
Clusterbasierte Zustandsbewertung von technischen Systemen zur Unterstützung der prädiktiven Instandhaltung

**Cluster-based Condition Assessment of Technical Systems to Support
Predictive Maintenance**

Vom Fachbereich Maschinenbau an der
Technischen Universität Darmstadt
zur
Erlangung des Grades eines Doktor-Ingenieurs (Dr.-Ing.) genehmigte

Dissertation

vorgelegt von

Christian Preusche M. Sc.

aus Darmstadt

Berichterstatter: Prof. Dr.-Ing. Uwe Klingauf

Mitberichterstatter: Prof. Dr.-Ing. Dipl.-Wirtsch.-Ing. Joachim Metternich

Tag der Einreichung: 22. Januar 2018

Tag der mündlichen Prüfung: 10. April 2018

Darmstadt 2018

D 17

Bitte zitieren Sie dieses Dokument als:

URN: [urn:nbn:de:tuda-tuprints-77206](https://nbn-resolving.org/urn:nbn:de:tuda-tuprints-77206)


URL: <http://tuprints.ulb.tu-darmstadt.de/7720>

Dieses Dokument wird bereitgestellt von tuprints,

E-Publishing-Service der TU Darmstadt

<http://tuprints.ulb.tu-darmstadt.de>

tuprints@ulb.tu-darmstadt.de



Die Veröffentlichung steht unter folgender Creative Commons Lizenz:

Namensnennung – Nicht kommerziell – Keine Bearbeitung 4.0 International

<http://creativecommons.org/licenses/by-nc-nd/4.0/>

Kurzfassung

Die zunehmende Digitalisierung ermöglicht Unternehmen die Umsetzung neuartiger Instandhaltungsansätze. So wird bei der prädiktiven Instandhaltung anhand von Sensordaten eine umfassende und kontinuierliche Bewertung des Zustands eines technischen Systems vorgenommen. Fehlerhaftes Verhalten kann frühzeitig diagnostiziert und der Ausfallzeitpunkt prognostiziert werden. Als Konsequenz lassen sich notwendige Instandhaltungsmaßnahmen effizient planen. Die Umsetzung einer prädiktiven Instandhaltung erfordert die Entwicklung von innovativen Algorithmen. Dadurch motiviert ist das Ziel der vorliegenden Arbeit die Entwicklung, Implementierung und Bewertung eines datenbasierten Algorithmus. Der Fokus liegt dabei auf der Entwicklung eines neuen Ansatzes zur Diagnose der Degradation eines Systems. Ungenauigkeiten bei diesem Schritt führen zu einer fehlerbehafteten Prognose und somit zu falsch geplanten Instandhaltungsmaßnahmen.

Auf Basis historischer Schadensverläufe identifizieren und modellieren datenbasierte Algorithmen Zusammenhänge zwischen dem Zustand des Systems und Merkmalen, welche aus den Sensorsignalen gewonnen werden. Eine Herausforderung hierbei ist, dass die Relevanz von Merkmalen zwischen unterschiedlichen Schadensverläufen aufgrund der Stochastik von Degradierungsprozessen variiert. Dies erschwert eine einheitliche Modellierung. Der in dieser Arbeit vorgeschlagene Algorithmus löst dieses Problem mithilfe der hierarchischen Clusteranalyse. Dies ermöglicht, ähnliche Schadensverläufe innerhalb einer Datenbank zu identifizieren und anschließend zu gruppieren. Innerhalb dieser Gruppen können datenbasierte Algorithmen relevante Merkmale erkennen und Zusammenhänge modellieren. Zu diesem Zweck wird ein Algorithmus vorgeschlagen, welcher die automatische Identifikation und Bewertung von Merkmalen auf Grundlage von historischen Daten erlaubt. Die Abschätzung des Zustands findet in zwei Schritten statt. Zunächst erfolgt die Bestimmung der ähnlichsten Gruppe zum aktuellen Schadensverlauf. Im Anschluss findet die Bewertung des Zustands anhand geeigneter Merkmale statt.

Die vorliegende Arbeit behandelt drei Forschungsfragen. Die Erste analysiert den Einfluss des Ansatzes auf die Prognosefähigkeit. Bei einer Gegenüberstellung mit einem Vergleichsalgorithmus zeigt sich, dass die Gruppierung von Schadensverläufen die Zustandsbewertung positiv beeinflusst. Dadurch kann die Genauigkeit der Restlebensdauerprognose erhöht und Unsicherheiten der Vorhersage reduziert werden.

Die zweite Forschungsfrage untersucht die Übertragbarkeit des Ansatzes auf unterschiedliche Anwendungsfälle. Drei definierte Szenarien liefern den Nachweis, dass der Ansatz ohne Anpassungen eine Prognose auf Basis unterschiedlicher Sensorquellen ermöglicht. Eine generelle Übertragbarkeit ist jedoch nicht gewährleistet, da hinsichtlich einer äußeren Belastung Einschränkungen vorzunehmen sind.

Im Rahmen der dritten Fragestellung wird eine wirtschaftliche Betrachtung durchgeführt. Dabei wird analysiert, ob eine Instandhaltung auf Basis des entwickelten Algorithmus einen Vorteil gegenüber einem herkömmlichen Ansatz bietet. Zu diesem Zweck werden die Systemkosten pro Zeiteinheit betrachtet, die sich aus fiktiven Kosten für präventive und korrektive Instandhaltungsmaßnahmen berechnen. Das Ergebnis dieser Gegenüberstellung ist, dass eine Halbierung der Systemkosten und eine Verringerung der ungeplanten Ausfälle möglich sind, wenn ein Austausch auf Basis der prognostizierten Restlebensdauer stattfindet.

Mit dem Ziel, die Untersuchungen unter realistischen Rahmenbedingungen durchzuführen, zieht die vorliegende Arbeit reale Schadensverläufe einer Beispielkomponente heran. Diese wurden mithilfe eines Prüfstandes erhoben, der die Erfassung des Degradierungsprozesses von Lagerelementen eines Asynchronmotors ermöglicht. Zur Generierung einer Datenbasis dienten die Phasenströme des Motors sowie die am Gehäuse gemessenen Vibrationen.

Abstract

The increasing digitalisation allows companies to implement innovative maintenance approaches. In predictive maintenance, for example, a comprehensive and continuous assessment of the condition of a technical system is carried out on the basis of sensor data. Faulty behaviour can be diagnosed at an early stage and the time of failure can be predicted. In this way, necessary maintenance activities can be planned efficiently. The implementation of predictive maintenance requires the development of innovative algorithms. This motivates the goal of the present work to develop, implement and evaluate a data-based algorithm. The focus is on the development of an approach to diagnose the degradation of a system. Inaccuracies in this step lead to a faulty prognosis and thus to incorrectly planned maintenance tasks.

On the basis of historical damage progressions, data-based algorithms identify and model correlations between the state of the system and features derived from the sensor signals. A challenge here is that the relevance of features varies between different damage progressions due to the stochastics of degradation processes. This circumstance renders uniform modelling more difficult. The algorithm proposed in this thesis analyses historical damage processes within a database using hierarchical cluster analysis. This enables the identification and grouping of comparable degradation processes. Within these groups, data-based algorithms can better identify relevant features and model correlations. For this purpose, an algorithm is proposed that allows the automatic identification and rating of features based on historical data. The estimation of the condition is performed in two steps. First of all, the most similar group to the current damage progression is determined, then the condition is evaluated on the basis of suitable features.

This thesis deals with three research questions. The first concerns the influence of the approach on prognosis. A comparison with a comparative algorithm shows that the grouping of damage processes has a positive influence on the condition assessment. As a result, the accuracy of the remaining useful lifetime prognosis can be increased and uncertainties of the prediction reduced.

The second research question examines the transferability of the approach to different applications. By setting up three defined scenarios, it was possible to prove that the approach enables a prognosis based on different sensor sources without adjustments. However, a general transferability is not guaranteed, since restrictions are made with regard to external loads.

In the third question, an economic analysis is carried out. It is analyzed whether maintenance based on the developed algorithm offers an advantage over a conventional approach. For this purpose, the system costs per time unit are taken into account, which are calculated from fictive costs for preventive and corrective maintenance tasks. It can be shown that it is possible to halve system costs and reduce unplanned downtime if replacement takes place on the basis of the predicted remaining lifetime.

With the aim of carrying out the investigations under realistic conditions, the present work uses real damage progressions of an example component. These were obtained by means of a test rig that allowed the degradation process of bearing elements of an asynchronous motor to be recorded. The phase currents of the motor and the vibrations measured at the housing were used to generate a database.

Danksagung

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter im Zeitraum zwischen 2012 und 2017 am Institut für Flugsysteme und Regelungstechnik der TU Darmstadt unter Leitung von Herrn *Prof. Dr.-Ing. Uwe Klingauf*. Ihm, als meinem Doktorvater, gebührt mein besonderer Dank sowohl für die vielen Freiheiten, die er mir bei der Wahl und Bearbeitung meines Themas lies, als auch für das entgegengebrachte Vertrauen.

Für die Übernahme des Koreferats und das Interesse an meiner Arbeit danke ich Herrn *Prof. Dr.-Ing. Joachim Metternich*.

Bei all den Kollegen, die ich während meiner Tätigkeiten kennengelernt habe, bedanke ich mich für die angenehme Atmosphäre am Institut und für die vielen schönen Stunden, die wir gemeinsam in und abseits der Universität verbracht haben. Insbesondere gilt mein Dank *Christoph Anger* und *Alexander Kählert* für die vielen freundschaftlichen Gespräche und intensiven Diskussionen über die Diagnose und Prognose von technischen Systemen sowie über die Badewannenkurve. So sind in der Zeit an der Universität enge Freundschaften entstanden.

An dieser Stelle gilt mein Dank auch meinen Kollegen *Simon Mehringskötter* und *Henrik Heier* für die kritische Auseinandersetzung mit meiner Dissertation und die dadurch entstandenen Anregungen. Auch bedanke ich mich bei den vielen Studierenden, die durch Abschlussarbeiten und Studienprojekte, zu dieser Dissertation beigetragen haben. Besonders hervorheben möchte ich *Benjamin Weymer* für die Unterstützung während der experimentellen Untersuchungen. Darüber hinaus möchte ich mich auch bei *Sebastian Stern* für die Hilfe beim Aufbau des Prüfstandes bedanken.

Abschließend möchte ich meiner Familie und meinen Freunden im besonderen Maße danken, die mir während des langen und nicht selten holprigen Weges bis hin zum Abschluss dieser Dissertation immer zur Seite gestanden haben. Meiner Lebensgefährtin *Esther Kolbe* danke ich, dass sie mich stets ermutigt hat sowie mir beim Schreiben den Rücken freigehalten und somit maßgeblich zum Gelingen dieser Dissertation beigetragen hat.

Darmstadt, im August 2018

Christian Preusche



Inhaltsverzeichnis

Nomenklatur	xi
1 Einleitung	1
1.1 Zielsetzung und Vorgehensweise	2
1.2 Aufbau der Arbeit	3
2 Instandhaltung technischer Systeme	5
2.1 Grundbegriffe der Instandhaltung	5
2.2 Arten der Instandhaltung	7
3 Datenbasierte PHM Systeme	13
3.1 Architektur eines PHM Systems	13
3.1.1 Modellbasierte und Datenbasierte Systeme	15
3.1.2 Anwendungsgebiete	16
3.2 Datenerfassung	18
3.3 Datenverarbeitung und Generierung von Merkmalen	19
3.3.1 Reduktion von Merkmalen	21
3.4 Fehlerdiagnose	23
3.4.1 Unüberwachtes Lernen	25
3.4.2 Kennwerte zur Bewertung der Diagnosefähigkeit	26
3.5 Fehlerprognose	27
3.5.1 Kennwerte zur Bewertung der Prognosefähigkeit	30
3.6 Erzeugen einer Datenbasis	34
3.7 Problemstellung und Beitrag der Arbeit	35
4 Konzept des PHM Systems	37
4.1 Definition der Systemgrenze und Schnittstellen	37
4.2 Algorithmus zur Zustandsbewertung	39
4.2.1 Klassifikation des Schadenszustands	42
4.2.2 Zuordnung und Klassifikation der Schadensgruppen	48



4.3	Algorithmus zur Restlebensdauerprognose	51
4.4	Generierung einer Handlungsempfehlung	53
4.5	Vergleichsalgorithmus	55
4.6	Zusammenfassung	56

5 Verifikation am Anwendungsfall eines Asynchronmotors 59

5.1	Testumgebung	59
5.1.1	Verwendete Messtechnik	60
5.1.2	Abgrenzung zu bestehenden Prüfständen	61
5.2	Experimente zur Untersuchung von Lagerschäden	62
5.2.1	Generierung einer Datenbasis	65
5.3	Verifikation des PHM Systems	68
5.3.1	Merkmalsselektion und Klassifikation des Schadenszustands	69
5.3.2	Gruppierung und Klassifikation von Schadensverläufen	73
5.3.3	Prognose der Restlebensdauer	77
5.4	Zusammenfassung	80

6 Methode zur Bewertung von PHM Systemen 83

6.1	Bewertungskonzept	83
6.2	Zeitbasierter Vergleichsalgorithmus	86
6.3	Bewertung des Austauschzeitpunkts	88

7 Untersuchung der Leistungsfähigkeit 91

7.1	Prognosefähigkeit	91
7.1.1	Ergebnisse	93
7.1.2	Diskussion	96
7.2	Übertragbarkeit	102
7.2.1	Ergebnisse	103
7.2.2	Diskussion	104
7.3	Wirtschaftliche Betrachtung	105
7.3.1	Ergebnisse	106
7.3.2	Diskussion	109
7.4	Zusammenfassung	113

8 Fazit und Ausblick 115

8.1	Inhalt der Arbeit und Fazit	115
8.2	Weiterführende Arbeiten	119

Literaturverzeichnis	121
A Trainingsprozess des PHM Systems	137
B Training des Bayes-Klassifikators	139
C Daten der Clusteranalyse	141
D Messkonzept des Prüfstands	143
E Referenzmessungen	145
F Durchgeführte Experimente	147
G Berechnung der Fehlerfrequenzen	149
H Ausfallverhalten des Motors	151
I Leistungskennwerte	153



Nomenklatur

Skalare

Notation	Einheit	Beschreibung
a	[h]	Weibull Skalenparameter
b	[-]	Weibull Formparameter
c	[€]	Kosten für präventive oder korrektive Maßnahmen
r	[h]	Prognostizierte Restlebensdauer
t	[h]	Zeiteinheit
w	[-]	Kriterium zur Bewertung der Merkmalsselektion
z	[-]	Schadenzustand
B	[h]	Zeitbereich
C	$[\frac{€}{h}]$	Systemkosten pro Zeiteinheit
G	[-]	Anzahl an Schadensgruppen
I	[-]	Anzahl an Prognosen pro Testdatensatz
J	[-]	Anzahl an Schadensverläufen einer Datenbasis
K	[-]	Anzahl an Merkmalsvektoren eines Datensatzes
M	[-]	Dimension eines Merkmalsvektors
N	[-]	Dimension eines reduzierten Merkmalsvektors
R	[h]	Wahre Restlebensdauer
S	[-]	Erreichte Punktzahl eines Algorithmus
U	[-]	Anzahl an Tests innerhalb der Merkmalsselektion
V	[-]	Verhältnis
W	[-]	Kriterium zur Bewertung der Merkmalsselektion
Z	[-]	Anzahl an definierten Schadenszuständen
α	[-]	Größe des Fehlerbandes (Prognosehorizont)
β	[-]	Anteil der prognostizierten PDF im Fehlerband
δ	[-]	Parameterkonstellation
ϵ	[%]	Abbruchbedingung bei der Merkmalsselektion
ζ	[-]	Schwellwert der hierarchischen Clusteranalyse
λ	[-]	relative Lebensdauer
μ	[-]	Erwartungswert

Fortsetzung auf nächster Seite

Fortsetzung von vorheriger Seite

Notation	Einheit	Beschreibung
σ	[-]	Standardabweichung
Δ	[h]	absoluter Fehler der Restlebensdauerprognose

Vektoren und Matrizen

Notation	Beschreibung
\mathbf{g}	Gewichtungsvektor
\mathbf{v}	Faltungsvektor
\mathbf{T}	Transformationsmatrix
ϕ	Merkmalsvektor
ψ	Klassenvektor
Φ	Merkmalsmatrix
Ψ	Klassenmatrix

Superskripte

Notation	Beschreibung
'	Transformiert
~	Schätzung eines Klassifikators
-	Reduzierter Vektor

Subskripte

Notation	Beschreibung
c	Kostenverhältnis (zeitbasierter Ansatz zu PHM System)
e	Fensterlänge
g	Schadensgruppe
i	Prognose
j	Datensatz
k	Merkmalsvektor
$korr$	Kosten einer korrektiven Maßnahme
kp	Kostenverhältnis (korrektive zu präventive Maßnahme)

Fortsetzung auf nächster Seite

Notation	Beschreibung
m	Merkmal
opt	optimal
pr	Kosten einer präventiven Maßnahme
q	Iteration des Selektionsalgorithmus
u	Test innerhalb Merkmalsselektion
wbl	Weibull
x	Index der ersten Schadensgruppe
y	Index der zweiten Schadensgruppe
z	Schadenzustand
A	Austausch
EoL	Ausfallzeitpunkt
M	Median der Größe
P	Start einer Prognose
PDF	Wahrscheinlichkeitsdichtefunktion
SF	Sicherheitsfenster
SG	Schadensgruppe
SZ	Schadenzustand
T	Testdatensatz
50	50 %-Perzentil

Funktionen

Notation	Beschreibung
$f(t)$	Wahrscheinlichkeitsdichtefunktion
$F(t)$	Verteilungsfunktion
$P(A B)$	Wahrscheinlichkeit des Eintretens von Ereignis A unter der Bedingung, dass Ereignis B eingetreten ist
$P(A)$	Wahrscheinlichkeit des Eintretens von Ereignis A
$K(\mathbf{a})$	Entscheidungsfunktion (Klassifikator)

Acronyms

CDF	Cumulative Distribution Function	MCSA	Motor Current Signature Analysis
EoL	End Of Life	PCA	Principal Component Analysis
FP	False Positive	PDF	Probability Density Function
FN	False Negative	PH	Prognosehorizont
FFT	Fast Fourier Transform	PHM	Prognostics and Health Management
RUL	Remaining Useful Lifetime	SVM	Stützvektormethode
NASA	National Aeronautics and Space Administration	STFT	Short-Time Fourier Transform
KNN	Künstliche Neuronale Netzwerke	TP	True Positive
MAD	Mean Absolute Deviation from median	TN	True Negative
MAPE	Mean Absolute Percentage Error	UUT	Unit Under Test

1 Einleitung

Die zunehmende Digitalisierung erfasst von der Idee, über die Entwicklung, Fertigung, Nutzung und Wartung, bis hin zum Recycling alle Lebensphasen eines Produktes. Dieses ermöglicht Unternehmen, getrieben durch den ständig wachsenden Druck im Wettbewerb um Qualität und Produktivität, immer effizientere Instandhaltungsstrategien zu entwickeln und umzusetzen. Anhand von detaillierten und während des Betriebes verfügbaren Daten kann eine umfassende und konsequente Bewertung des Zustands eines technischen Systems realisiert werden [Sen16]. Mit intelligenteren Monitoring- und Entscheidungsprozessen wird die Grundlage geschaffen, Maßnahmen zur Instandhaltung nur durchzuführen, wenn der Zustand es tatsächlich erfordert. Dadurch wird das Ziel verfolgt, bei einer gleichbleibenden oder verbesserten Zuverlässigkeit und Verfügbarkeit eines technischen Systems die Instandhaltungskosten zu reduzieren.

Für die Umsetzung einer zustandsorientierten Instandhaltung stellen die Fehlerdiagnose und die Fehlerprognose zwei Schlüsseltechnologien dar. Die Fehlerdiagnose zielt darauf ab, anormale Abweichungen eines Prozesses im laufenden Betrieb zu erkennen, die Fehlerursache zu isolieren und anschließend zu bewerten. Auf Basis dieser Informationen wird bei der Fehlerprognose eine in die Zukunft gerichtete Vorhersage des Degradierungsprozesses durchgeführt; scheinbare Zufallsentwicklungen eines Schadens werden dadurch kalkulierbar gemacht [RMM09]. Mit diesem Wissen ist eine Aussage über die verbleibende Restlebensdauer eines technischen Systems möglich. Zudem können daraus Handlungsempfehlungen zur Anpassung der Wartung an sich verändernde Rahmenbedingungen oder unvorhergesehene Ereignisse abgeleitet werden. Zusammengefasst wird diese Abfolge von Vorgängen als *Prognostics and Health Management*, kurz PHM, bezeichnet [PJ10].

Bei der Entwicklung von PHM Systemen zur Unterstützung des Instandhaltungsprozesses werden unterschiedliche Strategien verfolgt: Die modellbasierte Herangehensweise verwendet ein mathematisches Modell, welches im Vorfeld anhand von physikalischen Kenntnissen des technischen Systems definiert wird. Die Nutzung von selbstlernenden Algorithmen ermöglicht bei der datenbasierten Strategie das Erkennen von Zusammenhängen ausschließlich durch die Auswertung von historischen Daten. Dadurch ist eine Diagnose und Prognose von Fehlerfällen möglich, auch wenn keine genauen Kenntnisse des zugrunde liegenden Degradierungsprozesses vorliegen.

Die Prognosefähigkeit hängt entscheidend von der Fähigkeit eines datenbasierten Algorithmus ab, den momentanen Zustand eines technischen Systems anhand von Sensordaten abzuschätzen [SG14]. Eine Fehlinterpretation beeinflusst die Genauigkeit und Präzision der Restlebensdauerprognose und kann zu ungeplanten Ausfällen führen. Insbesondere bei sicherheitsrelevanten Komponenten entsteht dadurch ein Risiko. Bei vielen Anwendungen stellt die Aufgabe der Zustandsbewertung jedoch eine große Herausforderung dar. Die stochastische Charakteristik vieler Schadensverläufe (z. B. Lagerschäden einer Drehstrommaschine) erschwert für datenbasierte Algorithmen das Identifizieren und Modellieren von Zusammenhängen innerhalb der Datenbasis. Als Konsequenz reduziert sich die Güte der Zustandsbewertung.

1.1 Zielsetzung und Vorgehensweise

Die vorliegende Arbeit greift die Problematik der Bewertung des Zustands eines technischen Systems auf. Zu diesem Zweck wird ein datenbasiertes PHM System entwickelt und implementiert. Der Schwerpunkt liegt dabei auf der Umsetzung eines Algorithmus für die Zustandsbewertung. Dieser basiert auf einem neu entwickelten Ansatz, der es ermöglicht mithilfe einer hierarchischen Clusteranalyse ähnliche Schadensverläufe innerhalb der Datenbasis zu erkennen und zu gruppieren. Dadurch wird das Ziel verfolgt, relevante Zusammenhänge zur Zustandsbewertung besser identifizieren und genauer modellieren zu können als ohne eine Gruppierung. Auf Grundlage des implementierten PHM Systems ist das Ziel der Arbeit, die folgenden drei Forschungsfragen zu beantworten.

Die erste Frage beschäftigt sich damit, ob durch die Integration des neuen Ansatzes die Genauigkeit der Restlebensdauerprognose erhöht werden kann. Zu diesem Zweck werden ausgewählte Leistungskennwerte ermittelt und diese den Ergebnissen eines Vergleichsalgorithmus gegenübergestellt. Im Rahmen der zweiten Fragestellung wird analysiert, inwieweit der entwickelte Algorithmus es erlaubt, dass das PHM System auf andere Anwendungsszenarien ohne kostenintensive Anpassungen übertragen werden kann. Anhand der Nutzung unterschiedlicher Sensorquellen werden hierfür drei Szenarien definiert und die Veränderung der Performanz untersucht. Im Rahmen der dritten Fragestellung wird eine wirtschaftliche Betrachtung durchgeführt. Dabei wird analysiert, ob das entwickelte PHM System einen Vorteil gegenüber einem konventionellen Wartungsansatz bietet. Für die Beantwortung der Fragestellungen unter möglichst repräsentativen Rahmenbedingungen werden mittels eines entsprechend instrumentierten Prüfstandes reale Messdaten eines Degradierungsprozesses erhoben und eine umfangreiche Datenbasis für die Untersuchungen generiert.

1.2 Aufbau der Arbeit

Die vorliegende Arbeit ist in acht Kapitel gegliedert. In Abbildung 1.1 ist der Aufbau dargestellt und es wird verdeutlicht, welche zentrale Fragestellung dem jeweiligen Kapitel zugrunde liegt. Nach der Einleitung folgt in Kapitel 2 zunächst eine Einführung in die Methoden zur Instandhaltung von technischen Systemen, außerdem wird die Notwendigkeit von PHM Systemen in Unternehmen erörtert. Das nachfolgende Kapitel 3 beschäftigt sich mit dem Stand der Technik von datenbasierten PHM Systemen. Dabei werden die wesentlichen Elemente von der Messdatenerfassung bis zur Restlebensdauer betrachtet und hervorgehoben, an welchen Stellen Probleme heutiger PHM Systeme bestehen. Diese werden in Kapitel 4 aufgegriffen und der entwickelte Lösungsansatz präsentiert. Nachdem die Systemgrenze definiert ist, wird auf die Funktionsweise des Algorithmus zur Bewertung des Zustands eingegangen. Abschließend wird der verwendete Ansatz zur Restlebensdauerprognose und Generierung einer Handlungsempfehlung vorgestellt.

Die Verifikation des PHM Systems wird in Kapitel 5 beleuchtet. Zu diesem Zweck wird zunächst die Testumgebung beschrieben und im Anschluss darauf eingegangen, wie die verwendete Datenbasis generiert wurde. Die anschließende Verifikation findet in drei Schritten statt, wobei jeder Schritt einen anderen Aspekt des Ansatzes näher beleuchtet. In Kapitel 6 wird das verwendete Konzept zur Bewertung von PHM Systemen vorgestellt, welches in Kapitel 7 zur Untersuchung der Leistungsfähigkeit angewendet wird. Daraufhin werden die Ergebnisse der Untersuchung zur Prognosefähigkeit, Übertragbarkeit und der wirtschaftlichen Betrachtung vorgestellt und erörtert. Abschließend werden in Kapitel 8 die gewonnenen Erkenntnisse in einem Fazit zusammengefasst und ein Ausblick auf zukünftige Forschungsarbeiten auf diesem Gebiet gegeben.

<p>Kapitel 1: Einführung</p> <ul style="list-style-type: none"> • Was ist das Ziel der Arbeit? • Was ist die Motivation der vorliegenden Arbeit? • Welche Forschungsfragen stehen im Fokus?
<p>Kapitel 2 und 3: Stand der Technik</p> <ul style="list-style-type: none"> • Welche Defizite und Probleme können bei heutigen PHM Systemen identifiziert werden? • Welche Instandhaltungsarten gibt es und wieso werden PHM Systeme benötigt? • Wie sind der grundsätzliche Aufbau und die Funktionsweise eines PHM Systems? • Wo liegen aktuelle Forschungsschwerpunkte im Gebiet der Fehlerdiagnose und -prognose?
<p>Kapitel 4: Konzept des PHM Systems</p> <ul style="list-style-type: none"> • Welcher Ansatz wird zur Problemlösung vorgeschlagen? • Wie ist die Systemgrenze definiert? • Wie wird die Zustandsbewertung für ein technisches System durchgeführt? • Wie werden die Restlebensdauer und Handlungsempfehlung generiert?
<p>Kapitel 5: Verifikation am Anwendungsfall eines Asynchronmotors</p> <ul style="list-style-type: none"> • Kann dem entwickelten Ansatz vertraut werden? • Funktioniert der entwickelte Algorithmus wie erwartet? • Wie wird die Datenbasis für die Untersuchungen generiert?
<p>Kapitel 6: Methode zur Bewertung von PHM Systemen</p> <ul style="list-style-type: none"> • Wie kann die Leistungsfähigkeit von PHM Systemen bewertet und einander gegenübergestellt werden?
<p>Kapitel 7: Untersuchung der Leistungsfähigkeit</p> <ul style="list-style-type: none"> • Kann die Prognosefähigkeit durch den entwickelten Ansatz verbessert werden? • Kann der Ansatz auf andere Anwendungsszenarien übertragen werden? • Ist ein wirtschaftlicher Vorteil gegenüber einem konventionellen Ansatz gegeben?
<p>Kapitel 8: Zusammenfassung</p> <ul style="list-style-type: none"> • Was sind die gewonnenen Erkenntnisse dieser Arbeit? • Wo gibt es Ansatzpunkte für zukünftige Forschungsthemen?

Abbildung 1.1.: Struktur der Arbeit und zentrale Forschungsfragen der jeweiligen Kapitel

2 Instandhaltung technischer Systeme

Die Motivation dieses Kapitels liegt darin, die Notwendigkeit von Algorithmen zur Fehlerdiagnose und -prognose bei der Instandhaltung technischer Systeme aufzuzeigen. Zu diesem Zweck werden in Abschnitt 2.1 zunächst wesentliche Grundbegriffe eingeführt und die Zielsetzung der Instandhaltung definiert. Im darauffolgenden Abschnitt wird dargestellt, welche Arten der Instandsetzung derzeit in der Industrie Anwendung finden und welche Stellung dabei die Fehlerdiagnose und -prognose einnimmt. Diese werden anschließend in Kapitel 3 näher beleuchtet.

2.1 Grundbegriffe der Instandhaltung

Der allgemeine Begriff des technischen Systems umfasst in der Technik die schlecht abgrenzbaren Ausdrücke Apparate, Geräte oder Maschinen. Es ist gekennzeichnet durch die Funktion Material, Energie und/oder Informationen umzuwandeln, zu transportieren und/oder zu speichern [Czi15, S. 11]. Das Versagen von technischen Systemen wird anhand der Ausfallrate veranschaulicht. Diese beschreibt, wie viele Ausfälle eines Systems innerhalb einer definierten Zeitspanne zu erwarten sind und wird über der Lebensdauer dargestellt. In Abbildung 2.1 ist ein idealtypisches Ausfallverhalten gezeigt. Aufgrund der Form wird von der Badewannenkurve gesprochen.

Die Ausfallursache wird in Früh-, Zufalls- und Altersausfälle unterteilt. Ausfälle eines Systems in der ersten Phase beruhen in der Regel auf Montage-, Konstruktions- oder Fertigungsfehlern und werden als Kinderkrankheiten bezeichnet. Eine Reduzierung der Frühausfälle wird durch eine Steigerung der Qualitätskontrollen oder Burn-In-Tests, bei denen Komponenten vor der Auslieferung unter hoher Belastung geprüft werden, erreicht. Zufällige Ausfälle treten unabhängig von dem Alterungsprozess auf und sind meist auf Bedienungsfehler oder zeitweise Überbeanspruchung zurückzuführen. Aufgrund unvermeidbarer, regulärer Abnutzung eines Systems (z. B. durch Verschleiß, Materialermüdung oder Korrosion) steigt mit zunehmender Lebensdauer die Wahrscheinlichkeit eines altersbedingten Ausfalls. Es wird vom Abbau oder der Degradation des Abnutzungsvorrats gesprochen. [Alc00, S. 12-16]

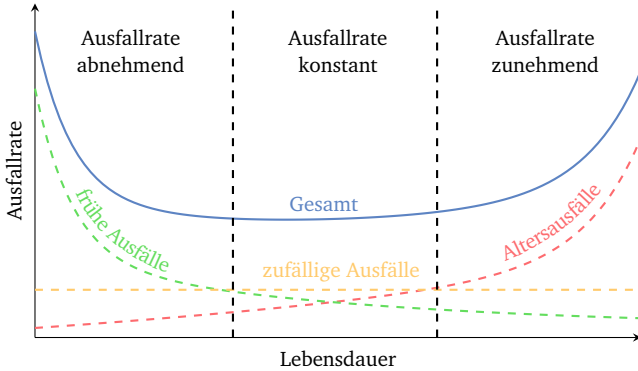


Abbildung 2.1.: Darstellung der Ausfallrate über der Lebensdauer eines technischen Systems und Einteilung der Ausfallursachen in Früh-, Zufalls- und Altersausfälle, angelehnt an [Alc00, S. 14]

Die Instandhaltung beinhaltet alle technischen und administrativen Maßnahmen, die während des Lebenszyklus zur Bewahrung des Abnutzungsvorrates oder der Rückführung in einen funktionsfähigen Zustand erfolgen. Die Instandhaltung steht als Oberbegriff für die vier Grundmaßnahmen Wartung, Inspektion, Instandsetzung und Verbesserung [Deu12]. Die Absicht von Wartungsmaßnahmen (z. B. Reinigen, Schmieren oder Nachstellen) ist, den Abbau des Vorrates zu verlangsamen. Alle Tätigkeiten, die zur Feststellung und Beurteilung des Ist-Zustands dienen, fallen in den Bereich der Inspektion (z. B. Messen, Prüfen oder Diagnostizieren). Die Instandsetzung beinhaltet Maßnahmen, die das System in den funktionsfähigen Bereich zurückführen (z. B. Austauschen oder Ausbessern von Komponenten). Das Ziel der Verbesserung ist durch eine Weiterentwicklung des Systems die Funktionssicherheit (Erhöhung des maximalen Abnutzungsvorrats) gegenüber des Ausgangszustands zu steigern. [Paw16, S. 17]

In Abbildung 2.2 sind ein idealtypischer Verlauf der Abnutzungskurve eines technischen Systems sowie die Auswirkung der vier Grundmaßnahmen dargestellt. Nach der Herstellung, Instandsetzung oder Verbesserung befindet sich das System zunächst im Ausgangszustand. Unter festgelegten Bedingungen erfüllt es im funktionsfähigen Bereich seine vorgesehene Funktion. Sofern keine Maßnahmen zur Instandhaltung getroffen werden, ist der Abnutzungsvorrat zu einem bestimmten Zeitpunkt aufgebraucht. Es wird vom Ausfall des Systems gesprochen. Es befindet sich anschließend in einem fehlerhaften Zustand und ist nicht mehr funktionsfähig.

Um das System wieder in einen funktionsfähigen Zustand zu überführen, ist eine ungeplante Instandsetzung nötig.

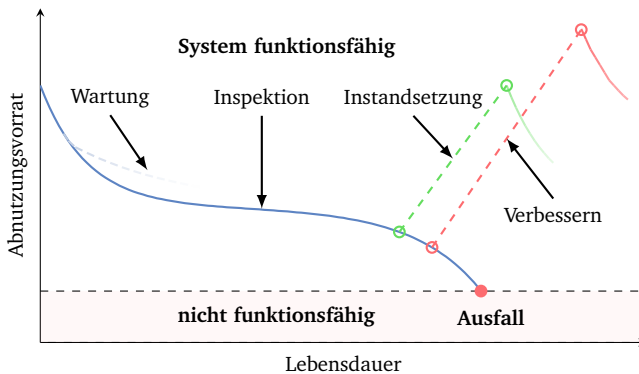


Abbildung 2.2.: Idealtypischer Verlauf einer Abbaukurve des Abnutzungsvorrats, angelehnt an [Deu12]

Nach [Lei14, S. 15-16] sollen mit den Instandhaltungsmaßnahmen die folgende Primärziele erreicht werden:

- Steigerung der *Sicherheit*:
Es darf keine Gefahr von dem System ausgehen.
- Erhöhung der *Verfügbarkeit*:
Das System muss jederzeit den Betrieb aufnehmen können.
- Erhöhung der *Zuverlässigkeit*:
Das System muss den Betrieb störungsfrei durchführen können.
- Erhalten des *Werts*:
Das System soll eine hohe Restlebenserwartung besitzen.

Dabei werden die Ziele entweder als untereinander gleichwertig erachtet oder individuell priorisiert. Mögliche Nebenziele sind nach [Paw16, S. 55] die Verbesserung der Produktqualität und Kapazitätsauslastung oder die Verkürzung der Auftragsabwicklungszeit.

2.2 Arten der Instandhaltung

Durch die Wahl einer Instandhaltungsart wird definiert, welche Maßnahmen nach Inhalt, Methodik und Umfang in einer festgelegten zeitlichen Reihenfolge umge-

setzt werden [Sch10, S. 107-108]. In Abbildung 2.3 ist eine Gliederung der Instandhaltungsarten dargestellt. In der Literatur wird eine Vielzahl von weiteren Herangehensweisen vorgestellt, welche auf die dargestellten Grundarten zurückgeführt werden können [Paw16, S. 173]. Grundsätzlich wird nach [Deu12] zwischen zwei Arten unterschieden: die präventive und korrektive Instandhaltung. In der Literatur werden als alternative Begriffe auch die Bezeichnungen der proaktiven oder reaktiven Instandhaltung verwendet [Sch10, S. 108].

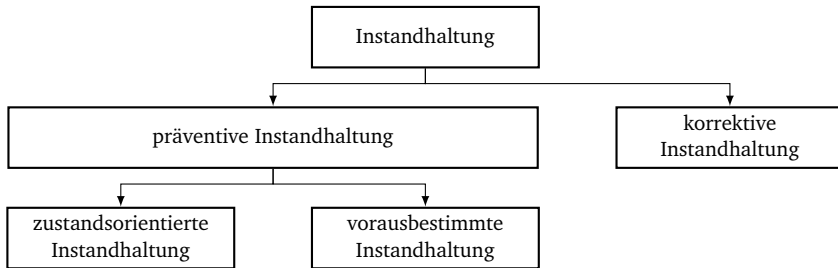


Abbildung 2.3.: Gliederung der Instandhaltungsarten, angelehnt an [Deu12]

Bei der korrektiven Instandhaltung handelt es sich um die einfachste Herangehensweise. Maßnahmen werden bewusst erst nach dem Verlust der Funktionsfähigkeit ausgeführt. Die maßgeblichen Vorteile dieses Konzepts sind, dass die maximale Lebensdauer des Bauteiles ausgenutzt wird und der Planungsaufwand vernachlässigbar ist. Ein hoher Anteil an kurzfristigen Maßnahmen und den daraus resultierenden Stillstandszeiten aufgrund nicht vorhersehbarer Ausfälle wird in Kauf genommen. Diese Herangehensweise sollte verfolgt werden, wenn eine schnelle Verfügbarkeit aller Instandhaltungsressourcen gewährleistet ist, redundante Systeme vorhanden sind oder es sich um kein sicherheitskritisches Bauteil handelt. Ein Beispiel ist die Instandhaltung von herkömmlichen Fahrzeugscheinwerfern. [Lei14, S. 19-21]

Mit dem Ziel einem Ausfall vorzubeugen, wird bei der präventiven Instandhaltung ein Austausch von verschleißanfälligen Komponenten durchgeführt, bevor der Abnutzungsvorrat aufgebraucht ist. Dadurch kann die Leistungsfähigkeit und Zuverlässigkeit von technischen Systemen gesteigert sowie Kosten aufgrund ungeplanter Instandhaltungsarbeiten reduziert werden. Demgegenüber steht, dass durch die Bestimmung eines idealen Austauschzeitpunkts Planungsaufwand entsteht. Wird dieser zu früh gewählt, kann die Restnutzungsmöglichkeit nur bedingt ausgeschöpft werden. Andersherum steigt die Wahrscheinlichkeit eines ungeplanten Systemausfalls. [Sch10, S. 108]

Die vorausbestimmten und zustandsorientierten Instandhaltungsarten stellen zwei Herangehensweisen dar, den Austauschzeitpunkt eines technischen Systems zu bestimmen. Bei Ersterem werden Maßnahmen in regelmäßigen Abständen ausgeführt, die auf Erfahrungswerten oder Empfehlungen vom Hersteller basieren [AK12]. Für die Abschätzung eines optimalen Wartungszeitpunkts kommen statistische Modelle zum Einsatz. Über unterschiedliche Verteilungsformen werden historische Ausfalldaten eines Systems abgebildet und der wahrscheinlichste Ausfallzeitpunkt bestimmt [Sch10, S. 107-108]. Ein Nachteil dieses Vorgehens ist, dass der wahre Zustand des Systems für die Planung nicht berücksichtigt wird und als Konsequenz unnötige Maßnahmen durchgeführt werden [Mis08]. Demgegenüber ist außer den Ausfallzeitpunkten kein Systemwissen nötig, weshalb der Ansatz in der Praxis einfach umgesetzt werden kann und in Unternehmen etabliert ist [EER16]. Anstatt der Betriebszeit wird in vielen Fällen eine Produktionsmenge oder eine geleistete Arbeit zur Planung der Intervalle verwendet. Beispielsweise erfolgt der Motorölwechsel eines Pkws auf Grundlage von Herstellerempfehlungen nach einer bestimmten Fahrleistung oder zeitlicher Alterung [Lei14, S. 18].

Ein wesentlicher Aspekt der zustandsorientierten Instandhaltung ist die Inspektion. Durch regelmäßige oder dauerhafte Überwachung des technischen Systems wird der verbleibende Abnutzungsvorrat festgestellt und die Maßnahmen entsprechend geplant [Sch10, S. 108]. Der Inspektionsaufwand schwankt zwischen einfachem Hinschauen, der Demontage eines Bauteils oder der Zuhilfenahme von diagnostischen Technologien (z. B. Temperatur- oder Vibrationsmessung) [Lei14, S. 18-19]. Durch die Informationen über den Systemzustand kann die Lebensdauer eines Systems im Gegensatz zur vorausbestimmten Instandhaltung optimal ausgenutzt werden. Je genauer die Bestimmung ist, desto höher ist der Nutzen. Ein Nachteil sind hohe Anschaffungs- und Entwicklungskosten, die bei einer Zustandsüberwachung mittels Sensoren entstehen. Zudem wird in vielen Fällen ein umfangreiches Wissen über das Systemverhalten vorausgesetzt. [JLB06]

Während die Diagnose die Erfassung des momentanen Ist-Zustands ermöglicht, erlaubt eine Fehlerprognose, also eine in die Zukunft gerichtete Schätzung des Zustands unter Berücksichtigung äußerer Bedingungen, die Bestimmung der Restlebensdauer (engl. *Remaining Useful Lifetime*, kurz RUL) eines Systems. Bei einer Unterstützung der Instandhaltung durch Prognosen wird anstatt zustandsorientierter ebenfalls von voraussagender oder prädiktiver Instandhaltung gesprochen [Mis08]. Je genauer eine Schätzung der RUL gelingt, desto zielgerichteter kann eine Maßnahme ohne erhebliche Produktionsstörung durchgeführt werden. Ein weiterer Nutzen ist ein optimiertes Ersatzteilmanagement, da Reserveteile auf den Punkt angefordert werden und nicht ungenutzt Lagerplatz belegen. Der größte Vorteil einer durch Fehlerprognosen unterstützten Instandhaltung liegt insbesondere bei den

altersbedingten Ausfällen (vgl. Abbildung 2.1). Aufgrund regulärer technischer Abnutzungen tritt in dieser Phase eine messbare Degradierung des Systems auf, die mithilfe des Wissens über die Verschleißcharakteristiken prognostizierbar gemacht wird. Dieses gilt insbesondere für Funktionshauptkomponenten wie z. B. Kugelgewindetriebe, Führungssysteme und Spindellagerungen. [Hod09, S. 140-141]

Den idealen Instandhaltungsaufwand betreibt ein Unternehmen, wenn es erreicht, dass die Summe aus Ausfall- und Instandhaltungskosten minimiert wird. In Abbildung 2.4 ist dieser Zusammenhang veranschaulicht. Wird ein korrekatives Konzept verfolgt, also das technische System mit minimalem Aufwand betrieben, steigt für ein Unternehmen die Gefahr eines ungeplanten Ausfalls, sodass die Folgekosten überproportional ansteigen. Diese umfassen nicht nur die Kosten des Austausches und der Betriebsunterbrechung, sondern auch Folgeschäden durch eine Minderung der Reputation oder aufgrund von Klagen, welche mit dem Ausfall verbunden sind. Je mehr Aufwand betrieben wird, desto geringer ist die Ausfallwahrscheinlichkeit. Jedoch wachsen als Konsequenz mit zunehmendem Umsetzungsgrad einer vorausbestimmten Instandhaltung die präventiven Kosten überproportional an. Durch die Verwendung einer zustandsorientierten Instandhaltung bemühen sich Unternehmen das Kostental zwischen den beiden Extremwerten zu erreichen. [Hod09, S. 137-138]

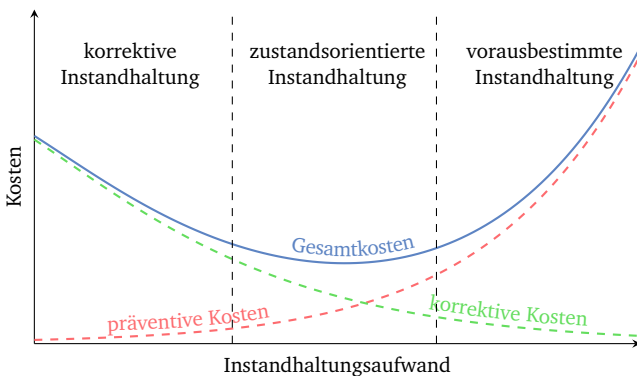



Abbildung 2.4.: Entwicklung der entstehenden Gesamtkosten über den Instandhaltungsaufwand und Zuordnung der drei Instandhaltungsarten, angelehnt an [Hod09]

Keine der vorgestellten Instandhaltungsarten ist universell einsetzbar. Dadurch hat jede Herangehensweise eine Daseinsberechtigung. Erst durch die Kombination der verschiedenen Arten ist es möglich, eine optimierte Vorgehensweise zu gestalten.



ten. Das bedeutet, dass in einem Unternehmen in der Regel verschiedene Instandhaltungsarten für unterschiedliche Anlagen, Systeme, Teilsysteme, Elemente und Komponenten koexistieren. Auf diese Art und Weise wird sich bemüht, etwaige Nachteile eines Konzepts zu umgehen. [Lei14, S. 21-26]



3 Datenbasierte PHM Systeme

Die Disziplinen, welche sich mit der Datenerfassung, Fehlerdiagnose, -prognose und der Ableitung einer Handlungsempfehlung befassen, werden unter dem Begriff *Prognostics and Health Management* (PHM) zusammengefasst. Der Schwerpunkt dieses Kapitels ist die Beschreibung der Funktionsweise eines PHM Systems. Darauf aufbauend wird dargelegt, welche Problemstellung die vorliegende Arbeit aufgreift, um einen Beitrag zur Verbesserung der Instandhaltung von technischen Systemen zu leisten.

Zunächst wird in Abschnitt 3.1 die grundsätzliche Architektur vorgestellt und auf Anwendungsbereiche eines PHM Systems eingegangen. Die Abschnitte 3.2 bis 3.5 befassen sich mit den wesentlichen Schritten, wie Merkmale aus Sensordaten eines technischen Systems gewonnen und anschließend im Rahmen der Diagnose und Prognose zu verwertbaren Informationen aufbereitet werden. Abschließend wird in Abschnitt 3.7 die Problemstellung und der Beitrag dieser Arbeit vorgestellt.

3.1 Architektur eines PHM Systems

Ein PHM System umfasst alle nötigen Schritte von der Überwachung des Zustands eines technischen Systems durch Sensoren über die Messdatenauswertung bis zur Generierung einer Handlungsempfehlung. Die grundsätzliche Struktur eines PHM Systems ist in der ISO 13374 festgelegt. Durch die Definition eines einheitlichen Standards, wird die Integration von PHM Systemen in technische Systeme und der Austausch von Informationen erleichtert. [Int10]

Die Architektur ist in Abbildung 3.1 dargestellt. Bis zur Ausgabe einer Handlungsempfehlung für die Instandhaltung werden sechs Schritte sequenziell durchlaufen. Diese können darüber hinaus in vier Ausbaustufen gegliedert werden. Die erste Stufe beinhaltet alle Technologien, die zur Ermittlung des aktuellen Zustands der betrachteten Komponente benötigt werden. Die Datenerfassung bezeichnet alle Methoden, die zum Erfassen und Speichern der Ausgaben von Sensoren einschließlich relevanter Information (z. B. Zeitstempel eines Messwerts) erforderlich sind. Anschließend werden die aufgenommenen Messdaten für die weitere Auswertung aufbereitet. Hierzu zählen Verfahren wie Filtern, Ausreißerererkennung oder Synchronisation von Messdaten unterschiedlicher Sensoren. Wichtig ist insbesondere

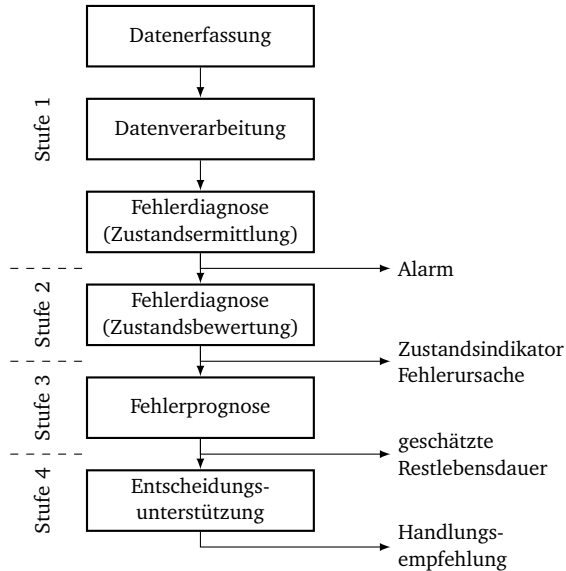


Abbildung 3.1.: Architektur eines PHM Systems, angelehnt an [VWD14, S. 29]

das Generieren von aussagefähigen Merkmalen, die sensitiv gegenüber einem fehlerhaften Verhalten sind. Im Rahmen der Zustandsermittlung findet eine erste Diagnose statt. Dabei wird das Verhalten anhand der generierten Merkmale und eines zuvor definierten Arbeitsbereiches beurteilt. Im Falle einer Überschreitung eines Schwellwerts wird ein Alarm ausgegeben. [VWD14, S. 28-31]

Während bei der Zustandsermittlung die Merkmale separat kontrolliert werden, findet bei der Zustandsbewertung eine Fusion aller Informationen statt. Ziel ist es, die Ursache eines abnormalen Verhaltens zu isolieren und anschließend zu quantifizieren. Durch die Aggregation der verfügbaren Informationen wird ein sogenannter Zustandsindikator abgeleitet, der den Zustand des betrachteten Systems auf einer definierten Skala abbildet. Ist der Indikator bestimmt, wird in der nächsten Stufe eine Ausfallprognose realisiert. Unter Berücksichtigung des bevorstehenden Belastungsprofils sowie bereits vergangener Fehlerfälle, wird eine Vorhersage der zukünftigen Fehlerentwicklung getroffen und daraus geschätzt, zu welchem Zeitpunkt der Abnutzungsvorrat aufgebraucht ist. In der letzten Ausbaustufe werden alle bisherigen Ergebnisse zusammengefasst und zu einer operationalen Information aufbereitet. Diese betreffen Maßnahmen zur Instandhaltung oder auch den Betrieb des Systems. Beispielsweise werden automatisch Ersatzteile angefordert,

um Wartungszeiten zu minimieren oder durch eine Veränderung des Nutzungsverhaltens die Belastung gemindert und somit der Abbau des Abnutzungsvorrats verzögert. [VWD14, S. 28-31]

3.1.1 Modellbasierte und Datenbasierte Systeme

Bei der Entwicklung von Algorithmen für ein PHM System wird in der Literatur zwischen verschiedenen Herangehensweisen differenziert. In Abbildung 3.2 ist eine häufig verwendete Gliederung in modellbasierte, datenbasierte und hybride Ansätze dargestellt (z. B. in [Sch05], [MZB13] und [GSS08]). Andere Forschungsarbeiten, wie [BRG02], [Vac07] und [KSH11], weichen von dieser Aufteilung ab und führen andere Arten, wie ein erfahrungsbasiertes PHM System, auf.

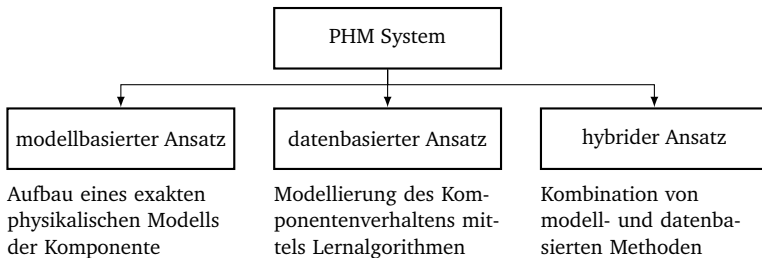


Abbildung 3.2.: Gliederung von unterschiedlichen Herangehensweisen bei der Entwicklung von PHM Systemen, angelehnt an [Sch05]

Modellbasierte Ansätze beschreiben das physikalische Systemverhalten einer Komponente durch ein Set aus mathematischen Gesetzen [Ise05]. Bei der modellbasierten Diagnose wird dieses Modellwissen für die Bildung von Residuen genutzt. Abweichungen zwischen gemessenen und simulierten Parametern dienen als Basis für die Diagnose von einem Fehlverhalten des Systems [BDDR⁺09]. In diesem Rahmen werden Filtertechniken wie das Kalman-Filter und das Partikel-Filter zur Schätzung der Modellparameter verwendet [DG13]. Eine detaillierte Einführung in die modellbasierte Diagnose ist in [Din08] und [Ise11] zu finden. Für eine Prognose der RUL ist es notwendig, das Degradierungsverhalten einer Komponente mathematisch abzubilden. Hierfür wird beispielsweise in [YH01] ein Modell für die Lebensdauerberechnung von Kugellagern vorgestellt und in [PCCC06] Gleichungen zur Vorhersage des Risswachstums in Strukturen hergeleitet. Weitere modellbasierte Prognoseansätze werden in [Jen13] und [Vac07] aufgezeigt.

Die Qualität der Ergebnisse von modellbasierten Techniken ist maßgeblich von den zugrunde liegenden Modellen abhängig. In der Regel ist es jedoch für kom-

plexe Systeme zeitaufwendig oder gar unmöglich die Wirklichkeit hinreichend exakt abzubilden. Dieses gilt insbesondere bei der Modellierung von Degradierungsprozessen, da diese nichtlinear und stochastisch ablaufen [KSH11]. Datenbasierte Diagnose- und Prognosealgorithmen umgehen diesen Nachteil, indem das Systemverhalten anhand von historischen Messdaten antrainiert wird. Dabei finden Lernalgorithmen aus dem Bereich des Maschinellen Lernens oder der Statistik Anwendung [Jen13]. Diese werden detailliert in den Abschnitten 3.4 und 3.5 behandelt. Ein Vorteil der datenbasierten Techniken ist die Vielfältigkeit der Anwendungsgebiete, da nur ein begrenztes Wissen über das betrachtete System benötigt wird. Der Gültigkeitsbereich der Methoden wird hauptsächlich durch die Verfügbarkeit von Trainingsdatensätzen beschränkt [Mik15]. Demgegenüber steht der Nachteil, dass eine umfangreiche Datenbasis für das Training der Lernalgorithmen verfügbar sein muss. Zudem handelt es sich bei vielen Ansätzen um Black-Box-Verfahren, bei denen Modelleigenschaften unbekannt sind und nicht garantiert ist, dass die im Trainingsprozess gefundene Lösung ein globales Optimum darstellt [WW12].

Sowohl das modellbasierte als auch das datenbasierte Konzept haben Vor- und Nachteile. Der hybride Ansatz bemüht sich, durch eine Kombination der beiden Konzepte die Leistungsfähigkeit zu steigern. In [BMLZ16] werden verschiedene Herangehensweise vorgeschlagen. Beim parallelen Ansatz werden die Ergebnisse des modell- und datenbasierten Algorithmus separat berechnet und anschließend fusioniert. Bei einem sequenziellen Konzept wird der datenbasierte Algorithmus verwendet, um die modellbasierte Methode zu unterstützen und somit die Genauigkeit zu verbessern.

3.1.2 Anwendungsgebiete

Die Entwicklung und Umsetzung von PHM Technologien gewinnt in vielen Branchen immer mehr an Bedeutung. Ein großer Teil der Forschungsarbeiten, wie z. B. [BMMH07], [BWES04] und [Vac07], stammen aus dem Bereich der zivilen oder militärischen Luftfahrt. Durch die Optimierung von Wartungsprozessen versprechen sich Fluggesellschaften infolge reduzierter Kosten einen Wettbewerbsvorteil, ohne dabei strenge Sicherheitsstandards zu verletzen. Auch in anderen Transportbereichen wie dem Eisenbahnsektor werden PHM Systeme vermehrt entwickelt [BMLZ16]. Ebenfalls relevant sind Anwendungen in Produktionsprozessen, die kontinuierlich laufen müssen. Um ungeplante Stillstände zu minimieren, ist diese Branche ein führender Treiber von Forschungsarbeiten [Sen16, S. 247-248]. Hierzu zählt insbesondere die Energieerzeugung, Stahlproduktion und die pharmazeutische Industrie.

Bei der Entwicklung von PHM Algorithmen stehen vielfältige Komponenten im Fokus von Forschungsarbeiten. Getriebe und Lagerelemente sind häufig zu findende Vertreter von mechanischen Systemen. In diesem Zusammenhang werden Algorithmen zur Instandhaltung von Helikoptern [Vac07, S. 134] und Windkraftanlagen [FLYW15] untersucht. Ein weiterer Bereich sind Ausfälle von Strukturen. In [OV07] wird ein PHM System vorgestellt, welches die Rissausbreitung in Schaufeln einer Turbine prognostiziert. Elektronische Komponenten stehen seltener im Fokus. In [SW07] wird das dadurch begründet, dass sich Degradierungsprozesse mechanischer Systeme aufgrund ihrer langsamen Ausbreitung besser für die Diagnose und Prognose eignen, während elektronische Bauteile ohne Vorankündigung ausfallen. Dennoch untersucht [KCBG12] beispielsweise die Prognosefähigkeit von Kondensatoren und Transistoren. In [GSS08] und [SGC09] wird ein PHM System für Batterien vorgestellt.

Eine große Anzahl an Veröffentlichungen beschäftigt sich mit Drehstrommaschinen. Aufgrund vieler Vorteile, wie eine hohe Verfügbarkeit und Leistung bei einer kompakten Bauweise, werden Drehstrommotoren in vielen Prozessen verwendet (z. B. in Werkzeugmaschinen, Förderbänder, Kränen, Elektroautos, Kompressoren, Pumpen und Lüfter). Da Drehstrommotoren die Grundlage vieler Prozesse darstellen und Ausfälle häufig mit langen Stillstandszeiten verbunden sind, ist ein Fortschritt in diesem Bereich für die Industrie von besonderem Interesse. [HZTM09]

Die Ursachen für einen Ausfall einer Drehstrommaschine kann in den meisten Fällen bei einer der drei Hauptkomponenten Stator, Rotor oder Lagerelemente gefunden werden. Die Verteilung der Ausfallwahrscheinlichkeit ist in Tabelle 3.1 festgehalten. Den größten Anteil daran haben die Lagerelemente, dessen Funktion es ist, die Last zu tragen und eine relative Bewegung zwischen Rotor und Stator zu erlauben. Kann durch natürliche Alterung oder fehlerhafte Nutzung diese Funktion nicht erfüllt werden, kommt es zu einem Ausfall. Daher spielt eine effiziente Diagnose von Lagerschäden und die Prognose der Ausfallzeit eine signifikante Rolle in der Entwicklung von PHM Systemen [Air08]. Forschungsarbeiten, die sich mit der Diagnose oder Prognose von Lagerschäden beschäftigen, sind unter anderem [SSA15], [SS05] und [LZPL17]. Aufgrund der hohen Verbreitung von PHM Systemen für Drehstrommaschinen beziehen sich viele der folgenden Konzepte und Methoden auf diesen Anwendungsfall. Zudem wird in dieser Arbeit ebenfalls eine Drehstrommaschine für die Verifikation und Untersuchung der entwickelten Algorithmen verwendet.

Tabelle 3.1.: Verteilung der Ausfallursache bei Drehstrommaschinen, angelehnt an [MTMZ12]

fehlerhafte Komponente	Ausfallwahrscheinlichkeit [%]		
	nach [BG12]	nach [O'D85, S. 853-872]	nach [AAM ⁺ 86, S. 39-46]
Lager	41	45 - 50	41
Stator	37	30 - 40	36
Rotor	10	8 - 12	9
Sonstiges	12	-	14

3.2 Datenerfassung

Die Basis eines PHM Systems ist die Datenerfassung, welche Informationen aus unterschiedlichsten Quellen zusammenträgt. Grundsätzlich wird zwischen sogenannten Ereignis- und Zustandsüberwachungsdaten unterschieden [JLB06]. Bei ereignisbasierten Daten handelt es sich um unstrukturierte Informationen über Vorgänge wie Installation, Überholung oder Ausfälle und deren Gründe sowie getroffene Gegenmaßnahmen. Die Zustandsüberwachungsdaten beinhalten dagegen die Messdaten von Sensoren. In der vorliegenden Arbeit wird nur auf Zustandsüberwachungsdaten eingegangen. Nähere Information zu ereignisorientierten Wartungssystemen finden sich in [RW11] und [RAH16].

Zustandsüberwachungsdaten können in verschiedener Form vorliegen. Nach [JLB06] werden diese in drei Kategorien gegliedert:

- Einzelne Messwerte zu einem bestimmten Zeitpunkt
- Wellenförmige Messwerte während einer Messspanne
- Mehrdimensionale Messwerte

Zu den ersten beiden Punkten zählen beispielsweise Messungen von Vibrationen, Akustik, Temperatur, Feuchtigkeit, Leistungsaufnahme sowie die Überwachung von Drücken, Ölzuständen oder des Wetters. Wichtige Vertreter von mehrdimensionalen Messdaten sind Bilder sowie Thermografie- oder Röntgenaufnahmen von Bauteilen. Für PHM Systeme von Drehstrommaschinen sind nach [AHT14], [SLNL14] und [JK11] hauptsächlich die Analyse von Vibrations-, Akustik- und Strommessungen sowie des Schmiermittels relevant.

Insbesondere für die Diagnose von Lagerschäden oder einer Exzentrizität ist die Auswertung von Vibrationen eine etablierte Technik. Dabei handelt es sich um eine sensitive Methode, da schon kleinere Schäden im Lagerelement zu einem unruhigen Lauf des Rotors und folglich zu Schwingungen am Gehäuse führen [LM06]. Es lassen sich viele Forschungsarbeiten zu diesem Thema finden, exemplarisch sind [AMB⁺13], [Bou15] und [CKTM13] zu nennen. Die Akustikmessung nutzt den an der Struktur abgestrahlten Schall für die Auswertung. Im Gegensatz zu den meisten Techniken wird diese Methode berührungsfrei angewendet. Teilweise wird in der Literatur der Akustikanalyse eine frühere Fehlerdetektion zugesprochen [HZF09]. Bei der Analyse des Schmiermittels werden die Menge und das Material von Verschleißpartikeln betrachtet. Dadurch ist es möglich einen Rückschluss auf den Zustand von einzelnen Komponenten zu treffen [AK12].

Ein weiteres Verfahren ist die Analyse der Phasenströme einer Drehstrommaschine (engl. *Motor Current Signature Anaysis*, kurz MCSA). Die theoretische Grundlage hinter dieser Technik ist, dass ein mechanisches oder elektrisches Fehlverhalten das magnetische Feld beeinflusst. Dazu kommt es, wenn der Luftspalt zwischen Rotor und Stator sich aufgrund eines unruhigen Laufs verändert [FCO16]. Durch die Analyse des Stromsignals im Frequenzbereich lassen sich Veränderungen auf einzelne Komponenten zurückführen. Die Forschungsarbeiten [JPL⁺15], [LN10] und [SK17] nutzen MCSA um Lagerschäden zu diagnostizieren. In [IV15], [GDF⁺12] und [JPBRC⁺14] wird die Strommessung zum Nachweis von Exzentrizitäten oder Schäden am Rotor verwendet. Elektrisches Fehlverhalten, wie ein Windungsschluss, Kurzschluss und Fehler in der Leistungsversorgung, werden in [SVJ11] und [CAGG16] betrachtet. Während die Isolation unterschiedlicher Fehlerfälle mittels der Phasenströme eine verbreitete Technik ist, findet eine Fehlerprognose noch keine Anwendung.

3.3 Datenverarbeitung und Generierung von Merkmalen

Die Aufgabe der Datenverarbeitung ist es, unerwünschte Signalanteile zu eliminieren oder zumindest abzuschwächen. In der Literatur findet sich hierfür eine Unmenge an Ansätzen, die sich mit dem Filtern von Messdaten oder der Detektion von Ausreißern befassen. Allgemein gilt, dass es keinen generalisierten Weg gibt und Ansätze für den entsprechenden Anwendungsfall ausgewählt und angepasst werden [JLB06]. Verschiedene Methoden zur Bereinigung von Daten sind in [Mey14] und [Bha10] zu finden.

Die Generierung von Merkmalen befasst sich mit dem Problem, wie aus anfänglichen Messdaten nützliche Informationen gewonnen werden können. Ziel ist es, große Datenmengen durch wenige relevante Merkmale zu ersetzen, die für eine

Anwendung nützliche Informationen enthalten, wie beispielsweise den Systemzustand [AK12]. Wie bereits in Abschnitt 3.2 erläutert, verwenden die meisten Messkonzepte für Drehstrommaschinen wellenförmige Messdaten. Daher wird sich im Folgenden auf Techniken beschränkt, um aus diesen Signalen Merkmale zu gewinnen. Wie in der Abbildung 3.3 dargestellt lässt sich eine grundsätzliche Unterteilung in Zeit-, Frequenz- und Zeit-Frequenz-Bereiche vornehmen [DGO11].

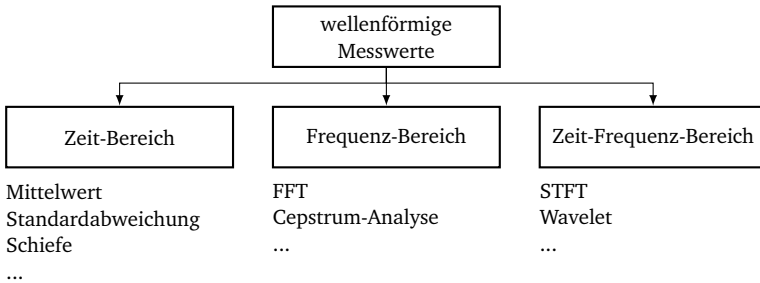


Abbildung 3.3.: Gliederung von ausgewählten Methoden zur Generierung von Merkmalen aus wellenförmigen Messwerten, angelehnt an [DGO11]

Bei Merkmalen aus dem Zeit-Bereich handelt es sich um statistische Parameter, die direkt aus dem Signal gewonnen werden. Hierzu zählt die Berechnung des Mittelwerts, der Standardabweichung, der Schiefe (engl. *skewness*) oder der Wölbung (engl. *kurtosis*). Eine Zusammenfassung verschiedener statistischer Parameter kann aus [DGO11] entnommen werden. Über den Zeit-Bereich kann ohne großen Aufwand eine allgemeine Information über den Systemzustand generiert werden, um damit ein Fehlverhalten zu detektieren [AHT14]. Für eine Isolation der Fehlerursachen eignen sich diese Merkmale jedoch selten [Air08].

Um genauere Informationen über die Schadensursache zu erhalten, wird das Zeitsignal in den Frequenz-Bereich transformiert. Die Idee ist es, nicht das gesamte Spektrum zu berücksichtigen, sondern nur jene Frequenzanteile, die für ein bestimmtes Fehlverhalten ausschlaggebend sind. Eine etablierte Technik hierfür ist die schnelle Fourier-Transformation (engl. *Fast Fourier Transform*, kurz FFT), die in [SAHR10] und [ABF⁺15] zur Diagnose angewendet wird. Andere Methoden sind die Dateneinhüllanalyse [BR16] und Cepstrum-Analyse [BPR⁺13]. Ein Überblick über weitere Methoden kann aus [Air08] entnommen werden.

Ein Nachteil der bisher vorgestellten Techniken ist ihr geringer Nutzen beim Verarbeiten nicht-stationärer Signale, bei denen sich statistische Eigenschaften über der Zeit ändern [JLB06]. Daher werden nicht-stationär Signale im Zeit-Frequenz-

Bereich analysiert. Hierbei wird der Zeit- und Frequenz-Bereich gleichzeitig betrachtet, um zeitabhängige Frequenzänderungen zu berücksichtigen. Als wichtige Stellvertreter sind hier die Kurzzeit-Fourier-Transformation (engl. *Short-Time Fourier Transform*, kurz STFT) [LRRTMS⁺16] und Wigner-Ville Verteilung [LM06] zu nennen. Bei diesen Methoden wird das nicht-stationäre Signal in kurze Zeitfenster eingeteilt und diese für die Verarbeitung als stationär angenommen. Ein Schwachpunkt dieser Techniken ist die sogenannte Zeit-Frequenz-Unschärfe. Das bedeutet, dass die Auflösung im Frequenz-Bereich umgekehrt proportional zur Zeitauflösung ist. Eine Technik, die diesen Nachteil umgeht, stellt die Wavelet-Transformation dar. Diese wird von vielen Forschergruppen, wie [AMB⁺13], [WZX⁺17] und [PGK16] zur Diagnose von Lagerschäden verwendet.

3.3.1 Reduktion von Merkmalen

Mithilfe der Techniken zur Generierung von Merkmalen kann eine große Anzahl an Merkmalen zur Beschreibung des Systemverhaltens gewonnen werden. Nicht alle der generierten Merkmale sind jedoch für ein spezifisches Diagnose- oder Prognoseproblem gleich bedeutend. Die Datenreduktion hat das Ziel, die Anzahl der Merkmale für ein spezifisches Problem zu verkleinern, ohne den Informationsgehalt zu reduzieren. [Alp10, S. 109]

Insbesondere datenbasierte Lernalgorithmen profitieren von einer geringen Komplexität eines Trainingsdatensatzes. Die reduzierte Merkmalsanzahl resultiert in einer Vereinfachung des Trainingsprozesses und einer Reduzierung der benötigten Trainingsdatenmenge. Zudem führt eine verminderte Anzahl an Eingabeparametern zu einfacheren Modellen, die robuster in Bezug auf Rauschen und Ausreißern sind [Alp10, S. 109]. Nach [JWHT13] verringert sich die Gefahr der Überanpassung. Dabei handelt es sich um ein Problem, bei dem sich Lernalgorithmen zu stark an die zugrunde liegenden Trainingsdaten anpassen und als Konsequenz keine generalisierte Anwendung der Modelle mehr möglich ist. Wenn große Datenmengen durch einige wenige Merkmale erklärt werden können, wird ebenfalls die Vorstellung für den Anwender erleichtert [GE03]. Datensätze mit einer geringen Dimension erlauben eine einfache grafische Darstellung, die eine visuelle Analyse hinsichtlich Ausreißer und Struktur der Daten ermöglicht.

Grundsätzlich wird bei der Reduktion von Daten zwischen zwei unterschiedlichen Techniken differenziert. In Abbildung 3.4 ist das Prinzip der beiden Methoden visualisiert. Gegeben ist ein Merkmalsvektor ϕ , der M generierte Merkmale enthält. Bei der Merkmalsextraktion wird der ursprüngliche Merkmalsvektor durch eine Transformationsvorschrift auf einen neuen Vektor $\tilde{\phi}$ mit einer geringeren Dimension N projiziert ($N < M$). Werden dagegen aus dem Merkmalsvektor die für

ein Problem relevanten Vertreter herausgegriffen und die Restlichen verworfen, wird von einer Merkmalsselektion gesprochen. [Alp10, S. 109-111]




Abbildung 3.4.: Methoden zur Datenreduktion: Unterschied zwischen Merkmalsextraktion und Merkmalsselektion

Ein wesentlicher Vorteile der Selektionsmethoden ist, dass der reduzierte Datensatz besser vom Anwender interpretiert werden kann, da keine Transformation stattfindet. Zudem müssen Merkmale, die als unnötig bewertet sind, nicht mehr generiert werden. Demgegenüber bietet die Datenextraktion ein höheres Reduktionsvermögen bei einem gleichbleibenden Informationsgehalt. Weitere Vor- und Nachteile der beiden Ansätze sowie eine Einführung in die Datenreduktion können aus [HG15], [AWA03] und [Agg15] entnommen werden.

Bei PHM Systemen ist insbesondere die Hauptkomponentenanalyse (engl. *Principal Component Analysis*, kurz PCA) eine häufig verwendete Technik für die Merkmalsextraktion [AHT14]. Die PCA überführt eine Vielzahl von korrelierten Variablen in möglichst wenige, aussagekräftige Linearkombinationen, welche Hauptkomponenten genannt werden [Agg15, S. 42]. Weitere Methoden sind die linear Diskriminanzanalyse und die Faktorenanalyse [VY12]. Alle drei Ansätze haben nur dann Gültigkeit, wenn die Merkmale eines Datensatzes linear variieren. In [SSM97] und [WCC07] wird eine Kernel-PCA verwendet, welche eine Reduktion der Merkmale ebenfalls bei nichtlinearen Datensätze erlaubt.

Bei der Selektion werden Merkmale nach bestimmten Kriterien gewichtet und anschließend die Besten ausgewählt. Hierfür wird in [Zio13] und [KS14] der sogenannte Filter-Ansatz verwendet, bei dem die Relevanz von Merkmalen durch uni- oder multivariate Kennwerte beurteilt werden [SILO7]. Mögliche Kriterien sind beispielsweise die Chi-Quadrat-Verteilung und die Transinformation zwischen zwei Merkmalen sowie das Bayessche Informationskriterium [JWHT13]. Ein Problem des Filter-Ansatzes ist, dass unter den gewählten Merkmalen Redundanzen nicht erkannt werden. Dieses Problem wird beim Wrapper-Ansatz gelöst. Innerhalb eines Selektionsalgorithmus wird ein bestimmtes Diagnoseproblem eingebettet und das Kriterium durch die Performanz der Diagnose (z. B. Fehlerrate) be-

stimmt [JGZZ12]. Merkmale, die signifikant zur Verbesserung beitragen, werden hoch gewertet und ausgewählt. Die Merkmalsselektion wird in Abschnitt 4.2.1.3 näher beleuchtet.

3.4 Fehlerdiagnose

Die Aufgaben der Fehlerdetektion, -isolation und -identifikation werden der Diagnose zugeordnet [Rus12, S. 6]. Die wesentlichen Elemente einer Fehlerdiagnose sind in Abbildung 3.5 dargestellt. Um den aktuellen Systemzustand zu beurteilen, wird im Rahmen der Diagnose der reduzierte Merkmalsvektor $\bar{\phi}$ analysiert. Wird bei der Detektion ein abnormales Verhalten erkannt, lokalisiert die Isolation den Fehlerursprung. Innerhalb der Identifikation wird das Ausmaß des Schadens quantifiziert.

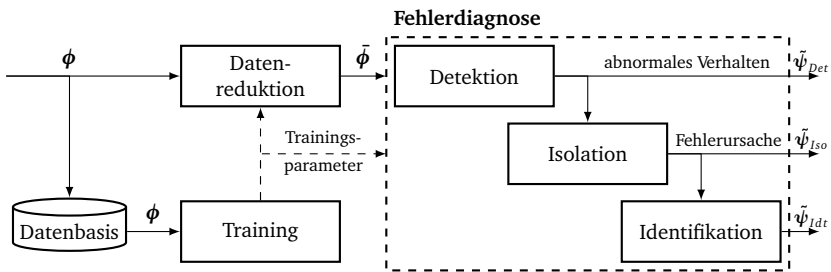


Abbildung 3.5.: Architektur eines datenbasierten Diagnosesystems, angelehnt an [Rus12, S. 6]

Datenbasierte Diagnosemethoden basieren auf sogenannten Klassifikatoren. Dabei handelt es sich um Lernalgorithmen, die einen Merkmalsvektor anhand einer antrainierten Entscheidungsfunktion

$$\tilde{\psi} = K(\bar{\phi}) \quad (3.1)$$

in Klassen einordnet. Der resultierende Vektor $\tilde{\psi}$ beinhaltet die geschätzten Wahrscheinlichkeiten, dass eine bestimmte Klasse vorliegt. Eine Klasse repräsentiert einen definierten Zustand. Dieser kann im Falle der Isolation beispielsweise eine Schadensursache (z. B. Lagerschaden oder Exzentrizität) sein oder im Rahmen der Identifikation für eine Abstufung des Schadenszustands (z. B. leichter oder kritischer Schadenszustand) stehen. [Alp10, S. 5]

In Abbildung 3.6 ist die Funktionsweise eines Klassifikators illustriert. Dargestellt ist ein Datensatz bestehend aus zwei Merkmalen (z. B. spezifische Frequenzanteile des Vibrationsspektrums) und dem Ausgabewert ψ , der den dazugehörigen Ist-Zustand (intakt, leichter und kritischer Schaden) beschreibt. Auf Grundlage des Datensatzes wird ein Lernalgorithmus trainiert. Die dargestellte Entscheidungsgrenze zeigt, in welchen Bereichen der Lernalgorithmus eine neue Beobachtung mit der höchsten Wahrscheinlichkeit einordnet.

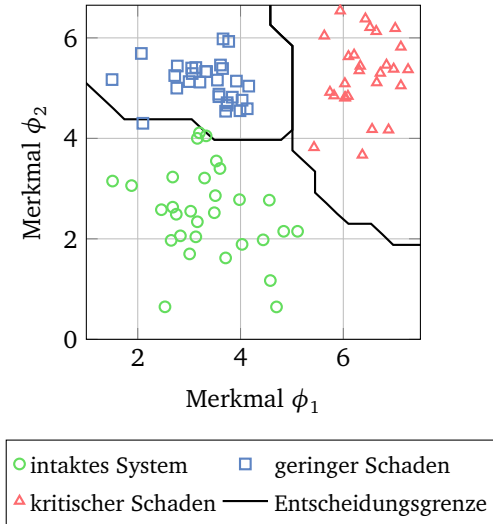


Abbildung 3.6.: Darstellung der Entscheidungsfunktion eines datenbasierten Klassifikators (Bayes-Klassifikator)

Das in Abbildung 3.6 gezeigte Ergebnis basiert auf einem Bayes-Klassifikator. Dabei handelt es sich um einen Lernalgorithmus, der neue Beobachtungen auf Grundlage des Satzes von Bayes einordnet. In Abschnitt 4.2.1.2 wird die Funktionsweise im Detail beleuchtet. Dieser Klassifikator zeichnet sich insbesondere durch eine hohe Erkennungsrate, Schnelligkeit und Robustheit bei geringer Komplexität aus und gehört aus diesem Grund zu den wichtigsten Algorithmen im Bereich des maschinellen Lernens [WKQ⁺08, S. 27].

In der Literatur kann eine Vielzahl von weiteren Ansätzen für Klassifikatoren gefunden werden. Zwei verbreitete Techniken sind Künstliche Neuronale Netzwerke (KNN) und die Stützvektormethode (SVM). Ersteres ist ein aus der Biologie inspirierter Ansatz, welcher der Nervenzellenvernetzung im Gehirn nachempfunden ist [Alp10, S. 246]. In [YHQ13] und [GCF⁺16] werden KNN erfolgreich angewendet,

um unterschiedliche Arten Lagerschäden in einem Drehstrommotor bzw. Generator anhand der Vibrationsdaten nachzuweisen. Bei der SVM wird über die Definition von Stützvektoren eine sogenannte Hyperebene gebildet, die eine möglichst breite Trennfläche zwischen den Klassen darstellt. Beispiele für die Verwendung der SVM zur Fehlerdiagnose lassen sich in [WZA12], [SMZ15] und [QX15] finden. Sowohl die SVM als auch KNN können für nichtlineare Klassifikationsprobleme verwendet werden [Jen13]. Demgegenüber steht, dass durch die Komplexität der Klassifikatoren ein aufwendiger Trainingsprozess nötig ist und die Nachvollziehbarkeit von Entscheidungen verloren geht [Wit11, S. 235-238]. Eine umfangreiche Einführung in KNN und SVM bietet [Bis13]. Weitere Techniken für die Entwicklung von Diagnosemodellen sind die Diskriminanzanalyse, Entscheidungsbäume [JGG⁺16], Bayessches Netz [CZLX17] und Hidden Markov Modelle [LL16].

3.4.1 Unüberwachtes Lernen

Mittels einer Datenbasis werden Lernalgorithmen in der Trainingsphase an das vorliegende Problem angepasst, indem die Entscheidungsregeln angelernt werden. Grundsätzlich wird dabei zwischen überwachtem und unüberwachtem Lernen unterschieden. Von Ersterem wird gesprochen, wenn die Datenbasis zu jeder Instanz (einem Merkmalsvektor) ebenfalls Information über die wahre Klasse, also die Ausgabewerte des Klassifikators ψ , enthält. Beim unüberwachten Lernen sind diese Informationen nicht vorhanden und es besteht zunächst die Notwendigkeit, Regelmäßigkeiten in der Datenbasis aufzuspüren und Merkmalsvektoren einer Klasse zuzuweisen. Der Vorteil des unüberwachten Lernens besteht genau darin, dass keine zugeordnete Information vorhanden sein muss, da eine Zuordnung der Daten aufwendig und kostspielig sein kann. [Alp10, S. 153]

Beim unüberwachten Lernen muss, bezogen auf die datenbasierte Diagnose bei technischen Systemen, den verfügbaren Datensätzen zunächst ein Fehlerzustand zugeordnet. Eine Möglichkeit hierfür ist die Clusteranalyse, deren Ziel es ist, in der Datenbasis Häufungen (Cluster) auf Basis von Dichteschätzungen zu finden. Grundsätzlich kann zwischen hierarchischen und partitionierenden Verfahren unterschieden werden. Letzteres zeichnet sich dadurch aus, dass die Zuordnung einer von Beginn an festgelegte Anzahl an Gruppen solange verändert wird, bis eine Zielfunktion ein Optimum erreicht. Ein verbreiteter Vertreter dieser Form ist das k-means-Verfahren. Dabei werden die Zentren der Gruppen zunächst zufällig bestimmt und solange variiert, bis der euklidische Abstand der Instanzen zu den Zentren minimal wird [WKQ⁺08]. In [YGA11], [MW16] und [EGY14] wird das k-means-Verfahren angewendet, um Vibrationsmessungen eines Drehstrommotors

in verschiedenen Fehlerfällen (Außen- und Innenringdefekt eines Lagers sowie ein Rotorschaden) zu kategorisieren.

Die hierarchische Clusteranalyse ist eine weitere etablierte Methode, um Gruppen innerhalb einer Datenbasis derart zu formen, dass Instanzen in dieser ähnlicher zueinander sind als zu Instanzen eines anderen Clusters. Die Gruppierung erfolgt auf Basis eines Ähnlichkeitsmaßes, welches die Distanz zwischen Instanzen beschreibt. Die Methode beginnt mit einer maximalen Anzahl an Gruppen, wobei jede nur eine Instanz enthält. Anhand des Ähnlichkeitsmaßes werden gleichartige Gruppen zusammengefasst und somit größere Gruppen gebildet. Nach diesem Prinzip werden iterativ immer größer Cluster geformt, bis sich alle Instanzen innerhalb einer großen Gruppe befinden. Der Vorteil dieser Methode ist es, dass die Anzahl an Klassen im Anschluss über die Wahl der maximalen Distanz festgelegt werden kann. Auf das hierarchische Verfahren wird näher in Abschnitt 4.2.2 eingegangen. [Wit11, S. 274-275]

3.4.2 Kennwerte zur Bewertung der Diagnosefähigkeit

Die Berechnung von Kennwerten zur Bewertung eines Diagnoseansatzes ermöglicht eine Abschätzung der zu erwartenden Fehlerrate für eine zukünftige Anwendung. Zudem erlauben die Kennwerte verschiedene Ansätze untereinander zu vergleichen und somit den Besten für die Zielanwendung zu wählen. [Alp10, S. 348]

Eine gängige Methode die Leistungsfähigkeit zu bestimmen basiert auf der Konfusionsmatrix. Dabei handelt es sich um eine Matrix, welche die Ergebnisse beim Testen eines Klassifikators zusammenfasst. In der Tabelle 3.2 ist die Konfusionsmatrix für einen binären Klassifikator dargestellt. Ein solcher Fall tritt bei der Fehlerdetektion auf, bei der die Hypothese geprüft wird, ob sich das System in einem fehlerhaften Zustand befindet. Ist das Ergebnis der Diagnose negativ, wird angenommen, dass die betrachtete Komponente intakt ist. Sind die wahren Ergebnisse bekannt, werden die geschätzten Aussagen in vier Kategorien eingeteilt. Falls die Einordnung richtig ist, wird von wahr positiv (engl. *True Positive*, kurz TP) bzw. wahr negativ (engl. *True Negative*, kurz TN) gesprochen. Ist eine Anomalie nicht erkannt worden, zählt dieses als falsch negativ (engl. *False Negative*, kurz FN), wohingegen ein Fehlalarm als falsch positiv (engl. *False Positive*, kurz FP) kategorisiert wird. [SJS06]

Anhand der Konfusionsmatrix kann eine Aussage über die Fehlerrate getroffen werden. Diese ist durch die Gleichung

$$FR = \frac{FP + FN}{TP + TN + FP + FN} \quad (3.2)$$

Tabelle 3.2.: Darstellung der Konfusionsmatrix für ein binäres Klassifikationsproblem

wahre Klasse	vorhergesagte Klasse	
	fehlerhaft	intakt
fehlerhaft	TP (wahres Positiv)	FN (falsches Negativ)
intakt	FP (falsches Positiv)	TN (wahres Negativ)

gegeben [XEHY10]. Für Anwendungen mit mehr als zwei Kategorien können die Konfusionsmatrix und Kennwerte erweitert werden [Jen13].

3.5 Fehlerprognose

Der Prognosealgorithmus schätzt die RUL eines technischen Systems. Auf Basis der Diagnoseergebnisse und Wissen aus historischen Schadensverläufen, wird der zukünftige Verlauf eines Fehlers bis zum Ausfall prognostiziert. In Abbildung 3.7 ist ein idealtypischer Verlauf einer Prognose dargestellt. Ab einem bestimmten Zeitpunkt (50 h), wird eine Prognose initiiert und die bisherige Entwicklung des geschätzten Zustandsindikators in die Zukunft prädiziert. Dabei kommt es zu einer unvermeidbaren Unsicherheit, welche durch das dargestellte Band visualisiert ist. Mit zunehmendem Prognosehorizont vergrößert sich die Unsicherheit. In [SZKP12] sind als Ursachen Ungenauigkeiten der Modelle (z. B. durch starke Vereinfachungen) sowie unbekannte zukünftige Nutzung und Belastung des Systems aufgeführt. Eine genaue Gliederung der Ursachen kann in [Pec08] gefunden werden.

Der Ausfallbereich definiert, bei welchen Zustandsindikatoren ein Versagen des Systems zu erwarten ist. Der Bereich wird aus historischen Daten abgeleitet und als eine Verteilung dargestellt. Um Unsicherheiten der Prognose zu berücksichtigen, wird das Ergebnis durch eine Wahrscheinlichkeitsdichtefunktion (engl. *Probability Density Function*, kurz PDF) oder Verteilungsfunktion (engl. *Cumulative Distribution Function*, kurz CDF) beschrieben [SCS⁺09]. In der Abbildung ist die CDF der RUL angegeben, welche die Wahrscheinlichkeit beschreibt, dass der Ausfall bis zu einem bestimmten Zeitpunkt stattgefunden hat.

Bei der Entwicklung eines Prognosealgorithmus existiert keine universell verwendbare Struktur. Begründet wird dies dadurch, dass es sich bei der Prognose noch um eine aufkommende Technologie handelt [LWZ⁺14]. Diese stellt im Ver-

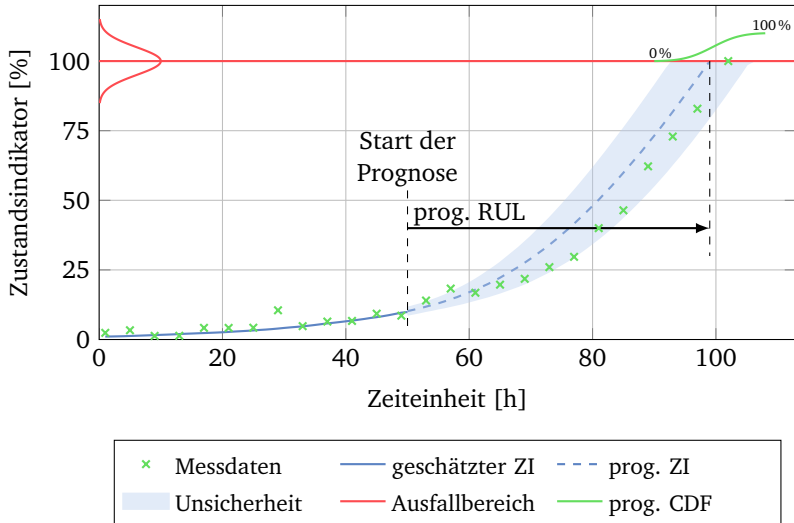


Abbildung 3.7.: Darstellung einer Prognose zum Zeitpunkt 50 h (wahrer Ausfall bei 102 h) und der dazugehörigen Unsicherheit auf Grundlage des geschätzten Zustandsindikators (ZI)

gleich zur Diagnose eine größere Herausforderung dar und ist dadurch mit einem hohen Entwicklungsaufwand verbunden [VWH16]. Zudem orientieren sich Prognosemethoden stark an der jeweiligen Anwendung, sodass es schwierig ist, einen allgemeinen Ansatz für jede Situation zu entwickeln [SCB⁺08]. Dennoch lassen sich zwei Kernkomponenten einer Prognose ausmachen: das Degradierungsmodell und der Prognosealgorithmus [Jen13, S. 50-52]. Abhängig von der jeweiligen Implementierung können beide Komponenten auch miteinander verschmelzen. Im Folgenden werden beiden Elemente näher beleuchtet.

Das Degradierungsmodell bildet das Verhalten des technischen Systems bei einem wachsenden Schaden ab. Eine Herausforderung dabei ist, dass es sich bei der Schadensausbreitung um einen nichtlinearen und stochastischen Prozess handelt. Zudem müssen wechselnde Betriebs- und Umgebungsbedingungen berücksichtigt werden, die einen Einfluss auf den Schaden haben. Eine wesentliche Anforderung bei der Entwicklung von datenbasierten Modellen ist die Verfügbarkeit von Daten, die Verhalten des betrachteten Systems vom intakten Zustand bis zum Ausfall wiedergeben. Die Generierung von Datensätzen ist eine besondere Herausforderung, welche in Abschnitt 3.6 näher beleuchtet wird. [Jen13, S. 50]

Bereits bei der Definition der Eingangs- und Ausgangsparameter des Modells lässt sich in der Literatur eine Vielzahl an unterschiedlichen Ansätzen finden. In Abbildung 3.8 sind zwei Möglichkeiten dargestellt, die in [Vac07, S. 302] bzw. [ASK12] vorgeschlagen werden. Beim linken Modell wird die zu erwartende RUL direkt als Ausgangsparameter verwendet. Anhand des aktuellen Zustandsindikators wird somit eine Aussage über die verbleibende Zeit und der Unsicherheit getroffen. In [ASK12] wird vorgeschlagen, die zu erwartende Änderungsrate des Zustandsindikators über den momentanen Wert abzubilden. Wie in Abbildung 3.8 (rechts) ersichtlich, wächst der Indikator schneller je höher die Degradierung ist. Durch ein iteratives Vorgehen wird die Entwicklung des Indikators bis zum Ausfall prädiziert. Andere Ansätze nutzen die Informationen von mehreren vergangenen Zeitschritten als Eingang [EO04]. Ist das betrachtete System einer wechselnden Belastung ausgesetzt, ist es zudem sinnvoll diese Auswirkung durch Aufnahme der Last als Eingang abzubilden. Nachteilig ist jedoch ein erhöhter Bedarf an Trainingsdaten [Jen13, S. 56].

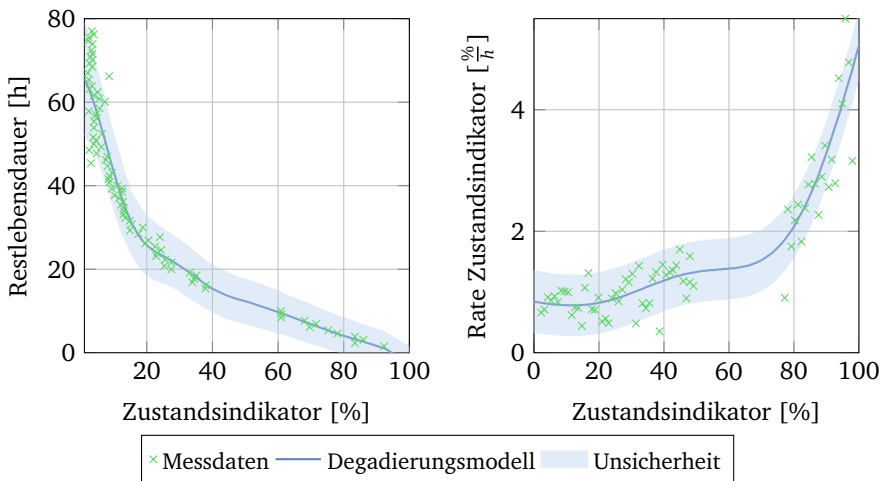


Abbildung 3.8.: Bestimmen der RUL direkt über den Zustandsindikator (links) sowie die Berechnung der Änderung des Indikators anhand des aktuellen Werts (rechts)

Im Rahmen der Regressionsanalyse wird eine Beziehung zwischen Eingangs- und Ausgangsparametern modelliert. Dieses ermöglicht den Einsatz der Degradierungsmodelle auch in Bereichen, in denen keine Trainingsdaten vorliegen. Die in

Abbildung 3.8 trainierten Modelle basieren auf dem Gaußprozess und erlauben auch eine Aussage für Bereiche zwischen 40 und 60. Wie in Abschnitt 3.1.1 erläutert, werden bei der datenbasierten Modellierung Methoden aus dem Bereich der künstlichen Intelligenz oder der Statistik eingesetzt. Letztere konstruieren aus den Trainingsdaten Wahrscheinlichkeitsmodelle, die beispielsweise auf der Normal- oder Weibullverteilung beruhen [Jen13, S. 56-57]. Demgegenüber stehen Ansätze aus dem Gebiet der künstlichen Intelligenz, welche durch die Analyse von Mustern in historischen Daten die RUL schätzen [ECJ12]. In [KEKM10] und [BMZR15] wird die SVM verwendet, um den Verschleiß von Lagerelementen zu prognostizieren. Ebenfalls mit dem Ziel die Lebensdauer von Lagerschäden zu präzisieren, nutzt [HZ12] den Gaußprozess für die Modellbildung. Weitere Techniken für die Erstellung von Degradierungsmodellen sind zudem neuronale Netze [RPN12], Fuzzy-Interferenz Systeme [JGZZ12] sowie die Relevanzvektormethode [SGC09].

Die Aufgabe des Prognosealgorithmus ist, den Schadensverlauf mithilfe des Degradierungsmodells in die Zukunft zu präzisieren. Eine verbreitete Methode hierfür ist das Erweiterte Kalman-Filter oder auch das Unscented Kalman-Filter, welche in [SSA15], [ASK12] und [Mik15] Anwendung finden. Beide Herangehensweisen erlauben die Verarbeitung von nichtlinearen Degradierungsmodellen und bieten zudem die Möglichkeit, Unsicherheiten zu berücksichtigen. Eine Beschränkung ist jedoch die Voraussetzung, dass die Unsicherheit durch eine Normalverteilung repräsentiert werden kann [BR10]. Eine Möglichkeit diese Einschränkung zu umgehen, ist die Verwendung eines Partikel-Filters [ZP11].

Bei dem Zusammenschluss mehrerer Modelle, welche jeweils ein unterschiedliches Degradierungsverhalten wiedergeben, können verschiedene Strategien verfolgt werden. In [MTMZ12] wird zum Zeitpunkt der Prognose ein Modell aus einem Pool ausgewählt und dieses für die Bestimmung der RUL verwendet. Die Entscheidung für ein Modell wird anhand der größten Übereinstimmung mit dem bisherigen Trend getroffen. In [ASK12] und [WG13] werden mehrere Modelle über einen sogenannten Multiple Modell Ansatz zusammengeschaltet. Dabei schätzt jedes Modell eine RUL, welche anschließend über einen Gewichtungsfaktor fusioniert werden.

3.5.1 Kennwerte zur Bewertung der Prognosefähigkeit

Kennwerte zur Bewertung der Prognosefähigkeit von Algorithmen lassen sich nach [SCB⁺08] in drei Bereiche aufteilen. Der erste Bereich bewertet die Prognosefähigkeit eines Algorithmus durch die Betrachtung der Genauigkeit, Präzision und Robustheit einer Restlebensdauerprognose. In den anderen zwei Bereichen Kosten-Nutzen und Rechenaufwand werden wirtschaftliche Größen sowie benötigte tech-

nische Ressourcen analysiert. Hierbei ist es wichtig zu erwähnen, dass es kein allgemeingültiges Bewertungskonzept für Prognosealgorithmen gibt, vielmehr ist die Aussage der Kennwerte vom betrachteten Anwendungsfall und dem zu untersuchenden Algorithmus abhängig [SCS⁺10]. Eine Auswahl an relevanten Kennwerten wird in diesem Abschnitt vorgestellt, wobei der Fokus auf den Kennwerten zur Bewertung der Prognosefähigkeit liegt. Soweit es nicht anders vermerkt ist, basieren diese auf der Veröffentlichung von [SCB⁺08].

Für eine Bewertung stehen J Schadensverläufe, die als Einheiten (engl. *Unit Under Test*, kurz UUT) bezeichnet werden, zur Verfügung. Bei jeder Einheit werden I Prognosen zu unterschiedlichen Zeitpunkten durchgeführt. Als Basis für viele Kennwerte dient der absolute Fehler. Ist die wahre RUL durch $R_{j,i}$ und die vom Algorithmus geschätzte RUL durch $r_{j,i}$ gegeben, berechnet sich der absolute Fehler $\Delta_{j,i}$ einer Prognose i durch die Gleichung

$$\Delta_{j,i} = R_{j,i} - r_{j,i}. \quad (3.3)$$

Dabei kennzeichnet j den betrachteten Schadensverlauf. Für die Beurteilung der Genauigkeit hat sich der mittlere absolute prozentuale Fehler (engl. *Mean Absolute Percentage Error*, kurz MAPE) etabliert. Für eine UUT j wird dieser mit

$$\text{MAPE}_j = \frac{1}{I} \sum_{i=1}^I \left| \frac{100 \cdot \Delta_{j,i}}{R_{j,i}} \right| \quad (3.4)$$

berechnet und fasst somit die Genauigkeit aller I durchgeführten Prognosen zusammen. Die Präzision beschreibt die Streuung der geschätzten Werte bei Prognosen zu unterschiedlichen Zeitpunkten. Ausgedrückt wird diese durch die mittlere absolute Abweichung vom Median (engl. *Mean Absolute Deviation from median*, kurz MAD), welche durch die Gleichung

$$\text{MAD}_j = \frac{1}{I} \sum_{i=1}^I |\Delta_{j,i} - \Delta_{M,j}| \quad (3.5)$$

definiert ist. Der Wert für $\Delta_{M,j}$ ergibt sich aus dem Median der absoluten Fehler einer Einheit.

Ein aussagekräftiger Kennwert, der sowohl die Genauigkeit und Präzision bewertet, ist der Prognosehorizont (PH). Dieser beschreibt, ab welchem Zeitpunkt der Fehler innerhalb eines tolerierbaren Fehlerbands liegt. Der PH wird mithilfe der relativen Lebensdauer λ angegeben. In Abbildung 3.9 ist die Definition des Kennwerts visualisiert. Dargestellt sind die geschätzten Werte der RUL bezogen auf

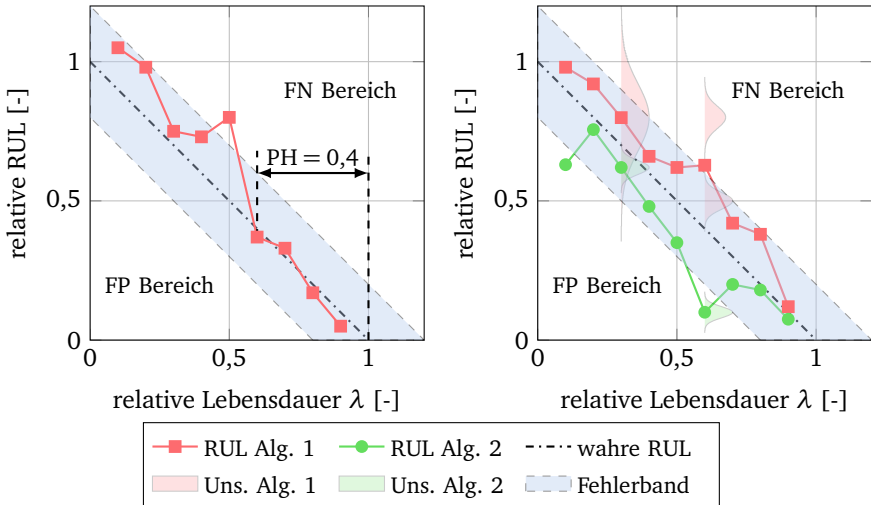


Abbildung 3.9.: Darstellung der Definition des Prognosehorizonts und der Erweiterung zur Berücksichtigung der Prognoseunsicherheit ($\alpha = 0,20$)

die Gesamtlebensdauer. Nach der Diagnose des Fehlers ($\lambda = 0$) bis zum Ausfall ($\lambda = 1$) wurden jeweils neun Prognosen durchgeführt. In der linken Abbildung liegen ab dem Zeitpunkt $\lambda = 0,6$ alle weiteren Prognosen innerhalb des Toleranzbandes. Der Kennwert für diese getestete Einheit beträgt somit $PH = 0,4$. Das Toleranzband wird über den Faktor α definiert. Ein maximal zugelassener Fehler von 10 % entspricht $\alpha = 0,10$.

Zur Beurteilung der Prognosefähigkeit ist es wichtig zu wissen, ob ein Algorithmus tendenziell zu konservativen oder risikobehafteten Prognosen neigt. Hierfür werden die Kennwerte FP und FN aus Abschnitt 3.4.2 herangezogen. Der Kennwert FP beschreibt die Häufigkeit, dass eine Prognose unterhalb des Toleranzbands liegt und somit der Ausfall zu früh prognostiziert wird. Ein hoher Wert für FN deutet auf zu hoch geschätzte Ausfallzeitpunkte hin. Definiert sind die Kennwerte für eine Prognose i wie folgt:

$$FP_{j,i} = \begin{cases} 1, & \text{falls } \Delta_{j,i} > t_{FP} \\ 0, & \text{sonst} \end{cases} \quad (3.6)$$

$$FN_{j,i} = \begin{cases} 1, & \text{falls } \Delta_{j,i} < t_{FN} \\ 0, & \text{sonst} \end{cases} \quad (3.7)$$

Die Parameter t_{FP} und t_{FN} definieren den Toleranzbereich, der nicht überschritten werden darf. Für eine Einheit j werden die Kennwerte zusammengefasst:

$$FP_j = \frac{1}{I} \sum_{i=1}^I FP_{j,i} \quad \text{bzw.} \quad FN_j = \frac{1}{I} \sum_{i=1}^I FN_{j,i}. \quad (3.8)$$

Ein Nachteil der vorgestellten Kennwerte ist, dass für die Bewertung der Prognosefähigkeit als Berechnungsgrundlage die mittlere RUL ohne Berücksichtigung der prognostizierten Unsicherheit verwendet wird. In Abbildung 3.9 (rechts) wird die Notwendigkeit erkenntlich, die Unsicherheit mit in die Bewertung aufzunehmen. Dargestellt sind die Ergebnisse von zwei Algorithmen bei der selben Einheit. Beide prognostizieren zum Zeitpunkt $\lambda = 0,3$ eine RUL, dessen Mittelwert innerhalb des Fehlerbands liegt und somit für die Berechnung der bisherigen Kennwerte als gleichwertig angesehen wird. Dennoch liegt ein Teil der PDF des ersten Algorithmus außerhalb des Fehlerbandes innerhalb des FN Bereiches. Im Gegensatz dazu befinden sich beide Prognose bei $\lambda = 0,6$ außerhalb und werden als ein FN bzw. FP Fehler bewertet, obwohl ein großer Teil innerhalb des Fehlerbandes liegt (Algorithmus 1).

Um die Unsicherheiten einer Prognose zu berücksichtigen, wird die Berechnung der Kennwerte PH, FN und FP angepasst. Hierfür werden zunächst die Anteile der prognostizierten PDF innerhalb des Fehlerbandes sowie der FP bzw. FN Bereiche berechnet. Für die Bestimmung des PH wird analysiert, ab welchem Zeitpunkt der Anteil innerhalb des Fehlerbandes konstant oberhalb eines Schwellwerts β liegt. Für $\beta = 0,5$ bedeutet das, dass 50% innerhalb des Fehlerbandes liegen müssen. Für die Berechnung der Kennwerte FN und FP wird der durchschnittliche Anteil innerhalb des FP bzw. FN Bereiches berechnet. [SCS⁺10]

Robustheit beschreibt die Auswirkungen von äußeren Störungen (wie Änderungen der Belastung oder Umgebungstemperatur) sowie Veränderungen am Algorithmus selbst (Änderung von Parameter). In [SCS⁺10] wird die Robustheit durch die Sensitivität von Kennwerten auf Änderungen bewertet. Im Idealfall sollten die Kennwerte nur geringen Schwankungen unterliegen, wenn sich die Bedingungen ändern.

Kennwerte zur Bewertung des Kostenvorteils sind dafür ausgelegt einem Unternehmen den Vorteil von Restlebensdauerprognosen zu beschreiben. Dieser kann über das Verhältnis der mittleren Betriebsdauer zwischen Ausfällen und der mittleren Betriebsdauer zwischen dem Austausch einer Komponente beschrieben werden. Je genauer die tatsächliche RUL bekannt ist, desto länger kann die Lebensdauer einer Komponente ausgenutzt werden, wodurch sich das Verhältnis verringert. In [Vac07, S. 396-398] sind weitere Berechnungswege vorgeschlagen. Dabei handelt

es sich um genaue Kostenanalysen, die exakte Kostensätze für Instandhaltungsmaßnahmen oder Entwicklungskosten benötigen. Die technischen Aspekte eines Algorithmus können beispielsweise durch die Rechenleistung oder -zeit bewertet werden.

3.6 Erzeugen einer Datenbasis

Das Vorhandensein einer umfassenden Datenbasis ist für die Entwicklung und das Bewerten eines datenbasierten PHM Systems essenziell. Diese beinhaltet Datensätze, die den Degradierungsprozess des betrachteten Systems wiedergeben und zum Training der Algorithmen verwendet werden. Die Datensätze stammen aus Simulationen, Experimenten oder aus dem realen Betrieb. Während die Simulation ein komplexes Modell voraussetzt, ist die Herausforderung bei der Datenerzeugung durch experimentelle Versuche, den Alterungsprozess der Komponenten künstlich zu beschleunigen, da diese für hohe Lebensdauern ausgelegt werden und ein Degradierungsprozess über Monate bis Jahre andauern kann. In der Industrie tritt das Problem auf, dass in der Regel keine Möglichkeit existiert, ein System ohne schwerwiegende Konsequenzen bis zum Ausfall zu betrachten [ECJ12].

Dieser Abschnitt gibt einen Überblick über Methoden, welche zur Generierung von Lagerschadensdaten bei Drehstrommaschinen Verwendung finden. Die in der Literatur vorgeschlagenen Herangehensweisen können in folgende Kategorien eingeordnet werden.

1. Radiale oder axiale Überlast
2. Vorschädigung der Lager
3. Verunreinigtes Schmiermittel
4. Funkenerosives Abtragen

Eine etablierte Technik ist die radiale Überlastung des Lagers. In [Bou15] wird ein Prüfstand bei der Nationalen Aeronautik- und Raumfahrtbehörde (engl. *National Aeronautics and Space Administration*, kurz NASA) speziell zur Generierung von Lagerschadensdaten vorgestellt. Ein Asynchronmotor treibt eine externe Welle an, die von dem zu untersuchenden Kugellager gestützt wird und eine Drehgeschwindigkeit von 2000 rpm erreicht. Ein Druckluftzylinder ermöglicht das Aufbringen einer variablen axialen und radialen Last von bis zu 6000 N auf das Lagerelement. Ein umfassendes Messkonzept von acht Beschleunigungssensoren, verschiedenen Temperatursensoren und einem Sensor, der die Verschmutzung des Schmiermittels misst, erfasst die Degradierung des Lagers. In [NGM⁺12] wird eine experimentelle Plattform PRONOSTIA vorgestellt. Diese wurde zum Zweck der Bewertung von PHM Algorithmen konstruiert und ermöglicht die Generierung von Schadensdaten mithilfe einer radialen Last in wenigen Stunden. Ein Teil der Messdaten ist frei

verfügbar und ist bereits von verschiedenen Forschungsgruppen (z. B. [JSQ⁺16], [SSA14] und [SMZ15]) verwendet worden, um auf Basis der Vibrationsmessungen entwickelte Algorithmen zu validieren.

Zur Beschleunigung der Degradierung werden ebenfalls die Laufbahnen der Außen- oder Innenringe vor dem Versuch künstlich beschädigt. Beispielsweise wird in [LSH12] und [HB08] der Degradierungsprozess von Lagerelementen durch eine Kerbe im Außenring und einer zusätzlichen radialen Last initiiert. In der Arbeit [WG13] wird das Ausbreiten eines Kratzers im Außenring von 0,27 mm bei einer zusätzlichen axialen Last untersucht.

Ungefähr 20 % der Ausfälle bei Lagern sind auf feste Verunreinigungen zurückzuführen [Sch13, S. 11]. Dabei handelt es sich insbesondere um Eisenspäne oder Staubpartikel, die während der Fertigung oder Montage in das Schmiermittel gelangt sind. Die Ermüdung des Materials infolge der Überrollung von Fremdkörpern wird in [CKTM13] und [BCSJ07] genutzt, um die Lageralterung zu simulieren. In [CKTM13] werden die Lager eines Schwenkkranes zusätzlich zu einer axialen Last von 30 t mit Kohlestaub verunreinigt. In [BCSJ07] sind synthetische Diamanten vorgeschlagen, um eine Ermüdung des Lagermaterials zu beschleunigen.

Bei Drehstrommaschinen kommt es durch stetig fließenden Wechsel- oder Gleichstrom zu Stromüberschlägen innerhalb des Lagers [Sch13, S. 38]. Die Entladung zwischen den Wälzkörpern und Laufbahnen besitzt genug Energie, um Kerben und Krater zu erzeugen. In [APK15] und [SSA16] werden Prüfstände vorgestellt, welche diesen Effekt nutzen, um den Ausfall der Lager innerhalb weniger Tage herbeizuführen.

Wenigen Untersuchungen stehen eine Datenbasis aus dem laufenden Betrieb zur Verfügung. In [BOFR12] wird beispielsweise die Prognosefähigkeit von Algorithmen anhand des Hauptlagers von Windkraftwerken untersucht. Dabei kann auf Sensordaten eines Windparks über eine Zeitspanne von 11 Monaten zurückgegriffen werden.

3.7 Problemstellung und Beitrag der Arbeit

Ein entscheidender Faktor der Restlebensdauerprognose ist die Bewertung des tatsächlichen Zustands eines technischen Systems. Fehler oder zu hohe Unsicherheiten reduzieren die Güte der anschließenden Prognose [SG14]. Für die Zustandsbewertung wird ein Zusammenhang zwischen den generierten Merkmalen und dem tatsächlichen Zustand hergestellt. Dieser wird bei datenbasierten PHM Systemen anhand einer Datenbank mit Methoden aus dem Bereich des maschinellen Lernens identifiziert und modelliert. Durch eine stochastische Fehlercharakteristik von Degradierungsprozessen kann die Relevanz von Merkmalen zwischen Scha-

densverläufen innerhalb der Datenbank jedoch stark variieren. Dadurch wird eine einheitliche Modellierung mit demselben Set an Merkmalen erschwert.

Dieses Problem adressiert die vorliegende Arbeit. Ziel ist die Entwicklung, Implementierung und Untersuchung eines PHM Systems. Der Fokus liegt dabei auf einem neuen Ansatz für die Bewertung des Zustands eines technischen Systems. Zu diesem Zweck wird zunächst eine Methode vorgeschlagen, welche es ermöglicht, relevante Merkmale selbstständig zu identifizieren und zu bewerten. Auf Basis dieser Informationen wird eine hierarchische Clusterung von ähnlichen Schadensverläufen innerhalb der Datenbasis vorgenommen. Durch die Gruppierung wird das Ziel verfolgt, Zusammenhänge innerhalb der Datenbank besser erkennen und modellieren zu können. Als Konsequenz der Gruppierung findet die Zustandsbewertung in zwei Schritten statt. Nachdem die wahrscheinlichste Gruppe identifiziert ist, findet im Anschluss die Bewertung des Zustands anhand geeigneter Merkmale statt. Durch die Zweiteilung soll eine Verbesserung der Zustandsbewertung und somit der Prognose erreicht werden. In Abbildung 3.10 ist der Unterschied zwischen den beiden Herangehensweisen dargestellt.

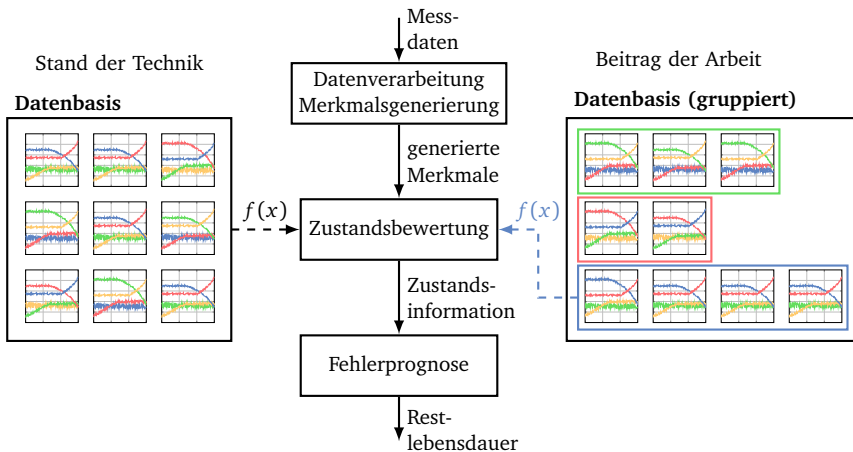


Abbildung 3.10.: Verbesserung der Zustandsbewertung durch eine Vorgruppierung der Schadensverläufe innerhalb der Datenbank

4 Konzept des PHM Systems

In diesem Kapitel werden die Algorithmen des PHM Systems zur Zustandsbewertung und Fehlerprognose vorgestellt. Zunächst wird in Abschnitt 4.1 die Systemgrenze beschrieben und die Schnittstellen zu einem möglichen Anwendungsfall definiert. Anschließend wird in Abschnitt 4.2 die zugrunde liegende Idee der Zustandsbewertung erläutert und darauf eingegangen, wie diese dazu beiträgt, das in Abschnitt 3.7 vorgestellte Problem zu lösen. Die Abschnitte 4.3 und 4.4 behandeln, wie anhand der Zustandsinformationen eine Abschätzung der RUL durchgeführt und anschließend eine Handlungsempfehlung generiert wird. Um die Funktionsweise der Algorithmen zu verdeutlichen, wird in diesem Kapitel ein künstlich erzeugter Datensatz verwendet. Die Verifikation und die Untersuchung der Leistungsfähigkeit anhand einer realen Anwendung finden in Kapitel 5 und 7 statt.

4.1 Definition der Systemgrenze und Schnittstellen

Eine Anforderung an die entwickelten PHM Algorithmen ist, dass diese unabhängig vom betrachteten Anwendungsfall sind. In Abbildung 4.1 ist das PHM Konzept in anwendungsspezifische und anwendungsunabhängige Komponenten geteilt. Das verwendete Messkonzept zur Fehlererkennung wird individuell für die Anwendung ausgelegt. Folglich sind ebenfalls die Techniken zur Vorverarbeitung der Messdaten und die Generierung von Merkmalen auf die verwendeten Sensoren abzustimmen. Vorschläge für Methoden können aus Abschnitt 3.2 und 3.3 entnommen werden. In Kapitel 5 wird der anwendungsspezifische Teil am Anwendungsfall eines Asynchronmotors näher behandelt.

Da es sich um ein datenbasiertes Konzept handelt, ist eine Datenbank für das Training der Lernalgorithmen essenziell. Diese beinhaltet die Informationen aller J bisherigen Schadensverläufe des betrachteten technischen Systems. Ein einzelner Datensatz Φ_j deckt den zeitlichen Ablauf vom Auftreten des Fehlers bis zum Ausfall des Systems in Form von Merkmalsvektoren ϕ_k ab, welche äquidistant verteilt sind. Ein Vektor ϕ_k beinhaltet M Merkmale, die im Rahmen der Merkmalsgenerierung aus verschiedenen Sensorquellen zu einem Zeitpunkt t_k berechnet werden:

$$\phi_k = [\phi_{k,1} \quad \phi_{k,2} \quad \dots \quad \phi_{k,M}]. \quad (4.1)$$

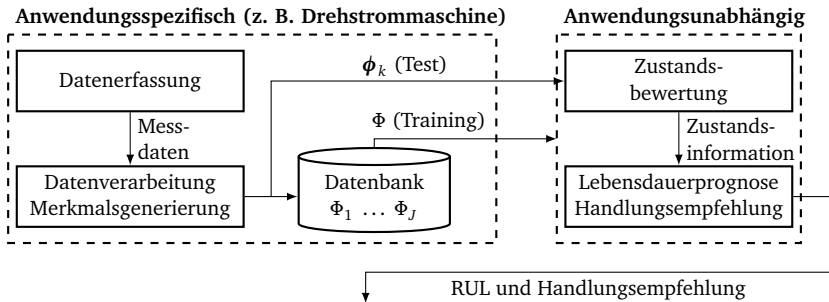


Abbildung 4.1.: Aufteilung des entwickelten PHM Systems in anwendungsspezifische und -unabhängige Komponenten

Werden während eines Schadensverlaufs bis zum Ausfall K Merkmalsvektoren berechnet, setzt sich ein Datensatz Φ_j wie folgt zusammen:

$$\Phi_j = \begin{bmatrix} \phi_{1,1} & \cdots & \phi_{1,M} \\ \vdots & \ddots & \vdots \\ \phi_{K,1} & \cdots & \phi_{K,M} \end{bmatrix}. \quad (4.2)$$

In Abbildung 4.2 ist der Verlauf von vier Merkmalen ($M = 4$) eines künstlich erzeugten Datensatzes dargestellt. Von der Diagnose eines Fehlers bis zum Ausfall vergehen 150 Stunden, die durch 150 Merkmalsvektoren ($K = 150$) abgebildet werden. Die Degradierung führt zu einer ansteigenden, abfallenden oder keiner Reaktion auf die Merkmale. Der gezeigte Datensatz wird im Folgenden verwendet, um die Funktionsweise der Algorithmen besser zu veranschaulichen.

In diesem Kapitel wird der anwendungsunabhängige Teil des PHM Systems erläutert. Dieser ist in eine Test- und Trainingsphase unterteilt. Während innerhalb der Trainingsphase die Lernalgorithmen anhand der Datenbasis trainiert werden, stellt die Testphase die Funktionsweise im Anwendungsfall dar. In dieser wird zunächst anhand des aktuellen Merkmalsvektors der Zustand des Systems abgeschätzt (Abschnitt 4.2). Auf Basis dieser Information wird eine Prognose der RUL (Abschnitt 4.3) durchgeführt, welche im Anschluss für die Generierung einer Handlungsempfehlung (Abschnitt 4.4) verwendet wird.




Abbildung 4.2.: Ausfall einer Komponente innerhalb von 150 Stunden nach dem Erkennen des Schadens (künstlich erzeugter Datensatz mit vier Merkmalen)

4.2 Algorithmus zur Zustandsbewertung

Im Folgenden wird der Lösungsansatz zur automatischen Selektion von relevanten Merkmalen und Gruppierung von ähnlichen Degradierungsprozessen vorgestellt. Das verfolgte Konzept basiert auf zwei Annahmen:

- Es existieren Schadensverläufe eines technischen Systems, bei denen der Zustand mit dem gleichen Set an Merkmalen bestimmt werden kann. Diese Schadensverläufe gehören derselben Schadensgruppe an.
- Schadensverläufe, bei denen der Zustand nicht mit dem gleichen Set an Merkmalen bestimmt werden kann, gehören einer anderen Schadensgruppe an.

Das bedeutet, dass die verfügbaren Schadensverläufe der Datenbasis einer Schadensgruppe zugeordnet werden. Degradierungsprozesse innerhalb einer Gruppe sind ähnlicher zueinander als zu Verläufen anderer Gruppen und können durch die gleichen Merkmale beschrieben werden. Durch die Einteilung in Gruppen wird das Ziel verfolgt, dass die Bewertung des Zustands innerhalb einer Gruppe verbessert wird.

In Abbildung 4.3 ist das Konzept des Algorithmus dargestellt und wie dieser in das gesamte PHM System integriert ist. Wie aus Abbildung 4.1 ersichtlich, dienen die aus dem Anwendungsfall generierten Merkmalsvektoren ϕ_k und Datensätze Φ_j dem Algorithmus als Eingangsgrößen. Während die verfügbaren Datensätze in der Trainingsphase verwendet werden, dienen die Vektoren ϕ_k in der Testphase als Grundlage zum Bewerten des Zustands.

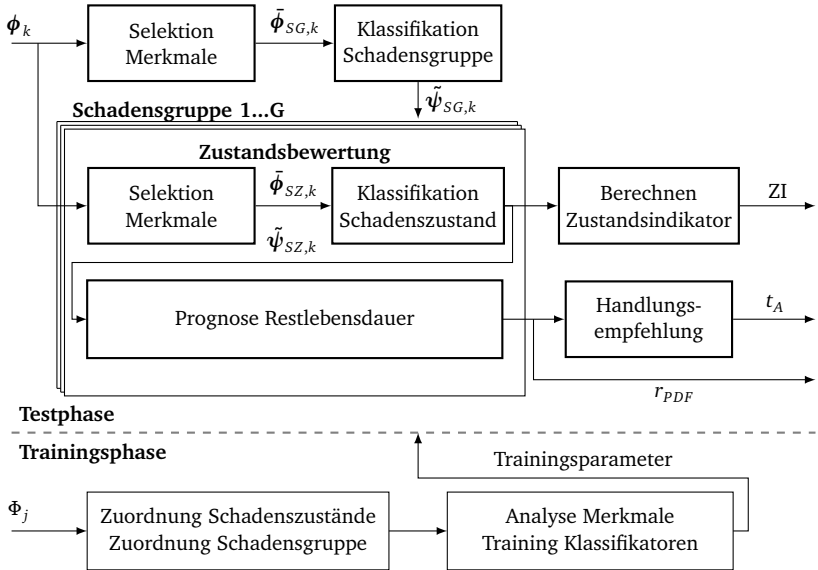


Abbildung 4.3.: Vorgehen bei der Schätzung des Schadenszustands und des Zustandsindikators (ZI) sowie Darstellung der Schnittstellen zur Prognose und der Generierung einer Handlungsempfehlung

Die Bewertung innerhalb der Testphase findet in zwei Schritten statt. Anhand eines Klassifikators

$$\tilde{\psi}_{SG,k} = K_{SG}(\bar{\phi}_{SG,k}) \quad (4.3)$$

wird der momentane Schadensverlauf einer Schadensgruppe zugeordnet. Hierfür wird zunächst der Merkmalsvektor reduziert, indem für die Klassifikation benötigte Merkmale $\bar{\phi}_{SG,k}$ selektiert werden. Das Ergebnis $\tilde{\psi}_{SG,k}$ beinhaltet die Wahrchein-

lichkeiten, dass der Verlauf einer Schadensgruppe g von insgesamt G Gruppen zugeordnet wird. Es gilt

$$\tilde{\psi}_{SG,k} = [\tilde{\psi}_{SG,k,1} \quad \tilde{\psi}_{SG,k,2} \quad \dots \quad \tilde{\psi}_{SG,k,G}] \quad (4.4)$$

mit der Bedingung $\sum_{g=1}^G \tilde{\psi}_{SG,k,g} = 1$. Die Bewertung des Zustands findet anschließend über die Schätzung des Schadenszustands, dem Ausmaß der Degradierung, innerhalb der gewählten Gruppe statt. Die Zuordnung wird über einen zweiten Klassifikator

$$\tilde{\psi}_{SZ,k} = K_{SZ}(\bar{\phi}_{SZ,k}) \quad (4.5)$$

realisiert. Der reduzierte Merkmalsvektor $\bar{\phi}_{SZ,k}$ wird einem von Z Schadenszuständen zugeordnet. Je größer der Schadenszustand ist, desto kritischer ist das Ausmaß des Schadens. Der resultierende Vektor

$$\tilde{\psi}_{SZ,k} = [\tilde{\psi}_{SZ,k,1} \quad \tilde{\psi}_{SZ,k,2} \quad \dots \quad \tilde{\psi}_{SZ,k,Z}] \quad (4.6)$$

beinhaltet dabei die Wahrscheinlichkeiten nach welcher ϕ_k dem Schadenszustand z zugeordnet wird. Dabei gilt $\sum_{z=1}^Z \tilde{\psi}_{SZ,k,z} = 1$. Auf Basis von $\tilde{\psi}_{SZ,k}$ wird der Zustandsindikator abgeleitet, der das Ausmaß des Schadens auf einer festgelegten Skala beschreibt. Höhere Werte stehen für einen kritischeren Zustand.

Der Trend der Schadenszustände $\tilde{\psi}_{SZ,k}$ dient dem Prognosealgorithmus abschließend als Grundlage zur Abschätzung der RUL in Form einer PDF (r_{PDF}). Ist diese berechnet, wird daraus eine Handlungsempfehlung abgeleitet. Diese dient als Unterstützung der Instandhaltung und empfiehlt ab einem Zeitpunkt t_A den Austausch der Komponente.

Im Rahmen der Trainingsphase ist es essenziell, dass zu den verfügbaren Merkmalsvektoren eines Datensatzes ϕ_j Informationen über den wahren Schadenszustand $\psi_{SZ,k}$ und -gruppe $\psi_{SG,k}$ vorliegen. Aus diesem Grund werden in der Trainingsphase die Datensätze zunächst mittels eines Clusteralgorithmus in Gruppen kategorisiert und der Schadenszustand abgeschätzt. Anschließend werden die Datensätze auf relevante Merkmale für die Klassifikation analysiert und die Klassifikatoren K_{SG} und K_{SZ} anhand dieser für die Testphase trainiert. Die Reihenfolge der folgenden Erläuterung weicht aus Gründen einer besseren Verständlichkeit von der Trainingsreihenfolge ab. In Anhang A findet sich eine Übersicht des tatsächlichen Trainingsablaufes.

4.2.1 Klassifikation des Schadenszustands

An dieser Stelle wird der Lösungsansatz zur Selektion von relevanten Merkmalen für die Zustandsbewertung vorgestellt. Dafür werden in Abschnitt 4.2.1.1 Schadenszustände eingeführt und eine Zuordnung zu jedem Merkmalsvektor eines Datensatzes durchgeführt ($\phi_k \mapsto \psi_{SZ,k}$). Als Konsequenz der Zuordnung entsteht ein Klassifikationsproblem, bei welchem die Eingabe- und Ausgabewerte definiert sind und mittels eines Lernalgorithmus ein Zusammenhang modelliert werden kann (Abschnitt 4.2.1.2). Die Nutzung eines Klassifikators und Techniken der Datenreduktion ermöglichen es, die generierten Merkmale hinsichtlich ihrer Eignung für das Klassifikationsproblem zu bewerten und zu selektieren (Abschnitt 4.2.1.3).

4.2.1.1 Zuordnung des Schadenszustands

Der wahre Schadenszustand eines technischen Systems ist in der Regel nicht bekannt und wird anhand der generierten Merkmale geschätzt. Unter der Annahme, dass der Degradierungsprozess stetig fortschreitet, wird der Zustand des Schadens $\psi_{SZ,k}$ für jeden Merkmalsvektor definiert. Hierfür wird die Lebensdauer gleichmäßig in Schadenszustände eingeteilt, welche das technische System bis zum Ausfall durchläuft. Das Prinzip ist in Schaubild 4.4 (links) am fiktiven Datensatz dargestellt (vgl. Abb. 4.2). Die relative Lebensdauer wird gleichmäßig in Z Schadenszustände eingeteilt ($Z = 3$). Während der erste Zustand das Verhalten kurz nach der Diagnose des Fehlers erfasst, beschreibt der Letzte das Systemverhalten kurz vor dem Ausfall.

Da der wahre Zustand unbekannt ist, wird die Klassenzugehörigkeit, wie in Abbildung 4.4 (rechts) dargestellt, über eine Wahrscheinlichkeit ausgedrückt. Das bedeutet, dass zu einem Zeitpunkt mehrerer Schadenszustände als Möglichkeit in Betracht gezogen werden. Die Wahrscheinlichkeit $\psi_{SZ,k,z}$, dass ein Merkmalsvektor ϕ_k einem Schadenszustand z angehört, wird mittels einer Normalverteilung festgelegt und über die Gleichung

$$\psi_{SZ,k,z} = \frac{1}{\sigma_z \sqrt{2\pi}} \cdot e^{-\frac{(\frac{k}{K} - \mu_z)^2}{2\sigma_z^2}} \quad (4.7)$$

berechnet. Der Parameter μ_z beschreibt den Mittelwert eines Schadenszustands und wird in Abhängigkeit der Anzahl an maximalen Schadenszuständen Z durch die Gleichung

$$\mu_z = \frac{z - 0,5}{Z} \quad (4.8)$$

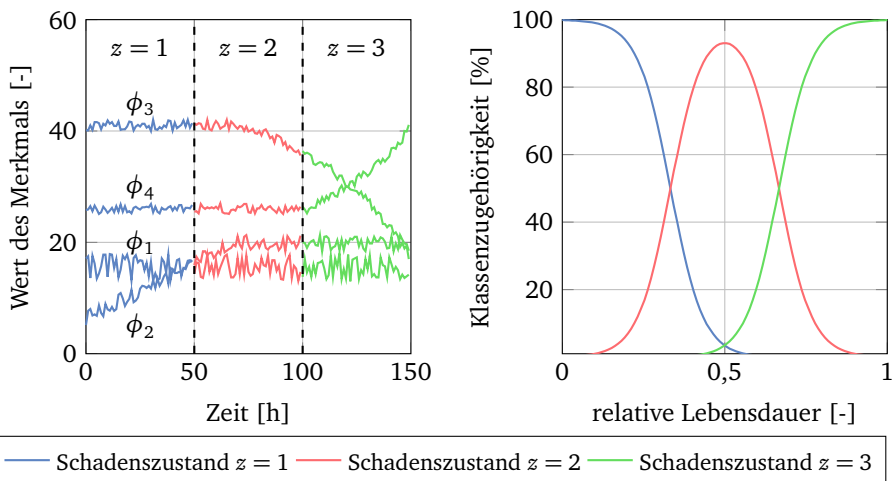


Abbildung 4.4.: Einteilung der Lebensdauer eines technischen Systems in Schadenszustände

bestimmt. Über die Standardabweichung σ_z wird die Zeitspanne beeinflusst, innerhalb welcher ein Merkmalsvektor einem Schadenszustand zugeordnet wird. Je höher σ_z gewählt wird, desto höher ist die Wahrscheinlichkeit von mehreren Schadenszuständen zu einem Zeitpunkt. Als Konsequenz basiert das Training des Klassifikators auf unpräzisen Ausgabewerten und erhöht in der Testphase die Unsicherheit bei der Einordnung des Schadenszustands. Wird σ_z zu niedrig gewählt, entstehen zu rapide Klassenübergänge. Diese reduzieren die Performanz des Klassifikators, wenn während des Übergangs keine Änderungen der Merkmale auftreten. Für die weitere Untersuchung wird

$$\sigma_z = \frac{1}{4 \cdot (Z - 1)} \tag{4.9}$$

angenommen, wobei es sich um einen Erfahrungswert handelt.

4.2.1.2 Bayes-Klassifikator

Mittels eines Lernalgorithmus wird der Zusammenhang zwischen dem Merkmalsvektor und dem Schadenszustand modelliert (vgl. Gl. 4.5). Hierfür wird die Bayes-

Klassifikation verwendet. Dabei handelt es sich um eine statistische Methode, welche auf Basis einer Beobachtung die Wahrscheinlichkeit berechnet, mit der ein Objekt einer bestimmten Klasse zugeordnet wird. Die Klassenzugehörigkeit wird über die bedingte Wahrscheinlichkeit ausgedrückt, welche über das Bayestheorem bestimmt wird. Liegt zu einem Zeitpunkt die Beobachtung ϕ_k vor, ist die bedingte Wahrscheinlichkeit, dass ein bestimmter Schadenszustand z vorliegt, durch $P(z|\phi_k)$ definiert.

Die bedingte Wahrscheinlichkeit einer Klasse z wird über den Satz von Bayes wie folgt beschrieben:

$$P(z|\phi_k) = \frac{P(z) \cdot P(\phi_k|z)}{P(\phi_k)}. \quad (4.10)$$

Der Faktor $P(z)$ ist die a-priori-Wahrscheinlichkeit, welche das Wissen ohne die Informationen aus dem Merkmalsvektor darstellt. Da die Schadenszustände gleichmäßig über die relative Lebensdauer verteilt sind, kann angenommen werden, dass $P(z) = \frac{1}{Z}$ ist. Der Wert für $P(\phi_k)$ ist die sogenannte Randwahrscheinlichkeit, dass die Beobachtung unabhängig von dem Schadenszustand gemacht wird. Dieser Faktor wird eliminiert, wenn die a-posteriori-Wahrscheinlichkeit normalisiert wird

$$P(1|\phi_k) + P(2|\phi_k) + \dots + P(Z|\phi_k) = 1 \quad (4.11)$$

und kann daher vernachlässigt werden. [Wit11, S. 90-99]

Der Faktor $P(\phi_k|z)$ ist die bedingte Wahrscheinlichkeit dafür, dass ein Schadenszustand die dazugehörige Beobachtung ϕ_k aufweist. Um diesen zu berechnen, wird jeder Zustand durch eine Wahrscheinlichkeitsdichte definiert. Da die Dichtefunktion in der Realität unbekannt ist, wird diese anhand der verfügbaren Trainingsdaten abgeschätzt. Hierfür wird angenommen, dass eine Normalverteilung vorliegt. Besitzt ϕ_k die Dimension $1 \times M$ und die Merkmale sind unabhängig voneinander, wird die a-posteriori-Wahrscheinlichkeit durch

$$P(\phi_k|z) = P(\phi_{k,1}|z) \cdot P(\phi_{k,2}|z) \cdot \dots \cdot P(\phi_{k,M}|z) \quad (4.12)$$

berechnet. Die einzelnen Terme werden durch die sogenannte Likelihood-Funktion bestimmt. Da eine Normalverteilung angenommen wird, kann ein Term durch

$$P(\phi_{k,m}|z) = \frac{1}{\sigma_{z,m} \sqrt{2\pi}} \cdot e^{-\frac{(\phi_{k,m} - \mu_{z,m})^2}{2\sigma_{z,m}^2}} \quad (4.13)$$

bestimmt werden. Die Parameter $\mu_{z,m}$ und $\sigma_{z,m}$ sind die Mittelwerte und Standardabweichungen des entsprechenden Merkmals ϕ_m der jeweiligen zugeordneten Klasse z . Der Klassifikator K_{SZ} ist vollständig durch die Standardabweichungen und Mittelwerte aller Klassen definiert. Diese werden innerhalb der Trainingsphase mittels der in Abschnitt 4.2.1.1 zugeordneten Schadenszustände berechnet. Da die Zuordnung auf Wahrscheinlichkeiten basiert, wird ein gewichteter Wert für $\mu_{z,m}$ und $\sigma_{z,m}$ bestimmt. Das Berechnen der Größen auf Basis der Trainingsdaten ist in Anhang B näher beschrieben.

In der Testphase wird das Ergebnis zu einem Zeitpunkt durch den Zustandsvektor $\tilde{\psi}_{SZ,k}$ repräsentiert, der die jeweiligen Klassenwahrscheinlichkeiten enthält:

$$\tilde{\psi}_{SZ,k} = [P(1|\phi_k) \quad P(2|\phi_k) \quad \cdots \quad P(Z|\phi_k)] \quad (4.14)$$

In Abbildung 4.5 (links) ist das Ergebnis eines Bayes-Klassifikators gezeigt. Dieser ist anhand des Beispieldatensatzes (vgl. Abb. 4.4) mit zehn Schadenszuständen ($Z = 10$) trainiert und auf einen Merkmalsvektor zum Zeitpunkt 80 h angewendet. Dargestellt sind die berechneten Wahrscheinlichkeiten, dass ein Schadenszustand z vorliegt. Über die Perzentile (5 %, 50 % und 95 %) wird die Verteilung der berechneten Wahrscheinlichkeiten beschrieben. Das 50 %-Perzentil repräsentiert den wahrscheinlichsten Zustand und wird als Zustandsindikator des Systems angenommen. Die äußeren Perzentile stehen für die Unsicherheit der Schätzung. In Abbildung 4.5 (rechts) ist die Entwicklung des Indikators über der Versuchsdauer dargestellt. Der Bayes-Klassifikator ordnet die fiktiven Daten vom Feststellen des Defekts bis zum Ausfall in die zehn Schadenszustände ein.

4.2.1.3 Selektion von Merkmalen

Bei dem definierten Klassifikationsproblem besitzen nicht alle generierten Merkmale des Vektors ϕ_k den gleichen Informationsgehalt. Dieses gilt beispielsweise für Merkmale, welche durch die Degradierung nicht beeinflusst werden oder untereinander korrelieren (vgl. Merkmale in Abbildung 4.4). Sind J Trainingsdatensätze gegeben, bei denen jeder Merkmalsvektor einem wahren Schadenszustand zugeordnet ist, ist es das Ziel, ein optimales Set an Merkmalen zu wählen, welche eine bestmögliche Klassifikation der Schadenszustände ermöglicht.

Durch die Einführung von Schadenszuständen und dem daraus resultierenden Klassifikationsproblem kann auf Techniken aus dem Bereich der Merkmalsselektion zurückgegriffen werden. Im Gegensatz zur Merkmalsextraktion ist es dadurch möglich, den verwendeten Klassifikator und dessen Eigenschaften mit in die Unter-

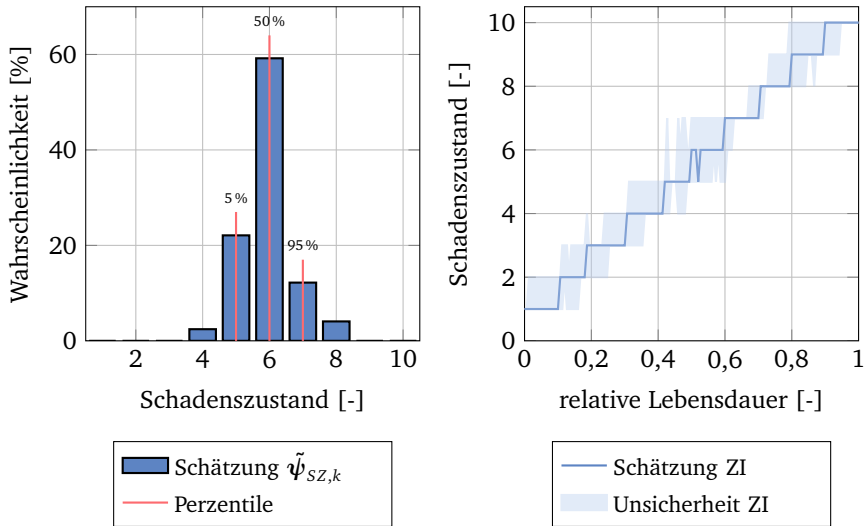


Abbildung 4.5.: Ergebnis des Klassifikators anhand einer Beobachtung zum Zeitpunkt von ungefähr 80 h (links) und Verlauf des geschätzten Zustandsindikators (ZI) über dem gesamten Datensatz (rechts)

suchung einzubeziehen und das Ergebnis besser zu interpretieren (siehe Abschnitt 3.3.1).

Mit dem Ziel die unterschiedlichen Merkmale auf ihre Eignung hinsichtlich des Klassifikationsproblems zu untersuchen, wird das Modell K_{SZ} in einen Suchalgorithmus eingepackt. Dieser generiert in einer deterministischen oder zufälligen Reihenfolge eine Teilmenge aus den Merkmalen. Anhand dieser wird der Klassifikator K_{SZ} trainiert und die Leistung mittels eines festgelegten Kriteriums W bewertet. Erfüllt das Kriterium eine definierte Bedingung, wird das entsprechende Set an Merkmalen gewählt. Ansonsten wird eine andere Kombination an Merkmalen geprüft, bis die Bedingung erfüllt ist.

Als Suchalgorithmus wird ein sogenannter Vorwärtsalgorithmus genutzt, der ausgehend von einem Merkmal, die Teilmenge iterativ erweitert, bis eine geeignete Untermenge gefunden wird. In Abbildung 4.6 ist das Vorgehen des Suchalgorithmus veranschaulicht, wenn dieser auf den fiktiven Datensatz in Abbildung 4.4 angewendet wird. In der ersten Iteration wird der Klassifikator jeweils mit einem der vier Merkmalen trainiert und das Kriterium W berechnet. Dieses beschreibt, mit welcher Ungenauigkeit der Klassifikator anhand des selektierten Merkmals die

Schadenzustände einordnet. Da ϕ_1 nicht von der Degradierung beeinflusst wird, kann keine genaue Klassifikation stattfinden und das Kriterium erzielt mit diesem Merkmal den schlechtesten Wert in der ersten Iteration. Dagegen erreicht das Kriterium unter Verwendung des dritten Merkmals ϕ_3 den geringsten Wert. Als Folge hieraus, dient das dritte Merkmal als Ausgangsbasis der nächsten Iteration und wird mit den Restlichen kombiniert. Durch die Verwendung der beiden Merkmale ϕ_3 und ϕ_2 kann das Ergebnis in der zweiten Iteration nochmals verbessert werden. Danach findet keine signifikante Verbesserung mehr statt und die Merkmale ϕ_3 und ϕ_2 werden als bestes Set für das Klassifikationsproblem selektiert. Die Merkmale ϕ_1 und ϕ_4 besitzen keinen weiteren Informationsgehalt und werden nicht weiter betrachtet.

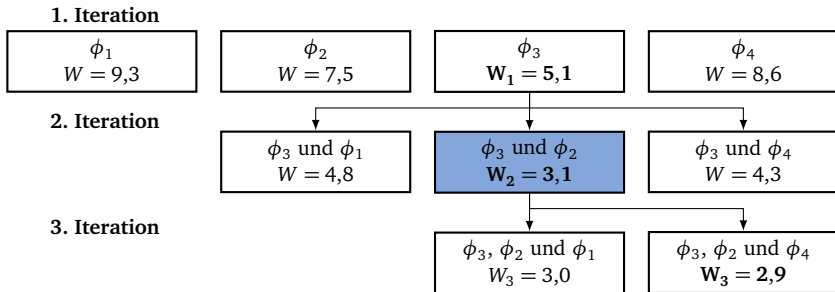


Abbildung 4.6.: Iteratives Vorgehen bei der Selektion von Merkmalen

Der Suchalgorithmus stoppt, sobald mit weiteren Merkmalen keine Verbesserung erzielt wird. Ist W_q das niedrigste Kriterium innerhalb der Iteration q , so stoppt die Suche, wenn die Bedingung

$$\frac{W_{q-1} - W_q}{W_{q-1}} < \epsilon \quad (4.15)$$

erfüllt ist. Die Abbruchbedingung wird über den Parameter ϵ festgelegt. Dieser beschreibt, welche prozentuale Verbesserung das Hinzufügen eines Merkmals minimal erreichen muss, damit es selektiert wird. Ist die Bedingung erfüllt, liefert die letzte Iteration q keine weiteren Informationen, sodass $q - 1$ Merkmale selektiert werden. Je geringer die Abbruchbedingung definiert wird, desto mehr Merkmale werden für das Klassifikationsproblem gewählt. Das Kriterium W_{q-1} ist ein Indikator dafür, welche Performanz der Klassifikator bei der Zuordnung der Schadenszustände erreicht.

Die Berechnung des Kriteriums W mit einer gewählten Merkmalskombination wird anhand U Schätzungen des Klassifikators durchgeführt. Liegt eine einzelne Schätzung $\tilde{\psi}_{SZ,u}$ und die dazugehörige wahre Größe $\psi_{SZ,u}$ vor, so wird diese mit

$$w_u = (\psi_{SZ,u} - \tilde{\psi}_{SZ,u}) \cdot \mathbf{g} \quad (4.16)$$

bewertet. Über den Vektor \mathbf{g} mit der Dimension $Z \times 1$ werden die Schätzungen der einzelnen Schadenszustände gewichtet. Liegt ein hoher Schadenszustand vor, wäre eine Einordnung in einen zu niedrigen Schadenszustand unter Umständen mit katastrophalen Folgen verbunden. Um diese Tatsache zu berücksichtigen, wird der Vektor mit

$$\mathbf{g} = [1 \quad 2 \quad \dots \quad Z]^T \quad (4.17)$$

definiert und gewichtet somit Fehler bei höheren Schadenszuständen stärker. Das Kriterium W ergibt sich schließlich aus dem Mittelwert der einzelnen Bewertungen

$$W = \frac{1}{U} \sum_{u=1}^U w_u. \quad (4.18)$$

Die Anwendung der Methode ist nicht auf die Daten eines einzelnen Schadensverlaufs beschränkt. Vielmehr werden alle Verläufe, welche der gleichen Schadensgruppe zugeordnet sind, gleichzeitig analysiert. In diesem Fall ist das Kriterium ein Maß dafür, wie gut der Schadenszustand für alle Verläufe mit dem gleichen Set an Merkmalen bestimmt werden kann und dient damit als Grundlage für das Gruppieren der Verläufe in Abschnitt 4.2.2.

4.2.2 Zuordnung und Klassifikation der Schadensgruppen

In diesem Abschnitt wird der Lösungsansatz für die Gruppierung von Degradierungsprozessen eines technischen Systems vorgestellt. Es wird beschrieben, wie einem Schadensverlauf in der Datenbasis eine Schadensgruppe zugeordnet und in der Testphase ein Merkmalsvektor klassifiziert wird. Die Gruppierung der J Schadensverläufe basiert auf der hierarchischen Clusteranalyse. Ziel ist es, dass Verläufe innerhalb einer Gruppe ähnlicher zueinander sind als zu Verläufen in anderen Gruppen. Allen generierten Merkmalen eines Schadensverlaufs wird genau eine Schadensgruppe g zugeordnet. Das bedeutet, dass der wahre Vektor $\psi_{SG,k}$ bis auf einen Eintrag aus Nullen besteht.

Wie in Abschnitt 3.4.1 beschrieben, werden bei der hierarchischen Clusteranalyse Gruppen auf Basis eines Werts zusammengefasst, welche die Ähnlichkeit zweier Objekte beschreibt. Degradierungsprozesse werden als ähnlich angesehen, wenn der Schaden vom Zeitpunkt des Auftretens eines Fehlers bis zum Ausfall die gleichen Merkmale beeinflusst und der Zustand mit dem gleichen Set an Merkmalen geschätzt werden kann.

Als Ähnlichkeitsmaß bietet sich daher das erreichte Kriterium W aus der Merkmalsselektion an, siehe Abschnitt 4.2.1.3. Für Schadensverläufe, die im Rahmen der Merkmalsselektion ein geringes Kriterium erzielen, kann der gleiche Klassifikator zur Bewertung des Zustands verwendet werden. Für die Clusteranalyse wird das Ähnlichkeitsmaß $W_{x,y}$ eingeführt. Dieses ist durch das Kriterium W definiert, welches erzielt wird, wenn die Merkmalsselektion auf die Schadensverläufe der Schadensgruppen x und y angewendet wird. Je geringer der Wert ist, desto ähnlicher sind sich die beiden Schadensgruppen, da die Fehlerrate bei der Klassifikation der Schadenszustände gering ist.

In Abbildung 4.7 (links) ist das Vorgehen bei der hierarchischen Clusteranalyse dargestellt. Als Ausgangssituation dienen fünf Schadensverläufe desselben technischen Systems. Der erste Datensatz Φ_1 umfasst die vier Merkmale des Schadensverlaufs, welche in Abbildung 4.2 dargestellt sind. Die anderen vier Datensätze sind im Anhang C beschrieben und weichen vom ersten Datensatz ab. Die Analyse beginnt mit fünf Gruppen, wobei jede genau einen Schadensverlauf enthält. Anhand des Ähnlichkeitsmaßes wird die Distanz zwischen allen Gruppen untereinander berechnet. Innerhalb der ersten Iteration liegt die geringste Distanz zwischen der ersten und zweiten Gruppe vor ($W_{1,2} = 0,5$), sodass diese als Basis für eine neue Gruppe 6 dienen. Nachdem die Distanzen zur entstandenen Gruppe berechnet sind, werden erneut die beiden Gruppen mit der geringsten Distanz fusioniert ($W_{4,5} = 0,7$). Nach diesem Prinzip werden iterativ alle Gruppen zusammengeschlossen, bis sich alle Schadensverläufe innerhalb einer großen Gruppe befinden und das Vorgehen endet. In der Abbildung 4.7 ist das Zwischenergebnis nach drei Iterationsschritten dargestellt.

Das Ergebnis der hierarchischen Clusteranalyse wird in einem Dendrogramm visualisiert. Dieses veranschaulicht, in welcher Reihenfolge Datensätze gruppiert werden und welches Ähnlichkeitsmaß dabei vorlag. In Abbildung 4.7 (rechts) ist das Dendrogramm für die fünf Datensätze dargestellt. Wie viele Schadensgruppen letztendlich angenommen werden, erfolgt über die Definition eines Schwellwerts ζ , der die maximal zulässige Distanz zwischen Gruppen festlegt. Im vorliegenden Beispiel ($\zeta = 2$) entstehen zwei Schadensgruppen ($G = 2$). Das bedeutet, dass die Datensätze eins bis drei der ersten Gruppe sowie vier und fünf einer Zweiten zugeordnet werden. Geringe Schwellwerte führen zu mehr Gruppen mit wenigen

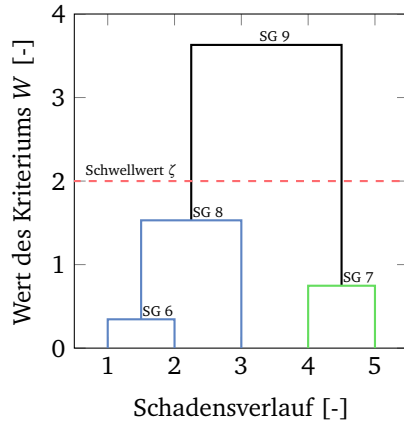
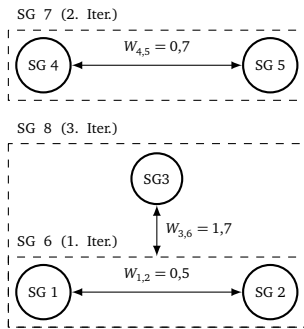


Abbildung 4.7.: Distanzberechnung zwischen den Schadensgruppen (SG) bei der hierarchischen Clusteranalyse (links) und Darstellung der Ergebnisse im Dendrogramm (rechts)

Instanzen, für die jeweils ein spezialisierter Klassifikator K_{SZ} für die Abschätzung des Schadenszustands trainiert wird. Dabei steigt die Gefahr der Überanpassung an die Daten und somit, dass der Klassifikator nicht auf neue Testdaten übertragbar ist. Durch einen höheren Schwellwert entstehen wenige Gruppen mit einem generalisierten Klassifikator K_{SZ} , welcher jedoch mehr Schätzfehler begeht, was an dem höheren Kriterium erkennbar ist. Der Einfluss verschiedener Werte für den Schwellwert ζ wird in Kapitel 5 und 7 diskutiert.

Als Resultat der Clusteranalyse ist jedem Merkmalsvektor innerhalb der Datenbasis eine wahre Schadensgruppe zugeordnet ($\phi_k \mapsto \psi_{SG,k}$). Auf Grundlage dieser Informationen findet das Training des Bayes-Klassifikators K_{SG} (siehe Gl. 4.3) statt. Dieses läuft grundsätzlich wie in Abschnitten 4.2.1.2 beschrieben ab, jedoch mit den Ausgabewerte $\psi_{SG,k}$. Das bedeutet, dass der trainierte Bayes-Klassifikator den Zusammenhang zwischen dem Merkmalsvektor und der entsprechenden Schadensgruppe modelliert.

Die Merkmalsselektion findet ebenfalls analog zu Abschnitt 4.2.1.3 statt. Mit Hilfe des Klassifikators K_{SG} und des vorgestellten Vorwärtsalgorithmus werden die relevanten Merkmale $\tilde{\phi}_{SG}$ für das Klassifikationsproblem selektiert. Die einzige Ab-

weichung betrifft den Gewichtsvektor \mathbf{g} . Auf Basis der Annahme, dass alle Schadensgruppen für die Zustandsbewertung gleich relevant sind, ist der Vektor durch

$$\mathbf{g} = [1 \quad 1 \quad \dots \quad 1]^T \quad (4.19)$$

gegeben und besitzt die Dimension $G \times 1$.

Wie in Abbildung 4.3 ersichtlich, entsteht in der Testphase eine Abfolge von zwei Bayes-Klassifikatoren. Mithilfe des Klassifikators K_{SG} wird zunächst die wahrscheinlichste Schadensgruppe $\tilde{\psi}_{SG,k}$ identifiziert. Anschließend findet, anhand für diese Schadensgruppe geeigneter Merkmale, eine Abschätzung des Schadenszustands $\tilde{\psi}_{SZ,k}$ durch den Klassifikator K_{SZ} statt.

4.3 Algorithmus zur Restlebensdauerprognose

Ist innerhalb der Testphase der Merkmalsvektor einer Schadensgruppe zugeordnet und der Schadenszustand geschätzt, ist das Ziel der Restlebensdauerprognose den Ausfallzeitpunkt in Form einer PDF abzuschätzen. Zu diesem Zweck wird der vergangene Trend der geschätzten Schadenszustände verwendet und mithilfe von bekannten Schadensverläufen eine Prognose der RUL durchgeführt. In Abbildung 4.8 ist das verwendete Konzept dargestellt. Die Prognose der RUL innerhalb einer Schadensgruppe basiert auf den J_g Schadensverläufen, welche im Rahmen der Clusteranalyse (siehe Abschnitt 4.2.2) der Gruppe zugeordnet werden. Jeder Verlauf dient als Grundlage für die Prognose eines möglichen zukünftigen Degradierungsverhaltens, sodass J_g Prognosen der RUL generiert werden. Abschließend findet eine Fusion der Ergebnisse statt. Im Folgenden wird näher auf die einzelnen Schritte eingegangen.




Abbildung 4.8.: Prinzip der Restlebensdauerprognose

Wird eine Prognose zu einem Zeitpunkt t_p durchgeführt, ist der bisherige Verlauf der Degradierung durch den geschätzten Schadenszustand

$$\tilde{\Psi}_T = \begin{bmatrix} \tilde{\psi}_{SZ,P} \\ \vdots \\ \tilde{\psi}_{SZ,P-e} \end{bmatrix} \quad (4.20)$$

gegeben. Der Parameter e beschreibt eine Fensterlänge, welche die für die Trendanalyse verwendete Zeitspanne definiert. Je kleiner dieser gewählt wird, desto schneller reagiert die Prognose auf abrupte Trendänderungen der Degradierung. Als Konsequenz kommt es jedoch zu größeren Schwankungen der prognostizierten RUL zwischen zwei Prognosezeitpunkten. Das Degradierungsverhalten eines in der Datenbasis vorhandenen Schadensverlaufs wird als eine Matrix in der Form

$$\tilde{\Psi}_j = \begin{bmatrix} \tilde{\psi}_{SZ,1} \\ \vdots \\ \tilde{\psi}_{SZ,K} \end{bmatrix} \quad (4.21)$$

beschrieben. Diese beinhaltet die geschätzten Schadenszustände des Datensatzes Φ_j . Für die Generierung von $\tilde{\Psi}_j$ wird der Klassifikator K_{SZ} der jeweiligen Schadensgruppe zur Abschätzung des Schadenszustands verwendet.

Die Prognose des weiteren Schadensverlaufs von $\tilde{\Psi}_T$ basiert auf der Annahme, dass ein ähnliches Degradierungsverhalten in dem bekannten Schadensverlauf $\tilde{\Psi}_j$ gefunden und daraus die RUL bestimmt werden kann. Die Suche wird über eine Faltung der beiden Matrizen $\tilde{\Psi}_j$ und $\tilde{\Psi}_T$ realisiert. Die Berechnung findet für jeden Schadenszustand z separat statt. Das Ergebnis der Faltung beschreibt der Vektor \mathbf{v}_j mit der Dimension $K \times 1$. Ist $\tilde{\psi}_{T,z}$ und $\tilde{\psi}_{j,z}$ der Spaltenvektor des Schadenszustands z der Matrizen $\tilde{\Psi}_T$ und $\tilde{\Psi}_j$, kann \mathbf{v}_j durch

$$\mathbf{v}_j = \sum_{z=1}^Z \tilde{\psi}_{T,z} * \tilde{\psi}_{j,z} \quad (4.22)$$

berechnet werden. Der Vektor \mathbf{v}_j beschreibt die Übereinstimmung zwischen $\tilde{\Psi}_T$ und $\tilde{\Psi}_j$. Das Ergebnis ist in Abbildung 4.9 gezeigt. Sowohl für das Testfenster $\tilde{\Psi}_T$ als auch für den Trainingsdatensatz $\tilde{\Psi}_j$ sind die geschätzten Schadenszustände dargestellt. Der berechnete Vektor \mathbf{v}_j deutet auf eine hohe Ähnlichkeit im Bereich von ungefähr 50 h hin.

Auf Basis des Vektors \mathbf{v}_j kann die PDF der RUL bestimmt werden. Dieses ist möglich, da der Ausfallzeitpunkt (engl. *End Of Life*, kurz *EoL*) t_{EoL} eines Trainingsdatensatzes $\tilde{\Psi}_j$ bekannt ist. Hierfür findet eine Transformation

$$\mathbf{v}'_j = T \cdot \mathbf{v}_j \quad (4.23)$$

statt. Wobei die Transformationsmatrix T die Dimension $K \times K$ besitzt und ausschließlich die Gegendiagonale mit Einsen besetzt ist. Dadurch wird der Ursprungsvektor \mathbf{v}_j umgedreht. In Abbildung 4.9 ist die Transformation des Vektors \mathbf{v}_j veranschaulicht. Es ist ersichtlich, dass der transformierte Vektor \mathbf{v}'_j eine Aussage über die zu erwartenden RUL ermöglicht. Unter der Annahme, dass ein ähnlicher Degradierungsprozess wie $\tilde{\Psi}_j$ vorliegt, beträgt die zu erwartende RUL ungefähr 100 h.

Die einzelnen Ergebnisse \mathbf{v}_j der J_g verfügbaren Degradierungsprozesse werden über

$$\mathbf{v} = \mathbf{v}'_1 + \mathbf{v}'_2 + \dots + \mathbf{v}'_{J_g} \quad (4.24)$$

zusammengefasst. Da die Zeitpunkte t_k eines Eintrages des Vektors \mathbf{v} bekannt sind, kann abschließend die Wahrscheinlichkeitsdichtefunktion r_{PDF} über eine Interpolation gewonnen werden. Dabei gilt

$$\int_{-\infty}^{\infty} r_{PDF}(t) dt = 1. \quad (4.25)$$

Da r_{PDF} auf unterschiedlichen Degradierungsprozessen der Schadensgruppe basiert, kann es sich um eine beliebige Verteilungsform handeln. Die zu erwartende Lebensdauer r_{50} wird daher über das 50%-Perzentil bestimmt. Die Unsicherheit der Prognose wird anhand des 5%- und 95%-Perzentils angegeben.

4.4 Generierung einer Handlungsempfehlung

Ein wichtiger Bestandteil eines PHM Systems besteht darin, eine Empfehlung zur Unterstützung von Instandhaltungsmaßnahmen zu generieren. Der vorgeschlagene Ansatz umfasst die Empfehlung, ob ein Austausch der Komponente initiiert werden sollte oder nicht. Zu diesem Zweck wird ein Sicherheitsfenster t_{SF} definiert. Ein Austausch der Komponente wird ab dem Zeitpunkt empfohlen, an dem die Bedingung

$$r_{50} < t_{SF} \quad (4.26)$$




Abbildung 4.9.: Vorgehen beim Abschätzen der Restlebensdauer: Faltung eines Testdatensatzes $\tilde{\Psi}_T$ mit einem Trainingsdatensatz $\tilde{\Psi}_j$ und anschließende Transformation des Faltungsvektors \mathbf{v}_j zu \mathbf{v}'_j

erfüllt ist. Das Vorgehen ist in Abbildung 4.10 illustriert. Es ist die wahre und geschätzte RUL des Prognoseansatzes über der Versuchszeit dargestellt. Bei einem Sicherheitsfenster von $t_{SF} = 5$ h liegt der Austauschzeitpunkt t_A bei ungefähr 20 h. Als Folge kommt es zu einem Verlust von über zehn Stunden der restlichen Nutzungsdauer. Wird ein Sicherheitsfenster von $t_{SF} = 2,5$ h gewählt, wird die Komponente länger verwendet und die Lebensdauer fast vollständig ausgenutzt.

Das Kernproblem ist die Wahl eines optimalen Sicherheitsfensters $t_{SF,opt}$. Allen voran ist $t_{SF,opt}$ eine Funktion der Leistungsfähigkeit des Prognosealgorithmus. Je näher die prognostizierte RUL an der Wahren liegt, desto niedrigere Werte können für $t_{SF,opt}$ angenommen werden, ohne einen ungeplanten Ausfall zu riskieren. Neben der Prognosefähigkeit des Algorithmus ist $t_{SF,opt}$ von möglichen Konsequenzen eines Ausfalls oder zu frühen Austausches abhängig. Kann es zu katastrophalen Folgen aufgrund eines verpassten Versagens kommen, sollte ein größeres Sicherheitsfenster gewählt werden. Wie in Abschnitt 2.2 gezeigt, können die Folgen durch korrektive und präventive Instandhaltungskosten beschrieben werden. In Kapitel 7 wird der optimale Wert $t_{SF,opt}$ des entwickelten Prognosealgorithmus näher untersucht.

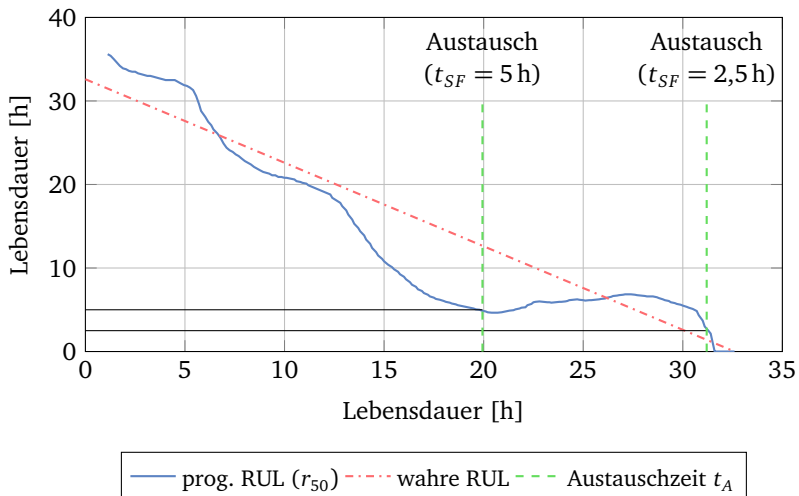


Abbildung 4.10.: Wahl des Wartungszeitpunkts in Abhängigkeit eines Sicherheitszeitraums t_{SF} bei kontinuierlicher Überwachung der RUL

4.5 Vergleichsalgorithmus

Um die Leistungsfähigkeit des entwickelten Konzepts zur Selektion von Merkmalen bewerten zu können, wird an dieser Stelle ein Vergleichsalgorithmus vorgestellt. Die Struktur des Algorithmus ist in Abbildung 4.11 dargestellt. Die Prognose der RUL sowie die Generierung einer Handlungsempfehlung verwenden die gleichen Algorithmen wie beim vorgestellten PHM System. Für die Klassifikation des Schadenszustands wird ebenfalls der Bayes-Klassifikator genutzt. Jedoch basiert die Datenreduktion auf dem Prinzip der Merkmalsextraktion. Hierfür wird auf die PCA zurückgegriffen, welche in [BMZR12] und [APK15] für die Extraktion von geeigneten Merkmalen für die Prognose vorgestellt wird. Eine Gruppierung der Schadensverläufe findet bei diesem Ansatz nicht statt.

Mithilfe der PCA werden die ursprünglichen Merkmale eines Datensatzes über eine Linearkombination in wenige aussagekräftige Hauptkomponenten überführt. Ziel ist es, dass die erste Komponente den größten Teil der Variation der ursprünglichen Daten wiedergibt. Jede weitere Hauptkomponente beschreibt immer weniger der Variation. Als Konsequenz wird mit einigen wenigen Komponenten die Dimension reduziert. In Abbildung 4.12 (links) sind die ersten drei Hauptkomponenten dargestellt, wenn die PCA auf den fiktiven Datensatz angewendet wird.

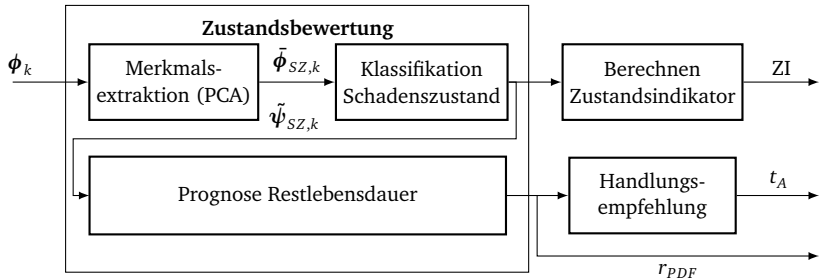


Abbildung 4.11.: Aufbau des Vergleichsalgorithmus zur Abschätzung des Schadenszustands und des Zustandsindikators (ZI) auf Basis der PCA

Diese beschreiben ungefähr 99 % der Variation des Datensatzes. Um möglichst viele Informationen zu behalten, werden für die Klassifikation des Schadenszustands, so viele Hauptkomponenten gewählt, dass 97% der Varianz des ursprünglichen Datensatzes erfasst werden [BMZR12]. In Abbildung 4.12 (rechts) ist das Ergebnis gezeigt, wenn die Klassifikation des Schadenszustands anhand der ersten drei Hauptkomponenten durchgeführt wird.

4.6 Zusammenfassung

In diesem Kapitel wurde der Lösungsansatz für die Problemstellung dieser Arbeit vorgestellt. Der entwickelte Ansatz für ein PHM System ermöglicht die selbstständige Selektion von Merkmalen für die Restlebensdauerprognose sowie eine Gruppierung von verfügbaren Degradierungsprozessen mit dem Ziel, die Zustandsbewertung eines technischen Systems zu verbessern.

Ersteres wird durch die Einführung von Schadenszuständen, welche das technische System bis zum Ausfall durchläuft, erreicht. Durch das resultierende Klassifikationsproblem kann auf Techniken aus dem Bereich der Merkmalsselektion zurückgegriffen werden. Diese ermöglichen die Bewertung und Selektion unterschiedlicher Kombinationen der verfügbaren Merkmale hinsichtlich ihres Potenzials zur Verbesserung des Klassifikationsproblems. Für die Modellierung eines Zusammenhangs zwischen den Eingangs- und Ausgangsdaten wird ein Bayes-Klassifikator eingesetzt.

Ein Vorteil des gewählten Ansatzes zur Selektion der Merkmale ist, dass ein Kriterium bestimmt wird, welches die Güte der Zustandsbewertung beschreibt und als Basis für die Gruppierung von Schadensverläufen dient. Durch die Verwendung

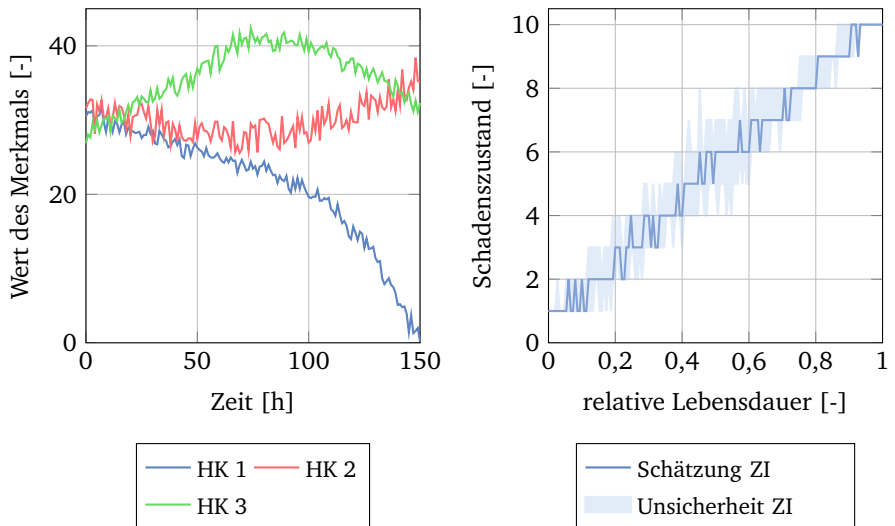


Abbildung 4.12.: Die ersten drei Hauptkomponenten (HK) der PCA (links) sowie der geschätzte Zustandsindikator (ZI) auf Basis der Hauptkomponenten (rechts)

einer hierarchischen Clusteranalyse ist es möglich, Gruppen von ähnlichen Schadensverläufen zu bilden. Die dadurch entstehenden Schadensgruppen beinhalten jeweils Degradierungsprozesse, deren Schadensausmaß mit dem gleichen Set an Merkmalen abgeschätzt werden kann.

Des Weiteren wird ein deterministischer und robuster Ansatz für die Prognose der RUL und die Generierung einer Handlungsempfehlung verwendet. Diese ermöglichen in Kapitel 7 die Untersuchung der entwickelten Methoden zur Zustandsbewertung auf Basis der Prognosefähigkeit und des berechneten Austauschzeitpunkts.



5 Verifikation am Anwendungsfall eines Asynchronmotors

Ziel dieses Kapitels ist die Verifikation der entwickelten Lösungsansätze anhand realer Messdaten. Zunächst werden in Abschnitt 5.1 die verwendete Testumgebung und Messtechnik vorgestellt. Als Prüfling dient ein Asynchronmotor, der bereits in [HMN⁺13] zur Diagnose von Schadensfällen und in [Mik15] für die Validierung eines Prognosealgorithmus anhand von Vibrationsdaten zum Einsatz kam. In Abschnitt 5.2 werden die durchgeführten Versuche beschrieben und welche Methode zur Generierung von Merkmalen für den Aufbau einer Datenbasis verwendet wurde. Diese dient in Abschnitt 5.3 als Grundlage für die Verifikation der Algorithmen sowie in Kapitel 7 zur Untersuchung der Leistungsfähigkeit des Ansatzes.

5.1 Testumgebung

In Abbildung 5.1 (links) ist die verwendete Drehstrommaschine gezeigt. Es handelt sich um einen luftfahrttauglichen Axiallüfter, welcher einen maximalen Volumenstrom von 235 l/s erzeugt. Der Motor ist ein Asynchronmotor mit drei Phasen und zwei Polpaaren. Die Versorgungsfrequenz des Prüflings liegt bei 400 Hz bei einer Spannungsversorgung von 115 VAC. Unter normalen Betriebsbedingungen erreicht der Rotor eine konstante Drehzahl von ungefähr 11 300 rpm, was 188 Hz entspricht. In diesem Zustand wird eine Leistung von 900 W bei einem Effektivstrom von 3,2 A benötigt.

In Abbildung 5.1 (rechts) ist der Versuchsaufbau dargestellt. Die gesamte Testumgebung ist auf einem Maschinenbett montiert. Für die Durchführung vergleichbarer Versuche sind eine gleichbleibende, homogene Anströmung und ein definierter Volumenstrom entscheidend. Um diese Anforderungen zu unterstützen, ist der Axiallüfter in einem Rohrsystem montiert, bei dem die Zu- und Abluft mit dem Außenbereich verbunden ist. Hinter dem Lüfter befindet sich eine Absperrklappe mit einem montierten Stellmotor, welcher den Volumenstrom reguliert. Die Strömung wird über einen Drucksensor am Ende des Rohrsystems gemessen. Die Regelung ist über einen PI-Regler realisiert. Betrieben wird der Prüfstand über eine variable Leistungsversorgung der Firma ELGAR Electronics.



Abbildung 5.1.: Foto des verwendeten Axiallüfters (links) und Gesamtansicht der Testumgebung (rechts)

5.1.1 Verwendete Messtechnik

Die Messdatenerfassung ist über ein DSpace System realisiert. Dieses zeichnet die Ströme der drei Phasen des Asynchronmotors auf. Bei den verwendeten Stromsensoren handelt es sich um Hall-Sensoren. Diese messen den Strom durch das um den Leiter entstehende Magnetfeld und erlauben somit eine berührungslose Messung. Diese galvanische Trennung hat den Vorteil, dass der bestehende Stromkreis nicht verändert wird und die Sensorik somit leicht in ein bestehendes System integriert werden kann.

Neben den Motorströmen werden die Vibrationen am Motorgehäuse erfasst. Diese werden über drei Piezo-Beschleunigungssensoren der Firma Kistler aufgenommen. Ein Montagewürfel erlaubt eine exakte dreiachsige Ausrichtung der Sensoren, siehe Abbildung 5.2. Ein Signalaufbereitungsgerät dient zur Verstärkung und Filterung der Signale, bevor diese weiter verarbeitet werden.

Die Messdaten der drei Stromsensoren und der drei Vibrationsaufnehmer werden jeweils mit einer Abtastfrequenz von 25 kHz digitalisiert. Zur Vermeidung von Aliasing-Effekten wird, entsprechend des Shannon-Kriteriums, ein analoges Tiefpassfilter mit einer Eckfrequenz von 10 kHz verwendet. Weitere Messgrößen sind die Rotordrehzahl, die Umgebungstemperatur und der Volumenstrom. Diese werden einmal pro Sekunde abgetastet. Im Anhang D sind die verwendeten Sensoren mit der jeweiligen Typenbezeichnung zusammengefasst.




Abbildung 5.2.: Foto des eingebauten Prüflings mit angebrachter Sensorik

5.1.2 Abgrenzung zu bestehenden Prüfständen

In Abschnitt 3.6 wurden verschiedene Plattformen für die Validierung von Prognosealgorithmen vorgestellt. Alle betrachteten Prüfstände basieren auf einer Drehstrommaschine und ermöglichen die Generierung von Schadensdaten der Lagerelemente. Das zu untersuchende Lagerelement befindet sich jeweils außerhalb der Drehstrommaschine. Der Grund liegt darin, dass für die künstliche Alterung eine externe Belastung aufgebracht wird. Hierfür ist eine separate Apparatur notwendig, die aufgrund des begrenzten Bauraumes nicht innerhalb des Motors untergebracht werden kann. Als Konsequenz wird das Lagerelement auf einer zweiten Welle montiert, welche über ein Getriebe oder eine Kupplung angetrieben wird. Im Fokus der in Abschnitt 3.6 vorgestellten Forschungsarbeiten liegt die Auswertung der Vibrationen. Die Begründung dafür ist, dass Schwingungen aufgrund der Degradierung direkt am ausgelagerten Lagerelement erfasst werden können.

Die hier verwendete Plattform grenzt sich von den in der Literatur beschriebenen Prüfständen dadurch ab, dass das zu untersuchende Lagerelement innerhalb der Drehstrommaschine liegt. Als Konsequenz bietet sich der Phasenstrom als Grundlage einer Restlebensdauerprognose an. Die Degradierung tritt direkt in der Drehstrommaschine auf, wodurch die Auswirkung auf den Rotor und somit auf das magnetische Feld größer ist, da die Vibrationen nicht durch ein Getriebe abgeschwächt oder gänzlich eliminiert werden. Ein weiterer Unterschied liegt in den Drehzahlen der betrachteten Lagerelemente. Während die vorgestellten Plattformen maximale Drehgeschwindigkeiten von ungefähr 5000 rpm erreichen, liegt die Drehzahl des verwendeten Motors mehr als doppelt so hoch. Somit erlaubt der

Prüfstand die Untersuchung, ob eine Identifizierung von Merkmalen für die Beschreibung des Schadenszustands trotz hoher Geschwindigkeiten möglich ist. Zudem handelt es sich bei dem betrachteten Asynchronmotor um ein fertiges Produkt, welches in der Luftfahrt zur Anwendung kommt. Die Untersuchung von Algorithmen zur Prognose der RUL ist daher von besonderem Interesse.

5.2 Experimente zur Untersuchung von Lagerschäden

Eine große Herausforderung bei der Verifizierung und Validierung von datenbasierten Prognosealgorithmen ist die Generierung von repräsentativen Datensätzen. Um als Trainings- oder Testdaten dienen zu können, muss ein Datensatz den Degradierungsprozess einer Komponente vom Auftreten eines Fehlers bis zum Ausfall abbilden und dabei einen gewissen Grad an Homogenität besitzen.

Wie in Abschnitt 3.6 erwähnt, ist der Verschleiß der Lagerelemente bei Elektromotoren eine der häufigsten mechanischen Versagensarten. Das vordere Lagerelement der Rotorwelle, siehe Abbildung 5.3, bietet sich für die Untersuchung des Degradierungsprozesses an, da dieses aufgrund der Lage zum Propeller eine höhere dynamische Belastung erfährt. Mit dem Ziel, den natürlichen Alterungsprozess in einem akzeptablen Zeitraum herbeizuführen, kamen modifizierte Kugellager während der Experimente zum Einsatz.




Abbildung 5.3.: Skizze und Foto des Rotors und der Lagerelemente

Voruntersuchungen, bei denen Lager mit einer geringen Vorschädigung (2 mm Bohrungen im Außen- oder Innenring) montiert wurden, konnten innerhalb von zwei Wochen im Dauerbetrieb keine beschleunigte Degradierung initiieren. Auch eine Dauerbelastung durch die Einbringung von Unwuchten am Propeller und die Kontaminierung mit Quarzpartikeln waren nicht erfolgreich. Erst eine Verschmut-

zung des Schmiermittels mit einer geringen Menge an Diamantenpolierpaste führte zum Ausfall des Motors. In Abbildung 5.4 sind die Lagerelemente und die Polierpaste für die Verunreinigung dargestellt.



Abbildung 5.4.: Vorderes Lagerelement mit und ohne Abdichtung (links) sowie synthetische Diamantenpolierpaste für die Verunreinigung der Lager (rechts)

Um eine Vergleichbarkeit der Experimente zu gewährleisten, wird jedes Lagerelement mit der gleichen Menge an synthetischen Diamanten (20 mg) verunreinigt und der Volumenstrom auf konstante 235 l/s geregelt. Zudem wurde anhand von Referenzmessungen sichergestellt, dass sich der Motor für jedes Experiment in einem vergleichbaren Ursprungszustand befindet. Hierfür wurde der Motor vor jedem Versuch zwei Stunden mit intakten Lagern betrieben und das Frequenzspektrum der Stromsignale mit den vorherigen Experimenten verglichen. Außerdem konnte mit diesen Messungen gewährleistet werden, dass der Einfluss der Montage und Demontage auf den Ursprungszustand des Asynchronmotors im Vergleich zu den Auswirkungen eines Schadens vernachlässigbar ist. In Anhang E sind beispielhaft Frequenzspektren von vier Referenzmessungen dargestellt.

Durch einen integrierten Überlastschutz wird der Motor beim Überschreiten einer maximalen effektiven Stromaufnahme von 5 A automatisch abgeschaltet und somit ein dauerhafter Schaden vermieden. Dies bedeutet, dass eine gesteigerte Leistungsaufnahme von ungefähr 60 % als Ausfall des jeweiligen Prüflings interpretiert wird. Eine visuelle Inspektion des Motors und des vorderen Lagerelementes nach dem Ausfall deutet auf zwei unterschiedliche Versagensarten hin. Zum einen führt ein erhöhter Abrieb an den Laufbahnen infolge der Verschmutzung zu einem unzulässig großen Lagerspiel. Dies hat zur Folge, dass sich sowohl Propeller und Gehäuse als auch Rotor und Stator berühren. Zum anderen kommt es zu einem Aufreißen des Metallkäfigs, wobei sich die offenen Enden des Käfigs verbiegen und den

Laufweg der Kugeln blockieren. Beide Schadensarten erhöhen den mechanischen Widerstand und als Folge auch die benötigte Antriebsleistung, welche letztendlich zu einem Abschalten der Spannungsversorgung führt. Die beiden Ausfallarten sind in Abbildung 5.5 festgehalten.




Abbildung 5.5.: Erhöhtes Lagerenspiel aufgrund des gestiegenen Verschleißes an den Laufbahnen (links) sowie zwei zerstörte Käfige mit und ohne Lager (rechts)

Insgesamt wurden 18 Experimente mit modifizierten Lagerelementen durchgeführt und stehen für die Untersuchung zur Verfügung. Die durchschnittliche Versuchsdauer bis zum automatischen Abschalten der Stromversorgung beträgt ungefähr 40 h Stunden. Trotz der gleichen Ausgangssituation variieren die Ausfallzeiten erheblich. Während der kürzeste Versuch 7 h dauerte, trat der späteste Ausfall nach 112 h auf. Eine genaue Auflistung aller Experimente mit der jeweiligen Versuchsdauer befindet sich in Anhang F. Es wird angenommen, dass die große Streuung (die Standardabweichung beträgt 30 h) der Versuchszeiten auf die ungleichmäßige Verteilung der Diamantenpaste zurückzuführen ist. Nach einem Ausfall des Motors ist beobachtbar, dass ein Teil der Diamantenpaste mit dem Schmiermittel aus den Laufbahnen der Kugeln gespült wird und als Ablagerung an den Dichtungsscheiben sichtbar ist. Da es sich dabei um einen stochastischen Prozess handelt, kommt es zu unterschiedlichen Geschwindigkeiten des Degradierungsprozesses. Dieser Prozess tritt ebenfalls unter realen Bedingungen auf, sodass angenommen wird, dass die Datensätze das Verhalten des Asynchronmotors bei Verschmutzungen des Lagerelementes durch Partikel repräsentieren.

5.2.1 Generierung einer Datenbasis

Als Grundlage für die Erzeugung der Merkmale dienen Messschriebe mit einer Länge von 10 s, welche alle 180 s bis zum Ausfall aufgezeichnet wurden. Im Anwendungsfall des Asynchronmotors werden Merkmale aus den Messdaten der Stromsensoren gewonnen. Zu diesem Zweck wird jeweils ein Messschrieb sowohl im Zeit- als auch im Frequenzbereich analysiert.

Mithilfe der FFT wird das gemessene Stromsignal der Motorphase a in seine Frequenzanteile zerlegt. In Abbildung 5.6 ist das Frequenzspektrum des Stromsignals für zwei Messaufzeichnungen dargestellt. Dabei handelt es sich um eine Referenzmessung und um eine Messung, bei welcher der Degradierungsprozess weit fortgeschritten ist. Die Auswirkung des Schadens ist deutlich in den Frequenzbereichen von 450 Hz bis 550 Hz erkennbar. Aufgrund unterschiedlicher Schadensbilder der Verläufe kann nicht davon ausgegangen werden, dass dieser Bereich immer betroffen ist und sich zur Beschreibung des Schadenszustands eignet. Um für die Algorithmen verwertbare Informationen zu generieren, wird das Frequenzspektrum in Bänder eingeteilt. Wie in Abbildung 5.6 dargestellt, umfassen diese jeweils 20 Hz und überlappen sich um 5 Hz. Insgesamt wird der Bereich von 0 Hz bis 6000 Hz abgedeckt, wodurch 400 Bänder entstehen. Jedes Band wird durch ein Merkmal repräsentiert, welches sich aus dem Mittelwert der Amplitudenwerte innerhalb eines Bandes ergibt. Der Zeitbereich wird über die Standardabweichung, Schiefe und Wölbung der drei Phasenströme abgedeckt. Somit wird ein Messschrieb von zehn Sekunden durch insgesamt 409 Merkmale zusammengefasst.

Bereits zu Beginn eines Versuchs weichen dieselben Merkmale zwischen unterschiedlichen Experimenten voneinander ab. Dabei handelt es sich um einen Offset, der beispielsweise durch eine Unregelmäßigkeit bei der Montage des Motors oder der unterschiedlichen Verteilung der Polierpaste auftreten kann. Um diese Abweichungen zu eliminieren, wird jedes Merkmal als relative Änderung im Bezug auf den Mittelwert der ersten zehn Messungen (30 min) berechnet. Das bedeutet, dass die resultierenden Merkmale die Veränderung vom intakten Zustand infolge der Degradierung des Systems wiedergeben. Abschließend erfolgt eine Glättung der Daten durch die Verwendung des gleitenden Mittelwerts mit einer Fensterlänge von 1 h, wodurch das Rauschen der Daten reduziert und der Einfluss von Ausreißern verringert wird.

In Abbildung 5.7 sind 40 Merkmale der Versuche #1, #6, #14 und #18 bis zum Ausfall des Motors dargestellt. Die Merkmale umfassen einen Frequenzbereich von 150 Hz bis 755 Hz des Stromspektrums. Es ist deutlich erkennbar, dass sich die Degradierungsprozesse der vier Versuche unterscheiden. In den Versuchen #1 und #14 steigen bereits kurz nach Beginn ein Großteil der Merkmale an. Anschließend




Abbildung 5.6.: Generierung der Merkmale aus dem Frequenzbereich des Stromsignals der Phase a

verbleiben diese auf einem hohen Niveau und nehmen bis zum Ausfall nur noch leicht zu. Bei den anderen beiden Degradierungsprozessen werden einzelne Merkmale angeregt, die annähernd exponentiell bis zum Ausfall anwachsen. Kurz vor dem Ende werden zudem alle Merkmale sichtbar größer. Die vier dargestellten Versuche verdeutlichen die Problemstellung dieser Arbeit und die Herausforderung trotz der unterschiedlichen Degradierungsprozesse, Merkmale zu identifizieren, welche für die Einschätzung des Zustands eines Systems verwendet werden können.

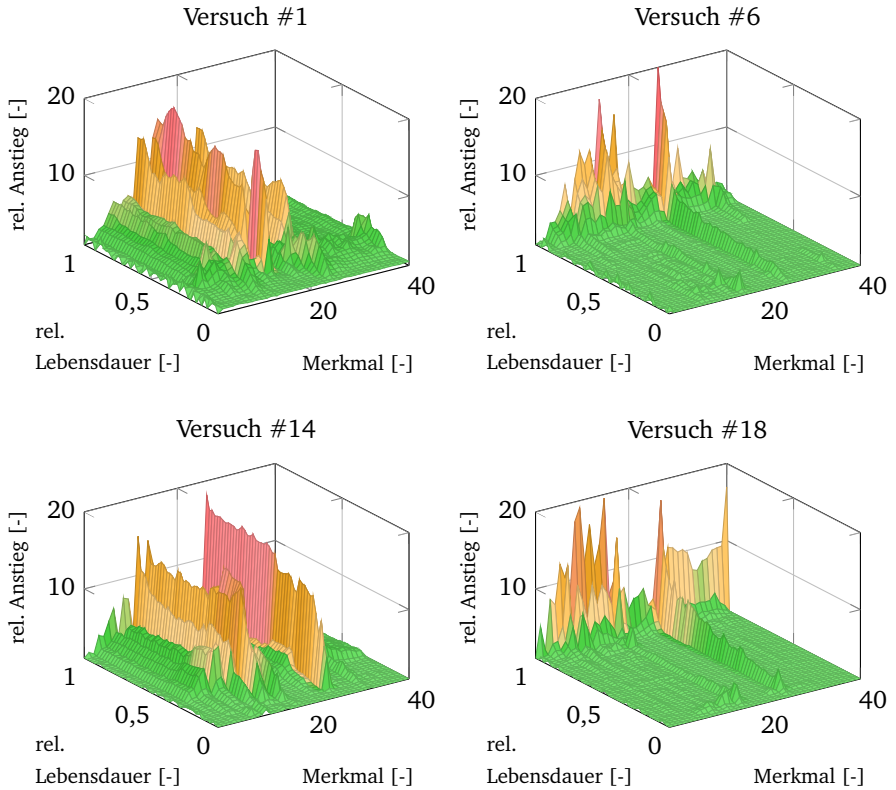


Abbildung 5.7.: Entwicklung von 40 Merkmalen (150 Hz bis 755 Hz) der Versuche #1, #6, #14 und #18 bis zum Ausfall des Motors

5.3 Verifikation des PHM Systems

Durch die Verifikation wird überprüft, ob die entwickelten Algorithmen ihre vorgesehene Funktion korrekt erfüllen. Nach [HT10, S. 95-105] wird zwischen formalen und simulativen Verifikationsmethoden unterschieden, die Extrema bezüglich der Vollständigkeit und Anwendbarkeit darstellen. Die Grundlage der formalen Verifikation ist die Prüfung der mathematischen Logik hinter den Algorithmen. Diese ist in der Regel für das gesamte System nicht möglich oder sehr aufwendig, sodass sich bei der Verifikation auf Teilsysteme oder stark abstrahierte Elemente beschränkt wird. Bei der simulativen Methode werden die Algorithmen mit ausgewählten Testszenarien stimuliert und das Verhalten mit dem zu erwarteten Verhalten gegenübergestellt. Der Vorteil des simulativen Vorgehens ist, dass der gesamte Algorithmus betrachtet wird. Demgegenüber steht, dass nur die formale Methode vollständig ist und die Abwesenheit von Fehlern aufzeigen kann. Die simulative Verifikation ist dazu nicht in der Lage, da es nicht möglich ist alle Anwendungsfälle durch einige ausgewählte Testszenarien zu simulieren. Daher liegt der primäre Nutzen vielmehr darin, durch eine umfangreiche Simulation des Anwendungsfalles das Vertrauen in die Algorithmen zu erhöhen. [HT10, S. 100]

Um die entwickelten Algorithmen zu verifizieren, wird in dieser Arbeit eine simulative Verifikation bevorzugt. Dieses ist insbesondere dadurch motiviert, dass die durchgeführten Experimente die Generierung einer umfangreichen Datenbasis ermöglichen, um unterschiedliche Anwendungsfälle für eine Verifikation zu erstellen. Auch wenn es sich dabei um eine unvollständige Verifikationsmethode handelt, wird angenommen, dass die gewonnenen Erkenntnisse auch auf weitere Schadensverläufe übertragbar sind. Die Verifikation ist in drei Teile gegliedert, wobei jeder den Nachweis einer der folgenden Spezifikationen verfolgt:

1. Der Algorithmus selektiert Merkmale aus Datensätzen, welche es ermöglichen den Schadenszustand zu klassifizieren.
2. Der Algorithmus verbessert die Zustandsbewertung durch die Gruppierung von Schadensverläufen.
3. Der Algorithmus ermöglicht die Prognose der Restlebensdauer auf Basis von verfügbaren Schadensverläufen.

Die ersten beiden Teile beleuchten die verwendeten Algorithmen zur Zustandsbewertung, welche in Abschnitt 4.2 vorgestellt wurden. Während der Erste die Klassifikation des Schadenszustands innerhalb einer Schadensgruppe verifiziert, analysiert der zweite Teil die Funktionsweise des hierarchischen Clusteralgorithmus sowie des dazugehörigen Klassifikators zur Einteilung von Schadensverläufen

in der Testphase. Der letzte Teil überprüft den Algorithmus zur Restlebensdauerprognose.

5.3.1 Merkmalsselektion und Klassifikation des Schadenszustands

Ziel dieses Abschnittes ist es zu überprüfen, ob der Algorithmus Merkmale selektiert, welche eine Klassifikation des Schadenszustands ermöglichen. Der Nachweis wird sowohl auf Basis einzelner als auch auf beliebigen Kombinationen von Schadensdatensätzen erbracht. Zur Bewertung der Ergebnisse wird das im Rahmen der Merkmalsanalyse hergeleitete Kriterium W herangezogen, siehe Abschnitt 4.2.1.3. Da W über eine gewichtete Fehlerrate berechnet wird, beschreibt dieses die Leistungsfähigkeit des Klassifikators bei der Einordnung der Schadenszustände. Die Anzahl der Schadenszustände ist auf $Z = 10$ festgelegt. Die Abbruchbedingung des Suchalgorithmus wird für die folgende Analyse nicht verwendet, stattdessen werden die fünf besten Merkmale gewählt.

Zunächst wird die Leistungsfähigkeit bei der Verwendung von einzelnen Schadensverläufen untersucht. Zu diesem Zweck werden die Merkmale von jedem der 18 Datensätze separat analysiert und betrachtet, welche Werte das Kriterium erreicht. In Abbildung 5.8 (links) ist die Entwicklung über einer steigenden Anzahl an gewählten Merkmalen dargestellt. Die Werte des Kriteriums für die 18 Datensätze werden durch den Median und die Perzentile (5 % und 95 %) repräsentiert. Es ist ersichtlich, dass jedes hinzugefügte Merkmal zu einer Verbesserung führt, welche mit einer steigenden Anzahl abnimmt. Das bedeutet, dass der Informationsgewinn durch hinzugefügte Merkmale geringer wird, wodurch keine weitere Optimierung der Klassifizierung des Schadenszustands stattfindet. Für alle verfügbaren Schadensverläufe erreicht das Kriterium Werte unterhalb von eins.

Um die Aussagekraft des Kriteriums zu veranschaulichen, ist in Abbildung 5.8 (rechts) das Ergebnis des berechneten Zustandsindikators über der relativen Lebensdauer für $W = 0,8$ bei der Verwendung von drei Merkmalen dargestellt. Im Idealfall durchläuft ein Verlauf vom Auftreten des Fehlers bis zum Ausfall die zehn definierten Schadenszustände gleichmäßig. Anhand der gewählten Merkmale liegt das Ergebnis der Klassifikation dicht an den definierten Schadenszuständen und ermöglicht somit eine zuverlässige Aussage über den Zustand der Komponente.

Der Nachweis an einzelnen Schadensverläufen zeigt, dass jeder Datensatz Merkmale besitzt, welche sich bis zum Ausfall signifikant verändern und somit eine eindeutige Einordnung zulassen. Dieses bedeutet jedoch nicht, dass diese Merkmale darüber hinaus ebenfalls bei anderen Schadensverläufen eine zuverlässige Klassifikation des Zustands zulassen. Mit dem Ziel zu überprüfen, ob der Algorithmus allgemein verwendbare Merkmale findet, wird das Ergebnis der Merkmalsanalyse







Abbildung 5.8.: Entwicklung des Kriteriums W mit einer steigenden Anzahl an Merkmalen (links) und Einfluss des Kriteriums auf die Schätzung des Zustandsindicators (ZI) (rechts)

untersucht, wenn diese auf mehrere Datensätze von verschiedenen Schadensverläufen angewendet wird. Im Rahmen der Verifikation werden die Ergebnisse aus hundert zufällig gewählten Kombinationen mit drei und fünf Datensätzen analysiert.

In Abbildung 5.8 (links) ist die Auswirkung auf das Kriterium sichtbar, welche ebenfalls als Verteilung der Ergebnisse dargestellt ist. Das Kriterium verschlechtert sich bei der Verwendung von mehr als einem Datensatz. Das bedeutet, dass der trainierte Klassifikator anhand der selektierten Merkmale den Schadenszustand der jeweiligen Kombination schlechter einordnet. Dieses zeigt sich auch in Abbildung 5.8 (rechts). Die schlechteren Werte führen zu einer höheren Abweichung zum idealen Schadenszustand. Insbesondere bei $W = 4,0$ kommt es vor dem Ausfall zu einer Fehleinschätzung des Zustands. Demgegenüber steht, dass die selektierten Merkmale für die jeweilige Kombination der Datensätze gültig sind. Die Auswirkung der Verschlechterung des Kriteriums W auf die Restlebensdauerprognose wird näher in Abschnitt 7.1 betrachtet.

In den Diagrammen in Abbildung 5.9 sind die Ergebnisse der Berechnung des Zustandsindikators für eine Kombination aus drei Datensätzen (#9, #10 und #12) über der Zeit abgebildet. Während in der linken Darstellung der Schadenszustand anhand eines Merkmals ($W = 2,5$) eingeordnet wird, sind die Ergebnisse rechts unter Verwendung von drei Merkmalen ($W = 1,5$) erzielt. Zudem ist die Unsicherheit der Klassifikation für den Versuch #12 dargestellt. Bereits bei der Verwendung von einem Merkmal ist ein steigender Trend für alle Versuche sichtbar. Problematisch ist die große Unsicherheit der Klassifikation, da bereits bei einer mittleren Versuchsdauer der Klassifikator hohe Zustände in Betracht zieht. Bei der Nutzung der Information aller drei Merkmale verbessert sich die Klassifikation des Zustands bei Versuch #12 und die Unsicherheit verringert sich.

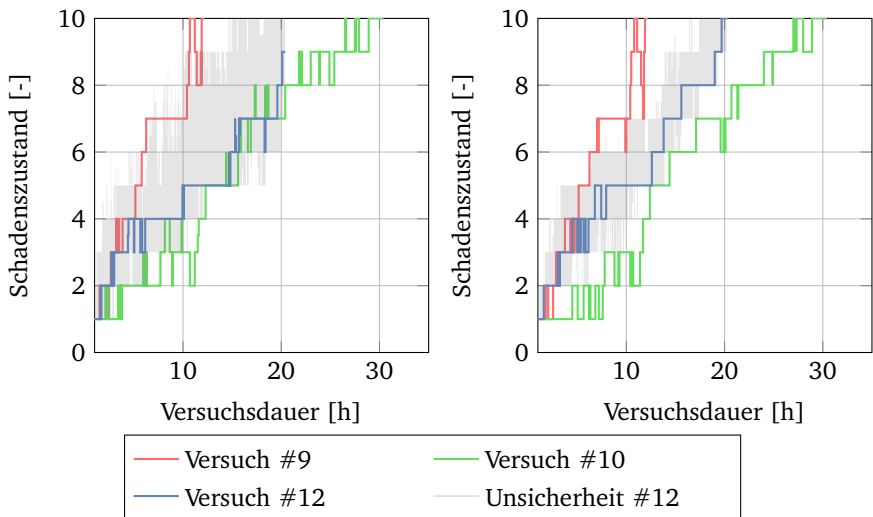


Abbildung 5.9.: Vergleich des Ergebnisses der Klassifikation unter Verwendung von einem Merkmal (links) und drei Merkmalen (rechts)

Wie in Abschnitt 5.2.1 erläutert, basiert der Großteil der generierten Merkmale auf dem Frequenzspektrum des Stromsignals. In der Theorie ist es möglich, anhand von Näherungsformeln die Auswirkung eines Schadens im Innen- oder Außenring des Lagerelementes sowie einer Exzentrizität des Rotors auf das Frequenzspektrum abzuschätzen. Mit dem Ziel die vom Algorithmus identifizierten Merkmale näher zu analysieren, werden diese den berechneten Frequenzen gegenübergestellt. Die Berechnung der Fehlerfrequenzen kann im Anhang G nachvollzogen werden. Im

Rahmen der Verifikation ist zu erwarten, dass die als relevant selektierten Merkmale im Bereich der Fehlerfrequenzen liegen.

In Abbildung 5.10 sind die zwei Frequenzbereiche dargestellt, in denen sich ungefähr 90 % der vom Algorithmus selektierten Merkmale befinden (~70 % links und ~20 % rechts). Die abgebildeten Daten stammen aus der durchgeführten Analyse mit hundert Testszenarien aus zufälligen Kombinationen von fünf Schadensverläufen. Während Schäden am Lagerelement im Bereich der Versorgungsfrequenz um 400 Hz zu erwarten sind (links), liegt eine Exzentrizität des Rotors im Bereich um 5000 Hz. Es ist ersichtlich, dass die selektierten Merkmale nicht mit den berechneten Frequenzen übereinstimmen.




Abbildung 5.10.: Vergleich der vom Algorithmus selektierten Merkmale mit berechneten Fehlerfrequenzen für einen Schaden am Innen- und Außenring (links) sowie einer Exzentrizität des Rotors (rechts)

Ein Grund für die Abweichungen liegt in der Verwendung von Näherungsformeln. Diese basieren auf der Annahme, dass auf der Laufbahn des Innen- bzw. Außenrings ein einzelner, diskreter Fehler auftritt. Eine visuelle Inspektion der Lagerelemente zeigt jedoch einen kontinuierlichen Abrieb über beide Laufbahnen. Ebenfalls berücksichtigen die verwendeten Formeln nur das Auftreten einer einzelnen Fehlerart. In den durchgeführten Experimenten treten alle drei Schadensarten gleichzeitig auf. Die Wechselwirkung zwischen den Fehlern auf das Frequenzspek-

trum wird in den Formeln nicht berücksichtigt. Trotz der Abweichungen bleibt festzuhalten, dass sowohl das Modell der Fehlerfrequenzen als auch der verwendete Algorithmus ähnliche Frequenzbereiche als relevant identifizieren.

5.3.2 Gruppierung und Klassifikation von Schadensverläufen

In diesem Abschnitt wird untersucht, ob die Einordnung der Schadensverläufe in Schadensgruppen durch die Clusteranalyse einen Vorteil hinsichtlich der Bestimmung des Schadenszustands bietet. Für die Verifikation wird der Clusteralgorithmus auf alle Datensätze angewendet und das Dendrogramm analysiert, welches in Abbildung 5.11 dargestellt ist. Die 18 Schadensverläufe sind auf Basis des Kriteriums W iterativ zusammengefasst, bis eine einzelne Gruppe verbleibt. Das Abbruchkriterium im Rahmen der Merkmalsanalyse beträgt $\epsilon = 5\%$. Der Schwellwert wird auf $\zeta = 3,5$ gesetzt, sodass drei Schadensgruppen entstehen.




Abbildung 5.11.: Generierung der Schadensgruppen (SG) anhand der hierarchischen Clusteranalyse unter Verwendung aller 18 Datensätze

Bei einem Vergleich des Dendrogramms mit den vier in Abbildung 5.7 dargestellten Degradierungsprozessen (#1, #6, #14 und #18) wird deutlich, dass diese in zwei unterschiedliche Schadensgruppen eingeordnet werden. Der Clusteralgorithmus ordnet #6 und #18 in die erste Gruppe ein, während sich #1 und #14 in der

zweiten Gruppe befinden. Ein Zusammenschluss der vier Verläufe in eine Gruppe findet erst in der letzten Iteration bei einem hohen Wert des Kriteriums statt. Demnach unterscheiden sich die Degradierungsprozesse zu stark, um mit dem gleichen Set an Merkmalen beschrieben zu werden. Dieses ist in Abbildung 5.12 (links) verdeutlicht. Dargestellt sind die geschätzten Zustandsindikatoren der vier Verläufe über der Versuchsdauer. Findet die Klassifikation des Schadenszustands mit den gewählten Merkmalen der entsprechenden Gruppe statt, wird der gesamte Bereich an Zuständen ausgenutzt. Ein hoher Indikator repräsentiert somit einen kritischen Zustand. Wird hingegen der Verlauf #1 mit dem Klassifikator einer anderen Gruppe eingeordnet, verschlechtert sich das Ergebnis. Der Grund liegt darin, dass jede entstandene Schadensgruppe sich durch ein eigenes Set an Merkmalen auszeichnet, welches speziell für die Klassifikation des Schadenszustands der dazugehörigen Schadensverläufe selektiert wird. Diese Tatsache ist in Abbildung 5.12 (rechts) visualisiert. Dargestellt ist jeweils das erste Merkmal der beiden Schadensgruppen, welches im Rahmen der Merkmalsanalyse selektiert wurde. In der ersten Gruppe deckt das Merkmal den Frequenzbereich um 535 Hz ab, in der Zweiten den Bereich um 325 Hz. Es ist ersichtlich, dass jeweils nur die korrekt gewählten Merkmale einen eindeutigeren Trend aufweisen.

Die Nutzung von mehreren Gruppen hat zum Ziel, dass die Verläufe innerhalb einer Gruppe alle Schadenszustände bis zum Ausfall ausnutzen und somit eine Bewertung des Zustands der Komponente verbessert wird. Um dieses zu veranschaulichen, wird der Ausfallbereich betrachtet. Dieser wird anhand der kurz vor dem Ausfall klassifizierten Schadenszustände abgeleitet. In Abbildung 5.13 ist der Ausfallbereich der drei Schadensgruppen durch eine Normalverteilung angenähert. Zum Vergleich ist die Ausfallzone dargestellt, wenn der Schwellwert erhöht wird, sodass alle Verläufe zu einer Schadensgruppe zusammengefasst werden. Bei drei Gruppen findet der Ausfall einer Komponente bei einem Zustandsindikator von ungefähr acht statt. Die Ausfallzone bei der Verwendung einer einzigen Gruppe ist größer, da ein einzelner Klassifikator K_{SZ} das Ausmaß des Schadens für alle Verläufe unzureichend wiedergibt und somit der Ausfall bei geringen Schadenszuständen auftritt.

Die Gruppierung der Verläufe auf Basis des Degradierungsprozesses lässt vermuten, dass ein Zusammenhang zwischen der vom Algorithmus gewählten Schadensgruppe und einer der beiden auftretenden Versagensarten (siehe Abschnitt 5.2) besteht. Dieses kann im Rahmen der Untersuchung jedoch nicht bestätigt werden. Während die Versuche #1 und #6 durch einen Bruch des Käfigs gestoppt wurden, war bei den Versuchen #18 und #14 die Lagerluft aufgrund des abrasiven Verschleißes der Laufbahnen zu hoch. Eine visuelle Inspektion der Laufflächen und

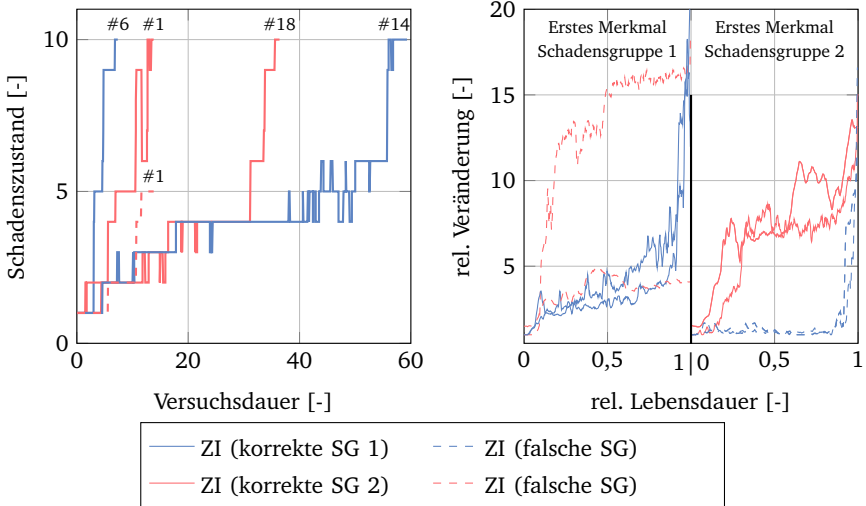


Abbildung 5.12.: Gegenüberstellung der Schätzung des Zustandsindikators (ZI) anhand der korrekt und falsch gewählten Schadensgruppe (SG) (links) sowie Vergleich des ersten Merkmals der ersten und zweiten Schadensgruppe (rechts)

Kugелеlemente nach dem Ausfall ermöglicht ebenfalls keinen Rückschluss auf die gewählte Schadensgruppe.

Der Vorteil, welcher durch die Generierung von Schadensgruppen entsteht, kann nur ausgenutzt werden, wenn neue Daten in der Testphase vom Klassifikator K_{SG} in eine geeignete Gruppe eingeordnet werden. Eine ungünstige Klassifikation kann dazu führen, dass eine Bewertung des Schadenszustands durch unpassende Merkmale durchgeführt wird. Im Folgenden wird untersucht, ob der verwendete Klassifikator eine geeignete Einteilung ermöglicht.

Zu diesem Zweck wird das Ergebnis des Clusteralgorithmus unter Verwendung aller Datensätze herangezogen, siehe Abbildung 5.11. Um die Funktionsweise des Klassifikators K_{SG} zu testen, werden nacheinander einzelne Datensätze aus einer Schadensgruppe entfernt und der Klassifikator anhand des modifizierten Dendrogramms trainiert. Anschließend wird geprüft, in welche Gruppe der entfernte Datensatz eingeordnet wird. Im Idealfall sollte die ursprüngliche Schadensgruppe gewählt werden. Um eine gleiche Gewichtung der Ergebnisse trotz unterschiedlicher Versuchsdauer zu gewährleisten, werden aus jedem entfernten Datensatz hundert,





Abbildung 5.13.: Vergleich der Ausfallzonen unter Verwendung einer einzelnen Schadensgruppe (SG) und drei Gruppen

über die Lebensdauer gleich verteilte, Merkmalsvektoren für die Klassifikation gewählt. Insgesamt findet die Untersuchung somit anhand von 1800 Merkmalsvektoren statt.

In Abbildung 5.14 (links) ist die Wahrheitsmatrix mit den Ergebnissen der Klassifikation dargestellt. Ein Großteil der Daten wird in die korrekte Gruppe eingeordnet. Die mittlere Fehlerrate liegt bei 19 %. Um die Ursache der falsch klassifizierten Fälle zu untersuchen, wird betrachtet, zu welchem Zeitpunkt der falsch eingeordnete Merkmalsvektor generiert wurde. In Abbildung 5.14 (rechts) ist die Verteilung der Fehler über der relativen Lebensdauer der Versuche dargestellt. Über die Hälfte der falschen Klassifikationen finden innerhalb der ersten 20 % der Lebensdauer eines Datensatzes statt. Der Grund liegt darin, dass zu Beginn der Experimente, die Auswirkung der Degradierung auf die Merkmale in der Regel gering ist, sodass diese in den verschiedenen Schadensgruppen eine große Ähnlichkeit aufweisen. Als Konsequenz ist keine eindeutige Zuordnung durchführbar. Nach diesem Zeitraum nimmt die Fehlerrate stark ab.

Für die Wahl des Schwellwerts ζ und somit der Klassenanzahl muss ein Kompromiss eingegangen werden. Einerseits führt eine Verringerung des Schwellwerts zu einer Verbesserung des Zustandsindikators innerhalb einer Gruppe. Anderer-

		geschätzte Klasse		
		SG 1	SG 2	SG 3
wahre Klasse	SG 1	81	4	15
	SG 2	12	71	17
	SG 3	7	2	91

(Werte in Prozent)




Abbildung 5.14.: Ergebnisse der Klassifikation von Schadensgruppen (SG) (links) sowie Zeitpunkt der Fehlklassifikation (rechts)

seits steigt mit jeder Gruppe das Risiko einer Fehlklassifikation und folglich einer falschen Einschätzung des Zustandsindikators. Dieser Sachverhalt ist in Abbildung 5.15 dargestellt. Über eine steigende Anzahl an Schadensgruppen (sinkender Schwellwert) ist die Fehlerrate dargestellt, welche nach dem oben beschriebenen Prinzip für die jeweilige Klassenanzahl berechnet ist. Dem gegenübergestellt ist die Standardabweichung, welche die Größe des Ausfallbereichs beschreibt. Es ist ersichtlich, dass mit einem sinkenden Schwellwert die Anzahl an fehlerhaften Klassifikationen zunimmt, während die Größe der Ausfallzone abnimmt. Mit dem Ziel einen idealen Wert für den Schwellwert ζ zu definieren, wird dieser in Kapitel 7 hinsichtlich seiner Auswirkung auf die Prognosefähigkeit untersucht.

5.3.3 Prognose der Restlebensdauer

In diesem Abschnitt wird die Prognosefähigkeit mittels der Degradierungsmodelle verifiziert. Zunächst wird untersucht, wie exakt ein einzelnes Modell den zum Training genutzten Schadensverlauf abbildet. Zu diesem Zweck werden neun Prognosen von $\lambda = 0,1$ bis $\lambda = 0,9$ gleichmäßig verteilt über die Lebensdauer des trainierten Schadensverlaufs durchgeführt und der Prognosehorizont, siehe Abschnitt 3.5.1, betrachtet. Im nächsten Schritt wird analysiert, wie sich das Ergebnis ändert, wenn die Prognose auf mehreren Modellen basiert und somit die RUL durch eine




Abbildung 5.15.: Gegenüberstellung der Fehlerrate bei der Klassifikation von Schadensgruppen mit der Standardabweichung des Ausfallbereiches über eine steigenden Anzahl von gewählten Schadensgruppen

Fusion der einzelnen Ergebnisse gebildet wird. Dabei befindet sich der zu testende Datensatz innerhalb der Trainingsdaten.

In Abbildung 5.16 ist das Ergebnis einer Prognose dargestellt, wenn ein Schadensverlauf (Versuch #12) sowohl als Trainings- als auch als Testdatensatz dient. Der Median der prognostizierten Verteilungsform liegt dicht an der realen RUL und jederzeit innerhalb des Fehlerbandes ($\alpha = 0,1$). Der Prognosehorizont erreicht den Maximalwert von $PH = 0,9$ und es wird angenommen, dass das Degradierungsverhalten genau wiedergegeben wird. Dennoch ist die Prognose mit einer sichtbaren Unsicherheit behaftet, welche sich teilweise außerhalb des Fehlerbands befindet. Die Ursache liegt bei der Schätzung der Schadenszustände. Wie in Abbildung 5.9 (rechts) erkennbar ist, entsteht bei der Klassifikation des Zustandsindikators eine Unsicherheit, welche einen direkten Einfluss auf die Prognose hat.

Zusätzlich ist in Abbildung 5.16 veranschaulicht, wie der Algorithmus die RUL schätzt, wenn die Prognose auf mehreren Modellen (Versuche #9, #10 und #12) basiert. Nach den ersten beiden Prognosen pendeln sich die prognostizierten Werte innerhalb des Fehlerbands ein. Zu Beginn liegen nicht genügend Informationen über den Trend vor, damit sich der Algorithmus zuverlässig für das richtige Modell





Abbildung 5.16.: Vergleich des Prognosehorizonts unter Verwendung eines Modells und drei Modellen

entscheidet. Erst nach zwei Prognosen wird der Verlauf #12 als wahrscheinlichstes Modell eingestuft. Die Kombination mehrerer Modelle führt zu einer gestiegenen Unsicherheit der Prognose. In Abbildung 5.17 (links) ist die Prognose nach ungefähr 8 Stunden ($\lambda = 0,4$) dargestellt. Ab diesem Zeitpunkt prognostiziert der Algorithmus auf Basis der drei Modelle den weiteren Verlauf des Zustandsindikators. Da der Testverlauf ebenfalls in den Trainingsdatensätzen vorhanden ist, liegt der tatsächliche und geschätzte Ausfallzeitpunkt dicht beieinander. Infolge der Informationen über die anderen Schadensverläufe zieht der Algorithmus auch schnellere (Versuch #9) und langsamere (Versuch #10) Degradierungsprozesse in Betracht. Dieses wird bei der Betrachtung der Verteilungsfunktion der prognostizierten RUL in Abbildung 5.17 (rechts) deutlich. Auf Basis der drei prognostizierten Verteilungsfunktionen wird die fusionierte Verteilungsform berechnet. Diese wiederum dient zur Bestimmung von r_{50} .

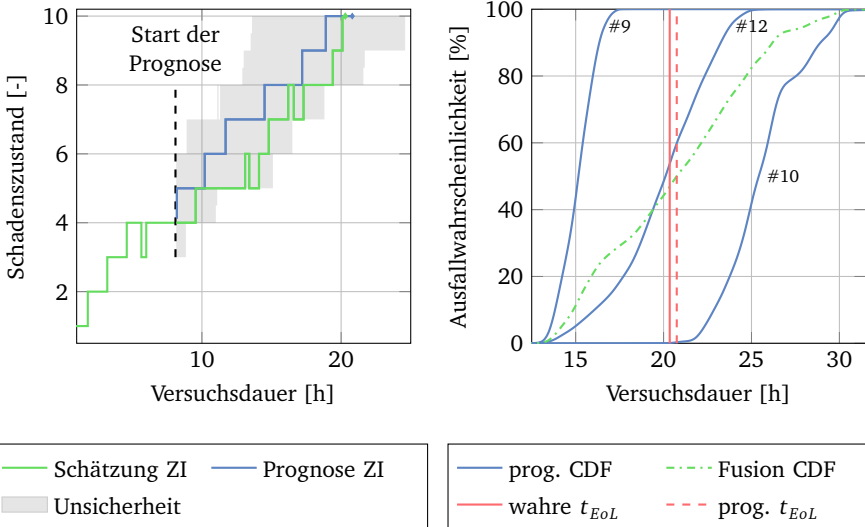


Abbildung 5.17.: Darstellung einer Prognose des Zustandsindicators (ZI) zum Zeitpunkt 8h (links), Fusion der prognostizierten CDF einer RUL (rechts)

5.4 Zusammenfassung

Insgesamt wurden mit dem Asynchronmotor 18 Versuche mit modifizierten Lagerelementen durchgeführt. Anhand der Messdaten konnten Merkmale aus dem Frequenzspektrum des Stromsignals generiert und somit eine umfangreiche Datenbasis erzeugt werden. Diese dient als Grundlage für die Erstellung von unterschiedlichen Testszenarien für die Verifikation der entwickelten Algorithmen. Die Verifikation wurde in drei Schritte unterteilt, welche jeweils verschiedene Aspekte des PHM Systems beleuchten.

Die erste Untersuchung zeigt, dass der Algorithmus die Selektion von relevanten Merkmalen für die Klassifikation des Zustandsindicators ermöglicht. Je mehr Datensätze dabei zur Verfügung stehen, desto höher ist die Validität der selektierten Merkmale. Demgegenüber steht, dass sich die Klassifikation des Schadensindicators verschlechtert. Wird die Anzahl an selektierten Merkmalen erhöht kann das Ergebnis verbessert und die Unsicherheit bei der Klassifikation reduziert werden. Eine Gegenüberstellung mit berechneten Fehlerfrequenzen von Lagerschäden zeigt

keine exakte Übereinstimmung mit den selektierten Merkmalen. Jedoch liegt eine vergleichbare Größenordnung vor und es ist zu hinterfragen, inwieweit die Näherungsformeln Gültigkeit für abrasiven Verschleiß der Lagerelemente besitzen.

In der zweiten Untersuchung konnte aufgezeigt werden, dass die Gruppierung von Schadensverläufen zu einer Verbesserung der Zustandsbewertung führt. Durch die individuelle Wahl von geeigneten Merkmalen zur Beschreibung unterschiedlicher Degradierungsprozesse wird der Ausfallbereich verkleinert, sodass das technische System bis zum Ausfall mehr definierte Schadenszustände durchläuft. Eine steigende Anzahl an Schadensgruppen führt jedoch zu einer höheren Fehlerrate bei der Einordnung von Testdaten. Bei der Wahl der optimalen Anzahl von Schadensgruppen muss demnach ein Kompromiss zwischen Verbesserung der Zustandsbewertung und Risiko von Fehlklassifikationen eingegangen werden.

Die letzte Untersuchung bezüglich des Algorithmus zur Restlebensdauerprognose zeigt, dass die trainierten Modelle den zugrunde liegenden Degradierungsprozess abbilden und zur Prognose verwendet werden können. Je mehr Informationen dem Algorithmus in Form von Schadensverläufen zur Verfügung stehen, desto größer wird die Unsicherheit, da mehr Möglichkeiten bei der Prognose in Betracht gezogen werden.



6 Methode zur Bewertung von PHM Systemen

In diesem Kapitel wird die Methode vorgestellt, welche die Untersuchung der Leistungsfähigkeit in Kapitel 7 ermöglicht. Zunächst wird in Abschnitt 6.1 das Bewertungskonzept präsentiert, welches den Vergleich von verschiedenen PHM Systemen erlaubt. In Abschnitt 6.2 wird ein zeitbasierter Wartungsalgorithmus vorgestellt, der für die wirtschaftliche Betrachtung herangezogen wird. Um bei der Untersuchung die Handlungsempfehlung zu bewerten, wird abschließend ein neuer Kennwert eingeführt.

6.1 Bewertungskonzept

Das Vorgehen bei der Bewertung des PHM Systems basiert auf einem Konzept, welches in der Forschungsarbeit [PAK14] vorgestellt wird. Dieses besitzt den Vorteil, dass auch mit einer geringen Anzahl an verfügbaren Schadensverläufen eine Aussage über die Performanz des Algorithmus getroffen werden kann. In Abbildung 6.1 ist das Vorgehen skizziert.

Zu Beginn wird ein ausgewählter Algorithmus mit zwei zufällig gewählten Schadensverläufen ($J = 2$) aus der Datenbank trainiert. Die restlichen verfügbaren Verläufe werden für das Testen genutzt. Da insgesamt 18 Datensätze zur Verfügung stehen, wird die Prognosefähigkeit anhand $18 - J$ Testdaten bewertet. Zu diesem Zweck werden jeweils neun über der Lebensdauer gleich verteilte Prognosen von $\lambda = 0,1$ bis $\lambda = 0,9$ an einem Testverlauf berechnet. Die prognostizierten Wahrscheinlichkeitsdichten der RUL dienen als Basis zur Berechnung von sechs Kennwerten. Die Kennwerte MAPE, PH ($\alpha = 0,15$), MAD, FP und FN beschreiben die Genauigkeit und Präzision der prognostizierten RUL, siehe Abschnitt 3.5.1. Der sechste Kennwert C bewertet die generierte Handlungsempfehlung und wird in Abschnitt 6.3 eingeführt. Im nächsten Schritt wird eine neue zufällige Kombination aus Trainings- sowie Testdatensätzen gewählt und die Berechnung der Kennwerte wiederholt. Nachdem eine definierte Anzahl an Tests erreicht ist, wird die Anzahl an verfügbaren Trainingsdatensätzen erhöht. Das bedeutet, dass dem Algorithmus mehr Informationen über den Degradierungsprozess für die Schätzung der RUL bereitgestellt werden. Dieses Vorgehen wird wiederholt, bis die Anzahl der Trainings-

datensätze gleich der Anzahl an maximal verfügbaren Schadensverläufen ist oder eine definierte Anzahl erreicht wird. Bei einem Vergleich von mehreren Algorithmen werden die zufälligen Kombinationen an Trainings- und Testdaten identisch gewählt.

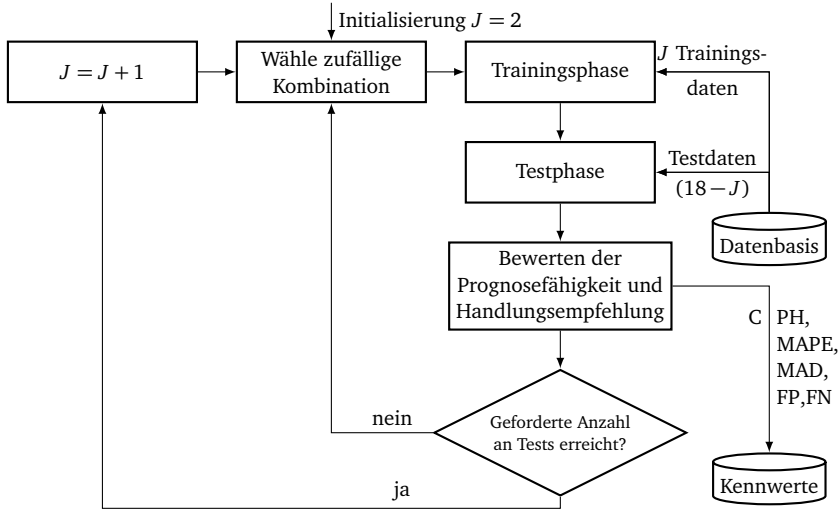


Abbildung 6.1.: Bewertungskonzept für die Untersuchung der Leistungsfähigkeit von PHM Systemen

Als Ergebnis liegen Kennwerte für jede Anzahl an J verfügbaren Trainingsdaten vor. In Abbildung 6.2 ist veranschaulicht, wie sich der Prognosehorizont von zwei Algorithmen mit steigendem Wissen über den Degradierungsprozess entwickelt. Die erreichte Leistung mit J Trainingsdaten wird über den Median der berechneten Prognosehorizonte $PH_M(J)$ repräsentiert. Es ist erkennbar, dass sich beide Algorithmen mit mehr Trainingsdaten verbessern. Mit dem Ziel, die Leistung zu quantifizieren und damit eine Vergleichbarkeit der beiden Algorithmen herzustellen, wird der Verlauf $PH_M(J)$ mittels einer Gewichtung zu einem Wert PH_M zusammengefasst. Wie in der Abbildung ersichtlich, werden die Kennwerte, welche mit mehr Trainingsdaten erzielt werden, höher gewertet. Dieses wird durch die Annahme begründet, dass bei der Entwicklung eines datenbasierten Ansatzes eine Datengrundlage vorhanden ist und diese bestmöglich von dem PHM System verwertet werden muss.

Um eine Vergleichbarkeit zwischen mehreren Algorithmen zu ermöglichen, wird eine Punktzahl S für einen Algorithmus berechnet, welche die Performanz auf Basis




Abbildung 6.2.: Entwicklung des Prognosehorizonts über eine steigende Anzahl von verfügbaren Trainingsdatensätzen sowie Berechnung des gewichteten Kennwerts PH_M anhand der normierten Gewichtungsfunktion

aller verwendeten Kennwerte zusammenfasst. Die erreichte Punktzahl eines Algorithmus wird über die Gleichung

$$S = w_{PH} \cdot \frac{PH_M}{PH_{M,opt}} + w_{FN} \cdot \frac{FN_{M,opt}}{FN_M} + w_{FP} \cdot \frac{FP_{M,opt}}{FP_M} + w_{MAPE} \cdot \frac{MAPE_M}{MAPE_{M,opt}} + w_{MAD} \cdot \frac{MAD_M}{MAD_{M,opt}} \quad (6.1)$$

bestimmt. Die Kennwerte mit dem Index opt dienen als Referenzwerte und ergeben sich durch den besten Wert, der von einem der untersuchten Algorithmen erreicht wird. Die Leistung wird demnach als Relation zu der höchsten erreichten Performance ausgedrückt. Abhängig davon, ob ein niedriger oder hoher Wert eine gute Leistung kennzeichnet, steht die Referenz im Nenner oder Zähler. Jeder Bruch besitzt somit den Maximalwert eins. Über die Faktoren w ist es möglich, die Kennwerte unterschiedlich zu gewichten. Dieses ist beispielsweise bei sicherheitskritischen

Bauteilen interessant, wenn ein hoher FN Wert zu vermeiden ist. Im Rahmen dieser Arbeit werden die Kennwerte gleich gewichtet, sodass

$$w_{PH} = w_{FN} = w_{FP} = w_{MAPE} = w_{MAD} = \frac{1}{5} \quad (6.2)$$

gilt. Damit ergibt sich eine maximal erreichbare Punktzahl von $S = 1$.

6.2 Zeitbasierter Vergleichsalgorithmus

Für die wirtschaftliche Betrachtung in Kapitel 7 wird an dieser Stelle ein Vergleichsalgorithmus vorgestellt. Es handelt sich um einen zeitbasierten Ansatz, welcher ein statistisches Modell verwendet. Für die Abschätzung des idealen Wartungszeitpunkts einer Komponente wird auf eine Verteilungsform zurückgegriffen, welche auf historischen Ausfalldaten der Komponente beruht. Da außer den Ausfallzeitpunkten kein Systemwissen vorhanden sein muss, kann ein zeitbasierter Ansatz in der Praxis einfach umgesetzt werden und ist weitverbreitet [EER16]. Insbesondere für die Planung der Wartungszeitpunkte von nicht sicherheitskritischen Komponenten bietet sich dieser Ansatz an [Joh11].

Nach [Nac17, S. 44-48] sind die Exponential- und Weibullverteilung etablierte Methoden, um die Wahrscheinlichkeitsdichtefunktion $f(t)$ für einen Ausfall zu einem Zeitpunkt t zu erfassen. Der hier angewendete Ansatz basiert auf der Weibullverteilung. Die Dichtefunktion $f(t)$ und Verteilungsfunktion $F(t)$ sind durch

$$f(t) = \frac{b}{a} \cdot \left(\frac{t}{a}\right)^{(b-1)} \cdot e^{-\left(\frac{t}{a}\right)^b} \quad (6.3)$$

und

$$F(t) = 1 - e^{-\left(\frac{t}{a}\right)^b} \quad (6.4)$$

gegeben. Der Skalenparameter a bestimmt die Breite der Verteilung. Der Formparameter b erlaubt die Realisierung verschiedener Verteilungsformen. In Abbildung 6.3 (links) sind die Ausfälle der durchgeführten Versuche dargestellt. Innerhalb eines Zeitraums von ungefähr 115 h fallen alle Komponenten aus. Neben den einzelnen Ausfällen ist die geschätzte Verteilungsfunktion dargestellt, welche mit den Parametern $a = 44,73$ h und $b = 1,45$ modelliert ist. Ein Vergleich zu Modellierungen mit anderen Verteilungsformen befindet sich im Anhang H.

Neben der Abschätzung des Ausfallzeitpunkts wird die Weibullverteilung genutzt, um eine Handlungsempfehlung in Form des optimalen Austauschzeitpunkts $t_{A,wbl}$ zu generieren. Eine Möglichkeit diesen zu definieren wird in [BDKM16, S.




Abbildung 6.3.: Modellierung der Ausfälle mittels einer Weibullverteilung mit den Parametern $a = 44,73\text{h}$ und $b = 1,45$ (links) sowie Minimierung der Systemkosten pro Zeiteinheit durch die Wahl des idealen Austauschzeitpunkts $t_{A,wbl}$ (rechts)

317-318] vorgeschlagen. Ziel ist es, durch die Wahl des Zeitpunkts t_A die Systemkosten pro Zeiteinheit C zu minimieren. Diese werden durch die Gleichung

$$C(t_A) = \frac{c_{prä} \int_{t_A}^{\infty} f(t) dt + c_{korr} \int_0^{t_A} f(t) dt}{t_A \int_{t_A}^{\infty} f(t) dt + \int_0^{t_A} t f(t) dt} \quad (6.5)$$

in Abhängigkeit der Kosten für präventive und korrektive Maßnahmen bestimmt. Eine präventive Maßnahme findet statt, wenn t_A vor einem Ausfallzeitpunkt liegt, ansonsten ist eine korrektive Maßnahme notwendig. Der Aufwand für eine präventive Maßnahmen wird anhand der Kosten $c_{prä}$ definiert. Die Kosten c_{korr} beschreiben den Aufwand einer korrektiven Maßnahmen. Bei der Definition von $c_{prä}$ und c_{korr} werden die Kosten für einen geplanten bzw. ungeplanten Austausch eines Bauteils berücksichtigt. Zusätzlich können Kosten für Stillstandszeiten oder weitere Folgeschäden eingeplant werden. Bei der Berechnung des Austauschzeitpunkts mithilfe von Gleichung 6.5 gilt die Einschränkung, dass es sich um ein nicht reparier-

bares technisches System handelt und somit nach einem Austausch eine neuwertige Komponente vorliegt.

Der optimale Wert für t_A wird anhand der verfügbaren Ausfalldaten einer Komponente numerisch ermittelt. In Abbildung 6.3 (rechts) ist die Lösung für $c_{prä} = 250\text{€}$ und $c_{korr} = 1000\text{€}$ anhand der ermittelten Weibullparameter gezeigt. Für eine Minimierung der Kosten muss der Komponentenaustausch nach ungefähr $t_{A,wbl} = 40\text{ h}$ stattfinden. Die Systemkosten pro Zeiteinheit betragen in diesem Fall ca. $23 \frac{\text{€}}{\text{h}}$. Findet ein früherer Austausch statt, steigen die Kosten aufgrund präventiver Maßnahmen. Demgegenüber erhöhen ungeplante Ausfälle die Kosten, wenn ein späterer Zeitpunkt gewählt wird.

6.3 Bewertung des Austauschzeitpunkts

Mit dem Ziel, die geschätzten Austauschzeitpunkte des entwickelten und zeitbasierten Ansatzes zu bewerten, werden die in der Testphase verursachten Systemkosten pro Zeiteinheit C bestimmt. Bei der Berechnung der Kennwerte im Rahmen des Bewertungskonzepts liegt der geschätzte Wartungszeitpunkt t_A sowie die wahre Ausfallzeit t_{EoL} eines Testverlaufs vor. Um die Systemkosten pro Zeiteinheit zu berechnen, wird die Gleichung 6.5 wie folgt angepasst:

$$C(t_A) = \begin{cases} \frac{c_{prä}}{t_A}, & \text{falls } t_A < t_{EoL} \\ \frac{c_{korr}}{t_{EoL}}, & \text{sonst} \end{cases} . \quad (6.6)$$

Es ist ersichtlich, dass sich die Kosten entweder aus einem präventiven oder korrekiven Anteil zusammensetzen. In Abbildung 6.4 sind die entstehenden Kosten in Abhängigkeit des geschätzten Austauschzeitpunkts veranschaulicht. Dabei sind die Kosten $c_{prä} = 1000\text{€}$ und $c_{korr} = 7000\text{€}$ angenommen. Wird ein Austausch durch den Algorithmus vor dem Ausfall einer Komponente initiiert, wird C auf Basis der Kosten $c_{prä}$ bestimmt. Je länger das System betrieben wird, desto geringer fallen die Kosten im Bezug auf die Lebensdauer aus. Befindet sich der geschätzte Wartungszeitpunkt nach dem Ausfall, verringern sich die Kosten je länger die Komponente insgesamt genutzt wurde.




Abbildung 6.4.: Berechnung der Systemkosten pro Zeiteinheit C für einen Testverlauf in Abhängigkeit des geschätzten Wartungszeitpunkts t_A ($c_{prä} = 1000\text{€}$, $c_{korr} = 7000\text{€}$)



7 Untersuchung der Leistungsfähigkeit

In diesem Kapitel liegt das Ziel darin, die Leistungsfähigkeit der entwickelten Algorithmen zu beleuchten und die drei in Abschnitt 1 gestellten Forschungsfragen zu diskutieren. Zu diesem Zweck werden drei Untersuchungen auf Basis des in Kapitel 6 vorgestellten Bewertungskonzepts und der 18 generierten Datensätze durchgeführt. Die Erste befasst sich in Abschnitt 7.1 mit dem Einfluss der entwickelten Methode zur Zustandsbewertung auf die Prognosefähigkeit. In Abschnitt 7.2 wird die Übertragbarkeit des Ansatzes auf andere Anwendungsszenarien betrachtet. Abschließend wird durch einen Vergleich mit einem zeitbasierten Wartungsansatz eine wirtschaftliche Betrachtung durchgeführt.

7.1 Prognosefähigkeit

Die Zielsetzung der ersten Untersuchung liegt darin, die Auswirkung der entwickelten Algorithmen zur Zustandsbewertung auf die Prognosefähigkeit des PHM Systems zu analysieren. Diese wird durch die Veränderung von drei ausgewählten Parametern durchgeführt. Zunächst wird jeweils ein einzelner Parameter variiert. Anschließend wird die gegenseitige Beeinflussung untereinander untersucht. Dadurch ist es möglich, zum einen die Auswirkung auf die Prognosefähigkeit zu untersuchen und zum anderen eine optimale Parameterkonstellation zu finden. Die Ergebnisse werden mit dem in Abschnitt 4.5 vorgestellten Vergleichsalgorithmus, welcher eine Datenreduktion auf Grundlage der PCA durchführt, gegenübergestellt.

Betrachtet wird eine Veränderung der Anzahl an generierten Schadensgruppen, der Anzahl an verwendeten Merkmalen sowie die Zahl an gewählten Schadenszuständen. In Tabelle 7.1 ist festgehalten, welche Werte für die jeweiligen Parameter getestet werden. Die Anzahl an generierten Schadensgruppen wird über den Schwellwert ζ bestimmt. Das Abbruchkriterium ϵ beeinflusst die Anzahl der Iterationsschritte innerhalb der Merkmalsselektion und somit die Anzahl an verwendeten Merkmalen für die Klassifikation. Der dritte Parameter Z legt die Anzahl an definierten Schadenszuständen fest.

Der Referenzwert eines Parameters wird verwendet, wenn jeweils ein anderer variiert wird. Bei der Verwendung des Referenzwerts für ζ werden alle verfü-

Tabelle 7.1.: Gewählter Testbereich der drei Parameter für die Untersuchung des Einflusses auf die Prognosefähigkeit

Parameter	Referenz	Parameterbereich
Schwellwert [-]	$\zeta = 5$	0; 1,25; 2,50; 3,75; 5
Abb. Kriterium [%]	$\epsilon = 100$	1; 25; 50; 75; 100
Schadenzustände [-]	$Z = 10$	3; 5; 10; 15; 20

baren Degradierungsprozesse im Training einer Schadensgruppe zugeordnet. Der Clusteralgorithmus hat somit keinen Einfluss auf das Ergebnis. Der Referenzwert ϵ führt innerhalb der Merkmalsselektion dazu, dass ausschließlich eine Iteration durchlaufen und somit nur das erstbeste Merkmal gewählt wird. Beim Referenzalgorithmus, also bei der Verwendung aller drei Referenzwerte, wird die RUL somit nur anhand eines Merkmals geschätzt.

Zunächst wird jeder Parameter einzeln betrachtet und ein optimaler Wert hinsichtlich des erreichten Prognosehorizonts gesucht. In Abbildung 7.1 ist schematisch das Vorgehen dargestellt. Für jede Parameterkonstellation werden zehn Iterationen des Bewertungskonzepts durchlaufen. Das bedeutet, dass die Trainingsdatenanzahl J sukzessive von zwei auf elf gesteigert wird. Innerhalb jeder Iteration werden jeweils 150 Tests durchgeführt, wodurch 150 Sets an Kennwerten (PH, MAPE, MAD, FN und FP) für die Untersuchung generiert werden.

Mit dem Ziel, die gegenseitige Beeinflussung zu untersuchen, werden jeweils zwei Werte eines Parameters gewählt und über einen statistischen Versuchsplan kombiniert. Hierfür werden der beste Wert hinsichtlich des erzielten Prognosehorizonts und der Referenzwert für jeden Parameter gewählt. Insgesamt entstehen somit acht Algorithmen mit unterschiedlichen Parameterkonstellationen. Diese werden anhand der erzielten Punktzahl S und der fünf Kennwerte analysiert und dem Vergleichsalgorithmus gegenübergestellt.




Abbildung 7.1.: Vorgehen bei der Untersuchung des Einflusses der Parameter auf den Prognosehorizont

7.1.1 Ergebnisse

Der Zusammenhang zwischen der Anzahl an Schadensgruppen und dem Schwellwert ist in Abbildung 7.2 (links) dargestellt. Zusätzlich ist die Anzahl an Degradierungsprozessen abgebildet, welche eine Schadensgruppe im Durchschnitt beinhaltet. Niedrige Schwellwerte führen zu einer höheren Tendenz, Schadensverläufe zu neuen Schadensgruppen zusammenzufassen. Je mehr Datensätze innerhalb der Trainingsphase zur Verfügung stehen, desto deutlicher ist der Effekt sichtbar. Wird der Schwellwert auf den maximalen Wert $\zeta = 5$ festgelegt, werden alle Modelle zu einer einzigen Schadensgruppe zusammengefasst. Wird hingegen der Schwellwert sehr niedrig gewählt, beinhaltet eine Schadensgruppe nur einen Trainingsdatensatz.

In Abbildung 7.2 (rechts) ist die Anzahl an Merkmalen über dem gewählten Abbruchkriterium aufgetragen. Da die Verbesserung des Kriteriums im Rahmen der Merkmalsselektion von den zugrunde liegenden Trainingsdaten abhängig ist, variiert die Anzahl der gewählten Merkmale, was durch das 5 %- und 95 %-Perzentil illustriert wird. Je niedriger das Kriterium gewählt wird, desto höher ist die Tendenz, weitere Merkmale hinzuzufügen. Liegt das Abbruchkriterium bei nur 1 %, werden bis zu sechs Merkmale für die Klassifikation selektiert.

In Abbildung 7.3 (links) ist der Einfluss der drei Parameter auf den berechneten Prognosehorizont PH_M dargestellt. Für eine bessere Vergleichbarkeit sind die Anzahl an Schadenszuständen und der Schwellwert ζ prozentual ausgedrückt. Der maximale Wert des jeweiligen Parameters entspricht 100 %. Der Referenzalgorithmus erreicht einen Prognosehorizont von $PH_M = 0,33$. Durch eine Verringerung des Schwellwerts auf $\zeta = 3,75$ (75 %) verbessert sich der Prognosehorizont. Je weiter der Schwellwert ζ darüber hinaus verringert wird, desto schlechter wird die erzielte Leistung. Ein ähnliches Verhalten ist bei der Veränderung des Abbruchkriteriums ϵ erkennbar. Jedoch fällt die Auswirkung geringer aus. Wird mehr als ein Merkmal verwendet, kommt es zunächst zu einer Verbesserung der Prognosefähigkeit. Der Effekt ist am stärksten, wenn durch die Wahl des Abbruchkriteriums ungefähr zwei bis drei Merkmale genutzt werden (vgl. Abb. 7.2). Eine weitere Verringerung besitzt einen negativen Einfluss. Die Anzahl an gewählten Schadenszuständen besitzt im Vergleich zu den anderen Parametern das geringste Verbesserungspotenzial. Eine geringe Verbesserung kann durch die Erhöhung der Anzahl auf $Z = 15$ Zustände (75 %) erreicht werden. Bei einer zu geringen Anzahl von drei Zuständen (15 %) verschlechtert sich das Ergebnis.

In Abbildung 7.3 (rechts) ist der Einfluss des Schwellwerts ζ auf die Entwicklung des Prognosehorizonts über der Anzahl an verfügbaren Trainingsdaten gezeigt. Es ist auffällig, dass durch die Gruppierung der Trainingsdaten in einige wenige Scha-

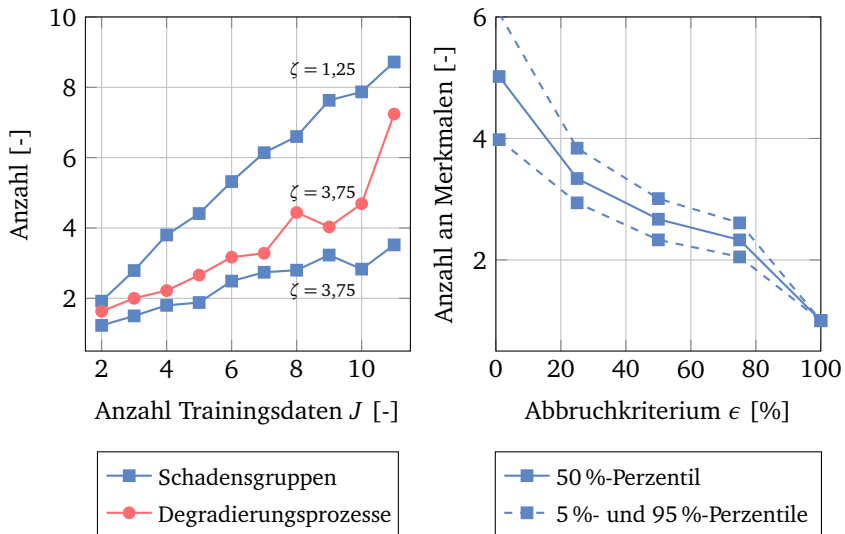


Abbildung 7.2.: Anzahl der generierten Schadensgruppen und der durchschnittlichen Degradierungsprozesse, die einer Gruppe zugeordnet sind (links) sowie die Anzahl an selektierten Merkmalen für die Klassifikation über einem steigenden Abbruchkriterium (rechts)

densgruppen der Prognosehorizont mit einer steigenden Anzahl an Trainingsdaten verbessert wird ($\zeta = 3,75$). Im Gegensatz dazu ist bei der Verwendung des Referenzalgorithmus keine Tendenz ersichtlich. Der Algorithmus profitiert nicht von mehr verfügbaren Trainingsdaten. Besteht jede Schadensgruppe aus maximal einem Degradierungsprozess, kommt es zu einer Reduzierung der Genauigkeit mit einer steigenden Anzahl an Trainingsdaten.

Um die gegenseitige Beeinflussung der Parameter zu untersuchen, wurde der in Abbildung 7.4 (rechts) dargestellte statistische Versuchsplan verwendet. Durch die Kombination des jeweils besten Werts und dem Referenzwert für jeden Parameter entstehen acht Parameterkonstellationen von δ_1 bis δ_8 . Der erzielte Prognosehorizont der jeweiligen Konstellationen ist in Abbildung 7.4 (links) dargestellt. Es wird deutlich, dass sich die drei Parameter positiv beeinflussen. Wie aus der vorangegangenen Untersuchung zu erwarten, wird der größte Sprung durch die Veränderung des Schwellwerts ζ erzielt ($\delta_2, \delta_4, \delta_6$ und δ_8). Der höchste Prognosehorizont wird bei Verwendung aller drei optimalen Werten (δ_8) erreicht. Insgesamt







Abbildung 7.3.: Auswirkung der drei Parameter auf den Prognosehorizont (links) sowie die Entwicklung des Prognosehorizonts über eine steigende Anzahl an Trainingsdaten für unterschiedliche Schwellwerte (rechts)

erhöht sich der Prognosehorizont somit um 0,053, was einer Verbesserung von ungefähr 16 % entspricht. Bei einer durchschnittlichen Laufzeit der Experimente von ca. 40 h befindet sich die prognostizierte RUL 6,4 h früher innerhalb des definierten Fehlerbandes.

Für eine vollständige Betrachtung der Leistungsfähigkeit werden alle fünf Kennwerte untersucht. In Tabelle 7.2 ist ein Ausschnitt der erreichten Werte für die Konstellationen δ_1 , δ_5 und δ_8 sowie des Vergleichsalgorithmus gezeigt. Die vollständige Tabelle befindet sich in Anhang I. Neben den Kennwerten ist die erreichte Punktzahl S berechnet (siehe Gl. 6.1), welche eine Einschätzung der gesamten Prognosefähigkeit gibt.

Die Kennwerte PH, MAPE und FN profitieren am meisten durch die entwickelte Zustandsbewertung. Beim Kennwert FP ist ebenfalls eine geringe Reduzierung erkennbar. Demnach liegen im Durchschnitt ca. 30 % der prognostizierten PDF im FP Bereich. Den geringsten MAD Wert erzielt der Referenzalgorithmus (δ_1), was be-





Abbildung 7.4.: Erreichter Prognosehorizont der einzelnen Parameterkonstellationen (links) sowie Aufspannen eines Versuchsplans mit drei Parametern und jeweils zwei Werten (rechts)

deutet, dass dieser die geringste Streuung der prognostizierten RUL aufweist. Der Vergleichsalgorithmus erreicht eine bessere Leistungsfähigkeit als der Referenzalgorithmus, jedoch schlechter als die des Algorithmus mit optimierten Parametern. Auffällig ist, dass die Performanz in einem ähnlichen Bereich liegt, wie die des Algorithmus mit den Parametern δ_5 .

7.1.2 Diskussion

Die folgende Diskussion ist zweiteilig aufgebaut. Zunächst wird auf das Vorgehen bei der Untersuchung und das verwendete Bewertungskonzept eingegangen. Anschließend werden die vorgestellten Ergebnisse zur Prognosefähigkeit diskutiert.

Das in Kapitel 6 vorgestellte Bewertungskonzept ermöglicht eine umfassende Einschätzung der Prognosefähigkeit. Durch die Verwendung von zehn Iterationschleifen von $J = 2$ bis $J = 11$ mit jeweils 150 getesteten Schadensverläufen, basieren die betrachteten Kennwerte in Tabelle 7.2 auf insgesamt 1500 einzelnen Kennwerten. Bei der Verwendung des Medians zur Beschreibung der Ergebnisse darf nicht vernachlässigt werden, dass die Hälfte der Prognosen schlechtere Ergebnisse erzielen. In Abbildung 7.5 ist die Verteilung der 150 erreichten Kennwerte des Prognosehorizonts gezeigt, welche mit der optimalen Parameterkonstellation δ_8 und elf Trainingsdatensätzen berechnet sind. Es ist ersichtlich, dass die Kenn-

Tabelle 7.2.: Vergleich der erreichten Leistungskennwerte zwischen den Parameterkonstellationen δ_1 , δ_5 und δ_8 sowie dem Vergleichsalgorithmus

Algorithmus	PH_M [-]	$MAPE_M$ [%]	FN_M [%]	FP_M [%]	MAD_M [h]	S [-]
Parameter δ_1	0,334	58,89	39,04	32,40	4,90	0,86
Parameter δ_5	0,343	54,98	38,02	32,18	5,18	0,87
Parameter δ_8	0,387	45,86	30,42	29,92	6,10	0,96
Vergleichsalg. PCA	0,341	55,85	36,06	30,99	5,29	0,88

werte breit verteilt sind und der gesamte Bereich erreichbarer Prognosehorizonte abgedeckt wird. Es erreichen 90 % der durchgeführten Tests einen Prognosehorizont zwischen $\lambda = 0,1$ und $\lambda = 0,8$. Bei einem Einsatz des PHM Systems muss jedoch berücksichtigt werden, dass ein Teil der Prognosen ($\sim 8\%$) nicht innerhalb des erlaubten Fehlerbandes liegen und somit zu ungeplanten Ausfällen führen.




Abbildung 7.5.: Verteilung der erzielten PH Kennwerte mit der Parameterkonstellation δ_8 unter der Verwendung von elf verfügbaren Trainingsdaten

Durch die Berechnung der Punktzahl kann die Leistungsfähigkeit zusammengefasst und über die Definition der Gewichtungsfaktoren hinsichtlich der Bedürfnisse einer Zielanwendung angepasst werden. Dennoch ist die Aussagekraft kritisch zu

betrachten. Die Punktzahl liefert zwar eine grobe Einschätzung, erlaubt aber nur einen relativen Vergleich der im Rahmen der Bewertung analysierten Algorithmen. Zudem korrelieren die gewählten Kennwerte teilweise. So zieht eine Erhöhung des Prognosehorizont ebenfalls eine Verbesserung des MAPE Kennwerts nach sich. Als Konsequenz fließt eine Verbesserung mehrfach in die Wertung ein und reduziert somit die Bedeutung andere Kennwerte. Für die Auswahl eines Algorithmus müssen die Kennwerte einzeln betrachtet und individuell für eine Anwendung entschieden werden.

Bei der durchgeführten Untersuchung findet die Bewertung der Algorithmen zur Zustandsbewertung anhand von Prognoseergebnissen statt. Dieses wird als zulässig erachtet, da alle verwendeten Ansätze den gleichen Algorithmus zur Restlebensdauerprognose nutzen. Dieser sucht nach ähnlichen Ergebnissen der Zustandsbewertung zwischen dem Testdatensatz und den Trainingsdatensätzen. Als Konsequenz verbessern sich die Prognosen, je genauer die Schadenszustände durch die gewählten Merkmale und der Gruppierung von Schadensverläufen differenziert werden können. Der Einfluss des Prognosealgorithmus auf das Ergebnis wird vernachlässigt, da dieser alle Ergebnisse betrifft.

Bereits im Rahmen der Verifikation hat sich gezeigt, dass die Gruppierung von Schadensverläufen als auch die Verwendung mehrerer Merkmale für das Klassifikationsproblem einen positiven Einfluss auf die Bewertung des Zustands besitzen. Wie sich in den Ergebnissen zur Prognosefähigkeit zeigt, verbessern sich dadurch vier der fünf verwendeten Kennwerte.

Den größten Einfluss auf den PH und MAPE Kennwert besitzt die Gruppierung der Degradierungsprozesse. Zudem ermöglicht diese, dass sich der Prognosehorizont mit einer steigenden Anzahl an Trainingsdaten verbessert. Die verfügbaren Informationen werden besser ausgenutzt. Bevor eine Prognose der RUL stattfindet, wird der getestete Degradierungsprozess in eine Schadensgruppe kategorisiert. Durch diese Vorklassifikation stehen dem Prognosealgorithmus weniger, aber dafür ähnlichere Degradierungsprozesse für die Schätzung der RUL zur Verfügung, wodurch die Prognose positiv beeinflusst wird.

Des Weiteren ist beobachtbar, dass der Algorithmus einzelne Schadensverläufe während der Clusteranalyse isoliert. Dieses Verhalten ist im Dendrogramm in Abbildung 7.6 (links) dargestellt. Dem Algorithmus stehen innerhalb der Trainingsphase acht Datensätze zur Verfügung. Durch die Gruppierung ($\zeta = 2,5$) entstehen drei Schadensgruppen. Während die ersten beiden Gruppen aus mehreren Schadensverläufen bestehen, wird Verlauf #11 einer einzelnen Gruppe zugeordnet. Der Grund hierfür ist in Abbildung 7.6 (rechts) veranschaulicht. Im Vergleich mit den vier Verläufen, welche in Abbildung 5.7 dargestellt sind, ist ersichtlich, dass sich der isolierte Verlauf deutlich von diesen unterscheidet. Ein Trend von einem der

dargestellten Merkmale über der Versuchsdauer ist nicht erkennbar, wodurch die Eignung dieses Verlaufs für eine Prognose nicht gegeben ist. Es wird angenommen, dass der Schaden, welcher zum Ausfall des Motors führte, abrupt innerhalb der drei Minuten zwischen zwei Messungen auftrat und somit nicht vom Messkonzept erfasst wurde. Je weniger Verläufe eine Schadensgruppe beim Training des Bayes-Klassifikators K_{SG} besitzt, desto größer muss die Übereinstimmung mit dem getesteten Verlauf sein, damit diese als wahrscheinlichste Gruppe gewählt wird. Als Konsequenz werden in der Testphase größere Gruppen bevorzugt und somit für die Prognose ungünstige Degradierungsprozesse isoliert.

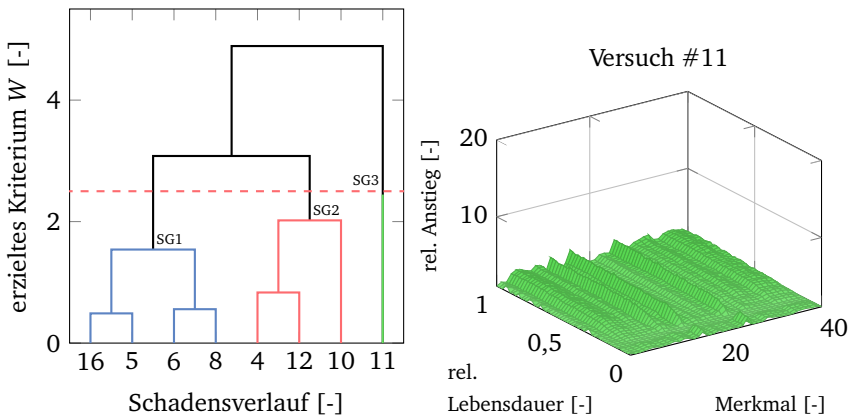


Abbildung 7.6.: Isolation von einzelnen Degradierungsprozessen durch den Clusteralgorithmus (links) sowie die Entwicklung von 40 Merkmalen eines ungünstigen Schadensverlaufs über der Lebensdauer (rechts)

Die Gruppierung als auch die Verwendung von mehreren Merkmalen führen zu einer Verbesserung der FN und FP Kennwerte. Wie in Abschnitt 5.3.1 gezeigt, verringert sich durch letzteres die Unsicherheit bei der Bewertung des Zustands (vgl. Abb. 5.9). Ist die Einschätzung des momentanen Zustands mit weniger Unsicherheit behaftet, führt das als Konsequenz zu einer präziseren Vorhersage der RUL. Die Gruppierung besitzt zudem den Vorteil, dass Prognosen auf weniger Verläufen basieren, wodurch sich die Breite der prognostizierten PDF verringert. In Kombination mit der gestiegenen Genauigkeit reduziert sich der Anteil der PDF in dem FN bzw. FP Bereich und führt somit zur Verbesserung der jeweiligen Kennwerte.

Obwohl sich der PH und MAPE Kennwert verbessern, kommt es zu einer Verschlechterung des MAD Kennwerts. Dieses deutet darauf hin, dass insbesondere frühe Prognosen eine stärkere Schwankung aufweisen, als die des Referenzalgo-

rhythmus. Die prognostizierten RUL Werte streuen höher, bevor sie stabil innerhalb des definierten Fehlerbandes des PH Kennwerts liegen. Um die Ursache der Verschlechterung zu beleuchten, sind in Abbildung 7.7 der geschätzte Zustandsindikator und drei Prognose zu einem Startzeitpunkt $\lambda = 0,1$, $\lambda = 0,3$ und $\lambda = 0,5$ dargestellt. Auffällig sind die Schwankungen des Indikators, welche insbesondere in der ersten Hälfte des Verlaufs sichtbar sind. Diese verdeutlichen, dass sich der Klassifikator nicht auf eine Gruppe festlegt und der Zustandsindikator anhand wechselnder Merkmale bewertet wird. Als Konsequenz schwankt die Ausgangssituation der drei Prognosen, was zu unterschiedlichen Ergebnissen führt und somit zu einem Anstieg des MAD Werts führt.




Abbildung 7.7.: Auswirkung von Unsicherheiten bei der Klassifikation von Schadensgruppen auf den Zustandsindikator (ZI) und auf drei Prognosen ($\lambda = 0,1$, $\lambda = 0,3$ und $\lambda = 0,5$)

Sowohl bei der Wahl eines zu niedrigen Schwellwerts ζ oder des Abbruchkriteriums ϵ kommt es zu einer sichtbaren Verschlechterung der Kennwerte. Die Ursache hierfür liegt in der Überanpassung des Algorithmus an die Trainingsdaten. Bei einem zu niedrigen Schwellwerte ζ beinhaltet jede Schadensgruppe genau einen Degradierungsprozess. Im Rahmen der Trainingsphase werden die Merkmale speziell für den jeweiligen Schadensverlauf gewählt. Diese sind jedoch nicht auf andere Testdaten übertragbar. Wird hingegen ein zu niedriges Abbruchkriterium ϵ gewählt, selektiert der Algorithmus zusätzliche Merkmale, auch wenn diese die Einordnung der Schadenszustände nur minimal verbessern. Damit steigt die Wahr-

scheinlichkeit, dass die Zustände aufgrund zufälliger Schwankungen der Merkmale oder durch äußere Einflüsse, wie beispielsweise der Umgebungstemperatur, besser eingeordnet werden können. Diese selektierten Merkmale verbessern zwar das Ergebnis in der Trainingsphase, sind aber nicht auf Testdaten übertragbar. In Abbildung 7.8 ist der Effekt auf die gewählten Merkmale für die Klassifikation des Schadenszustands sichtbar, wenn sowohl ein niedriger Wert für $\zeta = 0$ und $\epsilon = 1\%$ gewählt wird. Eine Gegenüberstellung mit Abbildung 5.10 verdeutlicht, dass die gewählten Merkmale breiter über dem Frequenzspektrum verteilt sind und tatsächlich relevante Merkmale nicht mehr identifiziert werden.




Abbildung 7.8.: Auswirkung eines zu geringen Abbruchkriteriums $\epsilon = 1\%$ und Schwellwerts $\zeta = 0$ auf die Selektion von Merkmalen

Werden nur drei Schadenszuständen $Z = 3$ verwendet, verschlechtert sich die Prognosefähigkeit stark. Dieser Effekt kann ebenfalls für den Vergleichsalgorithmus beobachtet werden. Da beide Ansätze davon betroffen sind, wird angenommen, dass die Verschlechterung durch den verwendeten Prognosealgorithmus verursacht wird. Je weniger Schadenszustände für die Einteilung eines Degradierungsprozesses verwendet werden, desto ungenauer ist das Ergebnis der verwendeten Faltung zur Suche nach Ähnlichkeiten zwischen Test- und Trainingsdaten. Eine zuverlässige Prognose ist erst bei einer Verwendung von mindestens fünf Schadenszuständen möglich.

Die Gegenüberstellung mit dem Vergleichsalgorithmus zeigt eine Prognosefähigkeit, welche im Bereich des Algorithmus mit der Parameterkonstellation δ_5 liegt. Da mit diesen Parametern keine Gruppierung der Schadensverläufe stattfindet, bedeu-

tet das, dass die Wahl zwischen den beiden Methoden zur Datenreduktion einen geringen Einfluss auf die Prognose besitzt. Sowohl die entwickelte Selektion von Merkmalen als auch die PCA ermöglichen es, geeignete Merkmale für die Prognose zu identifizieren. Für den Einsatz der PCA spricht, dass es sich um eine etablierte und robuste Methode zur Reduktion von großen Datenmengen handelt. Durch die Fusion der generierten Merkmale wird jedoch die Interpretation der Ergebnisse erschwert. Die Selektion von Merkmalen erlaubt dagegen eine genaue Aussage darüber, welche Merkmale für die Prognose relevant sind. Mit diesem Wissen kann in der Entwicklungsphase eines PHM Systems beispielsweise eine minimal benötigte Abtastrate definiert oder die Relevanz von verschiedenen Sensoren für die RUL bestimmt werden. Zudem basiert die Gruppierung der Schadensverläufe auf dem Kriterium W der Merkmalsselektion. Ein vergleichbarer Wert wird im Rahmen der PCA nicht generiert.

7.2 Übertragbarkeit

In der zweiten Untersuchung wird analysiert, ob der Algorithmus zur Identifizierung von Merkmalen eine Anpassung an andere Anwendungsszenarien ermöglicht. Zu diesem Zweck werden drei Szenarien definiert:

1. Die Merkmalsgenerierung findet auf Grundlage des Stromsignals statt.
2. Die Merkmalsgenerierung findet auf Grundlage des Vibrationssignals statt.
3. Die Merkmalsgenerierung findet auf Grundlage des Vibrations- und Stromsignals statt.

In jedem Szenario setzt sich die verfügbare Datenbank aus unterschiedlichen Merkmalen zusammen. Das Erste entspricht dem in Abschnitt 5.2.1 beschriebenen Vorgehen zur Generierung der Merkmale. Im zweiten Fall findet die gleiche Berechnung statt, jedoch auf Basis der Vibrationen, welche in radialer Richtung der Drehachse gemessen werden (siehe Abbildung 5.2). Im letzten Szenario hat der Algorithmus Zugriff auf die generierten Merkmale aus beiden Sensorquellen. Das hat zur Folge, dass zu der Bewertung des Zustands insgesamt 818 Merkmale verfügbar sind. Die Prognosefähigkeit wird für die drei Fälle sowohl mit der aus der ersten Untersuchung optimierten Parameterkonstellation δ_8 als auch mit dem Vergleichsalgorithmus anhand des Bewertungskonzepts berechnet. Jede Konstellation durchläuft zehn Schleifen von $J = 2$ bis $J = 11$ und die gewichteten Kennwerte werden zur Berechnung der Punktzahl verwendet.

7.2.1 Ergebnisse

In Abbildung 7.9 sind die erreichten Punktzahlen dargestellt, wenn die Algorithmen anhand der drei definierten Szenarien getestet werden. Beide Ansätze verbessern die Prognosefähigkeit, sobald die Vibrationsmessungen mit einbezogen werden. Auffällig ist, dass es keinen Unterschied zwischen Szenario zwei und drei gibt ($\Delta < 0,02$). Die zusätzlichen Daten des Stromsignals bringen demnach keinen Vorteil. In jedem Szenario erreicht der entwickelte Algorithmus mit den optimierten Parametern eine höhere Punktzahl als der Vergleichsalgorithmus.




Abbildung 7.9.: Gegenüberstellung der erzielten Punktzahlen des opt. Algorithmus (δ_8) und des Vergleichsalgorithmus bei drei unterschiedlichen Szenarien

In Tabelle 7.3 ist ein Ausschnitt der erreichten Kennwerte festgehalten. Die vollständige Tabelle befindet sich im Anhang I. Die Verwendung des Vibrationssignals hat auf alle Kennwerte einen positiven Einfluss. Beim Vergleichsalgorithmus kann ein größerer Effekt beobachtet werden (vgl. mit Kennwerten aus Tabelle 7.2). Wie in der Tabelle ersichtlich ist, kann der optimierte Algorithmus durch die Verwendung beider Signalquellen die Kennwerte nicht weiter verbessern. Insgesamt wird mit den Vibrationsmessungen ein Prognosehorizont von 0,40 erreicht, was einer Zeitspanne von ungefähr 16 h entspricht.

Tabelle 7.3.: Einfluss des Anwendungsszenarios auf die Kennwerte des optimierten Algorithmus δ_8 sowie des Vergleichsalgorithmus

Algorithmus	PH_M [-]	$MAPE_M$ [%]	FN_M [%]	FP_M [%]	MAD_M [h]	S [-]
Parameter δ_8 Sz. 2	0,395	43,77	29,75	29,80	6,08	0,97
Parameter δ_8 Sz. 3	0,399	44,37	29,88	29,51	6,11	0,97
Vergleichsalg. Sz.2	0,349	53,02	35,34	30,19	5,27	0,90

7.2.2 Diskussion

Die Ergebnisse deuten darauf hin, dass die Vibrationsmessungen sensitiver gegenüber den Auswirkungen eines Lagerschadens sind. Als Konsequenz können aus dem Vibrationsspektrum Merkmale generiert werden, welche sich besser für eine Bewertung des Zustands eignen. Die zusätzliche Hinzunahme der Merkmale aus dem Stromsignal beeinflusst die Prognosefähigkeit nicht. Eine Betrachtung der verwendeten Merkmale zeigt, dass ungefähr 98 % aus dem Vibrationsspektrum und nur 2 % aus dem Stromspektrum selektiert werden. Demnach erkennt der Algorithmus trotz der insgesamt 818 verfügbaren Merkmale, dass der Stromsensor keine zusätzliche Information enthält und damit überflüssig bei der Prognose ist. Hinsichtlich einer optimalen Prognosefähigkeit ist als Konsequenz eine Restlebensdauerprognose auf Basis der Vibrationssensoren zu bevorzugen.

Die Ergebnisse zeigen zudem, dass der entwickelte Ansatz auf unterschiedliche Sensorsignale ohne Anpassungen angewendet werden kann. In den drei definierten Szenarien erlaubt der Algorithmus die Identifizierung relevanter Merkmale in einem Datensatz zur Bewertung des Systemzustands und der Restlebensdauerprognose. Somit wird angenommen, dass sich der entwickelte Ansatz auch ohne ein tieferes Systemverständnis grundsätzlich auf andere Anwendungen übertragen lässt. Dabei müssen jedoch einige Einschränkungen beachtet werden, auf die im Folgenden eingegangen wird.

Eine Einschränkung betrifft insbesondere technische Systeme, bei denen der Degradierungsprozess durch eine äußere Belastung beeinflusst wird. Im betrachteten Anwendungsfall des Lüfters wird der Volumenstrom auf einen konstanten Wert geregelt. Eine Änderung eines Merkmals kann daher auf den fortschreitenden Schaden im Lagerelement zurückgeführt werden. Verändern sich jedoch die äußeren Bedingungen innerhalb eines Versuchs, werden die Merkmale ebenfalls beeinflusst.

In einem solchen Fall kann die Ursache für eine Veränderung der Merkmale nicht eindeutig identifiziert werden. Als Konsequenz selektiert der Algorithmus falsche Merkmale. Ein Ansatz um dieses Problem zu lösen, ist die Generierung eines Modells des intakten technischen Systems bei unterschiedlichen Lastzuständen. Durch das Wissen, wie das System bei Belastungen reagiert, kann der Anteil aufgrund einer veränderten Last eliminiert werden. Dieses Vorgehen erfordert jedoch zusätzliche Messdaten des Systems bei verschiedenen äußeren Bedingungen.

Eine weitere Herausforderung bei einer variablen Last ist, dass die äquidistante Zuordnung der Schadenszustände nicht mehr zulässig ist, siehe Abschnitt 4.2.1.1. Bei Schadensverläufen, die eine unterschiedliche Last erfahren, sind größere Schwankungen bei der Geschwindigkeit des Degradierungsprozesses zu erwarten. Daher müssen die Schadenszustände in Abhängigkeit der erfahrenen Belastung über die Lebensdauer verteilt werden. Zudem bietet die verwendete Methode zur Modellierung des Degradierungsprozesses im Rahmen der Prognose keine Möglichkeit weitere Eingabewerte, wie eine Belastung, zu berücksichtigen. Hier muss auf alternative Ansätze, wie KNN oder dem Gaußprozess, zurückgegriffen werden.

Der Bayes-Klassifikator setzt eine Normalverteilung der Merkmale eines Schadenszustands voraus. Aufgrund der nichtlinearen Charakteristik einer Degradierung ist dieses bei dem betrachteten Anwendungsbeispiel nicht gegeben. Dennoch liefert der Bayes-Klassifikator bessere Ergebnisse, als welche, die keine Normalverteilung voraussetzen. Zum Vergleich wurden Tests auf Basis anderer Klassifikatoren, wie der linearen und quadratischen Diskriminanzanalyse, durchgeführt. Die Ergebnisse sind im Anhang I zu finden. Bei der Übertragung auf einen anderen Anwendungsfall sollten unterschiedliche Klassifikatoren hinsichtlich einer besseren Eignung geprüft werden. Die Verwendung von komplexeren Klassifikatoren, wie SVM oder KNN, sind ebenfalls möglich, führen aber im Rahmen der Merkmalsselektion in der Trainingsphase zu einem Anstieg der Rechenzeit.

7.3 Wirtschaftliche Betrachtung

Für die wirtschaftliche Betrachtung wird der entwickelte Algorithmus einem zeitbasierten Wartungsansatz gegenübergestellt. Die Bewertung wird anhand des in Abschnitt 6.3 definierten Kennwerts zur Berechnung der Systemkosten pro Zeiteinheit durchgeführt. Dieser bewertet nicht die prognostizierte RUL, sondern den Zeitpunkt, ab wann ein Austausch der Komponente initiiert wird und somit die Qualität der generierten Handlungsempfehlung. Für die Untersuchung wird die Gesamtanzahl an verfügbaren Trainingsdaten konstant gehalten ($J = 11$). Insgesamt werden mittels des Bewertungskonzepts 150 Testdatensätze, mit verschiedenen Kombinationen an Trainingsdatensätzen, analysiert.

Zunächst wird anhand zweier fiktiver Szenarien die Leistung der beiden Ansätze für unterschiedliche Kosten für eine korrektive und präventive Maßnahmen näher analysiert. Während im ersten Szenario ein hohes Verhältnis ($V_{kp} = \frac{c_{korrr}}{c_{prä}}$) vorliegt, also ein ungeplanter Ausfall um ein vielfaches teurer ist, wird im zweiten Szenario ein Verhältnis von ungefähr eins betrachtet. Um den Einfluss von V_{kp} näher zu beleuchten, werden die gewonnenen Erkenntnisse auf weitere Kostenverhältnisse übertragen. Es wird ebenfalls untersucht, welche Auswirkung die Verwendung der entwickelten Methode zur Zustandsbewertung auf die Nutzungsdauer des technischen Systems und der Anzahl an ungeplanten Ausfällen hat.

Die zuvor beschriebene Herangehensweise basiert auf der Annahme, dass der Austausch einer Komponente zu jedem Zeitpunkt durchgeführt werden kann. Da diese Bedingung nicht immer erfüllt ist, wird in einer weiteren Untersuchung analysiert, welchen Einfluss eine Abweichung vom berechneten Austauschzeitpunkt t_A auf die Ergebnisse hat. Hierfür wird eine zufällige Verschiebung des Austauschzeitpunkts durch ein normalverteiltes Rauschen mit dem Erwartungswert μ_A und einer Standardabweichung σ_A simuliert. Der verschobene Austauschzeitpunkt t_V ergibt sich demnach zu

$$t_V = t_A + \mathcal{N}(\mu_A, \sigma_A). \quad (7.1)$$

Insgesamt werden drei Szenarien betrachtet. In den ersten beiden Fällen wird der Austausch ausgehend vom berechneten Zeitpunkt 5 h früher durchgeführt bzw. verzögert sowie mit einer zufälligen Verschiebung ($\sigma_A = 2,5$ h) variiert. Im dritten Szenario wird der Zeitpunkt ebenfalls verzögert $\mu_A = -5$ h und wird mit einer größeren zufälligen Komponente ($\sigma_A = 5,0$ h) behaftet.

7.3.1 Ergebnisse

In Abbildung 7.10 sind die berechneten Systemkosten pro Zeiteinheit C über dem gewählten Sicherheitsfenster t_{SF} dargestellt. Für die Analyse wird t_{SF} ausgehend von $t_{SF} = 0$ h sukzessive mit einem Zeitintervall von 15 Minuten auf $t_{SF} = 25$ h erhöht. Für jeden Wert von t_{SF} werden die verursachten Kosten C der 150 Testdatensätze über die Gleichung 6.6 berechnet, wenn die Bedingung für einen Austausch $r_{50} < t_{SF}$ eingehalten wird. Anschließend werden die Kosten gemittelt. Gilt beispielsweise ein niedriger Wert $t_{SF} = 1$ h, werden die Komponenten länger betrieben. Aufgrund der Ungenauigkeit der prognostizierten RUL steigt dadurch die Wahrscheinlichkeit eines ungeplanten Ausfalls.

Die Kosten sind für den optimierten (δ_8) und zeitbasierten Algorithmus berechnet. Im linken Szenario sind die Kosten einer präventiven und korrektiven Maßnahme mit $c_{prä} = 1500$ € und $c_{korrr} = 6500$ € gegeben. Je nachdem wel-




Abbildung 7.10.: Vergleich der Systemkosten pro Zeiteinheit C anhand eines Szenarios mit $c_{prä} = 1500€$ und $c_{korr} = 6500€$ (links) sowie eines Szenarios mit $c_{prä} = 5000€$ und $c_{korr} = 5500€$ (rechts)

ches Sicherheitsfenster t_{SF} beim entwickelten Ansatz gewählt wird, dominieren der präventive oder korrektive Anteil. Beim zeitbasierten Ansatz wird der ideale Austauschzeitpunkt nur anhand der Kosten $c_{prä}$ und c_{korr} bestimmt (siehe Gl. 6.5) und ist dadurch unabhängig von t_{SF} . Die Gesamtkosten des entwickelten Algorithmus sind über einen großen Bereich geringer als die entstehenden Kosten beim zeitbasierten Ansatz. Hinsichtlich der Optimierung der Systemkosten pro Zeiteinheit, ist der ideale Austauschzeitpunkt, wenn die prognostizierte RUL unter ungefähr 10 h liegt ($t_{SF,opt} = 10$ h).

In Abbildung 7.10 (rechts) ist das Ergebnis der beiden Ansätze dargestellt, wenn $c_{prä} = 5000€$ und $c_{korr} = 5500€$ beträgt ($V_{kp} = 1,1$). Als Konsequenz entsteht der größte Anteil der Kosten durch einen zu frühen Austausch. Das ideale Sicherheitsfenster liegt bei $t_{SF} = 0$, wobei C höher als beim zeitbasierten Ansatz ist. Die Kosten sinken im negativen Bereich weiter und schmiegen sich dem Wert des zeitbasierten Ansatzes an. Folglich kann die Prognose ignoriert und stattdessen die Komponente bis zum Ausfall betrieben werden, selbst wenn die prognostizierte RUL bereits null beträgt. Beim zeitbasierten Ansatz wird mit Gleichung 6.5 ein später Austauschzeit-

punkt von ungefähr 272 h berechnet. Als Konsequenz werden alle Komponenten bis zum Ausfall betrieben.

Die beiden Szenarien in Abbildung 7.10 verdeutlichen, dass der Vorteil des entwickelten Algorithmus gegenüber dem zeitbasierten Ansatz von V_{kp} einer Komponente abhängig ist. Wann sich der Einsatz lohnt, ist in Abbildung 7.11 (links) veranschaulicht. In Abhängigkeit der Kosten $c_{prä}$ und c_{korrr} ist das Verhältnis V_c zwischen den entstandenen Kosten C des zeitbasierten Ansatzes und des entwickelten PHM Systems aufgetragen. Dabei wird vorausgesetzt, dass der Austauschzeitpunkt entsprechend dem idealen Sicherheitsfenster $t_{SF,opt}$ gewählt wird. Die Werte für $c_{prä}$ und c_{korrr} wurden jeweils in einem Bereich von 1000€ bis 7000€ mit einer Auflösung von 500€ kombiniert. Je geringer die Kosten einer präventiven beziehungsweise je höher die Kosten einer korrektiven Maßnahme sind, desto größer ist der Nutzen des entwickelten Algorithmus. Liegt das Verhältnis V_c unterhalb von eins, bietet der zeitbasierte Ansatz einen Vorteil bezüglich der Systemkosten pro Zeiteinheit.

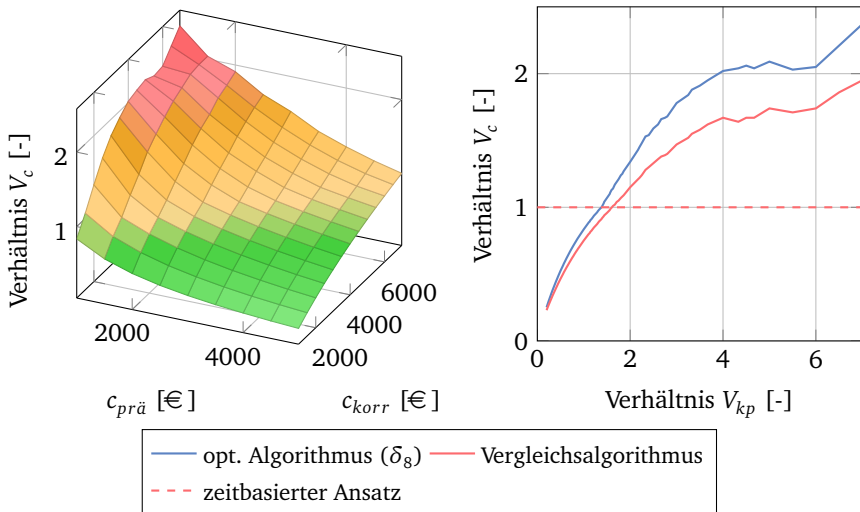


Abbildung 7.11.: Darstellung des Kostenverhältnisses V_c in Abhängigkeit der Kosten einer präventiven $c_{prä}$ und korrektiven c_{korrr} Maßnahme (links) sowie Gegenüberstellung des optimierten Algorithmus mit dem Vergleichsalgorithmus (rechts)

Für das Verhältnis V_c ist V_{kp} ausschlaggebend. In Abbildung 7.11 (rechts) ist daher aufgetragen, wie sich V_c über ein steigendes V_{kp} entwickelt. Neben dem optimierten Algorithmus ist das Ergebnis des Vergleichsalgorithmus dargestellt. Die Gruppierung der Schadensverläufe führt im Bereich $V_{kp} > 1,5$ zu besseren Ergebnissen. Ebenfalls verschiebt sich der Schnittpunkt mit dem zeitbasierten Ansatz zu niedrigen Werten von V_{kp} , wodurch sich die Anwendung des entwickelten PHM Systems bereits früher lohnt. In dem Bereich $V_{kp} < 1,5$ liefert der zeitbasierte Ansatz die besten Ergebnisse.

In Abbildung 7.12 sind die durchschnittliche Nutzungsdauer (links) und die Ausfälle in Prozent (rechts) der getesteten 150 Komponenten über V_{kp} dargestellt. Für geringe Werte von V_{kp} liegt die durchschnittliche Nutzungsdauer bei allen drei Ansätzen in einem ähnlichen Bereich. Erst bei hohen Werten ($V_{kp} > 4$) wird ein deutlicher Unterschied zwischen den Ansätzen sichtbar. Um ungeplante Ausfälle zu vermeiden, verringert der zeitbasierte Ansatz den Wartungszeitpunkt immer weiter. Im Gegensatz dazu erzielen die durch Prognosen gestützten Ansätze eine höhere Nutzungsdauer. Zudem sinken dabei die ungeplanten Ausfälle auf ungefähr 5 %. Beim Vergleichsalgorithmus liegt die Anzahl der Ausfälle leicht höher. Wird der zeitbasierte Ansatz verwendet, fällt trotz der geringsten Nutzungsdauer ungefähr jede dritte Komponente (39 von 150 Stück) ungeplant aus ($V_{kp} > 4$).

In den vorangegangenen Ergebnissen wurde davon ausgegangen, dass das ideale Sicherheitsfenster $t_{SF,opt}$ bekannt ist. In Abbildung 7.13 ist die Auswirkung auf das Ergebnis dargestellt, wenn das Sicherheitsfenster variiert (siehe. Gl. 7.1). Im linken Diagramm ist die Auswirkung auf den optimierten Algorithmus gezeigt. Zum Vergleich ist im rechten Schaubild das Ergebnis für den Vergleichsalgorithmus berechnet.

Beim optimierten Algorithmus hat ein früherer Austausch für hohe Verhältnisse von V_{kp} nur eine geringe Verschlechterung zur Folge. Beim Vergleichsalgorithmus ist diese deutlicher sichtbar. Eine größere Auswirkung hat ein verspäteter Austausch. Während der optimierte Algorithmus ungefähr auf das Niveau des Vergleichsalgorithmus ohne Beeinflussung sinkt, liegt dieser knapp oberhalb von eins. Eine Erhöhung der zufälligen Verschiebung sorgt für eine weitere Reduzierung. Dennoch bleiben beide Algorithmen über eins und somit besser als der zeitbasierte Ansatz.

7.3.2 Diskussion

Ziel dieser Untersuchung ist es, die Leistungsfähigkeit des entwickelten PHM Systems in einen wirtschaftlichen Kontext einzuordnen. Die Gegenüberstellung mit einem zeitbasierten Ansatz ist dadurch motiviert, dass es sich dabei um eine in der

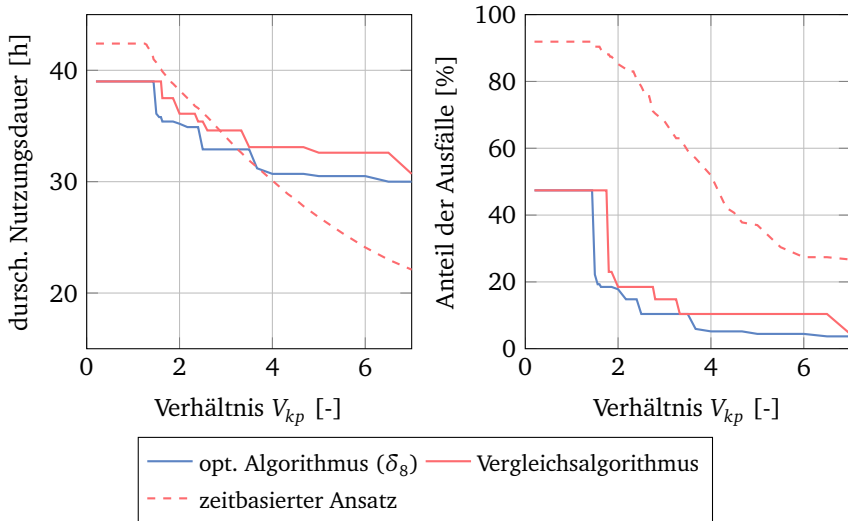


Abbildung 7.12.: Darstellung der durchschnittlichen Nutzungsdauer (links) sowie des prozentualen Anteils an ungeplanten Ausfällen aller 150 Testdatensätze (rechts)

Industrie etablierte Methode handelt. Bei der Untersuchung wurde die Annahme getroffen, dass das betrachtete System nicht repariert wird. Als Konsequenz fließen nur Kosten für einen präventiven und korrektiven Austausch der Komponente in die Berechnungen ein und nach einem Austausch liegt eine neuwertige Komponente vor. Die getroffenen Annahmen werden bei dem betrachteten Anwendungsfall des Asynchronmotors als zulässig angesehen. Es handelt sich um eine leicht austauschbare Komponente, die bei einem Ausfall oder Austausch durch eine Neue ersetzt wird.

Im Vergleich zum zeitbasierten Verfahren ist es durch den entwickelten Algorithmus möglich, für Verhältnisse $V_{kp} > 4$ die Systemkosten pro Zeiteinheit zu halbieren, die Nutzungsdauer zu erhöhen und die Anzahl ungeplanter Ausfälle zu reduzieren. Dabei wird jedoch vernachlässigt, dass bei einer vollständigen wirtschaftlichen Betrachtung zusätzliche Investitionen berücksichtigt werden müssen. Die Entwicklungs- und Hardwarekosten sind bei einem prognosebasierten Wartungsansatz um ein Vielfaches höher. Zudem sind Daten des Degradierungsprozesses bei einer Neuentwicklung nicht vorhanden und müssen aufwendig generiert werden. Ein weiterer Nachteil des prognosebasierten Wartungsansatzes ist, dass durch das

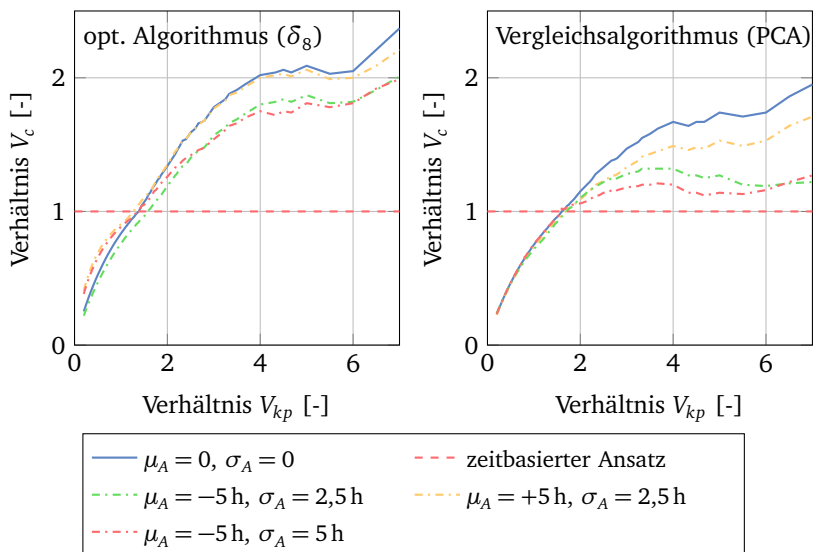


Abbildung 7.13.: Einfluss einer konstanten und zufälligen Verschiebung des geschätzten Austauschzeitpunkts auf das Verhältnis V_c des opt. Algorithmus (links) und des Vergleichsalgorithmus (rechts)

Einbringen von zusätzlichen Komponenten, wie Sensoren und Auswerteelektronik, potenzielle Fehlerquellen entstehen.

Ein Vorteil hinsichtlich der Hardwarekosten ist die Verwendung von Stromsensoren anstatt Vibrationssensoren. Die Nutzung von Stromsensoren ermöglicht eine Reduzierung der Anschaffungskosten, zumal die verwendeten Hall-Sensoren eine einfache Integration in ein bestehendes System erlauben. Demgegenüber steht, dass mit Vibrationssensoren eine höhere Prognosefähigkeit erreicht wird und somit eine Verringerung der Systemkosten pro Zeiteinheit zu erwarten ist (siehe Abschnitt 7.2).

Bei der Gegenüberstellung mit dem Vergleichsalgorithmus kann der entwickelte Algorithmus die Systemkosten pro Zeiteinheit im Schnitt um 11 % reduzieren (für $V_{kp} > 2$). Dieses Ergebnis untermauert, die in der ersten Untersuchung in Abschnitt 7.1 nachgewiesene höhere Prognosefähigkeit. Da die Leistungsfähigkeit des Vergleichsalgorithmus auf demselben Niveau liegt wie die des Algorithmus (δ_5), kann angenommen werden, dass die Verbesserung aufgrund der Gruppierung von Schadensverläufen entsteht. Zudem hat sich gezeigt, dass der optimierte Algorithmus

mus deutlich robuster gegenüber Schwankungen des Austauschzeitpunkts ist. Der Grund hierfür wird in Abbildung 7.14 (links) deutlich. Die Systemkosten pro Zeiteinheit sind für den optimierten Algorithmus, dem Vergleichsalgorithmus sowie dem zeitbasierten Ansatz dargestellt. Aufgrund der in Abschnitt 7.1 aufgezeigten Verbesserung der FN und FP Kennwerte, kommt es bei der Verwendung der optimierten Parameter zu weniger unnötiger Wartungsarbeiten und ungeplanten Ausfällen. Als Resultat bildet sich ein Bereich um den idealen Austauschzeitpunkt, in welchem die Kosten annähernd konstant verlaufen. Eine Verschiebung des Austauschzeitpunkts hat folglich eine geringere Auswirkung auf die Gesamtkosten. Beim Vergleichsalgorithmus fällt dieser Bereich geringer aus.

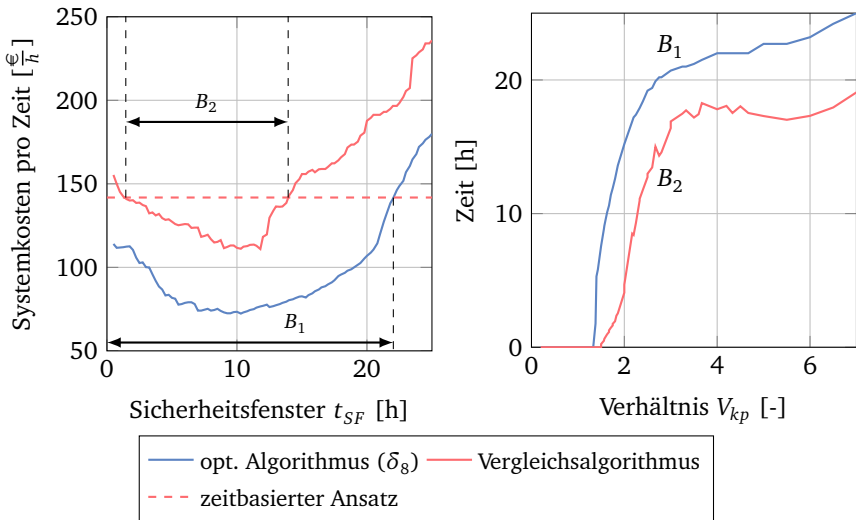


Abbildung 7.14.: Gegenüberstellung der Kosten pro Zeiteinheit des optimierten Algorithmus mit dem Vergleichsalgorithmus (links) sowie die Entwicklung des Bereiches B_1 und B_2 über dem Verhältnis V_{kp} (rechts)

In Abbildung 7.14 (links) sind die Bereiche B_1 und B_2 für beide PHM Ansätze gekennzeichnet. Diese beschreiben die Größe des Sicherheitsfensters, in denen der jeweilige PHM Ansatz ein besseres Ergebnis als der zeitbasierte Ansatz erzielt. Im Diagramm 7.14 (rechts) ist dargestellt, wie sich die Bereiche über ein steigendes Verhältnis V_{kp} entwickeln. Unterhalb der Grenze von ungefähr $V_{kp} < 1,5$ ist die Verwendung des zeitbasierten Ansatzes immer von Vorteil. Vergrößert sich V_{kp} steigen beide Bereiche stark an. Mit den optimierten Parametern nimmt der Bereich zu,

bis 25 h abgedeckt sind. Beim Vergleichsalgorithmus ist der Bereich immer geringer. Als Konsequenz führt eine Verschiebung des idealen Austauschzeitpunkts eher dazu, dass die Kosten C ansteigen und oberhalb des zeitbasierten Ansatzes liegen.

7.4 Zusammenfassung

In diesem Kapitel werden die Ergebnisse hinsichtlich der drei in der Einleitung gestellten Forschungsfragen vorgestellt und diskutiert. Zunächst wird der Einfluss des entwickelten Ansatzes auf die Prognosefähigkeit analysiert. Zu diesem Zweck werden zunächst die drei Parameter ϵ , ζ sowie Z variiert und deren Einfluss auf den Prognosehorizont ermittelt. Die Ergebnisse zeigen, dass die Anzahl der Schadensgruppen den größten Einfluss besitzt und den Prognosehorizont verbessert. Auf der Grundlage der Ergebnisse wird der beste Parametersatz abgeleitet und einem Vergleichsalgorithmus gegenübergestellt. Wird ausschließlich der Einfluss des Algorithmus zur Selektion von Merkmalen betrachtet, erreichen beide Algorithmen ein ähnliches Leistungsniveau. Erst durch die Hinzunahme der Gruppierung von Schadensverläufen kann ein Vorteil bei vier der fünf Kennwerte erzielt werden. Der MAD Kennwert verschlechtert sich, da es bei einer geringen Ausprägung des Schadens zu häufigen Fehlern bei der Klassifikation der Schadensgruppe kommt.

Der zweite Teil des Kapitels widmet sich der Übertragbarkeit des Algorithmus auf andere Anwendungsfälle. Anhand drei Szenarien mit unterschiedlichen Sensorquellen wird die grundsätzliche Übertragbarkeit des Algorithmus nachgewiesen. Die beste Leistung wird mit Merkmalen erreicht, welche aus den Vibrationsmessungen am Gehäuse des Motors generiert werden. Bei einer Kombination beider Sensorquellen zeigt sich, dass hauptsächlich Merkmale aus den Vibrationen für die Zustandsbewertung gewählt werden (ca. 98 %). Der Stromsensor bietet demnach keinen zusätzlichen Vorteil.

Abschließend wird eine wirtschaftliche Betrachtung anhand der Systemkosten pro Zeiteinheit vorgenommen. Zu diesem Zweck wird eine Gegenüberstellung mit einem zeitbasierten Wartungsansatz durchgeführt. Dabei zeigt sich, dass der Vorteil des PHM Systems steigt, je höher das Kostenverhältnis einer korrektiven zu präventiven Maßnahmen ist. In den betrachteten Szenarien kann eine Halbierung der Systemkosten erreicht werden. Zudem sinkt der Anteil der ungeplanten Ausfälle auf 5 %. Durch eine bessere Prognosefähigkeit ist der entwickelte Ansatz robuster gegenüber Abweichungen vom prognostizierten Austauschzeitpunkt als der Vergleichsalgorithmus.



8 Fazit und Ausblick

An dieser Stelle werden die Arbeitsschritte zur Beantwortung der in Kapitel 1 aufgestellten Forschungsfragen zusammengefasst und die Ergebnisse abschließend erörtert. Ausgehend von den gewonnenen Erkenntnissen wird eine Empfehlung für weitere Einsatzmöglichkeiten des vorgestellten Ansatzes gegeben. Im Anschluss werden die gesammelten Ideen für weiterführende Forschungsarbeiten dargestellt.

8.1 Inhalt der Arbeit und Fazit

Ein PHM System stellt eine Schlüsseltechnologie bei der Umsetzung eines zustandsorientierten Instandhaltungskonzepts dar und ist dadurch für Unternehmen ein wichtiger Baustein bei der digitalen Transformation im Rahmen der vierten industriellen Revolution. Durch diese Entwicklung motiviert, entstand die Zielsetzung der vorliegenden Arbeit, ein PHM System zu entwickeln, zu implementieren und dessen Leistungsfähigkeit zu untersuchen. Der Schwerpunkt lag dabei auf der Entwicklung eines neuartigen Ansatzes zur Zustandsbewertung.

Der in Kapitel 4 vorgestellte Ansatz zur Gruppierung von Schadensverläufen repräsentiert die Neuheit des entwickelten PHM Systems. Die Grundlage ist ein Algorithmus, der die automatische Auswertung von Schadensdatensätzen hinsichtlich relevanter Merkmale zur Abschätzung des Zustands eines technischen Systems ermöglicht. Dies wird durch die Definition von Schadenszuständen erreicht. Das dadurch generierte Klassifikationsproblem wird mithilfe von Techniken der Datenreduktion analysiert. Damit werden wesentliche Merkmale zur Lösung des Problems identifiziert. Dieses Ergebnis wird verwendet, um ähnliche Degradierungsprozesse eines technischen Systems zu erkennen und in Schadensgruppen zusammenzufassen. Der Grundgedanke dabei ist, Degradierungsprozesse zu gruppieren und Merkmale zur Zustandsbewertung individuell für jeweils eine Gruppe zu wählen. Die Gruppierung konnte durch die Nutzung einer hierarchischen Clusteranalyse erreicht werden. Als Resultat entsteht in der Testphase eine Abfolge von zwei Bayes-Klassifikatoren. Zunächst wird die wahrscheinlichste Schadensgruppe identifiziert, im Anschluss findet die Abschätzung des Zustands anhand geeigneter Merkmale statt. Dieser dient als Basis für die Restlebensdauerprognose und die Generierung einer Handlungsempfehlung.

Für die Verifikation des Ansatzes und zur Beantwortung der Forschungsfragen unter realistischen Rahmenbedingungen wurden mittels eines Prüfstandes Messdaten erfasst. Durch die Modifikation der vorderen Lagerelemente eines Axiallüfters konnte gewährleistet werden, dass der Degradierungsprozess beschleunigt und ein Ausfall in einer annehmbaren Zeit herbeigeführt wird. Die durchschnittliche Versuchsdauer betrug ungefähr 40 h. Insgesamt konnten durch dieses Vorgehen 18 Schadensverläufe unter vergleichbaren Ausgangsbedingungen generiert werden. Die somit erzeugte Datenbasis besteht aus Merkmalen, welche aus dem Frequenzspektrum eines Phasenstromes des Asynchronmotors berechnet werden.

Innerhalb des Verifikationsprozesses, welcher in Kapitel 5 beschrieben ist, konnte anhand der realen Daten gezeigt werden, dass der entwickelte Selektionsalgorithmus eine automatische Identifikation von relevanten Merkmalen ermöglicht. Unter Verwendung einzelner Schadensdatensätze konnte somit eine zuverlässige Zustandsbewertung ohne genauere Kenntnisse des betrachteten Systems stattfinden. Bei der Anwendung auf mehrere Datensätze zeigte sich allerdings eine Reduzierung der Leistungsfähigkeit. Dieses Ergebnis stützt die Annahme, dass keine allgemeingültigen Merkmale zur Beschreibung aller Degradierungsprozesse innerhalb der Datenbank gefunden werden können. Anschließend konnte nachgewiesen werden, dass eine Verbesserung der Zustandsbewertung durch die Gruppierung von ähnlichen Degradierungsprozessen erzielt werden kann. Der tatsächliche Nutzen der verwendeten Technik ist jedoch stark von der Fähigkeit abhängig, ob in der Testphase neue Daten in geeignete Gruppen eingeordnet werden. Hier konnte insbesondere bei einer geringen Ausprägung des Schadens eine hohe Fehlerrate des verwendeten Klassifikators festgestellt werden. Mit einer fortschreitenden Degradierung sinkt allerdings die Fehlerrate, sodass der verwendete Klassifikator als geeignet angesehen werden kann.

Zwar ist es möglich, anhand der gewonnenen Erkenntnisse im Rahmen der Verifikation auf einen positiven Einfluss auf die Zustandsbewertung zu schließen, jedoch muss die Gruppierung von Degradierungsprozessen kritisch hinterfragt werden. Im Rahmen der Untersuchung konnte kein Zusammenhang zwischen der vom Algorithmus zugeordneten Schadensgruppe und dem tatsächlich beobachtbaren Schadensbild hergestellt werden. Auf der einen Seite weisen die Messdaten eindeutig auf unterschiedliche Degradierungsprozesse hin, auf der anderen Seite brachte eine visuelle Inspektion der Lagerelemente nach dem Ausfall keine Erkenntnisse. Die Suche nach der Ursache von unterschiedlichen Prozessen konnte ebenfalls nicht zufriedenstellend abgeschlossen werden. Das Verhalten wird durch Variationen bei der Verteilung und Menge der verwendeten synthetischen Diamantpaste sowie geringfügige Abweichungen bei der Montage des Motors begründet. Kritisch zu betrachten ist auch die Tatsache, dass durch die stochastische Natur ei-

ner Degradierung eine unendliche Anzahl an möglichen Prozessen zu erwarten ist. Diese werden durch den verfolgten Ansatz jedoch auf eine endliche Anzahl an Gruppen abgebildet, was zu Fehlklassifikationen führt. Dennoch zeigt sich bei der Untersuchung der Ausfälle auch eine Stärke des verwendeten Ansatzes. Ohne genaue Kenntnisse der zugrunde liegenden physikalischen Vorgänge sind eine Zustandsbewertung und eine Prognose der Restlebensdauer möglich.

Die in Kapitel 7 vorgestellten und diskutierten Ergebnisse zur Beantwortung der drei gestellten Forschungsfragen basieren auf einem Bewertungskonzept, welches in Kapitel 6 eingeführt wurde. Dieses erlaubt eine umfassende Einschätzung der Leistungsfähigkeit, auch wenn nur wenige Schadensverläufe zur Verfügung stehen. Zunächst stand die Beantwortung der ersten Forschungsfrage mit der Untersuchung des Einflusses auf die Prognosefähigkeit anhand von fünf Kennwerten im Fokus. Zu diesem Zweck wurde der entwickelte Ansatz einem PHM Vergleichsalgorithmus, welcher auf der PCA basiert, gegenübergestellt. Wird ausschließlich der Einfluss des Algorithmus zur Selektion von Merkmalen betrachtet, zeigt sich, dass dieser hinsichtlich der gewählten Leistungskennwerte keinen Vorteil liefert. Als Konsequenz ist für die Datenreduktion die PCA des Vergleichsalgorithmus zu bevorzugen, da diese den Stand der Technik darstellt und eine einfachere Implementierung ermöglicht. Dennoch besitzt der verwendete Selektionsalgorithmus eine Daseinsberechtigung, da die Ausgabewerte als Grundlage für die verwendete hierarchische Clusteranalyse dienen und erst dadurch eine Gruppierung der Degradierungsprozesse ermöglicht wird. Anhand der Ergebnisse konnte gezeigt werden, dass die Prognosefähigkeit gegenüber dem Vergleichsalgorithmus gesteigert werden kann, wenn die Gruppierung von Schadensverläufen verwendet wird. Durch die genauere und präzisere Zustandsbewertung erhöht sich der Prognosehorizont bei einer gleichzeitigen Verringerung der FN und FP Kennwerte. Im Durchschnitt befindet sich die prognostizierte Restlebensdauer dadurch 2 h früher im definierten Fehlerband des Prognosehorizonts. Ein Schlüsselresultat der Arbeit stellt die Steigerung der Performanz des Algorithmus mit mehr verfügbaren Trainingsdaten dar, welche ausschließlich durch die implementierte Gruppierung erreicht wird. Dieses deutet auf eine höhere Lernfähigkeit des Algorithmus hin, da Informationen aus einer verfügbaren Datenbasis effizienter genutzt werden.

Die zweite Forschungsfrage betrifft die Übertragbarkeit des Ansatzes auf neue Anwendungsfälle. Anhand der Verwendung von unterschiedlichen Sensorquellen wurden drei Szenarien simuliert. Die Ergebnisse lassen darauf schließen, dass eine Übertragbarkeit gegeben ist. Sowohl der entwickelte Ansatz als auch der Vergleichsalgorithmus ermöglichen anhand der gemessenen Vibrationen, der Phasenströme sowie der Kombination aus beiden eine Zustandsbewertung. Beide Ansätze erreichen die beste Leistung unter der Verwendung von Vibrationsdaten. Im Gegen-

satz zum Vergleichsalgorithmus erlaubt der entwickelte Ansatz die Identifizierung von nicht relevanten Sensoren. So konnte anhand des kombinierten Szenarios gezeigt werden, dass nur Merkmale der Vibrationsmessungen selektiert werden und der Stromsensor demnach keinen zusätzlichen Nutzen bringt. Die gewonnene Erkenntnis gilt jedoch nur unter der Einschränkung, dass äußere Belastungen auf das betrachtete System gleichbleibend sind und somit der Einfluss auf den Degradierungsprozess vernachlässigt werden kann. Eine wechselnde Belastung beeinflusst die Merkmale und führt im Rahmen des Selektionsprozesses zu Fehlern bei der Auswertung der Datenbasis. Diese Tatsache kann bei dem betrachteten Anwendungsbeispiel des Lüftersystems vernachlässigt werden, schränkt aber eine generelle Übertragbarkeit ein. Mögliche Lösungsansätze und Erweiterungen des PHM Systems in diese Richtung werden in Kapitel 7 diskutiert.

Die dritte Forschungsfrage ist dadurch motiviert, dass die verwendeten Kennwerte zur Beschreibung der Prognosefähigkeit hinsichtlich eines Nutzens für die Instandhaltung schwer interpretierbar sind. Zu diesem Zweck wurde ein Kennwert definiert, welcher die entstehenden Systemkosten pro Zeiteinheit berechnet. Diese setzen sich aus anfallenden Kosten für korrektive oder präventive Maßnahmen zusammen und werden in Abhängigkeit des prognostizierten Austauschzeitpunkts berechnet. Mit dem Ziel, die Einordnung der Ergebnisse zu erleichtern, wurde als Referenz ein konventioneller zeitbasierter Wartungsansatz gewählt. Dabei zeigt sich, dass der Nutzen des prognosegestützten Austausches steigt, je größer das Verhältnis V_{kp} der Kosten einer korrektiven zu einer präventiven Maßnahme ist. Für hohe Verhältnisse ($V_{kp} > 4$) konnte eine Halbierung der Systemkosten nachgewiesen werden. Gleichzeitig erhöht sich die Nutzungsdauer um bis zu 36 % und der Anteil an ungeplanten Ausfällen reduziert sich auf ca. 5 %. Bei einer Gegenüberstellung mit dem Vergleichsalgorithmus sind die Systemkosten des entwickelten Ansatzes im Schnitt um 11 % niedriger. Die gewonnenen Erkenntnisse gelten unter der Annahme, dass es sich bei dem betrachteten System um eine nicht reparierbare Komponente handelt. Zudem besitzt der herangezogene Kennwert nur eine begrenzte Aussagekraft hinsichtlich des gesamten wirtschaftlichen Vorteils, da hierfür zusätzliche Entwicklungs- und Hardwarekosten, einkalkuliert werden müssen. Trotzdem liefert die Untersuchung eine erste Einschätzung über das mögliche Potenzial des entwickelten PHM Systems.

Wenn alle Erkenntnisse der drei Forschungsfragen berücksichtigt werden, lässt sich schlussfolgern, dass durch die Gruppierung der Schadensverläufe eine Verbesserung der Prognosefähigkeit gegenüber dem heutigen Stand der Technik möglich ist. Die Verbesserung führt zu einer Verringerung der Systemkosten, längeren Betriebszeiten eines technischen Systems sowie weniger ungeplanten Ausfällen und steigert somit den Nutzen für die Instandhaltung. Eine Übertragbarkeit auf weitere

Anwendungsfälle ist unter den oben genannten Einschränkungen ebenfalls gewährleistet, was die Verwertbarkeit des Algorithmus erhöht und die Möglichkeit schafft, einen Beitrag zur Umsetzung der vierten industriellen Revolution zu leisten.

Der vorgeschlagene Ansatz eignet sich insbesondere für technische Systeme, bei denen sich der Degradierungsprozess nicht mit einem einheitlichen Set an Merkmalen beschreiben lässt. In diesen Fällen wird eine Gruppierung der Schadensverläufe zur Verbesserung der Zustandsbewertung empfohlen. Die vorliegende Arbeit konnte zeigen, dass die Prognose von Lagerschäden einer Drehstrommaschine ein möglicher Anwendungsfall ist. Ebenfalls denkbar sind Getriebeschäden, bei denen ein Defekt unterschiedliche Frequenzbereiche des Vibrationsspektrums beeinflusst. Nicht empfehlenswert ist dagegen eine Anwendung des Ansatzes zur Prognose der Lebensdauer von Batterien. Der Zustand einer Batterie kann in der Regel anhand eines einzelnen Merkmals, beispielsweise der Kapazität [LZP16], beschrieben werden. Eine Gruppierung mithilfe der hierarchischen Clusteranalyse wäre in einem solchen Fall nicht zielführend.

8.2 Weiterführende Arbeiten

Mit dem Ziel das Anwendungsgebiet zu erweitern, wäre eine konsequente Weiterentwicklung die Implementierung eines Ansatzes zur Berücksichtigung von äußeren variablen Belastungen. Die Integration eines Modells des intakten Systems stellt hier eine vielversprechende Möglichkeit dar, um mögliche Einflüsse der Last auf die Merkmale zu berechnen und zu eliminieren. Weitere Messdaten von unterschiedlichen Lastzuständen eines Systems wären nötig. Zusätzlich wäre der Umstieg auf eine alternative Methode zur Erstellung von Prognosemodellen erforderlich, um weitere Eingangsgrößen zu berücksichtigen. Zu diesem Zweck könnte beispielsweise auf KNN zurückgegriffen werden.

Eine weitere Erweiterung des vorliegenden Ansatzes wäre der Austausch der verwendeten Bayes-Klassifikatoren gegen komplexere Ansätze, welche nichtlineare Zusammenhänge innerhalb der Datenbasis abbilden können. Dieses würde auf der einen Seite zu einem Anstieg der Rechenzeit innerhalb der Trainingsphase führen, könnte aber auf der anderen Seite zu einer besseren Bewertung des Zustands beitragen. Zudem hat sich gezeigt, dass unter Verwendung der PCA zur Datenreduktion vergleichbare Ergebnisse bei geringerer Komplexität erzielt werden können. Wird anstatt des verwendeten Selektionsalgorithmus eine Verknüpfung der PCA mit der hierarchischen Clusteranalyse hergestellt, könnte die Komplexität des entwickelten Ansatzes reduziert werden, ohne dabei die Leistungsfähigkeit negativ zu beeinflussen.

Mit Bezug auf einen tatsächlichen Einsatz wäre insbesondere die Reduzierung des Messequipments auf das Notwendigste interessant. Die Arbeit hat bereits gezeigt, dass eine Prognose nur anhand der Stromsensoren möglich ist. Weitere Untersuchungen sind nötig, um die erforderliche Qualität der Sensordaten zu ermitteln und somit das verwendete Messsystem gegen eine kostengünstigere Technik zu ersetzen. Erste Untersuchungen in diese Richtung konnten bereits zeigen, dass eine Fehlerdiagnose von Lagerschäden auf Basis eines Raspberry Pis möglich ist [Sch15].

Im Hinblick auf eine Ausweitung der Untersuchung der Leistungsfähigkeit des Ansatzes wären ebenfalls weitere Ansatzpunkte denkbar. Interessant wäre insbesondere die Betrachtung einer zweiten Fehlerquelle, wie der Degradierungsprozess des hinteren Lagerelementes. Werden die beiden Fehlerquellen in unterschiedliche Schadensgruppen eingeordnet, wäre der Ansatz ebenfalls für die Fehlerisolation, also die Identifikation der Schadensursache, geeignet.

Weiterhin darf nicht vernachlässigt werden, dass durch die durchgeführten Versuche eine umfangreiche Datenbasis generiert wurde. Diese kann für weitere Forschungsarbeiten im Gebiet von PHM Systemen genutzt werden.

Literaturverzeichnis

- [AAM⁺86] ALBRECHT, P. F., J. C. APPIARIUS, R. M. MCCOY, E. L. OWEN und D. K. SHARMA: *Assessment of the Reliability of Motors in Utility Applications - Updated*. IEEE Power Engineering Review, PER-6(3):31–32, 1986.
- [ABF⁺15] ATTOUI, I., N. BOUTASSETA, N. FERGANI, B. OUDJANI und A. DELIOU: *Vibration-based bearing fault diagnosis by an integrated DWT-FFT approach and an adaptive neuro-fuzzy inference system*. In: *3rd International Conference on Control, Engineering & Information Technology*, Seiten 1–6, 2015.
- [Agg15] AGGARWAL, C. C.: *Data Mining: The Textbook*. Springer International Publishing, Cham, 1. Auflage, 2015.
- [AHT14] AYE, S. A., P. S. HEYNS und C. J.H. THIART: *A Review of Slow Speed Bearing Diagnostics and Prognostics*. In: *International Journal of Engineering Science and Technology*, Seiten 726–739, 2014.
- [Air08] AIR FORCE RESEARCH LABORATORY: *Feature extraction for bearing prognostics and health management a survey*, 2008.
- [AK12] AHMAD, R. und S. KAMARUDDIN: *An overview of time-based and condition-based maintenance in industrial application*. *Computers & Industrial Engineering*, 63(1):135–149, 2012.
- [Alc00] ALCALDE RASCH, A.: *Erfolgspotential Instandhaltung: Theoretische Untersuchung und Entwurf eines ganzheitlichen Instandhaltungsmanagements*, Band 21 der Reihe *Duisburger betriebswirtschaftliche Schriften*. Erich Schmidt, Berlin, 2000.
- [Alp10] ALPAYDIN, E.: *Introduction to machine learning*. MIT Press, Cambridge, 2. Auflage, 2010.
- [AMB⁺13] ATTOUI, I., H. MERADI, R. BOULKROUNE, R. SAIDI und A. GRID: *Fault detection and diagnosis in rotating machinery by vibration monitoring using FFT and Wavelet techniques*. In: *8th International Workshop on Systems, Signal Processing and their Applications*, Seiten 401–406, 2013.

-
- [APK15] ANGER, C., C. PREUSCHE und U. KLINGAUF: *Asynchronous Motor Test Bench for the Generation and Current Signal Diagnostics of Accelerated Bearing Damage*. In: *Annual Conference of the Prognostics and Health Management Society*, 2015.
- [ASK12] ANGER, C., R. SCHRADER und U. KLINGAUF: *Unscented Kalman filter with gaussian process degradation model for bearing fault prognosis*. In: *European Conference of Prognostics and Health Management Society*, 2012.
- [AWA03] ADDISON, D., S. WERMTER und G. AREVIAN: *A comparison of feature extraction and selection techniques*. In: *International Conference on Artificial Neural Networks*, Seiten 212–215, 2003.
- [BCSJ07] BODDEN, D. S., N. S. CLEMENTS, B. SCHLEY und G. JENNEY: *Seeded Failure Testing and Analysis of an Electro-Mechanical Actuator*. In: *IEEE Aerospace Conference*, Seiten 1–8, 2007.
- [BDDR⁺09] BEN-DAYA, M., S. O. DUFFUAA, A. RAOUF, J. KNEZEVIC und D. AIT-KADI: *Handbook of Maintenance Management and Engineering*. Springer, London, 2009.
- [BDKM16] BEN-DAYA, M., U. KUMAR und D. N. P. MURTHY: *Introduction to maintenance engineering: Modelling, optimization and management*. John Wiley & Sons, Hoboken, 2016.
- [BG12] BLOCH, H. P und F. K. GEITNER: *Machinery failure analysis and troubleshooting*. Practical machinery management for process plants. Elsevier, Amsterdam, 4. Auflage, 2012.
- [BGRR08] BLODT, M., P. GRANJON, B. RAISON und G. ROSTAING: *Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring*. *IEEE Transactions on Industrial Electronics*, 55(4):1813–1822, 2008.
- [Bha10] BHATTACHARYYA, S. S.: *Handbook of signal processing systems*. Springer, New York, 2010.
- [Bis13] BISHOP, C. M.: *Pattern recognition and machine learning*. Information science and statistics. Springer, New York, 11. Auflage, 2013.

-
- [BMLZ16] BRAHIMI, M., K. MEDJAHER, M. LEOUATNI und N. ZERHOUNI: *Development of a prognostics and health management system for the railway infrastructure: Review and methodology*. In: *Prognostics and System Health Management Conference*, Seiten 1–8, 2016.
- [BMMH07] BROWN, E. R., N. N. MCCOLLOM, E. E. MOORE und A. HESS: *Prognostics and Health Management A Data-Driven Approach to Supporting the F-35 Lightning II*. In: *IEEE Aerospace Conference*, Seiten 1–12, 2007.
- [BMZR12] BENKEDJOUH, T., K. MEDJAHER, N. ZERHOUNI und S. RECHAK: *Fault prognostic of bearings by using support vector data description*. In: *IEEE Conference on Prognostics and Health Management*, Seiten 1–7, 2012.
- [BMZR15] BENKEDJOUH, T., K. MEDJAHER, N. ZERHOUNI und S. RECHAK: *Health assessment and life prediction of cutting tools based on support vector regression*. *Journal of Intelligent Manufacturing*, 26(2):213–223, 2015.
- [BOFR12] BUTLER, S., F. O'CONNOR, D. FARREN und J. V. RINGWOOD: *A feasibility study into prognostics for the main bearing of a wind turbine*. In: *IEEE International Conference on Control Applications*, Seiten 1092–1097, 2012.
- [Bou15] BOUKRA, T.: *Identifying new prognostic features for remaining useful life prediction using particle filtering and Neuro-Fuzzy System predictor*. In: *IEEE International Conference on Environment and Electrical Engineering*, Seiten 1533–1538, 2015.
- [BPR⁺13] BORGESANI, P., P. PENNACCHI, R. B. RANDALL, N. SAWALHI und R. RICCI: *Application of cepstrum pre-whitening for the diagnosis of bearing faults under variable speed conditions*. *Mechanical Systems and Signal Processing*, 36(2):370–384, 2013.
- [BR10] BUTLER, S. und J. RINGWOOD: *Particle filters for remaining useful life estimation of abatement equipment used in semiconductor manufacturing*. In: *Conference on Control and Fault-Tolerant Systems*, Seiten 436–441, 2010.
- [BR16] BABU, W. R. und C. S. RAVICHANDRAN: *Diagnosis of stator fault of Medium Voltage Induction Motors using Motor Stator Current Envelope*

-
- Analysis*. In: *3rd International Conference on Advanced Computing and Communication Systems*, Seiten 1–5, 2016.
- [BRG02] BYINGTON, C. S., M. J. ROEMER und T. GALIE: *Prognostic enhancements to diagnostic systems for improved condition-based maintenance*. In: *IEEE Aerospace Conference*, Seiten 2815–2824, 2002.
- [BWES04] BYINGTON, CARL S., M. WATSON, DOUG EDWARDS und PAUL STOELTING: *A model-based approach to prognostics and health management for flight control actuators*. In: *Aerospace Conference, 2004. Proceedings. 2004 IEEE*, Band 6, Seiten 3551–3562, 2004.
- [CAGG16] CIRA, F., M. ARKAN, B. GUMUS und T. GOKTAS: *Analysis of stator interturn short-circuit fault signatures for inverter-fed permanent magnet synchronous motors*. In: *42nd Annual Conference of the IEEE Industrial Electronics Society*, Seiten 1453–1457, 2016.
- [CKTM13] CAESARENDRA, W., B. KOSASIH, K. TIEU und C. A. S. MOODIE: *An application of nonlinear feature extraction - A case study for low speed slewing bearing condition monitoring and prognosis*. In: *IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, Seiten 1713–1718, 2013.
- [Czi15] CZICHOS, H.: *Mechatronik: Grundlagen und Anwendungen technischer Systeme*. Springer, Wiesbaden, 3. Auflage, 2015.
- [CZLX17] CAI, B., Y. ZHAO, H. LIU und M. XIE: *A Data-Driven Fault Diagnosis Methodology in Three-Phase Inverters for PMSM Drive Systems*. *IEEE Transactions on Power Electronics*, 32(7):5590–5600, 2017.
- [Deu12] DEUTSCHE NORM: *Grundlagen der Instandhaltung*, September 2012.
- [DG13] DAI, X. und Z. GAO: *From Model, Signal to Knowledge: A Data-Driven Perspective of Fault Detection and Diagnosis*. *IEEE Transactions on Industrial Informatics*, 9(4):2226–2238, 2013.
- [DGO11] DELGADO, M., A. GARCIA und J. A. ORTEGA: *Evaluation of feature calculation methods for electromechanical system diagnosis*. In: *8th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, Seiten 495–502, 2011.
- [Din08] DING, S. X.: *Model-based fault diagnosis techniques: Design schemes, algorithms, and tools*. Springer, Berlin, 2008.

-
- [ECJ12] EKER, Ö. F., F. CAMCI und I. K. JENNIONS: *Major challenges in prognostics: Study on benchmarking prognostic datasets*. In: *European Conference of Prognostics and Health Management Society*. PHM Society, 2012.
- [EER16] ELATTAR, H. M., H. K. ELMINIR und A. M. RIAD: *Prognostics: A literature review*. *Complex & Intelligent Systems*, 2(2):125–154, 2016.
- [EGY14] ETTEFAGH, M. M., M. GHAEMI und M. YAZDANIAN ASR: *Bearing fault diagnosis using hybrid genetic algorithm K-means clustering*. In: *IEEE International Symposium on Innovations in Intelligent Systems and Applications*, Seiten 84–89, 2014.
- [EO04] ERTUNC, H. M. und C. OYSU: *Drill wear monitoring using cutting force signals*. *Mechatronics*, 14(5):533–548, 2004.
- [FCO16] FONTES, A. S., C. A. V. CARDOSO und L. P. B. OLIVEIRA: *Comparison of techniques based on current signature analysis to fault detection and diagnosis in induction electrical motors*. In: *Electrical Engineering Conference*, Seiten 74–79, 2016.
- [FLYW15] FAN, X., X. LI, X. YANG und J. WANG: *A Particle-Filtering Approach for Remaining Useful Life Estimation of Wind Turbine Gearbox*. In: *International Conference on Chemical, Material and Food Engineering*, Seiten 198–200, 2015.
- [GCF⁺16] GALLOWAY, G. S., V. M. CATTERSON, T. FAY, A. ROBB und C. LOVE: *Diagnosis of tidal turbine vibration data through deep neural networks*. In: *European Conference of Prognostics and Health Management Society*, 2016.
- [GDF⁺12] GRITLI, Y., A. O. DI TOMMASO, F. FILIPPETTI, R. MICELI, C. ROSSI und A. CHATTI: *Investigation of motor current signature and vibration analysis for diagnosing rotor broken bars in double cage induction motors*. In: *International Symposium on Power Electronics Power Electronics, Electrical Drives, Automation and Motion*, Seiten 1360–1365, 2012.
- [GE03] GUYON, I. und A. ELISSEEFF: *An introduction to variable and feature selection*. *Journal of machine learning research*, 3(3):1157–1182, 2003.

-
- [GSS08] GOEBEL, KAI, BHASKAR SAHA und ABHINAV SAXENA: *A comparison of three data-driven techniques for prognostics*. In: *62nd meeting of the society for machinery failure prevention technology (mfpt)*, Seiten 119–131, 2008.
- [HB08] HE, D. und E. BECHHOEFER: *Development and Validation of Bearing Diagnostic and Prognostic Tools using HUMS Condition Indicators*. In: *IEEE Aerospace Conference*, Seiten 1–8, 2008.
- [HG15] HIRA, Z. M. und D. F. GILLIES: *A Review of Feature Selection and Feature Extraction Methods Applied on Microarray Data*. *Advances in bioinformatics*, 1(1):1–13, 2015.
- [HMN⁺13] HAUS, S., H. MIKAT, M. NOWARA, S. T. KANDUKURI, U. KLINGAUF und M. BUDERATH: *Fault Detection based on MCSA for a 400Hz Asynchronous Motor for Airborne Applications*. *International Journal of Prognostics and Health Management*, 1(4):1–19, 2013.
- [Hod09] HODAPP, W.: *Die Bedeutung einer zustandsorientierten Instandhaltung: Einsatz und Nutzen in der Investitionsgüterindustrie*. In: REICHEL, J., G. MÜLLER und J. MANDELARTZ (Herausgeber): *Betriebliche Instandhaltung*, Seiten 135–149. Springer, Berlin, 2009.
- [HT10] HAUBELT, C. und J. TEICH: *Digitale Hardware/Software-Systeme: Spezifikation und Verifikation*. Springer, Berlin, 2010.
- [HZ12] HONG, S. und Z. ZHOU: *Remaining useful life prognosis of bearing based on gauss process regression*. In: *5th International Conference on Biomedical Engineering and Informatics*, Seiten 1575–1579, 2012.
- [HZF09] HE, Y., X. ZHANG und M. I. FRISWELL: *Defect diagnosis for rolling element bearings using acoustic emission*. *Journal of Vibration and Acoustics*, 131(6):1–10, 2009.
- [HZTM09] HENG, A., S. ZHANG, A. C.C. TAN und J. MATHEW: *Rotating machinery prognostics: State of the art, challenges and opportunities*. *Mechanical Systems and Signal Processing*, 23(3):724–739, 2009.
- [Int10] INTERNATIONAL ORGANIZATION FOR STANDARDIZATION: *Condition monitoring and diagnostics of machines - Data processing, communication and presentation*, Dezember 2010.

-
- [Ise05] ISERMANN, R.: *Model-based fault-detection and diagnosis—status and applications*. Annual Reviews in control, 29(1):71–85, 2005.
- [Ise11] ISERMANN, R.: *Fault-diagnosis applications: Model-based condition monitoring: actuators, drives, machinery, plants, sensors, and fault-tolerant systems*. Springer, Berlin, 2011.
- [IV15] ISHKOVA, I. und O. VITEK: *Diagnosis of eccentricity and broken rotor bar related faults of induction motor by means of motor current signature analysis*. In: *16th International Scientific Conference on Electric Power Engineering*, Seiten 682–686, 2015.
- [Jen13] JENNIONS, I. K.: *Integrated vehicle health management*. SAE International, Warrendale, 2013.
- [JGG⁺16] JIARULA, Y., J. GAO, Z. GAO, H. JIANG und R. WANG: *Fault mode prediction based on decision tree*. In: *IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference*, Seiten 1729–1733, 2016.
- [JGZZ12] JAVED, K., R. GOURIVEAU, R. ZEMOURI und N. ZERHOUNI: *Features Selection Procedure for Prognostics: An Approach Based on Predictability*. IFAC Proceedings Volumes, 45(20):25–30, 2012.
- [JK11] JAMMU, N. S. und P. K. KANKAR: *A review on prognosis of rolling element bearings*. International Journal of Engineering Science and Technology, 3(10):7497–7503, 2011.
- [JLB06] JARDINE, A. K.S., D. LIN und D. BANJEVIC: *A review on machinery diagnostics and prognostics implementing condition-based maintenance*. Mechanical Systems and Signal Processing, 20(7):1483–1510, 2006.
- [Joh11] JOHNSON, S. B.: *System health management With aerospace applications*. Aerospace Series. Wiley, Hoboken, N.J, 2011.
- [JPBRC⁺14] JESUS RANGEL-MAGDALENO, J., H. PEREGRINA-BARRETO, J. M. RAMIREZ-CORTES, P. GOMEZ-GIL und R. MORALES-CAPORAL: *FPGA-Based Broken Bars Detection on Induction Motors Under Different Load Using Motor Current Signature Analysis and Mathematical Morphology*. IEEE Transactions on Instrumentation and Measurement, 63(5):1032–1040, 2014.

-
- [JPL⁺15] JUNG, J., Y. PARK, S. B. LEE, C. CHO, K. KIM, E. WIEDENBRUG und M. TESKA: *Monitoring of journal bearing faults based on motor current signature analysis for induction motors*. In: *IEEE Energy Conversion Congress and Exposition*, Seiten 300–307, 2015.
- [JSQ⁺16] JIN, X., Y. SUN, Z. QUE, Y. WANG und T. W. S. CHOW: *Anomaly Detection and Fault Prognosis for Bearings*. *IEEE Transactions on Instrumentation and Measurement*, 65(9):2046–2054, 2016.
- [JWHT13] JAMES, G., D. WITTEN, T. HASTIE und R. TIBSHIRANI: *An introduction to statistical learning: With applications in R*, Band 103 der Reihe *Springer texts in statistics*. Springer, New York, 6. Auflage, 2013.
- [KCBG12] KULKARNI, C. S., J. R. CELAYA, G. BISWAS und K. GOEBEL: *Prognostics of Power Electronics, methods and validation experiments*. In: *IEEE Autotestcon Proceedings*, Seiten 194–199, 2012.
- [KEKM10] KIRITSIS, D., C. EMMANOULIDIS, A. KORONIOS und J. MATHEW (Herausgeber): *Engineering Asset Lifecycle Management*. Springer, London, 2010.
- [KS14] KIMOTHO, J. K. und W. SEXTRO: *An approach for feature extraction and selection from non-trending data for machinery prognosis*. In: *European Conference of Prognostics and Health Management Society*, 2014.
- [KSH11] KANKAR, P. K., S. C. SHARMA und S. P. HARSHA: *Fault diagnosis of ball bearings using continuous wavelet transform*. *Applied Soft Computing*, 11(2):2300–2312, 2011.
- [Lei14] LEIDINGER, BERNHARD: *Wertorientierte Instandhaltung: Kosten senken, Verfügbarkeit erhalten*. Springer Gabler, Wiesbaden, 2014.
- [LL16] LUCAS ALVAREZ, M. und D. M. LANE: *A Hidden Markov Model application with Gaussian Mixture emissions for fault detection and diagnosis on a simulated AUV platform*. In: *OCEANS MTS/IEEE Monterey*, Seiten 1–4, 2016.
- [LM06] LI, W. und C. K. MECHEFSKE: *Detection of induction motor faults: A comparison of stator current, vibration and acoustic methods*. *Journal of vibration and Control*, 12(2):165–188, 2006.

-
- [LN10] LAU, E. C. C. und H. W. NGAN: *Detection of Motor Bearing Outer Raceway Defect by Wavelet Packet Transformed Motor Current Signature Analysis*. IEEE Transactions on Instrumentation and Measurement, 59(10):2683–2690, 2010.
- [LRRTMS⁺16] LOPEZ-RAMIREZ, M., R. J. ROMERO-TRONCOSO, D. MORINIGO-SOTELO, O. DUQUE-PEREZ, L. M. LEDESMA-CARRILLO, D. CAMARENA-MARTINEZ und A. GARCIA-PEREZ: *Detection and diagnosis of lubrication and faults in bearing on induction motors through STFT*. In: *International Conference on Electronics, Communications and Computers*, Seiten 13–18, 2016.
- [LSH12] LI, R., P. SOPON und D. HE: *Fault features extraction for bearing prognostics*. Journal of Intelligent Manufacturing, 23(2):313–321, 2012.
- [LWZ⁺14] LEE, J., F. WU, W. ZHAO, M. GHAFARI, L. LIAO und D. SIEGEL: *Prognostics and health management design for rotary machinery systems: Reviews, methodology and applications*. Mechanical Systems and Signal Processing, 42(2):314–334, 2014.
- [LZP16] LIU, YUEFENG, GUANGQUAN ZHAO und XIYUAN PENG: *A fusion prognostic approach based on multi-kernel relevance vector machine and Bayesian model averaging*. In: *2016 Prognostics and System Health Management Conference (PHM-Chengdu)*, Seiten 1–6. IEEE, 2016.
- [LZPL17] LI, C., W. ZHANG, G. PENG und S. LIU: *Bearing Fault Diagnosis Using Fully-Connected Winner-Take-All Autoencoder*. IEEE Access, 1(3):2169–2179, 2017.
- [Mey14] MEYER, M.: *Signalverarbeitung: Analoge und digitale Signale, Systeme und Filter*. Studium. Springer Vieweg, Wiesbaden, 7. Auflage, 2014.
- [Mik15] MIKAT, H.: *Hybride Fehlerprognose zur Unterstützung prädiktiver Instandhaltungskonzepte in der Luftfahrt*. Doktorarbeit, Technische Universität Darmstadt, Darmstadt, 2015.
- [Mis08] MISRA, K. B. (Herausgeber): *Handbook of Performability Engineering*. Springer, London, 2008.

-
- [MTMZ12] MEDJAHER, K., D. A. TOBON-MEJIA und N. ZERHOUNI: *Remaining Useful Life Estimation of Critical Components With Application to Bearings*. IEEE Transactions on Reliability, 61(2):292–302, 2012.
- [MW16] MEKAROONKAMON, T. und S. WONGSA: *A comparative investigation of the robustness of unsupervised clustering techniques for rotating machine fault diagnosis with poorly-separated data*. In: *Eighth International Conference on Advanced Computational Intelligence*, Seiten 165–172, 2016.
- [MZB13] MEDJAHER, K., N. ZERHOUNI und J. BAKLOUTI: *Data-driven prognostics based on health indicator construction: Application to PRONOSTIA's data*. In: *European Control Conference*, Seiten 1451–1456, 2013.
- [Nac17] NACHLAS, J. A.: *Reliability engineering: Probabilistic models and maintenance methods*. CRC Press, Boca Raton, 2. Auflage, 2017.
- [NGM⁺12] NECTOUX, P., R. GOURIVEAU, K. MEDJAHER, E. RAMASSO, B. CHEBEL-MORELLO, N. ZERHOUNI und C. VARNIER: *PRONOSTIA: An experimental platform for bearings accelerated degradation tests*. In: *IEEE International Conference on Prognostics and Health Management*, Seiten 1–8, 2012.
- [O'D85] O'DONNELL, P.: *Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part I*. IEEE Transactions on Industry Applications, IA-21(4):853–864, 1985.
- [OV07] ORCHARD, M. E. und G. J. VACHTSEVANOS: *A particle filtering-based framework for real-time fault diagnosis and failure prognosis in a turbine engine*. In: *Mediterranean Conference on Control & Automation*, Seiten 1–6, 2007.
- [PAK14] PREUSCHE, C., C. ANGER und U. KLINGAUF: *Evaluation of the Training Process of three different Prognostic Approaches based on the Gaussian Process*. In: *European Conference of Prognostics and Health Management Society*, 2014.
- [Paw16] PAWELLEK, G.: *Integrierte Instandhaltung und Ersatzteillogistik*. Springer Berlin, Berlin, 2. Auflage, 2016.
- [PCCC06] PUGNO, N., M. CIAVARELLA, P. CORENETTI und A. CARPENTERI: *A generalized Paris' law for fatigue crack growth*. Journal of the Mechanics and Physics of Solids, 54(7):1333–1349, 2006.

-
- [Pec08] PECHT, M.: *Prognostics and health management of electronics*. Wiley, Hoboken, N.J., 2008.
- [PGK16] PATIL, A. B., J. A. GAIKWAD und J. V. KULKARNI: *Bearing fault diagnosis using discrete Wavelet Transform and Artificial Neural Network*. In: *2nd International Conference on Applied and Theoretical Computing and Communication Technology*, Seiten 399–405, 2016.
- [PJ10] PECHT, MICHAEL und RUBYCA JAAI: *A prognostics and health management roadmap for information and electronics-rich systems*. *Microelectronics Reliability*, 50(3):317–323, 2010.
- [QX15] QIAO, L. Q. und L. J. XUN: *State of health estimation combining robust deep feature learning with support vector regression*. In: *34th Chinese Control Conference*, Seiten 6207–6212, 2015.
- [RAH16] REUSS, P., K. D. ALTHOFF und W. HENKEL: *Case-Based Decision Support on Diagnosis and Maintenance in the Aircraft Domain*. In: *Lernen, Wissen, Daten, Analysen - Workshop*, Seiten 249–256, 2016.
- [RGPLCA⁺13] RIERA-GUASP, M., J. PONS-LLINARES, V. CLIMENTE-ALARCON, F. VEDRENO-SANTOS, M. PINEDA-SANCHEZ, J. ANTONINO-DAVIU, R. PUCHE-PANADERO, J. PEREZ-CRUZ und J. ROGER-FOLCH: *Diagnosis of induction machines under non-stationary conditions: Concepts and tools*. In: *IE-EE Workshop on Electrical Machines Design, Control and Diagnosis*, Seiten 220–231, 2013.
- [RMM09] REICHEL, J., G. MÜLLER und J. MANDELARTZ (Herausgeber): *Betriebliche Instandhaltung*. Springer, Berlin, 2009.
- [RPN12] RAO, B. K. N., P. S. PAI und T. N. NAGABHUSHANA: *Failure diagnosis and prognosis of rolling-element bearings using Artificial Neural Networks: A critical overview*. In: *Journal of Physics: Conference Series*, Band 364, Seiten 12–23, 2012.
- [Rus12] RUSSELL, E. L.: *Data-driven methods for fault detection and diagnosis in chemical processes*. Springer, London, 2012.
- [RW11] RAM, A. und N. WIRATUNGA: *Case-based reasoning research and development*. In: *19th International Conference on Case-Based Reasoning*, Seiten 17–31. Springer London, 2011.

-
- [SAHR10] SERYASAT, O. R., M. ALIYARI SHOOREHDELI, F. HONARVAR und A. RAHMANI: *Multi-fault diagnosis of ball bearing using FFT, wavelet energy entropy mean and root mean square*. In: *IEEE International Conference on Systems, Man and Cybernetics*, Seiten 4295–4299, 2010.
- [SCB⁺08] SAXENA, A., J. CELAYA, E. BALABAN, K. GOEBEL, B. SAHA, S. SAHA und M. SCHWABACHER: *Metrics for evaluating performance of prognostic techniques*. In: *International Conference on Prognostics and Health Management*, Seiten 1–17, 2008.
- [Sch05] SCHWABACHER, M.: *A survey of data-driven prognostics*. In: *Infotech@Aerospace*, Seiten 1–5, 2005.
- [Sch10] SCHRÖDER, W.: *Ganzheitliches Instandhaltungsmanagement: Aufbau, Ausgestaltung und Bewertung*. Gabler Verlag, Wiesbaden, 2010.
- [Sch13] SCHAEFFLER TECHNOLOGIES AG & Co. KG: *Schadenserkenkung und Begutachtung gelaufer Wälzlager*, 2013.
- [Sch15] SCHICKEL, T.: *Inbetriebnahme eines Prüfstandes zur Generierung von Lagerschadendaten und Validierung eines low-cost Sensorsystems*. Masterthesis, TU Darmstadt, Darmstadt, 2015.
- [SCS⁺09] SAXENA, A., J. CELAYA, B. SAHA, S. SAHA und K. GOEBEL: *Evaluating algorithm performance metrics tailored for prognostics*. In: *IEEE Aerospace conference*, Seiten 1–13, 2009.
- [SCS⁺10] SAXENA, A., J. CELAYA, B. SAHA, S. SAHA und K. GOEBEL: *Metrics for offline evaluation of prognostic performance*. *International Journal of Prognostics and Health Management*, 1(1):20, 2010.
- [Sen16] SENDLER, U. (Herausgeber): *Industrie 4.0 grenzenlos*. Xpert.press. Springer Vieweg, Berlin, 2016.
- [SG14] SANKARARAMAN, S. und K. GOEBEL: *Uncertainty in prognostics and health management: An overview*. In: *European Conference of the Prognostics and Health Management Society*, Seiten 1–11, 2014.
- [SGC09] SAHA, B., K. GOEBEL und J. CHRISTOPHERSEN: *Comparison of prognostic algorithms for estimating remaining useful life of batteries*. *Transactions of the Institute of Measurement and Control*, 31(3-4):293–308, 2009.

-
- [SIL07] SAEYS, Y., I. INZA und P. LARRANAGA: *A review of feature selection techniques in bioinformatics*. *Bioinformatics*, 23(19):2507–2517, 2007.
- [SJS06] SOKOLOVA, M., N. JAPKOWICZ und S. SZPAKOWICZ: *Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation*. In: SATTAR, A. und B. KANG (Herausgeber): *AI 2006: Advances in Artificial Intelligence*, Band 4304, Seiten 1015–1021. Springer Berlin, Berlin, 2006.
- [SK17] SINGH, S. und N. KUMAR: *Detection of Bearing Faults in Mechanical Systems Using Stator Current Monitoring*. *IEEE Transactions on Industrial Informatics*, 13(3):1341–1349, 2017.
- [SLNL14] SEERA, M., C. P. LIM, S. NAHAVANDI und C. K. LOO: *Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models*. *Expert Systems with Applications*, 41(10):4891–4903, 2014.
- [SMZ15] SOUALHI, A., K. MEDJAHER und N. ZERHOUNI: *Bearing Health Monitoring Based on Hilbert–Huang Transform, Support Vector Machine, and Regression*. *IEEE Transactions on Instrumentation and Measurement*, 64(1):52–62, 2015.
- [SS05] SATISH, B. und N. D. R. SARMA: *A fuzzy approach for diagnosis and prognosis of bearing faults in induction motors*. In: *IEEE Power Engineering Society General Meeting*, Seiten 958–961, 2005.
- [SSA14] SINGLETON, R. K., E. G. STRANGAS und S. AVIYENTE: *Discovering the hidden health states in bearing vibration signals for fault prognosis*. In: *40th Annual Conference of the IEEE Industrial Electronics Society*, Seiten 3438–3444, 2014.
- [SSA15] SINGLETON, R. K., E. G. STRANGAS und S. AVIYENTE: *Extended Kalman Filtering for Remaining-Useful-Life Estimation of Bearings*. *IEEE Transactions on Industrial Electronics*, 62(3):1781–1790, 2015.
- [SSA16] SINGLETON, R., E. STRANGAS und S. AVIYENTE: *The Use of Bearing Currents and Vibrations in Lifetime Estimation of Bearings*. *IEEE Transactions on Industrial Informatics*, 1(3):1–7, 2016.
- [SSM97] SCHÖLKOPE, B., ALEXANDER SMOLA und K. R. MÜLLER: *Kernel principal component analysis*. In: HASLER, MARTIN und JEAN-DANIEL NICOD

(Herausgeber): *Artificial Neural Networks*, Band 1327 der Reihe *Lecture Notes in Computer Science*, Seiten 583–588. Springer Berlin, Berlin, 1997.

- [SVJ11] SAMAGA, R. L., K. P. VITTAL und V. J.: *Effect of unbalance in voltage supply on the detection of mixed air gap eccentricity in an induction motor by Motor Current Signature Analysis*. In: *IEEE Conference Innovative Smart Grid Technologies*, Seiten 108–113, 2011.
- [SW07] SANDBORN, P. A. und C. WILKINSON: *A maintenance planning and business case development model for the application of prognostics and health management (PHM) to electronic systems*. *Microelectronics Reliability*, 47(12):1889–1901, 2007.
- [SZKP12] SUN, B., S. ZENG, R. KANG und M. G. PECHT: *Benefits and Challenges of System Prognostics*. *IEEE Transactions on Reliability*, 61(2):323–335, 2012.
- [Vac07] VACHTSEVANOS, G. J.: *Intelligent fault diagnosis and prognosis for engineering systems methods and case studies*. John Wiley, Hoboken, 2007.
- [VWD14] VOGL, G. W., B. A. WEISS und M. A. DONMEZ: *Standards Related to Prognostics and Health Management (PHM) for Manufacturing*. National Institute of Standards and Technology, Gaithersburg, 2014.
- [VWH16] VOGL, G. W., B. A. WEISS und M. HELU: *A review of diagnostic and prognostic capabilities and best practices for manufacturing*. *Journal of Intelligent Manufacturing*, 63(1):135, 2016.
- [VY12] VAN, T. T. und B. S. YANG: *An intelligent condition-based maintenance platform for rotating machinery*. *Expert Systems with Applications*, 39(3):2977–2988, 2012.
- [WCC07] WANG, F., B. CHENG und B. CAO: *Machine condition monitoring by nonlinear feature fusion based on kernel principal component analysis with genetic algorithm*. In: *Third International Conference on Natural Computation*, Seiten 665–670, 2007.
- [WG13] WANG, J. und R. X. GAO: *Multiple model particle filtering for bearing life prognosis*. In: *IEEE Conference on Prognostics and Health Management*, Seiten 1–6, 2013.

-
- [Wit11] WITTEN, I. H.: *Data mining: Practical machine learning tools and techniques*. Elsevier, Elsevier, 3. Auflage, 2011.
- [WKQ⁺08] WU, X., V. KUMAR, J. R. QUINLAN, J. GHOSH, Q. YANG, H. MOTODA, G. J. MCLACHLAN, A. NG, B. LIU und S. Y. PHILIP: *Top 10 algorithms in data mining*. Knowledge and information systems, 14(1):1–37, 2008.
- [WW12] WANG, Y. und W. WANG: *Failure prognostic of systems with hidden degradation process*. Journal of Systems Engineering and Electronics, 23(2):314–324, 2012.
- [WZA12] WANG, Z., J. ZARADER und S. ARGENTIERI: *A novel aircraft engine fault diagnostic and prognostic system based on SVM*. In: *IEEE International Conference on Condition Monitoring and Diagnosis*, Seiten 723–728, 2012.
- [WZX⁺17] WANG, Z., Q. ZHANG, J. XIONG, M. XIAO, G. SUN und J. HE: *Fault Diagnosis of a Rolling Bearing Using Wavelet Packet Denoising and Random Forests*. IEEE Sensors Journal, 17(1):5581–5588, 2017.
- [XEHY10] XUE, Y., N. H. W. EKLUND, X. HU und W. YAN: *Time receiver operating characteristic (tROC) curves: A new tool for evaluating the performance of diagnostic systems*. In: *International Joint Conference on Neural Networks*, Seiten 1–7, 2010.
- [YGA11] YIAKOPOULOS, C. T., K. C. GRYLLIAS und I. A. ANTONIADIS: *Rolling element bearing fault detection in industrial environments based on a K-means clustering approach*. Expert Systems with Applications, 38(3):2888–2911, 2011.
- [YH01] YU, W. K. und T. A. HARRIS: *A New Stress-Based Fatigue Life Model for Ball Bearings*. Tribology Transactions, 44(1):11–18, 2001.
- [YHQ13] YOON, J. M., D. HE und B. QIU: *Full ceramic bearing fault diagnosis using LAMSTAR neural network*. In: *IEEE Conference on Prognostics and Health Management*, Seiten 1–9, 2013.
- [Zio13] ZIO, E.: *Prognostics and Health Management of Industrial Equipment*. In: KADRY, SEIFEDINE (Herausgeber): *Diagnostics and Prognostics of Engineering Systems*, Seiten 333–356. IGI Global, 2013.

-
- [ZP11] ZIO, ENRICO und GIOVANNI PELONI: *Particle filtering prognostic estimation of the remaining useful life of nonlinear components*. Reliability Engineering & System Safety, 96(3):403–409, 2011.

A Trainingsprozess des PHM Systems

benötigter Parameter:

Abschnitt:

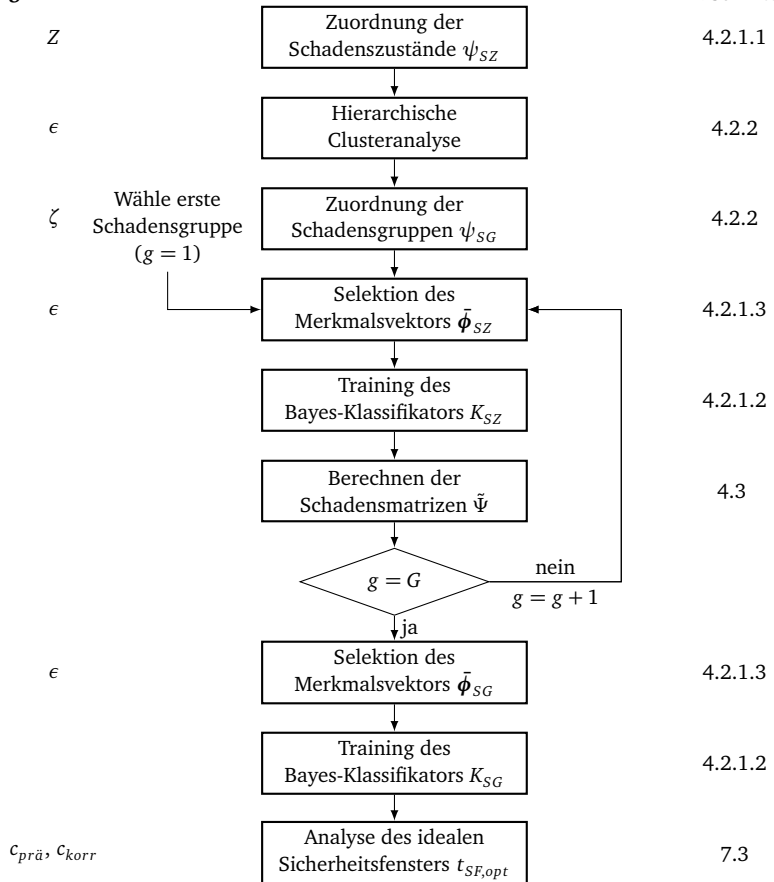


Abbildung A.1.: Ablauf des Trainingsprozesses



B Training des Bayes-Klassifikators

Gegeben sind K Merkmalsvektoren, die jeweils M Merkmale $\phi_{k,m}$ beinhalten. Jeder Vektor k wird mit einer Wahrscheinlichkeit $\psi_{SZ,k,z}$ dem Schadenszustand z zugeordnet. Der Mittelwert und die Standardabweichung eines Merkmals m zur Beschreibung der Klasse z sind durch

$$\mu_{z,m} = \frac{\sum_{k=1}^K \phi_{k,m} \cdot \psi_{SZ,k,m}}{\sum_{k=1}^K \psi_{SZ,k,m}} \quad (\text{B.1})$$

und

$$\sigma_{z,m} = \sqrt{\frac{\sum_{k=1}^K \psi_{SZ,k,m} \cdot (\mu_{z,m} - \phi_{k,m})^2}{\left(\sum_{k=1}^K \psi_{SZ,k,m}\right) - 1}} \quad (\text{B.2})$$

gegeben. Auf gleiche Weise wird die Berechnung des Mittelwerts und der Standardabweichung zur Beschreibung einer Schadensgruppe durchgeführt.



C Daten der Clusteranalyse

Der erste Datensatz Φ_1 ist durch die in Abbildung C.1 dargestellten Merkmale gegeben:

$$\Phi_1 = [\phi_1 \quad \phi_2 \quad \phi_3 \quad \phi_4].$$

Die vier weiteren Datensätze für die hierarchische Clusteranalyse basieren auf Φ_1 und sind durch

$$\begin{aligned} \Phi_2 &= [\phi_1 \quad 0,9 \cdot \phi_2 \quad \phi_3 \quad \phi_4], & \Phi_3 &= [\phi_1 \quad 0,8 \cdot \phi_2 \quad 1,1 \cdot \phi_3 \quad \phi_4], \\ \Phi_4 &= [\phi_1 \quad 0,4 \cdot \phi_2 \quad \phi_3 \quad 0,5 \cdot \phi_4] \text{ und } \Phi_5 &= [\phi_1 \quad 0,3 \cdot \phi_2 \quad \phi_3 \quad 0,3 \cdot \phi_4] \end{aligned}$$

gegeben. Es ist ersichtlich, dass die Datensätze Φ_4 und Φ_5 sich mehr von Φ_1 unterscheiden als Φ_2 und Φ_3 .




Abbildung C.1.: Darstellung der vier Merkmale des fiktiven Datensatzes



D Messkonzept des Prüfstands

Tabelle D.1.: Auflistung der integrierten Sensorik, aufgeteilt nach Typ, Anzahl und der Messgröße des Sensors

Sensor	Typ	Anzahl	Messgröße
Stromsensoren	LEM LA 25-NP	3	Drei Phasenströme des Asynchronmotors
Beschleunigungssensor	Kistler 8704B/4B50	3	Radiale, axiale und tangentielle Schwingungen am Gehäuse
Drehzahlsensor	integriert im Asynchronmotor	1	Rotordrehzahl
Temperatursensor	National Semiconductor LM35	1	Umgebungstemperatur
Volumenstromsensor	First Sensor BTEL/PTUL5000	1	Vom Motor erzeugter Volumenstrom



E Referenzmessungen

In Abbildung E.1 ist das Frequenzspektrum des Phasenstroms a von vier Referenzmessungen vor den Versuchen #2, #10, #18 und nach einer fehlerhaft durchgeführten Montage (leichte Schiefstellung des Lagertopfes) dargestellt. Die korrekte Montage und die Durchführung der Versuche besitzen einen vernachlässigbaren Einfluss. Eine falsche Montage führt zu einem deutlichen Anstieg im Bereich 345 Hz.

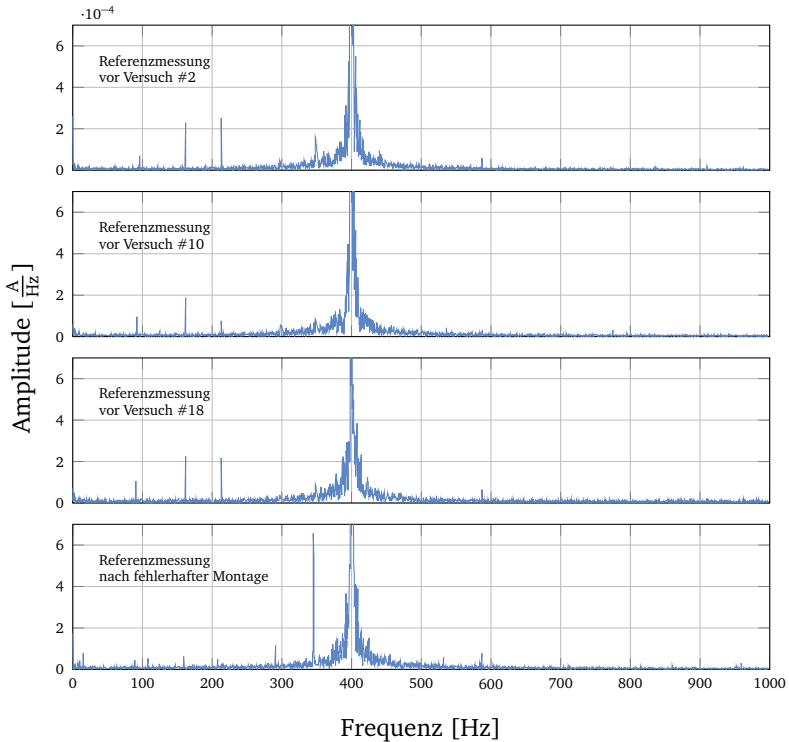


Abbildung E.1.: Vier Referenzmessungen vor Versuch #2, #10, #18 und nach einer fehlerhaft durchgeführten Montage

In Abbildung E.2 sind jeweils zwei Schwingungen der Phasenströme a, b und c dargestellt. Bei einer Abtastfrequenz von 25 000 Hz werden zwei Schwingungen durch 125 Samples repräsentiert. In Abbildung E.3 ist das Verhalten des Phasenstroms kurz vor dem Ausfall gezeigt. Der Effektivwert steigt bis ungefähr 5 A an, bevor der Überlastschutz greift und den Versuch abbricht.

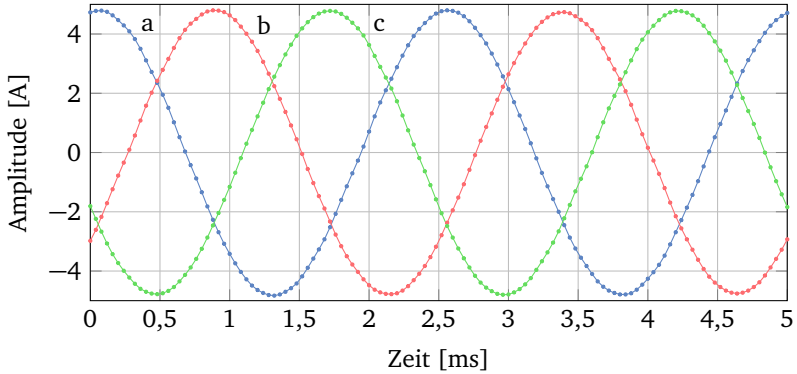


Abbildung E.2.: Zwei Schwingungen der Phasenströme a, b und c einer Referenzmessung




Abbildung E.3.: Verhalten des Phasenstroms a kurz vor dem Ausfall

F Durchgeführte Experimente

Tabelle F.1.: Versuchszeiten und Ausfallursache der 18 Experimente

Versuchsnr.	Dauer t_{EoL} [h]	Ausfallursache
1	13,8	Käfigschaden
2	61,4	Lagerspiel
3	21,1	Käfigschaden
4	50,3	Käfigschaden
5	94,3	Lagerspiel
6	7,6	Käfigschaden
7	40,8	Lagerspiel
8	112,6	Käfigschaden
9	12,2	Käfigschaden
10	30,4	Käfigschaden
11	78,6	Lagerspiel
12	20,4	Käfigschaden
13	12,1	Käfigschaden
14	59,3	Lagerspiel
15	17,6	Käfigschaden
16	26,5	Lagerspiel
17	30,9	Käfigschaden
18	36,4	Lagerspiel



G Berechnung der Fehlerfrequenzen

Die Berechnung der Schadensfrequenzen im Phasenstrom infolge eines Schadens im Innenring f_{ir} oder Außenring f_{or} erfolgt nach [BGRR08] mit den Gleichungen

$$f_{ir} = |f_s + m \cdot f_{v,ir}| \text{ und} \\ f_{or} = |f_s + m \cdot f_{v,or}|.$$

Der Faktor m ist eine Laufvariable, die jeden ganzzahligen Wert außer Null annehmen kann. Die Frequenzen $f_{v,ir}$ und $f_{v,or}$ sind die entsprechenden Fehlerfrequenzen im Vibrationsspektrum:

$$f_{v,ir} = 0,6 \cdot N_b \cdot f_r \text{ und} \\ f_{v,or} = 0,4 \cdot N_b \cdot f_r.$$

Bei f_r , f_s und N_b handelt es sich um die Dreh- und Versorgungsfrequenz sowie die Kugelanzahl eines Lagerelementes, welche aus Tabelle G.1 entnommen werden kann. In Tabelle G.2 sind die Fehlerfrequenzen für $m = -3$ bis $m = 3$ festgehalten.

Nach [RGPLCA⁺13] wird die Auswirkung einer Exzentrizität auf den Phasenstrom nach der Gleichung

$$f_{Ex} = f_s \cdot \left((m_{rt} \cdot R + m_d) \cdot \frac{1-s}{P} + m_{ws} \right) \quad (\text{G.1})$$

berechnet. Die Bedeutung und der Wert der Parameter R , P und s sind aus Tabelle G.1 zu entnehmen. Die Faktoren m_{rt} , m_d und m_{ws} sind Laufvariablen. In Tabelle G.3 sind die Frequenzen einer Exzentrizität für verschiedene Kombinationen berechnet.

Tabelle G.1.: Notation zur Berechnung der Fehlerfrequenzen

Notation	Beschreibung	Wert
f_r	Drehfrequenz	188 Hz
f_s	Versorgungsfrequenz	400 Hz
N_b	Anzahl Lagerkugeln	7
P	Anzahl Polpaare	2
R	Anzahl Läuferstäbe	29
s	Schlupf	$1 - \frac{P \cdot f_r}{f_s} = 0,06$

Tabelle G.2.: Fehlerfrequenzen im Phasenstrom infolge eines Außen- und Innenringschadens

m	1	-1	2	-2	3	-3
f_{IR} [Hz]	1189	389	1979	1179	2768	1968
f_{OR} [Hz]	926	126	1452	652	1979	1179

Tabelle G.3.: Fehlerfrequenzen im Phasenstrom infolge einer Exzentrizität des Rotors

m_{rt}	1	1	1	1	2	2	2	2
m_d	1	1	-1	-1	1	1	-1	-1
m_{ws}	1	-1	1	-1	1	-1	1	-1
f_{Ex} [Hz]	6040	5240	5664	4864	11492	10692	11116	10316

H Ausfallverhalten des Motors

In Abbildung H.1 ist das Ausfallverhalten des Motors mit drei Verteilungsformen modelliert. In Tabelle H.1 sind die quadratischen Mittelwerte der Fehler zwischen dem Ausfallverhalten und der jeweiligen Verteilungsform festgehalten. Diese zeigen, dass sich die Weibull- als auch die Log-Normalverteilung gleichermaßen zur Beschreibung des Ausfallverhaltens eignen.




Abbildung H.1.: Modellierung des Ausfallverhaltens mittels einer Weibull-, Exponential- und Log-Normalverteilung

Tabelle H.1.: Vergleich der Verteilungen zur Modellierung des Ausfallverhaltens

Verteilungsform	RMS Fehler [%]
Weibull	3,33
Exponential	6,15
Log-Normal	3,34



I Leistungskennwerte

Tabelle I.1.: Erzielte Kennwerte im Rahmen der Untersuchungen zur Prognosefähigkeit

Algorithmus	PH_M [-]	$MAPE_M$ [%]	FN_M [%]	FP_M [%]	MAD_M [h]	S [-]
Parameter δ_1	0,334	58,89	39,04	32,40	4,90	0,86
Parameter δ_2	0,372	48,23	33,98	31,79	5,89	0,91
Parameter δ_3	0,340	55,93	37,98	32,50	5,08	0,87
Parameter δ_4	0,375	48,07	33,14	31,28	5,89	0,92
Parameter δ_5	0,343	54,98	38,02	32,18	5,18	0,87
Parameter δ_6	0,385	48,08	31,01	30,80	6,10	0,94
Parameter δ_7	0,346	53,92	36,15	31,70	5,09	0,89
Parameter δ_8	0,387	45,86	30,42	29,92	6,10	0,96
Vergleichsalg. (PCA)	0,341	55,85	36,06	30,99	5,29	0,88

Tabelle I.2.: Erzielte Kennwerte im Rahmen der Untersuchungen zur Übertragbarkeit des Konzepts

Algorithmus	PH_M [-]	$MAPE_M$ [%]	FN_M [%]	FP_M [%]	MAD_M [h]	S [-]
Parameter δ_8 Sz. 1	0,387	45,86	30,42	29,92	6,10	0,95
Parameter δ_8 Sz. 2	0,395	43,77	29,75	29,80	6,08	0,97
Parameter δ_8 Sz. 3	0,399	44,37	29,88	29,51	6,11	0,97
Vergeichalg. Sz.1	0,341	55,85	36,06	30,99	5,29	0,88
Vergeichalg. Sz.2	0,349	53,02	35,34	30,19	5,27	0,90
Vergeichalg. Sz.3	0,350	52,85	34,90	30,10	5,29	0,91

Tabelle I.3.: Erzielte Kennwerte mit unterschiedlichen Klassifikatoren bei der Verwendung der Parameterkonstellation δ_8

Klassifikator	PH_M [-]	$MAPE_M$ [%]	FN_M [%]	FP_M [%]	MAD_M [h]	S [-]
Bayes	0,387	45,86	30,42	29,92	6,10	1,00
lineare Diskriminanzanalyse	0,386	46,85	30,69	30,36	6,12	0,99
quadratische Diskriminanzanalyse	0,386	46,73	30,81	30,26	6,11	0,99