien. Dazu wird die Anforderungsliste lösungsneutral abstrahiert, die Funktionsstruktur erstellt, Lösungsprinzipien erarbeitet, verknüpft und schrittweise konkretisiert. Parallel erfolgt die Modellbildung und -analyse. Zu Beginn werden Ziele, der Aufbau des Modells und dessen gewünschte Leistungsfähigkeit festgelegt. Anschließend erfolgt die Modellbildung, die Modellanalyse sowie Verifikation und Validierung. Auf den Systementwurf folgen die domänenspezifischen Entwürfe. Dabei werden die Teilfunktionen des vorher bestimmten Lösungskonzeptes innerhalb der einzelnen Bereiche Maschinenbau, Elektrotechnik und Informationstechnik weiter konkretisiert. Die Ergebnisse der einzelnen Bereiche werden in der Systemintegration über standardisierte Schnittstellen zu einem Gesamtsystem zusammengefasst. In der Eigenschaftensicherung werden die gewählten Varianten verifiziert und validiert. [VDI2206]

Kapitel 3

Forschungsmethodik

Wissenschaftliche Methoden der Ingenieurwissenschaften sehen sich häufig mit Akzeptanzproblemen konfrontiert [BC09; Mar14]. Ursachen können fehlende Effektivitätsmaße, falsche Zielsetzungen oder die Adressierung irrelevanter Stakeholder sein [Mar14]. Die Design Research Methodology (DRM) nach Blessing und Chakrabarti [BC09] stellt eine Forschungsmethode zur zielorientierten und strukturierten Entwicklung von Methoden innerhalb der Ingenieurwissenschaften dar. Dabei sollen Akzeptanzprobleme vermieden werden, indem deren Ursachen beherrscht werden. DRM formt die Basis der Forschungsaktivitäten innerhalb dieser Arbeit, die nach Blessing und Chakrabarti [BC09] typischerweise aus den folgenden vier Phasen bestehen:

1. Abgrenzung der Forschungsaufgabe (engl. Research Clarification)
2. Deskriptive Studie I (engl. Descriptive Study I)
3. Präskriptive Studie (engl. Prescriptive Study)
4. Deskriptive Studie II (engl. Descriptive Study II)

In **Phase 1 (Abgrenzung der Forschungsaufgabe)** stehen die Ermittlung der initialen Forschungsziele sowie die Identifikation möglicher Hemmnisse im Fokus. Mögliche Ergebnisse dieser Phase sind die Formulierung der Forschungsziele, ein initiales Referenz-/Wirkmodell sowie die Identifikation der Forschungsfragen. Dabei sind Referenzmodelle eine grafische Elaboration des „Stand von Wissenschaft und Technik“. Sie sind außerdem oft Basis für das Wirkmodell, welches wiederum die angestrebte Veränderung zum „Stand von Wissenschaft und Technik“ darstellt. Aufbauend auf den Ergebnissen aus Phase 1, werden in **Phase 2 (Deskriptive Studie I)**

die Erkenntnisse wissenschaftlich vertieft. Ein wesentlicher Punkt dieses Schrittes ist die Identifikation von Schlüsselfaktoren. Schlüsselfaktoren stellen eine Art von Leitsätzen oder Leitgedanken dar, um ausgehend vom Stand von Wissenschaft und Technik die Forschungsziele zu entwickeln. Hauptziel von **Phase 3 (Präskriptive Studie I)**, ist die Weiterentwicklung des Wirkmodells. Auf Basis der initialen Modelle, der Forschungsfragen sowie der Schlüsselfaktoren, wird das finale Forschungsziel ausgestaltet. **Phase 4, die zweite Deskriptive Studie**, beschreibt eine Iteration zur Weiterentwicklung sowie Evaluation der vorherigen Ergebnisse. Zum Ende dieser Phase ist das Forschungsziel erreicht und evaluiert. [BC09]

In den folgenden Abschnitten werden die grundlegenden Arbeiten zur Forschungsmethodik vorgestellt. Dazu gehören insbesondere Forschungsaufgabe, durchgeführte Studien, Schlüsselfaktoren sowie Forschungsfragen. Ziel ist eine Basis zur zielorientierten und strukturierten Entwicklung der finalen Ausarbeitung in Kapitel 4 und Kapitel 5.

3.1 Abgrenzung der Forschungsaufgabe

Dieser Abschnitt stellt die initiale Motivation zur Bearbeitung der Forschungsaufgabe und deren Abgrenzung vor. Dabei werden insbesondere wissenschaftliche Kritik und Forschungsziele vorgestellt.

3.1.1 Wissenschaftliche Kritik

Den Ausgangspunkt der Forschung bilden Untersuchungen von Rakowsky und Bertsche [RB15], die im Fachbereich PHM eine fehlende Struktur auf Metaebene kritisieren. Weitere Arbeiten stützen diese Kritik und belegen eine undurchsichtige Vielzahl an Methoden und Modellen verbunden mit der Schwierigkeit einer effektiven und effizienten Entwicklung von PHM-Lösungen [Sax10; AC15; HZB17; LVC18a].

Für die fehlende Struktur auf Metaebene gibt es mehrere Ursachen. Eine Ursache ist das Zusammentreffen unterschiedlichster Fachdisziplinen aus unterschiedlichen Kontexten, mit unterschiedlichen Terminologien [RB15; HZB17]. Eine zweite Ursache ist, dass es sich bei PHM um eine relativ junge Fachdisziplin handelt [KAC17], der eine grundlagenwissenschaftliche Basis fehlt. In der Wissenschaftstheorie kommt es häufig vor, dass eine Reihe praktischer Anwendungen² existieren, bevor es die eigentliche Grundlagenwissenschaft gibt [Hel16]. Die Annahme, dass es sich bei PHM um diese übergeordnete Disziplin etablierter Teildisziplinen handelt, wird durch die Arbeiten von Gouriveau et al. [GMZ16] und Johnson et al. [Joh+11] gestützt.

²Im PHM sind das z. B. Condition Monitoring (dt. Zustandsüberwachung), das Predictive Maintenance (dt. Vorausschauende Instandhaltung), die Prescriptive Maintenance (dt. Aktive Instandhaltung) u. v. a. m.

Im Folgenden wird die initiale Formulierung einer „fehlenden Struktur auf Metaebene“ nach Rakowsky und Bertsche [RB15], auf Basis der Wissenschaftstheorie als Forderung nach einer grundlagenwissenschaftlichen Formulierung der Fachdisziplin PHM verstanden. Mit dieser Arbeit soll ein Beitrag zur Erreichung einer Grundlagenwissenschaft PHM erzielt werden. Auf dieser Basis ergibt sich die Chance, die Fachdisziplin PHM zu ordnen, zu definieren, mit anderen Disziplinen zu vergleichen, von diesen abzugrenzen und letztendlich eine effektive und effiziente Entwicklung von PHM-Lösungen zu ermöglichen.

3.1.2 Forschungsziele

Aufbauend auf der wissenschaftlichen Kritik und den Prinzipien einer Grundlagenwissenschaft [Hel16], lassen sich für diese Arbeit zwei bestimmende Forschungsziele formulieren:

- Holistische Beschreibung der theoretischen Zusammenhänge.
- Generische Anwendbarkeit.

Zur Beherrschung der Komplexität einer grundlagenwissenschaftlichen Formulierung, lassen sich nach Winzer [Win16] eine Reihe von Grundprinzipien des Systems-Engineering heranziehen. Auf die Erfüllung der Grundprinzipien wird in der Entwicklung der Forschungsziele besonders Wert gelegt. Dabei handelt es sich um die Grundprinzipien des „Denkens in Systemen“, der „Strukturierung“, der „minimalen Modelle“, der „Verständlichkeit“, der „Anwendung mehrere Sichten“, der „Standardisierung“ und des Vorgehens „vom Ganzen zum Detail“ [Win16]. In den folgenden Absätzen werden die Forschungsziele nochmals aufgegriffen und konkretisiert.

Holistische Beschreibung der theoretischen Zusammenhänge

Essentieller Bestandteil einer Grundlagenwissenschaft ist der Fokus auf die Beschreibung der theoretischen Zusammenhänge [Hel16]. Der abstrakte Begriff der Zusammenhänge, soll an dieser Stelle auf drei wesentliche Punkte fokussieren: Konzepte, Modelle und die Methodik. Dabei beschreiben Konzepte die Zusammenhänge innerhalb und zwischen den etablierten Anwendungswissenschaften, in einer holistischen Perspektive. Sie bilden den Beginn eines Entwicklungsprozesses und liefern initiale Architektur, Eigenschaften und Funktionsumfang der beabsichtigten Lösung [FG13]. Die finale Lösung selbst wird in Form eines Modells beschrieben, das die PHM-Funktionalität abbildet. Den Weg vom Konzept zum Modell bildet die Methodik. Aus den Formulierungen lassen sich die ersten drei Schlüsselfaktoren ableiten:

1. Beschreibung der Zusammenhänge innerhalb und zwischen den Anwendungswissenschaften in einer holistischen Perspektive als Konzepte.

2. Beschreibung der funktionalen Zusammenhänge in Form von Modellen.
3. Beschreibung des Zusammenhangs „Konzept → Modell“ als Methodik.

Generische Anwendbarkeit

Eine generische Beschreibungsform ist ein entscheidender Faktor, um diese Arbeit einem möglichst großen Anwenderkreis einfach und universell zugänglich zu machen [Win16]. Dabei werden insbesondere die Schlüsselfaktoren der Standardisierung und Verständlichkeit adressiert. Übertragen auf diese Arbeit lassen sich daraus Anforderungen für die zentralen Elemente: Konzept, Modell und Methode formulieren.

Als Anforderung für die Gestaltung von **Konzepten und Modellen** sollen diese universell auf technische Systeme anwendbar sein. Unter dem Begriff des **technischen Systems** (kurz System), werden alle geeigneten technischen Produktionsgüter, Konsumgüter oder Liegenschaften verstanden. Das System kann im Einzelfall synonym zu Begriffen wie Teilsystem, Maschine, Maschinenelement, Element, Komponente u. v. a. m. stehen. Aus der Anforderung ausgeklammert, aber nicht ausgeschlossen, wird die Anwendbarkeit auf Software oder immaterielle Güter wie Services. Unter einer **Methodik** wird ein planmäßiges Vorgehen unter Verwendung mehrerer Methoden und Werkzeuge verstanden. Für die generische Anwendbarkeit der Methodik werden zwei Anforderungen formuliert. Die Methodik sollte einerseits domänenübergreifend die Methoden und Kompetenzen aus Data-Science, Zuverlässigkeitstechnik etc. kombinieren. Gleichzeitig sollte die Methodik frei von Einschränkungen auf spezielle Methoden oder Modellierungstechniken (Algorithmen) sein. Aus der generischen Anwendbarkeit folgen drei Schlüsselfaktoren:

4. Generische Anwendbarkeit auf allgemeine technische Systeme.
5. Domänenübergreifende Perspektive der Methodik.
6. Generische Anwendbarkeit spezieller Methoden und Modellierungstechniken.

3.2 Studien

Im Rahmen dieser Arbeit werden zwei Studien unterschieden, der „Vergleich etablierter Literaturquellen“ und die „Metaanalyse“. Beide Analysen werden im Folgenden kurz vorgestellt.

3.2.1 Vergleich etablierter Literaturquellen

Der Vergleich diskutiert etablierte Literaturquellen der Fachliteratur und Normung. Einleitend werden als Diskussionsbasis Terminologie, Konzepte, Modelle und Me-




Bild 3.1 Einteilung der Aktivitäten in Diagnose und Prognose anhand ihres zeitlichen Bezugs.

thodik analysiert, bevor eine abschließende Bewertung der etablierten Literaturquellen erfolgt.

Terminologie

Henß et al. [HZB17] und Henß und Bertsche [HB17] zeigen, dass die Vielzahl beteiligter Fachdisziplinen zu einer teilweise überschneidenden, teilweise widersprüchlichen semantischen Nutzung der zentralen Begriffe **Diagnose und Prognose** führt. Dabei ist ein konsistentes terminologisches Verständnis eine Grundvoraussetzung zur holistischen und generischen Beschreibung der Zusammenhänge.

Diagnose und Prognose beschreiben unterschiedliche Aktivitäten zur Bewertung von Ereignissen oder Zuständen. Um diese Begriffe klar zu unterscheiden, bei gleichzeitiger Konformität mit der Alltagsbelegung, werden die Begriffe in Anlehnung an Bachleitner et al. [BWP16] anhand ihrer philosophischen Semantik unterschieden. Es folgt, dass sich Aktivitäten der Diagnose mit Gegenwart und Vergangenheit beschäftigen, während Aktivitäten der Prognose in Bezug zur Zukunft stehen. Grafisch ist der Zusammenhang in Bild 3.1 dargestellt. Die Einteilung ist trivial, schafft jedoch eine scharfe Trennung der beiden Begriffe und steht im Konsens mit der Alltagsbelegung.

Prognostics-Konzepte

Prognostics Konzepte werden in der Literatur auch als Typen oder Methoden bezeichnet. Die Anzahl an Konzepten variiert in der Literatur zwischen drei und fünf [Cob+12; RB15; KAC17; Goe+17]. In Anlehnung an Coble et al. [Cob+12] lauten die drei Grundkonzepte 1) Zuverlässigkeitsanalysen, 2) Belastungsbasiert und 3) Degradationsbasiert. Das vierte Konzept ergibt sich aus der Unterscheidung in 3.1) Degradations- und Modell-basiert sowie 3.2) Degradations- und Daten-basiert [RB15; KAC17; GMZ16]³. Damit sind die vier Konzepte eine konsekutive Weiterentwicklung der drei Konzepte. Von Rakowsky und Bertsche [RB15] wird als fünftes Konzept die „Optimierung“ vorgeschlagen. Diese Definition konnte sich bisher nicht durchsetzen und steht auch im Konflikt mit der Definition des Health Management als Optimierung (siehe folgender Abschnitt).

Neben den genannten Konzepten benennt die [ISO13381] zusätzlich Wissensbasierte Konzepte, die im Sinne dieser Arbeit als wenig automatisierte Ansätze mit

³Die konkrete Bezeichnung variiert innerhalb der Literaturquellen.

hoher menschlicher Interaktion verstanden werden. Ebenfalls werden Konzepte des „Predictive Analytics“ nicht berücksichtigt, die Goebel et al. [Goe+17] als Datenbasierte Ansätze ohne Einfluss auf die angenommene zukünftige Nutzung versteht. Diese Unterscheidung wird in dieser Arbeit als Art und Weiße der Modellierung gesehen und stellt auch kein eigenständiges Konzept dar.

In der Fachliteratur sind die Konzeptbezeichnungen sowie auch deren Beschreibungen unterschiedlich präzise spezifiziert. Dies trifft insbesondere auf Daten- und Modell-basierte Ansätze zu. Kim et al. [KAC17] unterscheidet anhand der Modell-Parameter θ . Besitzen diese eine physikalische Bedeutung ist es ein Modell-basierter Ansatz. In ähnlicher Form beschreibt Goebel et al. [Goe+17] Modell-basierte Ansätze als solche, die auf der Beschreibung von Fehlermechanismen beruhen und Daten-basierte als selbst lernend aus Run-to-Failure Daten⁴. Gouriveau et al. [GMZ16] klassifiziert Daten-basierte Ansätze als solche, die auf der Auswertung von Beobachtungsdaten beruhen. Modell-basierte Ansätze beruhen hingegen auf der Entwicklung von Dynamikmodellen, die das Systemverhalten unter Berücksichtigung der Degradation abbilden. Die [ISO13381] definiert Modell-basierte Ansätze als solche, die das physikalische Verhalten auf Basis geeigneter Gleichungen abbilden. Im Vergleich sind Daten-basierte Ansätze die Repräsentation von Run-to-Failure Daten.

Health Management Konzepte

Im Health Management werden die Erkenntnisse des Prognostics im Kontext unternehmerischer Ziele (Life-Cycle-Management) gemanagt. Oft wird die Definition des Health Managements durch individuelle Kenntnisse einzelner Anwendungswissenschaften geprägt, beispielsweise indem Health Management und Instandhaltung gleich gesetzt werden. Diese beschreiben aber nur einen Teilausschnitt der gesamten Grundlagenwissenschaft. In Folge, bleibt das volle Potenzial des Health Managements oft unerkannt. Aus diesem Grund ist es wichtig das Health Management holistisch und generisch zu beschreiben. In dieser Arbeit erfolgt dies in Form einer Optimierungsaufgabe. Das Ziel der Optimierung ist es aus der Kenntnis über Ereignisse/Zustände in Kombination mit Vorgaben aus Instandhaltung, Sicherheit, Qualität, Ökonomie etc. eine optimale Entscheidung zu finden und umzusetzen. Damit generiert das Health Management die wesentliche unternehmerische Wertschöpfung. Die Optimierungsaufgabe kann dabei für eine beliebige Anzahl an Zielgrößen und Nebenbedingungen definiert werden, sodass eine ganzheitliche Betrachtung möglich ist. Somit ist es theoretisch möglich das komplexe soziotechnische Wesen des Health Management [Joh+11] zu berücksichtigen. Das heißt, die Betrachtung kann neben dem eigentlichen technischen System die Einflüsse und Wechselbeziehungen mit der Organisation, dem Kunden/Nutzer, dem Operateur, den Regulierungen etc. berücksichtigen.

⁴Daten die über einen längeren Zeitraum am System aufgezeichnet werden. Dabei liegt der Ausfallzeitpunkt innerhalb dieses Zeitraums.

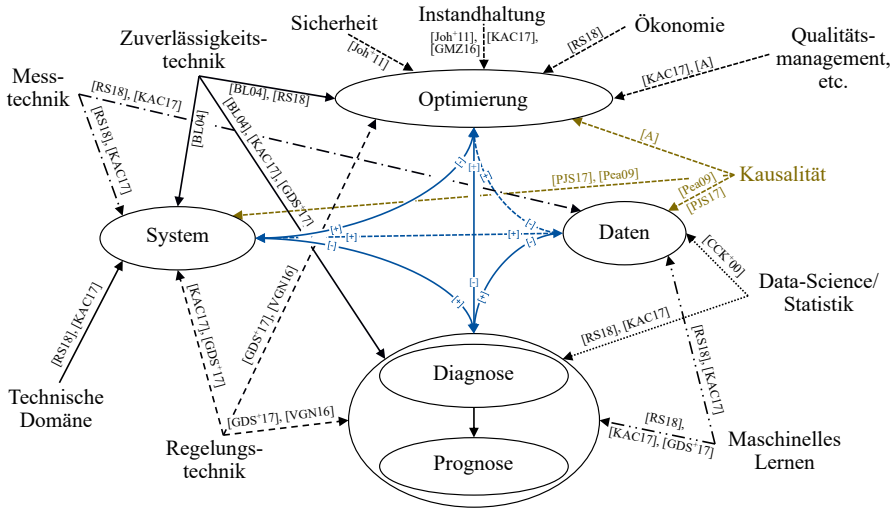


Bild 3.2 Vernetzung der Modellierungsbereiche über die Fachdisziplinen ([A]: Annahme, Pfeilrichtung \rightarrow : [-] - [+], Pfeilrichtung \leftarrow : [+] - [-])

Modellierung

Mit der Modellierung wird ein Abbild der Funktionalität beschrieben. Nach dem Grundprinzip „vom Ganzen zum Detail“ sollte das Modell hierarchisch Top-Down zerlegbar sein und alle Elemente in eine Zuordnung bringen [Win16]. In der Regel ergibt sich so auf dem höchsten Level eine Black-Box-Darstellung, während der Detailgrad mit sinkendem Level stetig zunimmt [Win16]. Das PHM-Modell wird in Anlehnung an Henß et al. [HZB17] und Henß und Bertsche [HB17] in vier Hauptbereiche untergliedert: System, Daten, Prognostics und das Health Management. Mit den Schlüsselfaktoren der vorangegangenen Abschnitte wird das Health Management als Optimierung definiert und das Prognostics in Diagnose und Prognose unterschieden. Es folgen fünf Hauptelemente der Modellierung: **System, Daten, Diagnose, Prognose, Optimierung**.

Bild 3.2 zeigt die fünf Modellierungsbereiche sowie deren Vernetzung in Modellen und Methoden über die beteiligten Fachdisziplinen. Dargestellt sind ausschließlich starke Vernetzungen. Besonders ausgeprägte Vernetzungen zeigen „Diagnose/Prognose \rightarrow Optimierung \rightarrow System \rightarrow Diagnose/Prognose \leftarrow Daten“. Weniger vernetzt sind die Bereiche „System \leftrightarrow Daten \rightarrow Optimierung“ und zeigen somit eine wissenschaftliche Lücke. Mit den Modellen und Methoden der Fachdisziplin Kausalität, nach Judea Pearl, Elias Bareinboim, Bernhard Schölkopf und Weiteren, wird mindestens eine Reduzierung dieser Lücke erwartet. Dabei verbindet die Kausalität Daten und datenerzeugende Mechanismen miteinander [Pea09]. Im PHM werden

die datenerzeugenden Mechanismen durch das System repräsentiert, weshalb die Kausalität als Bindeglied zur Vernetzung „System \leftrightarrow Daten“ gesehen wird. Zudem können auf Basis kausaler Modelle Fragen über Interventionen beantwortet werden [Sch19]⁵. Ein Beispiel für eine Interventionsfrage im PHM ist: „Wie verändert sich der Health H , wenn ich die Nutzung X verändere?“. Es wird deshalb ebenfalls ein Beitrag zur Vernetzung „Daten \rightarrow Optimierung“ erwartet. Die beschriebenen Beziehungen zeigen zudem, dass es keine strikt linear oder hierarchische Abfolge zwischen den Bereichen gibt. Vielmehr sind die Bereiche agil miteinander verbunden.

Methodik

Die beabsichtigte Methodik verbindet Konzepte und Modelle. Wesentliche Bestandteile einer Methodik sind zudem eine adäquate Analyse des Istzustandes sowie die Evaluation der Ergebnisse. Es ergeben sich vier Schwerpunkte der Methodik: **Konzeptauswahl, Analyse, Modellierung und Evaluation**. Zu den leistungsfähigsten Ansätzen im PHM gehören Modell- und Daten-basierte [Goe+17; KAC17], die zudem über 93 % der aktuellen wissenschaftlichen Beiträge ausmachen [MAP19]. In beiden Ansätzen liegt eine kontinuierliche Datenerhebung und -auswertung in der Betriebsphase des Systems vor⁶. Mit weltweit steigenden Trends in Datensammlung und Vernetzung wird sich diese Entwicklung vermutlich noch verstärken. Aus diesen Gründen soll der Rahmen der Methodik einen starken Fokus auf Daten legen.

Data-Mining Prozesse geben einen Rahmen vor, der den Fokus auf Daten legt und gleichzeitig eine Reihe weiterer Anforderung erfüllt. Dazu gehört die Anforderung nach einer domänenübergreifenden Perspektive, die sich über die Technik Wissenschaften nutzen lässt. Die vier wichtigsten Data Mining Prozesse sind CRISP-DM, SEMMA, KDD und der EliteDataScience-Prozess [MMS09]. Tabelle 3.1 zeigt die einzelnen Phasen und stellt diese gegenüber. Die Analyse zeigt, dass CRISP-DM einen der vollständigsten und ausführlichsten Prozesse bildet. Zudem handelt es sich um den seit einigen Jahren etabliertesten Prozess [Pia14]. Ein weiterer Vorteil ist die explizit beabsichtigte Adaptionsfähigkeit an spezifische Aufgaben, wodurch sich die speziellen Charakteristika des PHM berücksichtigen lassen⁷. Des Weiteren ist CRISP-DM unabhängig von der Anwendung spezieller Methoden oder Modellierungstechniken und erfüllt somit den Schlüsselfaktor der generischen Anwendbarkeit. Auf Basis dieser Vorteile wird CRISP-DM als methodische Basis für die Arbeiten in Kapitel 5 ausgewählt.

⁵Dies ist ebenfalls auf Basis von physikalischen Modellen nicht aber mit statistischen Modellen (aus den Daten gelernten Modellen) möglich (siehe auch Abschnitt 2.2).

⁶Im Folgenden wird auch von Zeitreihen gesprochen.

⁷Mit der Verwendung eines Data-Mining-Prozesses als methodische Basis wird das Grundprinzip der Anwendung mehrerer Sichten sowie der Standardisierung angewendet.

Tabelle 3.1 Vergleich der Phasen etablierter Data-Mining Prozesse (in Anlehnung an [Bre18]).

Phase	CRISP-DM	SEMMA	KDD	EliteDataScience
1.	Business Verstehen			
2.	Daten Verstehen	Sample, Explore	Selektion	Explorative Analyse
3.	Daten Aufbereitung	Modifizieren	Preprocessing Transformation	Datenbereinigung Merkmalsentwickl.
4.	Modellierung	Modellierung	Data-Mining	Algorithmen Auswahl & Training
5.	Evaluation	Bewerten	Interpretation Evaluation	
6.	Bereitstellung (Deployment)			

Etablierte Literaturquellen der Fachliteratur und Normung

DIN ISO 13379-1: Zustandsüberwachung und -diagnostik von Maschinen – Verfahren zur Dateninterpretation und Diagnostik – Teil 1: Allg. Anleitungen

Die DIN ISO 13379-1 diskutiert Zustandsüberwachung und -diagnostik von Maschinen. Im Verständnis dieser Arbeit, adressiert dies den Bereich der Diagnose als Teilgebiet des Prognostics. Ziel der Norm ist es, den Anwendern die Möglichkeit zu geben, sich über gemeinsame Konzepte zu verständigen, die technischen Merkmale des physischen Systems zu definieren sowie Methoden und Modelle vorzustellen. Zu diesem Zweck werden Methoden und Modelle anschaulich an Beispielen beschrieben. [DIN13379]

ISO 13381-1: Condition monitoring and diagnostics of machines — Prognostics — Part 1: General guidelines

Im Gegensatz zur vorangegangenen Norm liegt der Fokus der ISO 13381-1 auf der Prognose, bei einer vergleichbaren Zielsetzung. Dabei beschreibt die Norm nur einen Teil der Prognose-Konzepte, weitere Konzepte sollen in zukünftigen Normen beschrieben werden. Nicht beschrieben werden Prognosekonzepte zu Trendverläufen (ISO 13381-2), zyklisch gesteuerte Techniken (ISO 13381-3) und Modelle für die nutzbare Restlebensdauer (ISO 13381-4). [ISO13381]

IEEE Std 1856: Standard Framework for Prognostics and Health Management of Electronic Systems

Die IEEE 1856 beschreibt Informationen zur Implementierung von PHM. Dabei wird ein normativer Rahmen für die Klassifizierung der Leistungsfähigkeit eines PHM-Ansatzes sowie für die Entwicklungsplanung für elektronische Systeme beschrieben. Ziel des Standards ist es Herstellern und Endbenutzern ein Werkzeug zur Planung und Implementierung von PHM-Systemen zu liefern. Der Anwendungsbereich des Standards konzentriert sich auf elektronische Systeme, ohne eine Übertragbarkeit auf andere Systeme auszuschließen. Neben einer kurzen Einführung in PHM legt der Standard den Fokus auf Terminologie und Anforderungen. [IEEE1856a]

DIN ISO 17359 - Zustandsüberwachung und -diagnostik von Maschinen – Allgemeine Anleitungen

Die DIN ISO 17359 legt den Fokus auf eine Methodik zur Entwicklung von PHM-Programmen⁸. In den Hauptschritten der Methodik werden die folgenden Punkte behandelt: Kosten-Nutzen Analyse, Audits von Anlage, Zuverlässigkeit und Gefährdung, Festlegung von Instandhaltungs- und Prognosticskonzept, Datenaufnahme und -analyse, Festlegung der Instandhaltungsaktion und eine abschließende Bewertung. Konkrete Konzepte und Modelle werden nicht behandelt, stattdessen wird auf weiterführende Normen verwiesen. [DIN17359]

Prognostics and Health Management of Electronics

Das Fachbuch legt den Fokus auf PHM für elektronische Systeme. Dabei wird auf ein Grundverständnis und eine Vielzahl von Konzepten, Methoden und Modellierungstechniken eingegangen. Insbesondere Physics of Failure (PoF), Daten-basierte und Hybride Konzepte der Elektronik werden näher erläutert. Im Fokus des Fachbuchs stehen zudem Implementierungskosten, Potenziale zur Kostenvermeidung und die resultierende Kapitalrendite. [PK18]

Prognostics: The Science of Prediction

„Prognostics: The Science of Prediction“ basiert auf den Arbeiten des Prognostics Center of Excellence (PCoE) des NASA Ames Research Center. Beschrieben wird der Teilbereich des Prognostics, durch Konzepte, Modelle und Methoden. Das Health Management wird nicht näher ausgeführt. Methodisch adressiert die Quelle die Bereiche Entwicklung, Modellierung, Evaluierung, Unsicherheiten, Kosten-Nutzen-Analyse und Risikobewertung. [Goe+17]

Prognostics and Health Management of Engineering Systems

Das Fachbuch legt einen hohen Wert auf anwendungsnahe Beispiele etablierter Algorithmen mit Benennung von Vor- und Nachteilen. Ebenfalls werden Konzepte und Methoden des Prognostics vorgestellt, mit Bezug zur Instandhaltung (Health Management). Daneben werden historische Hintergründe, industrielle Anwendungen und

⁸In der Norm als Programm zur Zustandsüberwachung bezeichnet.

verschiedene Algorithmen vorgestellt. [KAC17]

From Prognostics and Health Systems Management to Predictive Maintenance

Die Quelle beschreibt PHM im Kontext der Instandhaltung, insbesondere des Predictive Maintenance und Condition Based Maintenance. Dabei wird PHM als übergeordnete generische Disziplin mit starkem Instandhaltungsbezug gesehen. Neben einer kurzen theoretischen Eingliederung, werden insbesondere Datenakquisition, -verarbeitung, Health Assessment und Prognostics behandelt. Weitere Aktivitäten, wie Diagnose und Entscheidung, werden bewusst ausgespart. [GMZ16]

Neben den genannten gibt es eine Vielzahl weiterer Normen und Fachbücher. Die getroffene Auswahl repräsentiert die aktuell populärsten und im Kontext dieser Arbeit relevantesten Literaturquellen. Weiterführende Literaturquellen können den genannten Normen oder den folgenden Arbeiten entnommen werden [VWD14; Goe+17].

Bewertung

Tabelle 3.2 zeigt einen qualitativen Vergleich der diskutierten Fachliteratur und Normung. Vergleichsbasis bilden die in Abschnitt 3.1 formulierten Schlüsselfaktoren. Diese werden nach „Prognostics“ und „Health Management“ gegliedert. Spezifische Anforderungen dieser Arbeit an Terminologie, Formulierungen oder beabsichtigte Lösungswege werden nicht berücksichtigt, zur Wahrung der Neutralität. Im Vergleich ist das Ziel dieser Arbeit die vollständige Erfüllung der erarbeiteten Schlüsselfaktoren.

3.2.2 Empirische Metaanalyse

Die zweite Studie analysiert aktuelle wissenschaftliche Beiträge, in Form einer Metaanalyse⁹. Dabei liegt der Fokus auf Konzepten und Modellen konkreter PHM-Lösungen. Die analysierte Stichprobe bilden ca. 260 wissenschaftliche Beiträge aus ca. drei Datenbanken für die Jahre 2011 bis 2018 (Schwerpunkt 2017 und 2018), siehe Bild 3.3.

In der Metaanalyse werden die Quellen anhand definierter Merkmale untersucht, die von der Systembeschreibung bis zu Spezifikationen des Prognostics and Health Managements reichen. Zu den Merkmalen gehören beispielsweise: Fehlermechanismus, Einflussfaktoren, Prognosealgorithmus, Sensordaten und Health Management Ziel¹⁰. Die Metaanalyse bildet die Basis der Modellbildung (Abschnitt 4.3) und zeigt ebenfalls etablierte Lösungsansätze als Praxisbeispiele in der generischen Methodik (Kapitel 5).

⁹Bei der Metaanalyse handelt es sich um eine quantitative Literaturanalyse, mit dem Ziel anwendungsorientierte Studien in Form eines neuen Datensatzes zu erfassen [SHE18].

¹⁰Die vollständige Liste findet sich in Anhang A.

Tabelle 3.2 Vergleich etablierter Literatur auf Basis relevanter Schlüsselfaktoren. Legende: ● → Trifft eher zu, ◐ → Trifft teilweise zu, ○ → Trifft eher nicht zu.

	Generisch-holistische Beschreibung der...	... Konzepte im Prognostics.	... Konzepte im Health Management.	... Modellierung im Prognostics.	... Modellierung im Health Management.	Effektive und effiziente Methodik zur Entwicklung des Prognostics.	... Entwicklung des Health Management.	... domänenübergreifenden Perspektive.	Generische Anwendbarkeit auf technische Systeme.	... von Methoden / Modellierungstech.
[DIN13379]	◐	○	◐	○			◐	○	◐		●	◐
[ISO13381]	◐	○	◐	○			◐	○	◐		●	◐
[IEEE1856a]	○	○	○	○			◐	◐	◐		◐	◐
[DIN17359]	○	○	○	○			●	◐	◐		●	◐
[PK18]	◐	◐	◐	◐			●	●	◐		◐	◐
[Goe+17]	●	○	●	○			●	○	◐		●	◐
[KAC17]	◐	◐	◐	◐			◐	◐	◐		●	◐
[GMZ16]	◐	◐	◐	◐			◐	◐	◐		●	◐
Ziel der Arbeit	●	●	●	●			●	●	●		●	●

Die Interpretation der Ergebnisse unterliegt Faktoren, die an dieser Stelle diskutiert werden. Einer der Faktoren ist der begrenzte Veröffentlichungszeitraum, der im Schwerpunkt auf den Jahren 2017 und 2018 liegt. Neuere Arbeiten zeigen einen weiter zunehmenden Trend zu Daten-basierten Ansätzen. Ein weiterer Faktor sind die hohen Aufwände zur Erhebung eigener Datensätze. Viele Arbeiten greifen daher auf Open-Source Datensätze zurück. Dies führt zu einer Verzerrung der Stichprobe hinsichtlich verwendeter Systeme und Daten, sodass die Metaanalyse nur bedingt die Diversität der Praxis widerspiegelt. Letztendlich unterliegt die Metaanalyse auch den subjektiven Bewertungen der Bearbeiter.

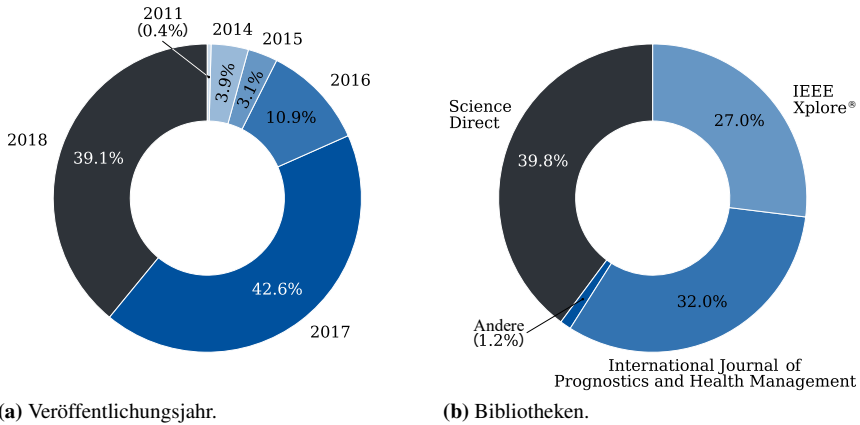


Bild 3.3 Metadaten der untersuchten wissenschaftlichen Beiträge in der Metaanalyse.

3.3 Zwischenfazit

Das Zwischenfazit lautet: Obwohl es einige Normen, Fachliteratur und etliche wissenschaftliche Beiträge gibt, bietet keines eine ausreichende Lösung, das Fachgebiet aus grundlagenwissenschaftlicher Perspektive zu beschreiben. Jedoch bilden die analysierten Quellen einen guten Startpunkt der Forschung. Nachfolgend werden die Schlüsselfaktoren, Forschungsfragen sowie die Evaluation nochmals zusammenfassend erläutert.

3.3.1 Schlüsselfaktoren

Schlüsselfaktoren bezeichnen Einflussfaktoren zur Verbesserung der Referenz-Situation, mit dem scheinbar größten Potenzial [BC09]. Sie stellen somit Grundsätze dar, die in der finalen Ausarbeitung (Kapitel 4 und Kapitel 5) Anwendung finden. Die vollständige Liste der Schlüsselfaktoren lautet:

1. Beschreibung der Zusammenhänge innerhalb und zwischen den Anwendungswissenschaften in einer holistischen Perspektive als Konzepte.
2. Beschreibung der funktionalen Zusammenhänge in Form von Modellen.
3. Beschreibung des Zusammenhangs Konzept → Modell als Methodik.
4. Generische Anwendbarkeit auf allgemeine technische Systeme.
5. Domänenübergreifende Perspektive der Methodik.

6. Generische Anwendbarkeit spezieller Methoden und Modellierungstechniken.
7. Berücksichtigung der Grundprinzipien: Denken in Systemen, Strukturierung, minimale Modelle, Verständlichkeit, Anwendung mehrere Sichten, Standardisierung, vom Ganzen zum Detail [Win16].
8. Semantische Trennung der Begriffe Diagnose und Prognose.
9. Formulierung des Health Managements als Optimierung.
10. Integration der Kausalität.
11. Nutzung von CRISP-DM als methodische Basis.

3.3.2 Forschungsfragen

In den Forschungsfragen wird das Ziel der Forschung formuliert. In Anlehnung an die initialen Forschungsziele aus Abschnitt 3.1 sowie den Schlüsselfaktoren werden zwei zentrale Forschungsfragen abgeleitet:

1. Wie lassen sich sowohl Konzepte (fachlicher Diskursraum) als auch Modelle im PHM generisch und holistisch im Kontext der Technikwissenschaften beschreiben, sodass einerseits Einordnung und Abgrenzung gegenüber etablierter Anwendungswissenschaften und andererseits die Beherrschung der Komplexität möglich ist?
2. Wie lassen sich die Konzepte und Modelle in einer Methodik logisch verknüpfen, sodass die Entwicklung von PHM-Lösungen strukturiert und effizient abläuft?

3.3.3 Evaluation

Eine Grundlagenwissenschaft kann nach Helfrich [Hel16] auf Basis der Güte ihrer Abbildung bewertet werden. In dieser Arbeit geschieht dies in Form von drei Evaluationsschritten:

1. Iterativer Abgleich mit den Literaturquellen der Metaanalyse.
2. Anwendung und daraus folgende ständige Weiterentwicklung auf Basis studentischer Arbeiten (Literaturverzeichnis Abschnitt 7).
3. Finale Evaluation anhand der Beispiele in Kapitel 6.

Kapitel 4

PHM: Grundlagen, Konzepte und Modellierung

Prognostics and Health Management (PHM) verknüpft klassische Disziplinen, wie Zuverlässigkeits- und Regelungstechnik, mit Ansätzen des Data-Science und Maschinellen Lernen (Kapitel 3). Die sich daraus ergebende Vielfalt in Terminologie und Methodiken verbunden mit dem relativ jungen Alter der Disziplin [KAC17] bilden eine Barriere in der Entwicklung von PHM-Lösungen. Auf Basis einer konsistenten Formulierung von Grundlagen, Konzepten und Modellierung zielt dieses Kapitel darauf ab, diese Barrieren zu überwinden und legt somit die Basis zur Entfaltung der vollen Potentiale einer PHM-Lösung in Kapitel 5.

4.1 Einführung

Das übergeordnete Ziel einer PHM-Lösung ist es zukünftige Ausfälle, Fehler oder Störungen (allg. den Zustand) im System¹¹ zu prognostizieren und auf Basis dieses Wissens optimale Maßnahmen im gesamten Lebenszyklus abzuleiten. Dies sind beispielsweise Maßnahmen der Instandhaltung, Sicherheit, Zuverlässigkeit oder eine Kombination der Genannten. In dieser Arbeit wird PHM als übergeordnete Grundlagenwissenschaft einer Reihe etablierter Anwendungswissenschaften gesehen¹². Zu den Anwendungswissenschaften gehören das „Condition Monitoring“, „Predictive Maintenance“, „Prescriptive Maintenance“ u. v. a. m.

¹¹System wird hier und im Folgenden als generischer Begriff verwendet, siehe auch Abschnitt 3.2.

¹²Siehe Kapitel 3.




Bild 4.1 Unsicherheiten in der Bewertung der zukünftigen Zustandsverläufe (EOL: End of Life, RUL: Remaining Useful Life).

Charakteristisch im PHM ist der Gedanke der Transition von der Zustandsdiagnose hin zur Zustandsprognose, adressiert durch den Begriff des **Prognostics**. Dabei beschreibt die Zustandsdiagnose den zum Zeitpunkt der Aussage bekannten Zustandsverlauf, d. h. bis zum gegenwärtigen Zustand (siehe Bild 4.1). Ausgehend vom aktuellen Zeitpunkt, kann sich der zukünftige Zustandsverlauf¹³ in Abhängigkeit der angenommenen Nutzung stark unterscheiden. Erst mit der Zustandsprognose wird es möglich die zukünftige Nutzung zu schätzen und den Ausfallzeitpunkt (t_{EOL}) mit minimaler Unsicherheit vorherzusagen.

Hohe Genauigkeiten in der Zustands-Bewertung sind die Basis qualifizierter Entscheidungen hinsichtlich Instandhaltungs-, Verfügbarkeits- und Sicherheitsmaßnahmen. Die gesamtheitliche Einbeziehung all dieser Aspekte in die Entscheidungsfindung ist das zweite PHM-Charakteristikum, adressiert durch den Begriff des **Health Management**. Gesamtheitlich meint einerseits die Einbeziehung aller an das System gestellten Ziele plus Nebenbedingungen. Ebenfalls ist damit die Berücksichtigung des soziotechnischen Systemumfelds über den gesamten Lebenszyklus gemeint. Beispielsweise können sich die Systemziele eines Industrieroboters dynamisch mit den Zuständen anderer Produktionsgüter verändern. Dabei ermöglicht das Health Management theoretisch den Zustand eines Systems so zu regeln, dass dieses nie ausfällt. Praktisch fordert dies aber meistens einen Verlust an Funktionalität, der ebenfalls nur bis zu einem gewissen Maß akzeptiert wird. In Anlehnung an Abschnitt 3.2 wird PHM wie folgt verstanden:

„Prognostics and Health Management ist eine technische Disziplin, die sich mit der Bewertung, Optimierung und Regelung der nutzbaren Restlebensdauer (RUL) eines Systems unter Betriebsbedingungen beschäftigt.“

Dabei bezieht sich die „RUL Bewertung“ auf den Teilbereich des Prognostics

¹³Auch als Zustandstrajektorie bezeichnet.

und die „RUL Optimierung und Regelung“ auf die darauf aufbauenden Maßnahmen des Health Managements. Der Begriff der nutzbaren Restlebensdauer wird in Anlehnung an die Definition der Lebensdauer [BL04] wie folgt definiert:

„Die nutzbare Restlebensdauer RUL (engl. Remaining Useful Life) ist die, zum Zeitpunkt der Aussage, ermittelte verbleibende Lebensdauer, für die angenommen wird, dass das System unter angenommenen zukünftigen Funktions-, Nutzungs- und Umgebungsbedingungen nicht ausfällt.“

4.1.1 Terminologie

Neben den Begriffen PHM und RUL ist das Verständnis der folgenden Begriffe im Kontext dieser Arbeit wichtig. Sortiert sind die Begriffe in die Kategorien PHM, Zuverlässigkeitstechnik sowie Allgemeines.

Begriffe des PHM

Der **Health** (dt. die Gesundheit) des Systems beschreibt eine charakteristische Größe, einen Zustand oder ein Ereignis von Interesse. Oft steht der Health in Verbindung mit der Beschreibung einer Fehlfunktion (Fehler), einem Schaden (Degradation) oder einer Leistungsgröße.

Prognostics umfasst als übergeordneter Begriff alle Aufgaben zur Bewertung des Health, die weiter in Diagnose und Prognose unterteilt werden.

- Aufgaben der **Diagnose** widmen sich der Bewertung des Health in Vergangenheit und Gegenwart.
- Aufgaben der **Prognose** bauen i. d. R. auf der Diagnose auf und widmen sich der Bewertung des Health in der Zukunft. Das Ziel ist die Vorhersage der Lebensdauer, die noch verbleibt, bis ein bestimmtes zukünftiges Ereignis oder ein bestimmter Zustand erreicht ist [Goe+17].

Das **Health Management** beschäftigt sich mit der gesamtheitlichen Optimierung und Regelung der RUL.

Begriffe der Zuverlässigkeitstechnik

Zuverlässigkeit (engl. Reliability) „ist die Wahrscheinlichkeit dafür, dass ein Produkt während einer definierten Zeitdauer unter gegebenen Funktions- und Umgebungsbedingungen nicht ausfällt“ [BL04].

Instandhaltbarkeit (engl. Maintainability) ist die „Kombination aller technischen und administrativen Maßnahmen sowie Maßnahmen des Managements während des Lebenszyklus eines Objekts, die dem Erhalt oder der Wiederherstellung seines funktionsfähigen Zustands dient, sodass es die geforderte Funktion erfüllen kann“ [DIN13306].

Verfügbarkeit (engl. Availability) „ist die Wahrscheinlichkeit dafür, dass sich ein System zum Zeitpunkt t oder während einer definierten Zeitspanne in einem funktionsfähigen Zustand befindet, wenn es vorschriftsmäßig betrieben und instandgehalten wurde“ [BL04]. Verfügbarkeit folgt aus der Kombination von Zuverlässigkeit und Instandhaltbarkeit.

Sicherheit (engl. Safety oder Security) ist die „Freiheit von inakzeptablen Risiken“ [DIN50126]. Sicherheit wird weiter unterschieden in:

- **Safety** beschreibt Aspekte der Sicherheit, „bei der keine absichtliche Gefährdung durch den Menschen im Spiel ist“ [BW18].
- **Security** beschreibt Aspekte der Sicherheit, bei der „menschliche Absicht und Intelligenz hinter einer Gefährdung“ [BW18] steckt.

RAMS bezeichnet die Kombination von Reliability, Availability, Maintainability, Safety [DIN50126].

RAMSS erweitert RAMS um Aspekte der Security.

RAMS+ definiert RAMS als offen für mögliche weitere Aspekte, wie aus Ökonomie oder Qualität.

Allgemeine Begriffe

Ein **Fehler** (engl. Defect) ist die „Abweichung einer Eigenschaft von einem Sollzustand, die jedoch (noch) nicht zu einer maßgeblichen Einschränkung von Funktionen geführt hat, aber Ursache für einen Schaden werden kann“ [VDI3822].

Ein **Schaden** (engl. Failure) beschreibt eine Veränderung „an einem System, durch die eine oder mehrere seiner vorgesehenen Funktionen wesentlich beeinträchtigt oder unmöglich gemacht werden“ [VDI3822]. Ein Schaden wird weiter in Schadensbeeinflussende Faktoren, Schadensmechanismus und Schadensphänomen untergliedert:

- **Schadensbeeinflussende Faktoren:** Einflussfaktoren auf den Schadensmechanismus.
- **Schadensmechanismus:** (engl. Failure mechanism, Physics of Failure (PoF)) Abfolge werkstofflicher Ereignisse, die einzeln oder kombiniert unter Berücksichtigung des Schadensumfelds zum Schaden führen. [VDI3822]

- **Schadensphänomen/-bild/-art:** Äußeres, offensichtliches oder augenscheinliches Erscheinungsbild des beschädigten Systems bzw. einer fehlenden Funktionalität. [VDI3822]

Degradation oder **Schädigung** wird in dieser Arbeit mit einem beobachtbaren Schaden gleichgesetzt. In der Regel verhält sich die Degradation komplementär zum Health, bzw. negativ proportional. In Anlehnung an Meeker und Escobar [ME98] wird unterschieden zwischen:

- **Physikalische-Degradation:** Der Schadensmechanismus ist direkt messbar. Beispiele sind die Messung des Belagverschleißes einer Bremse oder Flächenkorrosion.
- **Leistungs-Degradation:** Der Schadensmechanismus ist indirekt messbar. Beispiele sind die Messung des Leistungsoutputs einer Maschine oder die Kapazität einer Batterie.

4.1.2 Einführungsbeispiel

Ziel dieses Kapitels ist es, auf Basis eines Toy-Examples eine mögliche PHM-Lösung zu veranschaulichen. Bild 4.2 zeigt einen Industrieroboter, der im Toy-Example das **System/Asset** repräsentiert. Das Ausfallverhalten wird durch den Verschleiß der Wälzlager dominiert. Kommt es zu einem ungeplanten Ausfall, verbunden mit dem Stillstand der Produktionsstraße, kann dies zu Stillstandskosten von bis zu 20.000 € pro Minute führen [Con19]. Ziel der PHM-Lösung ist es mittels Zustands-Bewertung die Instandhaltungsmaßnahmen so zu planen, dass ungeplante Stillstände auf ein Minimum reduziert werden.

Der Industrieroboter ist zu diesem Zweck mit Sensoren ausgestattet, die in festgelegten Zeitintervallen Beschleunigungen (**Daten**) aufnehmen. Diese werden bereits am Sensor in ein Frequenzspektrum umgewandelt, um in der Datenübertragung die Vorteile eines deutlich höheren Informationsgehalts zu nutzen. Der stationär verbaute Industrieroboter verfügt über eine stabile und leistungsfähige Netzwerkanbindung, weshalb die Daten zur weiteren Verarbeitung auf eine zentrale Plattform übertragen werden.

Auf die Datenerhebung und -vorverarbeitung folgen Diagnose und Prognose des Zustandes. In der **Diagnose** wird aus den Daten die aktuelle Schädigung D als komplementäre Größe zum Health ermittelt. Bei Inbetriebnahme liegt die Schädigung nahe $D_{t_0} \approx 0$, die mit zunehmender Lebensdauer ansteigt. Der Healthverlauf zum aktuellen Zeitpunkt t_p bildet sich aus allen diagnostizierten Schädigungen von Inbetriebnahme bis zum aktuellen Zeitpunkt. Zur Beschreibung des Verlaufs können Degradationsmodelle oder auch Daten-basierte Algorithmen (Maschinelles Lernen)

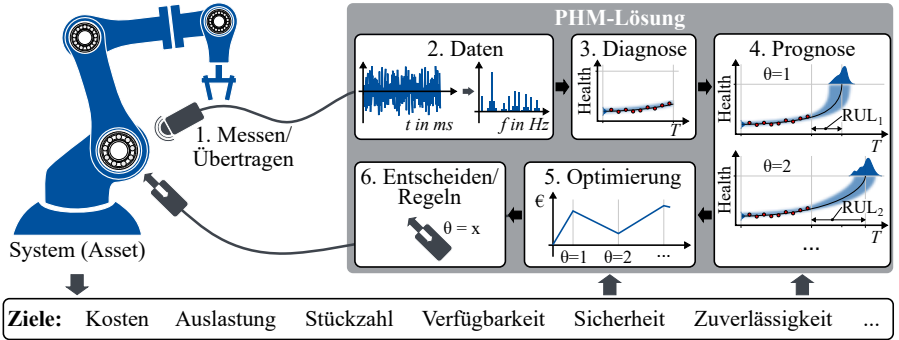


Bild 4.2 Einführendes Toy-Example einer PHM-Lösung.

zum Einsatz kommen. In der **Prognose** werden die Informationen über den bisherigen Zustandsverlauf mit der angenommenen zukünftigen Nutzung (Produktionsplanung) kombiniert und der zukünftige Verlauf prognostiziert. In Verbindung mit einem Ausfallkriterium (EOL-Kriterium, engl. End of Life) ergibt sich der Ausfallzeitpunkt t_{EOL} . Die RUL berechnet sich aus der Differenz zwischen aktuellem Zeitpunkt t_p und berechnetem Ausfallzeitpunkt t_{EOL} . Für unterschiedliche Annahmen der zukünftigen Nutzung θ ergeben sich unterschiedliche RULs.

Das **Health Management** beschäftigt sich damit ein Optimum zu finden und daraus eine Entscheidung abzuleiten. Neben der prognostizierten RUL können diverse weitere Zielgrößen eine Rolle spielen. Im Toy-Example ist das oberste Ziel die Vermeidung eines ungeplanten Stillstands bei minimalen Instandhaltungskosten. Bild 4.3 zeigt den zum aktuellen Zeitpunkt t_p berechneten RUL-Verlauf über der Lebensdauer T ¹⁴. Eine mehr bzw. weniger schädigende Nutzung führt zu einem mehr bzw. weniger steilem Verlauf der RUL. Der Ausfallzeitpunkt verschiebt sich entsprechend zu einer niedrigeren bzw. höheren Lebensdauer. Jede RUL Bewertung unterliegt Unsicherheiten und auch in der Instandhaltung gibt es Latenzzeiten (engl. lag time), die berücksichtigt werden müssen, um Handlungsfähigkeit zu gewährleisten. Aus Sicht der Zuverlässigkeit, legen Ausfallzeitpunkt t_{EOL} und Latenzzeit den lebensdaueroptimalen Zeitpunkt für eine Instandhaltung fest. Bei einem früheren Eingriff wird Lebensdauer verschwendet (Ressourcen bleiben ungenutzt) und bei einem späteren Eingriff besteht ggf. keine Handlungsfähigkeit. Auf der anderen Seite legt die planmäßige Instandhaltung Zeiträume fest, in welchen Wartungsarbeiten einen minimalen Einfluss auf den aktiven Betrieb haben. Neben dem Lebensdaueroptimal gibt es somit einen instandhaltungsoptimalen Zeitpunkt.

¹⁴Wird zum Zeitpunkt t_p eine RUL von $t_{RUL;t_p}$ berechnet, so ergibt sich zum Zeitpunkt $t_p + 1$ eine RUL von $t_{RUL;t_p} - 1$. In allgemeiner Form gilt $t_{RUL;t_p+i} = t_{RUL;t_p} - i$, sprich ein linearer Zusammenhang.

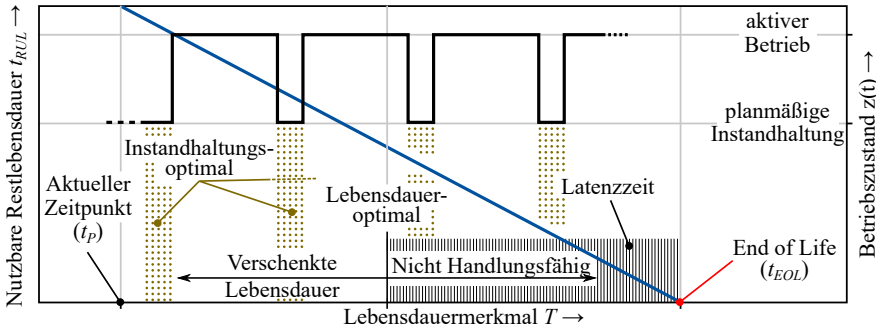


Bild 4.3 Zielkonflikt zwischen Instandhaltungs- und Lebensdaueroptima im RUL-Plot.

In der **Optimierung** werden die Varianten der zukünftigen Nutzung hinsichtlich ihrer Gesamtkosten bewertet. Im Toy-Example ergibt sich das Optimum, wenn Lebensdauer- und Instandhaltungsoptimal zusammen fallen. Dabei kann das Lebensdaueroptimal, respektive die RUL, durch eine Anpassung von Systemparametern oder Nutzung verschoben werden (**Regelung**). Im Falle des Industrieroboters wird das Maß der Schädigung einer Nutzung durch die Taktung beeinflusst. Eine höhere Taktung bedeutet eine niedrigere RUL bei höherer Ausbringung je Zeiteinheit. Konkret wird eine Nutzung gewählt, die das Lebensdauer- in das Instandhaltungsoptimal verschiebt und somit eine vollständige Verwendung der Ressource Lebensdauer mit den Zielgrößen der Verfügbarkeit kombiniert.

4.1.3 Der Health eines technischen Systems

Der Health ist eine System inhärente Größe, die generisch den Gesundheitszustand eines technischen Systems charakterisiert. Dabei handelt es sich um einen Zustand oder ein Ereignis von Interesse, das oft in Verbindung zu einer Funktionalität oder Leistungsgröße steht. Antonym zu Health werden die Begriffe des Fehlers, des Schadens und der Degradation verstanden. In allgemeiner Form ist der Health H bzw. die Schädigung D eine Funktion $f(\cdot)$ eines Lebensdauermerkmals T , der Modellparameter θ und den unabhängigen Variablen \mathbf{X} . Gleichung 4.1 zeigt eine deterministische Formulierung des Health¹⁵.

$$H = 1 - D = f(T, \theta, \mathbf{X}) \quad (4.1)$$

Die wertmäßige Ausprägung des Health wird auch als Healthindex bezeichnet. Dieser lässt sich nach Wang et al. [WYH12] weiter in einen physikalischen Heal-

¹⁵Die deterministische Formulierung ist hier aus Gründen der Einfachheit gewählt. Der Health kann genauso als stochastische Größe definiert werden, beispielsweise in Form von $P_{h_t|\theta, \mathbf{X}, h_{t-1}}$.

thindex (PHI) und einen synthetischen Healthindex (SHI) unterteilen. Der PHI ist anwendbar, wenn die unabhängigen Variablen \mathbf{X} in direkter Verbindung mit Größen der Physik (PoF) stehen. Ist dies nicht der Fall, wird vom SHI gesprochen.

Die Wertemenge \mathbb{W} des Healthindex kann in Form eines Ereignisses, in Form eines Zustandes oder in einer Mischform beschrieben werden. Ereignisse unterscheiden im einfachsten Fall zwischen System intakt ($H = 1$) und nicht intakt ($H = 0$). Bei einer Beschreibung in Form eines diskreten oder stetigen Zustandes liegt die Wertemenge häufig in einem mit fortschreitendem Lebensdauermerkmal abnehmenden Intervall $[0, 1]$.

4.2 Konzepte

Ziel dieses Abschnittes ist es, die Vielzahl der PHM-Anwendungswissenschaften in Form generisch holistischer Konzepte zu ordnen und zu beschreiben¹⁶. Auf dieser Basis werden die vollen Potenziale des Health Managements sichtbar und für den Anwender zugänglich. Bild 4.4 zeigt die gesamtheitliche Darstellung der Konzepte in Form des **fachlichen Diskursraums**. Der Diskursraum wird durch die drei Merkmale beschrieben:

1. Zielsetzung der Konzepte: Unterscheidung zwischen a) der Health Bewertung (Prognostics) und b) der Health Optimierung und Regelung (Health Management).
2. Zeitlicher Bezug: Unterscheidung zwischen a) Aktivitäten der Diagnose (Vergangenheit und Gegenwart) und b) Aktivitäten der Prognose (Zukunft).
3. Charakteristik der Konzepte: Spezielle Merkmale je nach Zielsetzung.

Die drei Merkmale unterteilen den Diskursraum entlang der drei Raumachsen (Bild 4.4). Während Zielsetzung und zeitlicher Bezug eine grundlegende Struktur festlegen, beschreibt das Merkmal „Charakteristik“ eher Entwicklungsstufen, die auch als Treiber hinter der Fachdisziplin PHM gesehen werden können.

Zielsetzung der Konzepte: Während die Zielsetzung im Prognostics die „Health Bewertung“ des Systems in Form einer RUL-Vorhersage ist, geht es im Health Management um eine darauf aufbauende gesamtheitliche Wertschöpfung („Health Optimierung und Regelung“).

Zeitlicher Bezug: Die Bedeutung der Unterscheidung von Diagnose und Prognose Aktivitäten wird in Kapitel 3 ausführlich diskutiert. In der Diagnose wird der Health hinsichtlich Erfahrungen aus Vergangenheit und Gegenwart bewertet. Sprich

¹⁶Basis der folgenden Ausführungen ist die Definition von PHM als übergeordnete Grundlagenwissenschaft, siehe Kapitel 3.

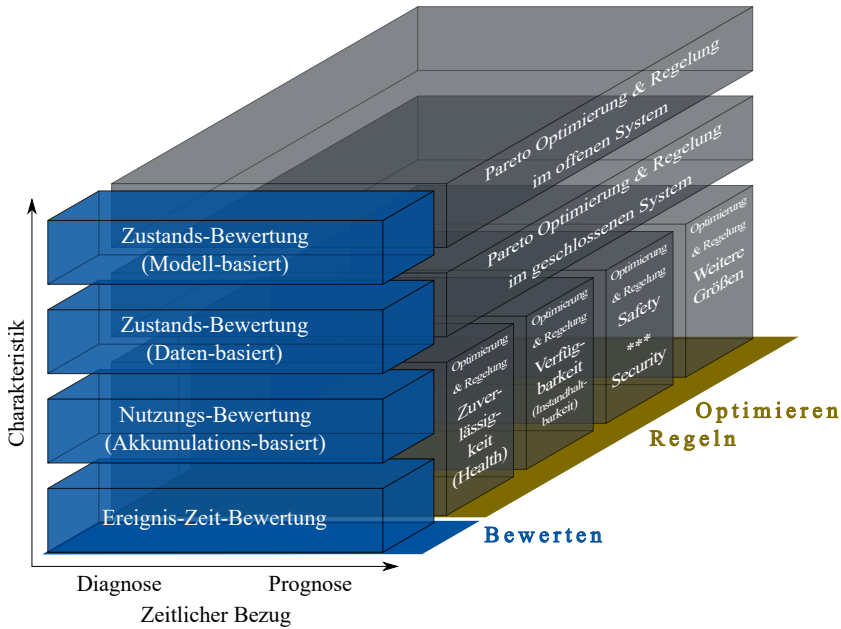


Bild 4.4 Fachlicher Diskursraum PHM (Würfelmodell).

zu bestimmten Zeitpunkten sind Messdaten vorhanden, die aufbereitet, ausgewertet und modelliert werden. Prognosen sind hingegen Vorhersagen zukünftiger Ereignisse. Messdaten sind entsprechend noch nicht verfügbar und auch die zukünftige Nutzung kann nur mit einer gewissen Unsicherheit angenommen werden.

Das Health Management baut immer auf dem Prognostics auf, weshalb der zeitliche Bezug etwaiger Maßnahmen in gewisser Weise immer in der Zukunft liegt. Auf Basis einer Health-Prognose lässt sich der Zeithorizont der Maßnahmenplanung aber deutlich verlängern. Können im Prognostics zudem unterschiedliche zukünftige Nutzungsszenarien simuliert werden, kann eine bezüglich des Health Management optimale Zukunft definiert werden. Im Folgenden wird von einem prognostischen Health Management gesprochen, wenn dieses auf einer prognostischen Bewertung aufbaut.

Charakteristik der Konzepte: Charakteristisch für die Entwicklung sind einerseits die Bemühungen zu immer genaueren Bewertungen sowie andererseits die immer gesamtheitlichere Optimierung und Regelung. In anderen Worten, beschreibt die Charakteristik die Vollständigkeit des Wissens über den tatsächlichen Zustand eines einzelnen Systems sowie die Vollständigkeit aller relevanten Zielsetzungen. Dieser Punkt wird in den folgenden Unterkapiteln (4.2.1 und 4.2.2) detailliert ausgeführt.

Neben den drei vorgestellten Merkmalen ist ein weiteres Merkmal der Grad der Automatisierung einer PHM-Lösung. Dieses Merkmal bezieht sich insbesondere auf die Art der praktischen Umsetzung eines Konzeptes und wird deshalb in Kapitel 5 thematisiert. Grundsätzlich können sowohl die Konzepte der Health Bewertung, Optimierung und auch Regelung vollständig automatisiert oder mit einem sehr starken manuellen Anteil umgesetzt werden. Häufig steigt bei Konzepten mit steigender Genauigkeit und Gesamtheitlichkeit auch der Grad der Automatisierung, da die Komplexität und die Anforderungen steigen.

4.2.1 Prognostics Konzepte

Bevor die Prognostics Konzepte vorgestellt werden, wird einführend das Merkmal „Charakteristik der Konzepte“ diskutiert. Die Charakteristik im Prognostics ist die Entwicklung in Richtung immer genauerer Bewertungen des individuellen Systemhealth. Charakteristische und bestimmende Merkmale dieser Entwicklung sind die Art der Informationsbasis und das verwendete Modell. Dabei legt die Informationsbasis die theoretischen Grenzen der Genauigkeit fest. Die Modellierung bestimmt hingegen die praktische Leistungsfähigkeit. Die charakteristischen Merkmale im Prognostics sind:

- Informationsbasis: Ereignis-, Nutzungs- oder Zustandsdaten
- Modellierung: Ereignis-Zeit-, Akkumulations-, Daten- oder Modell-basiert

Informationsbasis: Das Ausfallverhalten eines Systems wird grundsätzlich durch das Zusammenspiel aus wirkenden Belastungen und ertragbarer Belastbarkeit bestimmt [BL04]. Allgemeiner formuliert ist der Systemzustand abhängig von der individuellen Nutzung und den inhärenten Systemmerkmalen. In der Bewertung des Health sind Art und Umfang der Informationen über Zustand, Nutzung und Systemmerkmale daher entscheidend. In Anlehnung an die Arbeit von Coble et al. [Cob+12] eignen sich die zum System verfügbaren Daten als Basis einer Einteilung der Informationen.

Bild 4.5 zeigt die Einteilung in Nutzungs-, Zustands- und Ereignisdaten. **Nutzungsdaten** sind Input-Daten, die das Systemverhalten beeinflussen und Belastungen repräsentieren. Neben Steuer- und Prozessgrößen beschreiben Nutzungsdaten auch äußere Lasten oder Umweltgrößen. Systemmerkmale werden durch Gestaltung, Fertigung, Werkstoff etc. festgelegt und bestimmen die Belastbarkeit, werden selten aber direkt gemessen. **Zustandsdaten** bilden den System-Output und tragen Informationen über Belastung und Belastbarkeiten [Cob+12; GMZ16]. Eine dritte Kategorie bilden **Ereignisdaten**, wie Ausfallzeiten, Instandhaltungs-, Service- oder Garantie- & Kulanzdaten. Im Vergleich zu Nutzungs- und Zustandsdaten werden Ereignisdaten nicht im klassischen Sinne gemessen, sondern beschreiben eher skalare Leistungskennzahlen, die aus den erstgenannten gewonnen werden.

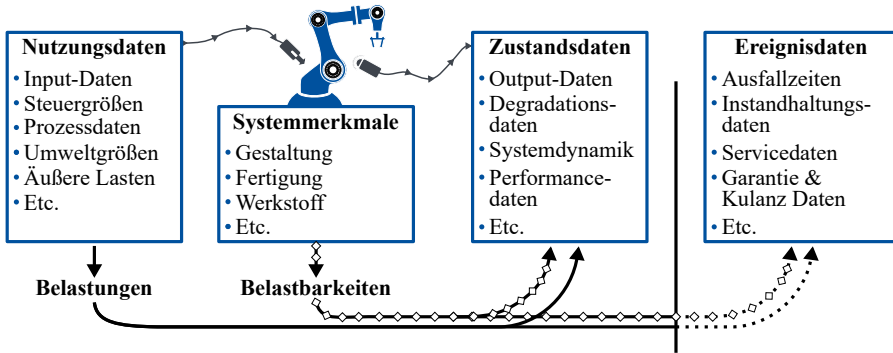


Bild 4.5 Einteilung der Daten in a) Nutzung, b) Zustand und c) Ereignis.

Der wahre Zustand eines Systems wird beeinflusst durch eine Vielzahl an Faktoren, dazu gehören: die Anzahl und Variation von Systemmerkmalen, deren Wechselwirkungen, das komplexe Zusammenspiel mit den wirkenden Mechanismen, konkurrierende Fehlermechanismen, Einflüsse der Belastungsreihenfolge und wechselnde Umweltfaktoren. Zwei Systeme sind deshalb nur in Ausnahmefällen vergleichbar. Aus diesen Gründen lässt sich der wahre Zustand eines individuellen Systems am genauesten auf Basis von Zustandsdaten ableiten¹⁷. In Nutzungsdaten fehlen hingegen wichtige Informationen über die Belastbarkeit des individuellen Systems. Die theoretische Genauigkeit in der Bestimmung des wahren Zustands eines individuellen Systems verringert sich entsprechend der Streuung der Belastbarkeiten in der Grundgesamtheit. Ereignisdaten tragen nur indirekt Informationen über Belastung und Belastbarkeiten. Für das individuelle System liegen Ereignisdaten erst vor, wenn das Ereignis eingetreten ist. Eine Bewertung der systemindividuellen Belastungen/Belastbarkeiten ist vor Eintritt des Ereignisses somit nicht möglich. Die Genauigkeit in der Bestimmung des wahren Zustandes verringert sich entsprechend der Streuung von Belastung und Belastbarkeit in der Grundgesamtheit.

Modellierung: Bei der Vielzahl möglicher Modellierungsansätze ergeben sich selbst bei gleicher Datenbasis unterschiedlich leistungsfähige Konzepte. In Anlehnung an die Arbeiten von Coble et al. [Cob+12], Rakowsky und Bertsche [RB15], Kim et al. [KAC17] und Goebel et al. [Goe+17] sind die folgenden vier Modellierungen hervorzuheben: Ereignis-Zeit-, Akkumulations-, Daten- und Modell-basiert¹⁸. Zudem gibt es Kombinationen und Mischformen, die als Hybride Ansätze bezeichnet werden.

¹⁷Hier und im Folgenden wird vorausgesetzt, dass die Daten Informationen über den Zustand, die Nutzung und das Ereignis von Interesse tragen und nicht andere Zustände/Ereignisse beschreiben.

¹⁸Folgende Bezeichnungen sind in der Literatur äquivalent: Ereignis-Zeit-basiert ↔ Zuverlässigkeits-basiert, Daten-basiert ↔ Daten-getrieben, Modell-basiert ↔ Wissens-/Physik-basiert.

In **Ereignis-Zeit-basierten** Ansätzen wird der Health in Form einer statistischen Verteilung modelliert. Dabei beschreibt die Verteilung die Wahrscheinlichkeit des Eintritts eines Ereignisses über der Lebensdauer. Innerhalb der klassischen Zuverlässigkeitstechnik handelt es sich typischerweise um Ausfallverteilungen, siehe Abschnitt 2.4.1. **Akkumulations-basierte** Ansätze sind grundsätzlich Ereignis-Zeit-basierte Modelle parametrisiert durch die Nutzung und erweitert um eine Schadenshypothese (Vergleich Abschnitt 2.4.3). In Kombination ermöglichen Akkumulations-basierte Ansätze eine Modellierung der auf das System einwirkenden Belastungen (Nutzung) und der daraus resultierenden (inkrementellen) Schädigung.


In dieser Arbeit beschreiben **Daten-basierte** Modelle rein statistische Modelle. Diese können anhand von Daten gelernt werden, erlauben aber nur assoziative Aussagen unter i. i. d. Bedingung¹⁹. Der modellierte Zusammenhang beschreibt nur selten und falls doch, eher zufällig die physikalischen Mechanismen. Assoziative Zusammenhänge sind zudem nicht frei von Störgrößen und Stichprobenverzerrung. Zum Einsatz kommen Daten-basierte Modelle vor allem dann, wenn viele Datenreihen vorhanden sind, aber die physikalischen Mechanismen nicht bekannt, zu komplex, zu vielseitig, zu aufwendig oder nicht direkt messbar sind. Insbesondere bei hochdimensionalen Datensätzen können Daten-basierte Modelle Zusammenhänge erfassen, die dem Experten nicht zugänglich sind. Hier kommen besonders häufig Algorithmen des Maschinellen Lernens zum Einsatz.

Modell-basierte Ansätze beschreiben physikalische Modelle, z. B. in Form physikalischer Fehlermechanismen (PoF). Dabei verknüpfen sie Ursachen (Belastungen und Belastbarkeiten) mit der Wirkung in Form eines Zustandes oder Verhaltens, respektive der gesuchten Healthgröße. Die Modelle beschreiben somit in den allermeisten Fällen kausale Zusammenhänge. Somit ist es auch möglich Interventionen, physikalische Einblicke und sogar kontrafaktische Fragen zu untersuchen¹⁹. Ein Vorteil dieser Modelle ist ihre Robustheit und Invarianz gegenüber Störgrößen, weshalb die höchsten Genauigkeiten erreichbar sind.


Hybride Ansätze kombinieren zwei oder mehrere der vorgenannten Ansätze. Es ist zu beachten, dass die Modellierung selbst aus einer Vielzahl von Teilmodellen bestehen kann, siehe auch Abschnitt 4.3. Dabei können unterschiedliche Ansätze als Teilmodelle genutzt werden, sodass es zu einer sequentiellen Kombination verschiedener Ansätze kommt (Bild 4.6a). Die Gesamtperformance des Modells wird bestimmt durch sein schwächstes Teilmodell. Neben der sequentiellen Kombination, können Ansätze auch parallel kombiniert werden, siehe Bild 4.6b. Motiviert wird diese Lösung durch die Annahme, dass sich Schwächen der einzelnen Modelle gegenseitig ausgleichen²⁰. Daneben sind auch Mischformen oder die Nutzung eines Ansatzes zur gegenseitigen Assistenz möglich (Bild 4.6d und Bild 4.6c).

¹⁹Vergleich Tabelle 2.1 in Abschnitt 2.2.


²⁰Dieses Vorgehen ist in Statistik und Maschinellern auch unter dem Begriff Ensemble-Methoden bekannt [Kan11].




(a) Sequentiell.



(b) Parallel.



(c) Assistenz.



(d) Mischform.

Bild 4.6 Unterschiedliche Kombinationsformen innerhalb der Hybriden (in Anlehnung an [BL04; GMZ16])

Konzepte

Prognostics Konzepte ergeben sich aus der Kombination von Informationsbasis und Modellierung. Grundsätzlich ist so eine Vielzahl an Konzepten möglich und denkbar. Aus den möglichen Kombinationsmöglichkeiten haben sich die folgenden vier Prognostics Konzepte etabliert:

1. Ereignis-Zeit-Bewertung
2. Nutzungsbewertung (Akkumulations-basiert)
3. Zustands-Bewertung (Daten-basiert)
4. Zustands-Bewertung (Modell-basiert)

Tabelle 4.1 zeigt die Kombinationsmatrix der charakteristischen Merkmale zu den vier Prognostics Konzepten²¹. Charakterisiert werden die Konzepte anhand der Daten mit dem höchsten Informationsgehalt, welche die Basis der Modellierung bilden. Dies schließt nicht aus, dass in der praktischen Umsetzung auch weitere Daten genutzt werden. Beispielsweise kann in der Zustands-Bewertung der Ausfallzeitpunkt (EOL) anhand des Abgleiches mit Ereignis-Daten ermittelt werden. Ebenfalls ist es möglich aus Zustandsdaten Ereignisdaten zu extrahieren, dies bedeutet aber i. d. R. ein Verlust an Genauigkeit. Im Folgenden werden die vier Prognostics Konzepte beschrieben. Eine Übersicht über die wichtigsten Merkmale zeigt Tabelle 4.2. Tabelle 4.3 fasst die Vor- und Nachteile der vier Prognostics Konzepte nochmals zusammen.

²¹Ein nennenswertes weiteres Konzept bildet die Nutzungsbewertung auf Basis Daten-basierter Modelle. Praktische Anwendungen sind aus der Metaanalyse nicht bekannt, weshalb es hier nicht näher ausgeführt wird.

Tabelle 4.1 Kombinationsmatrix Prognostics Konzepte.

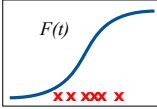
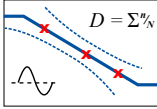
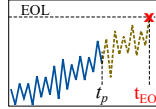
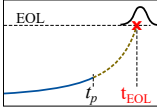
	Ereignis-Daten	Nutzungs-Daten	Zustands-Daten
Ereignis-Zeit-basiert	1. Ereignis-Zeit-Bewertung		
Akkumulations-basiert		2. Nutzungs-Bewertung (a. Akkum.-basiert)	
Daten-basiert		(b. Daten-basiert)	3. Zustands-Bew. (Daten-basiert)
Modell-basiert			4. Zustands-Bew. (Modell-basiert)

Die **Ereignis-Zeit-Bewertung** modelliert typischerweise Ausfälle (Ereignis) in Form von Ausfallverteilungen P_T , wie der Weibull-, Lognormal- oder Exponentialverteilung (siehe Abschnitt 2.4.1). Dabei werden die Modelle auf Basis einer Stichprobe bekannter Ausfälle als Repräsentant der Grundgesamtheit gebildet. Das individuelle zu bewertende System hat keinen Einfluss auf die Modellbildung. In der Diagnose eines neuen Systems lässt sich zu jedem Zeitpunkt der Lebensdauer t eine Ausfallwahrscheinlichkeit $P_{T=t}$ zuordnen. Zur Prognose wird als EOL-Kriterium eine Ausfallwahrscheinlichkeit X festgelegt und die zugehörige Ausfalllebensdauer B_X ermittelt. Im Betrieb kann die RUL als einfache Differenz aus aktueller Laufzeit t_p und B_X berechnet werden.

Sind Ausfalldaten vorhanden, lässt sich dieses Konzept mit dem geringsten Aufwand umsetzen. Da die individuellen Belastungen und Belastbarkeiten nicht berücksichtigt werden, ist die Genauigkeit vergleichsweise gering. Zudem ist zu beachten, dass zum Zeitpunkt B_X ein Ausfall von $X\%$ aller Systeme in Kauf genommen wird. Auf der anderen Seite sind $1 - X\%$ aller Systeme noch funktionsfähig.

Die **Nutzungs-Bewertung** erweitert die Ereignis-Zeit-Bewertung um die Differenzierung der systemindividuellen Nutzung, meist in Form spezifischer Belastungen σ_j . In der Modellierung werden überwiegend Akkumulations-basierte Ansätze verwendet, die Lebensdauermodelle und Schadenshypothesen kombinieren. Zu diesem Zweck wird die Menge aller möglichen Belastungen in k diskrete Belastungsgruppen eingeteilt. Die Festlegung bildet einen Kompromiss zwischen Genauigkeit, Modellierungs- und Messaufwand. Anhand dieser Belastungsgruppen werden k belastungsspezifische Ausfallverteilungen $P_{T=t|\sigma_j}$ bzw. ein Lebensdauermodell modelliert (siehe Abschnitt 2.4.2). Neben dem Lebensdauermodell ist eine Schadenshypothese zu wählen, die den Einfluss der Einzelbelastungen auf den Health beschreibt

Tabelle 4.2 Gegenüberstellung charakteristischer Eigenschaften der Prognostics Konzepte.

	Ereignis- Zeit- Bewertung	Nutzungs- Bewertung (Akku.-bas.)	Zustands- Bewertung (Daten-bas.)	Zustands- Bewertung (Modell-bas.)
				
	Erreichbare Genauigkeit			
Informationsb.:	Ereignisdaten	Ereignis- und Nutzungsdaten	Zustands- und Nutzungsdaten	Zustands- und Nutzungsdaten
Modellierung:	Ereignis-Zeit-basiert	Akkumulations-basiert	Daten-basiert	Modell-basiert
Modell-Taxonomie ¹⁹ :	Statistische-Modelle	Statistisch-Physikal.-Modelle	Statistische-Modelle	Physikal.-modelle
Interventionen:	×	(✓)	×	✓
Healthmodell:	$P_{T \theta}$	$P_{T \sigma_j, \theta_j; \sum_j^k}$	$f(\theta, \mathbf{X})$	$f(\theta, \mathbf{X})$
Beispiele:	Ausfallverteilungen	Lebensdauermodelle & Schadenshypothesen	Selbstlernende Modelle	Degradationsmodelle
Parameter θ :	Verteilungs-Parameter	Leb.-Modell-Parameter	Beliebige Bedeutung	Deg.-Modell-Parameter
Nutzungs-information in Variable \mathbf{X} :	Laufzeit T	Laufzeit T je Nutzungsgruppe σ_j	Beliebige Merkmale über Laufzeit	Physikalische Merkmale über Laufzeit
Zustands-information in Variable \mathbf{X} :	×	×	Beliebige Merkmale über Laufzeit	Physikalische Merkmale über Laufzeit
$\mathbf{X} \rightarrow H$:	Assoziativ	Assoziativ	Assoziativ	Kausal
Healthverlauf:	Binär	Diskret	Stetig	Stetig

und so die systemindividuelle Nutzung adressiert.

In der Diagnose eines neuen Systems wird die Laufzeit t je Belastungsgruppe σ_j ermittelt, z. B. in Form eines Belastungskollektivs $h(\sigma_j)$. Auf Basis von Lebensdauermodell und Schadhypothese kann jeder aufgetretenen Belastung σ_j eine (inkrementelle) Abnahme des Health d_i zugeordnet werden. Handelt es sich um eine Schadhypothese mit linearem Ansatz, ergibt sich die Gesamtschädigung zum Zeitpunkt t_p zu $D_t = \sum_{i=0}^t d_i$. Der Ausfall wird dabei häufig über einen definierten Grenzwert (z. B. $H_{EOL} = 0$) definiert [Hai06]. In der Prognose wird der Ausfallzeitpunkt t_{EOL} in Abhängigkeit des zukünftig angenommenen Belastungskollektivs $h(\sigma_j)$ ermittelt. Der Ausfallzeitpunkt entspricht dem Zeitpunkt beim Erreichen des Grenzwertes H_{EOL} . Für unterschiedliche Belastungskollektive $h_i(\sigma_j)$ ergeben sich unterschiedliche Ausfallzeiten $t_{EOL;i}$. Somit ist es mit diesem Konzept vergleichsweise einfach möglich, unterschiedliche Nutzungsszenarien zu simulieren.

Die Ermittlung eines Lebensdauermodells ist bereits um einiges komplexer als die Ermittlung einer einzelnen Ausfallverteilung. Im Gegenzug kann die Modellierung aber auch systemindividuelle Nutzungen berücksichtigen, wodurch die Streuung sinkt und die Genauigkeit steigt. Ein weiterer Vorteil dieses Konzeptes ist die sehr einfache und anschauliche Simulation unterschiedlicher zukünftiger Nutzungsszenarien.

Die **Zustands-Bewertung** ermöglicht als einziges Konzept einen Rückschluss auf die tatsächliche Belastbarkeit des individuellen Systems im Betrieb. Im Vergleich aller Konzepte lässt sich der Health auf dieser Basis am genauesten bewerten.

In der **Daten-basierten Zustands-Bewertung** kommt eine Vielzahl unterschiedlicher Modelle zum Einsatz, angefangen bei einfacher Regression bis hin zu Künstlichen Neuronalen Netzen. Zur Modellerstellung wird i. d. R. eine hohe Anzahl strukturierter und unstrukturierter Merkmale verwendet, die von einer möglichst großen Vielzahl an Systemen stammen. Auf Basis der Daten wird das Modell parametrisiert, häufig nach den Prinzipien des Maschinellen Lernens. Ziel ist es Muster oder Trends in den Daten zu identifizieren, auf deren Basis der Zustand bewertet werden kann.

Je nach gewählter Modellierungstechnik, den verfügbaren Daten, der Modellierungsaufgabe etc. sind Diagnose und Prognose sehr unterschiedlich ausgeführt. Ein Beispiel ist die Daten-basierte Modellierung des Zustandsverlaufs auf Basis von Recurrent Neural Networks (RNNs). Als Daten stehen eine Vielzahl unterschiedlicher Nutzungs- und Zustandsdaten für eine Reihe von Systemen als Input und der wahre Healthverlauf als Output zur Verfügung. Das RNN wird supervised anhand der Input und Output Daten trainiert. In der Diagnose eines neuen Systems sind dessen Nutzungs- und Zustandsdaten der Input für das trainierte Modell, das als Output eine Schätzung des Healthverlaufs liefert. Unter bestimmten Bedingungen können die Modellparameter leicht nachjustiert werden (Transfer-Learning), um die Anpassung auf das neue System zu verbessern. Zur Prognose kann das RNN mit einem zeitlichen Versatz k zwischen Input $t_I = t$ und Output $t_O = t + k$ trainiert werden. Das

Tabelle 4.3 Vor- und Nachteile der Prognostics Konzepte.

Ereignis-Zeit-Bewertung	Nutzungs-Bewertung (Akku.-basiert)	Zustands-Bewertung (Daten-basiert)	Zustands-Bewertung (Modell-basiert)
Vorteile			
<ul style="list-style-type: none"> • Einfache Modelle • Etabliert 	<ul style="list-style-type: none"> • Relativ einfache Modelle • Systemspezifische Belastungen • Anschauliche Nutzungs-Szenarien 	<ul style="list-style-type: none"> • Hoch genaue Modelle • Systemspezifische Belastung & Belastbarkeit • Komplexität beherrschbar • Gut Übertragbar 	<ul style="list-style-type: none"> • Höchst genaue, robuste Modelle • Systemspezifische Belastung & Belastbarkeit • Anschauliche Nutzungs-Szenarien
Nachteile			
<ul style="list-style-type: none"> • Systemspezifische Belastung und Belastbarkeit unbekannt • $X\%$ Ausfälle werden akzeptiert 	<ul style="list-style-type: none"> • Systemspezifische Belastbarkeit unbekannt • Lebensdauermodell benötigt • Belastungserfassung nur in def. Gruppen 	<ul style="list-style-type: none"> • Modell ohne physikalische Bedeutung • Gefahr des Overfitting • Benötigt sehr viele Daten 	<ul style="list-style-type: none"> • Komplexe Modellierung • Benötigt Domänenwissen • Schwierigere Übertragbarkeit

Modell schätzt so einen Healthverlauf mit einem Versatz von k Zeiteinheiten in die Zukunft. Das EOL-Kriterium wird wieder bei Erreichen eines bestimmten (ggf. systemindividuellen) Healthwertes definiert, auf dessen Basis Ausfallzeitpunkt t_{EOL} und RUL bestimmt werden.

Das RNN ist ein Beispiel einer Vielzahl möglicher Ansätze der Daten-basierten Bewertung. Daten-basierte Ansätze können oft angewendet werden, wenn andere Ansätze scheitern. Beispielsweise können Zusammenhänge in hochdimensionalen Daten identifiziert werden, die auf eine andere Weise (vom Experten) nicht erfasst werden. Ein Nachteil ist, dass Daten-basierte Ansätze i. d. R. sehr viele Daten benötigen und ausschließlich assoziative Beziehungen beschreiben. Zudem neigen die Modelle zum Overfitting an die Trainingsdaten, wodurch die Anwendung im Feld zu schlechten Ergebnissen führen kann.

Die **Modell-basierte Zustands-Bewertung** nutzt physikalische Modelle²² zur Beschreibung des Health, wie beispielsweise Degradations- bzw. PoF-Modelle. Das Modell kann entweder aus einer Reihe bekannter Modelle der Fachliteratur ausgewählt werden, oder individuell in geplanten Experimenten entwickelt werden. Die unabhängigen Variablen des Modells bestimmen die relevanten Einflussfaktoren und legen so den benötigten Dateninput fest. In der Diagnose wird der Health auf Basis von Modell und Inputdaten direkt geschätzt. Die Prognose stellt im einfachsten Fall eine Extrapolation des Modells dar (siehe auch Abschnitt 4.3.4). Die Bestimmung von EOL-Kriterium, EOL-Zeitpunkt und RUL entspricht dem vorangegangenen Ansatz. Insbesondere Modell-basierte Ansätze bieten die Chance, ein physikalisches EOL-Kriterium festzulegen, wie eine maximale Risslänge oder eine maximale Verschleißbreite.

Ein Vorteil Modell-basierter Ansätze ist, dass die höchsten Genauigkeiten erreichbar sind. Im Gegensatz zu Daten-basierten benötigen Modell-basierte Konzepte wesentlich weniger dafür aber spezifische Daten. Zur korrekten Identifikation und Beschreibung der relevanten Mechanismen ist zudem ein hohes Maß an Domänenwissen²³ notwendig. Diese hochspezialisierte Modellierung eines Systems ist zudem nur bedingt ohne Anpassung auf ähnliche Produkte (wie Nachfolger, oder Varianten) übertragbar.

4.2.2 Health Management Konzepte

Health Management umfasst Aktivitäten zur Optimierung und Regelung des Health aufbauend auf den Ergebnissen des Prognostics. In anderen Worten, steht hier die Frage im Vordergrund: Wie kann auf Basis der Healthinformationen eine maximale Wertschöpfung im Lebenszyklus des Systems stattfinden? Dabei unterscheiden sich die Ziele von System zu System teilweise stark [RS18; FG13]. Beispielsweise Werkzeugmaschinen, die nicht als Produkt sondern als Service verkauft werden (Betreibermodelle), haben besonders hohe Verfügbarkeitsziele. In autonomen Fahrzeugen liegt die höchste Priorität hingegen auf der Erhaltung sicherheitsrelevanter Funktionen.

Bevor die Health Management Konzepte vorgestellt werden, wird einführend das Merkmal „Charakteristik der Konzepte“ diskutiert, wie im vorangegangenen Abschnitt (4.2.1). Die Charakteristik im Health Management ist die Entwicklung zu einer immer gesamtheitlicheren Optimierung & Regelung des individuellen Systemhealth. Charakteristische und bestimmende Merkmale dieser Entwicklung sind die Zieldefinition (RAMS+) und der Grad an Optimierung & Regelung. Dabei legt die

²²Wird von physikalischen Modellen gesprochen, so umfasst dies auch alle anderen Naturwissenschaften, bspw. Modelle der Chemie oder Biologie.

²³Domänenwissen beschreibt das dem Projektteam zugängliche Wissen über die Health relevanten funktionalen und physikalischen Aspekte sowie die zugrundeliegenden Mechanismen.




Bild 4.7 Darstellung eines Soziotechnischen-Systems (in Anlehnung an [BW18]).

Zieldefinition alle theoretisch an das System gestellten Ziele und Nebenbedingungen fest. Der Grad an Optimierung & Regelung bestimmt hingegen, ob die praktische Optimierung einzelne oder alle Zieldefinitionen berücksichtigt und ob dies zusätzlich in Abstimmungen mit einem weiteren Kontext geschieht. Die charakteristischen Merkmale im Health Management sind:

- Zieldefinition RAMS+
- Grad von Optimierung & Regelung

Zieldefinition RAMS+: In Betrieb eines technischen Systems lassen sich die Ziele klassischerweise in Ziele der Zuverlässigkeit, Verfügbarkeit bzw. Instandhaltbarkeit und Sicherheit unterscheiden. In einer gesamtheitlichen Optimierung sind aber noch weitere Zielsetzungen denkbar, z. B. aus der Ökonomie, weshalb im Folgenden von **RAMS+** gesprochen wird. Zur Festlegung der Systemziele reicht es nicht aus, sich auf die technischen Aspekte zu konzentrieren. Vielmehr müssen auch das soziale und regulatorische Umfeld mit einbezogen werden [BW18]. Eine mögliche Beschreibungsform ist das Soziotechnische System (STS). Bild 4.7 zeigt die Maschine (das technische System) und die Vielzahl an Wechselbeziehungen mit anderen Elementen des STS. Dabei hängt die Funktionserfüllung eines komplexen STS vom reibungslosen Zusammenspiel seiner technischen und sozialen Komponenten ab [BHP12]. In der Definition der Ziele ist es daher wichtig alle Stakeholder im STS einzubeziehen und die Ziele über den gesamten RAMS+ Bereich zu erfassen. Bei der Zieldefinition ergeben sich zudem häufig Nebenbedingungen, wie der Wunsch nach einer minimalen Lagerhaltung von Ersatzteilen. Eine typische Festlegung von Zielen ist die Definition von Kennwerten. Beispielsweise in Form einer B_{10} Lebensdauer, einer Dauerverfügbarkeit A_D oder einem SIL-Level²⁴.

Grad von Optimierung & Regelung: Aufbauend auf den Zielen und Nebenbedingungen lässt sich das Health Management als (mathematische) Optimierungsaufgabe verstehen, die als Output eine Entscheidung liefert [HZB17; HB17]. Die

²⁴Eine ausführliche Beschreibung der Kennwerte ist im Sinne dieser Arbeit nicht zielführend, weshalb auf die Anwendungs- und Branchenspezifischen Normen/Fachbücher verwiesen wird.

Entscheidung kann eine bestimmte zukünftige Nutzung festlegen und so aktiv Einfluss auf den zukünftigen Verlauf des Health nehmen, d. h. der Health wird geregelt. In dieser Arbeit werden die folgenden drei Grade von Optimierung und Regelung unterschieden:

1. Optimierung & Regelung einzelner Ziele
2. Pareto Optimierung & Regelung im geschlossenen System
3. Pareto Optimierung & Regelung im offenen System

Im einfachsten Fall besitzt die Optimierung ein einzelnes Ziel, beispielsweise die Maximierung der Verfügbarkeit. Nebenbedingungen ergeben sich dann aus den Instandhaltungsplänen und dem Umfang an Möglichkeiten die weitere Systemnutzung (Belastung) aktiv zu beeinflussen. Bestehen mehrere Zieldefinitionen, wird von einer Pareto- oder Mehrzieloptimierung gesprochen [Wei06]. Mit steigender Anzahl an Zielen existiert kein globales Optimum mehr sondern mehrere gleichwertige Lösungen, die Paretomenge [Wei06]. Die Auswahl einer Entscheidung kann dann in Abhängigkeit der mit der Entscheidung verbundenen Risiken erfolgen. Beziehen sich alle Zieldefinitionen weiterhin auf ein einzelnes technisches System, wird von einer **Pareto-Optimierung & Regelung im geschlossenen System** gesprochen. Die an ein einzelnes System gestellten Ziele stellen dabei i. d. R. eine Vereinfachung übergeordneter Ziele dar, beispielsweise von Prozess- oder Organisationszielen. Somit stehen die Zieldefinitionen eines einzelnen Systems auch in Wechselwirkung mit anderen Systemen. Mit einer gesamtheitlichen Betrachtung aller Ziele in einem übergeordneten Kontext steigt die Wahrscheinlichkeit gesamtheitlich optimale Entscheidungen zu finden. Ebenfalls steigt die Komplexität des Optimierungsproblems. In diesem Fall wird von einer **Pareto Optimierung & Regelung im offenen System** gesprochen.

Konzepte

Abhängig von den Eigenschaften des Prognostics Konzepts, den Zieldefinitionen des Systems, dem gewählten Grad von Optimierung & Regelung, etc. ergibt sich eine Vielzahl möglicher Konzepte im Health Management. Wie im Prognostics, werden an dieser Stelle die wichtigsten Health Management Konzepte vorgestellt. Dabei werden die Konzepte zwischen **Fehlerprävention** und **Fehlertoleranz** unterschieden (in Anlehnung an [Joh+11]). Konzepte der Fehlerprävention zielen auf die Vermeidung von Fehlern durch zuvorkommende Maßnahmen ab. Im Vergleich, treten in Konzepten der Fehlertoleranz Fehler auf, geeignete Maßnahmen verhindern aber den Verlust wichtiger Funktionen.

Konzepte der Fehlerprävention

Fehlerprävention umfasst alle Maßnahmen, die das Eintreten eines Fehlers verhindern. Dabei handelt es sich insbesondere um Konzepte der Präventiven Instandhaltung^{25,26} [Joh+11], die im Folgenden vorgestellt und in den Diskursraum eingeordnet werden. Die vier Konzepte der Präventiven Instandhaltung sind:

1. Vorausbestimmte Instandhaltung (Periodische Instandhaltung)
2. Nichtvoraussagend (Zustandsorientierte) Instandhaltung
3. Voraussagende (Zustandsorientierte) Instandhaltung
4. Aktive (Zustandsorientierte) Instandhaltung

Bild 4.8 zeigt die Einteilung etablierter Konzepte der Fehlerprävention. Ebenfalls sind die wesentlichen Charakteristika der einzelnen Konzepte beispielhaft dargestellt. Im Folgenden werden die Charakteristika kurz beschrieben. Für detaillierte Erläuterungen zu einzelnen Punkten, wie Planung oder Umsetzung, wird auf die angegebenen Normen verwiesen.

Die **Vorausbestimmte Instandhaltung** ist ein Konzept, in dem die Instandhaltung wiederkehrend in einem bestimmten Zeitintervall oder nach einer festgelegten Anzahl von Nutzungseinheiten durchgeführt wird [DIN13306]. Typischerweise ist die Ereignis-Zeit-Bewertung Basis der Instandhaltungsplanung. Mit der Festlegung der B_X Lebensdauer wird der Zeitpunkt der Instandhaltung bestimmt. Somit wird in diesem Konzept ein Anteil von $X\%$ ungeplanter Ausfälle in Kauf genommen bzw. bei $100\% - X\%$ wird die individuelle Lebensdauer nicht genutzt, d. h. verschenkt. Je nach Varianz der Ausfallverteilung, fällt dieser Anteil höher oder niedriger aus. Ein Vorteil der Vorausbestimmten Instandhaltung ist die vergleichsweise geringe Komplexität.

Die **Zustandsorientierte Instandhaltung** basiert auf einer Nutzungs- oder Zustands-Bewertung des Health. Dabei wird zwischen der Voraussagender sowie der **Nichtvoraussagenden Instandhaltung** unterschieden. In der Nichtvoraussagenden Instandhaltung findet die Entscheidungsfindung auf Basis des diagnostizierten Health statt. Wird ein bestimmter Health erreicht, werden Instandhaltungsmaßnahmen eingeleitet. Im Vergleich zur Vorausbestimmten Instandhaltung kann auf Basis des systemindividuellen Health der Anteil ungeplanter Ausfälle sowie die ungenutzte Lebensdauer stark reduziert werden.

²⁵Während sich die meisten Normen und Literaturquellen über die grundlegenden Konzepte der Instandhaltung einig sind, unterscheidet sich deren Bezeichnung. Basis dieser Arbeit sind die Bezeichnungen nach [DIN13306].

²⁶Neben der Präventiven Instandhaltung kann eine Fehlerprävention auch durch konstruktive Verbesserung erfolgen.

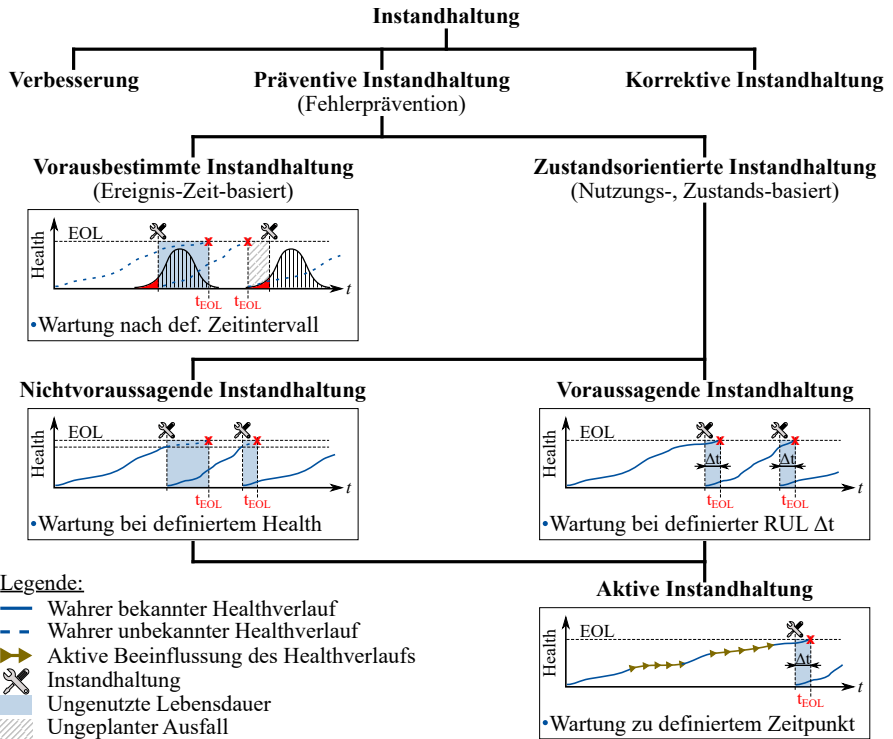



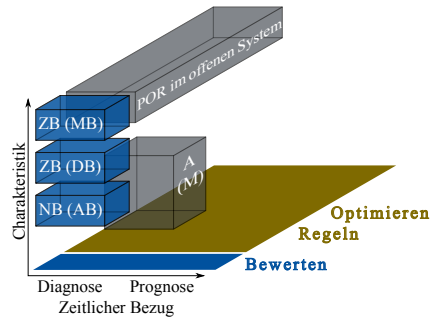
Bild 4.8 Einteilung etablierter Konzepte der Fehlerprävention (in Anlehnung an [DIN13306]).

Die **Voraussagende Instandhaltung** erweitert das vorherige Konzept um die Prognose. Somit wird es erstmals möglich die RUL als Zeitwert direkt zu quantifizieren (unter den entsprechenden Unsicherheiten). Die Instandhaltungsplanung erhält so die bestmögliche Entscheidungsbasis. Alle vorherigen Konzepte nutzen indirekte Größen, wie Ausfallwahrscheinlichkeit oder Healthwert. Der Anteil ungeplanter Ausfälle sowie die ungenutzte Lebensdauer können mit diesem Konzept weiter reduziert werden.


Die **Aktive Instandhaltung** baut auf der Nichtvoraussagenden bzw. der Voraussagenden auf. Neu ist in diesem Konzept die Möglichkeit der aktiven Einflussnahme auf den zukünftigen Verlauf des Health, im Verständnis dieser Arbeit die Health Regelung. Mit der aktiven Einflussnahme auf den Healthverlauf ist es möglich den Instandhaltungszeitpunkt auf einen global optimalen Zeitpunkt zu verschieben, beispielsweise durch Belastungsreduktion zur Verlängerung der RUL. Die RUL kann durch Belastungserhöhung aber auch verkürzt werden, bei ggf. gesteigerter Systemperformance (siehe auch Abschnitt 4.1.2). Theoretisch lassen sich so aus-




(a) Vorausbestimmte Instandhaltung.



(b) Nichtvoraussagend Instandhaltung.



(c) Voraussagende Instandhaltung.



(d) Aktive Instandhaltung.

Bild 4.9 Einordnung etablierter Konzepte der Fehlerprävention in den fachlichen Diskursraum. (EZB: Ereignis-Zeit-Bewertung, NB (AB): Nutzungs-Bewertung (Akkumulations-basiert), ZB (DB): Zustands-Bewertung (Daten-basiert), ZB (MB): Zustands-Bewertung (Modell-basiert), R: Zuverlässigkeit, A (M): Verfügbarkeit (Instandhaltbarkeit), S & S: Safety & Security, +: Weitere Größen, POR: Pareto Optimierung & Regelung, siehe auch Bild 4.4).

fallfreie Systeme entwickeln. Praktisch führt jede Health Regelung zu einer Veränderung/Einschränkung der Funktionalität, die von den meisten Nutzern nur bis zu einem gewissen Grad akzeptiert wird. Mit diesem Konzept kann hinsichtlich der ungeplanten Ausfälle sowie der ungenutzten Lebensdauer ein globales Optimum erreicht werden. Im Idealfall reduziert sich die ungenutzte Lebensdauer dabei bis auf die Latenzzeit.

Bild 4.9 verdeutlicht die Leistungsfähigkeit der vorgestellten Konzepte der Fehlerprävention auf Basis der Einordnung in den fachlichen Diskursraum. Insbesondere die Aktive Instandhaltung ist in der Lage sowohl in der Bewertung des Health als auch in Optimierung und Regelung die höchsten Genauigkeiten bzw. optimalsten Ergebnisse zu erzielen. Im Verständnis der [DIN13306] wird insbesondere die

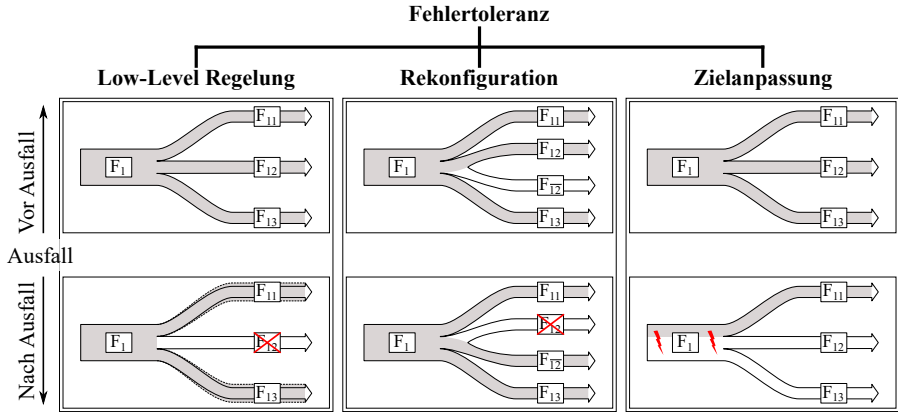


Bild 4.10 Einteilung etablierter-Konzepte der Fehlertoleranz. Die gewählte Darstellung impliziert nicht, dass Funktionen immer seriell/parallel angeordnet sein müssen (F: Funktion).

Optimierung im geschlossenen System adressiert. Unter der Voraussetzung, dass die Optimierungsaufgabe beherrscht ist, gibt es keine Einschränkung die Aktive Instandhaltung im offenen System anzuwenden. Mit der Leistungsfähigkeit der Konzepte steigen prinzipiell der Bedarf an Ressourcen und die Herausforderungen in der Umsetzung. Deshalb unterliegt die Auswahl des individuell passenden Konzeptes einer Kosten-Nutzen-Abschätzung.

Konzepte der Fehlertoleranz

Konzepte der **Fehlertoleranz** erlauben das Auftreten eines Fehlers. Das heißt Fehler werden toleriert, die Fehlerfolgen müssen aber kontrolliert werden [Joh+11]. Um auf einen Fehler reagieren zu können, muss dieser systemindividuell und meist in Echtzeit erkannt werden, weshalb in der Fehlertoleranz ausschließlich Konzepte der Zustands-Bewertung zum Einsatz kommen. Zudem liegt der Fokus oft auf der Detektion von Fehlern, das heißt der Diagnose. Johnson et al. [Joh+11] beschreibt drei prinzipielle Konzepte der Fehlertoleranz:

1. Low Level Regelung
2. Rekonfiguration
3. Zielanpassung

Alle drei-Konzepte spielen vor allem bei sicherheitskritischen Systemen eine Rolle [Joh+11]. Beispielsweise ist die Rekonfiguration und damit die Absicherung über Redundanzen in der Luftfahrt elementar. Bild 4.10 stellt die drei Prinzipien gegenüber. Im Folgenden werden die Charakteristika kurz beschrieben. Für detaillierte

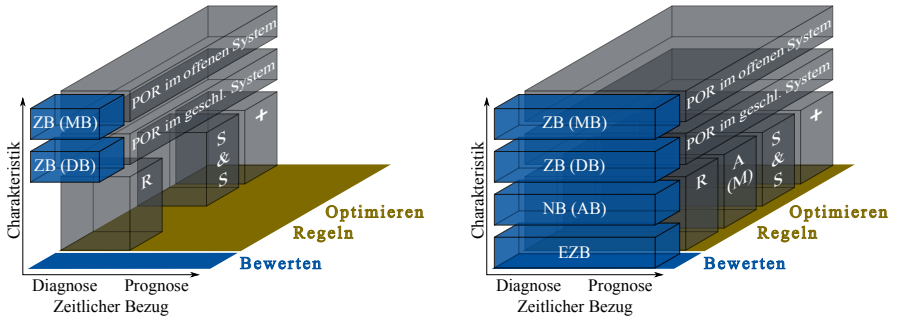
Erläuterungen zur Entwicklung, Umsetzung etc. wird auf die angegebene Literatur verwiesen.

Das Konzept der **Low Level Regelung** verfolgt das Ziel, unkritische Fehler zu zulassen und kritische Fehler zu vermeiden [Joh+11]. Dabei kommen häufig ereignisgesteuerte Kontrollmechanismen zum Einsatz, die Störungen in Echtzeit behandeln [WW18]. Ein solcher Mechanismus, kann beispielsweise eine Getriebesteuerung sein, die bei Ausfall eines Schaltelementes verhindert, dass mit dem defekten Element weitere Schaltvorgänge durchgeführt werden. Damit wird das Getriebe mit eingeschränkter Funktionalität bzw. in nicht optimalen Bereichen angesteuert. Im Gegenzug wird das Risiko minimiert, dass defekte Schaltelemente durch weitere Beanspruchung zerstört werden und es als Folge zum Ausfall des gesamten Getriebes kommt.

Ziel der **Rekonfiguration** ist die Umleitung von Funktionen auf einen intakten Funktionszweig [Joh+11; WW18]. Dafür ist es notwendig, dass die gleiche Funktion von mehreren (unabhängigen) Teilsystemen ausgeführt werden kann. In der Zuverlässigkeitstechnik wird in diesem Fall auch von Redundanzen gesprochen [BL04]. Ist eine Funktion vollständig redundant ausgeführt, kann nach Eintreten des Fehlers das System bei voller Funktionalität weiter betrieben werden. Jede physische Redundanz steigert andererseits die Komplexität, das Gewicht und die Kosten eines Systems.

Das Konzept der **Zielanpassung** sichert die Funktionalität von Primärfunktionen durch Reduzierung sekundärer Funktionen [Joh+11]. Im Vergleich zur Low Level Regelung ist in der Zielanpassung die volle Funktionalität der Primärfunktion gewährleistet. Beispielsweise wird in einem elektrischen Fahrzeug beim Ausfall einiger Batteriezellen die Stromversorgung von sicherheitskritischen Fahrfunktionen aufrechterhalten, während die Versorgung von Sekundärfunktionen (Komfortfunktionen wie Klimatisierung) reduziert wird [Sto+13].

Bild 4.11a zeigt die Einordnung der Konzepte der Fehlertoleranz in den fachlichen Diskursraum. Hinsichtlich der gewählten Merkmale des Diskursraumes lassen sich alle drei Konzepte in der gleichen Darstellung einordnen. Im Vergleich zeigt Bild 4.11b einen prognostischen PHM-Ansatz, der beispielsweise einen sicheren Betrieb bei optimaler Verfügbarkeit unter Beachtung minimaler Kosten im Gesamtunternehmenskontext ermöglicht. Inwieweit die maximale Leistungsfähigkeit eines ganzheitlichen PHM-Konzeptes genutzt wird, ist Kosten-Nutzen Abwägung.



(a) Low Level Regelung, Rekonfiguration und Zielanpassung.

(b) Ganzheitliches PHM.

Bild 4.11 Einordnung etablierter-Konzepte der Funktionserhaltung in den fachlichen Diskursraum. (EZB: Ereignis-Zeit-Bewertung, NB (AB): Nutzungs-Bewertung (Akkumulations-basiert), ZB (DB): Zustands-Bewertung (Daten-basiert), ZB (MB): Zustands-Bewertung (Modell-basiert), R: Zuverlässigkeit, A (M): Verfügbarkeit (Instandhaltbarkeit), S & S: Safety & Security, +: Weitere Größen, POR: Pareto Optimierung & Regelung, siehe auch Bild 4.4).

4.3 Modellierung

Die Modellierung beschreibt den funktionalen Zusammenhang im PHM und ist neben den PHM-Konzepten ein Kernpunkt dieser Arbeit. Wie kein Produkt dem anderen gleicht, gibt es auch wenige PHM-Lösungen deren funktionale Strukturen exakt übereinstimmen. Aus diesem Grund wird die Modellierung anhand generisch holistischer Modellierungselemente beschrieben. In einer konkreten PHM-Lösung werden die relevanten Elemente ausgewählt und zur Erfüllung der Hauptfunktion verknüpft. Dem Grundprinzip „vom Ganzen zum Detail“ folgend, bildet die PHM-Modellierung auf Ebene der Hauptfunktion eine Black-Box, die sich hierarchisch in immer konkretere Teilmodelle aufgliedert. Die hier vorgestellten Teilmodelle gehen auf die Studien in Kapitel 3 sowie darauf aufbauenden Arbeiten zurück und sollen die Gesamtheit an PHM-Lösungen möglichst holistisch repräsentieren. Dabei ist die Modellierung offen für die Ergänzung spezifischer Teilmodelle, deren Existenz bei der Vielzahl individueller Lösungen nicht ausgeschlossen werden kann²⁷.

Bild 4.12 zeigt eine generisch holistische Darstellung der PHM-Modellierung im „PHM-Regelkreis“. Dabei bilden „Bewertung, Optimierung und Regelung des Health“ die Hauptfunktion der PHM-Lösung, wobei der individuelle Schwerpunkt variieren kann. Auf der nächsten Ebene teilen sich die Modellierungselemente in die Bereiche System, Daten, Diagnose, Prognose und Optimierung²⁸ auf, die in Teilm-

²⁷Die Arbeit umfasst keine Ansätze, die alleine auf den menschlichen Sinnen als Sensor aufbauen.

²⁸Siehe auch Kapitel 3.

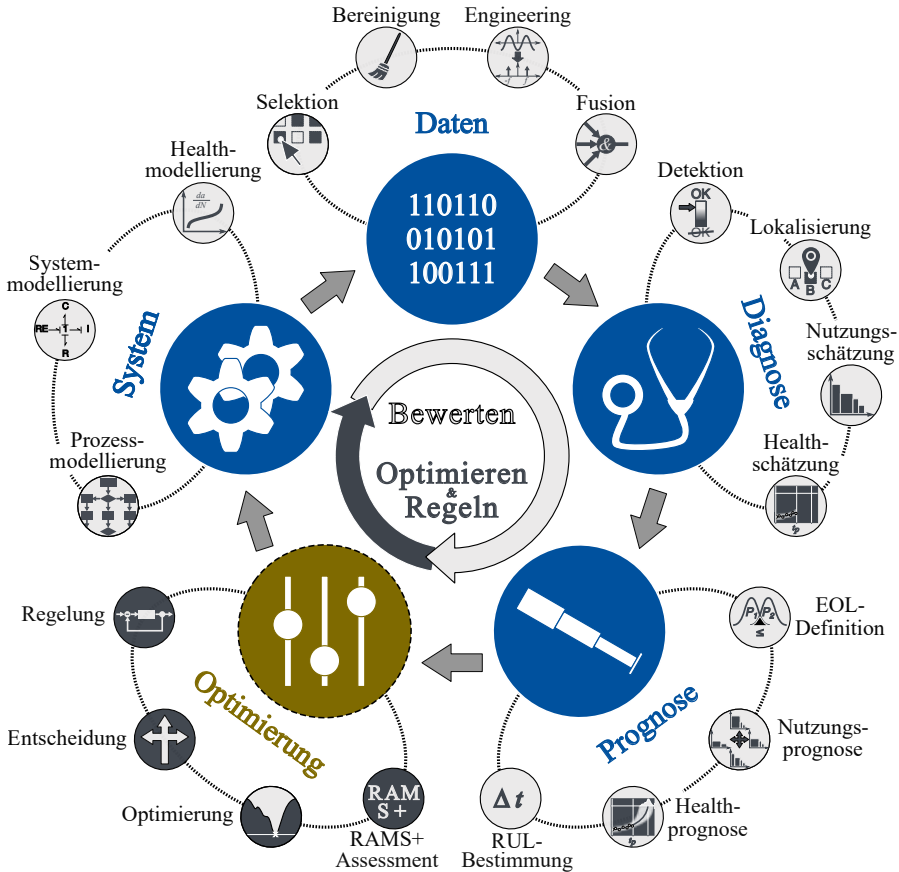


Bild 4.12 PHM-Regelkreis: Wesentliche Elemente der Modellierung (in Anlehnung an [HZB17; HB19a] und [MAP19]).

odelle untergliedert werden. Die Formulierung als geschlossener Kreis, drückt den rekursiven Charakter von PHM-Lösungen aus [HZB17]. D. h. Optimierung und Regelung des Health wirken sich direkt auf die darauf folgende Neubewertung des Health aus (siehe auch Bild 5.14). Im Folgenden werden die Modellierungselemente und soweit möglich typische Lösungsansätze beschrieben.

4.3.1 System

Die Systemmodellierung bildet Zusammenhänge des Systems ab. Dabei wird zwischen Health- und System-/Prozessmodellen unterschieden.

Healthmodellierung

Das Healthmodell beschreibt die Beziehung zwischen unabhängigen Variablen und dem gesuchten Health. Das Healthmodell bildet eine mögliche aber nicht zwingend erforderliche Basis für die Modellierung der Healthschätzung und -prognose. Ansätze²⁹ zur Healthmodellierung sind:

- Physikalische Modelle, wie Lebensdauer- oder Degradationsmodelle³⁰.
- Allgemeine Degradationsmodelle, wie das General Path Model.
- Allgemeine Regressionsmodelle (z. B. linear, exponentiell).
- Healthmodell wird vom Algorithmus gelernt (siehe Healthschätzung).

System- und Prozessmodellierung

System- und Prozessmodelle beschreiben das Systemverhalten im Normalbetrieb [Goe+17]. Dies umfasst Modelle der Systemeigenschaften, -funktionen, -dynamik, -nutzung. Je nach Ansatz reichen die Modellierungsformen von analytischen Modellen bis hin zu numerischen Modellen (FEM, MKS, etc.). Besonders bei Verwendung komplexer rechenintensiver Modelle, wird vom Digitalen Zwilling gesprochen. Ansätze²⁹ zur Nutzung von System-/Prozessmodellen sind:

- Referenzmodell zur Beschreibung des Normalverhaltens. Abweichungen zwischen Normalverhalten und Realität werden erfasst und bewertet.
- Modellierung einer relevanten Variable, die nicht in den unabhängigen Variablen enthalten ist, sich aber aus diesen bestimmen lässt. Dieser Ansatz ist auch unter dem Begriff des Virtuellen Sensors bekannt.
- Simulation verschiedener Alternativen (Iterationen), z. B. zur Simulation möglicher Nutzungsszenarien.
- Performancesteigerung bzgl. Genauigkeit, Rechenzeit oder Speicherbedarf.
- Modellierung der RAMS+ Eigenschaften (z. B. Petrinetze).
- Modelle zur Regelung und Automatisierung.

²⁹Hier und im Folgenden beschreiben die vorgestellten Ansätze eine Auswahl ohne Anspruch auf Vollständigkeit.

³⁰Siehe auch Abschnitt 4.1.3 und Abschnitt 2.4

4.3.2 Daten

Das Ziel der Datenmodellierung ist den Datensatz soweit zu bearbeiten, dass er einen gültigen In-/Output für die nachfolgenden Modellierungsbereiche bildet. Bestandteile der Datenmodellierung³¹ sind Datenselektion, -bereinigung, -engineering und -fusion.

Selektion

In der Selektion wird der Datensatz auf die relevanten Merkmale und Datenreihen reduziert [CRISP-DM]. Relevant sind i. d. R. die Merkmale, die eine starke Beziehung mit der Zielgröße besitzen. Neben Merkmalen werden auch Datenreihen selektiert, zur Sicherstellung der Validität des Datensatzes [CRISP-DM]. Dabei werden beispielsweise Datenreihen auf die Gültigkeit hinsichtlich Umgebungs- und Nutzungsbedingungen geprüft.

Bereinigung

Ziel der Bereinigung ist die Gewährleistung der gewünschten Datenqualität [CRISP-DM] (siehe Kapitel 5.2.2). Dabei sollten insbesondere Erkennung und Handhabung von fehlenden oder inkorrekten Daten definiert werden.

Engineering

Das Feature/Data Engineering bezeichnet die Transformation von Merkmalen in eine Form, die von nachfolgenden Modellierungstechniken effizient genutzt werden kann [BCV12]. Dabei kann ein Ziel die Erhöhung des Informationsgehalts der Eingangsdaten sein, um die Modellierung effizienter oder interpretierbarer zu gestalten. Ein typisches Beispiel ist die Transformation von Vibrationsdaten aus dem Zeit- in den (Zeit-)Frequenz-Bereich. Ein anderes Ziel ist die Dimensionalitätsreduzierung. Viele Daten-basierte Modellierungstechniken benötigen standardisierte und metrische Daten, diese Transformation sollte ebenfalls spätestens an dieser Stelle durchgeführt werden.

Fusion

Die Sensor-, Data- oder Informationsfusion kombiniert Daten und Informationen aus einzelnen und mehreren Quellen. Ziel der Kombination sind homogene, robuste und widerspruchsfreie Datensätze [Kle18]. Beispielsweise werden die Informationen von zwei Sensoren kombiniert, um Fehler am Sensor zu detektieren oder die Genauigkeit zu steigern.

³¹Für konkrete Ansätze der einzelnen Teilmodelle wird auf die entsprechende Fachliteratur verwiesen.

4.3.3 Diagnose

Die Diagnose bewertet den aktuellen Health im Sinne eines Ereignisses oder Zustands. Modellierungselemente der Diagnose sind:

- Detektion: Ist ein Ereignis³² eingetreten?
- Lokalisierung: An welchem Teilsystem ist das Ereignis aufgetreten? Welches Teilereignis ist im System aufgetreten?
- Nutzungsschätzung: Wie wird das System genutzt/beansprucht?
- Healthschätzung: Wie hat sich der Health über der Zeit entwickelt?

Detektion

Die Detektion als eigenständiges Element bewertet das Eintreten von Ereignissen. Dabei wird auch von Anomalien gesprochen, da die Ereignisse oft selten und unerwünscht sind. Ansätze²⁹ zur Detektion und deren Anforderungen sind in Anlehnung an Chandola et al. [CBK09]:

- Supervised Anomalie Detektion (Klassifikation): Der Datensatz beinhaltet eine hohe Anzahl aufgetretener Ereignisse³³, die zur Erstellung eines Algorithmus genutzt werden.
- Unsupervised Anomalie Detektion (Clustering): Ein Algorithmus wird erstellt, der die Datensätze anhand ihrer intrinsischen Eigenschaften unterscheidet (z. B. Ähnlichkeitsmaße). Der Datensatz beinhaltet eine geringe Anzahl aufgetretener Ereignisse, die zur Unterscheidung der Cluster genutzt werden.
- Semi-Supervised Anomalie Detektion: Der Datensatz beinhaltet einen Bereich, der einen ungestörten/ereignisfreien/normalen Betrieb ausweist. Auf diesen Daten wird ein Algorithmus erstellt, sodass dieser die Eigenschaften des normalen Datensatz repräsentiert. Eine Abweichung im Verhalten oder den Ergebnissen des Algorithmus kann dann als eine Abweichung des Datensatzes vom Normalbetrieb gedeutet werden.
- Regelbasierte Detektion: Definition fester Merkmale/Merkmalwerte deren Eintritt ein Ereignis indiziert. Basis können Domänenwissen, Normen und Richtlinien sein.
- Kombinationen der vorgenannten.

³²Im Sinne der Zuverlässigkeitstechnik meist Fehler oder Störung.

³³Verknüpfung von unabhängigen Variablen und der Information wann/welches Ereignis aufgetreten ist

Über den passenden Ansatz entscheiden neben Datensatz und Art des Ereignis die Art der Anomalie. Dabei unterscheidet Chandola et al. [CBK09] Anomalien anhand deren Auftreten (einzelner Datenpunkt oder Kollektiv von Datenpunkten) und ob die Anomalie immer oder nur in einem bestimmten Kontext als solche bewertet wird. Darüber hinaus können Domänenwissen, Systemmodell oder Kanarienvogel-Bauteile³⁴ die Anomaliedetektion unterstützen. Mit einem Systemmodell kann das System im Normalzustand beschrieben werden, sodass Abweichungen zwischen modelliertem fehlerfreiem Zustand und realem Zustand eine Anomalie zeigt.

Lokalisierung

In der Lokalisierung ist das Ziel, das Ereignis einem Teilsystem oder Teilereignis zuzuordnen. Ist diese Information im Datensatz vorhanden, können prinzipiell die gleichen Ansätze wie in der Detektion angewendet werden. Unter bestimmten Bedingungen kann die Lokalisierung auch auf Basis von Domänenwissen aus den Daten gewonnen werden. Beispielsweise können Seitenbänder in einem Frequenzspektrum Informationen über die Art des Fehlers enthalten.

Nutzungsschätzung

Die Nutzungsschätzung bewertet die relevanten Einflüsse zur Charakterisierung der bisherigen Systemnutzung. Dabei kann es sich um direkte äußere Lasten/Belastungen des Systems handeln oder um indirekte Größen, wie Systeminputs in Form von Teilprozessen oder Missionsprofilen. Beschreibungsformen²⁹ der Nutzung sind Last-Zeit-Schriebe, Lastkollektive, skalare Kennwerte etc.

Healthschätzung³⁵

Die Healthschätzung beschreibt Elemente zur Erfassung der Healthentwicklung über der Zeit, vom ersten erfassten Zeitpunkt bis zum Zeitpunkt der Schätzung. Das Ziel ist die Charakterisierung des Healthverlaufs $h(t)$, auf Basis einer deterministischen oder stochastischen Beschreibung. Dabei kann eine Abhängigkeit zwischen dem hier gewählten Ansatz und dem Ansatz der Healthprognose (Abschnitt 4.3.4) bestehen, weshalb die Auswahl in iterativem Abgleich stehen sollte. Die eigentliche Healthschätzung kann aus einem oder mehreren der folgenden Teilschritte bestehen:

- Detektion des Initialisierungszeitpunkts t_0
- Schätzung des Initialisierungswerts h_0
- Schätzung des aktuellen Healthwerts h_{t_p}

³⁴ Als Kanarienvogel-Bauteil (engl. Canary Device) werden Bauteile bezeichnet, welche die gleiche Nutzung wie das eigentliche Teilsystem erfahren aber definiert früher als dieses ausfallen [PK18].

³⁵ In dieser Arbeit wird zur Unterscheidung von Diagnose und Prognose zwischen „schätzen“ und „prognostizieren“ unterschieden. Schätzen bezeichnet das Berechnen von Schätzwerten aus Daten [HS20]. Von prognostizieren wird gesprochen, wenn Aussagen über zukünftige Schätzwerte getroffen werden.

- Schätzung des Healthverlaufs $h(t)$, $\{t \in [t_{0'}, t_p]\}$

Initialisierungszeitpunkt: Viele physikalische Mechanismen besitzen eine Initiierungsphase, wie beispielsweise Ermüdung (Phase der Rissbildung [Hai06]) oder Verschleiß (Einlaufverhalten [RS18]). Eine genaue Healthschätzung vor dem Ende der Initiierungsphase ist oft schwierig, da die vorliegenden Effekte einem stochastischen Einfluss unterliegen. Entsprechend beschreiben viele Degradations-/Lebensdauermodelle erst die anschließende Phase, deren Mechanismen stabiler ablaufen. Ziel dieses Schrittes ist die Detektion des Zeitpunktes, ab dem eine gültige Healthschätzung durchgeführt werden kann³⁶. Die Detektion eines Initialisierungszeitpunkts kann ebenfalls sinnvoll sein, wenn die Healthschätzung sehr performanceintensiv ist. Ansätze²⁹ zur Detektion des Initialisierungszeitpunkts sind neben Domänenwissen insbesondere die der Detektion.

Initialisierungswert: Neben dem Zeitpunkt ist auch der Healthwert zu diesem Zeitpunkt eine stochastische Größe. Ziel dieses Schrittes ist die Schätzung des Healthwertes zum Initialisierungszeitpunkt. Dieser Schritt ist umso wichtiger, umso länger das Gedächtnis der Modellierung ist³⁷. Ansätze²⁹ zur Schätzung des Initialisierungswerts sind:

- Modellierung einer Verteilung $p_{h_{0'}}$ über alle Systeme.
- Schätzung des individuellen Healthwerts (siehe auch Healthwert/-verlauf).
- Normen und Richtlinien.
- Allgemeines Domänenwissen.

Healthwert/-verlauf: Das Ziel dieses Schrittes ist den Healthverlauf nach dem Initialisierungszeitpunkt zu schätzen. Input der Schätzung sind die unabhängigen Variablen zum Zeitpunkt t_p und ggf. die vorherigen Healthwerte, falls eine zeitliche Abhängigkeit besteht³⁸. Die Schätzung kann dabei in einem Schritt erfolgen, oder zuerst den aktuellen Healthwert h_{t_p} ermitteln und anschließend einen Healthverlauf über der Lebensdauer modellieren. Ansätze der Modellierung ergeben sich grundsätzlich aus den Prognostics Konzepten (Kapitel 4.2.1). Insbesondere die Schätzung des Healthverlaufs besitzt eine starke Verbindung mit der Healthprognose. Deshalb sollten die Ansätze aufeinander abgestimmt sein, wenn nicht ein gemeinsamer Ansatz gewählt wird. Insbesondere bei der Schätzung des Healthverlaufs sollten immer auch die Unsicherheiten bewertet werden, beispielsweise in Form von Konfidenzintervallen.

³⁶Dieser Zeitpunkt kann auch mit der Inbetriebnahme zusammenfallen.

³⁷Die Abhängigkeit des gesuchten Wertes von dessen zeitlich vorangegangenen Werten.

³⁸Zeitreihen weisen im Allgemeinen eine Abhängigkeit zwischen benachbarten Werten (einfacher oder auch höherer Ordnung) auf [Box+16; PJS17].

4.3.4 Prognose

Die Prognose folgt auf die Diagnose und ermöglicht die Bewertung der nutzbaren Restlebensdauer unter angenommener zukünftiger Nutzung. Wird die Nutzung explizit modelliert, lassen sich verschiedene Nutzungsszenarien beschreiben und vergleichen. Modellierungselemente der Prognose sind:

- EOL-Definition: Wie ist das Lebensdauerende (engl. End of Life) definiert?
- Nutzungs-Prognose: Wie wird das System in der Zukunft genutzt? Welche unterschiedlichen Szenarien gibt es?
- Health-Prognose: Wie entwickelt sich der Health unter der angenommenen Nutzung?
- RUL-Bestimmung: Wie viel Zeit verbleibt bis der Health das Lebensdauerende erreicht?

EOL-Definition

Ziel der EOL-Definition ist die Bestimmung eines Zustandes, der den Ausfall des Systems charakterisiert. Der Zustand kann auf Basis von Health, Lebensdauermerkmal oder einer Kombination beider definiert werden. In den meisten Fällen handelt es sich um einen konstanten Wert. Theoretisch ist auch eine Modellierung als Funktion möglich. Dabei kann der EOL als absoluter Wert, Änderungsrate etc. des Merkmals beschrieben werden. Ansätze²⁹ der EOL-Definition sind:

- Akzeptierte Ausfalllebensdauer (bspw. B_X).
- Toleranzen des Systemverhaltens (bspw. Vibrationsverhalten).
- Grenzwerte der Degradation/des Verschleiß.
- Grenzwerte des Healthmodells.
- Normen und Richtlinien.
- Allgemeines Domänenwissen.

Nutzungsprognose

Dieser Schritt beschreibt die explizite Prognose der zukünftig angenommenen Systemnutzung. Dabei kann die Nutzungsprognose eine einzelne Nutzung oder verschiedene Nutzungsszenarien ermitteln. Mehrere Szenarien bieten die Möglichkeit im Health Management (Optimierung) ein optimales Szenario auszuwählen oder Unsicherheiten über die zukünftige Nutzung zu adressieren. Ansätze²⁹ der Nutzungsprognose bauen i. d. R. auf der Nutzungsschätzung auf und sind:

- Modellierung durch System-/Prozessmodelle.
- Modellierung anhand ähnlicher Systeme (mit längerer Nutzungszeit).
- Bootstrapping historischer Nutzungen.
- Allgemeines Domänenwissen.

Healthprognose

Die Healthprognose modelliert den zukünftigen Verlauf des Health unter der prognostizierten Nutzung. Dabei besteht eine enge Verbindung mit den Ansätzen der Healthschätzung und Nutzungsprognose. Diese können Basis der Healthprognose oder gemeinsamer Teil eines einzelnen Modells sein. In Konzepten der Ereignis-Zeit-Bewertung entfällt die explizite Modellierung der Prognose, da der Ausfallzeitpunkt bereits durch Ausfallverteilung und EOL-Definition festgelegt ist. In Akkumulations-basierten Konzepten liegt der Fokus auf der Nutzungsprognose, die auf Basis der Schadenshypothese in eine Schädigung umgerechnet wird. Wesentlich ist die Healthprognose insbesondere für Konzepte der Zustands-Bewertung. Ansätze²⁹ der Healthprognose werden der Zeitreihenanalyse zugeordnet und umfassen in Anlehnung an Box et al. [Box+16] und Goebel et al. [Goe+17] folgende:

- Deterministische Systemmodellierung: Ein Healthmodell ist bekannt oder erlernt und der Health lässt sich deterministisch beschreiben, d. h. Einflüsse von Störgrößen, Stichprobenverzerrung und Modellierungsverkürzung sind vernachlässigbar. Zur Prognose wird das Modell des individuellen Systems im mathematischen Sinne extrapoliert.
- Stochastische³⁹ Prozessmodellierung: Der Health wird als stochastischer Prozess abgebildet. Auf Basis dieses Modells wird der Healthverlauf eines individuellen Systems prognostiziert.
- Regression: Der Algorithmus erlernt die Prognose anhand von Trainingsdaten und überträgt gelernte Trends/Muster auf das individuelle System.
- Übertragungsfunktion und Bayes-Filter: Das Healthmodell liefert eine Gleichung in Form einer Übertragungsfunktion (Zustandsraumdarstellung). Die Healthschätzung wird als Filterprozess modelliert, der sich zur Prognose des Healthverlaufs eines individuellen Systems nutzen lässt.
- Resampling: Der zukünftige Healthverlauf ergibt sich durch resampling bekannter Healthverläufe (ähnlicher Systeme), bspw. durch Bootstrapping.

³⁹Bei Degradations- und Verschleißmechanismen handelt es sich grundsätzlich um nichtstationäre Prozesse.

Grundsätzlich sind alle Modellierungen mit Unsicherheiten verbunden, beispielsweise in Form von Modellierungsverkürzungen, Ungenauigkeiten in der Parametrierung oder den Daten [KHO01]. In Prognosen kommen Unsicherheiten über die zukünftige Nutzung, externe Ereignisse, usw. hinzu. Zudem folgen Prognosen konsekutiv Diagnosen und sind somit wiederum von deren Unsicherheiten abhängig. Der Health sollte deshalb immer als statistische Größe gesehen werden und in Kombination mit einem Konfidenz- (Diagnose) bzw. Vorhersageintervall (Prognose) beschrieben werden. Allgemeine Kategorien von Unsicherheiten, die in einer holistischen Betrachtung adressiert werden sollten, sind in Anlehnung an Kennedy et al. [KHO01] die folgenden:

- **Parameterunsicherheiten:** Unsicherheiten in den Modellparametern θ , z. B. in Form eines Bias oder einer Varianz (Under-/Overfitting).
- **Modellunzulänglichkeit:** Verkürzungsmerkmale zwischen Modell und realem Prozess, d. h. Effekte, Zustände, Wechselwirkungen etc. die im realen Prozess nicht aber im Modell vorhanden sind.
- **Restvariabilität:** Variabilität der realen Prozesse unter gleichen Bedingungen, die nicht auf Modellunzulänglichkeiten beruhen.
- **Beobachtungsfehler:** Unsicherheiten in den Eingangsdaten X , z. B. in Form von Messungenauigkeiten.
- **Codeungenauigkeit:** Die Implementierung eines Modells in Code ist häufig nicht trivial, sodass selbst bei bekannter Eingabe die Modellausgabe erst durch Anwendung bekannt ist.

Der Ausfallzeitpunkt t_{EOL} ergibt sich, wenn der Healthverlauf das festgelegte EOL-Kriterium erreicht. Dabei kann der Ausfallzeitpunkt deterministisch t_{EOL} oder stochastisch $p_{t_{EOL}}$ beschrieben werden. Die konkrete Berechnung unterscheidet sich in Abhängigkeit des gewählten Konzeptes, lässt sich im Grundsatz über die Bedingung $h_t \leq h_{EOL}$ beschreiben. Anstelle der deterministischen Beschreibung kann die Beschreibung auch stochastisch erfolgen.

RUL-Bestimmung

Die RUL-Bestimmung bewertet die verbleibende Lebensdauer unter der angenommenen Nutzung. Dabei ergibt sich die RUL aus der Differenz des aktuellen Zeitpunkts t_p (deterministisch bekannt) und dem prognostizierten Ausfallzeitpunkt t_{EOL} .

4.3.5 Optimierung

Die Optimierung repräsentiert die holistische Modellierung des Health Managements, mit dem Ziel einer betriebswirtschaftlichen Wertschöpfung. Basis dieses Schrittes

ist die Healthbewertung der vorangegangenen Schritte. Bestandteile dieses Modellierungselements⁴⁰ sind RAMS+ Assessment, Optimierung, Entscheidung und Regelung.

RAMS+ Assessment

Das RAMS+ Assessment steht für die Ermittlung aller Zielgrößen und Nebenbedingungen in der gesamtheitlichen Betrachtung des Health Managements. Ziel dieses Schrittes ist es, alle relevanten Faktoren zu erfassen und zu analysieren. Dabei können Zielgrößen als einmalig definierte Kennzahlen vorliegen, oder in System-/Prozessmodellen zu jedem Zeitpunkt neu ermittelt werden.

Optimierung

Das Ziel der Optimierung ist die Bestimmung des Optimum/der Paretomenge zwischen RUL/Nutzung und RAMS+ Zielgrößen unter Beachtung der Nebenbedingungen. Zur Lösung der Optimierungsaufgabe stehen eine Reihe von Ansätzen zur Verfügung, wie das Gradientenverfahren oder Evolutionäre Algorithmen.

Entscheidung

Im PHM handelt es sich i. d. R. um Entscheidungen unter bestimmten Risiken bzw. Unsicherheiten, da Healthbewertung und angenommene Nutzung stochastische Größen sind. Ziel der Entscheidung ist es, aus der Paretomenge und den verbundenen Risiken/Unsicherheiten optimale Maßnahmen abzuleiten.

Regelung

Die Regelung nimmt Einfluss auf das System, um die festgelegten Maßnahmen umzusetzen. Ein großer Stellhebel ist die Systemnutzung mit der die RUL aktiv verlängert oder verkürzt werden kann (siehe auch Abschnitt 4.1.2). Auf die aktive Beeinflussung des Systems folgt eine Neubewertung des Health, sodass sich die Modellierung zu einem Regelkreis schließt.

4.4 Einfluss der Prognosegenauigkeit auf die nutzbare Lebensdauer

Mit steigender Genauigkeit in der Healthbewertung können gleichzeitig ungeplante Ausfälle und der Anteil der ungenutzten Lebensdauer reduziert werden (Vergleich

⁴⁰Für konkrete Ansätze der jeweiligen Anwendungswissenschaften, wird auf die entsprechende Fachliteratur/Normung verwiesen.

Abschnitt 4.2.2). Dieser Abschnitt zeigt welchen Einfluss eine Genauigkeitssteigerung auf den Anteil der genutzten Lebensdauer⁴¹ eines Systems besitzt. Diese Betrachtung kann Basis einer Kosten-Nutzen Analyse oder Hilfestellung zur Konzeptauswahl sein.

Im Folgenden wird zwischen Ausfallverteilung und EOL-Verteilung unterschieden. Die Ausfallverteilung modelliert das Ausfallverhalten mehrerer Systeme (Grundgesamtheit) im Sinne der Ereignis-Zeit-Bewertung. Im Vergleich modelliert die EOL-Verteilung die Unsicherheit des Ausfallzeitpunktes eines einzelnen Systems, sprich den Schnittpunkt von Zustandsverlauf und EOL-Kriterium (siehe auch Bild 4.1). Die geringste systemindividuelle Genauigkeit besitzt die Ereignis-Zeit-Bewertung, da sie weder individuelle Belastungen noch Belastbarkeiten berücksichtigt. Mit dem Wechsel zu Nutzungs- bzw. Zustands-Bewertungen lässt sich der wahre Zustand immer genauer erfassen. Aufgrund der flexiblen Form, wird das Ausfallverhalten häufig mittels einer Weibullverteilung $Wbl(b, T)$ modelliert, während EOL-Verteilungen eher als Normalverteilung $N(\mu, \sigma)$ beschrieben werden [BL04; KAC17; Goe+17].


4.4.1 Vorgehen

Die Schwierigkeit in der Beschreibung einer Genauigkeitssteigerung liegt in der Transformation der Weibullverteilung in eine Normalverteilung. Klassische Verfahren, wie die Box-Cox-Transformation, können an dieser Stelle nicht genutzt werden, da das Ziel nicht die Annäherung der Ausfalldaten an eine Normalverteilung ist. Das Ziel ist es vielmehr, die Weibullverteilung mittels einer äquivalenten EOL-Verteilung zu beschreiben. Äquivalent bedeutet an dieser Stelle, dass die genutzte Lebensdauer im Median in beiden Ansätzen identisch ist.


Ausgangspunkt der Transformation sind Weibullverteilungen, mit unterschiedlichen Formparametern b und unterschiedlichen B_X Lebensdauern bei konstantem Lageparameter T . Wird aus der Weibullverteilung ein Ausfallzeitpunkt t_i gezogen, entspricht dieser dem wahren Ausfallzeitpunkt eines einzelnen Systems. Der wahre Ausfallzeitpunkt ist wiederum der Median $\mu_i = t_i$ der EOL-Verteilung. Zur Ermittlung der Standardabweichung σ_{Wbl} wird die Äquivalentsbedingung genutzt. Dabei wird σ_{Wbl} so gewählt, dass sich für eine Wahrscheinlichkeit $P_{N(\mu, \sigma_{Wbl})} = X\%$ im Median der Ausfallzeitpunkte eine Lebensdauer von B_X ergibt. Berechnet wird dies mithilfe der Monte-Carlo Methode, bei 1000 Replikationen und einer maximal zulässigen Abweichung von einem Prozent. Den beschriebenen Zusammenhang zeigt Bild 4.13a. Aus Darstellungsgründen sind hier zwei der n EOL-Verteilungen dargestellt, deren $X\%$ Wert sich im Median mit dem B_X der Weibullverteilung deckt.

Die EOL-Verteilungen $N(\mu, \sigma_{Wbl})$ beschreiben somit im Sinne dieser Untersuchung äquivalente Verteilungen zur ursprünglichen Weibullverteilung. Ziel der Un-

⁴¹Die nutzbare Lebensdauer entspricht beim einzelnen System der Lebensdauer bis zum Ausfall und in der Grundgesamtheit aller Systeme dem Median der Ausfallverteilung.



(a) Transformation der Ausfallverteilung $Wbl(b, T)$ in EOL-Verteilung $N(\mu, \sigma_{Wbl})$.



(b) Vergleich der relativen Standardabweichung $\frac{\sigma_i}{\sigma_{Wbl}}$.

Bild 4.13 Herleitungen zur Untersuchung des Einflusses der Genauigkeit auf die genutzte Lebensdauer.



tersuchung ist die Quantifizierung des Einflusses einer Genauigkeitssteigerung, die in Form einer Reduzierung der Standardabweichung beschrieben wird. Die Abhängigkeit der Weibull äquivalenten Standardabweichung σ_{Wbl} von den Weibullparametern wird durch Normieren herausgerechnet, sodass ein repräsentativer Vergleich zwischen den Parameterkombinationen möglich ist. Beschrieben wird die Genauigkeitssteigerung durch die relative Standardabweichung, die sich aus der reduzierten Standardabweichung σ_i bezogen auf die zugehörige Weibull äquivalente Standardabweichung σ_{Wbl} ergibt. Eine relative Standardabweichung von 0.5 lässt sich bildlich als halbierte Unsicherheit interpretieren. Bild 4.13b zeigt relative Standardabweichungen σ_i/σ_{Wbl} im Vergleich.

4.4.2 Ergebnisse

Die nutzbare Lebensdauer wird anhand der B_X Lebensdauer beschrieben. Dabei wird in beiden Fällen, der Weibullverteilung und EOL-Verteilung, ein Anteil von X % ungeplanter Ausfälle akzeptiert. Bild 4.14a zeigt die absolute Lebensdauer $B_{X;i}$ über der relativen Standardabweichungen σ_i/σ_{Wbl} für verschiedene Kombinationen der Weibullparameter. Die Darstellung zeigt, dass mit steigender Genauigkeit $\lim_{\sigma_i \rightarrow 0}$ die Lebensdauer $B_{X;i}$ gegen den Median der jeweiligen Weibullverteilung strebt. Bild 4.14b zeigt die relative Lebensdauer, das heißt die absolute Lebensdauer $B_{X;i}$ bezogen auf die Weibull äquivalente Lebensdauer $B_{X;Wbl}$. Dabei ist die Darstellung der relativen Lebensdauer logarithmisch aufgetragen.

4.4.3 Schlussfolgerungen

Aus der Untersuchung lassen sich folgende Schlussfolgerungen ziehen:



(a) Absolute Lebensdauer $B_{X;i}$.

(b) Relative Lebensdauer $B_{X;i}/(B_{X;Weib})$.

Bild 4.14 Einfluss der Genauigkeit auf die genutzte Lebensdauer.

- Das theoretische Optimum genutzter Lebensdauer der Grundgesamtheit liegt beim Median der Ausfallverteilung B_{50} .
- Auf Basis einer genaueren Healthbewertung lässt sich die genutzte Lebensdauer verlängern, die Anzahl ungeplanter Ausfälle reduzieren ohne konstruktive Anpassungen oder Änderungen in der Nutzung vorzunehmen.
- Die maximal erreichbare relative Lebensdauererlängerung (Abstand von B_X zum theoretischen Optimum B_{50}) steigt mit kleineren Werten des Formparameters b und kleineren Werten der Ausfallwahrscheinlichkeit X .
 - Kleine Formparameter b weisen beispielsweise Wälzlager ($b \approx 1$, 1 bis 1, 35) und Elektronikkomponenten ($b \approx 1$) auf [BL04]. Diese Bauelemente repräsentieren einen Großteil heutiger PHM-Lösungen [MAP19].
 - Kleine Ausfallwahrscheinlichkeiten X reduzieren den Anteil ungeplanter Ausfälle und zeigen die hohe Bedeutung von PHM-Lösungen für verfügbarkeits- und sicherheitskritische Systeme.
- Der Zusammenhang zwischen Lebensdauer und relativer Standardabweichung ist linear. Das heißt, der Nutzen einer Reduzierung der relativen Standardabweichung von 1, 0 auf 0, 8 verlängert die Lebensdauer um den gleichen Anteil wie die Reduzierung der relativen Standardabweichung von 0, 4 auf 0, 2.

Kapitel 5

Methodik im PHM

Dieses Kapitel beschreibt eine Methodik zur zielgerichteten Auswahl und Entwicklung individueller PHM-Lösungen. Basis der Methodik sind die PHM-Konzepte (Abschnitt 4.2) die schrittweise in eine Modellierung (Abschnitt 4.3) überführt werden. Hierzu verzahnen die einzelnen Schritte etablierte Methoden des Data-Science und der Zuverlässigkeitstechnik.

Eingeordnet in das V-Modell ([VDI2206]) als allgemeiner Produktentwicklungsprozess, konzentriert sich die Methodik auf den Prozessbaustein „domänenspezifischer Entwurf“. Entwurf und Integration der zur PHM-Lösung gehörenden Hardware, Mess- und Kommunikationstechnik, stehen nicht im Fokus dieser Arbeit⁴². Ob und in welchem Umfang auf Entwurf und Integration Einfluss genommen werden kann, hängt stark von der zeitlichen Synchronisierung der Entwicklungsprozesse zwischen System (engl. Assets) und PHM-Lösung ab. Die Entwicklungsprozesse können vollständig parallel, teilweise parallel oder sequentiell ablaufen.

Der datenzentrierte Unterbau der folgenden Methodik ist der CRISP-DM Prozess (Abschnitt 2.5.1), mit einer systematischen Spezialisierung auf den PHM-Kontext. Mit der Spezialisierung werden insbesondere die Phasen der Konzeptauswahl, Analyse und Modellierung beeinflusst, die aus diesem Grund im Fokus der Arbeit stehen. Die Phase der „Daten-Vorbereitung“ im klassischen CRISP-DM wird in dieser Arbeit als Teil der Modellierung behandelt. Einerseits adressiert dies die Notwendigkeit einer online Daten-Vorbereitung in ex-ante Algorithmen (siehe Abschnitt 5.3.1). Zum anderen können Daten-Vorbereitung und Modellierung in Ansätzen des De-

⁴²Abhängig von Reifegrad der Entwicklung sowie ökonomischen Faktoren, reichen Entwurf und Integration von der Entwicklung einer Cloud-Lösung, über Feldtests und Stichprobenerhebung bis zur Planung, Umsetzung und Auswertung von Laborexperimenten. Die Abdeckung dieser Themen übersteigt den Umfang und die Ziele dieser Arbeit.

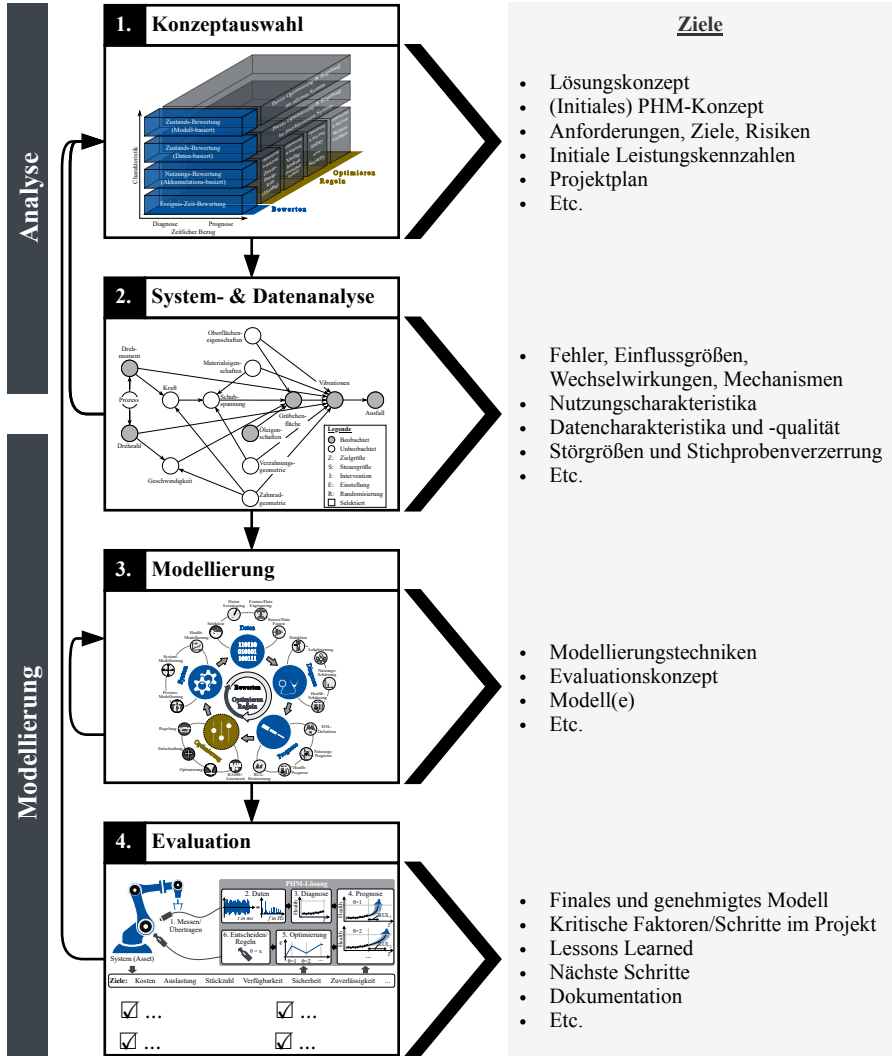


Bild 5.1 Methodik: Die vier Hauptphasen.

ep Learning Teil eines einzelnen Modells sein. Nicht behandelt wird die Phase der „Bereitstellung“, da sie den Bereichen „Entwurf und Integration“ zugeordnet wird.

Bild 5.1 zeigt die vier Hauptphasen der Methodik. Startpunkt bildet die Analyse geeigneter Lösungskonzepte, als Basis für ein spezifisches PHM-Konzept. Diese

Phase steht in starker Abhängigkeit mit der darauf folgenden System- und Datenanalyse. Ziel der Analyse ist ein tiefgreifendes Verständnis der Situation, inklusive der Eingrenzung auf das Wesentliche. In der Modellierungsphase folgt die Festlegung, Umsetzung und Bewertung der Modellierung, die in der letzten Phase evaluiert wird. Eine Phase der Methodik wird i. d. R. in mehrmaliger Iteration mit sich selbst oder einer anderen Phase durchlaufen (vergleichbar mit dem Reifegrad des V-Modells). Jede Phase wird anhand der folgenden drei Aspekte beschrieben:

- Aufgaben
- Ziele
- Metaanalyse

Aufgaben untergliedern die Hauptphasen in einzelne Unterschritte. Die Relevanz der einzelnen Aufgaben unterscheidet sich in Abhängigkeit individueller Faktoren, wie dem avisierten PHM-Konzept, Vorwissen, Ressourcen, Systemspezifikationen etc. **Ziele** beschreiben den Output einer Aufgabe. Je nach individueller PHM-Lösung, besitzen die Ziele eine mehr oder weniger starke Bedeutung. In Bild 5.1 sind die wesentlichen Ziele der Hauptphasen in der rechten Spalte dargestellt. Während die Methodik generisch und unabhängig von Modellierungstechniken ist, zeigt die **Metaanalyse**⁴³ etablierte Lösungen. Mit der Metaanalyse soll somit eine Brücke zu realen PHM-Lösungen geschlagen werden. Die folgenden Abschnitte stellen die vier Hauptphasen im Detail vor.

5.1 Konzeptauswahl (1.)

Das Ziel der ersten Phase ist die schrittweise Eingrenzung und Auswahl eines initialen PHM-Konzeptes mit anschließender Projektplanung. Beeinflusst wird die Auswahl der Konzepte durch eine Vielzahl interner und externer Impulse beteiligter Stakeholder [FG13]. Es gilt Stakeholder, wie Kunden und Betreiber, aber auch Organisationen und Regulatoren zu erfassen und deren Anforderungen in eine einheitliche Sprache zu übersetzen. In dieser Arbeit, ist gemeinsame Basis die Beschreibung in Form von PHM-Konzepten, siehe Abschnitt 4.2.

Bild 5.2 zeigt die drei Aufgaben, die zugehörigen Teilschritte und Ziele der Konzeptauswahl. Neben den internen und externen Impulsen, bestimmen Umsetzbarkeit und Leistungsfähigkeit das optimale Konzept. Diese können häufig erst mit fortschreitender Durchdringung der Komplexität korrekt eingeschätzt werden, weshalb die Konzeptauswahl in iterativer Abstimmung mit der Analyse erfolgen sollte. Ergebnis der Konzeptauswahl ist nicht zwingend nur ein einzelnes Konzept. Oft bietet

⁴³Siehe auch Abschnitt 3.2.2.

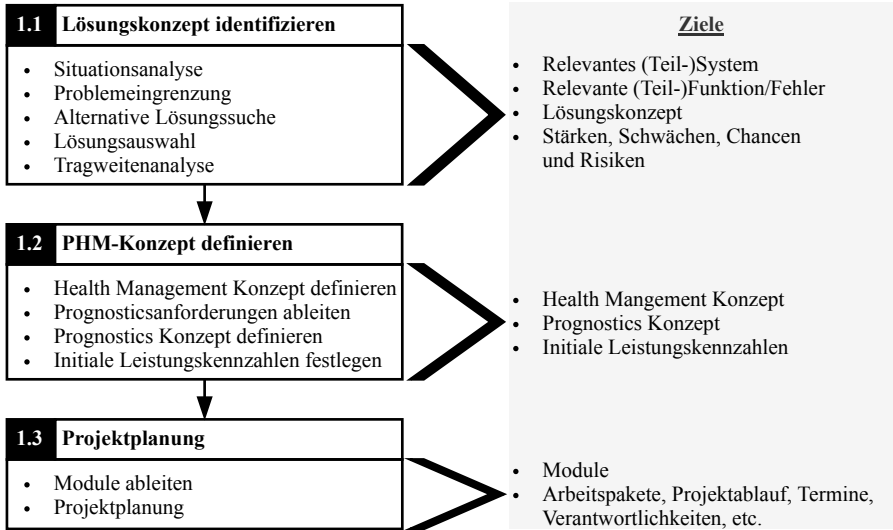


Bild 5.2 Methodik: Phase 1 Konzeptauswahl (Schritt 1.1 in Anlehnung an [Alb+05]).

es sich an mehrere Konzepte bzw. Konzeptvarianten zu definieren und die finale Auswahl in Abstimmung mit den folgenden Phasen zu treffen. Legt der Produktentwicklungsprozess bereits ein konkretes PHM-Konzept fest, entfallen die Teilschritte 1.1 und 1.2.

5.1.1 Lösungskonzept identifizieren (1.1)

Das Ziel der ersten Aufgabe ist es Situation, Problemstellung und Zielsetzung zu verstehen. Vor allem die unternehmerischen Perspektiven stehen im Vordergrund, die erst später in technische Anforderungen übersetzt werden. Die Teilschritte dieser Aufgabe folgen der SPALTEN Problemlösungsmethodik nach Albers et al. [Alb+05] und lauten:

1. Situationsanalyse
2. Problemeingrenzung
3. Alternative Lösungssuche
4. Lösungsauswahl
5. Tragweitenanalyse

Situationsanalyse

Im Schritt der Situationsanalyse werden alle verfügbaren Informationen zusammengetragen, strukturiert, auf Relevanz gefiltert und für die nächsten Schritte verdichtet [Alb+05]. Relevante Informationen sind unter anderem Benchmarks, Konstruktionsdaten, Prozessablaufpläne, Fertigungsunterlagen, Qualitätsdokumente, Instandhaltungspläne oder auch Reparaturdaten.

Problemeingrenzung

Auf die Situationsanalyse folgt die Analyse der Abweichung zwischen Ist- und Sollzustand und somit die Eingrenzung auf den Kern des Problems [Alb+05]. Methodische Hilfsmittel können Situationsanalysen oder Suchstrategien sein, wie 5-W-Methode, Portfolio- oder Szenariotechnik [FG13; RS18]. Es sollten aktuelle und zukünftige Impulse aller Stakeholder identifiziert und der eigenen Leistungsfähigkeit gegenübergestellt werden. Komplexere Kernprobleme können strukturiert in Teilprobleme zerlegt werden, bspw. in Form eines Issue-Trees.

Alternative Lösungssuche

In der Lösungssuche werden zu jedem (Teil-)Problem konkrete Lösungsideen entwickelt. Für diese Aufgabe gibt es nach Feldhusen und Grote [FG13] keine generelle und Erfolg garantierende Methodik. Um möglichst viele diverse Ideen zu generieren, bieten sich Workshops mit Teilnehmenden aller relevanten Fachbereiche⁴⁴ sowie die moderierte Verwendung von Kreativitätstechniken an. (Teil-)Problem und Lösungsideen lassen sich zum Beispiel in einem Morphologischen Kasten beschreiben.

Lösungsauswahl

In einem ersten Schritt werden die Lösungsideen zu konkreten Lösungskonzepten kombiniert. Anschließend werden Bewertungskriterien festgelegt, um die Lösungsideen/-konzepte zu gewichten und miteinander zu vergleichen, beispielsweise mittels Paarweisen Vergleich. Auf dieser Basis findet die finale Auswahl eines Lösungskonzepts statt. [Alb+05]

Im PHM sollte das Lösungskonzept mindestens eine erste Auswahl des relevanten (Teil-)Systems sowie der (Teil-)Funktionalität⁴⁵, die überwacht bzw. erhalten werden soll, beschreiben. Ein weiterer Bestandteil des Lösungskonzepts ist die geplante Umsetzung. Hier sollten neben der zur Verfügung stehenden Infrastruktur, hinsichtlich Laufzeit, Speicherbedarf, Kommunikation usw. ebenfalls der geplante

⁴⁴Relevant können Teilnehmer aus Qualität, Zuverlässigkeit, Systementwickler (Domänenexperten), Algorithmenentwickler, Mess- und Kommunikationstechnik, Service, Versuchsplanung, Finanzen etc. sein.

⁴⁵Die Funktion kann ebenfalls in Form eines Fehlers/einer Störung beschrieben werden.

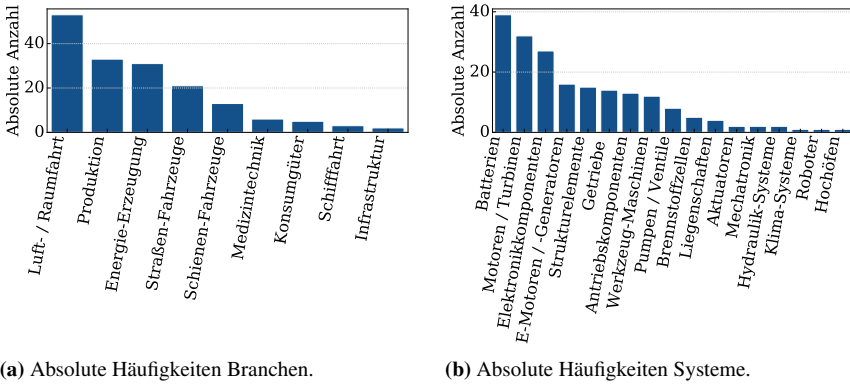


Bild 5.3 Ergebnisse der Metaanalyse: Branchen und Systeme (Basis: [MAP19]).

Grad an Automatisierung beschrieben werden. Dieser reicht von vollautomatisierten Algorithmen bis zu Ansätzen in welchen Experten die Auswertung im laufenden Betrieb manuell durchführen (siehe auch Kapitel 5.3.1).

Tragweitenanalyse

Die Tragweitenanalyse hinterfragt die Stärken und Schwächen des gewählten Lösungskonzepts. Ziel ist es einerseits kritische Punkte aufzudecken und diese durch Gegenmaßnahmen zu entgegnen. Auf der anderen Seite sollen Stärken verstärkt, Chancen ergriffen und Schwächen reduziert werden. [Alb+05].

Metaanalyse ([MAP19]): Die Ergebnisse der Metaanalyse zeigen typische Branchen und Systeme in Verbindung mit PHM-Lösungen, siehe Bild 5.3. Dominant sind Branchen mit hohen Verfügbarkeits- und/oder Sicherheitsanforderungen. In der Systembetrachtung kommen besonders häufig Batterien, dynamisch betriebene Maschinen und Elektronikkomponenten vor. Auf Bauelementebene überwiegen Batteriezellen, Wälzlager und Elektronikkomponenten wie Kondensatoren oder Transistoren.

5.1.2 PHM-Konzept definieren (1.2)

Ziel dieser Aufgabe ist die schrittweise Überführung des Lösungskonzept in ein PHM-Konzept. Ein PHM-Konzept ist eine zusammenfassende Beschreibung der Art und Weise wie, an welcher Stelle und zu welchem Zweck das Prognostics bzw. das Health Management stattfinden soll. Beschreibungsbasis sind die Konzepte in Abschnitt 4.2. Die Aufgabe beinhaltet die folgenden Teilschritte:

1. Health Management Konzept definieren
2. Prognosticsanforderungen ableiten
3. Prognostics Konzept definieren
4. Initiale Leistungskennzahlen festlegen

Health Management Konzept definieren

Im ersten Schritt wird das Lösungskonzept in ein Health Management Konzept übersetzt und erst anschließend in ein Prognostics Konzept. Der Top-Down Ansatz bietet sich an, da Lösungskonzept und Health Management Konzept oft über den Gedanken der unternehmerischen Wertschöpfung verbunden sind und so das strategische Ziel festlegen. Basis der Übersetzung sind die Spezifikationen der Lösungskonzepte, ggf. kombiniert mit Benchmarks vergleichbarer Systeme/Funktionen. Die Erarbeitung kann wie zuvor in Workshops unter Einsatz von Kreativitätsmethoden erfolgen. Legt das Lösungskonzept den Fokus auf die reine Funktionsbewertung (reines Prognostics) entfallen dieser und der nächste Teilschritt.

Prognosticsanforderungen ableiten

Mit der Wahl des Health Management Konzepts werden implizit Anforderungen an das Prognostics Konzept festgelegt. Eine qualitative Orientierungshilfe zur Identifikation dieser Anforderungen gibt Tabelle 5.1. Möglicher Startpunkt ist die Einteilung in Konzepte der **Fehlerprävention** und **-toleranz**. Diese legen initiale Anforderungen an den zeitlichen Bezug und das Prognostics Konzept fest, siehe Abschnitt 4.2.2. Eine **Health-Regelung** setzt mindestens voraus, dass die Wirkung einer Belastungsänderung auf den Health beschrieben werden kann. Dies ist nur in Konzepten der Nutzungs- oder Zustands-Bewertung möglich. Soll die Regelung automatisiert erfolgen, muss der Health als Stellgröße messbar sein, eine Anforderung, die nur Konzepte der Zustands-Bewertung erfüllen. Weitere Anforderungen ergeben sich aus der benötigten **Latenzzeit**. Diese wird einerseits durch die benötigte Zeit zur Umsetzung reaktiver Maßnahmen bestimmt, wie Zeiten zum herunterfahren der Systeme. Andererseits bestimmt sich die Latenzzeit durch den Gradienten der Zustandsänderung. Sehr schnelle Latenzzeiten erfordern Ansätze die Änderungen im Zustand oder der Belastung ohne Verzögerung erfassen und idealerweise im voraus prognostizieren.

Prognostics Konzept definieren

Im dritten Schritt wird das Prognostics Konzept definiert. Basis sind die abgeleiteten Anforderungen aus dem vorherigen Teilschritt sowie qualitative Systemeigenschaften, verfügbare Ressourcen und Anforderungen an Bewertungsgenauigkeit und Re-

Tabelle 5.1 Orientierungshilfe zur Ableitung von Anforderungen an das Prognostics Konzept. Legende: D → Diagnose, P → Prognose, EB → Ereignis-Zeit-Bewertung, NB → Nutzungs-Bewertung, D/MB → Daten- oder Modell-basiert (Zustands-Bewertung), ● → Trifft eher zu, ◐ → Trifft teilweise zu, ○ → Trifft eher nicht zu, × → Nicht möglich.

Lösungskonzept

		D	P	EB	NB	D/MB
Fehlerprävention:	Vorausbestimmt	●	●	●	○	○
	Nicht Vorausschauend	●	×	×	●	●
	Vorausschauend	◐	●	×	●	●
	Aktiv	●	●	×	○	●
Fehlertoleranz:	●	○	×	×	●	
Health-Regelung:	Keine Eingriffe	◐	◐	◐	◐	◐
	Manuelle Eingriffe	◐	◐	×	◐	◐
	Automatisierte Eingriffe	◐	◐	×	○	●
Latenzzeit:	Langsam	●	◐	◐	◐	◐
	Sehr schnell	◐	●	○	◐	●

aktionszeit. Eine qualitative Orientierungshilfe⁴⁶ zur Charakterisierung des Prognostics Konzepts anhand relevanter Kriterien gibt Tabelle 5.2. Etwaige Konflikte können einerseits durch Anpassung des Health Management bzw. Prognostics Konzepts gelöst werden, andererseits kann die Wahl eines Hybriden Konzepts Widersprüche auflösen.

Die **Ausfallart** ist eine typische Charakterisierung der Zuverlässigkeitstechnik, siehe auch Badewannenkurve Abschnitt 2.4. Unabhängig von der Ausfallart gilt, ist ein Fehler eingetreten, lässt sich dieser auf Basis geeigneter Zustandsdaten diagnostizieren. Möglich ist dies unter anderem mithilfe von Algorithmen zur Daten-basierten Anomaliedetektion. Eine Prognose vor dem Eintreten des Fehlers ist prinzipiell bei Degradations-/Verschleißausfällen möglich. Das Erscheinungsbild eines Zufallsausfalls kann sich aus der Akkumulation unterschiedlicher Ausfälle unter Vernachlässigung der statistischen Unterschiede ergeben. In diesem Fall ist es möglich, dass die zugrundeliegenden Ausfälle Degradationsmechanismen beschreiben, womit auch in diesem Fall Prognosen möglich sind. Da die Mechanismen dem Entwickler aber nicht zugänglich sind, in diesem Fall würde man von einem Degradationsausfall

⁴⁶Nutzung der Orientierungshilfe: Für alle relevanten und bewertbaren Kriterien sollte die zutreffende Ausprägung bestimmt werden. Von dieser Auswahl werden Spalten ausgeschlossen, die mindestens ein Kreuz (×) aufweisen. Die Eignung der übrigen Spalten lässt sich über die Vollständigkeit der Kreisfüllung bewerten. Starke Divergenzen innerhalb einer Spalte sollten auf Risiken untersucht und ggf. in einem weiteren Iterationsschritt aufgelöst werden.

Tabelle 5.2 Orientierungshilfe zur Definition eines Prognostics Konzepts. Legende: D → Diagnose, P → Prognose, EB → Ereignis-Zeit-Bewertung, NB → Nutzungs-Bewertung, DB → Daten-basiert (Zustands-Bewertung), MB → Modell-basiert (Zustands-Bewertung), ● → Trifft eher zu, ◐ → Trifft teilweise zu, ○ → Trifft eher nicht zu, × → Nicht möglich.

Lösungskonzept		D	P	EB	NB	DB	MB
Einordnung Tabelle 5.1:		?	?	?	?	?	?
Ausfallart:	Frühausfälle	◐	×	○	×	◐	×
	Zufallsausfall	◐	○	◐	◐	◐	×
	Degradationsausfall	◐	◐	◐	◐	◐	◐
Datenvolumen & -heterogenität:	Sehr gering	◐	◐	◐	◐	○	◐
	Sehr hoch	◐	◐	◐	◐	●	◐
Domänenwissen:	Fehlend	◐	◐	○	○	●	×
	In Ansätzen	◐	◐	◐	◐	◐	×
	Vollständig	◐	◐	◐	◐	◐	●
Daten:	Direkt relevante Größen	◐	◐	◐	●	◐	●
	Indirekt relevante Größen	◐	◐	◐	◐	●	○
Nutzung:	Nicht erfassbar	◐	◐	◐	×	◐	◐
	Erfassbar	●	◐	◐	○	●	◐
	Beschreibbar	●	●	◐	●	◐	◐
Genauigkeit RUL:	Weniger hoch	●	◐	◐	◐	◐	◐
	Sehr hoch	◐	●	×	○	◐	●
System ist:	Einzelstück & hochpreisig	◐	◐	×	×	◐	●
	Serie im Flottenbetrieb	◐	◐	●	●	●	◐
Anforderungen:	Hohe Robustheit	◐	◐	○	○	○	●
	Hohe Erklärbarkeit	◐	◐	◐	◐	○	●
	⋮	⋮	⋮	⋮	⋮	⋮	⋮

sprechen, können keine Modell-basierten Bewertungen angewendet werden.

Insbesondere zum Training der Algorithmen des Maschinellen Lernens wird ein hohes **Datenvolumen** benötigt, d. h. eine hohe Anzahl an Instanzen. Zudem sind Daten-basierte Ansätze im Vergleich zu menschlichen Experten besonders leistungsfähig in stark heterogenen Daten. **Domänenwissen** beschreibt das dem Pro-

jektteam zugängliche Wissen über die healthrelevanten funktionalen und physikalischen Aspekte sowie die zugrundeliegenden Mechanismen. Datenvolumen und Domänenwissen sind ggf. komplementär, sodass Defizite im Einen durch das Andere kompensiert werden können (Konzeptwechsel vorausgesetzt). Voraussetzung ist in beiden Ansätzen, dass direkt oder indirekt relevante Größen beschrieben werden.

Für die Bewertung unterschiedlicher zukünftiger Nutzungsszenarien muss die **Nutzung** des Systems erfassbar sein. Erfassbar meint, dass die Informationen in den Daten vorhanden sind, aber nicht von Menschen beschrieben werden können. Hier bietet sich wieder der Einsatz Daten-basierter Ansätze an. Beschreibbar wird die Nutzung zum Beispiel in Form von Lastkollektiven, die sich für einzelne Funktionen/Prozesse unterscheiden. In diesem Fall, folgt z. B. aus der Produktionsplanung direkt die zukünftige Nutzung. Gibt es verschiedene Varianten der Produktionsplanung, ergeben sich verschiedene Nutzungsszenarien.

Die **Genauigkeit der RUL** ist eine qualitative Abschätzung der Anforderungen an die zulässigen Unsicherheiten der Health-Bewertung. Eine Hilfestellung gibt der Vergleich des Einflusses der Prognosegenauigkeit auf die nutzbare Lebensdauer, siehe Abschnitt 4.4. Bei hochpreisigen, hochkomplexen Einzelstücken, wie z. B. Satelliten, gibt es selten eine hohe Zahl an Daten ausgefallener **Systeme**. Im Gegenzug ist das Domänenwissen oft umfangreich vorhanden und die Anforderungen an die Genauigkeit besonders hoch. Bei diesen Systemen bieten sich daher Modell-basierte Ansätze an. Im Gegensatz liegen für Systeme im Flottenbetrieb ggf. viele Daten vor und die Herausforderung liegt in einer hohen Generalisierung und Übertragbarkeit der Modelle. Unter diesen Rahmenbedingungen eignen sich Daten-basierte Ansätze.

Weitere **Anforderungen** sind eine hohe Robustheit und Erklärbarkeit der Modelle, die insbesondere durch Modell-basierte Ansätze erfüllt werden. Grund ist, dass hier die Mechanismen meist physikalisch modelliert werden und die relevanten Größen direkt gemessen werden und somit Störgrößen reduziert werden. Darüber hinaus ergeben sich oft weitere unternehmens- oder projektspezifische Anforderungen, z. B. aus den zur Verfügung stehenden Ressourcen, Vorwissen, Entwicklungszeit, Verfügbarkeit von Experten und monetären Mitteln. Alle weiteren Anforderungen sollten entsprechend in der Entscheidung berücksichtigt werden. Anforderungen an die Güte der PHM-Lösung werden im folgenden Absatz diskutiert

Initiale Leistungskennzahlen festlegen

Leistungskennzahlen beschreiben die Modellqualität und stehen teils in direkter Beziehung mit den Zielen und Anforderungen des Lösungskonzepts. Dabei können Anforderungen festgelegt werden, die den zulässigen Anteil fehlerhafter Systeme definieren, die unerkannt bleiben. In PHM-Ansätzen ist das übergeordnete Ziel entweder die diagnostische Detektion oder die prognostische RUL-Bestimmung [MAP19]. Diese lassen sich beispielsweise wie folgt mit Leistungskennzahlen beschreiben:

- Detektion⁴⁷ (in Anlehnung an [HS20], siehe auch Abschnitt 2.3.3):
 - „False Negative Rate“: Anteil fehlerhafter Systeme an der Gesamtheit aller tatsächlich fehlerhaften Systeme, die fälschlicherweise nicht detektiert werden, also unerkannt bleiben.
 - „False Positive Rate“: Anteil funktionsfähiger Systeme an der Gesamtheit aller tatsächlich funktionsfähigen Systeme, die fälschlicherweise als fehlerhaft detektiert werden.
 - „Precision“: Anteil der korrekterweise fehlerhaft detektierten Systeme an der Gesamtheit aller (korrekter- und fälschlicherweise) als fehlerhaft detektierten Systeme.
 - „Accuracy“: Anteil aller korrekt detektierten (korrekt fehlerhaft und korrekt funktionsfähig) Systeme an der Gesamtheit aller Systeme.
- RUL-Bestimmung (in Anlehnung an [Goe+17], siehe auch Abschnitt 2.3.3):
 - „Prognostics Horizon“: Mindestzeitraum vor dem Ausfall $t_{EOL} - t_i$ zu dem ein absoluter Error in der RUL Berechnung ($RUL \in [t_{EOL}, 0]$) nicht mehr überschritten wird.
 - „ α - λ Accuracy, Relative Accuracy“: Zulässiger prozentualer Error in der RUL ($RUL \in [t_{EOL}, 0]$).

5.1.3 Projektplanung (1.3)

In der Projektplanung werden die bisherigen Erkenntnisse dokumentiert und das weitere Vorgehen ausgearbeitet. Die Aufgabe besteht aus den folgenden Teilschritten:

1. Module ableiten
2. Projektplanung

Module ableiten

Aus dem Lösungskonzept können sich mehrere sinnvolle Health Management Konzepte ergeben. Ein Health Management Konzept kann wiederum mit einem oder mehreren Prognostics Konzepten verknüpft werden, welches wieder auf unterschiedliche Weisen modelliert und evaluiert werden kann. Im Gesamten ergibt sich für das initiale Konzept eine baumartige Struktur. An dieser Stelle sollten identische Module identifiziert werden, um Dopplungen in der Entwicklung zu vermeiden. Ebenfalls sollten Pfade systematisch auf Risiken untersucht werden.

⁴⁷Klasse Positive: Fehlerhaftes System; Klasse Negativ: Funktionsfähiges System. Bei der Interpretation ist das Verhältnis der Anzahl fehlerhafter und funktionsfähiger Systeme zu beachten, Stichwort „unbalanced data“.

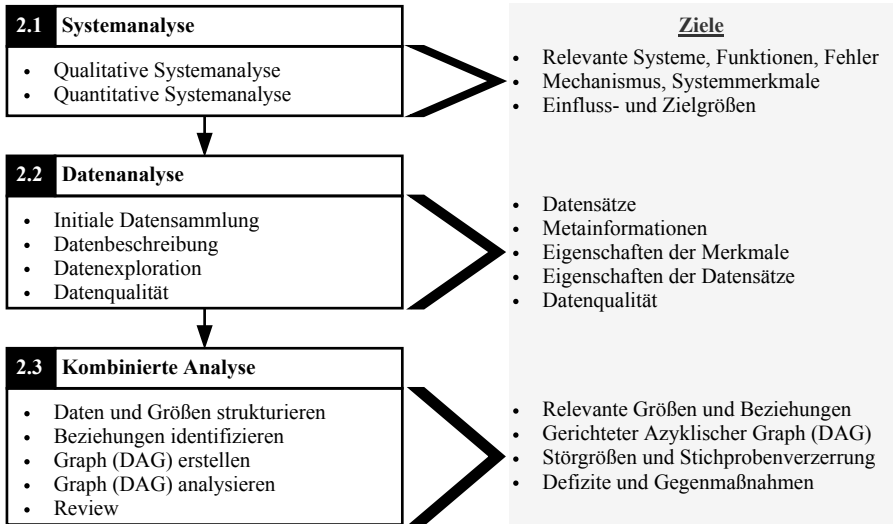


Bild 5.4 Methodik: Phase 2 Analyse.

Projektplanung

Die Projektplanung sollte u. a. Projektablauf, Termine, Verantwortlichkeiten und Arbeitspakete definieren. Mögliche Methoden reichen von der klassischen Meilensteinplanung bis zu agilen Methoden wie SCRUM. An dieser Stelle wird auf die jeweils etablierten Methoden der Fachliteratur und Normung verwiesen.

5.2 System- & Datenanalyse (2.)

Ziel dieser Phase ist die Durchdringung der Komplexität auf Basis von zwei separaten sowie einer kombinierten Analysen von System und Daten. Das System, dessen Funktionen und Fehler werden in der Systemanalyse untersucht und ermöglichen eine Reduzierung der Betrachtung auf die wesentlichen Einflüsse, Wechselwirkungen und Mechanismen. Im Vergleich dazu, steht in der Datenanalyse die explorative und deskriptive Untersuchung der Datensätze, deren Charakteristika und Qualität im Vordergrund. Die kombinierte Analyse verbindet die Einzelanalysen und leitet Implikationen für die folgende Modellierung ab. Bild 5.4 zeigt die drei Aufgaben, deren Teilschritte und Ziele.

Je nach gewähltem Konzept kann der Fokus stärker auf dem System (Ereigniszeit-, Nutzungs-, Modell-basierte Bewertung) oder den Daten (Daten-basierte Bewertung) liegen. Dennoch sollten immer beide Bereiche analysiert werden, da kau-



Bild 5.5 Größen: Systemmerkmale, Einfluss-, Steuer-, Stör- und Zielgrößen (in Anlehnung an [Kle20]).

sale Zusammenhänge nur in der Kombination des Wissens über Daten und die datenerzeugenden Mechanismen identifizierbar sind [Pea09]⁴⁸. Die Beschreibung kausaler Zusammenhänge wird aus verschiedenen Gründen bevorzugt⁴⁹: Ein Grund ist der reduzierte Einfluss von Störgrößen, d. h. assoziative Korrelationen, die den eigentlichen Effekt verfälschen. Kausale Beziehungen sind robuster, aussagekräftiger und verlässlicher im Vergleich zu rein assoziativen Beziehungen [Pea09]. Darüber hinaus neigen kausale Modelle dazu invariant zu sein und bieten die Möglichkeit zur Analyse von Interventionen [Pea09; PJS17].

5.2.1 Systemanalyse (2.1)

Basis der Analyse sind das im Lösungskonzept definierte (Teil-)System sowie die zugehörige (Teil-)Funktionalität, die überwacht bzw. erhalten werden soll. Diese werden schrittweise weiter reduziert, um eine kleinstmögliche aber hinreichend umfangreiche Betrachtung zu ermöglichen. Dazu gehört die Identifikation und Bewertung der relevanten Mechanismen, Systemmerkmale, Steuer-, Stör- und Zielgrößen. Die Gesamtheit wird im Folgenden mit dem Sammelbegriff „Größen“ bezeichnet.

Bild 5.5 stellt den Zusammenhang zwischen Systemmerkmalen, Einfluss- und Zielgrößen dar. Die Bezeichnungen dienen vorrangig der Kategorisierung wichtiger Größen, als Basis für weiterführende Untersuchungen. Im PHM wird die **Zielgröße** primär durch den Health charakterisiert, zum Beispiel die Grübchenfläche auf einem Zahnrad. Sekundäre Fragestellungen können auch eine andere Zielgröße definieren, wie beim Einsatz von Systemmodellen zur Berechnung von Ersatzgrößen. **Einflussgrößen** sind Größen, welche die Zielgröße potentiell beeinflussen und setzen sich aus Steuer- und Störgrößen zusammen [Kle20]. Als **Steuergrößen** werden Größen bezeichnet, die am System bzw. im Prozess in Stufen vorgegeben werden können (in Anlehnung an [Kle20]). **Störgrößen** sind Größen bei denen dies nicht möglich oder nicht beabsichtigt ist. Im Beispiel der Grübchen, sind Drehmoment und Drehzahl Steuergrößen, während die Schmierstoffcharakteristik eine Störgröße darstellt. **Systemmerkmale** bezeichnen in dieser Arbeit Eigenschaften der Stichprobe, als Folge der Stichprobenerhebung. I. d. R. handelt es sich um Merkmale, die das System charakterisieren, wie Material, Fertigung, Gestalt oder im Allgemeinen

⁴⁸In Anlehnung an die Definition zur „Causal Effect Identifiability“ nach Pearl [Pea09].

⁴⁹Siehe auch Abschnitt 2.2 und Abschnitt 5.2.3.

die Belastbarkeit. Ähnlich zu Störgrößen können Systemmerkmale technologisch nur bedingt kontrolliert werden und besitzen einen Einfluss auf die Zielgröße. Im Beispiel der Grübchen, sind die geometrischen Toleranzen ein Systemmerkmal. Der Zusammenhang zwischen Systemmerkmalen, Einfluss- und Zielgrößen wird durch den im System ablaufenden **Mechanismus** hergestellt. Ist der relevante Mechanismus identifiziert, lassen sich oft Rückschlüsse auf die relevanten Größen treffen.

Die Systemanalyse kombiniert qualitative und quantitative Verfahren, zur Reduktion der Betrachtung auf das Wesentliche sowie der Identifikation und Bewertung relevanter Größen. Die Bearbeitung erfolgt oft in einem iterativen Wechsel. Startpunkt ist i. d. R. eine qualitative Analyse, die im weiteren Verlauf durch quantitative Analysen geprüft und vertieft wird. Die Teilschritte lauten:

1. Qualitative Systemanalyse
2. Quantitative Systemanalyse

Qualitative Systemanalyse

Im PHM relevant sind i. d. R. kritische Fehler hinsichtlich Zuverlässigkeit, Instandhaltbarkeit, Verfügbarkeit oder Sicherheit. Sind die relevanten Fehler identifiziert, können deren Größen, Wechselwirkungen sowie die zugrunde liegenden Mechanismen analysiert werden.⁵⁰ Eine qualitative Methode, die alle genannten Punkte adressiert, ist die Fehler-Möglichkeiten-Mechanismen und Einfluss-Analyse (FMMEA) nach Kapur und Pecht [KP14]. Weitere etablierte qualitative Methoden sind die Fehlerbaumanalyse (FTA), die klassische FMEA, das Design-Review, die Design-Review Based on Failure Mode Analyse (DRBFM) und die ABC-Analyse (vergleich [BL04; ARP926C; VDA32; DIN60300-2]).

Quantitative Systemanalyse

Quantitative Systemanalysen evaluieren und vertiefen das qualitative Verständnis. Dafür eignen sich neben den Modellen der Zuverlässigkeitstechnik eine Vielzahl domänenspezifischer Modelle, wie Modelle der Finiten Elemente Methode (FEM) oder der Mehrkörpersimulation (MKS).

Metaanalyse ([MAP19]): Die Metaanalyse zeigt die Verwendung von Degradationsmechanismen und deren Zuordnung zu Systemen, Bild 5.6. In absoluten Zahlen wird am häufigsten eine Performance-Degradation beschrieben, stark getrieben durch das System Batterie. Bei den physikalischen Mechanismen lassen sich Rissbildung und die verschiedenen Verschleißmechanismen hervorheben. Die Rissbildung findet insbesondere in Strukturelementen und bei Motoren/Turbinen (Turbinen-

⁵⁰Insbesondere wenn die Nutzung relevanter Teil der Modellierung ist, sollte die Untersuchung um Nutzungsgrößen erweitert werden.




Bild 5.6 Ergebnisse der Metaanalyse: Degradationsmechanismen (Basis: [MAP19]).

schaufeln) Anwendung. Verschleißmechanismen dominieren hingegen in Antriebskomponenten, Getrieben und Werkzeugmaschinen. Besonders häufig handelt es sich um Oberflächen-Ermüdung, z. B. in Form der Grübchenbildung.

5.2.2 Datenanalyse (2.2)

In der Datenanalyse liegt der Fokus auf explorativen und deskriptiven Verfahren, welche die Eigenschaften der verfügbaren Daten bzw. der Stichprobe beschreiben. Chapman et al. [CRISP-DM] bezeichnen diese Phase als „Data Understanding“ und weist die folgenden vier Teilschritte aus:

1. Initiale Datensammlung
2. Datenbeschreibung
3. Datenexploration
4. Datenqualität

Initiale Datensammlung

Zu Beginn werden alle verfügbaren Datensätze identifiziert und Zugriffsmöglichkeiten geschaffen [CRISP-DM]. Als Datenquellen eignen sich geplante Experimente und Beobachtungsstudien. In dieser Arbeit werden Daten als **Labordaten** bezeichnet, die zum Zeitpunkt der Entwicklung einer PHM-Lösung zur Verfügung stehen. Labordaten können aus Experimenten und Beobachtungsstudien stammen, mit

großen Unterschieden in der Interpretation der Daten (siehe auch Abschnitt 5.2.3). Gesammelt werden die Daten an einer Stichprobe von Systemen. Wird die PHM-Lösung in Betrieb genommen, wird hier von der **Feldanwendung** gesprochen.

In **geplanten Experimenten** werden die relevanten Steuergrößen X gezielt kontrolliert und der Effekt auf die Zielgröße Y analysiert [Pea09]. Dabei wird eine Versuchsplanung vor Beginn des Experimentes durchgeführt. In ideal randomisiert kontrollierten Experimenten liefert das Experiment direkt den gesuchten kausalen Effekt $P_{Y|do(X=x)}$ der Steuergröße X auf die Zielgröße Y [HB19b]⁵¹. Randomisierung nach Fisher [Fis71] ist eine Möglichkeit, um den Einfluss unkontrollierter Störgrößen aufzulösen.

Bei **Beobachtungsstudien** handelt es sich um eine passive Datenerhebung. Das heißt, während der Datenerhebung findet keine gezielte Manipulation oder Randomisierung einzelner Größen statt. Zu Beginn der Analyse stehen Daten der multivariaten Verteilung $P_{Y,X}$ zur Verfügung [BP16]. Daher ist der Unterscheidung zwischen statistischen und kausalen Beziehungen eine besondere Aufmerksamkeit zu schenken. Wesentlich ist, dass bedingte Wahrscheinlichkeiten der Form $P_{Y|X=x}$ statistische Abhängigkeiten (assoziative Beziehungen) beschreiben, die nicht zwingend auf kausale Beziehungen zurückgehen. Ursache einer statistischen Abhängigkeit kann neben einer kausalen Beziehung zwischen X und Y ($X \rightarrow Y$ oder $X \leftarrow Y$) auch der Einfluss einer dritten Größe Z auf X und Y sein [Rei56], siehe auch Abschnitt 2.2.

Datenbeschreibung

Im zweiten Schritt werden die Metainformationen eines Datensatzes beschrieben. Dazu gehören die Bezeichnung der Größen, die Anzahl an Instanzen je Größe, Datentypen, Speicherdatum usw. [CRISP-DM]. Ein Datensatz im PHM ist mit einem oder mehreren physischen Systemen verknüpft. Wichtige Größen eines Datensatzes ergeben sich somit ebenfalls aus den individuellen Eigenschaften des Systems (Ausstattung, Charge, etc.), der Systemumgebung (Ort, Klima, etc.) und dem Systemnutzer (Erfahrung, Charakteristik, etc.)⁵². Die initial gegebenen Größen eines Datensatzes decken nicht zwingend alle relevanten Größen ab. Aus diesem Grund, sollte die Vollständigkeit geprüft werden. Dies kann recherchierend, intuitiv oder diskursiv erfolgen und sollte in Abstimmung mit der Systemanalyse stehen.

Bei der Interpretation der Daten ist die Unterscheidung zwischen geplanten Experimenten und Beobachtungsstudien wichtig, wie im vorherigen Abschnitt erläutert. Tabelle 5.3 erfasst die jeweiligen Charakteristiken, in Anlehnung an Bareinboim und Pearl [BP16]. Es werden Metainformationen zur Art der Datenerzeugung, der Stichprobenerhebung, der Beschreibung der Grundgesamtheit sowie den Größen

⁵¹Der „do-Operator“ ($do(X = x)$) beschreibt die Intervention der Steuergröße X [Pea09]. Dies ist vergleichbar mit der gezielten Manipulation (Kontrolle) in geplanten Experimenten. Siehe auch Abschnitt 2.2.

⁵²In Anlehnung an die 3 F-Methodik [Küç90].

Tabelle 5.3 Metainformationen der Datensätze (in Anlehnung an [BP16])

Metainformation	Datensatz 1	Datensatz 2	Datensatz 3	...
Datenerzeugung: a) Geplantes Experiment b) Beobachtungsstudie	Geplantes Experiment	Geplantes Experiment	Beobachtungsstudie	...
Beschreibung Grundgesamtheit	Werk I Q1 2019	Werk I Q3 2020	Europa 2018 - 2020	...
Erfasste Größen	X_1, X_2, X_3, Y_1	X_1, X_2, X_4, Y_1	X_1, X_2, X_3, Y_2	...
• Zielgrößen	Y_1	Y_1	-	...
• Steuergrößen	X_1	X_1	-	...
• Randomisierte Größen	X_3	X_4	-	...
• Selektierte Größen	$X_2 = 1$	$X_2 = 1$	$Y_2 = 1$...

selbst erfasst. Letztgenannte werden weiter in Zielgrößen, Steuergrößen, randomisierte und selektierte Größen unterschieden. **Ziel-**, **Steuer-** und randomisierte Größen beschreiben Merkmale geplanter Experimente, vergleiche Abschnitt 5.2.1. Die Zielgröße ist der gesuchte Effekt und die Steuergrößen die gezielt kontrollierte Ursache während der Datenerhebung. **Randomisierte Größen** werden in der Stichprobenerhebung zufällig zugeteilt. Hierbei handelt es sich häufig um Systemmerkmale, mit dem Ziel unkontrollierbare Einflüsse aufzulösen. **Selektierte Größen** verzerren die natürliche Verteilung der Ausprägungen einer Größe. Beispielsweise kann eine binäre Größe Z die Werte 0 und 1 annehmen. Durch die Selektion auf $Z = 0$ werden aber alle Daten mit $Z = 1$ aus der Verteilung ausgeschlossen.

In dieser Arbeit wird die Art der **Zielgröße** in Zustand, Verhalten und Fehler unterschieden, siehe auch Bild 5.7. Während der Zustand selbst einen Effekt wie eine voranschreitende Degradation beschreibt, wird das Verhalten durch den Zustand beeinflusst. Zum Beispiel bezeichnet der Zustand die Grübchenfläche auf einem Zahnrad, die mit fortschreitendem Betrieb zunimmt. Vibrationen beschreiben das Verhalten des Systems, welches sich u. a. in Abhängigkeit des Zustandes ändert. Verlässt das Verhalten einen erlaubten Toleranzbereich, tritt ein Fehler ein. Dieser repräsentiert die Zielgröße in diskreter Form. Zustand ist somit Ursache des Verhaltens, die wiederum Ursachen des Fehlers sind.




Bild 5.7 Einteilung der Zielgrößen in Zustand, Verhalten und Fehler.

In welcher Art die Zielgröße benötigt wird, unterscheidet sich je nach Prognostics Konzept (siehe Abschnitt 4.2.1), Modellierungsansatz und -technik. Wird eine bestimmte Art benötigt, aber nur eine Andere gemessen, lassen sich die Zielgrößen unter bestimmten Einschränkungen ineinander umrechnen. Während sich aus einem Zustand theoretisch das Verhalten bzw. aus beiden vorgenannten der Fehler ableiten lässt, gilt dies nicht zwingend auch vice versa. Grund ist die gerichtete Ursache-Effekt-Beziehung der Größen. Insbesondere der Rückschluss von diskreten Fehlern auf einen stetigen Zustand/Verhalten ist nur eingeschränkt möglich. In diesem Fall kann die Korrektheit des Verlaufs nur bedingt validiert werden.

Neben der Art der Zielgröße spielen Verfügbarkeit und Repräsentativität eine wichtige Rolle. Die Verfügbarkeit bewertet die Häufigkeit in den Datensätzen. Es wird insbesondere die Unterscheidung zwischen Daten von fehlerfreien Systemen und Systemen mit Fehlern adressiert. Mit der Repräsentativität wird bewertet, inwieweit die verfügbare Zielgröße die Häufigkeit in der beabsichtigten Feldanwendung abdeckt. Verfügbarkeit und Repräsentativität sind für Modellierung und Evaluation von Bedeutung.

Datenexploration

In der Datenexploration werden die Eigenschaften der Größen eines Datensatzes untersucht [CRISP-DM]. Wichtige Eigenschaften sind allgemeine statistische Merkmale, fehlende Werte, Ausreißer (Anomalien), Gradienten, Relationen etc. Typische Methoden der Exploration sind die deskriptive Statistik kombiniert mit Formen der Visualisierung, z. B. in Form von Uni-, Bi- und multivariaten Analysen oder der Dimensionalitätsreduktion. Die Basis der meisten Nutzungs- und Zustands-basierten Konzepte bilden Zeitreihen, deren spezielle Eigenschaften an dieser Stelle untersucht werden sollten. Dazu gehören nach Box et al. [Box+16] und Hedderich und Sachs [HS20] der Autokorrelationskoeffizienten, Stationarität, Trends, Saisonalität und Rauschen. Aus der Analyse der Autokorrelationskoeffizienten über den zeitlichen Versatz (engl. lag) ergeben sich ggf. direkt Rückschlüsse auf die Leistungsfähigkeit des Prognosehorizontes.

Datenqualität

In der Datenqualität werden die Datensätze verifiziert, dokumentiert und Lösungen bezüglich möglicher Probleme erarbeitet [CRISP-DM]. Indikatoren der Datenquali-




Bild 5.8 Ergebnisse der Metaanalyse: Daten (Basis: [MAP19]).

tät sind nach Kantardzic [Kan11] die Folgenden:

- Korrekte sowie vollständige Bezeichnungen und Wertebereiche.
- Speicherung im korrekten Format bei minimaler Redundanz in den Daten.
- Sicherstellung der Daten Integrität bei Änderungen.
- Standardisierte Benennung und Speicherung sowie Konsistenz der Datensätze.
- Explizite oder implizite Verknüpfung der Daten mit Zeitstempeln.

Metaanalyse ([MAP19]): Bild 5.8 zeigt die Erfassung von Größen in absoluter Häufigkeit sowie deren kombinierte Verwendung in einer PHM-Lösung. Besonders häufig werden Größen verwendet, die das Verhalten des Systems beschreiben. Dazu zählen in der Mechanik Vibrationen (Beschleunigungen und Schwingungsdaten) und in der Elektrotechnik elektrische Spannung und Stromstärke. Diese Merkmale beschreiben die Zielgröße als Verhalten. Vorteil ist die einfache Messung im Vergleich zu der direkten Messung von Zuständen, wie der Grübchenfläche.

5.2.3 Kombinierte Analyse (2.3)

Die kombinierte Analyse legt den Fokus auf die Beziehung zwischen Größen, Daten und den datenerzeugenden Prozessen. Ziele sind ein weiter vertieftes Verständnis sowie die Ableitung von Implikationen für eine robuste Modellierung. Die Basis der Analyse bilden Ansätze des Forschungsbereichs Kausalität (Abschnitt 2.2). Begleitet werden die Ausführungen von einem Beispiel zur Grübchenbildung. Die Teilschritte lauten:

1. Daten und Größen strukturieren
2. Beziehungen identifizieren
3. Graph (DAG) erstellen
4. Graph (DAG) analysieren
5. Review

Ein Treiber im PHM ist die steigende Menge an zur Verfügung stehenden Betriebs- und Sensordaten, die z. B. den weiten Einsatz des Maschinellen Lernens befähigen [PK18; KAC17]. In diesen passiven Beobachtungsstudien ist der datenerzeugende Prozess i. d. R. unbekannt. Die Interpretation dieser Prozesse entscheidet aber über die Leistungsfähigkeit der Modellierung in Labor- und Feldanwendung. Entscheidend sind interne und externe Validität. **Interne Validität** beschreibt die Übereinstimmung zwischen Modell und dem wahren datenerzeugenden Prozess [HB19b]. Kausale Beziehungen gelten als intern valide hinsichtlich ihrer Grundgesamtheit [Pea09; MJ20]. Mit der internen Validität werden Störgrößen und Stichprobenverzerrung adressiert [HB19b]. Im Vergleich, bewertet die **externe Validität** die Übertragbarkeit kausaler Beziehungen von einer auf eine andere Grundgesamtheit [HB19b]. Dies kann der Fall sein, bei der Übertragung von der Labor- auf die Feldanwendung. In ideal randomisiert kontrollierten Experimenten herrscht interne Validität, externe Validität kann aber selbst in dieser Art von Experimenten nicht gewährleistet werden [BP16]. Im Fokus dieser Arbeit steht die interne Validität, d. h. kausale Beziehungen (Ursache-Effekt). Für die Identifikation kausaler Beziehungen gibt es nach Hünemund und Bareinboim [HB19b] drei Ansätze:

- Detaillierte Kenntnis der wirkenden physikalischen Mechanismen.
- Korrekt durchgeführte geplante Experimente.
- Die Kausale Inferenz⁵³.

Informationen über die physikalischen Mechanismen folgen aus der Systemanalyse, d. h. Funktionen, Degradation, Mechanismen etc. (Abschnitt 5.2.1). Zudem identifizieren eine Reihe hier verwendeter Methoden Ursache-Effekt Beziehungen, beispielsweise die FMEA in Form von Fehlerursache und Fehler. Die Datenanalyse erfasst wichtige Eigenschaften der Daten, wie die Selektion bestimmter Größen (Abschnitt 5.2.2). Die vorangegangenen Analysen bieten in Kombination mit der Kausalen Inferenz somit gute Voraussetzungen zur Identifikation kausaler Beziehungen. Hierzu kann wie folgt vorgegangen werden:

⁵³Basis der folgenden Ausführungen sind Forschungsarbeiten im Bereich der Kausalität nach Pearl, Bareinboim, Schölkopf und Weiteren. Der Bereich der Kausalität geht über die gezeigten Ansätze weit hinaus. An dieser Stelle wird auf die angegebene Literatur verwiesen.








Einflussgrößen (Steuergrößen, Störgrößen)			System- merkmale	Zielgrößen		
Nutzungsdaten				Zustandsdaten	Ereignisdaten	
Betriebsdaten		Sensordaten I		Sensordaten II	Servicedaten	
Nutzung (System Input)	Äußere Lasten (Umwelt)	Belastungen		Zustand	Verhalten (System Output)	Fehler (-folgen)
Tertiäre Ursache	Sekundäre Ursache	Primäre Ursache	Mechanismus	Primärer Effekt	Sekundärer Effekt	Tertiärer Effekt
						

Bild 5.9 Strukturierung von Größen und Daten.

Daten und Größen strukturieren

In diesem Teilschritt werden Größen der System- und Datenanalyse in eine gemeinsame Menge überführt. Die Gesamtmenge der Größen sollte frei von Doppelungen sein und eine grundlegende Struktur vorgeben. Bild 5.9 zeigt eine mögliche Strukturierung zur systematischen Zuordnung von Größen und Daten im PHM-Kontext. In der Terminologie der Größen steht in der Mitte das System mit seinen Systemmerkmalen, links die Einflussgrößen und rechts die Zielgrößen. In der Klassifikation der Daten nach Abschnitt 4.2.1, stehen links Nutzungs- und rechts Zustands- bzw. Ereignisdaten (siehe auch Bild 4.5). Zu Beginn steht die Nutzung des Systems. Aus der Nutzung folgen die äußeren Lasten, aus diesen die lokalen Belastungen, die wiederum den Zustand bestimmen, der Ursache des Verhaltens ist und letztendlich zu einem Fehler führen kann. Allgemein lassen sich die Größen links vom Mechanismus als dessen Ursachen und die Größen rechts als dessen Effekte bezeichnen.

Als Beispiel, ist der Schadensmechanismus Grübchenbildung einer Verzahnung am System Roboter dargestellt, siehe Bild 5.9. Dabei wird angenommen, dass eine ausreichende Menge von Systemen beschrieben wird und je System eine Datenerhebung bei X-Betriebstunden stattfindet. Einflussfaktoren auf die Grübchenbildung (primärer Effekt) sind einerseits Systemmerkmale, wie Zahngeometrie, Oberflächen- oder Öleigenschaften [Nau+19]. Andererseits ist Ursache die Materialzermürbung unter der Oberfläche, die aus der anliegenden Hertz'schen Pressung (primäre Ursache) bzw. deren Schubspannung resultiert [RS18]. Die Hertz'sche Pressung ist wiederum eine Folge der Nennumfangskraft (sekundäre Ursache) [RS18], die sich aus Zahnradgeometrie und Nenndrehmoment bestimmt [DIN3990]. Drehmoment und Drehzahl bzw. die Nutzung bestimmt sich wiederum aus den Prozessparametern. Primärer Effekt des wirkenden Schadensmechanismus ist der Ausbruch von Grüb-

chen. Beim Überrollen der lokalen Defekte entstehen Stöße, die als Vibrationen gemessen werden können [Ran11]. Diese beschreiben das Verhalten des Roboters, d.h. sekundäre Effekte. Der Ausfall (Fehlerfolge) tritt ein, wenn die Vibrationen den zulässigen Bereich verlassen. In der Praxis wird dies oft beeinflusst von der Beurteilung und Dokumentation des jeweiligen Mitarbeiters. Neben Abweichungen in der zeitlichen Zuordnung von primärem und tertiären Effekt, können primäre Effekte auch übersehen oder fehlerhaft bewertet werden.

Beziehungen identifizieren

Kausale Beziehung beschreiben einen Ursache-Effekt Zusammenhang zwischen zwei Größen, d. h. „ X ist Ursache von Y “ bzw. in Kurzform $X \rightarrow Y$ ⁵⁴. Die Kenntnis über physikalische Mechanismen bietet eine valide Basis zur Identifikation kausaler Beziehungen. Soweit physikalische Gleichungen aus der Systemanalyse (Abschnitt 5.2.1) bekannt sind, sollten diese als Startpunkt genutzt werden. Im Vergleich zu kausalen Beziehungen drücken physikalische Gleichungen keine gerichteten Beziehungen aus, d. h. sie lassen sich nach Größen umstellen [PJS17]. In diesem Fall, kann die Richtung aus Überlegungen folgen. Zum Beispiel aus der Interventions-Frage: Ändert sich Größe X_1 bei gezielter Intervention von Größe X_2 oder ist dies vice versa der Fall? In der direkten kausalen Beziehung zwischen zwei Größen, kann nur eine Aussage wahr sein.

Zum Beispiel bestimmt sich die Längenänderung unter Temperatureinfluss nach der folgenden Gleichung $\Delta l = l_0 \alpha \Delta T$ [BG20]⁵⁵. Zur Identifikation der Beziehungsrichtung wird die Frage der Intervention gestellt. Es wird erwartet, dass sich bei einer Intervention der Umgebungstemperatur die Länge ändert. Wird hingegen die Länge interveniert, wird keine nennenswerte Änderung der Umgebungstemperatur erwartet. Es folgt die Beziehung $\Delta T \rightarrow \Delta l$.

Im Allgemeinen sollten alle Größen paarweise auf mögliche Beziehungen geprüft werden. Dies gilt insbesondere, wenn die physikalischen Mechanismen nicht (exakt) bekannt sind. Beziehungen können methodisch recherchierend, intuitiv oder diskursiv erarbeitet werden. Wird eine Beziehung zwischen zwei Größen identifiziert, kann dies bedeuten, dass es a) eine kausale Beziehung zwischen den beiden Größen gibt oder b) eine dritte Größe gemeinsame Ursache der beiden Größen ist [Rei56]. Im ersten Fall ist die Richtung der Beziehung zu klären, im zweiten Fall ggf. Art und Relevanz der dritten Größe.

Im Beispiel der Grübchenbildung lassen sich eine Reihe physikalischer Beziehungen identifizieren. Die Schubspannung τ_{max} in Folge der Hertz'schen Pressung bestimmt sich nach Gleichung 5.1. Darin enthalten ist die Nennumfangskraft F , die sich nach Gleichung 5.2 aus dem Nenndrehmoment T berechnet. Wesentliche

⁵⁴Nicht zu verwechseln mit der mathematischen Zuordnungsvorschrift $X \mapsto Y$.

⁵⁵Legende: Längenänderung Δl , Referenzlänge l_0 , Längenausdehnungskoeffizient α , Temperaturänderung ΔT .

Faktoren auf die Grübchenbildung A sind nach Naunheimer et al. [Nau+19]: Schubspannung τ_{max} , Umfangsgeschwindigkeit v (Gleichung 5.3), Oberflächenhärte/-rauheit, Ölviskosität/-temperatur und Flankenformfehler. Grübchendefekte sind wiederum Ursache einer Schwingungsanregung. Ebenfalls Ursache von Vibrationen der Zahnradpaarung sind Eingriffsstöße, parameterangeregte Schwingungen und Abwälzgeräusche [Nau+19]. Diese werden durch folgende Faktoren beeinflusst: Drehzahl, Drehmoment, Verzahnungsgeometrie, Zahnradgeometrie, Materialeigenschaften und Oberflächeneigenschaften [Nau+19]. Der Einfluss anderer Maschinenelemente wird an dieser Stelle aus Gründen der Veranschaulichung vernachlässigt.⁵⁶

$$\tau_{max} = -0,3 \sqrt{\frac{FE\rho}{2\pi l(1-\nu^2)}};^{56} \quad [\text{RS18}] \quad (5.1)$$

$$F = \frac{2000T}{d};^{56} \quad [\text{DIN3990}] \quad (5.2)$$

$$v = \omega \frac{d}{2};^{56} \quad (5.3)$$

Graph (DAG) erstellen

Gerichtete Azyklische Graphen (DAGs, engl. Directed Acyclic Graphs) bieten eine anwendungsorientierte Sprache zur Beschreibung kausaler Beziehungen und bilden die Basis der Kausalen Inferenz nach Pearl [Pea09]⁵⁷. Das Ziel dieses Teilschritts ist die Identifikation des DAGs, aufbauend auf den Größen und Beziehungen der vorherigen Teilschritte⁵⁸. Im DAG wird eine Größe X durch einen Knoten (X) repräsentiert. Eine kausale Beziehung zwischen zwei Größen X (Ursache) und Y (Effekt) wird durch eine Kante dargestellt $X \rightarrow Y$. Alle Kanten im DAG sind gerichtet und es gibt keine zyklischen Beziehungen, siehe auch Abschnitt 2.2. Die Beziehung zweier Größen über eine gemeinsame Ursache, sprich eine unbekannte dritte Größe W , wird als Gabelung $X \leftarrow W \rightarrow Y$ gezeichnet (siehe auch Teilschritt „Graph (DAG) analysieren“). In Kurzform wird für eine Gabelung mit unbekannter mittlerer Größe auch die folgende Darstellung gewählt $X \leftarrow - \rightarrow Y$. Größen im DAG sind grundlegend in beobachtet und unbeobachtet zu unterscheiden. Darüber hinaus können Größen kontrolliert, randomisiert oder selektiert sein. Die beiden erstgenannten sind charakteristisch für geplante Experimente. Werden Größen bei der Stichprobenerhebung (im Experiment) gezielt kontrolliert oder randomisiert, hat dies folgende

⁵⁶Legende: Drehzahl ω , Nenndrehmoment T , Durchmesser d , Nennumfangskraft F , Schubspannung τ_{max} , E-Modul E , Krümmung ρ , Länge l , Poissonzahl ν , Grübchenfläche a , Geschwindigkeit v .

⁵⁷Das Wissen über kausale Beziehungen lässt sich ebenfalls in Form eines Struktur-Kausalen-Modells (SCMs, engl. Structural Causal Model) beschreiben [Pea09; HB19b].

⁵⁸Zur Erstellung und Analyse von DAGs, gibt es verschiedene Programmpakete, z. B. [DAGitty].

Einflussgrößen (Steuergrößen, Störgrößen)			System- merkmale	Zielgrößen		
Nutzungsdaten				Zustandsdaten	Ereignisdaten	
Betriebsdaten		Sensordaten I		Sensordaten II	Servicedaten	
Nutzung (System Input)	Äußere Lasten (Umwelt)	Belastungen		Zustand	Verhalten (System Output)	Fehler (-folgen)
Tertiäre Ursache	Sekundäre Ursache	Primäre Ursache	Mechanismus	Primärer Effekt	Sekundärer Effekt	Tertiärer Effekt

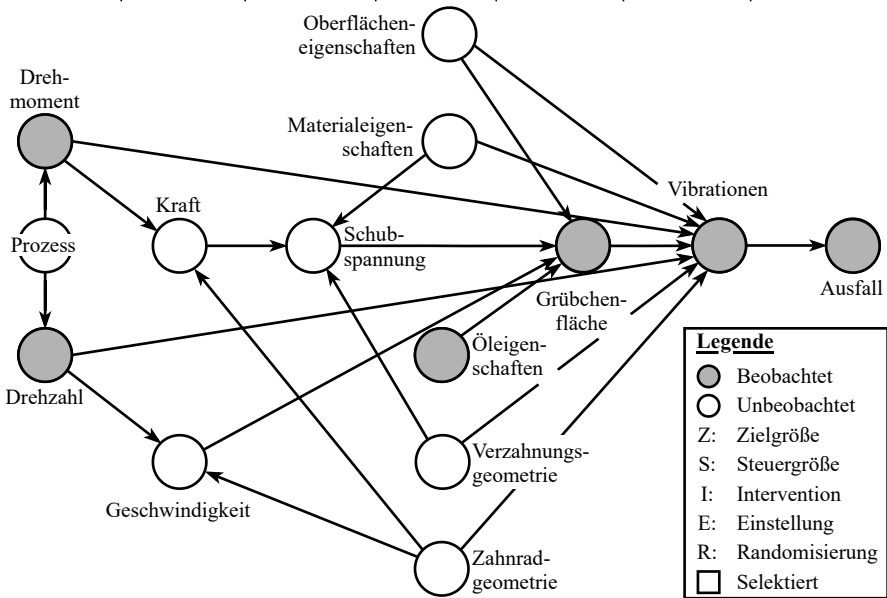


Bild 5.10 DAG für das Beispiel Grübchenwachstum.

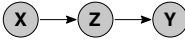
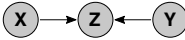
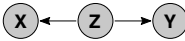
Bedeutung: a) die gezielte Kontrolle einer Größe entfernt alle eingehenden Beziehungen (Ursachen)⁵⁹ b) die ideale Randomisierung einer Größe entfernt alle Beziehungen mit dieser Größe [Pea09]. Unter Anwendung der vorangegangenen Regeln wird aus den Informationen über Größen und Beziehungen der DAG erstellt.

Bild 5.10 zeigt den DAG für das Beispiel der Grübchenbildung⁶⁰. Die dargestellten Größen und Beziehungen entsprechen den Ausführungen der vorherigen Teilschritte. Im Beispiel wird angenommen, dass die Größen Drehmoment, Drehzahl, Öl-eigenschaften, Grübchenfläche, Vibrationen und Ausfall in einer passiven Beob-

⁵⁹In Anlehnung an die „Kausaler Effekt“ Definition nach Pearl [Pea09], siehe auch Defintion 2.2.1.

⁶⁰Das Fallbeispiel dient vorrangig der Veranschaulichung und erhebt keinen Anspruch auf Vollständigkeit.

Tabelle 5.4 Implikationen der d-Separation für Folge, Kollision und Gabelung, in Anlehnung an [Pea09; HB19b]. DE_Z^G : Nachkommen (engl. descendants) der Größe Z in Graph G .

Art	Fall 1: Unkonditioniert	Fall 2: Konditioniert
Folge: 	$X \not\perp\!\!\!\perp Y$	$X \perp\!\!\!\perp Y \mid Z$
Kollision: 	$X \perp\!\!\!\perp Y$	$X \not\perp\!\!\!\perp Y \mid Z, DE_Z^G$
Gabelung: 	$X \not\perp\!\!\!\perp Y$	$X \perp\!\!\!\perp Y \mid Z$

achtungsstudie erhoben werden. Alle anderen Größen sind unbeobachtet.

Graph (DAG) analysieren

DAGs bilden die Basis für eine Vielzahl an Analysen. Im Folgenden wird näher eingegangen auf: a) die Identifikation von Fehlern im DAG „Konsistenz DAG-Daten“ sowie b) die Identifizierbarkeit kausaler Effekte aus Beobachtungsstudien „Kausale Inferenz“. Je nach Problemstellung können an dieser Stelle weitere Analysen durchgeführt werden, wie die automatische Ableitung des DAG aus den Daten (genauer die Äquivalenzklasse des DAG), oder die Überprüfung der externen Validität zwischen verschiedenen Datensätzen.

Konsistenz DAG-Daten: Interne Validität wird erreicht bei Übereinstimmung von Modell (DAG) und datenerzeugendem Prozess [HB19b]. Falsch angenommene oder fehlende Größen/Beziehungen gefährden die interne Validität. In diesem Fall ergibt sich eine Diskrepanz zwischen Modell und datenerzeugendem Prozess. In anderen Worten, das Modell repräsentiert nicht die Realität. Dies führt mit hoher Wahrscheinlichkeit zu Fehlern bei der Modellnutzung. Mit der Kausalität werden Werkzeuge geliefert, um die Konsistenz zwischen DAG und Daten (datenerzeugendem Prozess) zu prüfen und so Fehler in der Modellierung zu reduzieren. Dies erlaubt wiederum Rückschlüsse auf die Korrektheit des Verständnisses der physikalischen Mechanismen. Über den Anwendungsrahmen entscheidet insbesondere, inwiefern relevante Größen beobachtet werden und Mechanismen bekannt sind.

Grundlage der folgenden Ausführungen ist die Definition der „d-Separation“ nach Pearl [Pea09], siehe auch Definition 2.2.2⁶¹. Mit den Regeln der d-Separation können aus dem DAG statistische Implikationen abgeleitet werden, die an den Daten testbar sind. Allgemein sind die Regeln der d-Separation für einen beliebig langen Pfad zwischen zwei Größen (X und Y) sowie mindestens einer dazwischen liegenden Größe Z gültig. Ausgehend vom allgemeinen Fall, lassen sich drei Arten von

⁶¹Faithfulness vorausgesetzt, siehe auch [PJS17].

Beziehungen unterscheiden: Folgen (engl. chain), Kollisionen (engl. collider) und Gabelungen (engl. fork) [Pea09; HB19b], siehe Tabelle 5.4. Abhängig von der Art der Beziehung besteht eine statistische Abhängigkeit oder Unabhängigkeit zwischen X und Y . Durch Konditionierung (Bedingung) auf Z lässt sich der Zustand umkehren. D.h. aus einer statistischen Abhängigkeit von X und Y wird eine statistische Unabhängigkeit und vice versa. Diese zwei Fälle sind statistisch unterscheidbar und somit auf Basis der Daten testbar. Tabelle 5.4 fasst die Implikationen der d-Separation zusammen. Es ist zu beachten, dass Folge und Gabelung äquivalente Eigenschaften besitzen. D. h. bei nur drei gegebenen Größen ohne weitere Kenntnis über die physikalischen Mechanismen (den datenerzeugenden Prozess), sind Folge und Gabelung nicht zu unterscheiden. Im Beispiel der Grübchenbildung resultieren, für den gegebenen DAG (Bild 5.10) und die als beobachtet angenommenen Größen, folgende testbare Implikationen⁶²:

- Drehmoment $T \perp\!\!\!\perp$ Ausfall | Vibrationen
- Drehmoment $T \perp\!\!\!\perp$ Öleigenschaften
- Drehzahl $\Omega \perp\!\!\!\perp$ Ausfall | Vibrationen
- Drehzahl $\Omega \perp\!\!\!\perp$ Öleigenschaften
- Grübchenfläche $A \perp\!\!\!\perp$ Ausfall | Vibrationen
- Ausfall $\perp\!\!\!\perp$ Öleigenschaften | Vibrationen

In vier der sechs Implikationen wird eine statistische Unabhängigkeit durch Konditionierung auf die Vibrationen erreicht. Wie beschrieben, teilen sich die Vibrationen in einen zulässigen und unzulässigen Bereich. Werden nur Daten mit zulässigen Vibrationen betrachtet, schließt dies im Wesentlichen fehlerhafte Systeme aus⁶³. Somit besteht keine statistische Abhängigkeit zwischen Ausfall und Grübchenfläche. Dies gilt entsprechend für Drehmoment, Drehzahl und die Öleigenschaften.

Kausale Inferenz: Ziel dieser Analyse ist die Vorhersage des Effekts von Interventionen $do(X = x)$ auf eine Zielgröße Y , das heißt $P_{Y|do(X=x)}$. Die Schwierigkeit besteht darin, dass nur Daten der multivariaten Verteilungen $P_{Y, X}$ einer Beobachtungsstudie vorliegen. Infolgedessen muss die Interventionsverteilung $P_{Y|do(X=x)}$ in eine do-freie Verteilung umgeformt werden. Das heißt eine Verteilung, die auf Basis der Beobachtungsstudie berechnet werden kann. Inwieweit dies möglich ist, hängt von DAG und den beobachteten Größen ab. Basis der Umformung sind die Regeln des do-Calculus (Definition 2.2.1) nach Pearl [Pea09]. Um den gesuchten kausalen Effekt zu beschreiben, sind in der Analyse ungewollte Beziehungen aus Störgrößen-Bias und Stichprobenverzerrung zu adressieren.

⁶²Bestimmt mit [DAGitty]

⁶³Abgesehen von Dokumentationsfehlern etc.




 (a) Störgrößen Bias (Z unkonditioniert).

 (b) Stichprobenverzerrung (Z konditioniert).

Bild 5.11 Beispiel DAGs für Störgrößen Bias und Stichprobenverzerrung.

Eine **Störgröße** Z erzeugt eine statistische Abhängigkeit zwischen zwei anderen Größen X und Y , die nicht kausal ist [HB19b]. Dies ist der Fall, wenn X und Y über eine unkonditionierte Gabelung verbunden sind (Tabelle 5.4). Ein Beispiel zeigt Bild 5.11a. Der gesuchte kausale Effekt $X \rightarrow W \rightarrow Y$ wird hier durch einen zweiten Pfad $X \leftarrow Z \rightarrow Y$ gestört. Dabei beschreibt Z die Störgröße, die unkonditioniert eine statistische Abhängigkeit zwischen X und Y erzeugt. Häufige Ursache für Störgrößen ist eine nicht randomisierte Stichprobenerhebung [HB19b]. Handhabbar sind Störgrößen mit dem Backdoor- und Frontdoor-Kriterium (Definition 2.2.3 und 2.2.4). Wichtiges Instrument ist das Einstellset (engl. Adjustmentset), welches über die enthaltenen Größen konditioniert. Dabei ist das Backdoor-Kriterium anwendbar, wenn auf dem Pfad der Störgröße relevante Größen beobachtet werden. In Bild 5.11a ist dies der Fall, wenn X , Y und Z beobachtet werden. Wird die Störgröße bzw. eine relevante Größe auf deren Pfad nicht beobachtet, ist ggf. das Frontdoor-Kriterium anwendbar. Eine Voraussetzung ist, dass eine weitere Größe auf dem kausalen Pfad beobachtet wird. In Bild 5.11a ist dies der Fall, wenn X , Y und W beobachtet werden. Der gesuchte kausale Effekt $P_{Y|do(X=x)}$ kann in diesen Beispielen somit auf zwei unterschiedliche Weisen bestimmt werden, abhängig von den beobachteten Größen.

Bei der **Stichprobenverzerrung** wird die ungewollte statistische Abhängigkeit durch Konditionierung einer dritten Größe erreicht [PJS17]. Dies kann eintreten, wenn in der Stichprobenerhebung nur bestimmte Realisierungen einer Größe selektiert werden, sodass die Stichprobe nicht repräsentativ für die angenommene Grundgesamtheit ist [Pea09; HB19b]. Bild 5.11b zeigt ein Beispiel für Stichprobenverzerrung. Hier beinhaltet der zweite Pfad eine Kollision $X \rightarrow Z \leftarrow Y$. Angenommen es handelt sich bei Z um eine binäre Größe, so werden durch Selektion auf $Z = 1$ alle Werte $Z = 0$ aus der Stichprobe ausgeschlossen. Diese Konditionierung erzeugt wiederum eine statistische Abhängigkeit zwischen $X \not\perp\!\!\!\perp Y \mid Z = 1$, wie in der d -Separation diskutiert.

Aus der Kausalität ergeben sich eine Reihe von Erkenntnissen. Dazu gehören insbesondere die Identifikation von Störgrößen und Stichprobenverzerrung sowie die Bestimmung kausaler Effekte. Aus der Analyse kann aber auch folgen, welche Größen zu beobachten sind, um gewünschte Effekte zu berechnen. Dabei sind Stör-

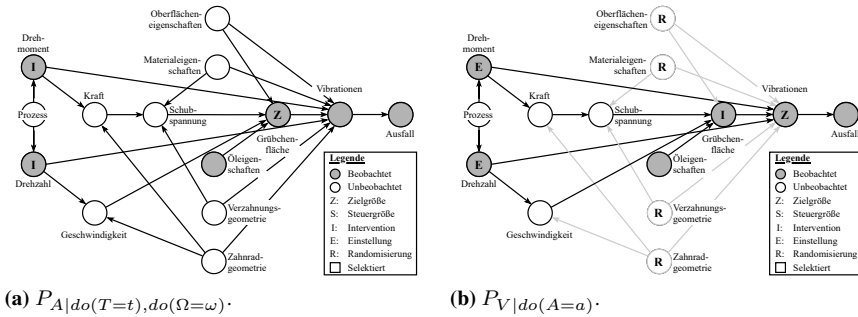


Bild 5.12 DAGs zur Bestimmung kausaler Effekte am Beispiel der Grübchenbildung.

größen und Stichprobenverzerrung immer gemeinsam zu adressieren. Ein Grund ist, dass die vermeintliche Konditionierung einer Störgröße diesen Pfad zwar blockiert aber gleichzeitig einen anderen Pfad über eine Kollision öffnen kann. Somit wird ein Bias entfernt und gleichzeitig ein anderer hinzugefügt.

Heutige Algorithmen des Maschinellen Lernens sind statistische Modelle, welche die bedingte Wahrscheinlichkeit $P_{Y|X}$ oder die multivariate Verteilung $P_{Y,X}$ lernen. Implikationen der Kausalität für das Maschinelle Lernen betreffen unter anderem das Unsupervised Learning. Dieses verspricht entgegen der kausalen Richtung bessere Resultate [PJS17]. Hintergrund ist, dass der Effekt P_Y Informationen über die Ursache P_X enthält, dies vice versa aber nicht der Fall ist. Darüber hinaus kann es sinnvoll sein, Algorithmen mit getrennten Datensets zu trainieren, statt alle Daten in einem Set zu agglomerieren. Zum Beispiel zeigt Arjovsky et al. [Arj+19], das so der Bias von Störgrößen verringert wird und die Modelle invarianter werden. Dieser Ansatz überträgt die d-Separation gedanklich auf die Modellierung.

Im Beispiel der Grübchenbildung werden zwei kausale Effekte untersucht: a) der Einfluss von Drehmoment T und Drehzahl Ω auf die Grübchenfläche A und b) der Einfluss der Grübchenfläche A auf die Vibrationen V . Bild 5.12 stellt die beiden Fälle gegenüber. Der kausale Effekt von Drehmoment und Drehzahl auf die Grübchenfläche kann direkt aus den gegebenen Größen bestimmt werden. Neben den relevanten kausalen Pfaden gibt es zwischen Intervention und Zielgröße keine weiteren offenen Pfade, die einen unerwünschten Bias verursachen. D. h. eine Konditionierung bestimmter Größen ist nicht notwendig und das Einstellset ist somit leer $\{\}$. Es ist zu beachten, dass eine Selektion auf ausschließlich ausgefallene Daten ($Ausfall = 1$) eine Stichprobenverzerrung darstellt. Durch die Konditionierung wird die Kollision in Vibrationen geöffnet, sodass sich sowohl von Drehmoment als auch von Drehzahl weitere Pfade zur Grübchenfläche ergeben. Eine Selektion der Größe Ausfall muss daher vermieden werden. Aus dem Backdoor-Kriterium mit dem Einstellset

$\{\emptyset\}$ folgt als Lösung Gleichung 5.4.

$$P_{A|do(T=t),do(\Omega=\omega)} = P_{A|T=t,\Omega=\omega} \quad (5.4)$$

Im Gegensatz wird der kausale Effekt zwischen Grübchenfläche und Vibrationen durch eine Reihe von Störgrößen beeinflusst, siehe Bild 5.12b. Dazu gehören Oberflächen-, Materialeigenschaften, Verzahnungs- und Zahnradgeometrie. Theoretisch gibt es verschiedene Möglichkeiten, zur Handhabung der Störgrößen. Eine Möglichkeit ist die Integration der Größen in das Einstellset des Backdoor-Kriteriums. Somit werden die Störgrößen blockiert und keine neuen Pfade geöffnet. Eine weitere Möglichkeit ist, die Größen durch statistisches Matching nachträglich zu randomisieren. Beide Varianten sind an dieser Stelle nicht anwendbar, da die relevanten Größen unbeobachtet sind. Auch das Frontdoor-Kriterium ist nicht anwendbar, unter anderem da keine weitere beobachtete Größe zwischen Intervention und Zielgröße liegt. An dieser Stelle ist der kausale Effekt nur bestimmbar unter der Annahme, dass die Größen bereits in der Stichprobenerhebung randomisiert werden. Diese sehr starke Annahme, sollte in der Praxis umfassend geprüft werden. Neben den genannten Störgrößen gibt es zwei weitere offene Pfade über Drehmoment und Drehzahl. Da beide Größen beobachtet werden, lassen sie sich ins Einstellset integrieren und somit blockieren. Mit der starken Annahme randomisierter Systemmerkmale folgt aus dem Backdoor-Kriterium mit dem Einstellset $\{T, \Omega\}$ als Lösung Gleichung 5.5.

$$P_{V|do(A=a)} = \sum_t \sum_{\omega} P_{V|A=a,T=t,\Omega=\omega} P_{T=t} P_{\Omega=\omega} \quad (5.5)$$

Review

Im letzten Schritt werden die Erkenntnisse der vorangegangenen Schritte mit den Anforderungen des gewählten Konzeptes verglichen. Essentiell sind interne Validität, eine ausreichende Verfügbarkeit und Repräsentativität der Zielgröße sowie die Abdeckung relevanter Größen durch die Daten. Ziel dieses Teilschritts ist die Identifikation von Defiziten im Sinne von Stärken, Schwächen, Chancen oder Risiken. Im Besonderen Schwächen und Risiken sollten kritisch hinterfragt sowie Gegenmaßnahmen definiert werden.

5.3 Modellierung (3.)

Die Modellierung beschreibt die Umsetzung des gewählten PHM-Konzeptes auf den Erkenntnissen der Analyse in Form eines oder mehrerer Modelle. Entsprechend hängen Art und Umfang dieser Phase stark von der individuell avisierten PHM-Lösung bzw. vom individuellen System und Datensatz ab. Beschrieben werden an dieser Stelle grundsätzliche Aufgaben und Schritte, deren detaillierte Ausgestaltung sich

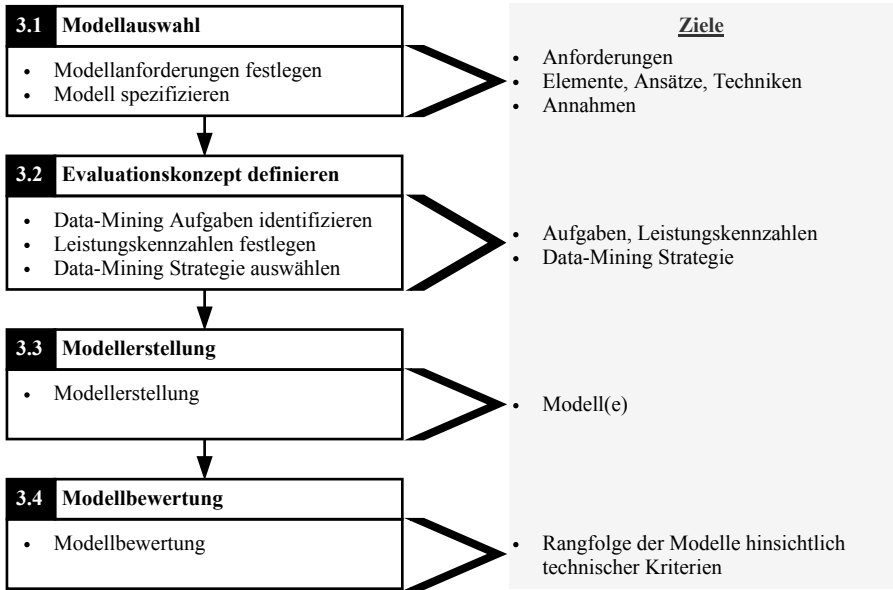


Bild 5.13 Methodik: Phase 3 Modellierung.

erst in iterativer Kombination mit den jeweiligen Rahmenbedingungen ergibt. Das Ziel dieser Phase kann die Modellierung selbst oder die Erstellung eines Modells sein (siehe auch Aufgabe 3.1 Modellauswahl). Bild 5.13 zeigt die vier Aufgaben dieser Phase, deren Teilschritte und Ziele. In allen Schritten sollten Ergebnisse, mögliche Annahmen, Schwierigkeiten etc. dokumentiert werden [CRISP-DM].

5.3.1 Modellauswahl (3.1)

Ziel der Modellauswahl ist es, Anforderungen an die Modellierung zu sammeln und darauf aufbauend die Modellierungselemente, -ansätze und -techniken zu spezifizieren. Entsprechend beinhaltet die Aufgabe die folgenden Teilschritte:

1. Modellanforderungen festlegen
2. Modell spezifizieren

Modellanforderungen festlegen

In dieser Arbeit werden drei Anforderungsklassen unterschieden: 1) Leistungskennzahlen 2) Performance (Laufzeit und Speicherbedarf) und 3) allgemeine Anforderungen. Die beiden erstgenannten werden in Abschnitt 5.1 bzw. in der folgenden




Bild 5.14 Input, Modellierung und Output einer PHM-Lösung.

Aufgabe behandelt. Ziel dieses Teilschritts ist es, alle weiteren Anforderungen zu identifizieren, zu analysieren und zu bewerten. Drei wesentliche Punkte sind die Unterscheidung zwischen ex-ante und ex-post Ansätzen, der Grad der Automatisierung und Black- vs. White-Box-Modelle, die im Folgenden kurz diskutiert werden.

In Anlehnung an Hyndman und Athanasopoulos [HA18], lassen sich Prognosen in **ex-ante** und **ex-post** Ansätze unterteilen. In ex-ante Prognosen beruht die Bewertung alleine auf Informationen, die zum Prognosezeitpunkt zur Verfügung stehen. Im Vergleich, sind in ex-post Ansätzen ebenfalls Informationen nach dem Prognosezeitpunkt verfügbar. Die jeweils geltende Anforderung (ex-ante vs. ex-post) ist insbesondere in der Entwicklung des Algorithmus zu beachten, da Labordaten i. d. R. ex-post Informationen enthalten, dies aber ggf. nicht der Situation in der Feldanwendung entspricht. Eine weitere Anforderung stellt der **Grad der Automatisierung** dar. Es wird zwischen wenig und hoch automatisierten Ansätzen unterschieden. In wenig automatisierten Ansätzen ist das Ziel der PHM-Lösung die manuelle Modellierung durch einen menschlichen Experten. Im Vergleich ist in hoch automatisierten Ansätzen das Ziel ein Modell, das ohne menschlichen Einfluss auf andere Systeme übertragen werden kann⁶⁴. Die einzelnen Modellierungselemente im PHM können als **Black- oder White-Box** abgebildet werden. Insbesondere Restriktionen bei der Verwendung von Black-Box-Modellen können durch innere oder äußere Regularien gegeben sein. Solche Restriktionen grenzen einerseits die Auswahl der Modellierungsansätze und -techniken ein (Deep vs. Shallow Learning). Andererseits können sie Anforderung an die Abbildung bestimmter Modellierungselemente stellen, wie zum Nachweis bestimmter Eigenschaften des Systems.

Modell spezifizieren

Ziel dieses Teilschritts ist die Auswahl relevanter Modellierungselemente sowie die Zuordnung von Modellierungsansätzen und -techniken. Grundlage sind die in Abschnitt 4.3 beschriebenen Modellierungselemente. Bild 5.14 zeigt nochmals das modulare Verständnis der Modellierungselemente. Input der Modellierung sind die verfügbaren Daten und Output eine Entscheidung in Form einer Aktion. Innerhalb der

⁶⁴Heute ist der Grad der Automatisierung im Prognostics oft höher als im Health Management [Con18]. Mit Ansätzen wie den Cyber-Physical Systems (CPS) wird die ganzheitliche Modellierung von Optimierung und Entscheidung immer zugänglicher, was eine zunehmende Automatisierung im Health Management erwarten lässt.


Tabelle 5.5 Orientierungshilfe zur Eingrenzung relevanter Modellierungselemente. Legende: D → Diagnose, P → Aktivitäten der Prognose, EB → Ereignis-Zeit-Bewertung, NB → Nutzungs-Bewertung, DB → Daten-basiert (Zustands-Bewertung), MB → Modell-basiert (Zustands-Bewertung), ● → Trifft eher zu, ◐ → Trifft teilweise zu, ○ → Trifft eher nicht zu, × → Nicht möglich

PHM-Konzept					
Modellierungselemente	D/P	EB	NB	DB	MB
Detektion:	D	×	×	◐	◐
Lokalisierung:	D	×	×	◐	○
Nutzungs-Schätzung:	D	×	●	◐	◐
Health-Schätzung:	D	●	●	●	●
EOL Definition:	D/P	●	●	●	●
Nutzungs-Prognose:	P	×	●	○	◐
Health-Prognose:	P	●	●	●	●
RUL-Bestimmung:	D/P	●	●	●	●


Modellierung besitzen Systemmodelle oft einen unterstützenden Charakter für die anderen Elemente. Zu Beginn sind die relevanten Modellierungselemente der individuellen PHM-Lösung zu identifizieren. Tabelle 5.5 gibt hierfür eine Orientierungshilfe. Dabei legen Prognostics Konzept und zeitlicher Bezug (Diagnose/Prognose) die Relevanz der Modellierungselemente fest. Nach der Auswahl sollten die einzelnen Elemente und ihre Wechselwirkungen soweit wie möglich spezifiziert und beschrieben werden.

Modellierungsansätze konkretisieren die ausgewählten Elemente hinsichtlich ihrer Umsetzung und werden ebenfalls in Abschnitt 4.3 beschrieben. Wichtige Auswahlkriterien sind die Verfügbarkeit von Daten, der Zielgröße, der Systemmodelle, die interne Validität und alle Anforderungen. Die Zuordnung einer oder mehrerer Modellierungstechniken erfolgt anschließend und kann anhand von Expertenwissen oder Fachliteratur erfolgen. Eine gute und aktuelle Übersicht verfügbarer Techniken, bieten zudem Programmier-Bibliotheken, wie [SCKT-LRN] und [TNSRFLW]. Abschließend sollten die Annahmen der gewählten Technik festgehalten werden [CRISP-DM].


Metaanalyse ([MAP19]): Bild 5.15a zeigt die absoluten Häufigkeiten verwendeter Healthmodelle. In einer überwiegenden Mehrzahl werden allgemeine Modelle verwendet, oft mit einer exponentiellen oder linearen Funktionsform. Als PoF-Modell findet das Paris-Law in verschiedenen Variationen am häufigsten Anwendung. Bild 5.15b zeigt die absoluten Häufigkeiten verwendeter Techniken in der Datenmodellierung. Am häufigsten kommen Zeit-Frequenz-Transformationen im „Engineering“ zum Einsatz, was sich mit der Häufigkeit der verwendeten Daten deckt (siehe




(a) Healthmodellierung.




(b) Datenmodellierung.




(c) Grundsätzliche Modellierungsansätze.



(d) Modellierungsziele.



(e) Diagnose/Prognosemodellierung.



(f) Zusammenhang zwischen System und Diagnose-/Prognosemodellierung.

Bild 5.15 Ergebnisse der Metaanalyse: Health- und Datenmodellierung; Ansätze und Ziele der Modellierung; Diagnose-/Prognosemodellierung (Basis: [MAP19]).

Bild 5.8). Im Detail handelt es sich vor allem um Techniken der Fast-Fourier-, Wavelet- und Hilbert-Huang-Transformation. Mittelwertbildung und allgemeine Regression werden insbesondere zur Ergänzung fehlender Werte, oder zur Reduzierung des Signalrauschens genutzt. Die Signalfilterung findet in der Rauschreduzierung sowie in der Detektion von Ausreißern Anwendung. Künstliche Neuronale Netze werden überwiegend im Sinne des „Representation Learnings“ genutzt. Das „Allgemeine Feature/Data Engineering“ beschreibt Quellen mit nicht näher spezifizierten Techniken. Bild 5.15c und 5.15d zeigen die absoluten Häufigkeiten allgemeiner Modellierungsansätze und Ziele in Diagnose und Prognose. Es zeigt die Dominanz Datenbasierter Ansätze der letzten Jahre. Innerhalb der Zielsetzung lassen sich Lösungen der Health-Bewertung (Schätzung oder Prognose) und der Detektion unterscheiden. Die Bilder 5.15e und 5.15f zeigen die absoluten Häufigkeiten der genutzten Modellierungstechniken sowie deren Verbindung zu Systemen. Optimale Ergebnisse in der Prognose lassen sich unter Verwendung stochastischer Modelle [Box+16] ggf. kombiniert mit Zustandsraummodellen [Goe+17] erreichen. Dies begründet die Dominanz der Bayes'schen Filter. Im Bereich der Daten-basierten Ansätze dominieren Künstliche Neuronale Netze⁶⁵. Verteilungsmodelle sprich Konzepte der Ereignis-Zeit- und Akkumulations-basierten Bewertung kommen nur relativ selten zum Einsatz.

5.3.2 Evaluationskonzept definieren (3.2)

Neben der Entwicklung einer PHM-Lösung ist eine weitere Herausforderung der Transfer von der Labor- auf die Feldanwendung. Hierzu sollte ein Evaluationskonzept definiert werden. Das Evaluationskonzept beinhaltet die Formulierung der Data-Mining Aufgabe(n), einer oder mehrerer Leistungskennzahlen sowie einer Data-Mining Strategie. Die Aufgabe besteht somit aus den folgenden Teilschritten:

1. Data-Mining Aufgaben identifizieren
2. Leistungskennzahlen festlegen
3. Data-Mining Strategie auswählen

Data-Mining Aufgaben identifizieren

Falls noch nicht geschehen, wird im ersten Schritt jedes Modellierungselement mit einer Data-Mining Aufgabe verknüpft. Dies hilft relevante Evaluationmetriken einzugrenzen. Abschnitt 2.3.2 listet etablierte Aufgaben im Maschinellen Lernen bzw. Data-Mining. Im PHM sind die Hauptaufgaben Anomalie Detektion, Klassifikation, Regression und Prognose ([MAP19]).

⁶⁵Im Detail handelt es sich überwiegend um Convolutional-, Recurrent- (LSTM) und Feedforward Neuronale Netze. Zum Einsatz kommen aber auch spezielle Varianten, wie Extreme Learning Machines oder Self-Organizing Maps.

Tabelle 5.6 Übersicht wichtiger Leistungskennzahlen eingeteilt anhand der Data-Mining Aufgabe [MAP19].

Anomalie Detektion und Klassifikation	
Receiver Operator Curve Area Under the Curve	Accuracy, Precision, Recall, F-Measure, False-Negative/Positive-Rate
Regression	
Bestimmtheitsmaß (R^2)	Mean Squared Error
Mean Deviation	Mean Absolute Error
Root Mean Squared Error	Mean Absolute Percentage Error
Prognose	
Prognostic Horizon (PH)	Relative Accuracy (RA)
$\alpha - \lambda$ Accuracy	Cummulative Relative Accuracy (CRA)

Leistungskennzahlen festlegen

In Abschnitt 5.1.2 werden Leistungskennzahlen definiert, die in Verbindung zu unternehmerischen Zielen stehen. Zusätzlich sollten Leistungskennzahlen definiert werden, welche die Qualität der Modellierungstechnik bewerten [CRISP-DM]. Basismetriken die selbst oder in abgeleiteten Varianten häufig Anwendung finden zeigt Tabelle 5.6.

Data-Mining Strategie auswählen

Ziel der Data-Mining Strategie ist die korrekte Bewertung der Modellgüte, im Sinne der Übertragbarkeit des Modells vom Labor auf das Feld. Zur statistischen Bewertung des Modells dienen die Verfahren der Kreuzvalidierung, die Separierungsart und -verhältnis der Labordaten festlegen. Beispielsweise wird separiert in eine Trainings-, Validierungs- und ggf. Testmenge (siehe Abschnitt 2.1.2).

5.3.3 Modellerstellung (3.3)

Der Fokus dieser Aufgabe liegt auf der Erstellung eines oder mehrerer Modelle mit den beabsichtigten Eigenschaften. Mehrere Modelle können sich ebenfalls durch die Wahl unterschiedlicher Hyperparameter ergeben. Die Teilschritte dieser Aufgabe werden durch das Evaluationskonzept definiert.

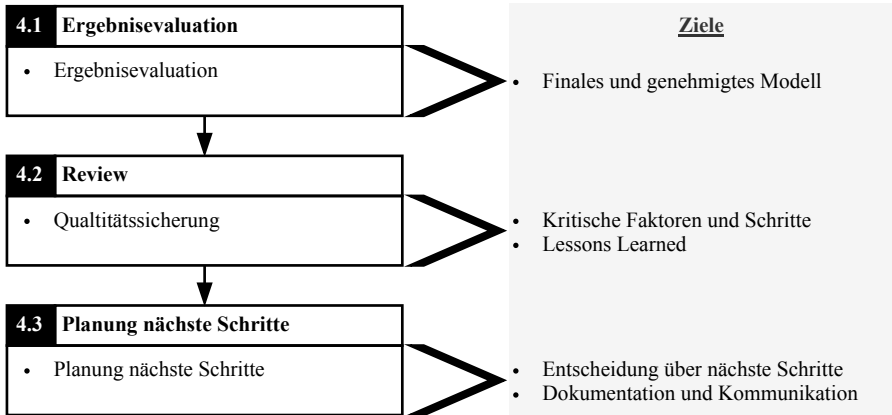


Bild 5.16 Methodik: Phase 4 Evaluation.

5.3.4 Modellbewertung (3.4)

In dieser Aufgabe wird eine Rangfolge der Modelle auf Basis technischer Kriterien bestimmt. In Anlehnung an Chapman et al. [CRISP-DM] sollten die folgenden Kriterien adressiert werden: Leistungskennzahlen, Modellverhalten und -interpretation, physikalische Interpretation, Plausibilität, Over- und Underfitting und die Modellergebnisse.

5.4 Evaluation (4.)

Die Evaluation bewertet das Modell und darüber hinausgehende Erkenntnisse des Projekts. Erkenntnisse können neue Fragen aufwerfen, Ansätze aufzeigen oder andere Effekte auf das Unternehmen besitzen. Bewertet werden hier nicht nur technische sondern auch alle anderen Kriterien, insbesondere hinsichtlich der unternehmerischen Ziele. Bild 5.16 zeigt die drei Aufgaben dieser Phase, die zugehörigen Teilschritte und Ziele. Die Ausführungen dieser Phase sind wenig PHM-spezifisch und orientieren sich daher sehr stark am allgemeinen CRISP-DM. [CRISP-DM]

5.4.1 Ergebnisevaluation (4.1)

Ziel dieser Aufgabe ist die finale Genehmigung des Modells bzw. die Formulierung von zu bearbeitenden Mängeln. Dazu werden die Modelle kritisch hinsichtlich aller nicht technischen Anforderungen und Ziele verifiziert. Falls möglich, kann das Modell auch in der Feldanwendung validiert werden. Die vollständige Evaluation ergibt sich in Kombination mit den Ergebnissen der Modellbewertung (3.4). [CRISP-DM]

5.4.2 Review (4.2)

Im Fokus des Reviews steht die Qualitätssicherung des gesamten Prozesses. Alle Schritte des Prozesses sollten kritisch analysiert werden. Dabei geht es einerseits um die Frage ob die Schritte notwendig waren und falls ja ob sie optimal ausgeführt wurden. Andererseits sollen Fehler, falsche Schritte, Alternativen sowie übersehene Faktoren und Aufgaben geprüft werden. [CRISP-DM]

5.4.3 Planung nächste Schritte (4.3)

In dieser Aufgabe wird eine Entscheidung darüber getroffen, ob weitere Schritte zu unternehmen sind oder das Projekt abgeschlossen werden kann [CRISP-DM]. Ein Projekt sollte abschließend immer dokumentiert werden und alle Informationen entsprechend zur Verfügung gestellt werden. Dies betrifft auch relevante Erkenntnisse für andere Fachbereiche, die innerhalb des Projektes gewonnen wurden.

Kapitel 6

Anwendungsbeispiel AutoEncoder

Dieses Kapitel zeigt ein ergebnisorientiertes Anwendungsbeispiel, in Anlehnung an [HB19a]. Das synthetische Beispiel beschreibt eine Produktion in der eine Vielzahl von Wälzlagern eingesetzt werden, z. B. in Getrieben, Motoren, Werkzeug- und Fördermaschinen [RS18]. Gemein ist all diesen dynamisch betriebenen Systemen, dass Wälzlagerschäden eine der wesentlichen Ausfallursachen darstellen [KAC17; NTL05]. Aus diesem Grund soll eine PHM-Lösung für das System Lager entwickelt werden. Eine weitere Anforderung ist die einfache Übertragbarkeit der Lösung auf neue Lagervarianten. Das heißt, ein Transfer des Modells ohne zeit- und kostenintensive manuelle Arbeit. Diese und weitere Anforderungen werden in den folgenden Abschnitten nochmals vertieft vorgestellt und analysiert. Als Resultat der Analysen folgt ein AutoEncoder Modell, das im Semi-Supervised Learning trainiert wird Anomalien zu erkennen.

Im Folgenden wird die in Kapitel 5 vorgestellte Methodik schrittweise angewendet. Strukturiert ist das Anwendungsbeispiel anhand der vier Aufgaben der Methodik, von der Konzeptauswahl bis zur Evaluation des Modells. Ob und in welchem Umfang einzelne Teilschritte der Methodik vorgestellt werden, hängt von der Relevanz des Teilschritts im Anwendungsbeispiel ab. Im Sinne des Anwendungsbeispiels, werden organisatorische Aufgaben wie Projektplanung, Review und die Planung nächster Schritte nicht vertieft.

Tabelle 6.1 Anwendungsbeispiel: Anforderungen an das Prognostics Konzept (siehe Tabelle 5.1). Legende: D → Diagnose, P → Prognose, EB → Ereignis-Zeit-Bewertung, NB → Nutzungs-Bewertung, D/MB → Daten- oder Modell-basiert (Zustands-Bewertung).

Lösungskonzept		D	P	EB	NB	D/MB
Fehlerprävention:	(Nicht) Vorausschauend	●	●	×	●	●
Health-Regelung:	Manuelle Eingriffe	◐	◐	×	◐	◐
Latenzzeit:	Langsam	●	◐	◐	◐	◐
	Mittelwert	◐	◐	×	◐	◐

6.1 Konzeptauswahl

Mit der hohen Bedeutung von Lagerschäden für den Ausfall der Industriegetriebe, kann das Problem der Verfügbarkeit zugeordnet werden. Potentielle Folgefehler und davon ausgehende Sicherheitsaspekte werden an dieser Stelle ausgeklammert. Dabei ist das Problem nicht, dass es keine PHM-Ansätze zur Identifikation von Lagerschäden gibt oder die Reaktionszeiten besonders gering sind. Die Probleme liegen vielmehr bei den unterschiedlichen Getrieben, der Vielfalt an Betriebsmodi und dem daraus folgenden hohen Zeit- und Arbeitsaufwand zur Adaption der Ansätze an neue Lager. Mit dem Fokus auf Verfügbarkeit folgt eine Eingrenzung des Health Management Konzepts auf die Fehlerprävention. Im realen Betrieb sind Lager hoch instationären Belastungen ausgesetzt [Ran11], weshalb der wahre Zustand nur bedingt mittels Ereignis-Zeit-Analysen abgeschätzt werden kann. Somit wird die vorausbestimmte Instandhaltung ausgeschlossen. Im Weiteren wird der Fokus auf die Entwicklung eines Prognostics Ansatzes gelegt. Aus diesem Grund wird die Aktive Instandhaltung ausgeklammert und die Health-Regelung auf manuelle Eingriffe festgelegt. Die genannten Kriterien erlauben eine Ableitung erster Anforderungen an das Prognostics Konzept nach Tabelle 6.1.

Zur weitere Eingrenzung des Prognostics Konzeptes kann Tabelle 5.2 herangezogen werden. Dies geschieht bereits in enger Abstimmung mit der Analysephase (folgender Abschnitt). Hier zeigt sich, dass die Lager Verschleißausfälle aufweisen. Es wird angenommen, dass Domänenwissen über Verschleißmechanismen zwar vorhanden ist, die Vielzahl der angedachten Getriebe und Betriebsmodi im instationären Betrieb aber nicht ausreichend abgedeckt und unterschieden werden. Die Beschleunigungsdaten enthalten neben den Informationen über den Lagerschaden weitere Störgrößen, d. h. relevante Informationen werden indirekt abgebildet. Mit der Information von Radialkraft und Drehzahl, lässt sich die Nutzung der Lager theoretisch

Tabelle 6.2 Anwendungsbeispiel: Definition des Prognostics Konzepts (siehe Tabelle 5.2). Legende: D → Diagnose, P → Prognose, EB → Ereignis-Zeit-Bewertung, NB → Nutzungs-Bewertung, DB → Daten-basiert (Zustands-Bewertung) MB → Modell-basiert (Zustands-Bewertung).

Lösungskonzept		D	P	EB	NB	DB	MB
Einordnung Tabelle 6.1:		●	●	×	●	●	●
Ausfallart:	Verschleißausfall	●	●	●	●	●	●
Domänenwissen:	In Ansätzen	●	●	●	●	●	×
Daten:	Indirekt relevante Größen	●	●	●	●	●	○
Nutzung:	Beschreibbar	●	●	●	●	●	●
Genauigkeit RUL:	Weniger Hoch	●	●	●	●	●	●
System ist:	Serie im Flottenbetrieb	●	●	●	●	●	●
Anforderungen:	Hohe Übertragbarkeit	●	●	●	●	●	●
Mittelwert		●	●	×	●	●	×

beschreiben [RS18]. Es wird angenommen, dass die Anforderung an Genauigkeit weniger hoch ist, da das System i. d. R. nicht schlagartig ausfällt. Zwei weitere Kriterien sind der Einsatz in Serie und die Anforderung an eine einfache Übertragbarkeit der Ansätze auf neue Lager. Die Eingrenzung ist in Tabelle 6.2 zusammengefasst.

Das Ergebnis der Konzeptauswahl zeigt zwei mögliche Prognostics Konzepte: a) die Nutzungs-Bewertung und b) die Daten-basierte Zustands-Bewertung. Auf Basis der Nutzungs-Bewertung können keine Früh- und Zufallsausfälle erkannt werden. Aus diesen Gründen wird im Folgenden ein Ansatz der Daten-basierten Zustands-Bewertung verfolgt. Da die Anforderungen zudem stärker auf einer hohen Übertragbarkeit des Ansatzes und weniger auf einer hohen Genauigkeit oder kurzen Latenzzeiten liegen, wird eine Diagnose ohne Prognose angestrebt.

6.2 System- & Datenanalyse

In diesem Anwendungsbeispiel werden Beschleunigungsdaten von Lagern aus der öffentlichen Datenbank des „Center for Intelligent Maintenance Systems“ (IMS) genutzt [Lee+07]. Das getestete Lager ist ein Pendelrollenlager (Rexnord ZA-2115). Die Datenbank umfasst Messungen zu zwölf Lagern aus drei Testreihen (Tests).










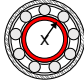





Bild 6.1 Anwendungsbeispiel: Aufbau des Prüfstands für den Lagertest (in Anlehnung an [Lee+07]).

Systemanalyse: Den schematischen Prüfstand zeigt Bild 6.1. Kontrollierte Einflussgrößen sind die konstante Antriebsdrehzahl (2000 U/min) und die Radialkraft von $F = 26,689 \text{ kN}$. Die Daten des IMS bieten den Vorteil, dass die Tests ohne Vorschädigung stattfinden, wie es bspw. zur Versuchsraffung typisch ist. Das heißt die Schädigung, bzw. Schadensinitiierung und Schadenswachstum, wird so wenig wie möglich verfälscht. [Qiu+06; Lee+07]

Eine Testreihe wird beendet, sobald eine gewisse Menge an Abrieb im Öl überschritten wird [Lee+07]. Der Start der Degradation liegt somit bereits vor diesem Zeitpunkt und die Höhe der Degradation einzelner Lager ist bei Versuchende nicht bekannt. Mit einer anschließenden Untersuchung konnten Ermüdungsschäden auf vier Lagern nachgewiesen werden, je einmal am Innenring und Wälzkörper sowie zweimal am Außenring [Lee+07]. Ermüdungsschäden starten mit feinen Anrissen teils unter der Oberfläche und zeigen sich mit der Zeit als Pittings oder Grübchen [RS18]. Diese Effekte bedingen unter anderem Ausbrüche, die sich als Abrieb im Öl zeigen. Durch kontinuierliches Überrollen werden die Schäden teilweise wieder geglättet, es kommt zum Phänomen der Heilung [Qiu+06]. Tabelle 6.3 zeigt die zwölf Lager, deren Position im Test, die Zuordnung zu einer Testreihe sowie den Ort des aufgetretenen Schadens.

Datenanalyse: Die Daten werden am Prüfstand in einem geplanten Experiment erhoben. Dabei ist jedes Lager mit einem Beschleunigungsaufnehmer ausgestattet, in Testreihe 1 sind es sogar zwei je Lager. Gemessen werden Beschleunigungen für je eine Sekunde mit einer Abtastrate von 20 kHz , alle fünf bis zehn Minuten [Lee+07; Qiu+06]. Zielgröße ist die Schädigung (Zustand), deren wahrer Verlauf aber unbekannt ist. Verfügbar ist die Information indirekt über die Beschleunigungsdaten (Verhalten) sowie Ort und Art des Schadens (Fehler). In vier von zwölf Lagern tritt ein Schaden auf, die restlichen Lager weisen keine sichtbaren Schäden auf. Dies setzt voraus, dass die Stichprobe von zwölf Lagern die Grundgesamtheit hinreichend genau abbildet. Die Zeitstempel der Messungen zeigen, dass Testreihe 1 und 3 mehrere Pausen enthalten. Genauere Informationen sind hierzu nicht vorhanden. Die Anzahl

Tabelle 6.3 Anwendungsbeispiel: Zuordnung der Lager zu Lagerposition, Testreihe, Defekt und Trainingsmenge. Erwartungswert (E) und Standardabweichung (σ) repräsentieren den Baseline-Vergleich in Anlehnung an [HWG17].

	Test 1 ($N = 2.156$)	Test 2 ($N = 984$)	Test 3 ($N = 6.324$)
Lager 1		 $E[N_{EOL}] \approx 575$ $\sigma[N_{EOL}] \approx 68$	 Trainingsmenge
Lager 2		 Trainingsmenge	
Lager 3	 $E[N_{EOL}] \approx 2.040$ $\sigma[N_{EOL}] \approx 78$	 Trainingsmenge	 $E[N_{EOL}] \approx 2.367$ $\sigma[N_{EOL}] \approx /$
Lager 4	 $E[N_{EOL}] \approx 1.715$ $\sigma[N_{EOL}] \approx 52$		 Trainingsmenge

an Messpunkten (Instanzen) je Testreihe variiert zwischen 984 und 6.324, siehe Tabelle 6.3. Da die Originaldaten keine Information über den wahren Beginn der Schädigung enthalten, wird dieser anhand eines Baseline-Vergleichs festgelegt. Hierzu werden Erwartungswert und Standardabweichung der gesammelten Ergebnisse von Hasani et al. [HWG17] gebildet.

Kombinierte Analyse: Da es sich um ein geplantes Experiment handelt, wird davon ausgegangen, dass die Voraussetzungen eines randomisierten kontrollierten Experimentes eingehalten werden. Zu beachten ist, dass das Versuchende keine Information über die Höhe des individuellen Lagerschadens enthält. Die ausschlaggebende Menge an Abrieb im Öl kann durch jede Komponente des Prüfstandes, in unterschiedlichen Verhältnissen erzeugt werden.

6.3 Modellierung

Aus den vorherigen Schritten ist bekannt, dass die PHM-Lösung in Form einer Daten-basierten Zustands-Bewertung umgesetzt werden soll. Dabei liegt der Fokus auf Diagnose und einer einfachen Übertragbarkeit auf neue Lager. Zu diesem Zweck stehen Beschleunigungsmessungen von zwölf Lagern, mit vier verzeichneten Schäden zur Verfügung. In diesem Abschnitt wird ein passendes Modell ausgewählt, das Evaluationskonzept festgelegt, das Modell erstellt und bewertet.




Bild 6.2 Anwendungsbeispiel: Modellierungselemente.

Modellauswahl: Bild 6.2 zeigt die Spezifikation der Modellierungselemente, die im Folgenden erläutert werden. Wichtige Anforderungen an das Modell sind die automatisierte ex-ante Verarbeitung der Daten sowie die einfache Übertragbarkeit. Als Daten-basierter Ansatz entfällt die Systemmodellierung. Mit dem Fokus auf Prognostics bzw. Diagnose entfallen ebenfalls die Modellierungselemente Prognose und Optimierung. Klassische Elemente der Lager-Diagnose sind nach Randall [Ran11]: Drehzahlsschwankungen korrigieren, Entfernen von diskreten Frequenzen, Korrektur von Smear-Effekten des Übertragungspfades, Festlegung geeigneter Frequenzintervalle für die Demodulation und Filterung sowie die abschließende Frequenzbereichstransformation. Da die Adaption dieser traditionellen Ansätze auf ein einzelnes System oft viel Zeit und Arbeit erfordert [Hea16], steht dies in Konflikt mit der Anforderung einer einfachen Übertragbarkeit.

Eine weitere Schwierigkeit besteht darin, dass die Zielgröße nur unpräzise für einen kleinen Teil der Lager bekannt ist. Acht von Zwölf Lagern laufen im fehlerfreien Normalzustand. Da die ausgefallenen Lager ebenfalls zu Beginn den Normalzustand beschreiben, ist der Anteil „normaler“ Daten wesentlich höher. Die angestrebte PHM-Lösung soll das unbalancierte Verhältnis adressieren und nutzen. Ziel ist es Abweichung vom Normalzustand zu detektieren und darauf aufbauend eine Healthschätzung durchzuführen. In der Diagnose wird dies durch die Modellierungselemente der Detektion, Healthschätzung und EOL-Definition abgedeckt. Der nächste Schritt ist die Auswahl konkreter Modellierungsansätze, bspw. auf Basis der in Abschnitt 4.3 Beschriebenen. Für die Detektion wird ein Ansatz der Semi-Supervised Anomalie Detektion gewählt. Mit diesem ist es möglich, die überwiegend vorhandenen Informationen über den normalen Zustand zu nutzen, um diesen von geschädigten Zuständen zu unterscheiden. Für die Healthschätzung und EOL-Definition wird nach Henß und Bertsche [HB19a] ein empirisches Modell gewählt.

Als Modellierungstechnik der Detektion wird ein AutoEncoder (AE) gewählt. AE beschreiben eine spezielle Architektur von KNN, mit einem Engpass (engl. Bottleneck) im mittleren Layer, Bild 6.3. In der Semi-Supervised Anomalie Detektion werden AE darauf trainiert, den Output \hat{y} als Kopie des Inputs x zu rekonstruieren ($\hat{y} \approx x$). Somit entfällt die Notwendigkeit eines expliziten Labels der Daten. Im Training lernen AE den Input bis zum Bottleneck-Layer zu kodieren (reduzieren)

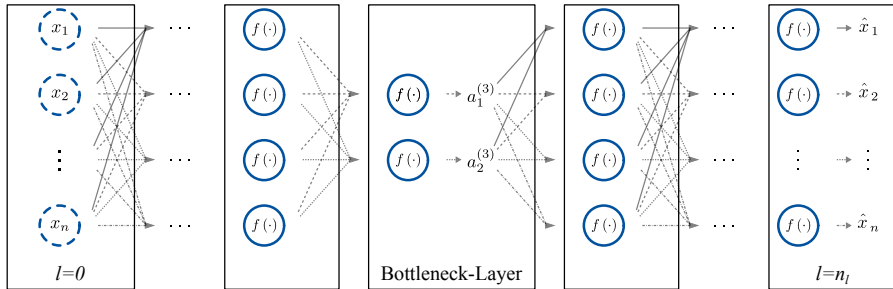


Bild 6.3 Anwendungsbeispiel: Architektur eines AutoEncoders.

und anschließend wieder zu dekodieren. In anderen Worten verdichtet der AE Informationen im Bottleneck-Layer. Nach Goodfellow et al. [GBC16] kann dies auch als nichtlineare Generalisierung einer Hauptkomponentenanalyse verstanden werden. Dabei ist die Herausforderung, dass der AE den wahren funktionalen Zusammenhang ($y = f(x)$) lernt und Overfitting vermieden wird. Der Aufbau eines AE ist i. d. R. symmetrisch. Im Folgenden wird der AE an Daten trainiert, die im Normalzustand beobachtet wurden ($p_{healthy}(x)$). Wenn der Systemzustand in fehlerhaft wechselt, ändert sich die zugrunde liegende Verteilung in $p_{faulty}(x)$. In diesem Fall trifft der gelernte Zusammenhang $y = f(x)$ nicht mehr zu und der AE reproduziert einen fehlerhaften Output. Auf Basis der Bewertung dieses Reproduktionsfehlers $\epsilon = \mathcal{L}(x, \hat{y})$ lassen sich Anomalien bewerten.

Aufbauend auf der Diagnose kann die Modellierung der Daten festgelegt werden. Da die Informationsdichte im Frequenzbereich wesentlich höher ist, wird dieser als Input des AE verwendet. Dies ist dem Modellierungselement Engineering zuzuordnen. Weitere Elemente sind Bereinigung und Fusion, die insbesondere beim Übertrag auf die Feldanwendung Bedeutung gewinnen. Mit der Bereinigung können im Betrieb Drehzahlschwankungen korrigiert und mit der Fusion mehrere Sensorsignale zum Ausgleich von Sensorfehlern kombiniert werden. Auf Basis der verfügbaren Daten, wird im Folgenden nur das Engineering weiter verfolgt.

Evaluationskonzept definieren: Es werden vier fehlerfreie Lager der Trainingsmenge zugewiesen, siehe Tabelle 6.3. Alle anderen Lager entfallen auf die Validierungsmenge. Aufgrund der geringen Anzahl an Lagern, wird auf die Testmenge verzichtet. Der Algorithmus wird somit ausschließlich an Lagern trainiert, die einen Normalzustand (gesunden Zustand) aufweisen. Im Detail werden 64 zufällige Messungen im Bereich der zeitlich ersten 264 Messungen ausgewählt, wobei die ersten acht Messungen aufgrund des Einlaufverhaltens ausgelassen werden. Die früheste Detektion einer Schädigung startet bei Messung 538 (Baseline-Vergleich [HWG17]). Die Verteilungen $p_{healthy}(x)$ und $p_{faulty}(x)$ sind somit voneinander getrennt. Mit

diesem Ansatz soll erreicht werden, dass ein Modell entsteht, das eine möglichst einfache Übertragbarkeit gewährleistet.

Modellerstellung: Im Folgenden wird die Prozedur anhand der Modellierungselemente (Bild 6.2) vorgestellt. Eingangssignal ist die gemessene Zeitreihe \mathbf{x}_Z . Im Engineering wird die Zeitreihe in drei Schritten verarbeitet: 1. eine Fast-Fourier-Transformation (FFT) mit Fensterfunktion, 2. ein nachgelagertes Pooling sowie 3. eine Normalisierung. Die FFT bietet eine ressourceneffiziente Umwandlung der Zeitreihe in deren Frequenzanteile $\mathbf{x}_Z \rightarrow \mathbf{x}_F$. Mittels Tukey-Fensterfunktion werden dabei Diskontinuitäten reduziert. Das anschließende Max-Pooling dient dem Downsampling, da eine niedrigere Auflösung im Folgenden ausreicht $\mathbf{x}_F \rightarrow \mathbf{x}_{FP}$. Abschließend werden die Daten skaliert $\mathbf{x}_{FP} \rightarrow \mathbf{x}_{FPS} \in [-1, \dots, 1]$.

Die verarbeiteten Daten \mathbf{x}_{FPS} sind der Input des AE, kurz als \mathbf{x} bezeichnet. Als finales Modell wird ein Denoising-AE (DAE) verwendet. Hier wird der Input im Training mit einem zufälligen Rauschen überlagert ($\mathbf{x} + \mathcal{N}(0, \sigma^2)$), Output bleibt weiterhin das unverrauschte Signal \mathbf{x} . Die Lernaufgabe ändert sich von der einfachen Rekonstruktion des Inputs zur komplexeren Rauschreduzierung, wodurch der AE gezwungen wird, die Struktur $p_{Data}(\mathbf{x})$ zu lernen [GBC16]. Im Folgenden werden die verwendeten Hyperparameter beschrieben. Diese sind Ergebnis einer Parameterstudie nach Henß und Bertsche [HB19a]. Als Leistungskennzahl wird der MSE verwendet. Die Kodierung besteht aus sechs Layern mit der Folgenden Anzahl an Units 390, 128, 64, 32, 8 und 2 Units im Bottleneck-Layer. Mit einem symmetrischen Aufbau ergibt sich die Dekodierung entsprechend umgekehrt und es folgt eine Gesamtzahl von elf Layern. ReLU wird als Aktivierungsfunktion verwendet, um selbst bei der hohen Layeranzahl stabile Gradienten in der Backpropagation zu erzielen. Nur im Output-Layer wird eine lineare Aktivierung verwendet. Um explodierenden und verschwindenden Gradienten zu entgegenen, werden die Gewichte je Layer auf den Einheitsvektor normiert $\|\mathbf{w}^{[l]}\| = 1$. Als Optimierungsalgorithmus wird Adams verwendet, mit einer Lernrate von $\alpha = 1E - 6$ und einer Zerfallsrate (engl. Decay) für das 1. bzw. 2. Moment von $\beta_1 = 0,9$ bzw. $\beta_2 = 0,999$.

Zur Healthschätzung (Schädigungsschätzung) bzw. zur EOL-Definition wird ein empirisches Modell nach Henß und Bertsche [HB19a] verwendet, siehe Gleichung 6.1 und 6.2. Dem Modell liegt die Annahme zugrunde, dass jede Abweichung vom Normalzustand das System schädigt. Der Zustand zum Zeitpunkt N_i wird anhand des DAE-Reproduktionsfehlers ϵ_i bewertet. Als Normalzustand wird der Median (\mathbf{M}) aller bisherigen Zustände ϵ_i ($i \in [0, p]$) definiert. Demgegenüber wird der aktuelle Zustand als gleitender Erwartungswert \mathbf{E} für ein w breites Fenster ϵ_i ($i \in [p - w, p]$) definiert. Im Sinne inkrementeller Ansätze der Schadensakkumulation, werden die Inkremente über der Zeit aufsummiert. Dabei repräsentiert $D(t_p)$ die Schädigung zum aktuellen Zeitpunkt t_p .

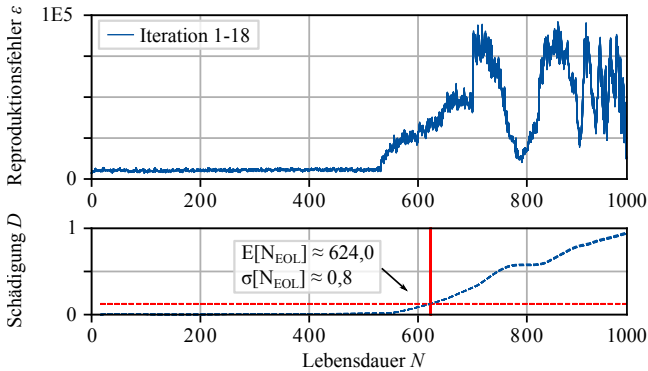


Bild 6.4 Anwendungsbeispiel: Reproduktionsfehler und Schädigung für Lager 1 aus Test 2.

$$D(t_p) = \frac{1}{t_p} \sum_{t_0}^{t_p} (\mathbf{E}[\epsilon_{p-w}, \dots, \epsilon_p] - \mathbf{M}[\epsilon_0, \dots, \epsilon_p]) \quad (6.1)$$

Die EOL-Defintion berechnet sich aus Median \mathbf{M} und Standardabweichung \mathbf{S} der Schädigung, der 50 ersten Werte nach Anlauf, Gleichung 6.2 [HB19a]. Die Faktoren $\alpha = 4$ und $\beta = 8$ sind über alle Lager konstant.

$$D_{EOL} = \alpha * \mathbf{M}[D(t_{0+w}), \dots, D(t_{50})] + \beta * \mathbf{S}[D(t_{0+w}), \dots, D(t_{50})]^{\frac{1}{2}} \quad (6.2)$$

Modellbewertung: Um die Ergebnisse statistisch zu validieren, werden 18 Iterationen von Training und Vorhersage durchgeführt. Dabei unterscheiden sich die Trainingsdaten aufgrund der zufälligen Auswahl von 64 aus 264 Messungen. In allen Iterationen konvergiert der DAE zuverlässig und reproduzierbar in ein schmales Errorband.

Bild 6.4 zeigt den zeitlichen Verlauf von Reproduktionsfehler und Schädigung für das ausgefallene Lager 1 aus Test 2. Der Verlauf des Reproduktionsfehlers ϵ zeigt deutlich einen Unterschied zwischen Normalzustand und der einsetzenden Anomalie ab ca. $N = 530$. Optisch ist der Verlauf über die 18 Iterationen dabei kaum zu unterscheiden. Lediglich die Standardabweichung der Schädigungsschätzung zeigt eine leichte Streuung. Im Verlauf der Schädigung zeigt sich der inkrementelle Ansatz der Schadensakkumulation. Alle Ergebnisse im Vergleich mit der Baseline sind in Tabelle 6.4 dargestellt. Der Schaden von Lager 3 aus Test 1 wird vom DAE nicht erkannt. Dieser tritt bei ca. $N = 2.040$ auf, kurz vor Testende ($N = 2.156$). Der Vergleich mit den anderen ausgefallenen Lagern lässt vermuten, dass der DAE im Vergleich mit der Baseline Schäden etwas später detektiert. Dabei ist zu beachten, dass die meisten

Tabelle 6.4 Anwendungsbeispiel: Ergebnisse des DAE im Vergleich zu den Baseline-Ergebnissen.

		Test 1		Test 2	Test 3
		Lager 3	Lager 4	Lager 1	Lager 3
Baseline [HWG17]	$\mathbf{E} [N_{EOL}]$	2.040	1.715	575	2.367
	$\mathbf{S} [N_{EOL}]$	78	52	68	/
DAE	$\mathbf{E} [N_{EOL}]$	/	1.961	624	6.272
	$\mathbf{S} [N_{EOL}]$	/	35	1	6

Baseline-Ansätze aber ebenfalls an den ausgefallenen Lagern trainiert werden. Im Fall des nicht erkannten Schadens könnte eine Ursache sein, dass nicht ausreichend Messungen nach Schadensbeginn vorhanden sind. Die grundsätzlich spätere Detektion ist auf den Fokus einer hohen Übertragbarkeit zurück zu führen. Mit einem Update der Modellparameter an jedem neuen Lager, kann die Genauigkeit weiter erhöht werden [HB19a]. Der Zeitpunkt des detektierten Schadens von Lager 3 aus Test 4 weicht stark vom Baseline-Vergleich ab. In der Baseline wird der Schaden aber lediglich von einem der sechs Ansätze detektiert. Die wahre Lebensdauer bei Schadensbeginn ist somit schwer zu bewerten.

6.4 Evaluation

Das Modell zeigt, dass mit dem DAE automatisierte, ex-ante und übertragbare Schadensdiagnosen für Lagerausfälle möglich sind. Somit werden die Anforderungen in einem Proof of Concept verifiziert. Ein wichtiger nächster Schritt zur Evaluation ist die Validierung in der Feldanwendung. Neben den unterschiedlichen Getrieben und Betriebsmodi müssen hier beispielsweise auch Auswirkungen von Instandhaltungsmaßnahmen auf die Güte des Modells bewertet werden.

Kapitel 7

Zusammenfassung und Ausblick

PHM nutzt die Entwicklung in Digitalisierung und Konnektivität technischer Systeme, um Störungen und Ausfälle frühzeitig zu erkennen und geeignete Gegenmaßnahmen zu definieren. Ziele sind beispielsweise die Senkung von Kosten, die Minderung von Risiken oder die Maximierung der nutzbaren Betriebsstunden. Langfristig sind PHM-Lösungen denkbar, die eine vollständig integrierte digitalisierte Selbstoptimierung über alle Stakeholder und die gesamte Wertschöpfungskette ermöglichen. Dies führt zu hohen ökonomischen Potenzialen, beispielsweise bei Garantie & Kulanz, den Instandhaltungskosten oder in Geschäftsmodellen wie der Servitization. Daraus folgt wiederum die Chance auf einen echten Wettbewerbsvorteil. Mit der „Methodik zur Konzeption, Analyse und Modellierung von Lösungen im Prognostics and Health Management (PHM)“ wird der Zugang zu diesen Vorteilen und Potenzialen gefördert. Wissenschaftliche Grundlage ist die Forschungsmethode DRM, auf deren Basis die Forschungsaufgabe abgegrenzt, Forschungsziele definiert, Studien durchgeführt sowie Forschungsfrage und Schlüsselfaktoren definiert werden (Kapitel 3).

Basis einer effektiven interdisziplinären Entwicklung von PHM-Lösungen ist eine gemeinsame sowie konsistente Formulierung von Grundlagen, Konzepten und Modellen. Kapitel 4 begegnet dieser Aufgabe und strukturiert den Diskursraum anhand einfacher Merkmale, die untereinander exklusiv aber gegenseitig vollständig sind. Wichtige Merkmale der Konzepte sind die Unterscheidung zwischen „Prognostics“ und „Health Management“, der zeitliche Bezug, der Modellierungsansatz und die RAMS+ Zieldefinition. Auf dieser Grundlage wird eine Basis geschaffen, um etablierte Konzepte wie die Rekonfiguration, das Predictive oder Prescriptive Main-

tenance in eine gemeinsame Betrachtung einzusortieren. Somit wird die Komplexität reduziert, die Konzepte können einfach verglichen und effizient ausgewählt werden. Im zweiten Schwerpunkt des Kapitels wird ein holistisches PHM-Modell vorgestellt, das den funktionalen Zusammenhang einer PHM-Lösung beschreibt. Um auch hier die Komplexität zu beherrschen, wird das Modell in 19 Elemente untergliedert. Mit der Unterteilung in Modellierungselemente wird dem Anwender die Möglichkeit gegeben, die gewünschte Funktionalität durch Kombination einzelner Elemente zweckdienlich umzusetzen. Zusätzlich werden jedem Element Modellierungsansätze zugeordnet, welche Optionen zur weiteren Konkretisierung der Elemente aufzeigen. Eine abschließende Parameterstudie zeigt die Potenziale, die mit dem Wechsel von der Ereignis-Zeit- auf die Zustands-Bewertung verbunden sind. Bei gleicher Konstruktion und Nutzung lässt sich der Umfang der nutzbaren Betriebsstunden, vor allem bei verfügbarkeits- und sicherheitsrelevanten Systemen, erheblich verlängern.

Kapitel 5 beschreibt die eigentliche Methodik. Diese gibt einen Leitfaden von der Lösungsfindung, über die Auswahl des passenden Konzepts und die Analyse der Rahmenbedingungen bis hin zur konkreten Umsetzung der PHM-Lösung in einem evaluierten Modell. In vier Hauptphasen werden die wichtigsten Aufgaben sowie deren Ziele vorgestellt, um den Anwender Schritt für Schritt zur richtigen PHM-Lösung zu führen. Aufgrund der Vielfalt möglicher PHM-Lösungen wird die Methodik generisch und unabhängig von beispielsweise konkreten Modellierungstechniken beschrieben. Allerdings fördern konkrete PHM-Lösungen das Verständnis und helfen etablierte Lösungswege zu erkennen. Aus diesem Grund wird die Methodik begleitet von einer empirischen Metaanalyse, bestehend aus ca. 260 wissenschaftlichen Beiträgen, die gezielt Lösungen aufzeigt. Vor dem Hintergrund von Digitalisierung und Konnektivität steigt der Einsatz von Daten-basierten Lösungen im PHM. Aus diesem Grund wird ein adaptierter CRISP-DM als Basis der Methode verwendet. Die steigende Anzahl an Beobachtungsdaten birgt weitere Herausforderungen im korrekten Umgang mit Störgrößen und Stichprobenverzerrung. Mit einer kombinierten Analyse von Domänenwissen und Daten, auf Basis der Kausalen Inferenz, werden Möglichkeiten aufgezeigt, diese Schwierigkeiten zu adressieren. Infolgedessen lassen sich nicht nur intern valide Modelle erstellen, darüber hinaus können Fehlentwicklungen frühzeitig erkannt und verhindert werden.

Die prinzipielle Anwendbarkeit der Methodik wird in Kapitel 6 gezeigt. Im Beispiel ist die Problemstellung die Entwicklung übertragbarer Ansätze zur Bewertung von Wälzlagerschäden in verschiedenen Getrieben bei unterschiedlichen Betriebsmodi. Durch Anwendung der Methodik wird die Problemstellung schrittweise in eine Daten-basierte Zustands-Bewertung mittels AutoEncoder überführt. Es wird nachgewiesen, dass mit einem Ansatz des Semi-Supervised Learnings Lagerschäden erkannt werden können, selbst wenn die Modellbildung ausschließlich Daten gesunder Lager berücksichtigt. Der Ansatz zeigt nicht nur eine gute Übertragbarkeit, sondern macht zudem die zeitintensive manuelle Erstellung relevanter Merk-

male überflüssig. Ein nächster Schritt könnte die Übertragung des Modells auf die Feldanwendung oder die Validierung von berechnetem und realem Schädigungsverlauf sein. Bei einer größeren Anzahl an Versuchsdaten, kann zudem eine Lokalisierung der schadhaften Komponente integriert werden. Die Analyse der Merkmale im Bottleneck-Layer bietet hierzu hohes Potenzial, ggf. in Kombination mit einem Wechsel auf einen Variational-AutoEncoder.

Potenzial für weiterführende Arbeiten wird zudem in der Erweiterung der kombinierten Analyse (Abschnitt 5.2.3) um eine Bewertung der externen Validität gesehen. Insbesondere der Wechsel von der Labor- auf die Feldanwendung stellt Entwickler häufig vor Herausforderungen. Anders als die interne Validität kann diese Frage nicht mittels ideal randomisierter kontrollierter Experimente adressiert werden. Ob und unter welchen Bedingungen Modelle übertragbar sind, kann aber mithilfe der externen Validität untersucht werden. Auf Grundlage einer Methodik, die externe Validität und den Fachbereich PHM verknüpft, lassen sich somit Probleme in der Feldanwendung frühzeitig erkennen und umgehen. Risiken von Fehlentwicklungen lassen sich so weiter reduzieren.

Die Methodik beschreibt ein Vorgehen zur Konzeption, Analyse und Modellierung von Lösungen im Prognostics and Health Management (PHM). Sowohl Entwurf als auch Integration der PHM-Lösung in das eigentliche System werden im Umfang dieser Arbeit bewusst nicht betrachtet. Dazu zählt auch die Schnittstelle zur statistischen Versuchsplanung, beispielsweise zur Ermittlung von Health-Modellen oder als Verfahren der Datenerzeugung. Eine konkrete Fragestellung könnte ebenfalls sein, inwieweit sich die PHM-Lösung einer Komponente auf andere Komponenten auswirkt. All diese Punkte und Weitere beschreiben wichtige Fragestellungen einer PHM-Lösung im gesamtheitlichen Produktentwicklungsprozess (PEP). Der PEP beschreibt wiederum nur einen Ausschnitt des Produktlebenszyklus (PLZ). Im gesamten PLZ ergeben sich somit eine Reihe interessanter Themen für weiterführende Arbeiten.

Zuletzt ist zu erwähnen, dass PHM eine Disziplin ist, die in starker Verbindung mit Digitalisierung, Konnektivität und Maschinellern steht. Diese Technologien entwickeln sich aktuell in kürzester Zeit weiter und ebenso die Fachdisziplin PHM. Dieser Ausblick eröffnet sowohl zusätzlichen Bedarf weiterführender Arbeiten und zeigt das wachsende Potenzial von PHM-Lösungen.

Literatur

Monographien

- [BWP16] Reinhard Bachleitner, Martin Weichbold und Markus Pausch. *Empirische Prognoseverfahren in den Sozialwissenschaften*. Wiesbaden: Springer Fachmedien Wiesbaden, 2016. ISBN: 978-3-658-11931-7.
- [BG20] Beate Bender und Dietmar Göhlich, Hrsg. *DUBBEL: Taschenbuch für den Maschinenbau Grundlagen und Tabellen - Band 1*. 26. Aufl. Springer Vieweg, 2020. ISBN: 978-3-662-59711-8.
- [BL04] Bernd Bertsche und Gisbert Lechner. *Zuverlässigkeit im Fahrzeug- und Maschinenbau*. 3. Aufl. Springer-Verlag Berlin Heidelberg, 2004. ISBN: 978-3-540-34996-9.
- [BW18] Jürgen Beyerer und Petra Winzer, Hrsg. *Beiträge zu einer Systemtheorie Sicherheit (acatech DISKUSSION)*. München: Herbert Utz Verlag, 2018.
- [BHP12] Wiebe E. Bijker, Thomas Parke Hughes und Trevor Pinch, Hrsg. *The Social Construction of Technological Systems*. The MIT Press, 2012. ISBN: 978-0-262-51760-7.
- [Bir17] Alessandro Birolini. *Reliability Engineering*. 8. Aufl. Springer Berlin Heidelberg, 2017. ISBN: 978-3-662-54208-8.
- [BC09] Lucienne T.M. Blessing und Amaresh Chakrabarti. *DRM, a Design Research Methodology*. Springer-Verlag London Limited, 2009. ISBN: 978-1-84882-587-1.
- [Box+16] George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel und Greta M. Ljung. *Time Series Analysis: Forecasting and Control*. 5. Aufl. John Wiley & Sons. Inc., 2016. ISBN: 978-1-118-67502-1.

- [Bro+15] I. N. Bronshtein, K. A. Semendyayev, G. Musiol und H. Mühlig. *HANDBOOK OF MATHEMATICS*. 6. Aufl. Springer-Verlag, 2015.
- [FG13] Jörg Feldhusen und Karl-Heinrich Grote, Hrsg. *Pahl/Beitz Konstruktionslehre*. 8. Aufl. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. ISBN: 978-3-642-29568-3.
- [Fis71] Ronald A. Fisher. *The Design of Experiments*. 8. Aufl. Hafner Publishing Company Inc., 1971.
- [Goe+17] Kai Goebel, Matthew J. Daigle, Abhinav Saxena, Shankar Sankararaman, Indranil Roychoudhury und José Ramon Celaya. *Prognostics: The Science of Prediction*. 1. Aufl. CreateSpace Independent Publishing Platform, 2017. ISBN: 978-1-539-07483-0.
- [GBC16] Ian Goodfellow, Yoshua Bengio und Aaron Courville. *Deep Learning*. <http://www.deeplearningbook.org>. The MIT Press, 2016.
- [GMZ16] Rafael Gouriveau, Kamal Medjaher und Nouredine Zerhouni. *From Prognostics and Health Systems Management to Predictive Maintenance*. John Wiley & Sons, Ltd, 2016. ISBN: 9781848219380.
- [Hai06] Erwin Haibach. *Betriebsfestigkeit: Verfahren und Daten zur Bauteilberechnung*. 3. Aufl. Springer Berlin Heidelberg, 2006. ISBN: 978-3-540-29363-7.
- [HS20] Jürgen Hedderich und Lothar Sachs. *Angewandte Statistik Methodensammlung mit R*. Springer Berlin Heidelberg, 2020. ISBN: 978-3-662-62294-0.
- [Hel16] Hede Helfrich. *Wissenschaftstheorie für Betriebswirtschafter*. Springer Gabler, Wiesbaden, 2016. ISBN: 978-3-658-07035-9.
- [HA18] R.J. Hyndman und G. Athanasopoulos. *Forecasting: principles and practice*. 2. Aufl. OTexts, 2018. URL: <https://otexts.com/fpp2/> (besucht am 11. 09. 2020).
- [Joh+11] Stephen B. Johnson, Thomas J. Gormley, Seth S. Kessler, Charles D. Mott, Ann Patterson-Hine, Karl M. Reichard und Philip A. Scandura, Hrsg. *System Health Management: With Aerospace Applications*. John Wiley & Sons, Ltd, 2011. ISBN: 978-0-470-74133-7.
- [Kan11] Mehmed Kantardzic, Hrsg. *Data Mining: Concepts, Models, Methods, and Algorithms*. 2. Aufl. John Wiley & Sons, INC., 2011. ISBN: 978-1-118-02912-1.
- [KI19] Md. Rezaul Karim und M. Ataharul Islam. *Reliability and Survival Analysis*. Springer Nature Singapore Pte Ltd., 2019. ISBN: 978-9-811-39776-9.

-
- [KAC17] Nam-Ho Kim, Dawn An und Joo-Ho Choi. *Prognostics and Health Management of Engineering Systems*. Springer International Publishing, 2017. ISBN: 978-3-319-44742-1.
- [Kle18] Lawrence A. Klein. *Sensor and data fusion: A tool for information assessment and decision making*. 2. Aufl. SPIE - The International Society for Optical Engineering, 2018. ISBN: 9780819491343.
- [Kle20] Wilhelm Kleppmann. *Versuchsplanung - Produkte und Prozesse optimieren*. 10. Aufl. Carl Hanser Verlag, 2020. ISBN: 978-3-446-46397-4.
- [KF09] Daphne Koller und Nir Friedman. *Probabilistic Graphical Models: Principles and Techniques*. The MIT Press, 2009. ISBN: 978-0-262-01319-2.
- [Mar14] Leif Marxen. *A Framework for Design Support Development based on the integrated Product Engineering Model iPeM*. IPEK - Institut für Produktentwicklung, 2014.
- [ME98] W. Q. Meeker und L. A. Escobar, Hrsg. *Statistical Methods for Reliability Data*. John Wiley & Sons, INC., 1998. ISBN: 978-0-471-67327-9.
- [MR12] Peter Mertens und Susanne Rässler, Hrsg. *Prognoserechnung*. 7. Aufl. Physica-Verlag HD, 2012. ISBN: 978-3-790-82796-5.
- [MJ20] Hernán Miguel A. und Robins James M. *Causal Inference: What If*. CRC Press, 2020.
- [Mit97] Tom M. Mitchell. *Machine Learning*. McGraw-Hill, 1997, S. 432. ISBN: 0070428077.
- [Mur12] Kevin P. Murphy. *Machine Learning: A Probabilistic Perspective*. The MIT Press, 2012. ISBN: 978-0-262-01802-9.
- [Nau+19] Harald Naunheimer, Bernd Bertsche, Joachim Ryborz, Wolfgang Novak und Peter Fietkau. *Fahrzeuggetriebe: Grundlagen, Auswahl, Auslegung und Konstruktion*. 3. Aufl. Springer Vieweg, 2019. ISBN: 978-3-662-58883-3.
- [Pea09] Judea Pearl. *Causality*. 2. Aufl. 2009. ISBN: 9780511803161.
- [PGJ16] Judea Pearl, Madelyn Glymour und Nicholas P. Jewell. *Causal Inference in Statistics: A Primer*. John Wiley & Sons Ltd, 2016. ISBN: 978-1-119-18684-7.
- [PM18] Judea Pearl und Dana Mackenzie. *The Book of Why: The New Science of Cause and Effect*. 1. Aufl. New York, NY, USA: Basic Books, Inc., 2018. ISBN: 978-0-465-09760-9.
-

- [PK18] Michael G. Pecht und Myeongsu Kang. *Prognostics and Health Management of Electronics*. John Wiley & Sons, 2018. ISBN: 978-1-119-51532-6.
- [PJS17] Jonas Peters, Dominik Janzing und Bernhard Schoelkopf. *Elements of Causal Inference - Foundations and Learning Algorithms*. 1. Aufl. The MIT Press, 2017. ISBN: 9780262037310.
- [Ran11] Robert Bond Randall. *Vibration-based Condition Monitoring*. John Wiley & Sons, Ltd, 2011. ISBN: 978-0-470-97766-8.
- [Rei56] Hans Reichenbach. *The Direction of Time*. University of California Press, 1956.
- [RS18] Frank Rieg und Rolf Steinhilper, Hrsg. *Handbuch Konstruktion*. München: Carl Hanser Verlag GmbH & Co. KG, 2018. ISBN: 978-3-446-45619-8.
- [SHE18] Rainer Schnell, Paul B. Hill und Elke Esser. *Methoden der Empirischen Sozialforschung*. 11. Aufl. De Gruyter Oldenbourg, 2018. ISBN: 978-3-110-57732-7.
- [Wal15] Roland Waldi. *Statistische Datenanalyse*. Springer Berlin Heidelberg, 2015.
- [WW18] Lihui Wang und Xi Vincent Wang. *Cloud-Based Cyber-Physical Systems in Manufacturing*. 1. Aufl. Springer International Publishing, 2018. ISBN: 978-3-319-67693-7.
- [Wei06] Joachim Weimann. *Wirtschaftspolitik*. 4. Aufl. Springer-Verlag Berlin Heidelberg, 2006. ISBN: 978-3-540-28857-2.
- [Win16] Petra Winzer. *Generic Systems Engineering: Ein methodischer Ansatz zur Komplexitätsbewältigung*. 2. Aufl. Springer Fachmedien Wiesbaden, 2016. ISBN: 978-3-642-30364-7.

Weitere Quellen

- [AC15] Jose Ignacio Aizpurua und Victoria M Catterson. „Towards a Methodology for Design of Prognostic Systems“. In: *Proceedings of the Annual Conference of the Phm Society*. 2015. ISBN: 978-1-936-26320-2.
- [Alb+05] A. Albers, N. Burkhardt, M. Meboldt und M. Saak. „SPALTEN Problem Solving Methodology in the Product Development“. In: *Engineering Design and the Global Economy: 15th International Conference on Engineering Design - ICED 2005, Melbourne, 15. - 18. August 2005*. Hrsg.: A. Samuel. The Design Society, 2005. ISBN: 978-0-8582-5788-7.
- [Arj+19] Martin Arjovsky, Léon Bottou, Ishaan Gulrajani und David Lopez-Paz. „Invariant Risk Minimization“. In: (2019). URL: <http://arxiv.org/abs/1907.02893>.
- [ARP926C] *ARP926C: Fault/Failure Analysis Procedure*. SAE Society of Automotive Engineers. 2018.
- [BP16] Elias Bareinboim und Judea Pearl. „Causal inference and the data-fusion problem“. In: *Proceedings of the National Academy of Sciences of the United States of America* 113.27 (2016), S. 7345–7352. ISSN: 10916490.
- [BCV12] Yoshua Bengio, Aaron Courville und Pascal Vincent. „Representation Learning: A Review and New Perspectives“. In: (2012). URL: <http://arxiv.org/abs/1206.5538>.
- [CT10] Gavin C. Cawley und Nicola L. C. Talbot. „On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation“. In: *Journal of Machine Learning Research* 11 (2010), S. 2079–2107.
- [CBK09] Varun Chandola, Arindam Banerjee und Vipin Kumar. „Anomaly Detection : A Survey“. In: *ACM Computing Surveys* 41 (2009), 15:1–15:58.
- [Cob+12] *Prognostics and Health Management in Nuclear Power Plants: A Review of Technologies and Applications*. Jamie Baalis Coble, P. Ramuhalli, L. J. Bond, B. R. Upadhyaya und J. W. Hines. 2012.
- [Con18] Porsche Consulting. 2018. URL: https://www.porsche-consulting.com/fileadmin/docs/Startseite/News/tt1364/Automobil_Industrie_Maerz_2018.pdf (besucht am 08. 08. 2020).

- [Con19] Porsche Consulting. 2019. URL: https://www.porsche-consulting.com/fileadmin/docs/04_Medien/Publicationen/SRX03912_Anticipate_the_Future/Anticipate_the_Future_EN_C_Porsche_Consulting.pdf (besucht am 08.08.2020).
- [CRISP-DM] *Crisp-Dm 1.0*. Pete Chapman, Julian Clinton, Randy Kerber, Thomas Khabaza, Thomas Reinartz, Colin Shearer und Rudiger Wirth. 2000. ISBN: 9780769532677.
- [DAGitty] Johannes Textor, Benito van der Zander, Mark S. Gilthorpe, Maciej Liśkiewicz und George TH Ellison. „Robust causal inference using directed acyclic graphs: the R package ‘dagitty’“. In: *International Journal of Epidemiology* 45.6 (2017), S. 1887–1894. ISSN: 0300-5771. eprint: <https://academic.oup.com/ije/article-pdf/45/6/1887/11120744/dyw341.pdf>. URL: <https://doi.org/10.1093/ije/dyw341>.
- [DIN13379] *DIN ISO 13379-1:2018 - Zustandsüberwachung und -diagnostik von Maschinen – Verfahren zur Dateninterpretation und Diagnostik – Teil 1: Allgemeine Anleitungen*. DIN Deutsches Institut für Normung e.V. 2018.
- [DIN50126] *DIN EN 50126-1:2018 - Bahnanwendungen - Spezifikation und Nachweis von Zuverlässigkeit, Verfügbarkeit, Instandhaltbarkeit und Sicherheit (RAMS) - Teil 1: Generischer RAMS-Prozess; Deutsche Fassung EN 50126-1:2017*. DIN Deutsches Institut für Normung e.V. 2018.
- [DIN13306] *DIN EN 13306:2018 - Instandhaltung - Begriffe der Instandhaltung; Dreisprachige Fassung EN 13306:2017*. DIN Deutsches Institut für Normung e.V. 2018.
- [DIN60050] *DIN IEC 60050-351: Internationales Elektrotechnisches Wörterbuch – Teil 351: Leittechnik*. DIN Deutsches Institut für Normung e.V. 2016.
- [DIN17359] *DIN ISO 17359 - Zustandsüberwachung und -diagnostik von Maschinen – Allgemeine Anleitungen*. DIN Deutsches Institut für Normung e.V. 2018.
- [DIN60300-2] *DIN EN 60300-2: Zuverlässigkeitsmanagement -Teil 2: Leitfaden zum Zuverlässigkeitsmanagement*. DIN Deutsches Institut für Normung e.V. 2004.
- [DIN3990] *DIN ISO 3990: Tragfähigkeitsberechnung von Stirnrädern – Teil 2: Berechnung der Grübchentrugfähigkeit*. DIN Deutsches Institut für Normung e.V. 1987.

-
- [HWG17] Ramin M. Hasani, Guodong Wang und Radu Grosu. „An Automated Auto-encoder Correlation-based Health-Monitoring and Prognostic Method for Machine Bearings“. In: *arXiv* (2017). arXiv: 1703.06272. URL: <http://arxiv.org/abs/1703.06272>.
- [Hea16] Jeff Heaton. „An empirical analysis of feature engineering for predictive modeling“. In: *Conference Proceedings - IEEE SOUTHEASTCON* (2016). ISSN: 07347502. arXiv: 1701.07852.
- [HB17] Mark Henß und Bernd Bertsche. „Prognostics and Health Management (PHM) - Rahmen, Methodik und aktuelle Anwendungen“. In: *DVM - Zuverlässigkeit mechatronischer und adaptiver Systeme*. 2017.
- [HB19a] Mark Henß und Bernd Bertsche. „AutoEncoder basierte automatisierte Zustandsdiagnose von Wälzlagern“. In: *Tagung Technische Zuverlässigkeit 2019*. Bd. 2345. VDI, 2019. ISBN: 978-3-18-092345-1.
- [HZB17] Mark Henß, Peter Zeiler und Bernd Bertsche. „Framework for a Uniform Description of Prognostics and Health Management“. In: *Proceedings of the Asia-Pacific Conference of the Phm Society*. 2017.
- [Hu+12] Chao Hu, Byeng D. Youn, Pingfeng Wang und Joung Taek. „Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life“. In: *Reliability Engineering and System Safety* 103 (2012), S. 120–135.
- [HB19b] Paul Hünermund und Elias Bareinboim. „Causal Inference and Data-Fusion in Econometrics“. In: (2019). URL: <http://arxiv.org/abs/1912.09104>.
- [IEEE1856a] *IEEE Std 1856: Standard Framework for Prognostics and Health Management of Electronic Systems*. IEEE Institute of Electrical and Electronics Engineers. 2017. ISBN: 9781504443197.
- [ISO13381] *ISO 13381-1: Condition monitoring and diagnostics of machines — Prognostics — Part 1: General guidelines*. ISO International Organization for Standardization. 2015. ISBN: 2831886376.
- [KP14] Kailash C. Kapur und Michael Pecht. „Failure Modes, Mechanisms, and Effects Analysis“. In: *Reliability Engineering*. John Wiley & Sons, Ltd, 2014. Kap. 10, S. 193–206. ISBN: 978-1-118-84171-6.
-

- [KHO01] Marc C. Kennedy, Anthony O. Hagan und Anthony O'Hagan. „Bayesian calibration of computer models“. In: *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 63 (2001), S. 425–464. ISSN: 1369-7412.
- [Küç90] F. Küçükay. „Rechnergestützte Getriebedimensionierung mit repräsentativen Lastkollektiven“. In: *ATZ - Automobiltechnische Zeitschrift* 6.92 (1990), S. 328–333.
- [Lee+07] Jay Lee, H. Qiu, G. Yu, J. Lin und Rexnord Technical Services. *Bearing Data Set IMS, University of Cincinnati*. 2007. URL: <http://ti.arc.nasa.gov/project/prognostic-data-repository>.
- [LVC18a] Rui Li, Wim J. C. Verhagen und Richard Curran. „A Functional Architecture of Prognostics and Health Management using a Systems Engineering Approach“. In: *Proceedings of the European Conference of the Phm Society*. Vol 4 No 1. 2018.
- [Lop+17] David Lopez-Paz, Robert Nishihara, Soumith Chintala, Bernhard Schölkopf und Léon Bottou. „Discovering causal signals in images“. In: *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*. 2017. ISBN: 9781538604571.
- [LDF14] Ryan Lowe, Jacob Dodson und Jason Foley. „Microsecond Prognostics and Health Management“. In: *IEEE Reliability Society Newsletter* 60 (2) (2014).
- [MMS09] Oscar Marbán, Gonzalo Mariscal und Javier Segovia. „A Data Mining & Knowledge Discovery Process Model“. In: 2009. ISBN: 978-3-902613-53-0.
- [Moo+16] Joris M. Mooij, Jonas Peters, Dominik Janzing, Jakob Zscheischler und Bernhard Schölkopf. „Distinguishing Cause from Effect Using Observational Data: Methods and Benchmarks“. In: *Journal of Machine Learning Research* (2016).
- [NACE] *NACE Rev. 2 - Aufstellung der statistischen Systematik der Wirtschaftszweige in der Europäischen Gemeinschaft*. 2008. ISBN: 978-92-79-04740-4.
- [NTL05] Subhasis Nandi, Hamid A. Toliyat und Xiaodong Li. „Condition monitoring and fault diagnosis of electrical motors - A review“. In: *IEEE Transactions on Energy Conversion* 20 (2005). ISSN: 08858969.

- [Pia14] Gregory Piatetsky. 2014. URL: <https://www.kdnuggets.com%20https://www.kdnuggets.com/2014/10/crisp-dm-top-methodology-analytics-data-mining-data-science-projects.html> (besucht am 27.02.2018).
- [Qiu+06] Hai Qiu, Jay Lee, Jing Lin und Gang Yu. „Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics“. In: *Journal of Sound and Vibration* 289.4-5 (2006), S. 1066–1090. ISSN: 10958568.
- [RB15] Uwe-Kay Rakowsky und Bernd Bertsche. „Introducing Type 5 to prognostics and health management classification schemes“. In: *Safety and Reliability of Complex Engineered Systems: ESREL 2015*. Taylor & Francis Group, 2015. ISBN: 978-1-138-02879-1.
- [Sax10] Abhinav Saxena. „Prognostics: The Science of Prediction“. In: *Proceedings of the Annual Conference of the Phm Society*. 2010.
- [Sch72] Jaap Schijve. „The Accumulation of Fatigue Damage in Aircraft Materials and Structures“. In: *AGARD* (1972), S. 125.
- [Sch19] Bernhard Schölkopf. „Causality for Machine Learning“. In: *arXiv e-prints*, arXiv:1911.10500 (2019), arXiv:1911.10500. arXiv: 1911.10500 [cs.LG].
- [Sch+20] Günther Schuh, Reiner Anderl, Roman Dumitrescu, Antonio Krüger und Michael ten Hompel, Hrsg. *Industrie 4.0 Maturity Index. Die digitale Transformation von Unternehmen gestalten – UPDATE 2020*. 2020.
- [SCKT-LRN] F. Pedregosa et al. „Scikit-learn: Machine Learning in Python“. In: *Journal of Machine Learning Research* 12 (2011), S. 2825–2830.
- [Sto+13] M. Stohrer, Stefan Kemmler, Oliver Koller, Peter Zeiler und Bernd Bertsche. „Zuverlässigkeitsorientierte Online-Optimierung von Betriebsstrategien mechatronischer Produkte“. In: 2013. ISBN: 978-3-8396-0573-8.
- [TNSRFLW] Martin Abadi et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. Software available from tensorflow.org. 2015. URL: <https://www.tensorflow.org/>.
- [VGN16] George Vachtsevanos, George Georgoulas und George Nikolakopoulos. „Fault diagnosis, failure prognosis and fault tolerant control of aerospace/unmanned aerial systems“. In: *24th Mediterranean Conference on Control and Automation, MED 2016*. 2016. ISBN: 9781467383455.

- [VDA32] *VDA 3.2: Zuverlässigkeitssicherung bei Automobilherstellern und Lieferanten: Zuverlässigkeits-Methoden und -Hilfsmittel.* VDA Verband der Automobilindustrie e.V. 2016.
- [VDI3822] *VDI 3822: Schadensanalyse - Grundlagen und Durchführung einer Schadensanalyse.* VDI-Fachbereich Werkstofftechnik. 2011.
- [VDI2206] *VDI 2206: Entwicklungsmethodik für mechatronische Systeme.* VDI-Verein Deutscher Ingenieure. 2004.
- [VWD14] Gregory W. Vogl, Brian A. Weiss und M. Alkan Donmez. „Standards for Prognostics and Health Management (PHM) Techniques within Manufacturing Operations“. In: *Annual Conference of the Prognostics and Health Management Society* (2014), S. 1–13.
- [WYH12] Pingfeng Wang, Byeng D. Youn und Chao Hu. „A generic probabilistic framework for structural health prognostics and uncertainty management“. In: *Mechanical Systems and Signal Processing* 28 (2012), S. 622–637. ISSN: 0888-3270. URL: <http://dx.doi.org/10.1016/j.ymssp.2011.10.019>.

Betreute Studentische Arbeiten

- [Beg18] Armin Begic. „Implementierung von (physikalischem) Vorwissen in Support Vector Machines im Kontext Prognostics and Health Management“. Masterarbeit. 2018.
- [Brä19] Oliver Brändle. „Parameterstudie zur Optimierung der Hyperparameter eines AutoEncoder“. Studienarbeit. 2019.
- [Bre18] Simon Breunig. „Prognose der nutzbaren Restlebensdauer von Mantelstromtriebwerken und Entwicklung einer Methode zur Anwendung des maschinellen Lernens im Bereich PHM“. Studienarbeit. 2018.
- [Dur18] Camilo Durán. „Methodische Clusterung und statistische Auswertung des State of the Art und aktueller Trends im Fachbereich Prognostics and Health Management“. Bachelorarbeit. 2018.
- [Hen18] Claudia Henzler. „Konzepte zur Implementierung des Prognostics and Health Management in den Entwicklungsprozess“. Studienarbeit. 2018.
- [Hit17] Hannes Hitzer. „Analyse von Prognosemodellen im Kontext Prognostics and Health Management (PHM)“. Masterarbeit. 2017.
- [Käs16] Andreas Käs. „Feldanalyse der Wirksamkeit der Kupplungsschutzfunktion“. Masterarbeit. 2016.
- [Lai20] Po Yuan Lai. „Methodisches Clustering von Anwendungsart innerhalb des Prognostics and Health Management“. Studienarbeit. 2020.
- [Läm19] Sven Lämmle. „Zustandsdiagnose auf der Basis multivariater Felddaten unter Verwendung von Algorithmen aus dem Maschinellen Lernen“. Masterarbeit. 2019.
- [Men19] Oliver Menges. „Ausfalldiagnose auf Basis von Betriebsdaten unter Verwendung von Künstlichen Neuronalen Netzen – Fallbeispiel Drehgestell“. Bachelorarbeit. 2019.
- [Mo19] Qu Mo. „Prozessstabilisierung in der Serienfertigung elektrischer Antriebe mittels Data Analytics“. Masterarbeit. 2019.
- [Na20] Dae Yeop Na. „Applikation und Optimierung von Reinforcement Learning zur Lebensdauererlängerung an Zahnrädern“. Masterarbeit. 2020.
- [Pos20] Maximilian Posner. „Entwicklung eines Reinforcement Learning Algorithmus zur Lebensdauererlängerung von Zahnrädern“. Bachelorarbeit. 2020.

- [Pre17] Nadine Preuninger. „Ansätze zur Beschreibung der Verlässlichkeit (RAMSS) technischer Systeme“. Masterarbeit. 2017.
- [Reb18] Alexander Rebstock. „Methodik zur Identifikation und Quantifizierung von Unsicherheiten in PHM – Systemen“. Studienarbeit. 2018.
- [She18] Minhao Shen. „Methodische Clusterung von Anwendungsarten innerhalb des Prognostics and Health Management“. Bachelorarbeit. 2018.
- [Son19] Liwen Song. „Methodische Kategorisierung von PHM-Anwendungen mit Fokus auf dem Health Management“. Studienarbeit. 2019.
- [Sor17] Maxime Sorgenfrei. „Analyse der Sensitivität einzelner Parameter auf die Ermittlung von Lastkollektiven für Nutzfahrzeuggremien“. Studienarbeit. 2017.
- [Stä16] Christian Stäbler. „Ausfallprognose auf Basis von Felddaten bei Elektrowerkzeugen“. Masterarbeit. 2016.
- [Tas18] Murat Tas. „Anomaliedetektion in Pendelrollenlagern unter dem Einsatz von Signalverarbeitungstechniken und maschinellem Lernen“. Studienarbeit. 2018.
- [Wal18] Alexander Walter. „Implementierung von Vorwissen in neuronale Netze im Kontext von Prognostics and Health Management“. Masterarbeit. 2018.
- [Wen19] Daniel Weng. „Methodik zur Analyse und Berücksichtigung zukünftiger Belastungen in Ausfallprognosen“. Masterarbeit. 2019.
- [Yin17] Peichao Yin. „Implementierung des Stress-Strength-Interference in MATLAB“. Studienarbeit. 2017.
- [Zho20] Xiaoqi Zhou. „Detektion von Fehlern auf Dichtungsgegenläufigkeiten mittels Deep Learning“. Masterarbeit. 2020.

Anhang A

Quellen Metaanalyse

A.1 Merkmale

Die Quellen der Metaanalyse werden hinsichtlich der folgenden Merkmale bewertet:

- Metadaten: Lfd.-Nr., Quelle, Titel, Autor, Link, Jahr, Programmiersprache
- Technisches System: Anwendungsgebiet, Kategorie, Umfeld, System, Baugruppe, Bauelement
- Systemmodell: Systemmodell
- Schaden (nach [VDI3822]): Schadensphänomen, Schadensstelle, Schädigungsmechanismus, Beschreibung, Belastungsart, Belastungsgröße, Degradationsmodell
- Daten: Datenherkunft, Sensorklasse, Sensorspezifikation, Sensor Position, Rohdaten, Daten Algorithmus, Merkmal (Feature)
- Prognostics: Prognostics Ziel, Prognostics Konzept, Prognostics Algorithmus, Unsicherheiten, Prognostics Modell, Evaluationsmetriken
- Health Management: Health Management Ziel, Health Management Algorithmus, Health Management Modell

A.2 Quellen

Die Liste der folgenden Quellen wird unter der Referenz [MAP19] zusammengefasst.

- [ABC18] Lall A. Pradeep, Zhang B. Hao und Lall C. Rahul. *PHM of State-of-Charge for Flexible Power Sources in Wearable Electronics with EKF*. *IEEE Xplore*. 2018.
- [Aba+18] Alessandro Abate, Carlos E. Budde, Nathalie Cauchi, Khaza Anuarul Hoque und Mariëlle Stoelinga. *Assessment of Maintenance Policies for Smart Buildings: Application of Formal Methods to Fault Maintenance Trees*. *International Journal Of Prognostics and Health Management*. 2018.
- [AB16] Alaa Abdulhady Jaber und Robert Bicker. *Fault Diagnosis of Industrial Robot Bearings Based on Discrete Wavelet Transform and Artificial Neural Network*. *International Journal Of Prognostics and Health Management*. 2016.
- [AOM17] David Acuna, Orchard und Marcos. *Prognostic Algorithms Design Based on Predictive Bayesian Cramér-Rao Lower Bounds*. *ScienceDirect*. 2017.
- [Agg+17] T. Aggab, F. Kratz, P. Vignat und M. Avila. *An Approach for Assessment of Level of Degradation and RUL Estimation for a dynamic systeme*. *IEEE Xplore*. 2017.
- [Ahm+18] Wasim Ahmad, Sheraz Ali Khan, M. M. Manjurul Islam und Jong-Myon Kim. *A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models*. *ScienceDirect*. 2018.
- [AAK18] Wasim Ahmad, Sheraz Ali Khan und Jong-Myon Kim. *A Hybrid Prognostics Technique for Rolling Element Bearings Using Adaptive Predictive Models*. *IEEE Xplore*. 2018.
- [AGC17] P. Aivaliotis, K. Georgoulas und G. Chryssolouris. *A RUL Calculation Approach Based on Physicalbased Simulation Models for Predictive Maintenance*. *IEEE Xplore*. 2017.
- [AC18] Attahir Aliyu und Alberto Castellazzi. *Prognostic System for Power Modules in Converter Systems Using Structure Function*. *IEEE Xplore*. 2018.
- [An17] T. An. *Study on the State Prediction of Electronic Device Based on the BP Neural Network of Genetic Algorithm*. *IEEE Xplore*. 2017.

- [Arr+18] Mikel Arrinda, Mikel Oyarbide, Haritz Macicidor und Eñaut Muxika. *Comparison of Stochastic Capacity Estimation Tools Applied on Remaining Useful Life Prognosis of Lithium Ion Batteries. International Journal Of Prognostics and Health Management.* 2018.
- [Asa+18] S. M. Asadzadeh, R. Galeazzi, E. Hovad, J. F. Andersen, C. Thyregod und A. F. S. Rodrigues. *Ballast Degradation Modeling for Turnouts based on Track Recording Car Data. International Journal Of Prognostics and Health Management.* 2018.
- [AS18] Masoud Asgarpour und John Sørensen. *Bayesian based Prognostic Model for Predictive Maintenance of Offshore Wind Farms. International Journal Of Prognostics and Health Management.* 2018.
- [AC17] Vepa Atamuradov und Fatih Camci. *Segmentation Based Feature Evaluation and Fusion for Prognostics. International Journal Of Prognostics and Health Management.* 2017.
- [AZM16] Remus Avram, Xiaodong Zhang und Jonathan Muse. *Quadrotor Accelerometer and Gyroscope Sensor Fault Diagnosis Using Non-linear Adaptive Estimation Methods. International Journal Of Prognostics and Health Management.* 2016.
- [AH17] S.A. Aye und P.S. Heyns. *An integrated Gaussian process regression for prediction of remaining useful life of slow speed bearings based on acoustic emission. ScienceDirect.* 2017.
- [Bai+17] X. Bai, W. Wang, X. Jia und G. Wang. *Health Status Monitor of Aerospace Payload Based on Neural Network and Fuzzy Classification. IEEE Xplore.* 2017.
- [BP18] P. Bangalore und M. Patriksson. *Analysis of SCADA data for early fault detection, with application to the maintenance management of wind turbines. ScienceDirect.* 2018.
- [Bap+18] Marcia Baptista, Elsa M.P. Henriques, Ivo P. de Medeiros, Joao P. Malere, Cairo L. Nascimento Jr. und Helmut Prendinger. *Remaining useful life estimation in aeronautics: Combining data-driven and Kalman filtering. ScienceDirect.* 2018.
- [BBZ18] P. Baraldi, G. Bonfanti und E. Zio. *Differential evolution-based multi-objective optimization for the definition of a health indicator for fault diagnostics and prognostics. ScienceDirect.* 2018.
- [Bar+15] Federico Barbieri, J. Wesley Hines, Michael Sharp und Mauro Venturini. *Sensor-Based Degradation Prediction and Prognostics for Remaining Useful Life Estimation: Validation on Experimental Data of Electric Motors. International Journal Of Prognostics and Health Management.* 2015.

- [Bat+14] Todd D. Batzel, Jeffrey Banks, Kevin Cunningham und Scott Harris. *Prognostic Health Management of the DC Starter/Generator*. *Prognostics Journal*. 2014.
- [BAB17] M. Behzad, H. Arghan und A. Bastami. *Prognostics of Rolling Element Bearings with the Combination of Paris Law and Reliability Method*. *IEEE Xplore*. 2017.
- [Bla+18] Olivier Blancke, Amélie Combette, Normand Amyot, Dragan Komljenovic, Mélanie Lévesque, Claude Hudon, Antoine Tahan und Noureddine Zerhouni. *A Predictive Maintenance Approach for Complex Equipment Based on Petri Net Failure Mechanism Propagation Model*. *International Journal Of Prognostics and Health Management*. 2018.
- [Bos18] M. J. Bos. *A Viable Opportunity for Fielding an Aircraft Structural Health Monitoring System*. *International Journal Of Prognostics and Health Management*. 2018.
- [Boš+17] P. Boškovski, B. Dolenc, B. Musizza und D. Juričić. *Model-based prediction of the remaining useful life of the machines*. *ScienceDirect*. 2017.
- [Bou+17] Z. Bouzidi, L. Terrissa, A. Lahmadi, N. Zerhouni und S. Ayad. *The performance measure of a data driven prognostic system: Application to an aircraft engine*. *IEEE Xplore*. 2017.
- [BL15] Nicola Bowler und Shuaishuai Liu. *Aging Mechanisms and Monitoring of Cable Polymers*. *International Journal Of Prognostics and Health Management*. 2015.
- [BT18] Jan Braaksma und Wieger Tiddens. *Selecting Suitable Candidates for Predictive Maintenance*. *International Journal Of Prognostics and Health Management*. 2018.
- [Cad+11] Francesco Cadini, Claudio Sbarufatti, Francesco Cancelliere und Marco Giglio. *A Data-Driven Particle Filter For Lithium-Ion Batteries State-Of-Life Prognosis*. *International Journal Of Prognostics and Health Management*. 2011.
- [CM16] Guowei Cai und Sankaran Mahadevan. *Big Data Analytics in Online Structural Health Monitoring*. *International Journal Of Prognostics and Health Management*. 2016.
- [CFZ17] Yang Chang, Huajing Fang und Yong Zhang. *A new hybrid method for the prediction of the remaining useful life of a lithium-ion battery*. *ScienceDirect*. 2017.

- [Cha+18] HU Changhua, PEI Hong, WANG Zhaoqiang, SI Xiaosheng und ZHANG Zhengxin. *A new remaining useful life estimation method for equipment subjected to intervention of imperfect maintenance activities*. *ScienceDirect*. 2018.
- [Che+17a] C. Chen, X. Ye, H. Wang, G. Zhai und R. Wan. *In-situ Prognostic Method of Power MOSFET Based on Miller Effect*. *IEEE Xplore*. 2017.
- [CCZ16] G. Chen, J. Chen und Y. Zi. *A GKPCA-NHSMM Based Methodology for Accurate RUL Prognostics of Nonlinear Mechanical System with Multistate Deterioration*. *IEEE Xplore*. 2016.
- [Che+17b] Gaige Chen, Jinglong Chen, Yanyang Zi und Huihui Miao. *Hyperparameter optimization based nonlinear multistate deterioration modeling for deterioration level assessment and remaining useful life prognostics*. *ScienceDirect*. 2017.
- [Che+16] H. Chen, W. Zhang, J. Shi und K. Jiang. *Research on Health Assessment Method for Power Supply Element of Avionics Electronic**. *IEEE Xplore*. 2016.
- [CQQ18] Fangzhou Cheng, Liyan Qu und Wie Qiao. *Fault Prognosis and Remaining Useful Life Prediction of Wind Turbine Gearboxes Using Current Signal Analysis*. *IEEE Xplore*. 2018.
- [Chi+18] Juan Chiachío, Manuel Chiachío, Darren Prescott und John Andrews. *A Bayesian assessment for railway track geometry degradation prognostics*. *International Journal Of Prognostics and Health Management*. 2018.
- [CAB17a] Benjamin Y. Choo, Stephen Adams und Peter Beling. *Health-Aware Hierarchical Control for Smart Manufacturing using Reinforcement Learning*. *IEEE Xplore*. 2017.
- [Cob+15] Jamie Coble, Pradeep Ramuhalli, Leonard Bond, J. Wesley Hines und Belle Upadhyaya. *A Review of Prognostics and Health Management Applications in Nuclear Power Plants*. *International Journal Of Prognostics and Health Management*. 2015.
- [CAB17b] Tyler Cody, Stephen Adams und Peter A Beling. *Unsupervised Deep Learning for Gear Health Monitoring*. *International Journal Of Prognostics and Health Management*. 2017.
- [Con+18] Paddy Conroy, Jacek Stecki, Joshua Bautista und Alex Ringeri. *Applications of Artificial Intelligence and Decision-Making Methods in PHM*. *International Journal Of Prognostics and Health Management*. 2018.

- [Cor+18a] Matteo Corbetta, Claudio Sbarufatti, Marco Giglio, Abhinav Saxena und Kai Goebel. *A Bayesian framework for fatigue life prediction of composite laminates under co-existing matrix cracks and delamination. ScienceDirect.* 2018.
- [Cor+18b] Matteo Corbetta, Claudio Sbarufatti, Marco Giglio und Michael D. Todd. *Optimization of nonlinear, non-Gaussian Bayesian filtering for diagnosis and prognosis of monotonic degradation processes. ScienceDirect.* 2018.
- [DJV17] Andrea De Martin, Giovanni Jacazio und George Vachtsevanos. *Windings Fault Detection and Prognosis in Electro-Mechanical Flight Control Actuators Operating in Active-Active Configuration. International Journal Of Prognostics and Health Management.* 2017.
- [DH17] Jason Deutsch und David He. *Using Deep Learning-Based Approach to Predict Remaining Useful Life of Rotating Components. IEEE Xplore.* 2017.
- [DJL17] Yuan Di, Xiaodong Jia und Jay Lee. *Enhanced Virtual Metrology on Chemical Mechanical Planarization Process using an Integrated Model and Data-Driven Approach. International Journal Of Prognostics and Health Management.* 2017.
- [DBS18] M.A. Djeziri, S. Benmoussa und R. Sanchez. *Hybrid method for remaining useful life prediction in wind turbine systems. ScienceDirect.* 2018.
- [Dol+17] B. Dolenc, P. Boškoski, M. Stepančič, A. Pohjoranta und Đ. Juričić. *State of health estimation and remaining useful life prediction of solid oxide fuel cell stack. ScienceDirect.* 2017.
- [DLS17] D. Dong, X. Li und F. Sun. *Life Prediction of Jet Engines Based on LSTMRecurrent Neural Networks. IEEE Xplore.* 2017.
- [Don+18] G. Dong, Z. Chen, J. Wie und Q. Ling. *Battery Health Prognosis Using Brownian Motion Modeling and Particle Filtering. IEEE Xplore.* 2018.
- [DCZ17] P. Dong, J. Cai und L. Zhang. *Residual Life prediction of Aviation APU Based on PH Model. IEEE Xplore.* 2017.
- [Du+16] D. Du, C. Hu, X. Si, Z. Zhang und W. Zhang. *An Improved Remaining Useful Life Prediction Method for System with Volatile Degradation Path. IEEE Xplore.* 2016.
- [DWM17] Ying Du, Tonghai Wu und Viliam Makis. *Parameter estimation and remaining useful life prediction of lubricating oil with HMM. ScienceDirect.* 2017.

- [EE16] David E. Acuñañ und Marcos E. Orchard. *Particle-filtering-based failure prognosis via sigma-points: Application to Lithium-Ion battery State-of-Charge monitoring*. ScienceDirect. 2016.
- [El +18] Asmae El Mejdoubi, Hicham Chaoui, Jalal Sabor und Hamid Gualous. *Remaining Useful Life Prognosis of Supercapacitors Under Temperature and Voltage Aging Conditions*. IEEE Xplore. 2018.
- [Ela+17] Faris Elasha, David Mba, Michael Togneri, Ian Masters und Joao Amaral Teixeira. *A hybrid prognostic methodology for tidal turbine gearboxes*. ScienceDirect. 2017.
- [Eli+18] Källström Elisabeth, Tomas Olsson, John Lindstr und Hakansson Lars. *On-board Clutch Slippage Detection and Diagnosis in Heavy Duty Machine*. International Journal Of Prognostics and Health Management. 2018.
- [FLY17] Y. Fang, D. Liu und L. Yu. *Remaining useful life prognostic of three-shaft gas turbine based on the low-pressure turbine outlet temperature*. IEEE Xplore. 2017.
- [GGK17] Jeet Gandhi, R. Gopinath und C. Santhosh Kumar. *System Independent Fault Diagnosis for Synchronous Generator*. International Journal Of Prognostics and Health Management. 2017.
- [Gao+16] J. Gao, H. Shi, H. Fang, K. Luo und S. Liu. *The Design of the Prognostics and Health Management System for Special Vehicle*. IEEE Xplore. 2016.
- [Gao+18] Xiaojing Gao, Octavian Niculita, Babakalli Alkali und Don Mcglinchey. *Cost benefit analysis of applying PHM for Subsea Applications*. International Journal Of Prognostics and Health Management. 2018.
- [Gao+17] Z. Gao, C. Ma, Y. Li, G. Xu und Y. Luo. *An IMA degradation model with intermittent faults for RUL prediction*. IEEE Xplore. 2017.
- [Geb+18] Owen Freeman Gebler, Ben Hicks, Jason Yon und Matt Barker. *Characterising Conveyor Belt System Usage from Drive Motor Power Consumption and Rotational Speed : A Feasibility Study*. International Journal Of Prognostics and Health Management. 2018.
- [GT17] Elaheh Gholamzadeh Nabatia und Klaus-Dieter Thoben. *Data Driven Decision Making in Planning the Maintenance Activities of Off-shore Wind Energy*. ScienceDirect. 2017.

- [Gug+18] Narendhar Gugulothu, Vishnu TV, Pankaj Malhotra, Lovekesh Vig, Puneet Agarwal und Gautam Shroff. *Predicting Remaining Useful Life using Time Series Embeddings based on Recurrent Neural Networks. International Journal Of Prognostics and Health Management.* 2018.
- [GLB17] Ram B. Gurung, Tony Lindgren und Henrik Boström. *Predicting NOx sensor failure in heavy duty trucks using histogram-based random forests. International Journal Of Prognostics and Health Management.* 2017.
- [Guz+18] Daniela Narezo Guzman, Edin Hadzic, Robert Schuil, Eric Baars und Jörn Christoffer Groos. *Data-driven condition now- and forecasting of railway switches for improvement in the quality of railway transportation. International Journal Of Prognostics and Health Management.* 2018.
- [HLM18] Houman HANACHI, Jie LIU und Christopher MECHEFSKE. *Multi-mode diagnosis of a gas turbine engine using an adaptive neuro-fuzzy system. ScienceDirect.* 2018.
- [HCB18] Moinul Shahidul Haque, Seungdeog Choi und Jeihoon Baek. *Auxiliary Particle Filtering-Based Estimation of Remaining Useful Life of IGBT. IEEE Xplore.* 2018.
- [HBL18] Yoann Hebrard, Guillaume Bastard und Tony Lhommeau. *A Wireless and autonomous sensor for Integrated Engine Health Management. International Journal Of Prognostics and Health Management.* 2018.
- [Hei+18] Roohollah Heidary, Steven A. Gabriel, Mohammad Modarres, Katrina M. Groth und Nader Vahdati. *A Review of Data-Driven Oil and Gas Pipeline Pitting Corrosion Growth Models Applicable for Prognostic and Health Management. International Journal Of Prognostics and Health Management.* 2018.
- [Hil+18] Jacob L. Hill, Paul W. Prickett, Roger I. Grosvenor und Gareth Hankins. *CNC Spindle Signal Investigation for the Prediction of Cutting Tool Health. International Journal Of Prognostics and Health Management.* 2018.
- [HT18] Ahmed Zakariae Hinch und Mohamed Tkiouat. *A multi-task deep learning model for rolling element-bearing diagnostics. International Journal Of Prognostics and Health Management.* 2018.

- [Hog+18] Edward F. Hogge, Brian M. Bole, Sixto L. Vazquez, Chetan S. Kulkarni, Thomas H. Strom, Boyd L. Hill, Kyle M. Smalling und Cuong C. Quach. *Verification of Prognostic Algorithms to Predict Remaining Flying Time for Electric Unmanned Vehicles*. *International Journal Of Prognostics and Health Management*. 2018.
- [Hos+18] Michael Hosseini, Joseph Helm, Bruce Stephen und Stephen D. J. Mcarthur. *Automated Feature Validation of Trip Coil Analysis in Condition Monitoring of Circuit Breakers*. *International Journal Of Prognostics and Health Management*. 2018.
- [Hu+18a] Chao Hu, Hui Ye, Gaurav Jain und Craig Schmidt. *Remaining useful life assessment of lithium-ion batteries in implantable medical devices*. *ScienceDirect*. 2018.
- [HC17] Q. Hu und F. Chu. *Study on Prognosis and Health Management For the Liquid tank*. *IEEE Xplore*. 2017.
- [Hu+14] Yang Hu, Piero Baraldi, Francesco Di Maio und Enrico Zio. *A Prognostic Approach Based on Particle Filtering and Optimized Tuning Kernel Smoothing*. *International Journal Of Prognostics and Health Management*. 2014.
- [Hu+18b] Yaogang Hu, Hui Li, Pingping Shi, Zhaosen Chai, Kun Wang, Xiangjie Xie und Zhe Chen. *A prediction method for the real-time remaining useful life of wind turbine bearings based on the Wiener process*. *ScienceDirect*. 2018.
- [Hua+17a] Qiang Huang, Guigang Zhang, Ting Zhang und Jian Wang. *A Kind of Approach for Aero Engine Gas Path Fault Diagnosis*. *IEEE Xplore*. 2017.
- [Hua+18] T. Huang, C. Liu, A. Sharma und S. Sarkar. *Traffic System Anomaly Detection using Spatiotemporal Pattern Networks*. *International Journal Of Prognostics and Health Management*. 2018.
- [Hua+17b] Zeyi Huang, Zhengguo Xu, Xiaojie Ke, Wenhai Wang und Youxian Sun. *Remaining useful life prediction for an adaptive skew-Wiener process model*. *ScienceDirect*. 2017.
- [Hus+18] Yameen M. Hussain, Stephen Burrow, Leigh Henson und Patrick Keogh. *A High Fidelity Model Based Approach to Identify Dynamic Friction in Electromechanical Actuator Ballscrews using Motor Current*. *International Journal Of Prognostics and Health Management*. 2018.
- [IMR17] Elinirina I. Robinson, Julien Marzat und Tarek Raissi. *Model-based prognosis using an explicit degradation model and Inverse FORM for uncertainty propagation*. *ScienceDirect*. 2017.

- [Ian+18] Matteo Iannitelli, Carmine Allegorico, Francesco Garau und Marco Capanni. *A Hybrid Model for on-line Detection of Gas Turbine Lean Blowout Events. International Journal Of Prognostics and Health Management.* 2018.
- [JS15] R. Jegadeeshwaran und V. Sugumaran. *Health Monitoring of a Hydraulic Brake System Using Nested Dichotomy Classifier – A Machine Learning approach. International Journal Of Prognostics and Health Management.* 2015.
- [JSR16] Devesh K. Jha, Abhishek Srivastav und Asok Ray. *Temporal Learning in Video Data Using Deep Learning and Gaussian Processes. International Journal Of Prognostics and Health Management.* 2016.
- [Jia+18] Xiaodong Jia, Chao Jin, Matt Buzza, Yuan Di, David Siegel und Jay Lee. *A deviation based assessment methodology for multiple machine health patterns classification and fault detection. Science-Direct.* 2018.
- [JZH17] X. Jiang, X. Zhao und S. Hu. *A PHM system for bridge monitoring on high speed railway. IEEE Xplore.* 2017.
- [Jia+17a] X. Jiao, B. Jing, Y. Huang, J. Li, G. Xu und M. Sun. *Remaining Useful Life Prediction for Airborne Fuel Pump Based on AR and Particle Filter. IEEE Xplore.* 2017.
- [Jia+17b] Xiaoxuan Jiao, Bo Jing, Yifeng Huang, Juan Li und Guangyue Xu. *Research on fault diagnosis of airborne fuel pump based on EMD and probabilistic neural networks. ScienceDirect.* 2017.
- [Jin+14a] Chao Jin, Agusmian P. Ompusunggu, Zongchang Liu, Hossein Davary Ardakani, Fredrik Petre und Jay Lee. *A Vibration-Based Approach for Stator Winding Fault Diagnosis of Induction Motors: Application of Envelope Analysis. International Journal Of Prognostics and Health Management.* 2014.
- [Jin+14b] Rong Jing, Zhimin Xi, Xiao Guang Yang und Ed Decker. *A Systematic Framework for Battery Performance Estimation Considering Model and Parameter Uncertainties. International Journal Of Prognostics and Health Management.* 2014.
- [Jin+17a] Hu Jinqiu, Zhang Laibin, Tian Wenhui und Zhou Shuai. *DBN based failure prognosis method considering the response of protective layers for the complex industrial systems. ScienceDirect.* 2017.

- [Jin+17b] Bao Jinsong, Guangchao Yuan, Zheng Xiaohu, Zhang Jianguo und Ji Xia. *A Data Driven Model for Predicting Tool Health Condition in High Speed Milling of Titanium Plates Using Real-Time SCADA*. *ScienceDirect*. 2017.
- [Jin+18] Lee Jinwoo, Kwon Daeil, Kim Namhun und Lee Changyong. *PHM-based wiring system damage estimation for near zero downtime in manufacturing facilities*. *ScienceDirect*. 2018.
- [Jue+16] Pablo Juesas, Emmanuel Ramasso, Vincent Placet und Rue Alain Savary. *On partially supervised learning and inference in dynamic Bayesian networks for prognostics with uncertain factual evidence: Illustration with Markov switching models*. *International Journal Of Prognostics and Health Management*. 2016.
- [KAM17] V.A. Kalmakov, A.A. Andreev und A.S. Martyanov. *Remaining Vehicles Useful Lifetime Estimation Based on Operation Conditions Measurement*. *ScienceDirect*. 2017.
- [KM16] Azadeh Keshtgar und Mohammad Modarres. *Probabilistic Approach for Nondestructive Detection of Fatigue Crack Initiation and Sizing*. *International Journal Of Prognostics and Health Management*. 2016.
- [KA18] Neeraj Kheraa und Shakeb A. Khan. *Prognostics of aluminum electrolytic capacitors using artificial neural network approach*. *ScienceDirect*. 2018.
- [KKH17] Hyeonmin Kim, Jung Taek Kim und Gyunyoung Heo. *Prognostics for integrity of steam generator tubes using the general path model*. *ScienceDirect*. 2017.
- [Kir+16] S. Kirillov, A. Kirillov, V. Iakimkin, A. Khodos, Y. Kaganovich und M. Pecht. *PHM Applications in Medicine and Medical Implantable Devices*. *IEEE Xplore*. 2016.
- [Kor+15] M. Kordestani, M. Foad Samadi, M. Saif und K. Khorasani. *Fault Prognosis of Multi-Function Spoiler (MFS) System Using Integrated Extended Kalman Filter and Bayesian Method*. *IEEE Xplore*. 2015.
- [KCM18] Sofia Koukoura, James Carroll und Alasdair Mcdonald. *An Insight into Wind Turbine Planet Bearing Fault Prediction Using SCADA Data*. *International Journal Of Prognostics and Health Management*. 2018.

- [KRR18] P. Krishnakumar, K. Rameshkumar und K. I. Ramachandran. *Feature level fusion of vibration and acoustic emission signals in tool condition monitoring using machine learning classifiers. International Journal Of Prognostics and Health Management*. 2018.
- [Kul+17] Chetan S. Kulkarni, Matthew J. Daigle, George Gorospe und Kai Goebel. *Experimental Validation of Model-Based Prognostics for Pneumatic Valves. International Journal Of Prognostics and Health Management*. 2017.
- [KSN15] T. Ch. Anil Kumar, Gurmeet Singh und V. N. A. Naikan. *Effectiveness of vibration monitoring in the health assessment of induction motor. International Journal Of Prognostics and Health Management*. 2015.
- [Lad+17] S. Laddada, T. Benkedjouh, M. Si-Chaib und R. Draï. *A data-driven prognostic approach based on wavelet transform and extreme learning machine. IEEE Xplore*. 2017.
- [LZL18] A. Lall, B. Zhang und C. Lall. *PHM of State-of-Charge for Flexible Power Sources in Wearable Electronics with EKF. IEEE Xplore*. 2018.
- [Lal+18] Thomas Laloix, Hai Canh Vu, Alexandre Voisin, Eric Romagne und Benoît Iung. *A priori indicator identification to support predictive maintenance: application to machine tool. International Journal Of Prognostics and Health Management*. 2018.
- [LMM14] Benjamin Lamoureux, Jean-Remi Masse und Nazih Mechbal. *Improving Aircraft Engines Prognostics and HealthManagement via AnticipatedModel-Based Validation of Health Indicators. Prognostics Journal*. 2014.
- [Lea+18] Kevin Leahy, R. Lily Hu, Ioannis C. Konstantakopoulos, Costas J. Spanos, Alice M. Agogino und Dominic T.J. O’Sullivan. *Diagnosing and Predicting Wind Turbine Faults from SCADA Data Using Support Vector Machines. International Journal Of Prognostics and Health Management*. 2018.
- [LK18] Changyong Lee und Daeil Kwon. *A similarity based prognostics approach for real time health management of electronics using impedance analysis and SVM regression. ScienceDirect*. 2018.
- [LL18] Jae-cheon Lee und Hao Liu. *Development of a Real-Time Driver Health Detection System Using a Smart Steering Wheel. International Journal Of Prognostics and Health Management*. 2018.

- [Lee17] Wan-Jui Lee. *Anomaly Detection and Severity Prediction of Air Leakage in Train Braking Pipes. International Journal Of Prognostics and Health Management*. 2017.
- [Lei+17] Yaguo Lei, Naipeng Li, Liang Guo, Ningbo Li, Tao Yan und Jing Lin. *Machinery health prognostics: A systematic review from data acquisition to RUL prediction. ScienceDirect*. 2017.
- [Lei+18] Yaguo Lei, Naipeng Li, Liang Guo, Ningbo Li, Tao Yan und Jing Lin. *Machinery health prognostics: A systematic review from data acquisition to RUL prediction. ScienceDirect*. 2018.
- [LCT17] Giacomo Leone, Loredana Cristaldi und Simone Turrin. *A data-driven prognostic approach based on statistical similarity: An application to industrial circuit breakers. ScienceDirect*. 2017.
- [LW17] H. Li und Y. Wang. *A sparse coding approach to RUL prediction in rolling bearing. IEEE Xplore*. 2017.
- [Li+18a] Pin Li, Xiaodong Jia, Jianshe Feng, Hossein Davari, Guan Qiao, Yihchyun Hwang und Jay Lee. *Prognosability study of ball screw degradation using systematic methodology. ScienceDirect*. 2018.
- [LP17a] Q. Li und X. Peng. *Application of Large-Data-Driven PHM Technology in Satellite Test and On-orbit Management. IEEE Xplore*. 2017.
- [LP17b] Qinyi Li und Xin Peng. *Application of Large-Data-Driven PHM Technology in Satellite Test and On-orbit Management. IEEE Xplore*. 2017.
- [LVC18b] Rui Li, Wim J. C. Verhagen und Richard Curran. *A Functional Architecture of Prognostics and Health Management using a Systems Engineering Approach. International Journal Of Prognostics and Health Management*. 2018.
- [LI+17] Tongyang LI, Shaoping WANG, Jian SHI und Zhonghai MA. *An adaptive-order particle filter for remaining useful life prediction of aviation piston pumps. ScienceDirect*. 2017.
- [LDS18] Xiang Li, Qian Ding und Jian-Qiao Sun. *Remaining useful life estimation in prognostics using deep convolution neural networks. ScienceDirect*. 2018.
- [Li+18b] Xin Li, Viliam Makis, Hongfu Zuo und Jing Cai. *Optimal Bayesian control policy for gear shaft fault detection using hidden semi-Markov model. ScienceDirect*. 2018.

- [Lia+17] Guo Liang, Li Naipeng, Jia Feng, Lei Yaguo und Lin Jing. *A recurrent neural network based health indicator for remaining useful life prediction of bearings*. *ScienceDirect*. 2017.
- [Liu+18] Bin Liu, Phuc Do, Benoit Iung, Min Xie, Flavien Peysson und Malyank Jha. *A study on the use of discrete event data for prognostics and health management: discovery of association rules*. *International Journal Of Prognostics and Health Management*. 2018.
- [Liu+17a] Hao Liu, Jian Chen, Ming Hou, Zhigang Shao und Hongye Su. *Data-based short-term prognostics for proton exchange membrane fuel cells*. *ScienceDirect*. 2017.
- [Liu+17b] Hao Liu, Jian Chen, Chuyan Zhu, Hongye Su und Ming Hou. *Prognostics of Proton Exchange Membrane Fuel Cells Using A Model-based Method*. *ScienceDirect*. 2017.
- [Liu+17c] Liansheng Liu, Shaojun Wang, Datong Liu und Yu Peng. *Quantitative selection of sensor data based on improved permutation entropy for system remaining useful life prediction*. *ScienceDirect*. 2017.
- [Liu+17d] Xiongjun Liu, Ping Song, Cheng Yang, Chuangbo Hao und Wenjia Peng. *Prognostics and Health Management of Bearings Based on Logarithmic Linear Recursive Least-Squares and Recursive Maximum Likelihood Estimation*. *IEEE Xplore*. 2017.
- [Liu+17e] Zhiliang Liu, Ming J. Zuo, Yaqiang Jin, Deng Pan und Yong Qin. *Improved local mean decomposition for modulation information mining and its application to machinery fault diagnosis*. *ScienceDirect*. 2017.
- [LWF17] Z. Long, X. Wang und Chengxin Fan. *Braking System Multi-state analysis of maglev train based on Bayesian Networks*. *IEEE Xplore*. 2017.
- [Lou+17] Panagiotis Loukopoulos, George Zolkiewski, Ian Bennett, Suresh Sampath, Pericles Pilidis, Fang Duan, Tariq Sattar und David Mba. *Reciprocating compressor prognostics of an instantaneous failure mode utilising temperature only measurements*. *ScienceDirect*. 2017.
- [LEZ17] Theodoros Loutas, Nick Eleftheroglou und Dimitrios Zarouchas. *A data-driven probabilistic framework towards the in-situ prognostics of fatigue life of composites based on acoustic emission data*. *ScienceDirect*. 2017.
- [Lu+18] Yanfei Lu, Qing Li, Zhipeng Pan und Steven Liang. *Prognosis of Bearing Degradation using Gradient Variable Forgetting Factor RLS Combined with Time Series Model*. *IEEE Xplore*. 2018.

- [Luo+17] M. Luo, S. Lin, D. Feng, Z. HE und L. Chen. *Design of the Prognostics and Health Management Platform of High-Speed Railway Traction Power Supply Equipment*. *IEEE Xplore*. 2017.
- [MJ17] Andrea Macaluso und Giovanni Jacazio. *Prognostic and Health Management System for Fly-by-wire Electro- Hydraulic Servo Actuators for detection and tracking of actuator faults*. *ScienceDirect*. 2017.
- [Mai+17] K. Mai, Y. Zhu, Z. Chen, X. Tao, Q. Xue, H. Wu, Y. Mao und J. Hou. *A Visual Model-based Evaluation Framework of Cloud-based Prognostics and Health Management*. *IEEE Xplore*. 2017.
- [McD+15] Darren McDonnell, Nora Balfe, Piero Baraldi und Garret E. O’Donnell. *Reducing Uncertainty in PHM by Accounting for Human Factors – A Case Study in the Biopharmaceutical Industry*. *ScienceDirect*. 2015.
- [McW+18] Richard McWilliam, Samir Khan, Michael Farnsworth und Colin Bell. *Zero-maintenance of electronic systems: Perspectives, challenges, and opportunities*. *ScienceDirect*. 2018.
- [Mik+17] T. Mikołajczyk, K. Nowicki, A. Kłodowski und D.Yu. Pimenov. *Neural network approach for automatic image analysis of cutting edge wear*. *ScienceDirect*. 2017.
- [Mis+18] Madhav Mishra, Jesper Martinsson, Matti Rantatalo und Kai Gobel. *Bayesian hierarchical model-based prognostics for lithium-ion batteries*. *ScienceDirect*. 2018.
- [MS18] Miguel Martínez Montaña und Miguel A Sanz-bobi. *Anomaly Detection Indicators of a Wind Turbine Gearbox Based on Feature Extraction from its Vibration Performance*. *International Journal Of Prognostics and Health Management*. 2018.
- [Nen+14] Nenad Nenadic, Howard Bussey, Paul Ardis, Michael Thurston und Tixlers Letters. *Estimation of State-of-Charge and Capacity of Used Lithium-Ion Cells*. *International Journal Of Prognostics and Health Management*. 2014.
- [NZL17] H. Nguyen, E. Zio und J. Liu. *Model ensemble-based prognostic framework for fatigue crack growth prediction*. *IEEE Xplore*. 2017.
- [Ngu+18] Khanh T. P. Nguyen, Amor Khlaief, Kamal Medjaher, Antoine Picot, Pascal Maussion und Diego Tobon. *Analysis and comparison of multiple features for fault detection and prognostic in ball bearings*. *International Journal Of Prognostics and Health Management*. 2018.

- [Oh+18] Hyunseok Oh, Yun Ho Seo, Min-hwan Mo und Joo-hyung Kim. *Coal Pulverizer Prognostics Data Challenge in PHMAP 2017 and Suggestions for Future Studies. International Journal Of Prognostics and Health Management*. 2018.
- [OBL17] M. A. Oomen, R. Bosman und P. M. Lugt. *Characterization of Friction and Wear Behavior of Friction Modifiers used in Wheel-Rail Contacts. International Journal Of Prognostics and Health Management*. 2017.
- [PI18] Ravi Kumar Pandit und David Infield. *Performance Assessment of a Wind Turbine Using SCADA based Gaussian Process Model. International Journal Of Prognostics and Health Management*. 2018.
- [PWZ18] Y. Peng, Y. Wang und Y. Zi. *Switching state-space degradation model with recursive filter/smoothen for prognostics of remaining useful life. IEEE Xplore*. 2018.
- [Per+18] Aramis Perez, Francisco Jaramillo, Vanessa Quintero und Marcos Orchard. *Characterizing the Degradation Process of Lithium-ion Batteries Using a Similarity-Based-Modeling Approach. International Journal Of Prognostics and Health Management*. 2018.
- [Pér+18] Aramis Pérez, Matías Benavides, Heraldo Rozas, Sebastián Seria und Marcos Orchard. *Guidelines for the Characterization of the Internal Impedance of Lithium-Ion Batteries in PHM Algorithms. International Journal Of Prognostics and Health Management*. 2018.
- [Pil+16] Prashanth Pillai, Anshul Kaushik, Shivanand Bhavikatti, Arjun Roy und Virendra Kumar. *A Hybrid Approach for Fusing Physics and Data for Failure Prediction. International Journal Of Prognostics and Health Management*. 2016.
- [PMA18] Gustavo de Novaes Pires Leite, Alex Maurício Araújo und Pedro André Carvalho Rosas. *Prognostic techniques applied to maintenance of wind turbines: a concise and specific review. ScienceDirect*. 2018.
- [Pow18] Yvonne Power. *Automated Predictive Monitoring and Diagnosis in the Energy and Natural Resources Sector. International Journal Of Prognostics and Health Management*. 2018.
- [Pra+18] Kundu Pradeep, Darpe Ashish K, S. P. Singh und K. Gupta. *A Review on Condition Monitoring Technologies for Railway Rolling Stock. International Journal Of Prognostics and Health Management*. 2018.

- [PSR17] T. Praveenkumar, M. Saimurugan und K. I. Ramachandran. *Comparison of Vibration, Sound and Motor Current Signature Analysis for Detection of Gear Box Faults. International Journal Of Prognostics and Health Management*. 2017.
- [QYG17] Yuning Qian, Ruqiang Yan und Robert X. Gao. *A multi-time scale approach to remaining useful life prediction in rolling bearing. ScienceDirect*. 2017.
- [Qia+17] Dayong Qiao, Rong Zhao, Yalong Zhang, Changfeng Xia, Xiumin Song und Qiaoming You. *An exploration for the degradation behavior of 2-D electrostatic microscanners by accelerated lifetime test. ScienceDirect*. 2017.
- [Qin+17] He Qingchuan, Chen Wenhua, Pan Jun und Qian Ping. *A prognostic method for predicting failure of dc/dc converter. ScienceDirect*. 2017.
- [Qiu+18] M. Qiu, W. Li, F. Jiang und Z. Zhu. *Remaining Useful Life Estimation for Rolling Bearing with SIOS-based Indicator and Particle Filtering. IEEE Xplore*. 2018.
- [RU17] Akhand Rai und S.H. Upadhyay. *The use of MD-CUMSUM and NARX neural network for anticipating the remaining useful life of bearings. ScienceDirect*. 2017.
- [RS16] Venkatesh Rajagopalan und Arun Subramaniyan. *A Methodology for Updating Prognostic Models via Kalman Filters. International Journal Of Prognostics and Health Management*. 2016.
- [RPP17] Sivakumar Ramalingam, Hanumath Prasad und Srinivasa Prakash Regalla. *Integrated Prognostics Observer for Condition Monitoring of an Automated Manual Transmission Dry Clutch System. International Journal Of Prognostics and Health Management*. 2017.
- [Ren+17] Lei Ren, Jin Cui, Yaqiang Sun und Xuejun Cheng. *Multi-bearing remaining useful life collaborative prediction: A deep learning approach. ScienceDirect*. 2017.
- [RDL14] Seyed Mohammad Rezvanizani, Jacob Dempsey und Jay Lee. *An Effective Predictive Maintenance Approach based on Historical Maintenance Data using a Probabilistic Risk Assessment: PHM14 Data Challenge. International Journal Of Prognostics and Health Management*. 2014.
- [RMB17] Diego J. Rodriguez, John J. Martinez und Christophe Berenguer. *Deterioration estimation for remaining useful lifetime prognosis in a friction drive system. ScienceDirect*. 2017.

- [RM18] Heraldito Rozas und Diego Mu. *An Approach to Prognosis-Decision-Making for Route Calculation of an Electric Vehicle Considering Stochastic Traffic Information*. *International Journal Of Prognostics and Health Management*. 2018.
- [SS17] Krishna Lok S. und Khazi M. M. Siddiqui. *Multi-physics based Simulations of an Oleo-pneumatic Shock Absorber System for PHM*. *International Journal Of Prognostics and Health Management*. 2017.
- [Sai+17a] L. Saidi, J. Ali, E. Bechhoefer und M. Benbouzid. *Particle filter-based prognostic approach for high-speed shaft bearing wind turbine progressive degradations*. *IEEE Xplore*. 2017.
- [Sai+17b] Lotfi Saidi, Jaouher Ben Ali, Eric Bechhoefer und Mohamed Benbouzid. *Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR*. *ScienceDirect*. 2017.
- [Sai+18] Lotfi Saidi, Jaouher Ben Ali, Mohamed Benbouzid und Eric Bechhoefer. *An integrated wind turbine failures prognostic approach implementing Kalman smoother with confidence bounds*. *ScienceDirect*. 2018.
- [Sba+18] Claudio Sbarufatti, Francesco Cadini, Andrea Locatelli und Marco Giglio. *A combined framework for automated diagnosis and prognosis of structures based on surrogate modelling and a particle filter*. *International Journal Of Prognostics and Health Management*. 2018.
- [Sha+16] T. Shan, J. Wang, G. Zhang, Y. Shen und C. Lu. *Real-Time Bearing Residual Life Prediction*. *IEEE Xplore*. 2016.
- [Sha+18] Haidong Shao, Hongkai Jiang, Xingqiu Li und Tianchen Liang. *Rolling bearing fault detection using continuous deep belief network with locally linear embedding*. *ScienceDirect*. 2018.
- [Sha+17] Sina Sharif Mansouri, Petros Karvelis, George Georgoulas und George Nikolakopoulos. *Remaining Useful Battery Life Prediction for UAVs based on Machine Learning*. *ScienceDirect*. 2017.
- [SW18a] Michael Sharp und Brian A. Weiss. *Hierarchical modeling of a manufacturing work cell to promote contextualized PHM information across multiple levels*. *ScienceDirect*. 2018.
- [SW18b] Michael Sharp und Brian A. Weiss. *Hierarchical modeling of a manufacturing work cell to promote contextualized PHM information across multiple levels*. *ScienceDirect*. 2018.

- [She+16] Y. Shen, T. Shan, X. Li, H. Wang, C. Sun und Y. He. *A Method of Health Evaluation for the Gear of Helicopter Main Gearbox*. *IEEE Xplore*. 2016.
- [SZD16] J. Shi, Y. Zhao und X. Duan. *Study about Health Assessment of Circuit Based on Three-state Health DBN Algorithm*. *IEEE Xplore*. 2016.
- [SLL18] Zhe Shi, Zongchang Liu und Jay Lee. *An auto-associative residual based approach for railway point system fault detection and diagnosis*. *ScienceDirect*. 2018.
- [Si+16] X. Si, T. Li, Q. Zhang und Z. Zhang. *A Prognostic Model for Degrading Systems With Randomly Arriving Shocks*. *IEEE Xplore*. 2016.
- [SMK17] Sarbjeet Singh, Arnab Majumdar und Miltos Kyriakidis. *Incorporating Human Reliability Analysis to enhance Maintenance Audits: The Case of Rail Bogie Maintenance*. *International Journal Of Prognostics and Health Management*. 2017.
- [Son+17a] Y. Song, D. Liu, Y. Peng, C. Yang und W. Wu. *Self-adaptive indirect health indicators extraction within prognosis of satellite lithium-ion battery*. *IEEE Xplore*. 2017.
- [SON+18] Yuchen SONG, Datong LIU, Yandong HOU, Jinxiang YU und Yu PENG. *Satellite lithium-ion battery remaining useful life estimation with an iterative updated RVM fused with the KF algorithm*. *ScienceDirect*. 2018.
- [Son+17b] Yuchen Song, Datong Liu, Chen Yang und Yu Peng. *Data-driven hybrid remaining useful life estimation approach for spacecraft lithium-ion battery*. *ScienceDirect*. 2017.
- [Su+17] Xiaohong Su, Shuai Wang, Michael Pecht, Lingling Zhao und Zhe Ye. *Interacting multiple model particle filter for prognostics of lithium-ion batteries*. *ScienceDirect*. 2017.
- [SUN+18] Jianzhong SUN, Chaoyi LI, Cui LIU, Ziwei GONG und Ronghui WANG. *A data-driven health indicator extraction method for aircraft air conditioning system health monitoring*. *ScienceDirect*. 2018.
- [Tab+15] Ali Tabrizi, Luigi Garibaldi, Alessandro Fasana und Stefano Marchesiello. *A Novel feature extraction for anomaly detection of roller bearings based on performance improved Ensemble Empirical Mode Decomposition and Teager-Kaiser Energy Operator*. *International Journal Of Prognostics and Health Management*. 2015.

- [Tan+17] Y. Tan, J. Cheng, H. Zhu, Z. Hu, B. Li und S. Liu. *Real-time Life Prediction of Equipment Based on Optimized ARMA Model*. *IEEE Xplore*. 2017.
- [Tan+16] Xin Tang, Yue Li, Zhongsheng Chen, Zheng Hu und Yongmin Yang. *An Exhaust Debris Monitoring Method for Gas Turbine PHM by Using a Planar Array of Hemisphere-Shaped Electrostatic Sensors*. *IEEE Xplore*. 2016.
- [Tao+17] Laifa Tao, Chao Yanga, Yujie Cheng, Chen Lu und Minvydas Raguškis. *Machine component health prognostics with only truncated histories using geometrical metric approach*. *ScienceDirect*. 2017.
- [TZZ18] Tao Tao, Enrico Zio und Wei Zhao. *A novel support vector regression method for online reliability prediction under multi-state varying operating conditions*. *ScienceDirect*. 2018.
- [TSB14] Moussa Traore, Moamar Sayed-Mouchaweh und Patrice Billaudel. *Adaptive Supervision of Patterns in Discrete Event Systems: Application to Crisis Management*. *International Journal Of Prognostics and Health Management*. 2014.
- [TR18] Pham Luu Trung Duong und Nagarajan Raghavan. *Heuristic Kalman optimized particle filter for remaining useful life prediction of lithium-ion battery*. *ScienceDirect*. 2018.
- [VA16] Sharma Vikas und Parey Anand. *A Review of Gear Fault Diagnosis Using Various Condition Indicators*. *ScienceDirect*. 2016.
- [Vol14] Andrei Volov. *Verification and Validation of Prognostic and Health Management*. *Prognostics Journal*. 2014.
- [Vu+16] Hai Canh Vu, Phuc Do, Mayank Shekhar Jha, Didier Theilliol und Flavien Peysson. *On the use of particle filters for prognostics in industrial applications*. *International Journal Of Prognostics and Health Management*. 2016.
- [WD17] Gero Walter und Simme Douwe Flapper. *Condition-based maintenance for complex systems based on current component status and Bayesian updating of component reliability*. *ScienceDirect*. 2017.
- [Wan+17a] B. Wang, Y. Xu, D. Liu, X. Peng und W. Qang. *An Approach of UAV Flight State Estimation and Prediction Based on Telemetry Data*. *IEEE Xplore*. 2017.
- [Wan+17b] Dong Wang, Fangfang Yang, Yang Zhao und Kwok-Leung Tsui. *Battery remaining useful life prediction at different discharge rates*. *ScienceDirect*. 2017.

- [Wan+17c] Dong Wang, Fangfang Yang, Yang Zhao und Kwok-Leung Tsui. *Prognostics of Lithium-ion batteries based on state spacemodeling-with heterogeneous noise variances. ScienceDirect. 2017.*
- [Wan+17d] Dong Wang, Yang Zhao, Fangfang Yang und Kwok-Leung Tsui. *Nonlinear-drifted Brownian motion with multiple hidden states for remaining useful life prediction of rechargeable batteries. Science-Direct. 2017.*
- [Wan+17e] F. Wang, S. Pan, Y. Xiong und H. Fang. *Research on Software Architecture of Prognostics and Health Management System for Civil Aircraft. IEEE Xplore. 2017.*
- [Wan17] X. Wang. *A Particle Filtering Approach for Aircraft Structure Life Prediction. IEEE Xplore. 2017.*
- [WHF18] Zhao-Qiang Wang, Chang-Hua Hu und Hong-Dong Fan. *Real-Time Remaining Useful Life Prediction for a Nonlinear Degrading System in Service: Application to Bearing Data. IEEE Xplore. 2018.*
- [Wan+18] Zhao-Qiang Wang, Chang-Hua Hu, Xiao-Sheng Si und Enrico Zio. *Remaining useful life prediction of degrading systems subjected to imperfect maintenance: Application to draught fans. ScienceDirect. 2018.*
- [Woo+18] Choi Woosung, Youn Byeng D., Oh Hyunseok und Kim Nam H. *A Bayesian approach for a damage growth model using sporadically measured and heterogeneous on-site data from a steam turbine. ScienceDirect. 2018.*
- [Wu+17] B. Wu, D. Kim, B. Han, A. Palczynska, A. Prisacaru und P. Gromala. *Hybrid Approach to Conduct Failure Prognostics of Automotive Electronic Control Unit. IEEE Xplore. 2017.*
- [Wu+16] D. Wu, C. Jennings, J. Terpenney und S. Kumara. *Cloud-Based Machine Learning for Predictive Analytics: Tool Wear Prediction in Milling. IEEE Xplore. 2016.*
- [Wu+18a] J. Wu, C. Wu, S. Cao, S. Wing, C. Deng und X. Shao. *Degradation Data-Driven Time-To-Failure Prognostics Approach for Rolling Element Bearings in Electrical Machines. IEEE Xplore. 2018.*
- [Wu+18b] Jun Wu, Yongheng Su, Yiwei Cheng, Xinyu Shao, Chao Deng und Cheng Liu. *Multi-sensor information fusion for remaining useful life prediction of machining tools by adaptive network based fuzzy inference system. ScienceDirect. 2018.*

- [Wu+18c] Linjiang Wu, Chao Liu, Tingting Huang, Anuj Sharma und Soumik Sarkar. *Traffic sensor health monitoring using spatiotemporal graphical modeling. International Journal Of Prognostics and Health Management*. 2018.
- [WLJ18] Z. Wu, W. Lin und Y. Ji. *An Integrated Ensemble Learning Model for Imbalanced Fault Diagnostics and Prognostics. IEEE Xplore*. 2018.
- [XCZ17] X. Xi, M. Chen und D. Zhou. *Online Prognostics Based on Multiple Dependent Degradation Processes. IEEE Xplore*. 2017.
- [Xi+18] Xiaopeng Xi, Maoyin Chen, Hanwen Zhang und Donghua Zhou. *An improved non-Markovian degradation model with long-term dependency and item-to-item uncertainty. ScienceDirect*. 2018.
- [Xia16] Wie Xiao. *A Probabilistic Machine Learning Approach to Detect Industrial Plant Faults. International Journal Of Prognostics and Health Management*. 2016.
- [Xin+14] Zhang Xin, Feng Naizhang, Wang Yan und Shen Yi. *Acoustic emission detection of rail defect based on wavelet transform and Shannon entropy. ScienceDirect*. 2014.
- [Xu+16] L. Xu, C. Zhang, H. Wang, X. Li, Y. Shen und Z. He. *A Method of Health Monitoring on Helicopter Speed Reducer Based on FME-CA. IEEE Xplore*. 2016.
- [XC17] Xin Xu und Nan Chen. *A state-space-based prognostics model for lithium-ion battery degradation. ScienceDirect*. 2017.
- [YZS17] H. Yan, H. Zuo und J. Sun. *Cost Effectiveness Evaluation Model for Civil Aircraft Maintenance Based on Prognostics and Health Management. IEEE Xplore*. 2017.
- [Yan+17a] J. Yan, Y. Meng, L. Lu und C. Guo. *Big-data-driven Based Intelligent Prognostics Scheme in Industry 4.0 Environment. IEEE Xplore*. 2017.
- [Yan+17b] Fangfang Yang, Dong Wang, Yinjiao Xing und Kwok-Leung Tsui. *Prognostics of Li(NiMnCo)O₂-based lithium-ion batteries using a novel battery degradation model. ScienceDirect*. 2017.
- [YR16] Ruochen Yang und Giorgio Rizzoni. *Comparison of Model-based Vs. Data-driven Methods for Fault Detection and Isolation in Engine Idle Speed Control System. International Journal Of Prognostics and Health Management*. 2016.

- [Yan+18] Shuhua Yang, Xiaomo Jiang, Shengli Xu und Xiaofang Wang. *Bayesian Stochastic Neural Network Model for Turbomachinery Damage Prediction*. *International Journal Of Prognostics and Health Management*. 2018.
- [YXY18] Lin Yanhui, Li Xudong und Hu Yang. *Deep diagnostics and prognostics: An integrated hierarchical learning framework in PHM applications*. *ScienceDirect*. 2018.
- [YL16] Fang Youlong und Yu Liangwu. *Problems of PHM Technology Application in the Marine Gas Turbine Engine and Coping Approaches*. *IEEE Xplore*. 2016.
- [Yu17] Jianbo Yu. *Aircraft engine health prognostics based on logistic regression with penalization regularization and state-space-based degradation framework*. *ScienceDirect*. 2017.
- [Yu18] Jianbo Yu. *State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble*. *ScienceDirect*. 2018.
- [YS16] Lijie Yu und Sachin Shrivastava. *Distributed Real Time Compressor Blade Health Monitoring System*. *International Journal Of Prognostics and Health Management*. 2016.
- [YSI17] Boyan Yuan, Christian Spiessberger und Tor Inge Waag. *Eddy current thermography imaging for condition-based maintenance of overlay welded components under multi- degradation*. *ScienceDirect*. 2017.
- [Yuj+17] Wanga Yujie, Pana Rui, Yanga Duo, Tangb Xiaopeng und Chen Zonghai. *Remaining Useful Life Prediction of Lithium-ion Battery Based on Discrete Wavelet Transform*. *ScienceDirect*. 2017.
- [ZT18] Ahmed Zakariae Hinchu und Mohamed Tkiouat. *Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network*. *ScienceDirect*. 2018.
- [Zel+18] Sophie ten Zeldam, Arjan de Jong, Richard Loendersloot und Tiedo Tinga. *Automated Failure Diagnosis in Aviation Maintenance Using Explainable Artificial Intelligence (XAI)*. *International Journal Of Prognostics and Health Management*. 2018.
- [Zha+16] G. Zhang, Jun Zhou, F. Han und D. Liu. *Data-based Anomaly Detection Model for Solar Array Power of In-orbit Satellites*. *IEEE Xplore*. 2016.

- [Zha+18a] Heng Zhang, Qiang Miao, Xin Zhang und Zhiwen Liu. *An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction*. *ScienceDirect*. 2018.
- [Zha+17a] Jian-Xun Zhang, Chang-Hua Hu, Xiao He, Xiao-Sheng Si, Yang Liu und Dong-Hua Zhou. *Lifetime prognostics for deteriorating systems with time-varying random jumps*. *ScienceDirect*. 2017.
- [Zha+18b] Jian-Xun Zhang, Xiao-Sheng Si, Dang-Bo Du und Chang-Hua Hu. *Specification analysis of the deteriorating sensor for required lifetime prognostic performance*. *ScienceDirect*. 2018.
- [Zha+17b] Jianlei Zhang, Binil Starly, Yi Cai, Paul H. Cohen und Yuan-Shin Lee. *Particle learning in online tool wear diagnosis and prognosis*. *ScienceDirect*. 2017.
- [ZWT17] X. Zhang, P. Wu und C. Tan. *A Big Data Framework for Spacecraft Prognostics and Health Monitoring*. *IEEE Xplore*. 2017.
- [ZML17] Xin Zhang, Qiang Miao und Zhiwen Liu. *Remaining useful life prediction of lithium-ion battery using an improved UPF method based on MCMC*. *ScienceDirect*. 2017.
- [Zha+17c] Y. Zhang, L. Wang, B. Gao, L. Wang, J. Luo und Z. Han. *System Analysis and PHM Methods for Power Devices Based on Physics-of-Failure*. *IEEE Xplore*. 2017.
- [Zha+17d] Yongzhi Zhang, Rui Xiong, Hongwen He und Zhiru Liu. *A LSTM-RNN method for the lithium-ion battery remaining useful life prediction*. *IEEE Xplore*. 2017.
- [Zha+17e] Yujie Zhang, Datong Liu, Jinxiang Yu, Yu Peng und Xiyuan Peng. *EMA remaining useful life prediction with weighted bagging GPR algorithm*. *ScienceDirect*. 2017.
- [Zha+18c] Zhengxin Zhang, Xiaosheng Si, Changhua Hu und Yaguo Lei. *Degradation data analysis and remaining useful life estimation: A review on Wiener-process-based methods*. *ScienceDirect*. 2018.
- [Zha+17f] Guangquan Zhao, Xiaoyong Liu, Bin Zhang, Guohui Zhang, Guangxing Niu und Cong Hu. *Bearing Health Condition Prediction Using Deep Belief Network*. *International Journal Of Prognostics and Health Management*. 2017.
- [Zha+18d] S. Zhao, V. Makis, S. Chen und Y. Li. *Evaluation of Reliability Function and Mean Residual Life for Degrading Systems Subject to Condition Monitoring and Random Failure*. *IEEE Xplore*. 2018.

- [Zha+17g] Zeqi Zhao, Bin Liang, Xueqian Wang und Weining Lu. *Remaining useful life prediction of aircraft engine based on degradation pattern learning*. *ScienceDirect*. 2017.
- [Zho+17a] Daming Zhou, Fei Gao, Elena Breaz, Alexandre Ravey und Abdellatif Miraoui. *Degradation prediction of PEM fuel cell using a moving window based hybrid prognostic approach*. *ScienceDirect*. 2017.
- [ZHL17] Haowen Zhou, Jinquan Huang und Feng Lu. *Reduced kernel recursive least squares algorithm for aero-engine degradation prediction*. *ScienceDirect*. 2017.
- [Zho+17b] Xunfei Zhoua, Sheng-Jen Hsieh, Bo Peng und Daniel Hsieh. *Cycle life estimation of lithium-ion polymer batteries using artificial neural network and support vector machine with time-resolved thermography*. *ScienceDirect*. 2017.
- [ZC18] Li Zhu und Junhui Chen. *Prognostics of PEM fuel cells based on Gaussian process state space models*. *ScienceDirect*. 2018.

Liste der bisher erschienenen Berichte aus dem IMA:

Nr.	Verfasser	Titel
1	H.K. Müller	Beitrag zur Berechnung und Konstruktion von Hochdruckdichtungen an schnellaufenden Wellen
2	W. Passera	Konzentrisch laufende Gewinde-Wellen-Dichtung im laminaren Bereich
	K. Karow	Konzentrische Doppelgewindewellendichtung im laminaren Bereich
3	F.E. Breit	Die Kreiszyinderschalendichtung: Eine Axialspaltdichtung mit druckabhängiger Spaltweite
	W. Sommer	Dichtungen an Mehrphasensystemen: Berührungsfreie Wellendichtungen mit hochviskosen Sperrflüssigkeiten
4	K. Heitel	Beitrag zur Berechnung und Konstruktion konzentrisch und exzentrisch betriebener Gewinnwellendichtungen im laminaren Bereich
5	K.-H. Hirschmann	Beitrag zur Berechnung der Geometrie von Evolventenverzahnungen
6	H. Däuble	Durchfluß und Druckverlauf im radial durchströmten Dichtspalt bei pulsierendem Druck
7	J. Rybak	Einheitliche Berechnung von Schneidrädern für Außen- und Innenverzahnungen. Beitrag zu Eingriffsstörungen beim Hohlrad-Verzahn mittels Schneidräder
8	D. Franz	Rechnergestütztes Entwerfen von Varianten auf der Grundlage gesammelter Erfahrungswerte
9	E. Lauster	Untersuchungen und Berechnungen zum Wärmehaushalt mechanischer Schaltgetriebe
10		Festschrift zum 70. Geburtstag von Prof. Dr.-Ing. K. Talke
11	G. Ott	Untersuchungen zum dynamischen Leckage- und Reibverhalten von Radialwellendichtringen
12	E. Fuchs	Untersuchung des elasto-hydrodynamischen Verhaltens von berührungsfreien Hochdruckdichtungen
13	G. Sedlak	Rechnerunterstütztes Aufnehmen und Auswerten spannungsoptischer Bilder
14	W. Wolf	Programmsystem zur Analyse und Optimierung von Fahrzeuggetrieben
15	H. v. Eiff	Einfluß der Verzahnungsgeometrie auf die Zahnfußbeanspruchung innen- und außenverzählter Geradstirnräder
16	N. Messner	Untersuchung von Hydraulikstangendichtungen aus Polytetrafluoräthylen
17	V. Schade	Entwicklung eines Verfahrens zur Einflanken-Wälzprüfung und einer rechnergestützten Auswertemethode für Stirnräder
18	A. Gührer	Beitrag zur Optimierung von Antriebssträngen bei Fahrzeugen
19	R. Nill	Das Schwingungsverhalten loser Bauteile in Fahrzeuggetrieben
20	M. Kammüller	Zum Abdichtverhalten von Radial-Wellendichtringen
21	H. Truong	Strukturorientiertes Modellieren, Optimieren und Identifizieren von Mehrkörpersystemen
22	H. Liu	Rechnergestützte Bilderfassung, -verarbeitung und -auswertung in der Spannungsoptik
23	W. Haas	Berührungsfreie Wellendichtungen für flüssigkeitsbespritzte Dichtstellen
24	M. Plank	Das Betriebsverhalten von Wälzlagern im Drehzahlbereich bis 100.000/min bei Kleinstmengenschmierung
25	A. Wolf	Untersuchungen zum Abdichtverhalten von druckbelastbaren Elastomer- und PTFE-Wellendichtungen
26	P. Waidner	Vorgänge im Dichtspalt wasserabdichtender Gleitringdichtungen
27	Hirschmann u.a.	Veröffentlichungen aus Anlaß des 75. Geburtstags von Prof. Dr.-Ing. Kurt Talke
28	B. Bertsche	Zur Berechnung der Systemzuverlässigkeit von Maschinenbau-Produkten
29	G. Lechner;	Forschungsarbeiten zur Zuverlässigkeit im Maschinenbau
	K.-H.Hirschmann;	
	B. Bertsche	
30	H.-J. Prokop	Zum Abdicht- und Reibungsverhalten von Hydraulikstangendichtungen aus Polytetrafluoräthylen
31	K. Kleinbach	Qualitätsbeurteilung von Kegelradsätzen durch integrierte Prüfung von Tragbild, Einflankenwälzabweichung und Spielverlauf
32	E. Zürn	Beitrag zur Erhöhung der Meßgenauigkeit und -geschwindigkeit eines Mehrkoordinatentasters
33	F. Jauch	Optimierung des Antriebsstranges von Kraftfahrzeugen durch Fahrsimulation
34	J. Grabscheid	Entwicklung einer Kegelrad-Laufprüfmaschine mit thermografischer Tragbilderfassung
35	A. Hölderlin	Verknüpfung von rechnerunterstützter Konstruktion und Koordinatenmeßtechnik
36	J. Kurfess	Abdichten von Flüssigkeiten mit Magnetflüssigkeitsdichtungen
37	G. Borenius	Zur rechnerischen Schädigungsakkumulation in der Erprobung von Kraftfahrzeugteilen bei stochastischer Belastung mit variabler Mittellast
38	E. Fritz	Abdichtung von Maschinenspindeln
39	E. Fritz; W. Haas;	Berührungsfreie Spindelabdichtungen im Werkzeugmaschinenbau. Konstruktionskatalog
	H.K. Müller	

Nr.	Verfasser	Titel
40	B. Jenisch	Abdichten mit Radial-Wellendichtringen aus Elastomer und Polytetrafluorethylen
41	G. Weidner	Klappern und Rasseln von Fahrzeuggetrieben
42	A. Herzog	Erweiterung des Datenmodells eines 2D CAD-Systems zur Programmierung von Mehrkoordinatenmeßgeräten
43	T. Roser	Wissensbasiertes Konstruieren am Beispiel von Getrieben
44	P. Wäschle	Entlastete Wellendichtringe
45	Z. Wu	Vergleich und Entwicklung von Methoden zur Zuverlässigkeitsanalyse von Systemen
46	W. Richter	Nichtwiederholbarer Schlag von Wälzlagereinheiten für Festplattenlaufwerke
47	R. Durst	Rechnerunterstützte Nutprofilentwicklung und clusteranalytische Methoden zur Optimierung von Gewindewerkzeugen
48	G.S. Müller	Das Abdichtverhalten von Gleitringdichtungen aus Siliziumkarbid
49	W.-E. Krieg	Untersuchungen an Gehäuseabdichtungen von hochbelasteten Getrieben
50	J. Grill	Zur Krümmungstheorie von Hüllflächen und ihrer Anwendung bei Werkzeugen und Verzahnungen
51	M. Jäckle	Entlüftung von Getrieben
52	M. Köchling	Beitrag zur Auslegung von geradverzahnten Stirnrädern mit beliebiger Flankenform
53	M. Hildebrandt	Schadensfrüherkennung an Wälzkontakten mit Körperschall-Referenzsignalen
54	H. Kaiser	Konstruieren im Verbund von Expertensystem, CAD-System, Datenbank und Wiederholteil-suchsystem
55	N. Stanger	Berührungsfrei abdichten bei kleinem Bauraum
56	R. Lenk	Zuverlässigkeitsanalyse von komplexen Systemen am Beispiel PKW-Automatikgetriebe
57	H. Nauhheimer	Beitrag zur Entwicklung von Stufenlosgetrieben mittels Fahrsimulation
58	G. Neumann	Thermografische Tragbilderfassung an rotierenden Zahnradern
59	G. Wüstenhagen	Beitrag zur Optimierung des Entlasteten Wellendichtrings
60	P. Brodbeck	Experimentelle und theoretische Untersuchungen zur Bauteilzuverlässigkeit und zur System-berechnung nach dem Booleschen Modell
61	Ch. Hoffmann	Untersuchungen an PTFE-Wellendichtungen
62	V. Hettich	Identifikation und Modellierung des Materialverhaltens dynamisch beanspruchter Flächen-dichtungen
63	K. Riedel	Pulsationsoptimierte Außenzahnpumpen mit ungleichförmig übersetzenden Radpaaren
64	D. Schwuchow	Sonderverzahnungen für Zahnpumpen mit minimaler Volumenstrompulsation
65	T. Spörl	Modulares Fahrsimulationsprogramm für beliebig aufgebaute Fahrzeugtriebstränge und An-wendung auf Hybridantriebe
66	K. Zhao	Entwicklung eines räumlichen Toleranzmodells zur Optimierung der Produktqualität
67	K. Heusel	Qualitätssteigerung von Planetengetrieben durch Selektive Montage
68	T. Wagner	Entwicklung eines Qualitätsinformationssystems für die Konstruktion
69	H. Zelfmann	Optimierung des Betriebsverhaltens von Getriebeentlüftungen
70	E. Bock	Schwimmende Wellendichtringe
71	S. Ring	Anwendung der Verzahnungstheorie auf die Modellierung und Simulation des Werkzeug-schleifens
72	M. Klöpfer	Dynamisch beanspruchte Dichtverbindungen von Getriebegehäusen
73	C.-H. Lang	Losteilgeräusche von Fahrzeuggetrieben
74	W. Haas	Berührungsfreies Abdichten im Maschinenbau unter besonderer Berücksichtigung der Fang-labyrinth
75	P. Schiberna	Geschwindigkeitsvorgabe für Fahrsimulationen mittels Verkehrssimulation
76	W. Elser	Beitrag zur Optimierung von Wälzgetrieben
77	P. Marx	Durchgängige, bauteilübergreifende Auslegung von Maschinenelementen mit unscharfen Vorgaben
78	J. Kopsch	Unterstützung der Konstruktionstätigkeiten mit einem Aktiven Semantischen Netz
79	J. Rach	Beitrag zur Minimierung von Klapper- und Rasselgeräuschen von Fahrzeuggetrieben
80	U. Häussler	Generalisierte Berechnung räumlicher Verzahnungen und ihre Anwendung auf Wälzfräse-rherstellung und Wälzfräsen
81	M. Hüsges	Steigerung der Tolerierungsfähigkeit unter fertigungstechnischen Gesichtspunkten
82	X. Nastos	Ein räumliches Toleranzbewertungssystem für die Konstruktion
83	A. Seifried	Eine neue Methode zur Berechnung von Rollenlagern über lagerinterne Kontakt-Beanspruchungen
84	Ch. Dörr	Ermittlung von Getriebelastkollektiven mittels Winkelbeschleunigungen
85	A. Veil	Integration der Berechnung von Systemzuverlässigkeiten in den CAD-Konstruktionsprozeß
86	U. Frenzel	Rückenstrukturierte Hydraulikstangendichtungen aus Polyurethan
87	U. Braun	Optimierung von Außenzahnpumpen mit pulsationsarmer Sonderverzahnung
88	M. Lambert	Abdichtung von Werkzeugmaschinen-Flachführungen
89	R. Kubalczyk	Gehäusegestaltung von Fahrzeuggetrieben im Abdichtbereich

Nr.	Verfasser	Titel
90	M. Oberle	Spielbeeinflussende Toleranzparameter bei Planetengetrieben
91	S. N. Dogan	Zur Minimierung der Loseilgeräusche von Fahrzeuggetrieben
92	M. Bast	Beitrag zur werkstückorientierten Konstruktion von Zerspanwerkzeugen
93	M. Ebenhoch	Eignung von additiv generierten Prototypen zur frühzeitigen Spannungsanalyse im Produktentwicklungsprozeß
94	A. Fritz	Berechnung und Monte-Carlo Simulation der Zuverlässigkeit und Verfügbarkeit technischer Systeme
95	O. Schrems	Die Fertigung als Versuchsfeld für die qualitätsgerechte Produktoptimierung
96	M. Jäckle	Untersuchungen zur elastischen Verformung von Fahrzeuggetrieben
97	H. Haier	PTFE-Compounds im dynamischen Dichtkontakt bei druckbelastbaren Radial-Wellendichtungen
98	M. Rettenmaier	Entwicklung eines Modellierungs-Hilfssystems für Rapid Prototyping gerechte Bauteile
99	M. Przybilla	Methodisches Konstruieren von Leichtbauelementen für hochdynamische Werkzeugmaschinen
100	M. Olbrich	Werkstoffmodelle zur Finiten-Elemente-Analyse von PTFE-Wellendichtungen
101	M. Kunz	Ermittlung des Einflusses fahrzeug-, fahrer- und verkehrsspezifischer Parameter auf die Getriebebelastkollektive mittels Fahrsimulation
102	H. Ruppert	CAD-integrierte Zuverlässigkeitsanalyse und -optimierung
103	S. Kilian	Entwicklung hochdynamisch beanspruchter Flächendichtverbindungen
104	A. Flaig	Untersuchung von umweltschonenden Antriebskonzepten für Kraftfahrzeuge mittels Simulation
105	B. Luo	Überprüfung und Weiterentwicklung der Zuverlässigkeitsmodelle im Maschinenbau mittels Mono-Bauteil-Systemen
106	L. Schüppenbauer	Erhöhung der Verfügbarkeit von Daten für die Gestaltung und Berechnung der Zuverlässigkeit von Systemen
107	J. Ryborz	Klapper- und Rasselgeräuschverhalten von Pkw- und Nkw- Getrieben
108	M. Würthner	Rotierende Wellen gegen Kühlschmierstoff und Partikel berührungsfrei abdichten
109	C. Gitt	Analyse und Synthese leistungsverzweigter Stufenlosgetriebe
110	A. Krolo	Planung von Zuverlässigkeitstests mit weitreichender Berücksichtigung von Vorkenntnissen
111	G. Schöllhammer	Entwicklung und Untersuchung inverser Wellendichtsysteme
112	K. Fronius	Gehäusegestaltung im Abdichtbereich unter pulsierendem Innendruck
113	A. Weidler	Ermittlung von Raffungsfaktoren für die Getriebeerprobung
114	B. Stiegler	Berührungsfreie Dichtsysteme für Anwendungen im Fahrzeug- und Maschinenbau
115	T. Kunstfeld	Einfluss der Wellenoberfläche auf das Dichtverhalten von Radial-Wellendichtungen
116	M. Janssen	Abstreifer für Werkzeugmaschinenführungen
117	S. Buhl	Wechselbeziehungen im Dichtsystem von Radial-Wellendichtung, Gegenauflfläche und Fluid
118	P. Pozsgai	Realitätsnahe Modellierung und Analyse der operativen Zuverlässigkeitskennwerte technischer Systeme
119	H. Li	Untersuchungen zum realen Bewegungsverhalten von Loseilen in Fahrzeuggetrieben
120	B. Otte	Strukturierung und Bewertung von Eingangsdaten für Zuverlässigkeitsanalysen
121	P. Jäger	Zuverlässigkeitsbewertung mechatronischer Systeme in frühen Entwicklungsphasen
122	T. Hitziger	Übertragbarkeit von Vorkenntnissen bei der Zuverlässigkeitstestplanung
123	M. Delonga	Zuverlässigkeitsmanagementsystem auf Basis von Felddaten
124	M. Maisch	Zuverlässigkeitsorientiertes Erprobungskonzept für Nutzfahrzeuggetriebe unter Berücksichtigung von Betriebsdaten
125	J. Orso	Berührungsfreies Abdichten schnelllaufender Spindeln gegen feine Stäube
126	F. Bauer	PTFE-Manschettendichtungen mit Spirallrille - Analyse, Funktionsweise und Erweiterung der Einsatzgrenzen
127	M. Stockmeier	Entwicklung von Klapper- und rasselgeräuschfreien Fahrzeuggetrieben
128	M. Trost	Gesamtheitliche Anlagenmodellierung und -analyse auf Basis stochastischer Netzverfahren
129	P. Lambeck	Unterstützung der Kreativität von verteilten Konstrukteuren mit einem Aktiven Semantischen Netz
130	K. Pickard	Erweiterte qualitative Zuverlässigkeitsanalyse mit Ausfallprognose von Systemen
131	W. Novak	Geräusch- und Wirkungsgradoptimierung bei Fahrzeuggetrieben durch Festradentkopplung
132	M. Henzler	Radialdichtungen unter hoher Druckbelastung in Drehübertragern von Werkzeugmaschinen
133	B. Rzepka	Konzeption eines aktiven semantischen Zuverlässigkeitsinformationssystems
134	C.G. Pflüger	Abdichtung schnelllaufender Hochdruck-Drehübertrager mittels Rechteckring und hocheffizient strukturierter Gleitfläche
135	G. Baitinger	Multiskalenansatz mit Mikrostrukturanalyse zur Drallbeurteilung von Dichtungsgegenauflflächen

Nr.	Verfasser	Titel
136	J. Gäng	Berücksichtigung von Wechselwirkungen bei Zuverlässigkeitsanalysen
137	C. Maisch	Berücksichtigung der Ölalterung bei der Lebensdauer- und Zuverlässigkeitsprognose von Getrieben
138	D. Kirschmann	Ermittlung erweiterter Zuverlässigkeitsziele in der Produktentwicklung
139	D. Weber	Numerische Verschleißsimulation auf Basis tribologischer Untersuchungen am Beispiel von PTFE-Manschettendichtungen
140	T. Leopold	Ganzheitliche Datenerfassung für verbesserte Zuverlässigkeitsanalysen
141	St. Jung	Beitrag zum Einfluss der Oberflächencharakteristik von Gegenläufigen auf das tribologische System Radial-Wellendichtung
142	T. Prill	Beitrag zur Gestaltung von Leichtbau-Getriebegehäusen und deren Abdichtung
143	D. Hofmann	Verknüpfungmodell zuverlässigkeitsrelevanter Informationen in der Produktentwicklung mechatronischer Systeme
144	M. Wacker	Einfluss von Drehungleichförmigkeiten auf die Zahnradlebensdauer in Fahrzeuggetrieben
145	B. Jakobi	Dichtungsergüsse am Beispiel von Pkw-Lenkungen – Analyse und Abhilfemaßnahmen
146	S. Kiefer	Bewegungsverhalten von singulären Zahnradstufen mit schaltbaren Koppelungseinrichtungen
147	P. Fietkau	Transiente Kontaktberechnung bei Fahrzeuggetrieben
148	B. Klein	Numerische Analyse von gemischten Ausfallverteilungen in der Zuverlässigkeitstechnik
149	M. Kläiber	Betriebs- und Benetzungseigenschaften im Dichtsystem Radial-Wellendichtung am Beispiel von additiven synthetischen Schmierölen
150	A. Baumann	Rasselgeräuschminimierung von Fahrzeuggetrieben durch Getriebeöle
151	M. Kopp	Modularisierung und Synthese von Zuverlässigkeitsmethoden
152	M. Narten	Abdichten von fließfettgeschmierten Getrieben mit Radialwellendichtungen – Reibungsminimierung durch Makrostrukturierung der Dichtungsgegenläufigkeit
153	P. Schuler	Einfluss von Grenzflächeneffekten auf den Dichtmechanismus der Radial-Wellendichtung
154	A. Romer	Anwendungsspezifischer Zuverlässigkeitsnachweis auf Basis von Lastkollektiven und Vorwissen
155	A. Daubner	Analyse, Modellierung und Simulation von Verschleiß auf mehreren Skalen zur Betriebsdauervorhersage von Wellendichtungen aus PTFE-Compound
156	J. Rowas	Ökologischer Einsatz der Traktionsarten im System Bahn
157	D. J. Maier	Sensorlose online Zustandserfassung von Vorschubantriebskomponenten in Werkzeugmaschinen
158	J.-P. Reibert	Statisches Abdichten auf nicht idealen Dichtflächen in der Antriebstechnik
159	M. Sommer	Einfluss des Schmierfettes auf das tribologische System Radial-Wellendichtung – Betriebsverhalten und Funktionsmodell
160	W. Haas	Basics der Dichtungstechnik
161	U. Nißler	Dichtheit von Hydraulikstangendichtungen aus Polyurethan
162	S. M. Neuburger	Entwicklung einer gasgeschmierten Gleitringdichtung für den Einsatz im Verbrennungsmotor
163	W. Goujavin	Strömungsmechanische Untersuchungen zur Funktionsweise von Manschetendichtungen aus PTFE-Compounds mit Rückförderstrukturen
164	K. Mutter	Simulation der Zuverlässigkeit von Gesamtfahrzeugfunktionen am Beispiel Fahrkomfort
165	S. Sanzenbacher	Reduzierung von Getriebegeräuschen durch Körperschallminderungsmaßnahmen
166	O. Koller	Zuverlässigkeit von Leistungsmodulen im elektrischen Antriebsstrang
167	M. Rempis	Untersuchungen zum Förderverhalten von Dichtsystemen mit Radial-Wellendichtungen aus Elastomer
168	M. Baumann	Abdichtung drallbehalteter Dichtungsgegenläufigkeiten – Messung, Analyse, Bewertung und Grenzen
169	M. Schenk	Adaptives Prüfstandsverhalten in der PKW-Antriebsstrangerprobung
170	J. Gözl	Manschettendichtungen aus PTFE-Compounds, Funktionsmechanismus von PTFE-Manschettendichtungen und Entwicklung von Rückförderstrukturen für beidseitig drehende Wellen
171	J. Kümmel	Schmutzabdichtung mittels Fettgefüllter Berührungsfreier Wellendichtungen
172	S. Bader	Gehäusedichtungen unter korrosiver Last
173	J. Juskowiak	Beanspruchungsgerechte Bestimmung des Weibull-Formparameters für Zuverlässigkeitsprognosen
174	F. Jakob	Nutzung von Vorkenntnissen und Raffungsmodellen für die Zuverlässigkeitsbestimmung
175	N. P. Tonius	Klauenschaltelmente in Stufenautomatgetrieben
176	V. Schweizer	Berücksichtigung und Bewertung streuender Einflussgrößen in der Zuverlässigkeitssimulation
177	F. Bosch	Abdichtung trockener Stäube mit fettgefüllten berührungsfreien Wellendichtungen
178	M. Botzler	Präventive Diagnose abnutzungsabhängiger Komponentenausfälle
179	C. Fehrenbacher	Förderverhalten im Dichtsystem Radial-Wellendichtung

Nr.	Verfasser	Titel
180	B. Heumesser	Optimierung des Klapper- und Rasselgeräuschverhaltens bei Doppelkupplungsgetrieben
181	A. Eipper	Einfluss transientser Betriebsbedingungen auf den RWDR im System Radial-Wellendichtung
182	Alexander Buck	Einfluss der Oberflächenrauheit auf den Verschleiß an Hydraulikstangendichtungen
183	Andrea Buck	Simulation und Optimierung der Instandhaltung unter Berücksichtigung sich ändernder Belastungen mittels Petrinetzen
184	St. Kemmler	Integrale Methodik zur Entwicklung von robusten, zuverlässigen Produkten
185	T. Rieker	Modellierung der Zuverlässigkeit technischer Systeme mit stochastischen Netzverfahren
186	M. Bartholdt	Kunden- und kostenorientierte Zuverlässigkeitszielermittlung
187	V. Warth	Systematische Synthese und Bewertung von Stufenlosgetrieben
188	N. Nowizki	Funktionale Sicherheit und Zuverlässigkeit in frühen Phasen der Produktentwicklung
189	F. Schiefer	Additive Fertigung von Radial-Wellendichtungen
190	M. Dazer	Zuverlässigkeitstestplanung mit Berücksichtigung von Vorwissen aus stochastischen Lebensdauerberechnungen
191	J. Totz	Funktionsuntersuchungen an Dichtsystemen mit weichgeschliffenen Dichtungsgegenauflächen und Radial-Wellendichtungen aus NBR
192	M. Stoll	Entwicklung und Funktionsanalyse rückenstrukturierter Manschettendichtungen aus PTFE-Compound
193	N. Dakov	Elastohydrodynamische Simulation von Wellendichtungen am Beispiel der PTFE-Manschettendichtung mit Rückförderstrukturen
194	Z. Beslic	Modellierung der Schadensdegradation Zahnradgrübchen bei Fahrzeuggetrieben
195	St. Jetter	Zuverlässigkeitsprognose mechanischer Komponenten auf Basis simulierter Betriebsfestigkeit
196	O. R. Orozco	Availability of Particle Accelerators: requirements, prediction methods and optimization
197	V. Schramm	Dependable System Development Methodology and Case Study for the LHC Beam Loss Monitoring System at CERN
198	J. Gröber	Zuverlässigkeitsanalyse neuartiger mechatronischer Systeme
199	K. Lucan	Methodische Ermittlung von repräsentativen Lastkollektiven am Beispiel der Nutzfahrzeugbremse
200	F. Müller	Realitätsnahe Modellierung, Simulation und Analyse der operativen Zuverlässigkeits- und Verfügbarkeitskennwerte technischer Systeme mit Vertrauensbereich
201	A. Ostertag	Zuverlässigkeit, Sicherheit und Nachhaltigkeit adaptiver Tragwerke
202	A. Kremer	Statistische Versuchsplanung in der Lebensdauererprobung mit Vertrauensintervallen
203	T. Herzig	Anforderungsgerechte Produktauslegung durch Planung effizienter beschleunigter Zuverlässigkeitstests