

Forschungsberichte aus dem
wbk Institut für Produktionstechnik
Karlsruher Institut für Technologie (KIT)

M.Sc. Jonas Hillenbrand

**Unsupervised Condition-Monitoring für
Kugelgewindetriebe mittels Acoustic Emission**

Band 276

Forschungsberichte aus dem
wbk Institut für Produktionstechnik
Karlsruher Institut für Technologie (KIT)

Hrsg.: Prof. Dr.-Ing. Jürgen Fleischer
Prof. Dr.-Ing. Gisela Lanza
Prof. Dr.-Ing. habil. Volker Schulze
Prof. Dr.-Ing. Frederik Zanger

M.Sc. Jonas Hillenbrand

Unsupervised Condition-Monitoring für Kugelgewindetriebe mittels Acoustic Emission

Band 276

Unsupervised Condition-Monitoring für Kugelgewindetriebe mittels Acoustic Emission

Zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften (Dr.-Ing.)

von der KIT-Fakultät für Maschinenbau des
Karlsruher Instituts für Technologie (KIT)

angenommene

Dissertation

von

M.Sc. Jonas Hillenbrand

aus **Dielheim**

Tag der mündlichen Prüfung: **05.02.2024**
Hauptreferent: **Prof. Dr.-Ing. Jürgen Fleischer**
Korreferent: **Prof. Dr.-Ing. Alexander Verl**

Bibliografische Information der Deutschen Nationalbibliothek

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

Zugl.: Karlsruhe, Karlsruher Institut für Technologie, Diss., 2024

Copyright Shaker Verlag 2024

Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, vorbehalten.

Printed in Germany.

ISBN 978-3-8440-9485-5
ISSN 0724-4967

Shaker Verlag GmbH • Am Langen Graben 15a • 52353 Düren
Telefon: 02421 / 99 0 11 - 0 • Telefax: 02421 / 99 0 11 - 9
Internet: www.shaker.de • E-Mail: info@shaker.de

Vorwort des Herausgebers

Die schnelle und effiziente Umsetzung innovativer Technologien wird vor dem Hintergrund der Globalisierung der Wirtschaft der entscheidende Wirtschaftsfaktor für produzierende Unternehmen. Universitäten können als "Wertschöpfungspartner" einen wesentlichen Beitrag zur Wettbewerbsfähigkeit der Industrie leisten, indem sie wissenschaftliche Grundlagen sowie neue Methoden und Technologien erarbeiten und aktiv den Umsetzungsprozess in die praktische Anwendung unterstützen.

Vor diesem Hintergrund wird im Rahmen dieser Schriftenreihe über aktuelle Forschungsergebnisse des Instituts für Produktionstechnik (wbk) am Karlsruher Institut für Technologie (KIT) berichtet. Unsere Forschungsarbeiten beschäftigen sich sowohl mit der Leistungssteigerung von additiven und subtraktiven Fertigungsverfahren, den Produktionsanlagen und der Prozessautomatisierung sowie mit der ganzheitlichen Betrachtung und Optimierung der Produktionssysteme und -netzwerke. Hierbei werden jeweils technologische wie auch organisatorische Aspekte betrachtet.

Prof. Dr.-Ing. Jürgen Fleischer

Prof. Dr.-Ing. Gisela Lanza

Prof. Dr.-Ing. habil. Volker Schulze

Prof. Dr.-Ing. Frederik Zanger

„Die Wissenschaft ist eine wunderbare Sache, wenn man nicht seinen Lebensunterhalt damit verdienen muss.“ – Albert Einstein

Vorwort des Verfassers

Die vorliegende Dissertation entstand im Rahmen meiner Tätigkeit als akademischer Mitarbeiter am Institut für Produktionstechnik (wbk) des Karlsruher Instituts für Technologie (KIT).

Mein Dank gilt Herrn Prof. Dr.-Ing. Jürgen Fleischer für die Übernahme des Hauptreferats, die fachliche Betreuung und persönliche Förderung, welche ich in den fünf Jahren am Institut erfahren durfte. Herrn Prof.-Dr.-Ing. Verl danke ich für den wissenschaftlichen Austausch und die Übernahme des Korreferats sowie Herrn Prof. Dr.-Ing. Cichon für die Übernahme des Prüfungsvorsitzes. Dem gesamten Kollegium des wbk danke ich für die gemeinsam erlebte Zeit, den wissenschaftlichen Austausch und die Erfahrungen, die ich mit jedem am Institut teilen konnte. Insbesondere möchte ich hier vor allem meinen wissenschaftlichen *Mitstreitern* der Gruppe Werkzeugmaschinen und Mechatronik danken. Ebenso zum Dank verpflichtet bin ich den Mitarbeitern in Technik und Administration des wbk. Allen voran danke ich Friedbert Mathes für seine unersetzliche Hilfe im Bereich Kugelgewindtrieb und Anne-Sophie Rossol für ihre tatkräftige Unterstützung in allen Bereichen des Institutslebens und darüber hinaus. Ein Dank gilt auch meinen Studenten, die ich betreuen durfte und die zum Gelingen der Arbeit beigetragen haben: Danke an Zewei Lu, Jan Detroy, Dominique Zipperling, Gregor Osen, Jakob Kretschmer und Patrick Schaible. Ein besonderer Dank gilt ebenso drei Personen, die meine Zeit am Institut maßgeblich geprägt haben: Ich bedanke mich bei Dr.-Ing. Christopher Ehrmann für die Wegbereitung meiner Arbeit und die Inspiration für die Welt der Elektronik, bei Eduard Gerlitz für seine unkonventionelle Art und bei Philipp Gönzheimer in seiner Rolle als Kollege, Freund und Gruppenleiter.

Zu guter Letzt gilt mein größter Dank meiner Familie, ohne die diese Leistung gar nicht möglich gewesen wäre. Ich sage Danke für den jahrelangen Rückhalt und einen Ort der Geborgenheit. Ich danke daher allen voran meinen Eltern Petra und Willi Hillenbrand, meiner Freundin Anita und meiner Schwester Sophia mit Dominic und Tochter Carlotta.

Albstadt, 08. Februar 2024

Jonas Hillenbrand

Abstract

A component of major importance in the context of machine tool maintenance are ball screw drives (BSD). Although, BSD have been present for years in production equipment, they are still in focus for unplanned downtimes or unforeseen machine failures.

There is currently no theoretical calculation basis that describes the failure of the component accurately enough, taking into account all external and internal influences. In order to solve existing obstacles and problems in the monitoring of BSD, an acoustic emission (AE) sensor system is investigated and a suitable condition monitoring (CM) system is conceived and tested within the scope of this work. While current CM approaches are mostly based on supervised learning methods, this work focuses on the use of unsupervised methods. These can be used without a-priori knowledge and costly training.

The dissertation outlines the current state of the art and research in the context of CM systems for BSD. Based on the lack of adequate CM systems, a novel cluster model for detection of unknown or emerging component behavior is introduced. The system is implemented without an offline training phase, but able to learn the system's condition and detect anomalies during operation. In addition to enabling the sensor system, a particular focus is on automatic creation of CM systems without user intervention in order to enable low-effort and transferable systems.

The sensor system is evaluated on a variety of different operation and degradation scenarios. Considered defect mechanisms are fatigue, preload loss, debris and lack of lubrication. AE monitoring shows promising results for the detection for these defects. Combined with the CM system, validation experiments provide significant detection results and the general ability to adapt to a variety of datasets.

Kurzfassung

Ein wichtiges Bauteil im Rahmen der Instandhaltung von Werkzeugmaschinen sind Kugelgewindetriebe (KGT). Obwohl KGT seit Jahren in Produktionsanlagen vorhanden sind, stehen sie immer noch im Fokus für ungeplante Stillstände oder unvorhergesehene Maschinenausfälle.

Derzeit gibt es keine theoretische Berechnungsgrundlage, die den Ausfall des Bauteils unter Berücksichtigung aller äußeren und inneren Einflüsse genau genug beschreibt. Um die bestehenden Hindernisse und Probleme bei der Überwachung von KGT zu lösen, wird im Rahmen dieser Arbeit eine Acoustic Emission (AE) Sensorik untersucht und ein geeignetes Condition-Monitoring (CM) System konzipiert und getestet. Während aktuelle CM-Ansätze meist auf überwachten Lernmethoden basieren, liegt der Fokus dieser Arbeit auf dem Einsatz von unüberwachten Methoden. Diese können ohne Vorkenntnisse und aufwändiges Training eingesetzt werden.

Die Dissertation umreißt den aktuellen Stand der Technik und Forschung im Kontext von CM-Systemen für KGT. Basierend auf dem Mangel an adäquaten CM-Systemen wird ein neuartiges Clustermodell zur Erkennung von unbekanntem oder aufkommendem Komponentenverhalten vorgestellt. Das System wird ohne eine Offline-Trainingsphase implementiert, ist aber in der Lage, den Zustand des Systems zu erlernen und Anomalien während des Betriebs zu erkennen. Neben der Befähigung des Sensorsystems liegt ein besonderer Fokus auf der automatischen Erstellung von CM-Systemen ohne Benutzereingriff, um aufwandsarme und übertragbare Systeme zu ermöglichen.

Das Sensorsystem wird in verschiedenen Betriebs- und Defektszenarien evaluiert. Berücksichtigte Defektmechanismen sind Ermüdung, Vorspannungsverlust, Verschmutzung und Mangelschmierung. Die AE-Überwachung zeigt vielversprechende Ergebnisse für die Erkennung dieser Defekte. In Kombination mit dem CM-System liefern Validierungsexperimente signifikante Detektionsergebnisse und die allgemeine Fähigkeit, sich an eine Vielzahl von Datensätzen anzupassen.

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Formelzeichen	IV
Abkürzungen	VII
1 Einleitung	1
1.1 Motivation	2
1.2 Zielsetzung	4
1.3 Aufbau der Arbeit	5
2 Stand der Technik und Forschung	7
2.1 Grundlagen zu Kugelgewindetrieben	7
2.1.1 Kinematik des Kugelgewindetriebs	10
2.1.2 Verschleiß- und Schadensmechanismen im Kugelgewindetrieb	17
2.1.3 CM-Anwendungen für Kugelgewindetriebe	21
2.1.4 Schlussfolgerung zu CM-Systemen für Kugelgewindetriebe	24
2.2 Grundlagen zu Acoustic Emission	25
2.2.1 Messung von Acoustic Emission	26
2.2.2 Anwendungen der Acoustic Emission Messung	29
2.2.3 Schlussfolgerung für die Auswertung von AE am KGT	32
2.3 Unsupervised Learning für Condition-Monitoring	36
2.3.1 Unüberwachte Merkmalsextraktion	38
2.3.2 Grundlagen der Clusterbildung	41
2.3.3 Schlussfolgerung zum Einsatz von Unsupervised Learning im CM	46
2.4 Fazit für die Zielsetzung und Vorgehensweise der eigenen Arbeit	48
3 Eigener Ansatz	50
3.1 Vorgehensweise	52
3.2 Systemgrenzen und -definitionen	54
4 Anforderungsanalyse	58
4.1 Anforderungen an die Messkette	58

4.2	Anforderungen an die digitale Signalverarbeitung	59
4.3	Anforderungen an das Condition-Monitoring-System	60
5	Versuchsträger für die Untersuchung mit Acoustic Emission	63
5.1	Verwendete Acoustic Emission Messkette	63
5.2	1-Achs-Axiallager-Prüfstand	66
5.3	2-Achs-KGT-RZA-Prüfstand	67
5.4	5-Achs-Prüfstand	70
5.5	Aufbau und Integration der Messtechnik am Kugelgewindetrieb	71
6	Vorversuche zur Überwachung des Wälzkontakts	77
6.1	Untersuchung von Acoustic Emission Sensorelementen	77
6.2	Untersuchung am Beispiel des Axialwälzlagers	80
7	Entwicklung des Unsupervised Condition-Monitoring-Systems	86
7.1	Teilsystem Sensierung	89
7.2	Teilsystem Vorverarbeitung	90
7.3	Teilsystem Segmentierung	91
7.4	Teilsystem Merkmalsextraktion	96
7.4.1	Gegenüberstellung von Merkmalen einschließlich Rekonstruktionsfehler	97
7.4.2	Auto-Konfiguration von Autoencodern für die Anomaliedetektion	103
7.5	Teilsystem Clusterbildung	115
7.6	Teilsystem Cluster-Tracking	121
8	Validierung des Unsupervised Condition-Monitoring-Systems	132
8.1	Unsupervised Architekturvarianten	134
8.2	Untersuchung des Kugelgewindetriebs mit Acoustic Emission	137
8.3	Unsupervised Condition-Monitoring in den Validierungsexperimenten	149
8.3.1	Visualisierung des Cluster-Tracking-Prozesses im CM-System	151
8.3.2	Szenario 1 – Geschwindigkeitsstufen	155
8.3.3	Szenario 3 – Mangelschmierung	162
8.3.4	Szenario 4 – Partikeleinbringung	167
8.3.5	Szenario 6 – Vorspannungsstufen bei verschiedenen Drehzahlen	172

8.3.6	Detektionsgüte der Architekturvarianten für unterschiedliche Szenarien	179
8.4	Verbesserung der Segmentierung durch domänenbasierte Konfiguration	185
8.5	Übertragbarkeit der Anomalieerkennung auf andere Problemstellungen	188
8.5.1	Übertragbarkeit des CM-Systems am Beispiel Axiallager	189
8.5.2	Übertragbarkeit des CM-Systems am Beispiel Motorstrom und Temperatur	192
9	Bewertung	195
9.1	Bewertung von Acoustic Emission zur Diagnose von Wälzkontakten	195
9.2	Bewertung der Unsupervised Strategie	197
9.2.1	Bewertung der Autoencoder für Anomalie- und Zustandserkennung	201
9.2.2	Bewertung des Cluster-Boundary-Trackings	202
9.3	Beantwortung der Forschungsfragen	203
10	Zusammenfassung	206
	Literaturverzeichnis	I
	Abbildungsverzeichnis	XXIII
	Tabellenverzeichnis	XXX
	Anhang	XXXI
	Veröffentlichungen des Autors	I

Formelzeichen

Formelzeichen	Größe	Einheit
α	Kontaktwinkel	°
b_j^L	Bias-Vektor für Schicht L eines Neuronalen Netzes	-
$\{b_i\}_j$	Menge an Boundary-Punkten in einem Clustering	-
b_{res}	Bit-Tiefe eines Signals	-
β, λ	Regularisierungskonstanten in der Kostenfunktion eines Neuronalen Netzes	-
c	Wellengeschwindigkeit in einem Medium	m/s
C_{dyn}	Dynamische Tragzahl eines Kugelgewindetriebs	N
C_k	Clustering (Partitionierung) k eines Datensatzes	-
d_i	Verweildauer in einem Zustand i , alternativ: Verwendung als Abstand	-
D_i	Datensatz zum Zeitpunkt t_i	-
D_w	Kugeldurchmesser	mm
D_{pw}	Kugelmittkreis-/Teilkreisdurchmesser	mm
D_{rc}	Hilfsabstand zwischen Rückführbohrungen	mm
E^t	System (en. <i>entity</i>) zum Zeitpunkt t	-
ε	Hyperparameter Epsilon des DBSCAN-Algorithmus	-
F	Kraftwert	N
f	Frequenz	Hz
$f_{b,k}$	Kugeleintrittsfrequenz für Komponente k (mit k : Spindel s , Mutter n , Kugelmittkreis pw oder $2P$ bzw. $4P$ für die Kontaktart)	Hz
$f_{b,t}$	Frequenz, mit der eine Kugel einmal durch den KGT rollt	Hz
$f_{m,i}$	Merkmalsvektor, mit m Merkmalen und i Datenpunkten	-
f_{res}	Frequenzauflösung	Hz
f_s	Spindeldrehzahl, optional n_s in 1/min	Hz

Formelzeichen	Größe	Einheit
f_{sr}	Abtastrate (en. <i>sample rate</i>)	Hz
g	Verstärkungsfaktor	-
h_h	Höhe der Helixlaufbahn	mm
h^L	Aktivierungsfunktion für Schicht L eines Neuronalen Netzes	-
i	Anzahl der Umläufe (im Kugelgewindetrieb)	-
λ	Wellenlänge	mm
$l_{b,t}$	Gesamtstrecke der Kugelkette im Kugelgewindetrieb	mm
l_h	Länge der Helixkurve	mm
l_{pw}	Laufbahnlänge der Kugelgewindetrieb-Helix, optional mit Index für die Komponente: $l_{pw,n}$ oder $l_{pw,s}$	mm
$l_{rc,1}$	Länge der Kugelumlenkcurve	mm
$l_{rc,2}$	Länge der Kugelrückführung	mm
N_L	Anzahl an Neuronen in einer Schicht L	-
N_H	Anzahl an versteckten Neuronen im Hidden Layer eines Neuronalen Netzwerks	-
N_f	Anzahl an Hauptfrequenzen in einem Spektrum	-
ω	Winkelgeschwindigkeit	rad/s
Ω	Regularisierungsterm der Kostenfunktion von Neuronalen Netzen, optional mit Index Ω^i	-
$p_{i,j}$	Häufigkeit einer Zustandsänderung von Zustand i zu j	-
P_h	Steigung der Kugelgewindetrieb-Helix (Schraubenlinie)	mm
φ	Steigungswinkel des Kugelgewindetriebs am Flankendurchmesser	°
ρ_i	Dichte eines Clusters	-
S_i^t	Zustand i zum Zeitpunkt t	-
$t_{b,t}$	Verweildauer einer Kugel in der Kugelkette	s
$t_{d,s}$	Zeitdauer beim Überrollen eines Defekts auf der Spindel	s

Formelzeichen	Größe	Einheit
t_{pw}	Verweildauer einer Kugel im Umlauf	s
τ	Grenzwert, optional mit Index τ_i	-
$v_{b,k}$	Geschwindigkeit eines Punkts auf Komponente k (mit k : Spindel s , Mutter n , Kugelmittlenkreis pw)	mm/s
v_f	Vorschubgeschwindigkeit	mm/s
V_i	Größe bzw. Volumen eines Clusters	-
w	Fenstergröße (Segmentierung)	-
W^L_{ij}	Gewichte für Schicht L eines Neuronalen Netzes	-
x_i	Inputvektor (eines Neuronalen Netzes) bzw. Messwerte eines Rohdatenstreams	-
X_i	Menge an Objekten (Samples) zum Zeitpunkt i	-
\hat{x}_i	Rekonstruktion eines Vektors x_i	-
y_i	Outputvektor (eines Neuronalen Netzes)	-
z_i	Anzahl der Kugeln pro Umlauf	-
z_j	Merkmalsvektor der versteckten Schicht im Autoencoder	-

Abkürzungen

Abkürzung	Bedeutung
ADC	en. <i>analog digital converter</i> , Analog-Digital-Wandler
AE	en. <i>acoustic emission</i> , Körperschallemissionen
AEN	Autoencoder-Netzwerk (en. <i>autoencoder network</i>)
API	en. <i>application programming interface</i> , Programmierschnittstelle
AutoML	en. <i>automated machine learning</i> , Automatisiertes Maschinelles Lernen
BNC	Stecker-Verbindung, benannt nach den Entwicklern, <i>Bayonet Neill Concelman</i>
BSD	En. <i>ball screw drive</i> , Kugelgewindetrieb
CF	Crest-Faktor, skalares Merkmal eines Vektors (siehe Anhang A 14)
CM	en. <i>condition monitoring</i> , Zustandsüberwachung
CSV	en. <i>comma-separated values</i> , Bezeichnung eines Dateiformats
DMS	Dehnmessstreifen
DSP	en. <i>digital signal processing</i> , digitale Signalverarbeitung
EE	Envelope-Energy, Zeitdomänenmerkmal der Einhüllenden des Signals (siehe Anhang A 14)
EMV	Elektromagnetische Verträglichkeit
FF	Form-Faktor, skalares Merkmal eines Vektors (siehe Anhang A 14)
FFT	Fast-Fourier-Transformation
KGT	Kugelgewindetrieb
KU	Kurtosis, skalares Merkmal eines Vektors (siehe Anhang A 14)
MAF	Margin-Faktor, skalares Merkmal eines Vektors (siehe Anhang A 14)
MF	Mean-Frequency, skalares Merkmal eines Frequenzspektrums (siehe Anhang A 14)
ML	Maschinelles Lernen
MSE	Mean-Squared-Error, Fehlersumme der Kostenfunktion für Autoencoder
NN	Neuronales Netz

Abkürzung	Bedeutung
PF	Peak-Faktor, skalares Merkmal eines Vektors (siehe Anhang A 14)
PM	en. <i>predictive maintenance</i> , vorbeugende Instandhaltung
P2P	Peak-2-Peak-Faktor, skalares Merkmal eines Vektors (siehe Anhang A 14)
RMS	Root-Mean-Square-Merkmal, skalares Merkmal eines Vektors (siehe Anhang A 14)
RZA	Ritzel-Zahnstangen-Antrieb
WZM	Werkzeugmaschine

1 Einleitung

Intensive Automatisierung und Digitalisierung in heutigen Fabriken haben die Bedeutung von Kapital als Produktionsfaktor erhöht. Steigende Investitionen in neue, leistungsfähigere Maschinen und Anlagen statt menschlicher Arbeitskraft vergrößern den Bedarf nach passenden Instandhaltungslösungen, um die Vermögenswerte zu schützen und zu erhalten. Die Instandhaltung muss hier neue Anforderungen je nach Verfügbarkeit, Zuverlässigkeit und Flexibilität der Anlagen erfüllen (März 2017). Neue Anwendungen aus dem Bereich Condition-Monitoring (CM), d. h. Zustandsüberwachung, und Predictive Maintenance (PM), vorausschauende Instandhaltung, sollen diesen Ansprüchen gerecht werden (Niu 2017; Moriarty 2015). Um CM und darauf aufbauend PM zu ermöglichen, setzen moderne Instandhaltungssysteme auf maschinelles Lernen und andere Data-Mining-Techniken. Diese Methoden werden eingesetzt, um die steigende Komplexität, die zunehmende Menge an verfügbaren Daten und den Bedarf an Automatisierung in diesen Systemen zu stemmen. CM und PM gehören daher zu den vielversprechendsten Anwendungsfeldern für maschinelles Lernen im Produktionskontext. Auf dem Weg zu einer smarten, effizienten und nachhaltigen Produktion bekommen sie entsprechend viel Aufmerksamkeit im Bereich der Forschung (Cioffi et al. 2020).

Bislang benötigt die erfolgreiche Umsetzung von CM und PM jedoch viel Expertenwissen und Software-Knowhow. Ob es um die Entscheidung geht, wie und wann eingegriffen wird, um die Kennzeichnung von gesammelten Daten (en. *labelling*), das Festlegen von Grenzwerten für Anomalieerkennung oder um die Auswahl von Merkmalen in den Rohdaten – menschliche Entscheidungsfindung und Erfahrung sind weiterhin unverzichtbar. Besonders in einem Kontext, in dem kein Vorwissen und keine historischen Daten über das System existieren, können überwachtes Lernen (en. *supervised learning*) und die Modellentwicklung sehr zeitintensiv und aufwendig sein. Hier stellt unüberwachtes Lernen (eng. *unsupervised learning*) eine Alternative zum Aufdecken von Struktur und nützlicher Information in unbekanntem Datensätzen (Celebi & Aydin 2016) dar.

Auch die Forschung im Bereich der Werkzeugmaschinen (WZM) befasst sich mit der Fragestellung der Autonomie von Anlagen und Maschinen. Der Lebenszyklus solcher Systeme kann, wie in Abbildung 1-1 dargestellt, beschrieben werden.

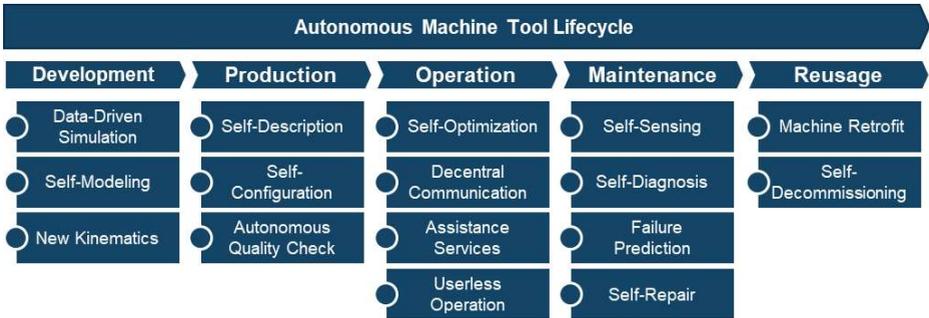


Abbildung 1-1: Autonome Funktionen im Lebenszyklus der Werkzeugmaschine, nach (Fleischer, Puchta & Gönninger 2021)

(Fleischer, Puchta & Gönninger 2021) unterscheiden hier fünf Phasen und zugehörige autonome Funktionen, die zum Erreichen von selbstständigeren und autonomeren Systemen, mit und ohne menschliche Beteiligung, führen. Zentrale Wegbereiter für die autonome (Werkzeug-)Maschine sind sogenannte *Self-X* Funktionen (Cohen & Singer 2021, S. 5). Im Bereich der Instandhaltung sind insbesondere die selbstständige Sensierung und Diagnose zu nennen (*Self-Sensing* und *Self-Diagnosis*). Diese Themen bilden den Rahmen der vorliegenden Arbeit.

1.1 Motivation

Eine Komponente, die im Kontext der Instandhaltung von Werkzeugmaschinen (WZM) besondere Beachtung findet, ist der Kugelgewindetrieb (KGT). Obwohl die Komponente bereits mehrere Jahrzehnte an Entwicklung und Auslegung erfahren hat, steht sie immer noch im Fokus der Instandhaltung für ungeplante Stillstände. Bisher existiert keine theoretische Berechnungsgrundlage, die den Ausfall der Komponente unter Berücksichtigung aller äußeren und inneren Einflüsse hinreichend genau beschreibt.

Betrachtet man Studien zu Ausfallverteilungen der Komponenten und deren Ausfallursachen (Schopp 2009; Wieser 2008), so ergibt sich besonders für KGT eine Notwendigkeit der Zustandsüberwachung. Der Studie zufolge sind in 38 Prozent der Fälle KGT für den Stillstand von Vorschubachsen in Werkzeugmaschinen verantwortlich. In der Verteilung der Ausfallursachen entfallen 30 Prozent der Ausfälle auf Verschleiß und vier Prozent auf Verschmutzung (siehe Abbildung 1-2). Wenn diese Einflüsse entsprechend frühzeitig detektiert werden, können Stillstandszeiten minimiert und Kosten gespart werden.

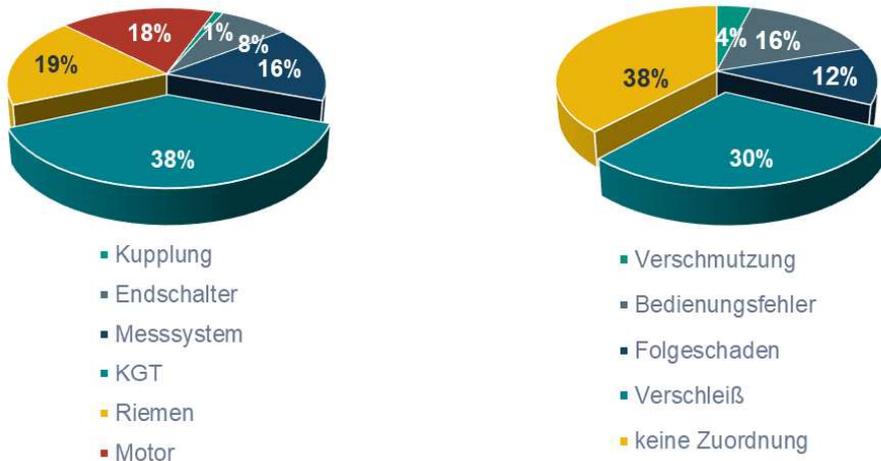


Abbildung 1-2: Aufteilung der Ausfälle nach Vorschubachsenkomponenten (links) und Verteilung der Ausfallursachen für Vorschubachsen (rechts) (Schopp 2009; Wieser 2008)

Aus diesem Grund entstanden eine Vielzahl von Forschungsarbeiten, die ein Zustandsüberwachungssystem vorschlagen, um die Degradation der Komponente zu diagnostizieren und ungeplanten Ausfällen vorzubeugen. Dabei weist der KGT viele sich überlagernde Ausfallmechanismen, zeitlich veränderliche Betriebsbedingungen und eine komplexe Kinematik auf (Li et al. 2020), die die Diagnose erschweren.

Der Einsatz von CM bietet gegenüber reaktiver als auch präventiver Instandhaltung einige Vorteile. So werden durch sicheres Zustandswissen und Schadensfrüherkennung planbare Instandhaltungsmaßnahmen, die Verkürzung von Stillstandszeiten und eine gezielte Optimierung möglich. Diese führen zur Reduzierung von Personal- und Planungskosten, die den Gewinn des eingesetzten Produktionskapitals steigert. Ein weiterer Aspekt ist die Sicherheit für Mensch und Maschine. Das frühzeitige Detektieren von Defekten vermeidet Folgeschäden und damit Schäden an Produktionsanlagen und die Gefährdung des Personals. Darüber hinaus können bei Kenntnis des aktuellen Zustandes Maschinen und Komponenten ohne Gefährdung bis an die Lebensdauerreserve betrieben werden. Es werden somit Ressourcen gespart und die Umwelt wird geschützt (GfM 2022).

Am Markt konnte sich jedoch bislang kein CM-System für den KGT etablieren. Es besteht weiterhin Bedarf an Systemen, die durch einfache Bedienung und Übertragbarkeit den breiten Einsatz von CM-Applikationen ermöglichen.

Im Rahmen dieser Arbeit wird hierzu die Applikation von breitbandigen Acoustic Emission (AE) Sensoren am KGT untersucht. Aufgrund der engen Verwandtheit von AE-Anregungsmechanismen und KGT-Schadensmechanismen birgt die Sensorik großes Potenzial bei der Diagnostik von KGT.

In Kombination mit unüberwachtem Lernen kann die Technologie dazu eingesetzt werden, den KGT unter Einwirkung unterschiedlichster Betriebs- und Schädigungsrandbedingungen zu diagnostizieren.

1.2 Zielsetzung

Um die vorliegenden Hindernisse und Problematiken bei der Überwachung von KGT zu lösen, soll im Rahmen dieser Arbeit ein AE-Sensorsystem untersucht und ein passendes CM-System konzeptionell erarbeitet und erprobt werden.

Das Sensorsystem wird dabei hinsichtlich seiner Eignung für die Detektion von Defekten sowie für die Sensibilität von Zustandsänderungen bewertet. Betrachtete Schadensmechanismen sind Laufbahnermüdung, Vorspannungsverlust, Verschmutzung und Mangelschmierung des KGT.

Während aktuelle CM-Ansätze meist auf überwachten Lernverfahren basieren, liegt der Fokus dieser Arbeit im Besonderen auf unüberwachten Verfahren. Diese können ohne Vorwissen und aufwendiges Training eingesetzt werden. Der Ansatz beinhaltet zudem Automatismen zur Konfiguration und Parametrierung der verwendeten Signalverarbeitung. Mittels datengetriebener Verfahren und Komponentenwissen über den KGT wird dem Anwender ein sich selbst konfigurierendes CM-System zur Verfügung gestellt.

Die Konzeption eines neuartigen Clustermodells und Ansätze aus dem Bereich des Cluster-Trackings sollen dazu verwendet werden, um unbekanntes oder neu auftretendes Komponentenverhalten zu detektieren. Das System wird ohne Offline-Trainingsphase implementiert. Es erlernt Zustände und detektiert Anomalien während des Betriebes. Neben der Befähigung des Sensorsystems für KGT liegt daher ein besonderer Fokus auf der automatischen Erstellung von CM-Systemen ohne Eingriff durch Benutzer, um aufwandsarme und übertragbare CM-Systeme zu ermöglichen.

1.3 Aufbau der Arbeit

Die vorliegende Arbeit unterteilt sich in nachfolgende Kapitel, die hier beschrieben werden und in Abbildung 1-3 grafisch dargestellt sind.

Nach der Einleitung in Kapitel 1 werden zur Zusammenfassung des bisherigen Standes der Technik und Forschung in Kapitel 2 drei Themenfelder aufgegriffen. Dazu gehören die Grundlagen zur Komponente KGT, mit besonderem Augenmerk auf Kinematik, Ausfallverhalten und existierende Verfahren zur Zustandsüberwachung in Abschnitt 2.1. Im nächsten Abschnitt wird die AE-Technologie vorgestellt. Das Kapitel zum Stand des Wissens schließt mit relevanten Themen aus dem Bereich des Unsupervised Learning in Abschnitt 2.3. Hierbei wird auf die automatisierte Merkmalsextraktion und Clusterbildung eingegangen. Die jeweiligen Unterabschnitte zu den Grundlagenthemen enthalten Schlussfolgerungen, weisen auf Forschungsdefizite hin und beschreiben den Handlungsbedarf für die vorliegende Arbeit.

Kapitel 3 stellt schließlich den eigenen Ansatz vor. Hier werden die Problem- und Zielstellung präzisiert und es wird eine Vorgehensweise zur Lösung präsentiert. Abschnitt 3.2 legt die Systemgrenzen für die Arbeit fest.

Die Ergebnispräsentation beginnt mit der Ausarbeitung der Anforderungsanalyse in Kapitel 4. Darauf folgt die Vorstellung der verwendeten Versuchsträger für die Arbeit. In Kapitel 5 werden hierzu die AE-Messkette und verschiedene Prüfstände vorgestellt. Das Kapitel endet mit der Vorstellung des Einbaus der Sensorik für KGT in Abschnitt 5.5.

Zur Charakterisierung und Potenzialbewertung der Messtechnik werden in Kapitel 6 Versuchsergebnisse zur Charakterisierung der Sensorelemente und die Applikation an Axialkugellagern in Form von Vorversuchen präsentiert.

Das gesamte Kapitel 7 beschäftigt sich mit der automatisierten Signalverarbeitung für das CM-System. Unterteilt wird das Kapitel in die Abschnitte Sensierung, Vorverarbeitung, Segmentierung, Merkmalsextraktion, Clusterbildung und Cluster-Tracking.

Nach der Vorstellung des CM-Systems wird dieses in Kapitel 8 der experimentellen Validierung unterzogen. Das Ergebniskapitel schließt mit der Betrachtung von weiteren Datenquellen und Systemen zur Übertragbarkeit des neuen Ansatzes.

1	Einleitung		
	Zielsetzung	Motivation	Aufbau
2	Stand der Technik und Forschung		
	Kugelgewindetribe	Acoustic Emission	Unsupervised Learning
3	Eigener Ansatz		
4	Anforderungsanalyse		
5	Versuchsträger		
6	Vorversuche		
7	Entwicklung des Unsupervised CM-Systems		
8	Validierung des Unsupervised CM-Systems		
9	Bewertung		
10	Zusammenfassung		

Abbildung 1-3: Kapitelaufbau dieser Arbeit

In Kapitel 9 werden die erlangten Erkenntnisse und Entwicklungen bewertet. Dieses Kapitel ist in drei Abschnitte untergliedert. Zuerst wird die Eignung der Messtechnik für den Einsatz am KGT (Abschnitt 9.1) diskutiert. Danach folgt die Beurteilung des vorgeschlagenen CM-Systems und im Abschnitt 9.3 die Beantwortung der im Kapitel 3 (eigener Ansatz) aufgestellten Forschungsfragen.

Die Arbeit wird schließlich in Kapitel 10 resümiert und umfasst einen Ausblick auf weiterführende Forschungsthemen im Kontext automatisierter Zustandsüberwachungssysteme.

2 Stand der Technik und Forschung

In den folgenden Abschnitten werden relevante Grundlagen zum KGT, AE und Unsupervised Learning im Kontext von CM vorgestellt. Es werden verschiedene Themenbereiche, die der Verständlichkeit des eigenen Ansatzes dienen, eingeführt und die jeweiligen Forschungsstände präsentiert sowie hinsichtlich aktueller Defizite analysiert.

2.1 Grundlagen zu Kugelgewindetrieben

Der Kugelgewindetrieb, seltener auch als Kugelrollspindel bezeichnet, ist der Hauptvertreter von linearen Vorschubachsen in Werkzeugmaschinen (WZM). Er gehört zur Gattung der Schraubgetriebe und wird außer in WZM auch in Bereichen der Luftfahrt, der Medizintechnik und in automobilen Anwendungen eingesetzt. Seine Aufgabe ist die Wandlung einer Rotationsbewegung in eine Linearbewegung (oder umgekehrt). Im Einsatz als Vorschubachse zeichnet sich der KGT insbesondere durch folgende Eigenschaften aus (Brecher & Weck 2017):

- hoher Wirkungsgrad,
- keine Stick-Slip-Effekte,
- Spielfreiheit (bei Verwendung von vorgespannten Systemen),
- hohe Steifigkeit.

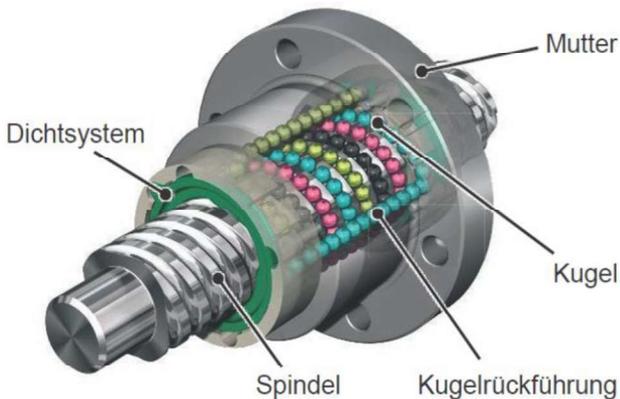


Abbildung 2-1: Aufbau eines Kugelgewindetriebs (Brecher 2022, S. 84)

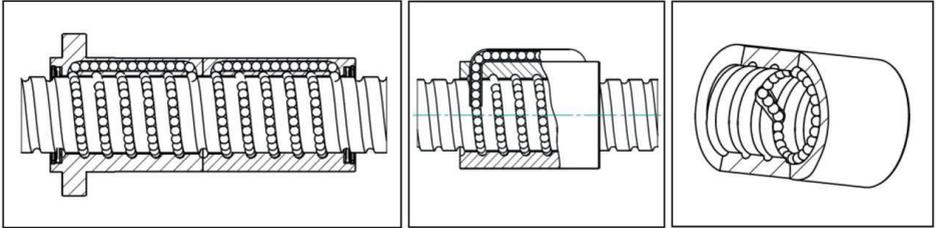


Abbildung 2-2: Umlenkung mit interner Gesamtumlenkung (links), externer Gesamtumlenkung (Mitte) und Einzelgangumlenkung (rechts) (Weck & Brecher 2006)

Um die Schraubkinematik zu realisieren, besteht das System aus einer Spindel (Gewinde), einer Mutter, Kugeln und einem Kugelrückführsystem. Dieser Aufbau ist in Abbildung 2-1 dargestellt. Um einen möglichst hohen Wirkungsgrad zu erreichen, werden beim KGT Kugeln als Wälzkörper zwischen den Gewindegängen der Spindel und der Mutter eingesetzt. Durch die Wälzkörper und eine entsprechende Schmierung kann die Reibung drastisch gesenkt werden, sodass im Idealfall lediglich Rollreibung vorliegt. Zum Schutz gegen Kontamination des Laufbahnkontakts werden Dichtsysteme an den Enden des KGT verwendet. Um eine kontinuierliche Bewegung zu realisieren, müssen die Wälzkörper nach Erreichen des Endes der Helix in der Mutter wieder zurückgeführt werden. Dies geschieht mit Kugelrückführsystemen. Nach dem Stand der Technik sind hierzu drei gängige Systeme bekannt. Es handelt sich um die in Abbildung 2-2 dargestellte Gesamtumlenkung (interne und externe Ausführung) und die Einzelgangumlenkung.

Eine Besonderheit des KGT ist seine Spielfreiheit, was ihn besonders als hochgenaue Positionierachse für die Werkzeugmaschine qualifiziert. Um diese Spielfreiheit zu erreichen, ist eine hohe Steifigkeit erforderlich, die bei KGT durch die Vorspannung des Systems realisiert wird. Konstruktiv wird ein vorgespanntes KGT-System über folgende Varianten erreicht: Prinzipiell kann unterschieden werden in zweiteilige Müttern (sogenannte Doppelmüttern), wobei durch Einbau von Distanzelementen zwischen den beiden Hälften eine Vorspannung erreicht wird, und in Einzelmüttern, die durch Gestaltung der Kugellaufbahn bzw. des Kugelübermaßes ihre Vorspannung erhalten. Beispiele hierfür sind in Abbildung 2-3 dargestellt: Einzelmutter mit Kugelübermaß (a), Doppelmutter mit Distanzstück (b), Einzelmutter mit Teilungsversatz (c), Pitch-Shift-Mutter (d) und federvorgespannte Mutter (e).

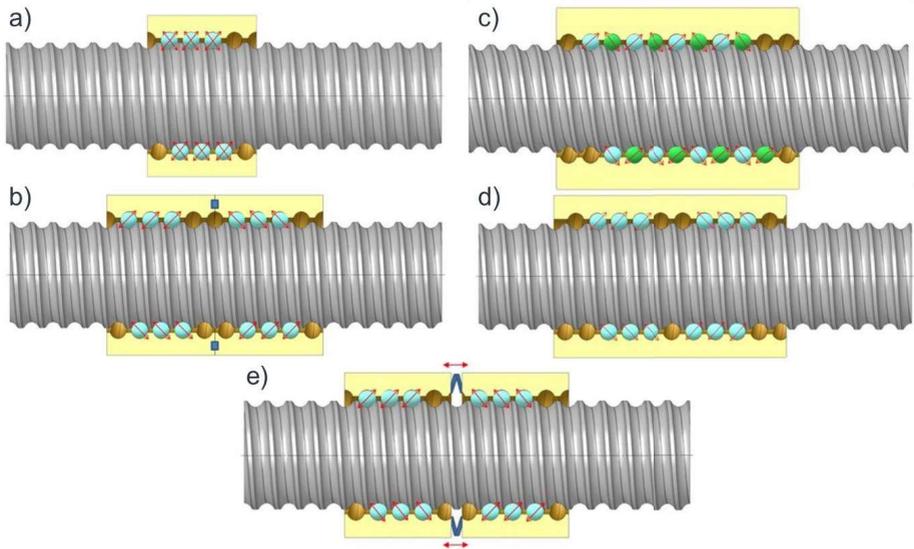


Abbildung 2-3: Vorspannungsarten und KGT-Bauformen, nach (August Steinmeyer GmbH & Co. KG 2021)

Je nach Bauform stellen sich im Wälzkontakt unterschiedliche Kontaktverhältnisse ein. Nach dem Stand der Technik sind drei Formen der Wälzkontaktausführung dokumentiert: 2-, 3- und 4-Punkt-Kontakt. Diese sind schematisch in Abbildung 2-4 dargestellt. Der Wälzkontakt ist damit bestimmend für die Kinematik und bedingt maßgeblich das Verschleißverhalten des KGT.

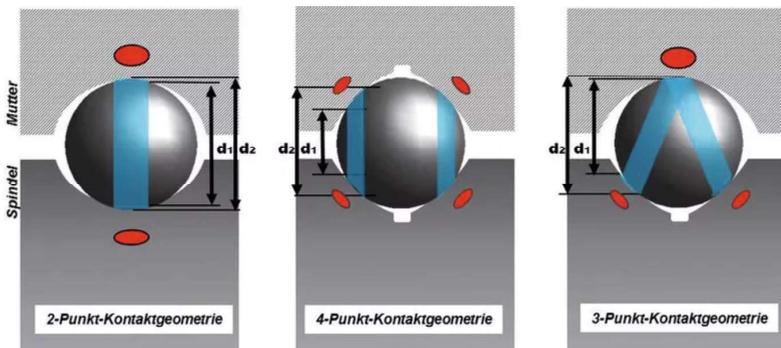


Abbildung 2-4: Verschiedene Kontaktgeometrien im Wälzkontakt des Kugelgewindetriebs (Hoyer & Drescher 2013)

2.1.1 Kinematik des Kugelgewindetriebs

Im Folgenden werden die für die Arbeit relevanten geometrischen Größen und Beziehungen innerhalb KGT-Kinematik eingeführt. Größen, die sich auf die jeweilige Komponente beziehen, werden mit dem entsprechenden Index versehen (Mutter: n [en. *nut*], Kugel: b [en. *ball*] und Spindel: s [en. *spindle*]).

Die Kinematik des KGT basiert auf einer schrauben- bzw. helixförmigen Bewegung der Wälzkörper zwischen der Spindel- und Mutterlaufbahn. Durch Ausführung der Bewegung findet durch die Wälzkörper zwischen den Laufbahnen eine Umwandlung der rotatorischen in eine Linearbewegung statt. In der Komponente überlagern sich daher im Betrieb verschiedene Rotations- und Linearbewegungen, die nachfolgend beschrieben werden.

Die Spindel führt bei Bewegung der Vorschubachse eine Rotation mit Drehzahl f_s aus. Für die Vorschubgeschwindigkeit v_f der Linearachse ergibt sich in Abhängigkeit der Spindeldrehzahl f_s und Steigung P_h folgender Zusammenhang (Brecher & Weck 2017):

$$v_f = f_s \cdot P_h \quad 2-1$$

Durch Rotation der Spindel werden die Wälzkörper innerhalb der Mutter in eine helixförmige Wälzbewegung versetzt, die sich aus Roll-, Gleit- und Bohranteilen zusammensetzt. Dabei sind die entstehenden Gleit- und Rollanteile geschwindigkeits- und lastabhängig (Wei & Lin 2003).

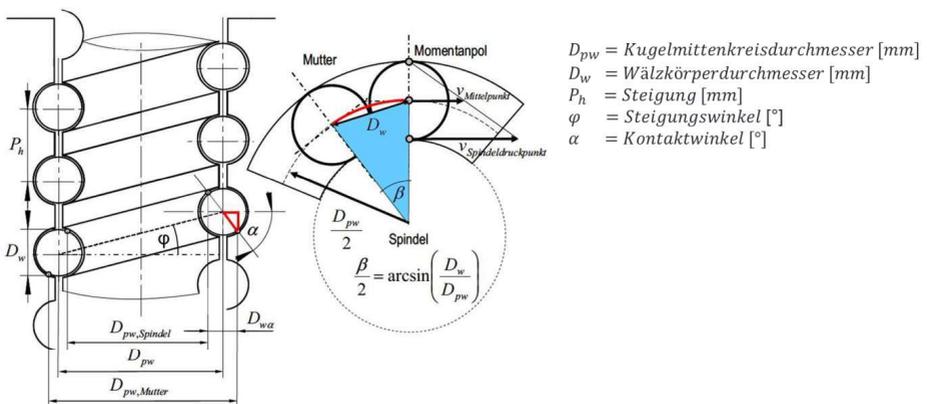


Abbildung 2-5: Geometrische Größen am Kugelgewindetrieb nach DIN ISO 3408-1 (Walther 2011)

Für die nachstehenden Formeln wird Schlupf, d. h. Gleiten im Wälzkontakt, vernachlässigt. Da die Formeln nur zur Herleitung der kinematischen Frequenzen verwendet werden, ist diese Vereinfachung hinreichend genau. Im Kontext dieser Arbeit werden unter kinematischen Frequenzen jene Frequenzen verstanden, die auf die Vorschubbewegung des Mehrkörpersystems KGT zurückzuführen sind.

Um die kinematischen Frequenzen des KGT herzuleiten, wird der Momentanpol in der Mutter in Abbildung 2-5 betrachtet (Walther 2011). Die Geschwindigkeit eines Punktes auf einer Kreisbahn mit Radius r bzw. Durchmesser D ergibt sich mit der Winkelgeschwindigkeit ω bzw. Drehfrequenz f allgemein zu:

$$v = \omega \cdot r = \pi \cdot f \cdot D \quad 2-2$$

Im KGT entstehen für den Kugelmittelpunkt mit dem Maß D_{pw} und den Kontaktpunkten von Kugel mit Spindel (Index s) und Mutter (Index n) nach Pythagoras folgende Laufbahnlängen pro Umlauf:

$$l_{pw} = \sqrt{(\pi \cdot D_{pw})^2 + P_h^2} \quad 2-3$$

$$l_{pw,n} = \sqrt{(\pi \cdot (D_{pw} + D_w \cdot \cos \alpha))^2 + P_h^2} \quad 2-4$$

$$l_{pw,s} = \sqrt{(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha))^2 + P_h^2} \quad 2-5$$

Damit ergibt sich für den Kontaktpunkt auf der Spindel folgende Geschwindigkeit entlang der Bahn:

$$v_{b,s} = f_s \cdot \sqrt{(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha))^2 + P_h^2} \quad 2-6$$

Aus dem Strahlensatz folgt für die Kugelmittelpunktgeschwindigkeit $v_{b,pw}$ anhand Abbildung 2-5:

$$v_{b,pw} = \frac{1}{2} \cdot f_s \cdot \sqrt{(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha))^2 + P_h^2} \quad 2-7$$

Die Eintrittsfrequenz der Kugeln in die Umlenkung lässt sich nun bestimmen als der Kehrwert der Zeitdauer, die eine Kugel im Umlauf (Kugelmittelenkreisbahn l_{pw}) verweilt, multipliziert mit der Anzahl an Kugeln z_i in einem Umlauf.

$$t_{pw} = \frac{l_{pw}}{v_{b,pw}} = \frac{\sqrt{(\pi \cdot D_{pw})^2 + P_h^2}}{\frac{1}{2} f_s \cdot \sqrt{(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha))^2 + P_h^2}} \quad 2-8$$

$$Z_i = \frac{2 \cdot \pi}{\beta} = \frac{\pi}{\sin^{-1}\left(\frac{D_w}{D_{pw}}\right)}$$

Damit liefert Formel 2-9 die Kugleintrittsfrequenz $f_{b,pw}$:

$$f_{b,pw} = \frac{1}{t_{pw}} \cdot Z_i = \frac{1}{2} \cdot f_s \cdot \frac{\sqrt{(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha))^2 + P_h^2}}{\sqrt{(\pi \cdot D_{pw})^2 + P_h^2}} \cdot \frac{\pi}{\sin^{-1}\left(\frac{D_w}{D_{pw}}\right)} \quad 2-9$$

Von weiterem Interesse kann auch die Betrachtung aus Sicht eines fixen Beobachters im Mutter- oder Spindelsystem sein.

$$f_{b,s} = \frac{v_{b,pw}}{l_{pw,s}} \cdot Z_i = \frac{1}{2} \cdot f_s \cdot \frac{\pi}{\sin^{-1}\left(\frac{D_w}{D_{pw}}\right)} \quad 2-10$$

$$f_{b,n} = \frac{v_{b,pw}}{l_{pw,n}} \cdot Z_i = \frac{1}{2} \cdot f_s \cdot \frac{\sqrt{(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha))^2 + P_h^2}}{\sqrt{(\pi \cdot (D_{pw} + D_w \cdot \cos \alpha))^2 + P_h^2}} \cdot \frac{\pi}{\sin^{-1}\left(\frac{D_w}{D_{pw}}\right)} \quad 2-11$$

Die Frequenz $f_{b,s}$ bezeichnet die Häufigkeit, mit der Kugeln an einem Beobachter auf der Spindellaufbahn vorbeifahren, und $f_{b,n}$ entspricht der Häufigkeit für einen Beobachter auf der Mutterlaufbahn. Während der Abrollbewegung rotieren die Kugeln mit der Drehfrequenz f_b um die senkrechte Achse zur Kontaktlinie der Kontaktpunkte in Spindel und Mutter und des Tangentenvektors der Helixlaufbahn. Zur Berechnung der Drehfrequenz der Kugel muss zwischen dem 2-Punkt- und 4-Punkt-Kontakt des KGT unterschieden werden. In Abbildung 2-6 sind die geometrischen Kontaktverhältnisse für die beiden Kontaktformen dargestellt.

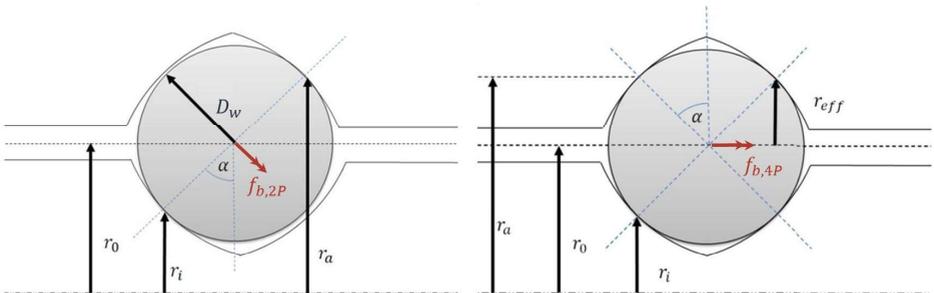


Abbildung 2-6: Kontaktverhältnisse (2-Punkt-Kontakt links, 4-Punkt-Kontakt rechts), nach (Maier 2013)

Für den 2-Punkt-Kontakt folgt die Drehfrequenz $f_{b,2P}$:

$$f_{b,2P} = \frac{v_{b,pw}}{\pi \cdot D_w} = \frac{1}{2\pi} \cdot \frac{f_s}{D_w} \cdot \sqrt{\left(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha)\right)^2 + P_h^2} \quad 2-12$$

Beim 4-Punkt-Kontakt rollt die Kugel auf einer Laufbahn auf der Mutter bzw. Spindel ab, die durch den Radius r_{eff} beschrieben wird. Es folgt:

$$f_{b,4P} = \frac{v_{b,pw}}{2\pi \cdot r_{eff}} = \frac{1}{2\pi} \cdot \frac{f_s}{D_w \cdot \cos \alpha} \cdot \sqrt{\left(\pi \cdot (D_{pw} - D_w \cdot \cos \alpha)\right)^2 + P_h^2} \quad 2-13$$

mit $r_{eff} = \frac{D_w}{2} \cos \alpha$

Eine Betrachtung, die in diesem Rahmen noch nicht stattgefunden hat, ist die Frequenz $f_{b,t}$ (mit t für total), mit der eine Kugel den gesamten KGT einmal durchläuft (inklusive Rückführung). Interessant ist diese Frequenz für die Ortung eines Kugeldefektes, um ihn der jeweiligen Einzelkugel zuordnen zu können.

Zunächst ist für die Berechnung die Gesamtstrecke zu ermitteln, die eine Kugel während des Durchlaufens der Komponente zurücklegt. Diese setzt sich wie folgt zusammen:

$$l_{b,t} = l_h + 2 \cdot l_{rc,1} + l_{rc,2}$$

mit l_h : Länge der Helixbahn,

$l_{rc,1}$: Länge der Kurve des Kugelumlenkstücks,

$l_{rc,2}$: Länge des Rückführkanals

2-14

Für die Bestimmung der gesamten Kugelstrecke gibt es keine allgemeingültige Formel, die für alle KGT-Bauformen gilt, da sie abhängig von der Art der Rückführung ist (siehe Abbildung 2-2) und die konstruktive Gestaltung der Kugelumlenkung individuell auf Basis der Erfahrung von Herstellern geschieht. In der vorliegenden Arbeit wird im Folgenden nur die interne Gesamtumlenkung betrachtet. Eine repräsentative Anordnung der Kugelumläufe und Rückführung ist in Abbildung 2-7 dargestellt. Im Folgenden wird anhand dieser Geometrie die Ermittlung der Gesamtstrecke einer Einzelkugel durch die Komponente hergeleitet (Größen, die einer Annäherung oder Annahme unterliegen oder herstellerabhängig sein können, werden mit * gekennzeichnet). Das globale $\{x, y, z\}$ -Koordinatensystem folgt der Konvention, dass die z -Achse in Richtung der Spindellängsachse, die x -Achse in Richtung des Kugelumlenkkanals und die y -Achse vertikal nach oben ausgerichtet ist (siehe Abbildung 2-8).

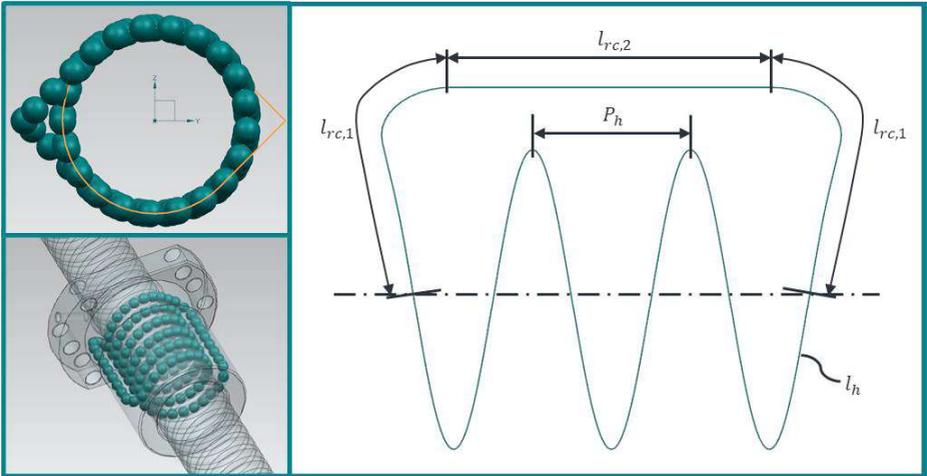


Abbildung 2-7: Kugelumlauf in Drahtansicht eines KGT und Helixbahn der Umläufe

Die Länge der Helixkurve l_h kann über

$$l_h = \left(i - \frac{1}{4}\right) \cdot l_{pw} \quad 2-15$$

bestimmt werden. Als allgemeine Annäherung für die Bahnkurve zur Umlenkung werden folgende Annahmen getroffen, die auf Basis der Inspektion verschiedener Geometrien von Herstellern entstanden:

- Zwischen dem Eintrittspunkt P_E^* und Austrittspunkt P_A^* auf der Helixbahn liegt ein Winkel von 90° (daher der Term $\frac{1}{4} \cong \frac{90^\circ}{360^\circ}$ in Formel 2-15).
- Dem blau markierten Bahnabschnitt (zwischen P_E^* und P_A^*) werden tangentielle Übergangsbedingungen zugrunde gelegt. Damit wird eine stetige Kurvenkrümmung sichergestellt.
- Die Länge a_{rc}^* als horizontaler Versatz (in Richtung z' -Achse) wird mit einem Wert $a_{rc}^* = D_W$ angenommen.

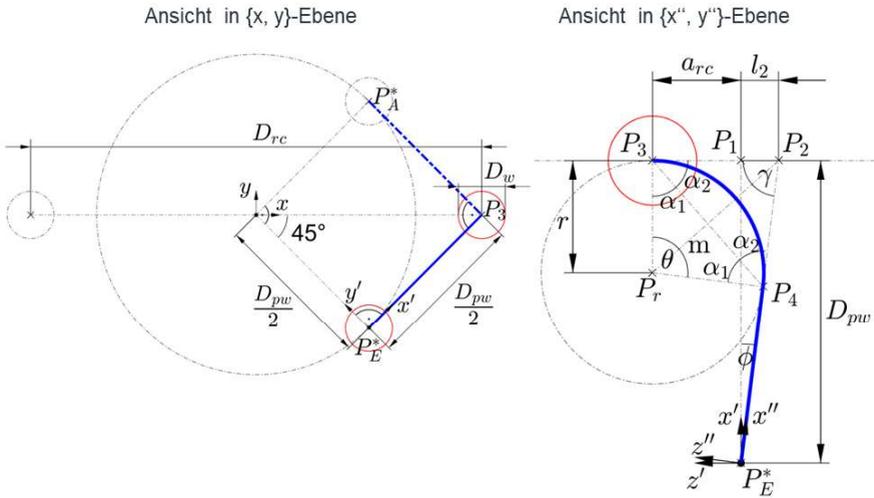


Abbildung 2-8: Geometrische Zusammenhänge der Kugelrückführung

In den Skizzen von Abbildung 2-8 entspricht die blau markierte Strecke $l_{rc,1}$. Gemäß den Skizzen können folgende Geometriezusammenhänge abgeleitet werden:

$$D_{rc} = 2 \cdot D_{pw} \cdot \cos 45^\circ$$

$$\gamma = 90^\circ - \varphi$$

$$l_2 = \frac{D_{pw}}{2} \cdot \tan \varphi$$

$$\alpha_2 = \frac{180^\circ - \gamma}{2}$$

$$\alpha_1 = 90^\circ - \alpha_2$$

$$\theta = 180^\circ - 2 \cdot \alpha_1$$

$$m = 2 \cdot (a_{rc}^* + l_2) \cdot \cos \alpha_2$$

$$r = \frac{m}{2} \cdot \cos \alpha_1$$

2-16

Punkt P_4 folgt als Kombination aus dem Ortsvektor zu P_3 und einem Verschiebungsvektor auf Basis der definierten Winkel im $\{x', y', z'\}$ -Koordinatensystem zu:

$$\vec{P}_4 = \vec{P}_3 + \begin{bmatrix} m \cdot \cos \alpha_2 \\ -m \cdot \sin \alpha_2 \\ 0 \end{bmatrix} = \begin{bmatrix} -a_{rc}^* + m \cdot \cos \alpha_2 \\ \frac{D_{pw}}{2} - m \cdot \sin \alpha_2 \\ 0 \end{bmatrix}$$

2-17

Die Gesamtlänge der blauen Kurve $l_{rc,1}$ entspricht dann der Strecke zwischen P_E^* und P_4 und dem Kreisbogenstück zwischen P_4 und P_3 .

$$l_{rc,1} = \|\overline{P_4}\| + r \cdot \frac{\theta}{180^\circ} \pi = \sqrt{(m \cdot \cos \alpha_2 - a_{rc}^*)^2 + \left(\frac{D_{pw}}{2} - m \cdot \sin \alpha_2\right)^2} + r \cdot \frac{\theta}{180^\circ} \pi \quad 2-18$$

Als weitere Größe ist die Länge des geraden Rückführkanals $l_{rc,2}$ zu berechnen. Sie entspricht der Höhe der Helixlaufbahn h_h abzüglich zweimal des Anteils a_{rc}^* .

$$\begin{aligned} l_{rc,2} &= h_h - 2 \cdot a_{rc}^* \\ h_h &= \left(i - \frac{1}{4}\right) \cdot P_h \end{aligned} \quad 2-19$$

Damit kann nun die Zeit berechnet werden, die eine Kugel braucht, um einmal durch den KGT zu laufen. Es folgt

$$t_{b,t} = \frac{l_{b,t}}{v_{b,pw}} \quad 2-20$$

bzw. die zugehörige Einzelkugelumlauffrequenz

$$f_{b,t} = \frac{1}{t_{b,t}} \quad 2-21$$

Bei der Beobachtung dieser kinematischen Frequenz muss beachtet werden, dass sie von der Spindeldrehzahl f_{sp} abhängt und von der Drehrichtung der Spindel. Kommt es zur Richtungsumkehr, bevor die betrachtete Kugel einmal durch die gesamte Komponente gelaufen ist, ist die Ermittlung dieser Frequenz hinfällig. Die Frequenz $f_{b,t}$ kann deshalb nur für langhubige Bewegungen mit konstanter Spindeldrehzahl f_{sp} beobachtet werden.

Eine weitere Einschränkung der Genauigkeit entsteht durch den Kugelfüllgrad, der montagebedingt nicht immer 100 Prozent entspricht. So unterliegen alle kinematischen Frequenzen einer weiteren Abweichung in Abhängigkeit des Füllgrades des KGT.

Die Formelzusammenhänge der obigen Formeln für die unterschiedlichen Frequenzen gelten nur unter der Annahme reinen Rollens. Diese Annahme wird in realen KGT durch den natürlichen Schlupf aufgrund von Last- und Fertigungseinflüssen verletzt. Die tatsächlich entstehenden Frequenzen werden daher von überlagerten Gleit- und Bohrbewegungen der Kugeln beeinflusst (Spath et al. 1995). Die rechnerisch auftretenden Frequenzen (zum Beispiel Kugelumlauffrequenz $f_{b,pw}$) können jedoch hinreichend genau im Betrieb durch den Einsatz von Dehnmessstreifen (DMS) an der Mutter detektiert werden (Veith et al. 2020).

Die Bestimmung von Frequenzen aufgrund der Kinematik von KGT wurde bereits in anderen Arbeiten untersucht. (Wei & Lin 2003) leiten in ihrer Arbeit die kinematischen und kinetischen Beziehungen für den KGT unter Berücksichtigung von Deformation und Schlupf her. (Schopp 2009) und (Lee et al. 2015) untersuchen die Kugelumlauffrequenz als Defektfrequenz zur Diagnose von Vibrationsdaten. Von (Ismail, Balaban & Spangenberg 2016) wurden Ausfallursachen und deren Zusammenhänge mit der Kugelumlauffrequenz untersucht, um diese durch Überwachung mit Schwingungssensorik zu detektieren.

2.1.2 Verschleiß- und Schadensmechanismen im Kugelgewindetrieb

In (DIN ISO 3408-5) wird die normative Auslegungsgrundlage von KGT beschrieben. Sie ist angelehnt an die Auslegung der kinematisch ähnlichen Wälzlager in (ISO 281). Als Einsatzgrenze wird in diesen Normen der Ermüdungverschleiß herangezogen. Aufgrund seiner Schraubkinematik und der zugrunde liegenden komplexen Wälzkörperbewegung wird der KGT jedoch einer Vielzahl von weiteren Verschleiß- und Schädigungsmechanismen ausgesetzt. In zahlreichen Forschungsarbeiten wird deshalb die aktuelle theoretische Lebensdauerberechnung kritisiert. Im Fokus der Kritik stehen vereinfachende Annahmen für die Lastverteilung zwischen Mutter und Spindel, ein konstantes Lastniveau (Münzing 2017) und die fehlende Beurteilung der Dauerfestigkeit der Laufbahnabschnitte (Hilmer 1978). Darüber hinaus können Betriebsbedingungen und Einflüsse aus der Montageart nicht über die Norm abgebildet werden. Betrachtet man die zahlreichen Einflüsse auf den Verschleiß und die Lebensdauer des KGT, wie sie in der Übersicht in Abbildung 2-9 abgebildet werden, so kommen auch (Jarosch 2008) und (Yagmur 2014) zum Schluss, dass die theoretische Berechnung viele Aspekte und Verschleißmechanismen nicht berücksichtigt. Außerdem liegt kein allgemeingültig definiertes Abbruchkriterium vor, das die Lebensdauer bzw. ein Betriebsende des KGT terminiert.

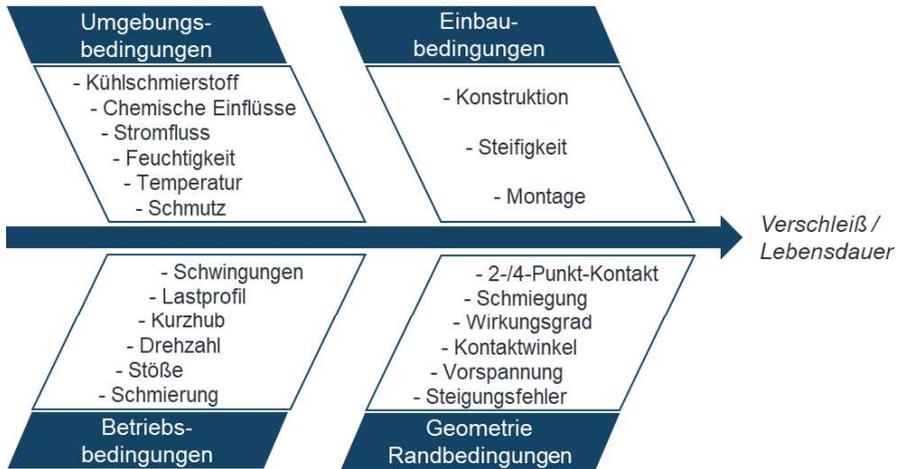


Abbildung 2-9: Einflüsse auf den Verschleiß von KGT, adaptiert nach (Bosch Rexroth AG 2006)

Die Vielfalt von Belastungskollektiven und Verschleißmechanismen, denen der KGT ausgesetzt ist, wurde bereits in anderen Forschungsarbeiten untersucht. Eine grundlegende Arbeit zu Ausfallszenarios für KGT lieferte (Haberkern 1998). Er unterschied drei Ausfallmechanismen für die Komponente: den langsamen Spätausfall, den langsamen Vorspannungsverlust und den plötzlichen Frühausfall. In seiner Arbeit weist er diesen Schadensformen die zugrunde liegenden Verschleißmechanismen, Bewegungsformen und betroffenen Komponenten zu (vgl. Abbildung 2-10). Die Untersuchungsergebnisse griff (Münzing 2017) in seiner Arbeit auf und ergänzte sie um eine Bewertung hinsichtlich der Auslegbarkeit bzw. Detektierbarkeit der Schadensformen.

Teil-system	Bewegungsform	Schadensmechanismus	Schadensform	Bewertung	
Tragender Kugel-Laufbahn Kontakt	Unvermeidbare Wechselbeanspruchung der Oberflächen durch Überrollung	Ermüdung	Zerrüttung der Oberflächen	Langsamer Spätausfall - Verklemmen - Gewaltbruch	berechenbar für rotierende Systeme, detektierbar
	Unvermeidbare Gleitanteile durch Bohrbewegung, Mikro- und Makroschlupf	Adhäsion und Abrasion	Durchmesserabnahme der Kugeln	Langsamer Vorspannungsverlust Abnahme der Steifigkeit, Zunahme des Umkehrspiels	Nicht bzw. teilweise berechenbar, detektierbar
	Unvermeidbare „Läppbewegung“ durch Regelkreisschwingung				
Umlenk- und Rückführsystem	Unvermeidbare Gleitanteile durch fehlende Wälzbewegung	Abrasion und Adhäsion	Aufweitung der Führungskontur durch Materialabtrag	plötzlicher Frühausfall	nicht berechenbar, abhängig von Werk- und Schmierstoffen
	Vermeidbares Schaben an Kanten, wenn Übergänge un stetig ausgeführt				
	Vermeidbarer Aufprall der Kugeln mit ihrer kin. Energie, wenn keine permanente Führung	Plastische Verformung	Aufweitung der Führungskontur durch Verformung	Unruhiger Lauf Verklemmen Gewaltbruch	nicht berechenbar, konstruktive Herausforderung bzw. Belastungsszenario nicht ausreichend genau bekannt
	Vermeidbares Verklemmen von Kugeln, wenn Führungskontur zu weit				

Abbildung 2-10: Schadensmechanismen und Schadensformen, nach (Münzing 2017; Haberkern 1998)

Beide Autoren kommen zum Schluss, dass nur der Ermüdungsverschleiß durch Oberflächenzerrüttung hinreichend genau berechenbar ist. Weitere Verschleiß- bzw. Ausfallinflüsse müssen durch eine entsprechende Diagnostik im Betrieb festgestellt werden.

Diese Darstellung lässt sich um die zugrunde liegenden Schadensursachen und Schadensbilder ergänzen. Ausgehend von den vier klassischen Verschleißmechanismen Abrasion, Adhäsion, Oberflächenzerüttung und tribochemische Reaktion ergibt sich der Zusammenhang in Abbildung 2-11. Genauere Details zu den wirksamen Schadensmechanismen finden sich in (Sommer, Heinz & Schöfer 2014, S.16ff). Setzt man Verschleißursachen und Schadensbilder in Relation, ergeben sich eine Vielzahl an überlagerten Abhängigkeiten.

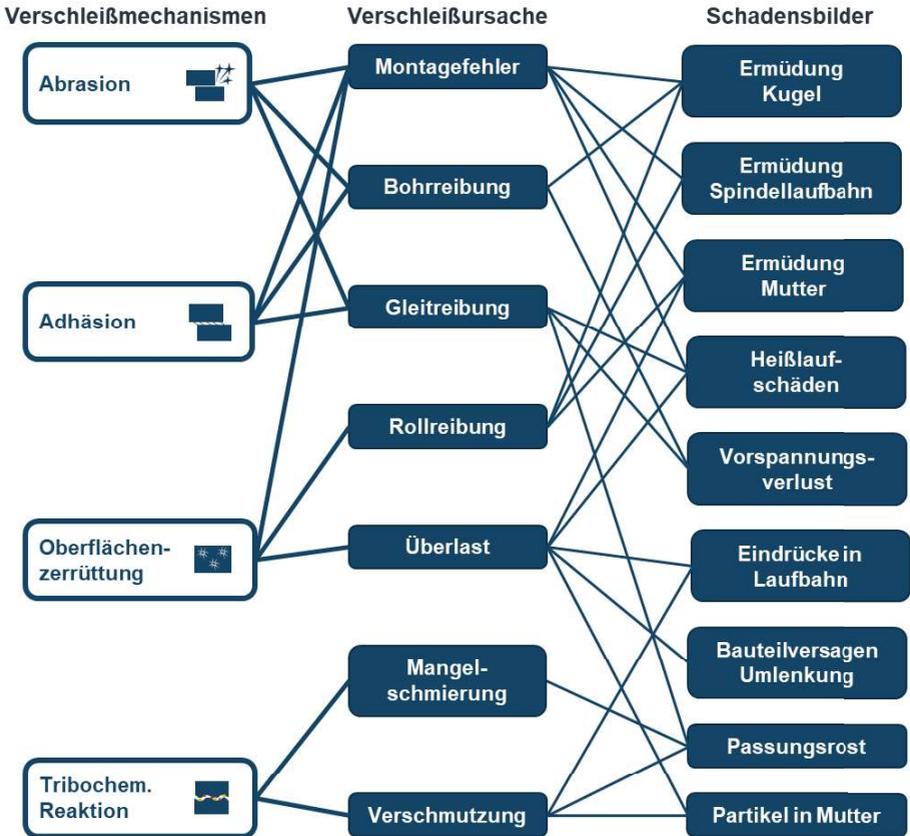


Abbildung 2-11: Schadensursachen und Schadensbilder am KGT, eigene Darstellung nach (Haberker 1998) und (Böge 2017, S. 511–512)

Aufgrund der engen Kopplung der verschiedenen Ursachen und Verschleißmechanismen kann die Entstehung von Schadensbildern nicht losgelöst voneinander betrachtet werden. Die große Anzahl an Einflüssen auf die Lebensdauer, die unterschiedlichen und zeitgleich wirkenden Verschleißmechanismen führen in der Praxis häufig zu Unterschieden zwischen der theoretisch erwarteten Lebensdauer und der tatsächlich erreichten Betriebsdauer. Eine zuverlässige Feststellung des realen Betriebszustands und daraus abgeleitet eine belastbare Prognose der Lebensdauerreserve sind daher essenziell für die Instandhaltung von KGT.

Im nachfolgenden Abschnitt werden hierzu die CM-Ansätze aus der industriellen Praxis und Forschung vorgestellt, die den Verschleißzustand des KGT erfassen.

2.1.3 CM-Anwendungen für Kugelgewindetriebe

Laut (ISO 13372) gilt für Condition-Monitoring folgende Definition:

DEFINITION 1. Condition-Monitoring

Erfassung und Verarbeitung von Informationen und Daten, die den Zustand einer Maschine über die Zeit anzeigen (übersetzt aus dem Englischen nach (ISO 13372))

Ein CM-System bezeichnet im Rahmen dieser Arbeit daher ein System, inklusive Software und Hardware, das die Aufgabe hat, alle notwendigen Funktionen zur Ausführung von CM an einer Maschine (dem betrachteten Objekt) zur Verfügung zu stellen.

In diesem Kontext bezeichnen die Begriffe *offline* und *online*, wann die Konfiguration, die Parametrierung oder das Training des CM-Systems stattfinden kann bzw. muss. Mit *offline* wird beschrieben, dass diese Einstellungen vor dem Betrieb des CM-Systems vorgenommen werden müssen. *Online* hingegen beschreibt die Fähigkeit des CM-Systems, diese Einstellungen während des regulären Betriebs stattfinden zu lassen (meist ohne menschliche Hilfe).

Folgende Gründe sprechen für die Notwendigkeit von CM für KGT:

- **Ausfallverteilung und -ursachen von KGT:**

Die normative und theoretische Auslegung der Komponente KGT ist nicht vollständig hinsichtlich der Beschreibung des Verschleißes. Die Vielzahl der Einflüsse und Randbedingungen erschweren eine geschlossene mathematische Beschreibung des Verschleißfortschritts. Mangels der Definition von allgemeingültigen Verschleiß- oder Ausfallkriterien lassen sich diese auch nicht mit einem einheitlichen System überwachen. Zudem ist eine a-priori-Auslegungsrechnung nur durch Schätzung des zukünftigen Lastprofils möglich, dies ist meist unbekannt, unsicherheitsbehaftet und kann stark von der Auslegung abweichen (Münzing 2017).

- **Geringe Ersatzteillagerhaltung:**

Die Ersatzteillagerung kann gegenüber einer reaktiven oder vorbeugenden Instandhaltungsstrategie geringer ausfallen. Die Zustandsüberwachung kann hierzu Auskunft über den aktuellen Verschleißzustand des KGT liefern. Reparatur- und Ersatzteile können dann zeitgerecht neu beschafft und kurzfristig gelagert werden. Dies verringert die Kapitalbindung und Lagerkosten (GfM 2022).

- **Beschaffung von Echtzeit-Daten und Informationen über den Betrieb von KGT (Erkenntnisgewinn):**

Um eine ausreichend hohe Signalgüte und relevante Signalinformationen zu erhalten, ist die unmittelbare Anbringung der Sensortechnik an den Wirkstellen der überwachten Systeme von Bedeutung. Das komplexe Ausfallverhalten von KGT mit Informationen zu beschreiben, die von bereits installierten Systemen in WZM stammen (beispielsweise Motorstrom, Schleppfehler o. ä.), ist meist mit einer hohen Ungenauigkeit verbunden. Sensorsysteme, die direkt oder indirekt eine Ausfallursache oder deren Wirkung überwachen, können eine höhere Aussagefähigkeit und Robustheit erreichen (Hennrich 2013).

In Tabelle 2-1 werden CM-Systeme aus dem Stand der Technik und Forschung aufgelistet, die repräsentativ für in der Literatur existierende sensorbasierte Ansätze stehen. Die Systeme werden unterschieden in indirekte und direkte Verschleißdetektion.

Direkte Verfahren erfassen unmittelbar ein konkretes Schadensmerkmal oder eine Systemfunktion wie die Vorspannung. (Möhring & Bertram 2012) ermöglichen dies beispielsweise durch Installation eines piezo-basierten Kraftsensors zwischen zwei Doppelmutterhälften, um den Verlust der Vorspannung zu detektieren. Ein System für die Anwendung in Einzelmuttern wurde von der (August Steinmeyer GmbH & Co. KG 2017) unter dem Markennamen *GuardPlus* entwickelt. Hierbei handelt es sich um die Vorspannungsmessung mit Dehnmessstreifen (DMS) durch Integration eines Sensorsystems direkt in die KGT-Mutter. Aufbau und Funktion werden im Patent (Kathan 2017) und von der (August Steinmeyer GmbH & Co. KG 2017) beschrieben.

Einen neuen Ansatz für die Betrachtung des Komponentenverschleißes am KGT liefert (Schlagenhauf et al. 2019) durch den Einsatz der bildbasierten Detektion von Defekten auf der Spindeloberfläche. Mit einer Kameraeinheit an der KGT-Mutter wird durch maschinelles Lernen die Entstehung von Laufbahnschäden detektiert, lokalisiert und deren Wachstum prognostiziert. Damit steht ein visuelles Inspektionssystem zur Verfügung, das vor allem als Retrofit-Lösung zur Detektion von Ermüdungsschäden dient. Prinzipbedingt liegt jedoch eine Einschränkung auf Schäden der Spindeloberfläche vor.

Mit der Kategorie indirekt wird der Umstand beschrieben, dass nicht direkt ein Schadensbild bzw. eine Systemfunktion gemessen werden, sondern ein Merkmal detektiert wird, das mit dem Verschleiß in Verbindung steht. Lösungen in diesem Bereich sind Systeme mit Schwingungs- und AE-Sensoren. In den recherchierten Arbeiten mit

Vibrationssensorik werden die Sensordaten auf Abweichung von einer Referenzgröße oder das Entstehen von Defektfrequenzen untersucht (Schopp 2009). Eine weitere Möglichkeit bietet sich durch die aufwendige Bestimmung von modalen Parametern mit Hilfe von Beschleunigungssensorik. Die Überwachung dieser Parameter über die Zeit kann Aufschluss über die Degradation der Komponente liefern (Benker, Kleinwort & Zah 2019).

Der Stand der Forschung weist bereits erste Arbeiten auf, die sich mit der Anwendung von AE am KGT befassen. Eine Unterscheidung von AE und konventionellen Beschleunigungssensoren wird in Abschnitt 2.2 vorgenommen. (D'Emilia et al. 2018) und (Nurudeen Alegeh et al. 2020) untersuchten die Verschleißdetektion am KGT mittels hochfrequentem Körperschall bis zu 500 kHz. Beide verwendeten Supervised Learning Ansätze, um ihre mit Labels versehenen Datensätze zu klassifizieren. Dabei gehen beide Arbeiten von bereits bekannten Defektzuständen aus. (Nurudeen Alegeh et al. 2020) unterscheidet hierbei einen nicht weiter beschriebenen Verschleißzustand und den Normalzustand. Es werden somit nur zwei statische Zustände miteinander verglichen. (D'Emilia et al. 2018) hingegen erzeugt die Defekte am KGT künstlich mit Hilfe von Bohrungen auf der Spindellaufbahn. Für real auftretende und zeitliche fortschreitende Schäden am KGT sind dies starke Einschränkungen, wodurch diese Ansätze nur bedingt in reale Anwendungen übertragen werden können und nur für Fälle mit vorhandenen Trainingsdaten umsetzbar sind.

Tabelle 2-1: Übersicht vorhandener CM-Ansätze für KGT

Kategorie	Überwachungsgröße	Quelle	Bewertung
indirekt	Antriebsdaten für kumulative Lastermittlung	(Huf 2012)	- beschränkt auf die Betrachtung der theoretischen Lebensdauer
indirekt	Vibrationssensor für Laufunruhe (20 kHz)	(Schopp 2009)	- intervallbasierte Auswertung, keine kontinuierliche Überwachung - Referenzfahrt notwendig - nur sensitiv für langsamen Spätausfall
indirekt	Beschleunigungssensor für modale Schwingungsparameter (20 kHz)	(Benker, Kleinwort & Zah 2019)	- aufwendige Bestimmung der modalen Parameter in Referenzfahrt
indirekt	Merkmalsextraktion mit AE-Sensor für künstliche Spindelschäden und reale Schäden an Lagerung (500 kHz)	(D'Emilia et al. 2018)	- reale Schäden am KGT wurden nicht untersucht - Signalverarbeitung mit aufwendigem Supervised Learning Verfahren
indirekt	AE-Sensor für Frequenzspektrum des AE-Signals (100-450 kHz)	(Nurudeen Alegeh et al. 2020)	- bislang nur direkter Vergleich zweier KGT mit und ohne Verschleißmerkmale
direkt	Piezokraft- und Temperatur-Sensor für Vorspannung	(Möhring & Bertram 2012)	- nur in Doppelmutter verwendbar
direkt	integrierter DMS-Sensor zur Vorspannungsüberwachung in Einzelmutter	(August Steinmeyer GmbH & Co. KG 2017)	- auf Überwachung der Vorspannung begrenzt - Referenzfahrt notwendig
direkt	Bildbasierte Detektion von Pittingdefekten auf Spindellaufbahn	(Schlagenhauf et al. 2019)	- Defekterkennung auf sichtbare Spindeloberfläche begrenzt

2.1.4 Schlussfolgerung zu CM-Systemen für Kugelgewindetriebe

Für aktuelle CM-Systeme basierend auf dem Stand der Forschung und Technik ergeben sich prinzipbedingte Einschränkungen. Die Verfahren sind meist auf eine Ausfallursache oder deren Wirkung beschränkt. Bekanntermaßen überlagern sich jedoch Vielzahlige Ausfallmechanismen beim Betrieb des KGT und seiner Degradation (siehe 2.1.2).

Im Speziellen müssen für CM-Anwendungen Auswertesysteme und -verfahren zur Verfügung gestellt werden, die trotz sich ändernder Randbedingungen und langen Betrachtungszeiträumen robust und aussagefähig sind. Diese Kriterien werden aktuell nur durch aufwendig parametrisierte Modelle, einen hohen Aufwand an a-priori-Training oder die Kombination einer Vielzahl an verschiedenen Sensorsystemen erreicht. Um den Anwender hier stärker zu unterstützen, Kosten für die zu installierenden

Sensorsysteme zu reduzieren und einen breiteren Einsatz zu ermöglichen, müssen neue CM-Systeme entwickelt werden.

Daher besteht weiterhin ein Bedarf an CM-Systemen, inklusive Sensorsystem und Auswertung, die trotz unbekannter Lastprofile und komplexer Ausfallmechanismen in der Lage sind, den Zustand von KGT richtig zu diagnostizieren.

Abgeleitet aus dem Stand der Technik und im Kontext erster Arbeiten, die sich mit AE am KGT befassen, stellt AE, verknüpft mit einem geeigneten Auswerteverfahren, ein potenzialträchtiges CM-Verfahren dar.

2.2 Grundlagen zu Acoustic Emission

Der Inhalt dieses Kapitels beschreibt die Grundlagen der Entstehung, Aufzeichnung und Auswertung von Acoustic Emission (AE) Signalen. Zunächst wird der Begriff AE erklärt. Übersetzt aus der Normschrift (ISO 22096) lautet er wie folgt:

DEFINITION 2. Acoustic Emission (AE)

AE beschreibt eine Reihe von Phänomenen, die aufgrund schneller Freisetzung von Energie innerhalb lokalisierter Quellen oder auf der Oberfläche von Material zur Entstehung von struktur- und flüssigkeitsgebundenen Ausbreitungswellen führen.

Typischerweise fällt der Frequenzbereich von detektierten AE-Signalen in den Bereich zwischen 20 kHz und 1 MHz und unterscheidet sich damit von herkömmlichen Schwingungs- und Beschleunigungssensoren, die nur einige kHz abdecken.

(ISO 22096)

In der deutschen Literatur werden häufig die Begriffe Körperschall und Acoustic Emission synonym verwendet. In dieser Arbeit steht der Begriff AE explizit für emittierten Körperschall im mehrstelligen kHz-Bereich und lässt sich damit abgrenzen von gebräuchlichen Beschleunigungs- und Vibrationssensoren, die eine Bandbreite von 5 bis 20 kHz aufweisen.

Eine weitere Unterscheidung zwischen Beschleunigungssensoren und AE-Sensoren lässt sich über die Art der Signalquelle treffen. Beschleunigungssensoren wie auch Modalanalyse-Equipment befassen sich mit der Erfassung von Starrkörperbeschleunigungen (Unwuchten, Überschwinger etc.) oder Schwingungsmoden und deren Eigenfrequenzen. Mit AE-Sensoren werden hingegen Körperschallquellen innerhalb eines Materials oder zwischen den Kontaktflächen zweier Körper detektiert.

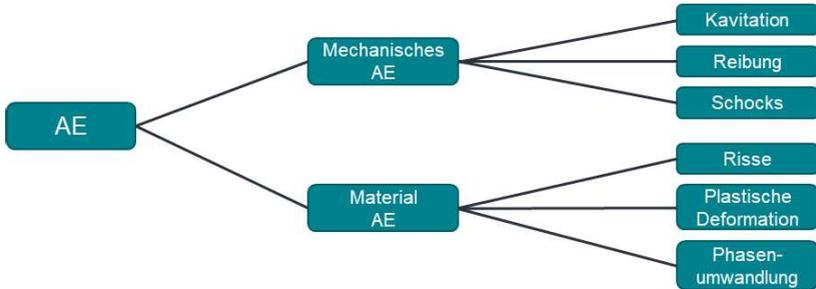
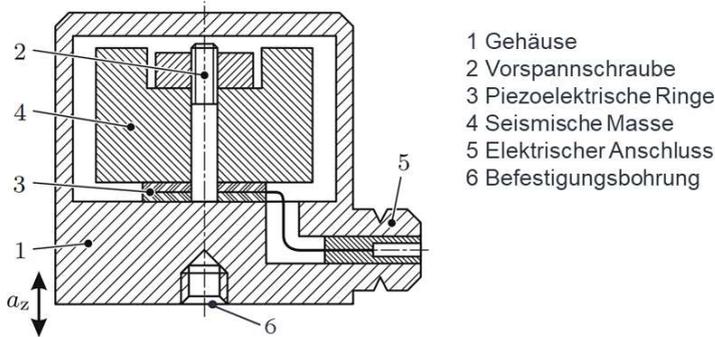


Abbildung 2-12: Anregungsmechanismen von AE, nach (Muravin 2009; Schäfer 2013)

Die Ursachen für die Entstehung von AE sind hierbei vielfältig und können allgemein in Material- und mechanisches AE unterschieden werden. Mechanisches AE bezeichnet Emissionen, die aufgrund der Interaktion zweier Körper oder Körper mit einem Fluid entstehen. Material-AE hingegen meint Phänomene, die innerhalb eines Körpers bzw. Materials ausgelöst werden. Zwar kann der Auslöser von Material-AE extern sein (Beispiel: Druck- oder Temperatureinwirkung auf Körper), die Emissionsquelle liegt jedoch innerhalb des Materials. In diesen Kategorien lassen sich die Quellen weiter verfeinern: Anregung durch Kavitation, Schocks und Reibung durch mechanische Effekte. Im Material kann AE entstehen durch Risse, plastische Deformation und auf mikroskopischer Ebene durch Versetzungsbewegungen, Zwillingsbildung und Phasenumwandlung (Muravin 2009; Schäfer 2013, S. 25). Die Untergliederung kann Abbildung 2-12 entnommen werden.

2.2.1 Messung von Acoustic Emission

Im Bereich technischer Anwendungen, im Besonderen der AE-Messung, haben sich piezoelektrische Sensoren etabliert. Der piezoelektrische Effekt wurde 1880 von den Brüdern Pierre und Jacques Curie entdeckt, der Einsatz von Piezo-Sensoren für die industrielle Messtechnik verbreitete sich erst in den 1980er Jahren (Tichý et al. 2010, S. 4&9). Mit dem Piezo-Effekt können zunächst nur Kräfte gemessen werden. Um den Effekt auch für die Erfassung von Beschleunigungen nutzen zu können, werden, wie in Abbildung 2-13 dargestellt, seismische Massen eingesetzt. Diese können die Vibrationen, die der Sensor erfährt, in Trägheitskräfte umwandeln, die wiederum als Spannungsänderungen an den Elektroden der Piezoelemente abgegriffen werden können.



- 1 Gehäuse
- 2 Vorspannschraube
- 3 Piezoelektrische Ringe
- 4 Seismische Masse
- 5 Elektrischer Anschluss
- 6 Befestigungsbohrung

Abbildung 2-13: Aufbau eines Piezo-Sensor-Elements (Rupitsch 2019, S. 419)

Kommerziell erhältliche AE-Sensorelemente weisen meist eine komplexe Übertragungsfunktion auf. Die Erstellung von breitbandigen Sensoren wird durch Dämpfung und Aufweitung der Resonanzfrequenzen erreicht. Selbst Sensoren gleicher Bauform und Hersteller sind jedoch einzigartig hinsichtlich ihres Übertragungsverhaltens und werden deshalb mit einem Kalibrierblatt bzw. ihrer Übertragungskurve ausgeliefert. In Abbildung 2-14 ist ein handelsüblicher AE-Sensor und dessen Übertragungsverhalten dargestellt.

Als Verstärker für die AE-Sensoren auf Piezo-Basis eignen sich entsprechend breitbandige Ladungs- oder Spannungsverstärker. Aufgrund der geringen Ausgangsspannungen der AE-Sensoren kommen Vorverstärker mit großem Verstärkungsfaktor zum Einsatz.

AE-Signale nehmen zwei charakteristische Grundsignalformen an. Unterschieden wird in Burst- und kontinuierliche (transiente) Signale (siehe Abbildung 2-15).

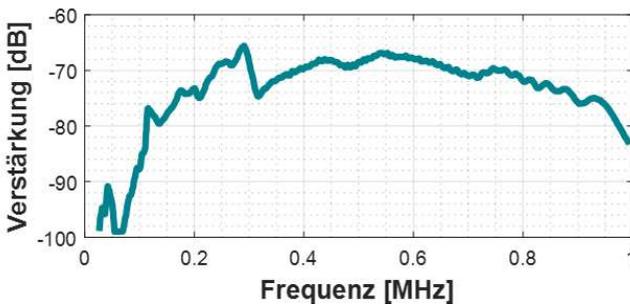


Abbildung 2-14: Übertragungsverhalten eines AE-Sensors (Mistras Group 2011)

Dies stellt besondere Herausforderungen an die Auswertung solcher Signale. Unabhängig von der Applikation ist das Ziel der AE-Messung, auf Basis der Signalcharakteristik auf einen Systemzustand oder eine Prüfobjekteigenschaft zu schließen. Das Extrahieren dieser Merkmale ist die Aufgabe der AE-Analyse. Verfahren, die sich in der Technik und Forschung etabliert haben, sind:

- Extraktion von statistischen Merkmalen in der Zeitdomäne (z. B. der Root-Mean-Square RMS oder Mittelwerte des Signals),
- Bestimmung der Stoßrate (en. *hit count*) durch Schwellwertfilterung mit Hysterese und Zählen von Stößen bzw. Häufigkeitsverteilung der Stöße,
- Analyse im Frequenzbereich mittels Fourier-Transformation,
- Analyse im Zeit-Frequenz-Bereich mittels Short-Time-Fourier-Transformation oder Wavelets,
- Lokalisierung von AE-Quellen mittels Trilateration,
- Mustererkennung mit künstlichen neuronalen Netzen (NN) oder Fuzzy-Logik.

Diese und weitere Verfahren werden in den Arbeiten von (Kuttner 2015, S. 264ff), (Scruby 1987, S. 951), (Mizutani 2016, S. 87ff) und (Deckers 2001, S. 29ff) näher erläutert.

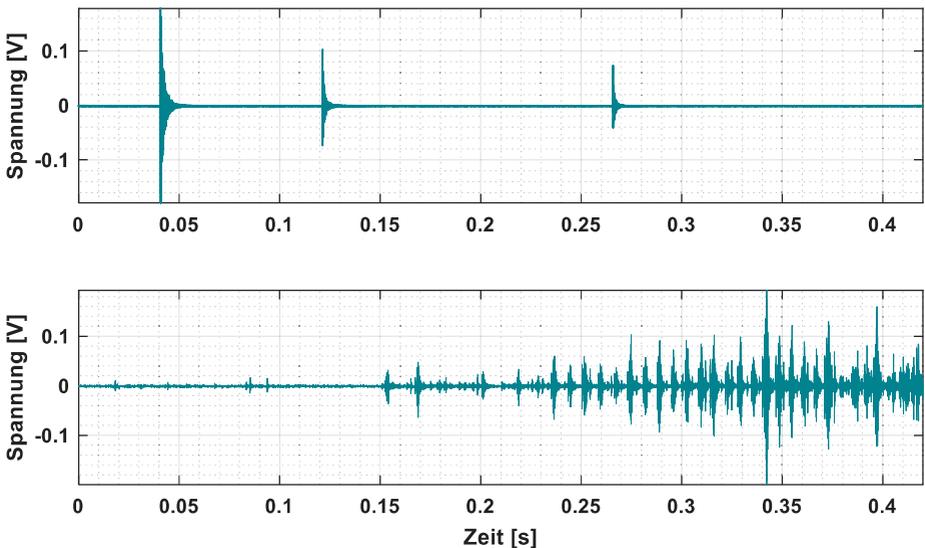


Abbildung 2-15: Beispiel für ein Burst- (oben) und kontinuierliches AE-Signal (unten)

2.2.2 Anwendungen der Acoustic Emission Messung

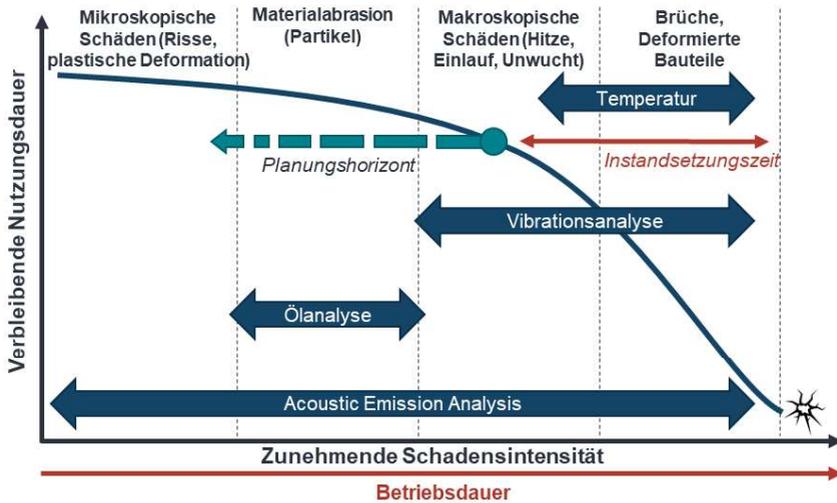


Abbildung 2-16: Potenzial von Acoustic Emission, nach (Reichel, Müller & Mandelartz 2009)

Die AE-Messung hat sich in verschiedenen Bereichen der Wissenschaft und Technik verbreitet und etabliert. AE ermöglicht die unmittelbare Ursache des Verschleißes in Form von Reibung und Stoßimpulsen in mechanischen Systemen zu messen. (Reichel, Müller & Mandelartz 2009, S. 198ff), stellen dieses Potenzial gegenüber anderen Technologien dar (vgl. Abbildung 2-16). Besonders die Vorteile gegenüber der technisch verwandten Vibrationsanalyse hinsichtlich des Potenzials zur Früherkennung werden hier genannt. Die AE-Messung weist einen Detektionsbereich auf, der von mikroskopischen über makroskopische Defekte reicht und Bauteilversagen erkennt. Das verhindert hohe Ausfallfolgekosten und Maschinenstillstände.

Zu den Einsatzbereichen der AE-Messung gehört zunächst die Werkstoff- und Bauteilprüfung. Die AE-Analyse wird besonders für die zerstörungsfreie Materialprüfung eingesetzt

Konkrete Anwendungen sind:

- Korrosion in Stahlbeton (NI 2017),
- Denkmalschutz (Carpinteri et al. 2013),
- Rissdetektion in Bahngleisen (Clark et al. 2017),

- Leckageüberwachung von Druckbehältern (Lv et al. 2017),
- Lötstellenprüfung (Kovtun, Boiko & Petrashchuk 2017),
- Qualitätskontrolle von geschweißten Verbindungen (Droubi et al. 2017).

Hierbei handelt es sich vornehmlich um Anwendungen in Prüflabors und an stationären, unbewegten Objekten. Demgegenüber stehen Applikationen im Bereich der Maschinen- und Prozessüberwachung. Diese haben andere Anforderungen an die Onlinefähigkeit und Robustheit der Auswertemethode, da es sich um dynamische und bewegte Systeme handelt. Besonders im Bereich von rotierenden Maschinenteilen haben sich AE-Sensoren etabliert:

- a) Kugellager (Hase 2020; Tandon & Choudhury 1999),
- b) Zerspanung (Lee et al. 2006),
- c) Getriebe und Zahnräder (Eftekharijad 2010),
- d) Schleifscheibenüberwachung (Jacobsen 2012),
- e) Kupplung und Bremsen (Kelemen 2012),
- f) Verschleißdetektion an KGT (Nurudeen Alegeh et al. 2020; D'Emilia et al. 2018),
- g) In-Process-Monitoring von Schweißnähten (Zhang et al. 2019),
- h) Ritzel-Zahnstangen-Antriebe (Ehrmann 2019),
- i) Werkzeugüberwachung (Wantzen 2020),
- j) Gleitlager (Wantzen 2020),
- k) Prozessüberwachung zur Porenbestimmung im Laserstrahlschmelzen (Eschner 2021).

Insbesondere von (Lee et al. 2006) und (Hase 2020) stammen Arbeiten, die das Potenzial von AE gegenüber herkömmlicher Schwingungsüberwachung dokumentieren. AE kann bis in einen Bereich von mehreren Megahertz detektiert werden und hat eine große Bandbreite. Betrachtet man beispielsweise die Auflösung einer Körperschallwelle in Stahl, mit $c_s = 5850 \text{ m/s}$ (Rose 2004), so ergeben sich bei einer Frequenz von 10 MHz nach Formel 2-22 Wellenlängen bis 0,5 mm. Damit werden auch Defekte auf mikroskopischer Skala auflösbar.

$$\lambda = \frac{c}{f}$$

In Abbildung 2-17 ist das Einsatzgebiet in der Präzisionszerspanung dargestellt. In der Grafik werden die detektierbaren AE-Anregungsfrequenzen über die Größe des Materialabtrags bei Zerspanungsvorgängen aufgetragen. Der Diagrammbereich ist aufgeteilt in die Bereiche Ultrapräzisions-, Präzisionszerspanung und konventionelle Zerspanung und ordnet den Bereichen außerdem Sensoren zu, die zur Messung verwendet werden können. AE hat laut der Abbildung den größten Verwendungsbereich und die besten Auflösungen von Ereignissen im Mikroskalenbereich. Die Abbildung illustriert, wie AE sogar zur Detektion von Versetzungsmechanismen verwendet werden kann.

Von (Hase 2020) wurden mit Hilfe von AE die Schadensmechanismen an Wälzlagern untersucht. Er konnte die Eignung von AE zur Schadensfrüherkennung nachweisen, da bereits Ereignisse wie plastische Deformation und Rissentstehung im Signal detektierbar waren, während konventionelle Schwingungsmesstechnik noch keine Aussage liefert (siehe Abbildung 2-18).

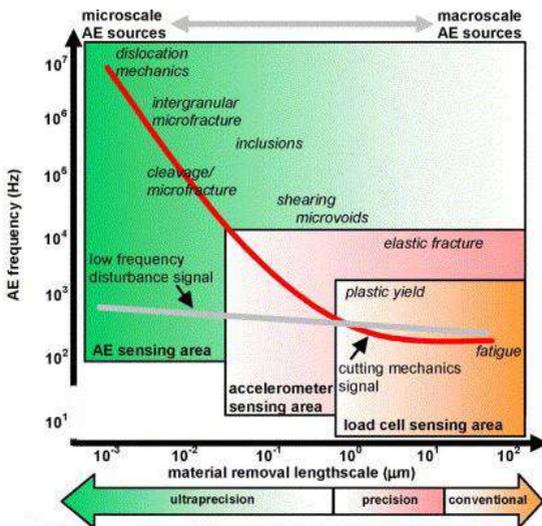


Abbildung 2-17: AE-Anregungsquellen im Bereich der Materialzerspanung (Lee et al. 2006)

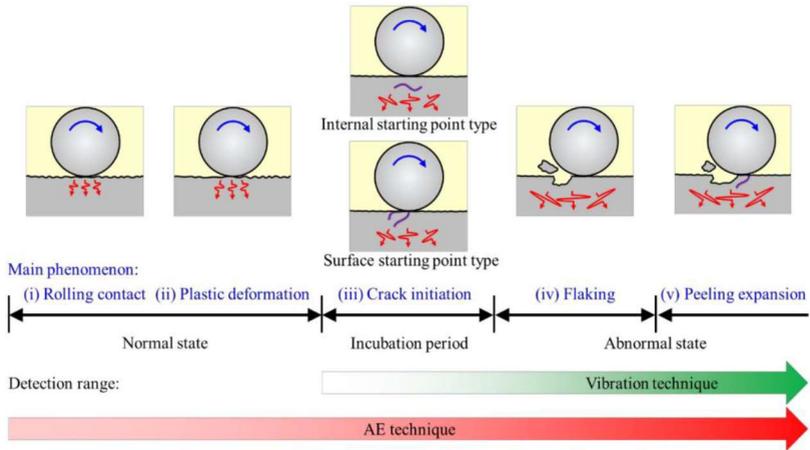


Abbildung 2-18: Unterschied im Detektionsbereich zwischen AE- und herkömmlichen Vibrations-Methoden für Wälzkörper (Hase 2020)

(Ehrmann 2019) konnte in seinen Untersuchungen von Ritzel-Zahnstangen-Antrieben eine Korrelation zwischen AE-Signalen und eintretender Mangelschmierung feststellen. Ebenso war mit Hilfe seiner entwickelten in-situ-Sensorik die Detektion von Verunreinigungen möglich. Der Autor konnte jedoch keine direkte Zuordnung der AE-Signalforn zu konkreten Schadensbildern vornehmen und schlägt hierfür weitere Ansätze mit Machine Learning und der Mustererkennung vor.

Im produktionstechnischen Kontext setzen die meisten Forschungsarbeiten auf die Verwendung von klassischen AE-Analysemethoden, die bereits in 2.2.1 erwähnt wurden. Die AE-Analyse wird dazu eingesetzt, Defekte, die im Vorfeld künstlich oder auf natürliche Weise hervorgerufen wurden, an charakteristischen Signalmerkmalen zu erkennen. In der Arbeit von (Wantzen 2020) wird dafür eine entsprechende Vorgehensweise geliefert und die Implementierung mit Hilfe von Supervised Machine Learning-Ansätzen durchgeführt. Relevante Arbeiten im Kontext von KGT wurden bereits im Abschnitt 2.1.3 benannt.

2.2.3 Schlussfolgerung für die Auswertung von AE am KGT

Nach dem Stand der Technik und Forschung wird der AE-Analyse ein hohes Potenzial für die Schadensfrüherkennung attestiert. Dieser Umstand resultiert aus den Vorteilen der AE-Analyse, die im Folgenden beschrieben werden (ISO 22096):

- Mit AE ist eine zerstörungsfreie Prüfung und nicht-invasive Anbringung des Sensors am zu überwachenden Objekt möglich. Als Anbringungsart sind Schraubbefestigung, Klemmbefestigung und Klebung gängige Varianten.
- Die AE-Analyse liefert Echtzeit-Informationen über den betrachteten Prozess bzw. die Maschine. Damit sind auch dynamische Prozesse leicht überwachbar.
- AE-Sensoren besitzen eine höhere Sensitivität und Bandbreite als herkömmliche Schwingungssensoren. Das ermöglicht die frühere Detektion von Defekten.
- Aufgrund der Bandbreite sind im Kontext rotierender Maschinenteile große Drehzahlbereiche abdeckbar, besonders signifikante Ergebnisse ergeben sich jedoch bei geringen Geschwindigkeiten.
- Es gibt einen Zusammenhang zwischen den Anregungsmechanismen von AE und Reibungs- und Verschleißprozessen.

Dennoch ist der Einsatz mit Herausforderungen verbunden. Zu diesen zählen (ISO 22096; Sikorska & Mba 2008):

- AE ist anfällig für Dämpfung. Dies kann für mechanisches AE zum einen von Vorteil sein, da es dafür sorgt, dass nur Signalquellen in der Nähe des Sensors detektiert werden. Auf der anderen Seite bedeutet dies aber auch, dass der Sensor in unmittelbarer Nähe des überwachten Objektes angebracht werden muss und bei großen Überwachungsgegenständen mehrere Sensoren installiert werden müssen.
- AE weist eine Anfälligkeit gegenüber hohem Hintergrundrauschen auf. Dies kann mechanischen Ursprungs sein, etwa durch eine reibende Dichtung oder Gleitlager, wenn diese nicht das Überwachungsobjekt selbst sind. Aber auch elektrische und elektromagnetische Störungen können in die Signalleitung von AE-Sensoren eingekoppelt werden. Eine entsprechende Isolierung und Abschirmung der AE-Hardware ist daher zu empfehlen. Eine Installation außerhalb von Schaltschränken und der Einsatz von differenziellen AE-Sensoren ist empfehlenswert.
- Eine genaue Zuordnung des resultierenden AE-Signalmerkmals zum zugrunde liegenden Schadensmechanismus lässt sich von vornherein nicht festlegen. Diese Zuordnung muss in Versuchen nachgewiesen werden und ist auf andere Applikationen nicht direkt übertragbar. Das liegt vor allem an den unterschiedlichen Übertragungsfunktionen der Sensoren. Eine beispielhafte Übertragungsfunktion wurde bereits in Abbildung 2-14 dargestellt. Dazu kommt die

Abhängigkeit der Übertragung vom verwendeten Koppelmedium (Klebstoff, Harze) und von der Maschinenstruktur. Sind diese Abhängigkeiten unbekannt, ist die Definition von absoluten Grenzwerten für AE-Signale nicht möglich. Entsprechend wichtig ist die Charakterisierung und Aufzeichnung des AE-Signals im Normalzustand.

- Die AE-Signale weisen darüber hinaus eine große Abhängigkeit vom Betriebszustand der überwachten Komponente oder von den Prozessrandbedingungen auf. Wird die AE-Analyse nicht in stationären Zuständen eingesetzt, so wird die Defektdetektion durch sich ändernde Randbedingungen erschwert.
- Aufgrund der großen Bandbreite des Anregungsspektrums ist eine entsprechende Hardware nötig, die dieses Spektrum mit der nötigen Samplingrate abtasten kann. Dabei entstehen Datenübertragungsraten im mehrstelligen Mbit/s-Bereich. Ist die Merkmalsextraktion ebenfalls mit einer hohen Rechenzeit verbunden, so wird eine echtzeitfähige Anwendung erschwert.

AE im Bereich der Zustandsüberwachung von Wälzlagern wurde in vielen Arbeiten untersucht. Recherchen von (Sikorska & Mba 2008) legen nahe, dass AE-Analysen vor allem erfolgreich zur Detektion von Laufbahndefekten und Abweichungen des Schmierzustands eingesetzt werden können.

Viele der Schädigungsmechanismen an Wälzlagern werden auch für den Betrieb von KGT genannt. Die geometrische und kinematische Ähnlichkeit der Laufbahnen suggeriert eine Übertragbarkeit der angewendeten Methoden zur Zustandsüberwachung. Werden die Anregungsmechanismen von AE beispielsweise den Schadensursachen und den Schadensbildern des KGT gegenübergestellt, so ergibt sich eine enge Verbindung zwischen den Anregungsmechanismen von AE und den Ausfallmechanismen von KGT (siehe Abbildung 2-19).

Aus der Abbildung geht allerdings auch hervor, dass eine konkrete Zuordnung des AE-Signals zu einem bestimmten Schadensbild äußerst komplex ist. Ähnliche Feststellungen wurden in den zuvor aufgeführten Arbeiten bereits für andere Systeme sowie in der Norm (ISO 22096) getroffen. Die Zuordnung zu bestimmten Schadensbildern findet häufig nur im Labormaßstab statt oder durch künstliche Erzeugung des Schadensbildes.

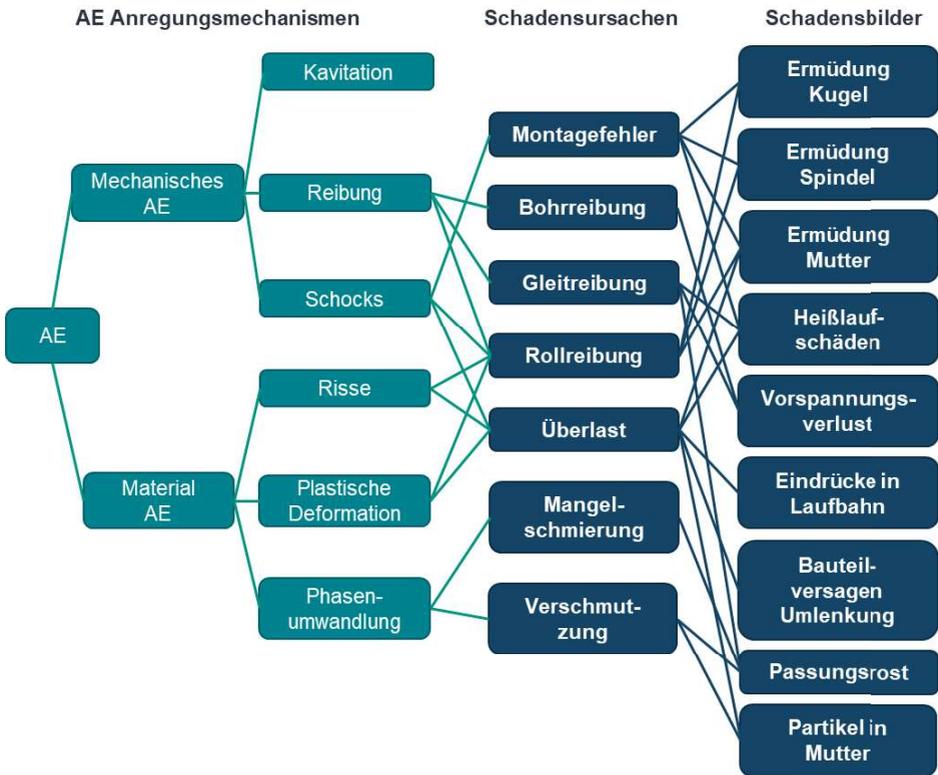


Abbildung 2-19: Zusammenhang zwischen den AE-Anregungsmechanismen und KGT-Schadensursachen

Am Beispiel KGT ist jedoch ersichtlich, dass diese Schadensbilder nicht unabhängig voneinander entstehen und sich ausbilden. Das Abbilden von Schadensbildern anhand eines AE-Signals oder -Merkmals ist für ein gesamtheitliches CM-System daher nicht zielführend. Es erfordert ein hohes Maß an Vorversuchen mit künstlichen Schäden unter verschiedenen Randbedingungen, um alle Wirkzusammenhänge und Abhängigkeiten der Ausfallursachen abzudecken.

Diese Erkenntnis steht im Zielkonflikt mit dem Einsatz von Supervised Machine Learning-Ansätzen. Diese benötigen eine große Anzahl an Trainingsdaten und eine zugehörige Annotation (Label). Im folgenden Kapitel wird deshalb speziell auf Unsupervised Learning als Verfahren für die Mustererkennung eingegangen.

2.3 Unsupervised Learning für Condition-Monitoring

Die Abgrenzung der Begriffe CM und Anomalieerkennung im Kontext dieser Arbeit illustriert die Abbildung 2-20. Wenn CM den Gesamtprozess beschreibt, so sind die Begriffe Anomalieerkennung, Zustandsdetektion oder Klassifikation als Aufgaben innerhalb dieses Prozesses zu verstehen. Dabei ist von Anomalieerkennung bis Klassifikation ein zunehmender Informationsgewinn möglich. Während die Anomalieerkennung nur die einfache Unterscheidung Gut-/Grundzustand und Anomalie ermöglicht, soll die Zustandsdetektion die Gesamtheit der möglichen Zustände beschreiben. Diese gestattet dann das Erfassen von Betriebszuständen, deren Häufigkeit, den Wechsel zwischen Zuständen und letztlich auch Abweichungen von diesen (Anomalien). Damit geht die Zustandsdetektion über die binäre Entscheidung bei der Anomalieerkennung hinaus. Eine weitere Verbesserung wird mit der Klassifikation erreicht. Mit ihr werden die detektierten Zustände tatsächlich benannt und zugeordnet, etwa zu einem Defekt oder Schadensbild. Um dies zu erreichen, sind jedoch Daten notwendig, die diese Zuordnung erlauben. Sogenannte *Label* (Beschriftungen) werden benötigt, um diesen Zusammenhang abzubilden.

Um die beschriebenen Aufgaben zu lösen, sind verschiedene Verfahren aus dem Bereich des maschinellen Lernens oder auch aus der Statistik denkbar. Der Kontext der Arbeit beschränkt sich hierbei auf die in Abbildung 2-20 nicht ausgegrauten Begriffe und Methoden. Es wird ein Ansatz verfolgt, der ohne gelabelte Daten auskommen soll. Daher ist eine Begrenzung auf Unsupervised Learning Methoden notwendig.

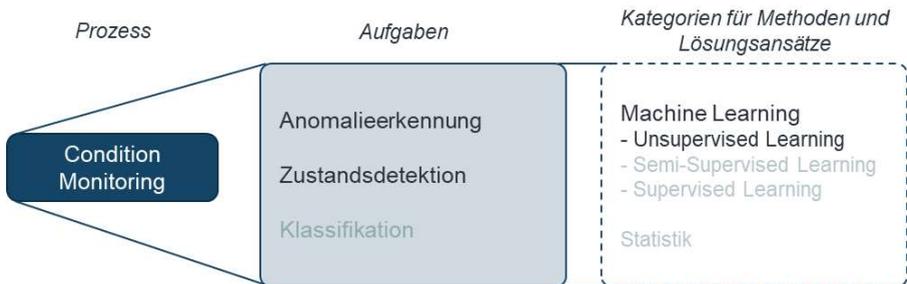


Abbildung 2-20: Abgrenzung von Begriffen im Kontext von CM

Der Begriff Unsupervised Learning (unüberwachtes Lernen) bezeichnet ein Teilgebiet des maschinellen Lernens, en. *machine learning* (ML). ML beschreibt den Prozess, bei dem ein Algorithmus aus Daten lernt. Nach (Mitchell 1997) verläuft der Vorgang wie folgt: „A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance at tasks in T , as measured by P , improves with experience E .“

(Steinwendner & Schwaiger 2020) beschreiben diese Art des Lernens, bei der Wissen aus Erfahrung generiert wird, als induktives Lernen. Auf Basis der verwendeten Erfahrung E , die in der Praxis aus Trainingsdaten und zugehörigen Klassen, sog. Labels, besteht, können verschiedene ML-Verfahren unterschieden werden:

- überwachtes Lernen (en. *Supervised Learning*),
- halb-überwachtes Lernen (en. *Semi-Supervised Learning*),
- unüberwachtes Lernen (en. *Unsupervised Learning*).

Die Unterscheidung der Verfahren hinsichtlich der benötigten Erfahrung E bzw. der erforderlichen Trainingsdaten lässt sich anhand von Abbildung 2-21 verdeutlichen.

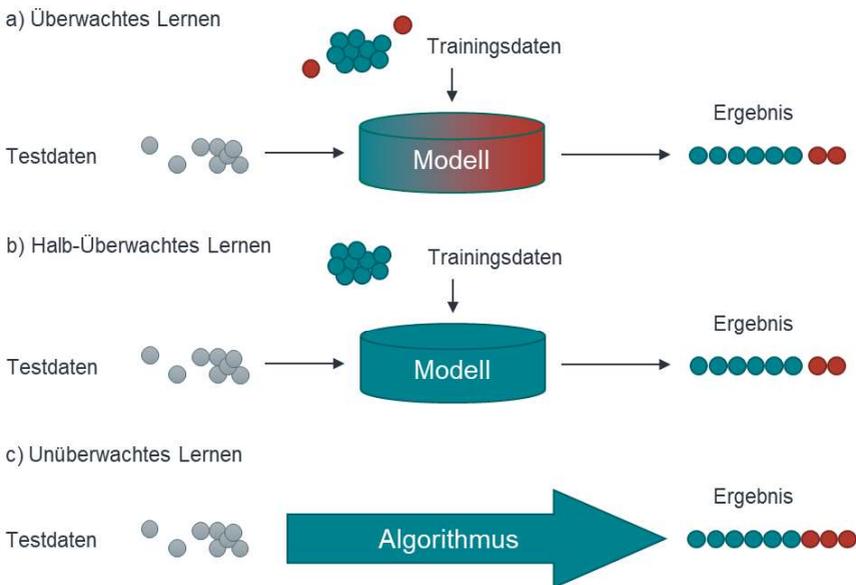


Abbildung 2-21: Unterschied zwischen den Machine Learning Arten (Goldstein & Uchida 2016)

Die überwachte Variante (a) nutzt einen vollständig gelabelten Datensatz für das Training. Dabei enthält der Datensatz sowohl Anomalie- als auch Normaldaten. Bei entsprechendem Modelltraining ist hier die Aussagegenauigkeit am höchsten. Der Aufwand für das Training und die Datenerzeugung ist jedoch am größten. Beim Semi-Supervised Learning (b) dagegen wird ein anomaliefreier Trainingsdatensatz verwendet. Danach werden die Abweichungen in den Testdaten dazu genutzt, um Anomalien zu detektieren. Unüberwachte Lernalgorithmen (c) verwenden lediglich die intrinsische Information in den Daten, um Datenpunkte zu detektieren, die von der Norm abweichen. Die Zuordnung, die der unüberwachte Algorithmus dabei erlernt, ist jedoch keine definitive Aussage über das tatsächliche Label (Anomalie/Normal), sondern nur eine Aussage über die Ähnlichkeit der Daten (Muster). Ein geringer Trainingsaufwand und größtmöglicher Informationsgewinn bzw. eine größtmögliche Aussagegenauigkeit sind gegensätzliche Zielgrößen bei der Verwendung dieser Ansätze. Wird jedoch nur eine Anomalieerkennung in den Kategorien normal und abnormal benötigt, ist die Verwendung von Unsupervised Learning naheliegend.

Insbesondere in der Produktionstechnik ist die Verfügbarkeit von Datensätzen mit Label (abnormal/normal) gering. Zum einen liegt das am hohen Aufwand für das Labeling, da Anomalien nur selten auftreten oder künstlich herbeigeführt werden müssen. Zum anderen sind diese Datensätze meist unbalanciert (en. *skewed*). Das heißt, der Anteil an Anomalien ist wesentlich geringer als der Anteil normaler Datenpunkte. Aus diesen Gründen eignen sich Ansätze des Supervised Learning nur begrenzt zur Anomaliedetektion (F.N. Oliveira et al. 2019). Darüber hinaus können während der Anwendung eines Machine Learning Modells neuartige Anomalien auftreten, die während der Trainingsphase nicht bekannt waren (Chalapathy & Chawla 2019). Diese Limitierungen führten zur weiten Verbreitung von Unsupervised und Semi-Supervised Learning-Konzepten im Kontext von CM.

Typische Aufgaben für die Anwendung von unüberwachtem Lernen sind die Clusterbildung und das Representation Learning. Diese werden aufgrund ihrer Bedeutung für die weitere Arbeit in den nachfolgenden Kapiteln erläutert.

2.3.1 Unüberwachte Merkmalsextraktion

Sollen Merkmale oder Muster aus einem Datensatz extrahiert werden, so befindet man sich im Bereich des *Representation* oder *Feature Learning*. Dieser Teilbereich des Maschinellen Lernens umfasst Methoden, die eine meist komprimierte Darstellung der

Rohdaten erlernen (Bengio, Courville & Vincent 2012). Eine Methode des *Representation Learning* sind Autoencoder-Netzwerke (AEN), die eine besondere Form von Neuronalen Netzen darstellen. Die Besonderheit von Autoencodern besteht darin, dass sie versuchen, den Input x_i auf sich selbst abzubilden. Die allgemeine Abbildungsvorschrift für Input x_i auf Output y_i neuronaler Netze wird daher zu:

$$y_i = f(x_i) \approx \hat{x}_i \quad 2-23$$

Dabei wird das Ziel verfolgt, eine komprimierte Darstellung der Inputdaten zu erhalten, aus der die Inputdaten wieder rekonstruiert werden können. Damit lassen sich Autoencoder für die Dimensionsreduktion und zur Rauschunterdrückung einsetzen (Hosseini et al. 2020). Der Autoencoder findet demnach automatisiert eine Menge intrinsischer Merkmale der Trainingsdaten, ohne dass diese im Vorfeld angegeben oder definiert werden müssen.

Der einfachste Aufbau eines Autoencoders, der *Vanilla* Autoencoder (Hosseini et al. 2020, S.101ff), ist exemplarisch in Abbildung 2-22 dargestellt. Formeln zur Abbildung der Gewichte, der Input- und Outputvektoren und der Kostenfunktion werden nachfolgend aufgeführt:

$$\begin{aligned} z_j &= h^E(W_{ji}^E x_i + b_j^E) \\ \hat{x}_i &= h^D(W_{ij}^D z_j + b_i^D) \\ J &= \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 + \lambda \cdot \Omega^{E,D} + \beta \cdot \Omega^{Sparsity} \end{aligned} \quad 2-24$$

Die versteckten Neuronen z_j bezeichnen die erlernte neue Repräsentation oder auch die erlernten Merkmale. Der erste Term in der Kostenfunktion J stellt den Rekonstruktionsfehler als Mean-Squared-Error (MSE) dar. Dieser kann um weitere sog. Regularisierungsterme, die das Trainingsverhalten verbessern, erweitert werden. Die zusätzlichen Terme sollen zum Beispiel ein Overfitting, d. h. eine Überanpassung, verhindern. Bei ML-Modellen kommt es zum Overfitting der Trainingsdaten, wenn das Modell Merkmale, die aus dem Rauschen oder der Varianz der Inputdaten entstehen, beschreibt, anstatt die tatsächliche Datenverteilung zu erlernen. Overfitting führt zum Verlust der Modellgenauigkeit bei neuen Testdaten, die nicht in den Trainingsdaten enthalten sind (Sammut 2010).

Mit steigender Kapazität bzw. Komplexität neuronaler Netze steigt auch der Bedarf an Speicherplatz.

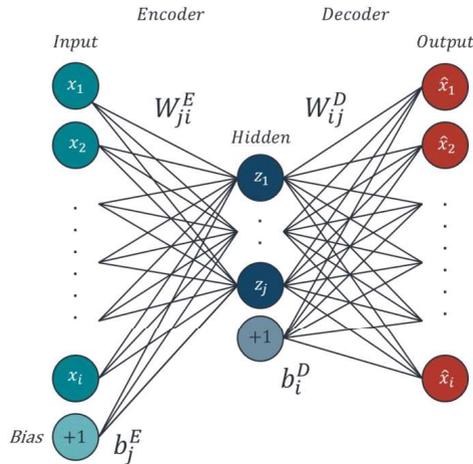


Abbildung 2-22: Aufbau eines Vanilla-Autoencoders (eigene Darstellung)

Bezeichnet $i = 1..N_{in}$ die Anzahl an Neuronen im Input-Layer und $j = 1..N_H$ die Anzahl an Neuronen in der versteckten Schicht (Hidden-Layer), so ergibt sich nach Formel 2-25 die Anzahl an Kilobytes, die ein solches Netz im Arbeitsspeicher oder auf der Festplatte eines Computers mindestens einnimmt. Dabei wurde eine Speichertiefe von 32 bit pro Gewicht angenommen. Dabei sind $W_{ji}^{E,D}$ Gewichte und $b_j^{E,D}$ Gewichte und Bias des Encoders bzw. Decoders (die Anweisung `numel()` gibt die Anzahl an Elementen einer Matrix zurück).

$$\begin{aligned}
 N_{Net} &= \text{numel}(W_{ji}^E) + \text{numel}(b_j^E) + \text{numel}(W_{ij}^D) + \text{numel}(b_j^D) \\
 &= N_{in} \cdot N_H + N_H + N_H \cdot N_{in} + N_{in} = N_H \cdot (2 \cdot N_{in} + 1) + N_{in} \quad 2-25 \\
 \text{memory}_{Net} &= N_{Net} \cdot \frac{32}{8 \cdot 1024} [\text{kByte}]
 \end{aligned}$$

Neben der Möglichkeit zur automatisierten Merkmalsextraktion kann auch der Rekonstruktionsfehler genutzt werden, um eine Anomalieerkennung zu realisieren. Anstatt im Vorfeld alle abnormalen Zustände zu erlernen, was oftmals nicht möglich oder mit viel Aufwand verbunden ist, wird ein Autoencoder auf Basis von Daten des Normalzustands trainiert. Ergeben sich nun große Rekonstruktionsfehler für neue Testdaten, so kann dies als Indiz für Anomalien verwendet werden. Dieser Ansatz eignet sich im Besonderen für unausgeglichene Datensätze und das Erkennen von zuvor unbekanntem Zuständen. Der Ansatz wird später in Abschnitt 7.4.1 näher vorgestellt.

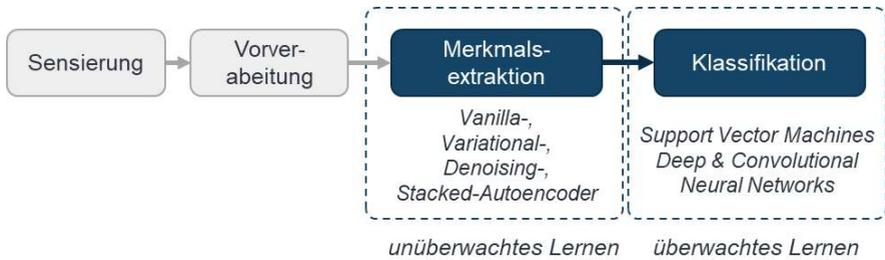


Abbildung 2-23: Prozessfolge für die Verwendung von Autoencodern in CM-Applikationen

In den meisten Arbeiten zum aktuellen Stand der Forschung wird der Autoencoder als Werkzeug für die unüberwachte Merkmalsextraktion eingesetzt. Die so extrahierten Merkmale dienen dabei als Input für ein Klassifikationsmodell. Häufig werden hierfür Support-Vector-Machines oder verschiedene Neuronale-Netzwerk-Architekturen verwendet. Beispielhafte Anwendungen im Kontext der Zustandsüberwachung sind die Arbeiten von (Michau et al. 2019), (Arellano-Espitia et al. 2019), (Roy et al. 2018) und (Sohaib & Kim 2018). Diese Arbeiten verwenden den Aufbau in Abbildung 2-23 und damit sowohl unüberwachte als auch überwachte Teilmodelle.

Ein weiterer Ansatz, der vollständig unüberwacht funktioniert, verzichtet auf die Klassifikation und nutzt den zuvor beschriebenen Rekonstruktionsfehler als Anomaliemaß. Die Autoren der Arbeiten, (Oh & Yun 2018) und (Ahmad et al. 2021), trainieren ein Autoencoder-Netzwerk mit akustischen oder Schwingungsdaten im Normalzustand. Die Trainingsdaten werden auch zur Einstellung eines Grenzwertes τ für die Anomalieerkennung genutzt. Neue Testdaten, deren Rekonstruktionsfehler τ überschreitet, werden einer Anomalie zugeordnet.

2.3.2 Grundlagen der Clusterbildung

Der Begriff Clusterbildung, häufig auch Clustering genannt, bezeichnet das Finden von Gruppen ähnlicher Objekte in einem Datensatz. Der Begriff Objekt kann hierbei für eine Vielzahl von Datentypen stehen, z. B. numerische Daten, Zeichenfolgen oder ganze Dokumente. Im Kontext dieser Arbeit wird Objekt stellvertretend für Datenpunkte einer sensorisch erfassten Zeitreihe oder Merkmalsvektoren einer Zeitreihe verwendet.

Clustering wird für eine Vielzahl von Aufgaben eingesetzt und beschränkt sich nicht auf den Einsatz in bestimmten Anwendungsbereichen. Wichtige Felder sind nach (Gunopulos 2009):

- Datenreduktion,
- Hypothesenbildung,
- Vorhersage von Gruppenzugehörigkeit,
- Marktrecherche und Geschäftsanalyse,
- Biologie und Bioinformatik,
- Datenanalyse in Geographischen Informationssystemen (GIS),
- Webmining.

Per Definition fließen in die Clusteroperation keine Labels der Datenobjekte mit ein. Darin besteht auch der Hauptunterschied zum Supervised Learning, wo die Zuordnung der Klassen im Vorfeld bekannt ist und zur Modellbildung explizit genutzt wird (Beyerer, Richter & Nagel 2018). Sind die Clustergruppen gefunden, können diese hinsichtlich ihrer Güte (meist unter Verwendung eines Ähnlichkeitsmaßes) bewertet werden. Wenn die Klassenzuordnung zur Verfügung steht, kann auch die tatsächliche Genauigkeit der Gruppierung beurteilt werden, der sog. *ground truth*.

Im Folgenden wird die Terminologie für den Kontext der Arbeit und die Begriffe Objekt, Datensatz und Clustering definiert (siehe DEFINITION 3 und DEFINITION 4).

DEFINITION 3. Datensatz

Ein Datensatz $D_d(X, y)$ besteht aus der Gesamtheit an Objekten X (Einzelobjekten x_i) und deren Klassenzuordnung y_i (sofern vorhanden). So ist $D_{tr}(X_{tr}, y_{tr})$ zum Beispiel ein Trainingsdatensatz mit einer Menge an Trainingsdaten X_{tr} mit Labels y_{tr} .

$X: \{x_i\}_1^n$, wobei $x_i \in R^m$, n die Anzahl an Objekten im Datensatz D_d und m die Anzahl an Merkmalen bzw. die Dimension des Objekts x_i ist.

$D_d: \{(x_i, y_i)\}_1^n$, wobei $y_i \in R$

DEFINITION 4. Clustering

Clustering, oder auch Partitionierung, ist die Zerlegung eines Datensatz D_d in Teilmengen C_1, \dots, C_k , sodass gilt:

$$\forall i \neq j : C_i \cap C_j = \emptyset$$

$$\bigcup_{i=1}^k C_i = D_d$$

Beim Clustering wird versucht, ein Optimierungskriterium zu erfüllen, z. B. Cluster-Mitglieder sind zueinander ähnlicher als zu anderen Nicht-Mitglieder-Objekten (Abstandsmaß).

Ein Cluster bezeichnet dabei die Menge an Datenpunkten $x_i \in C_i$.

Ein geclustertes Datensatz D_d^C enthält zusätzlich zur Klassenzuordnung y_i die Clusterindizes c_i , die jedem Clusterobjekt einen Clusterindex zuordnet, um die Gruppenzugehörigkeit auszudrücken.

Es ist damit $D_d^C: \{(x_i, y_i, c_i)\}_1^n$, wobei $c_i \in R$

2.3.2.1 Data Stream Clustering

Ein Spezialgebiet des Clustering, das sich mit dynamischen Datensätzen bzw. *Datenstreams* befasst, ist das Data Stream Clustering. Im Rahmen dieser Arbeit wird für den Begriff *Datastream* folgende Definition verwendet:

DEFINITION 5. Datenstream

Ein Datenstream D zeichnet sich aus durch eine veränderliche Menge an Objekten X_{t_i} zu den Zeitpunkten t_1, \dots, t_l . Dabei gilt $X_{t_{i-1}} \subseteq X_{t_i}$, sodass die Objektmenge des aktuellen Zeitpunkts auch alle Objekte des vorherigen Zeitpunkts beinhaltet.

Reale Datenquellen liegen meist als kontinuierliche *Datenstreams* vor. Im konventionellen Datamining wird hier zumeist eine Vereinfachung vorgenommen, wenn statische oder lokal gespeicherte Datensätze analysiert werden. Oft wird dieser Aspekt auch in Forschungsarbeiten bei der Validierung von Anomalie- und Zustandsüberwachungsmodellen vernachlässigt. Dabei werden Herausforderungen, die bei der Berücksichtigung von *Datenstreams* entstehen, vernachlässigt (Yang 2003; Silva et al. 2013):

- **Kontinuität:** Objekte im *Datenstream* entstehen kontinuierlich und müssen dementsprechend auch kontinuierlich verarbeitet werden.
- **Begrenzter Speicherplatz:** Ein *Datenstream* kann über die Zeit unbegrenzt groß werden und beansprucht eine große Menge Speicherplatz.
- **Begrenzte Rechenkapazität:** In vielen Applikationen werden Sensorwerte mit sehr hoher Abtastrate aufgezeichnet. Damit ist die zur Verfügung stehende Rechenzeit pro neuem Datenobjekt im *Datenstream* begrenzt.

- Cluster Evolution: Das Verhalten des *Datenstreams*, der zugrunde liegende Datengenerierungsprozess (im einfachsten Fall ein Sensor), ist nicht immer stationär. Die Datenverteilung kann sich über die Zeit ändern (siehe auch *Concept Drift* in (Widmer & Kubat 1996)). Darüber hinaus können Cluster, die bereits detektiert wurden, zu einem späteren Zeitpunkt zusammenfallen. Neue Cluster können im Zeitverlauf entstehen oder existierende Cluster sich aufspalten.

Um diese Herausforderungen zu berücksichtigen, müssen bereits die Clusteralgorithmen entsprechend ausgewählt und die jeweiligen Modelle oder Mechanismen für das *Datenstream*-Management implementiert werden. (Silva et al. 2013) verfasste hierzu eine Arbeit, die einen ganzheitlichen Überblick über vorhandene Algorithmen und Datenstrukturen gibt.

Im Kontext von CM-Systemen ist der Aspekt der Erfassung zeitlich veränderlicher Zustände von hoher Bedeutung. Wird ein Cluster-Algorithmus für das CM-System verwendet, so entspricht die Cluster Evolution der zeitlichen Änderung der Zustände des überwachten Systems. Allerdings sind gängige Datenstrukturen für *Data Stream Clustering* bisher nicht im Kontext CM betrachtet worden. Deren Eignung bzw. alternative Implementierung wird in Abschnitt 7.6 untersucht.

2.3.2.2 Cluster Evolution

In der Forschung wird bei der spatio-temporalen (Raum und Zeit betreffenden) Evolution von Clustern von *Time Aware Clustering* (Silva et al. 2013) und vom Cluster-Tracking gesprochen (Spiliopoulou et al. 2006; Putri et al. 2019). Diese Begrifflichkeiten beschreiben die Detektion von räumlichen und zeitlichen Vorgängen innerhalb und zwischen Clustern.

Das Framework *MONIC*, das von (Spiliopoulou et al. 2006) vorgeschlagen wurde, gibt Definitionen für diese Vorgänge an. Die Vorgänge werden als Cluster-Transitionen bezeichnet.

Abbildung 2-24 zeigt die für diese Arbeit relevanten Transitionen. Die Transitionen können unterteilt werden in interne und externe Transitionen: Bei externen Transitionen handelt es sich um Transitionen eines Clusters, die in Verbindung mit dem Rest der Cluster stehen. Beispiele hierfür sind die *Create* Transition, *Merge* Transition, *Split* Transition und *Vanish* Transition.

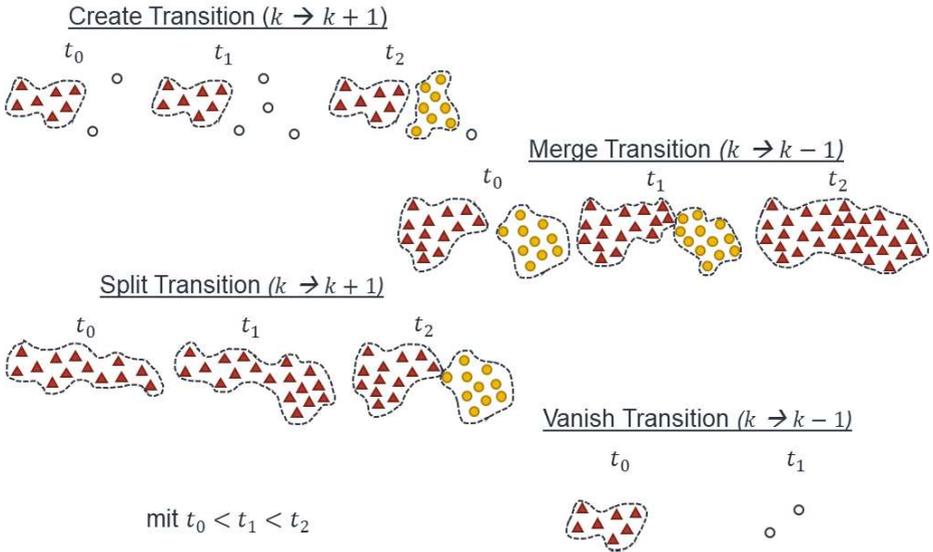


Abbildung 2-24: Externe Cluster-Transitionen, nach (Spiliopoulou et al. 2006)

Erfährt ein Cluster keine externe Transition von einem Zeitpunkt zum nächsten, so kann ihm die *Survive* Transition zugewiesen werden.

Bei internen Transitionen (Abbildung 2-25) handelt es sich um die Transitionen eines Clusters, die die Form oder Dichte und den Inhalt eines Clusters betreffen können. Beispiele hierfür sind die *Size* Transition, *Density* Transition und *Location* Transition.

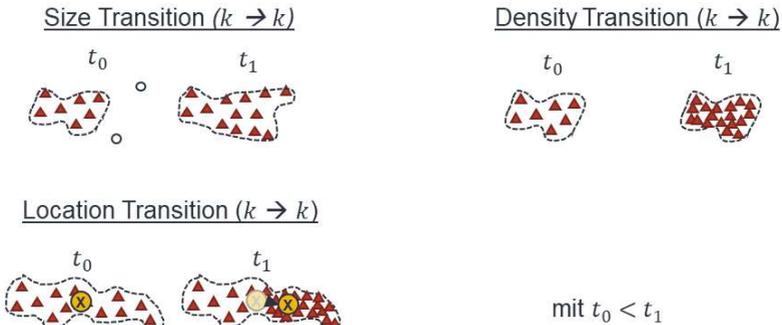


Abbildung 2-25: Interne Transitionen, nach (Spiliopoulou et al. 2006)

In *MONIC* stellen Cluster-Transitionen zu einem bestimmten Zeitpunkt eine Änderung eines Clusters dar, das bereits zu einem früheren Zeitpunkt detektiert wurde. Zur Bestimmung, ob ein Cluster $X \in D_i$ zum Zeitpunkt t_i dem Cluster $Y \in D_j$ zum Zeitpunkt t_j entspricht, wird ein Überlapp (en. *overlap*) definiert. Er zeigt auf Basis der normalisierten Gewichte aller Objekte in der Schnittmenge von X und Y an, ob eine Übereinstimmung der Cluster vorliegt. Durch paarweisen Vergleich aller Cluster in D_i und D_j werden die Transitionen für den aktuellen Zeitpunkt bestimmt. In *MONIC* wird jedem Datenpunkt/Objekt ein Gewicht zugewiesen, das mit zunehmendem Alter des Datenpunkts abnimmt. Die Zuweisung des Alters kann zum Beispiel über Moving-Window-Modelle erfolgen. Damit wird in diesem Framework implementiert, dass ältere Datenpunkte weniger Einfluss auf die Clusterbildung haben bzw. sogar ganz verschwinden können.

Die Analogie dieser Cluster-Transitionen kommt für die Problematik sich zeitlich veränderlicher Zustände und das Erfassen von Zustandsänderungen in Betracht. Eine Übertragung auf CM-Systeme wird in Abschnitt 7.6 dieser Arbeit diskutiert.

2.3.3 Schlussfolgerung zum Einsatz von Unsupervised Learning im CM

Im Forschungskontext der Zustandsüberwachung haben sich in den letzten zehn Jahren unüberwachte Lernverfahren (Clustering, vermehrt auch Deep Learning) für die Anomaliedetektion etabliert (Chalapathy & Chawla 2019). Vollständig unüberwachte Verfahren gehen allerdings im Vergleich zu überwachten Verfahren nicht über die binäre Entscheidung, ob es sich bei einem neuen Objekt um eine Anomalie handelt, hinaus. CM-Systeme stellen jedoch weitergehende Anforderungen an die verwendeten Algorithmen und Verfahren. In (Khan & Yairi 2018) werden Herausforderungen für autonome CM-Systeme aufgeführt und an dieser Stelle um weitere ergänzt. Es bestehen Herausforderungen für:

- die Modellierung:
 - keine durchgängige Automatisierung bei der Parametrierung von CM-Systemen und Modellerstellung mit möglichst geringer Anzahl an Hyperparametern,
 - Wahl einer Datenstruktur für das Modell, das zurückliegende Zustände berücksichtigt,
 - Wahl einer Datenstruktur, die die Datenstream-Problematik berücksichtigt,

- Ermöglichen von niedrig dimensionalen Darstellungen von multidimensionalen Problemen, damit die Entscheidung von Nutzern nachvollzogen werden kann.
- die Eingangsdaten (Input):
 - Funktion unter sich ändernden Betriebsbedingungen,
 - robust gegenüber verrauschten oder fehlenden Daten,
 - Detektion von langsamen (kontinuierlichen) Änderungen (*Concept Drift*),
 - Eingriffsgrenzen für Anomalieerkennung zumeist unbekannt,
 - a priori keine Daten verfügbar, keine Offline-Trainingsphase möglich.
- die Ausgangsdaten (Output):
 - Unterscheidung von verschiedenen Ausfällen mit einer einzigen Diagnosemethode bzw. einem Algorithmus,
 - robuste Unterscheidung von Ausfällen.
- die Anwender:
 - mangelndes Fachwissen bei der Konfiguration von CM-Systemen,
 - mangelndes Fachwissen für das beobachtete Objekt.

Um diese Herausforderungen zu lösen, existieren in der Forschung und Technik bereits Ansätze und Algorithmen. So können beispielsweise Autoencoder-Architekturen für die automatisierte Merkmalsextraktion ohne a-priori-Wissen eingesetzt werden. Unter Nutzung des Rekonstruktionsfehlers steht ein Anomaliemaß zur Verfügung (siehe Abschnitt 2.3.1), das mit einem Grenzwert überwacht werden kann. Weitere Automatismen sind jedoch bei der Einstellung dieses Grenzwerts vonnöten.

Schwächen zeigen aktuelle Ansätze bei der Verwendung in Szenarien mit vielen unterschiedlichen Ausfallursachen und Betriebszuständen. Auch die Berücksichtigung der zeitlichen Evolution von überwachten Systemen wird nicht direkt im Aufbau und der Funktionsweise der unüberwachten Algorithmen berücksichtigt. Einen Ansatz, diese Lücke zu schließen, bildet das Framework *MONIC* (Spiliopoulou et al. 2006).

Ein entscheidendes Kriterium bleibt auch die Wiederverwendbarkeit oder Übertragbarkeit solcher Systeme bzw. die Einfachheit der Einrichtung und Konfiguration. Daten- und domänengetriebene Parametriermechanismen können hier für einen höheren Grad der Automatisierung sorgen. Generalisierbare und ganzheitliche Ansätze im Bereich des CM können die Einstiegshürden für Anwender, wie Instandhalter und Maschinenbetreiber, vereinfachen.

2.4 Fazit für die Zielsetzung und Vorgehensweise der eigenen Arbeit

Aus den vorangegangenen Ausführungen zum KGT, zur AE-Analyse und zu unüberwachten Lernverfahren lassen sich Forschungsdefizite und offene Problemstellungen identifizieren. Sie werden in diesem Abschnitt erneut aufgegriffen und für die Präzisierung der Zielsetzung in Kapitel 3 genutzt.

Im Kontext der Ausfallbetrachtung von KGT besteht ein Defizit in der Lebensdauerberechnung nach Norm (DIN ISO 3408-5). Die dort beschriebene theoretische Lebensdauer betrachtet allein den Ermüdungsverschleiß. Ansätze, diese Norm zu erweitern, beschränken sich jedoch nur auf die Berücksichtigung der Betriebsart. Eine vollständige modellbasierte Beschreibung des KGT-Verschleißes unter Berücksichtigung aller Einflüsse gemäß Abbildung 2-9 wird von den meisten Autoren als zu komplex und nicht aufwandsgerecht verworfen. Als Lösung werden zustandsbasierte Überwachungsverfahren vorgeschlagen, die Abweichungen vom Normalzustand oder Schadensbilder klassifizieren sollen. Dabei beschränken sich die Verfahren zumeist auf die Detektion eines spezifischen Schadensbildes. Das Erzeugen und Trainieren solcher Verfahren basiert meist auf Supervised Learning-Ansätzen, die mit hohem Modellierungs- und Parametrierungsaufwand und der Notwendigkeit von Trainingsdaten verbunden sind. Für aktuelle CM-Lösungen, im Besonderen für KGT, bestehen daher die nachfolgend aufgeführten Defizite.

Defizit Zustandsüberwachung von KGT: Bislang gibt es keine Auslegungsgrundlagen oder ein Sensorsystem, das die verschiedenen Ausfallszenarien des KGT berücksichtigt, ohne zuvor mit aufwendigen Trainings- und Modellierungsprozessen konfiguriert worden zu sein.

Ein Sensorsystem, das sich im Bereich der Wälzlagertechnik bereits etabliert hat, nutzt AE-Sensoren. Für die in Abschnitt 2.1.1 vorgestellte komplexe Kinematik des KGT hat der Einsatz von AE bislang nur vereinzelt stattgefunden und wurde nur in Szenarien mit Supervised Learning eingesetzt. Gründe hierfür sind die in Abschnitt 2.2.3 genannten Herausforderungen. In der (ISO 22096) wird hervorgehoben, dass eine Zuordnung der zugrunde liegenden Ausfallmechanismen zur jeweiligen AE-Signalcharakteristik eines Defekts nicht möglich ist. Die Defekte emittieren zwar AE, äußere Randbedingungen, Sensortyp und -installation beeinflussen das Ausgangssignal jedoch genauso wie die jeweiligen Schadensmechanismen.

Defizit AE-Qualifizierung am KGT: Die geschilderte Problematik führt dazu, dass AE am KGT bisher noch nicht ausreichend bewertet ist. Besonders für einen flächendeckenden Einsatz zur Zustandsdiagnostik an Vorschubachsen unter Betriebsbedingungen fehlen entsprechende Untersuchungen.

Die Abhängigkeit des AE-Signals von der Vielzahl an Randbedingungen und Betriebszuständen erschwert die Befähigung von Supervised Learning-Ansätzen. Für eine ganzheitliche Abbildung der Einflussmöglichkeiten und Schadensmechanismen müsste eine große Menge an Trainingsdaten mit Label aggregiert werden. Selbst dann würde die Problematik von sich überlagerten Schadenszuständen und/oder Betriebszuständen bestehen. Wenn keine a-priori-Information über das zu überwachende System vorhanden ist, können daher nur Unsupervised Learning-Ansätze verwendet werden. Diese haben zwar eine geringere Aussagekraft hinsichtlich der Zuordnung von Anomalien zu einer speziellen Klasse (eines Defekts), benötigen jedoch keine Trainingsdaten mit Labeln. Eine Herausforderung, die jedoch auch für Unsupervised Learning-Ansätze weiterhin Bestand hat, ist die Konfiguration und Parametrierung der Modelle. Der Laie wird hier mit einer Vielzahl an Auswahlmöglichkeiten hinsichtlich Datenvorverarbeitung und Modellierung konfrontiert. Das automatisierte Parametrieren bzw. Tuning von Hyperparametern im Kontext von ML-Modellen findet in aktuellen Ansätzen nur offline und unter Nutzung von Labels statt. Insbesondere unter dem Aspekt von Systemen mit zeitlich veränderlichen Zuständen und kontinuierlichen Datenströmen mangelt es an Systemen, die den Anforderungen gerecht werden.

Defizit an aufwandsarmen, unüberwachten online CM-Systemen für zeitlich veränderliche Systeme: Unüberwachte online CM-Systeme, die beginnend bei der Datenvorverarbeitung über Merkmalsextraktion und Modellierung keine oder nur wenige Hyperparameter brauchen, sind entsprechend dem Stand der Forschung und Technik nicht vorhanden. Ebenso mangelt es an speziellen Modell- und Datenstrukturen, die dem Speicher- und Informationsbedarf in CM-Applikationen gerecht werden.

3 Eigener Ansatz

In diesem Kapitel wird auf Basis der gewonnenen Erkenntnisse die Problemstellung für die Überwachung des Zustands von KGT dargelegt und eine präzisere Formulierung der Zielstellung vorgenommen. Diese dient als Grundlage für die Vorgehensweise und Definition der Arbeitspakete. Am Ende des Kapitels werden Forschungsfragen formuliert, die im weiteren Verlauf der Arbeit beantwortet werden.

Die Zielstellung der vorliegenden Dissertation ist, mittels integrierter AE-Messtechnik Schadensphänomene durch Verwendung unüberwachter Anomalieerkennung am KGT zu diagnostizieren. Dadurch soll eine betriebsunabhängige und planbare Verfügbarkeitsabsicherung von KGT in Werkzeugmaschinen ermöglicht werden.

Basierend auf den vorgenommenen Recherchen und der Analyse vom Stand der Technik-Lösungen und Forschungsarbeiten im Bereich der Zustandsüberwachung von KGT und nach der Untersuchung relevanter Algorithmen und Modelle zum unüberwachten Lernen ergibt sich das in Abbildung 3-1 dargestellte Gesamtbild aus Zielstellungen, vorherrschenden Defiziten und vorgeschlagenen Lösungsansätzen. Die erwähnte Gesamtzielstellung teilt sich auf in drei Teilziele: die Ausfall- und Schadenserkenkung, das autonome Erkennen von Zustandsänderungen und die automatisierte Parametrierung von CM-Systemen.

Zielstellung	Defizit	Lösung
1 Ausfall- und Schadenserkenkung am Kugelgewindtrieb	1 Bisherige CM- Methoden können vielfältige Ausfall- und Verschleißszenarien nicht detektieren	1 Integration von Acoustic Emission als Messtechnik unmittelbar am Wälzkontakt
2 Autonomes Erkennen von Zustandsänderungen	2 Vollständige a-priori Modellierung des Verschleißverhaltens nicht möglich bzw. hoher Aufwand	2 Einsatz von Unsupervised Methoden für die Online- Überwachung
3 Automatisierte Parametrierung von CM- Systemen	3 Konfiguration der Unsupervised Methoden ist mit hohem Aufwand und Expertenwissen verbunden	3 Methodik zur Autokonfiguration von Anomalieerkennung und Clustering Methoden

Abbildung 3-1: Darstellung von vorherrschenden Defiziten sowie Lösungen und Zielstellungen der Arbeit

Wie bereits zum Stand der Technik (Kapitel 2.2.3) erwähnt, kann AE als potenzialträchtiges Messprinzip zur Zustandsüberwachung eingesetzt werden, um Schadensphänomene frühzeitig zu detektieren. Im Rahmen dieser Arbeit wird deshalb der Einsatz von AE in unmittelbarer Nähe des Wälzkontakts von KGT untersucht. In Kombination mit unüberwachten ML-Algorithmen soll ein System aufgebaut werden, das auch ohne vorheriges Wissen bzw. Training im Betrieb auftretende Zustände erkennen kann. Durch automatisierte Konfiguration der verwendeten Algorithmen und Modelle soll sichergestellt werden, dass für den Anwender ein System zur Verfügung steht, welches sich jederzeit anpassen kann und keine aufwendige oder für den Laien unverständliche und unzugängliche Parametrierung benötigt.

Das System nutzt die kontinuierlich erfassten AE-Rohdaten und führt diese nach Vorverarbeitung und Merkmalsextraktion der Anomalieerkennung zu. Bei der Anomalieerkennung handelt es sich um ein Clustering und Cluster-Tracking-Konzept, das innerhalb der Arbeit entworfen wird, um Zustandsänderungen ohne vorheriges Training zu erfassen und im Kontext von CM zuzuordnen. Beispiele für solche Zustandsänderungen am KGT sind unter anderem Betriebszustandsänderungen (wie Drehzahl und Last), Mangelschmierung oder Verschleiß (wie Ermüdungsschäden und Vorspannungsverlust). Das Modell zur Anomalieerkennung stellt sein Clustering-Ergebnis in Form eines Zeitstrahls zur Verfügung, der festhält, wann während des Betriebs der Komponente Ereignisse eingetreten sind, die eine Zustandsänderung suggerieren. Das Auftreten dieser Ereignisse kann somit mitverfolgt (*tracking*) werden und mit weiteren Aktionen, wie dem Auslösen von Alarm-E-Mails, Maschinen-Not-Stopp, Instandsetzungsarbeiten oder einer Neubeschaffung der Komponente verknüpft werden. Die Einbindung des Modells in ein übergeordnetes Maschinen- oder Fabrikssystem wird im Rahmen dieser Arbeit nicht betrachtet.

Zugrunde liegende Forschungsfragen:

Nach den bereits in Abschnitt 2.4 herausgestellten Forschungsdefiziten werden folgende Forschungsfragen formuliert:

- I. Ist AE zur Überwachung der Verschleißursachen und zugehörigen Schadensbilder des Kugelgewindetriebs geeignet?
- II. Welche Methoden und Ansätze können für die Umsetzung eines unüberwachten CM-Systems auf Basis von AE-Daten ohne vorheriges Training verwendet werden?

- III. Wie kann eine Modellarchitektur für die Überwachung des Betriebszustands sowie die zeitliche Entwicklung von Zustandsänderungen aussehen?
- IV. Wie kann die Anzahl an Modellparametern reduziert werden und/oder durch Domänenwissen und datengetrieben bestimmt werden?

3.1 Vorgehensweise

Zum Erreichen der genannten Zielstellungen wird das in Abbildung 3-2 dargestellte Vorgehen verfolgt. Die Abbildung visualisiert die Arbeitspakete (AP) und ordnet diese den jeweiligen Kapiteln zu. Die Pfeile deuten die chronologische Bearbeitungsfolge an, wobei zwischen AP3 und AP4 iterativ die Erkenntnisse geteilt werden und in den Weiterentwicklungsprozess mit einfließen.

Auf Basis der in Kapitel 2.4 festgestellten Forschungsdefizite erfolgt in Abschnitt 3.2 die Festlegung der Systemgrenzen und notwendigen Definitionen im Kontext der Arbeit. Kapitel 4 stellt die Ergebnisse der Anforderungsanalyse vor (AP1). Darüber hinaus werden in Kapitel 4 mögliche Algorithmen und Ansätze aus dem Bereich des maschinellen Lernens analysiert und es wird eine systematische Vorauswahl geeigneter Verfahren vorgenommen. Ebenso werden Anforderungen an Mechanik und Messtechnik festgelegt.

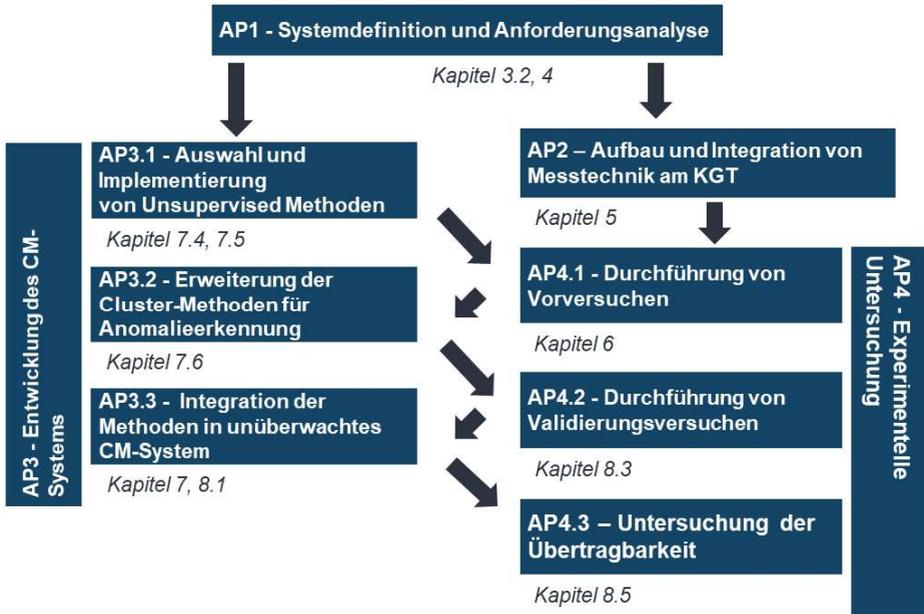


Abbildung 3-2: Aufteilung der Inhalte in Arbeitspakete

Aufbauend auf diesen Anforderungen und Randbedingungen werden in Kapitel 5 die Messkette und verschiedene Versuchsträger beschrieben, die für die Untersuchungen in dieser Arbeit verwendet werden (AP2). Das Arbeitspaket schließt mit der Beschreibung der Integration der Messtechnik in den KGT.

In AP3 wird die Entwicklung des Unsupervised Modells vorgenommen. Dazu gehört die Auswahl und Implementierung der zuvor ausgewählten Ansätze in AP1 und die Erweiterung dieser für den Zweck dieser Arbeit. Das gesamte Arbeitspaket (Kapitel 7) beschäftigt sich mit dem Aufbau des CM-Systems, um für den KGT eine Monitoringlösung zur Verfügung zu stellen. Dabei ist das Kapitel eng mit dem Vorgehen in AP4, der experimentellen Untersuchung, verknüpft. In einem iterativen Prozess werden neue Daten und Erkenntnisse aus den Versuchen genutzt, um Algorithmik und Systemaufbau zu verbessern und zu verifizieren. Hierzu fließen die Ergebnisse aus den Vorversuchen AP4.1 (siehe Kapitel 6) in die Absicherung der Messtechnik und deren Integration in den Kugelgewindetrieb ein (AP2). Weitere Versuchsreihen in AP4 dienen zur Verifikation und Validierung der entworfenen Machine Learning Methoden aus AP3. Die Validierungsergebnisse werden in Kapitel 8 beschrieben. Weiterhin werden

Untersuchungen zur Übertragbarkeit des Systems auf andere Anwendungsfälle in AP4.3 vorgenommen (siehe Abschnitt 8.5). Nach AP4 liegt ein Gesamtsystem zum unüberwachten Monitoring des KGT vor.

Die Beurteilung des neu entwickelten Ansatzes erfolgt in Kapitel 9. Die Arbeit schließt mit einer Zusammenfassung und einem Ausblick zu möglichen weiteren Forschungsthemen, die im Kontext des unüberwachten CM von KGT Zukunftspotenziale besitzen.

3.2 Systemgrenzen und -definitionen

Beim betrachteten Zielsystem handelt es sich um eine Vorschubachse auf Basis eines KGT, wie sie als klassische Linearachse in Produktionsmaschinen vorkommt. Der KGT wird zum Zweck der Überwachung mit einem AE-Sensorsystem ausgestattet. Das Sensorsystem dient primär zur Überwachung der Verschleißphänomene des KGT. Die Überwachung anderer Vorschubachsenelemente (z. B. Wälzlager oder Führungswagen) ist nicht Teil dieser Arbeit. Darüber hinaus wird nur das AE-Rohsignal bei der Signalverarbeitung berücksichtigt. Weitere Signale, wie Positions- und Drehzahlensignale aus den Antrieben, werden zunächst nicht mit in die Auswertung einbezogen. Sie dienen lediglich als sekundäre Signale zur Verifikation und Validierung des Gesamtsystems. Weitere Teile des Systems sind die messtechnische Verarbeitung der Rohsignale und ein Modul für die Auswertung der Rohdaten. Eine schematische Übersicht enthält Abbildung 3-3.

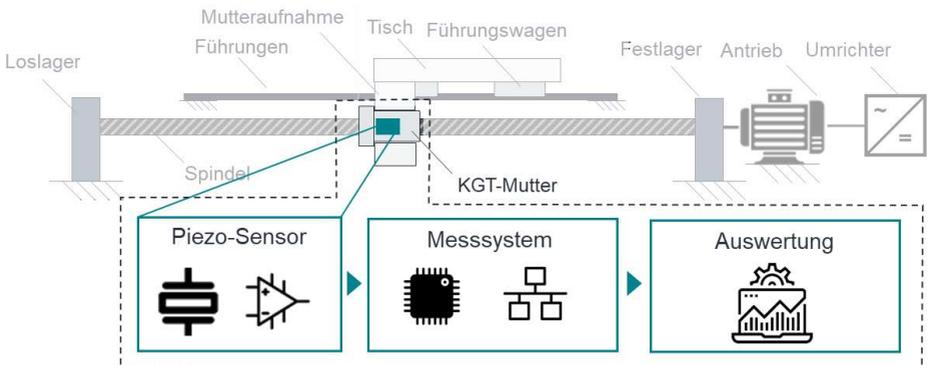


Abbildung 3-3: Schematische Darstellung der Systemgrenzen und Teilsysteme

In den vorhergehenden Abschnitten wurden die Begriffe *Anomalie*, *Zustandsänderung* und *Modellparameter (Hyperparameter)* genannt. Diese sollen im Folgenden für den Kontext der Arbeit definiert werden.

Die Anomalieerkennung ist ein bedeutendes Problem im Bereich der Datenwissenschaften und wurde bereits in vielen Disziplinen und Anwendungsfeldern untersucht. Es liegen einige allgemeine Definitionen für eine Anomalie im Bereich der Wissenschaft vor. Die Definition im Kontext dieser Arbeit stützt sich auf die Ausführungen von (Chandola, Banerjee & Kumar 2009).

DEFINITION 6. Anomalie

Eine Anomalie ist definiert als ein Muster, das nicht dem erwarteten normalen Verhalten entspricht. Dabei lassen sich drei grundsätzliche Formen der Anomalie unterscheiden.

Punktanomalie: Ein individueller Datenpunkt wird als anomal bezeichnet, da er sich vom Rest der Daten unterscheidet.

Kontextanomalie: Ein Datenpunkt wird als kontextuelle Anomalie bezeichnet, wenn er nur in einem bestimmten Kontext als anomal gilt. Dabei muss der Begriff des Kontexts als Teil der Problemformulierung mitgeliefert werden.

Kollektivanomalie: Wenn eine Sammlung von ähnlichen Datenpunkten anomal gegenüber dem gesamten Datensatz ist, spricht man von einer kollektiven Anomalie. Dabei ist der individuelle Datenpunkt allein nicht notwendigerweise anomal, sondern erst das gemeinsame Auftreten ergibt eine Anomalie.

Eine Anomalie tritt in dieser Betrachtung immer zeitlich diskret auf, d. h. zu einem festen Zeitpunkt. Die Definition macht hierbei keine Aussage über eine mögliche Evolution der Anomalie. Reale Systeme sind jedoch ständigen Änderungen und zeitlich kontinuierlichen Einflüssen ausgesetzt. An dieser Stelle werden deshalb weiterhin die Begrifflichkeiten Zustand und Zustandsänderung definiert, um einen Formalismus für die Beschreibung dieser Ereignisse zu erhalten.

DEFINITION 7. Zustand und Zustandsänderung

Ein System E^t zum Zeitpunkt t (en: entity) kann über seine einnehmbaren Zustände S_i^t (en: state) beschrieben werden.

$$E^t: \{S_i^t\}_1^N$$

Ein Systemzustand S_i^t zeichnet sich aus durch seine Verweildauer d_i und die Häufigkeit der Zustandsänderungen $p_{i,j}$ in einen (anderen) Zustand S_j^t

$$S_i^t: \{d_i, \sum_{i=1}^N \sum_{j=1}^N p_{i,j}\}$$

Im Sinne der Zustandsüberwachung ist die Aufgabe einer CM-Lösung das Erkennen von Systemzuständen bzw. explizit das Detektieren von Zuständen, die nicht erwünscht

sind. Der Begriff Zustand im Kontext sensorischer Überwachung beschreibt einen Zeitraum, in dem alle überwachten Größen ähnliche oder gleiche Merkmale aufweisen bei gleichen Randbedingungen und/oder Störeinflüssen. Für den Kontext von CM kann die Systembetrachtung auch als Sammlung von Systemzuständen und deren Änderung verstanden werden.

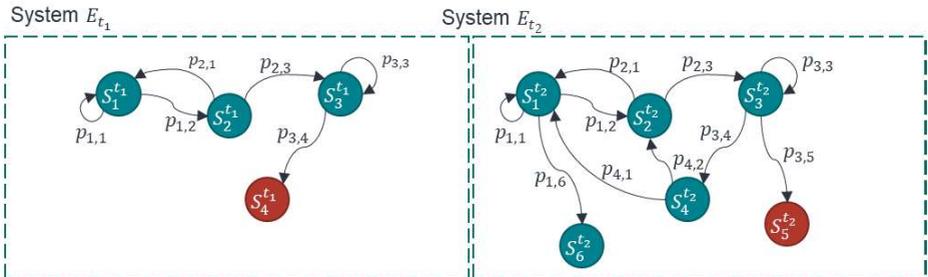


Abbildung 3-4: Abstrakte Beschreibung eines Systems zu unterschiedlichen Zeitpunkten

Die abstrakte Darstellung eines Systems nach DEFINITION 7 in Form von Zustandsübergangsdiagrammen gibt Abbildung 3-4 wieder. Das Bild zeigt ein System E zu zwei unterschiedlichen Zeitpunkten (links und rechts). Dieses System besteht aus Zustandsknoten S_i und die Kanten repräsentieren die Übergangshäufigkeiten $p_{i,j}$. Zu Beginn besitzt das System vier Zustände (Knoten), wobei S_4 rot als Anomalie bzw. unbekannter Zustand markiert ist. Befindet sich ein System wiederholt oder wechselt häufig in einen zuvor unbekanntem Zustand, so kann dieser Zustand über die Zeit auch zu einem bekannten bzw. erlaubten Systemzustand werden. Im zweiten Zeitschritt ist der Zustand bereits als bekannt deklariert worden, weil es häufige Wechsel von anderen bekannten Zuständen in diesen Zustand gab. Darüber hinaus können sich neue Zustände (S_6) oder Anomalien (S_5) ausbilden. Neue Zustände liegen somit zunächst immer als Anomalie vor, werden aber mit zunehmender Eintrittshäufigkeit zu stabilen Zuständen. Im Kontext dieser Arbeit wird zudem die Anomalie ausgeschlossen, wenn reversible Zustandsänderungen vorliegen. (Beispiel: Für den Übergang von S_1 zu S_2 in Abbildung 3-4 liegen Häufigkeiten $p_{i,j} > 0$ vor. Der Übergang kann somit bidirektional bzw. reversibel stattfinden.)

Aktuelle Bestrebungen im Bereich Maschinelles Lernen zielen auf eine automatisierte und selbstkonfigurierende Lernstrategie ab. Hierzu kann die automatisierte

Hyperparametersuche einen Teil beitragen (Claesen & Moor 2015). In der Anwendung entsteht dadurch weniger Aufwand in der Inbetriebnahme und erleichtert Laien den Zugang zu performanten Modellen, ohne dass Expertenwissen notwendig wird. Insbesondere die Wahl von Hyperparametern und Architekturen bei Neuronalen Netzen stellt unerfahrene Nutzer aufgrund der Vielzahl an Einstellmöglichkeiten vor Herausforderungen. Für die optimale Wahl von Hyperparametern (Tuning) und der Architektur greifen sogenannte AutoML (en. *automated machine learning*) Pipelines auf verschiedene Optimierungsalgorithmen zurück. Es handelt sich zumeist um Brute-Force oder zufallsbasierte Ansätze, die offline ausgeführt werden, da sie viel Zeit beanspruchen (He, Zhao & Chu 2021). Die Ansätze setzen meist voraus, dass alle Trainingsdaten zu Beginn der Optimierung zur Verfügung stehen. Im Kontext von CM-Anwendungen sind diese Ansätze daher weniger geeignet.

DEFINITION 8. Hyperparameter

Hyperparameter bezeichnen Parameter eines Modells (besonders Maschinelles Lernen), die vor dem Modelltraining gewählt werden. Hyperparameter werden zumeist manuell festgelegt und nehmen Einfluss auf die Modellgüte und -performanz.

Im Kontext dieser Arbeit werden Ansätze untersucht, die ohne vorheriges Wissen oder vorangegangene Trainingsphase eine *hyperparameterfreie Anomalieerkennung* (siehe Abbildung 3-1) ermöglichen. Darunter wird ein Konzept verstanden, das die Anzahl festzulegender Hyperparameter für das Modell verringert. Ein absoluter Verzicht bzw. die Eliminierung aller Hyperparameter wird nicht angestrebt und ist möglicherweise gar nicht erreichbar. Vielmehr soll die Anzahl der Hyperparameter reduziert werden. Es sollen keine weiteren Hyperparameter für die verwendeten Modelle eingeführt und notwendige Hyperparameter entweder datengetrieben oder durch Einsatz von Domänenwissen bestimmt werden. Damit entstehen Modelle, die kein aufwendiges Training bzw. keine umfangreiche Konfiguration benötigen.

4 Anforderungsanalyse

Anhand der in Abbildung 3-3 dargestellten Teilsysteme werden nachfolgend Anforderungen an die CM-Applikation festgelegt. Im weiteren Verlauf der Arbeit wird beurteilt, ob diese Anforderungen erfüllt werden. Das Kapitel untergliedert sich in die Abschnitte Messkette, digitale Signalverarbeitung und CM-System.

4.1 Anforderungen an die Messkette

Das erste Element der Messkette sind AE-Piezo-Sensoren. Prinzipiell sind auch andere Wandlerprinzipien für die Erfassung von AE denkbar. In Tabelle 4-1 werden die Anforderungen im Kontext Gesamtsystem an die Piezo-Sensorelemente beschrieben. Bei der Auswahl eines geeigneten Sensors müssen die spezifischen Vor- und Nachteile entsprechend der Tabelle in Anhang A 15 berücksichtigt werden. Der piezo-elektrische Wandler erfüllt die Voraussetzungen am besten. Ausschlaggebende Kriterien für die Auswahl sind Baugröße, Bandbreite und Empfindlichkeit.

Da bei den Piezo-Elementen nur sehr kleine Ausgangsspannungen entstehen, müssen diese verstärkt werden. Zur Vorverstärkung kommen geeignete kommerzielle Lösungen zum Einsatz. Prinzipiell können sowohl Ladungs- als auch Spannungsverstärker verwendet werden. In den nachstehenden Tabellen 4-1 und 4-2 werden die Anforderungen aufgeführt.

Tabelle 4-1: Anforderungskriterien an Piezo-Sensoren

Kriterium	Beschreibung
Bauform	- Schraub- oder Klemmfixierung - Optional: Klebung
Bauraum	- Platzsparendes Design für Unterbringung direkt an oder in KGT-Mutter
Genauigkeit/Sensitivität	- Möglichst lineares Übertragungsverhalten über gesamte Bandbreite
Schnittstellen	- Standardisierter Verbinder (z. B. BNC) für Kompatibilität mit Messequipment
Bandbreite	- Hohe Bandbreite, um großes Signalspektrum übertragen zu können

Tabelle 4-2: Anforderungskriterien an Vorverstärker

Kriterium	Beschreibung
Einstellbare Bandbreite	<ul style="list-style-type: none"> - Einstellbare Filter (Tief-, Hoch- oder Bandpass) - Mindestanforderung: Bandbreite 1 MHz
Verstärkung	<ul style="list-style-type: none"> - Mindestanforderung: 60 dB Verstärkung (Verstärkungsfaktor 1000) - Einstellbare Verstärkungsstufen
Bauform	<ul style="list-style-type: none"> - Portables Gerät - Platzsparendes Design für Anbringung direkt an Maschinenschlitten
Schnittstellen	<ul style="list-style-type: none"> - Einheitliche Verbindungsschnittstelle (z. B. BNC) - Mehrere Kanäle - 24 V Versorgungsspannung

4.2 Anforderungen an die digitale Signalverarbeitung

Bei der Erfassung von hochfrequenten AE-Daten ist die Analog-zu-Digital-Wandlung (ADC) besonders relevant. Speichertiefe und Abtastrate sind zwei wichtige Kriterien, die beim Transfer der Daten und ihrer kontinuierlichen Verarbeitung bedeutsam sind. Im Bereich von mehreren Megahertz entstehen Datenströme mit hohem Datendurchsatz, die über ein entsprechendes Bussystem an den Zielcomputer zur Verarbeitung übertragen werden müssen. Zudem ist die notwendige Rechenleistung für nachgelagerte Vorverarbeitungs- und Modellierungsschritte zu berücksichtigen. Solche Messsysteme können auf mehrere Geräte verteilt werden, sodass die ADC-Funktion durch einen Microcontroller gelöst werden kann und die zusätzliche Rechenkapazität mit einem Edge-PC oder Industrie-PC abgebildet wird. Gängige Schnittstellen zwischen diesen Systemen können USB und Ethernet, aber auch kabellose WLAN-Lösungen sein. Zum anderen gibt es auch Komplettlösungen, die analoges Frontend, ADC, Verarbeitung und Programmierumgebung für den Nutzer bereitstellen. In Tabelle 4-3 sind die Anforderungen an die digitale Signalverarbeitung (DSP) zusammengetragen.

Tabelle 4-3: Anforderungen an Messsystem und Digitale Signalverarbeitung

Kriterium	Beschreibung
Samplingrate	- mind. 1 MHz
Speichertiefe	- 12-24 bit
Kommunikationsprotokoll	- PC-basierte Kommunikation (USB oder Ethernet)
Analog-Input	- Standard-Schnittstelle (z. B. BNC) - Mehrere Kanäle
Nutzerschnittstelle	- Application Programming Interface (API) oder OpenSource
Datenverarbeitung	- Kontinuierlicher Rohdatenstream - Gebufferte Samples - Getriggerte Messung

4.3 Anforderungen an das Condition-Monitoring-System

In Abschnitt 2.3.3 wurden bereits Herausforderungen an autonome CM-Systeme aufgeführt. Zusätzliche Anforderungen, die aus der Kombination von AE und KGT entstehen, werden in Tabelle 4-4 beschrieben.

Tabelle 4-4: Anforderungen an die Auswertungs- und Überwachungslösung

Kriterium	Beschreibung
Messgröße	- Nur ein Rohdatensignal (AE) - Keine Kontextinformation
Modellausgabe	- Erkennen von Betriebszuständen und Anomalien (wiederkehrende Ereignisse vs. Ausreißer) - Mehr als eine Ausgabeklasse (Normal und Anomalie) möglich
Dimensionalität	- Hohe Kompressionsrate notwendig aufgrund großer Datenmenge und langer Überwachungszeiträume
Adaptivität/Flexibilität	- Funktion ist unabhängig von Sensorplatzierung und Baugröße/Bauform des KGT zu gewährleisten.
Rauschen/Ausreißer	- Signalverarbeitung muss mit verrauschten AE-Daten umgehen können. Ausreißer müssen vom Algorithmus erkannt werden.
Hyperparameter	- Geringe Anzahl an Hyperparametern
Automatisierungsgrad	- Automatisierte Konfiguration mit Hilfe von Daten und/oder Domänenwissen
Online-Fähigkeit	- Training und Prädiktion sollen während des Betriebs stattfinden.

Die Integration zusätzlicher Messsysteme ist grundsätzlich mit erhöhtem Aufwand verbunden: Die Sensorik muss untergebracht, Kabel müssen verlegt und die Datenverarbeitung und Auswertung müssen programmiert bzw. zur Verfügung gestellt werden. Dieser Aufwand steigt mit zunehmender Anzahl an Sensoren und zu synchronisierenden Datenquellen. Wenn zusätzliche Kontextinformationen für die Auswertung benötigt werden, erhöht sich der Integrationsaufwand software- und elektronikseitig weiter. Je weniger Sensoren und Systemschnittstellen gebraucht werden, desto einfacher wird die Integration und desto höher wird die Anwenderakzeptanz.

Da es sich beim zu entwickelnden System um eine unüberwachte ML-Strategie handelt, werden nicht direkt Klassifikationen oder Schadensbildzuordnungen als Ergebnis geliefert, sondern lediglich Zustandsänderungen und Anomalien detektiert. Dennoch soll eine größtmögliche Detektionsgüte bzw. Aussagequalität erreicht werden. Diese soll sichergestellt werden durch die Detektion von den Systemzuständen, selbst wenn diese nicht im Vorfeld bekannt sind. Beispielsweise soll durch das CM-System festgestellt werden, wenn das System im Laufe der Überwachung von einem Zustand in den nächsten übergeht.

Am Beispiel des Wechsels zwischen Drehzahlbereichen bedeutet dies: Die Information, dass es sich bei dem ersten Zustand um die Operation in einem bestimmten Drehzahlbereich handelt und im zweiten Zustand die Drehzahl erhöht wird, kann das System nicht liefern. Das System stellt jedoch fest, dass eine Änderung von Drehzahl 1 auf 2 stattfindet. Vorrangig sollen (abstrakte) Zustandsübergänge und das Auftreten von Anomalien detektiert werden. Ein geeignetes Modell für den Umgang mit Ausreißern ist hierfür unabdingbar.

Für CM-Systeme im Bereich von WZM bzw. KGT sind lange Beobachtungszeiträume notwendig, da unter den richtigen Voraussetzungen lange Betriebsdauern (Monate und Jahre) entstehen. Demzufolge müssen verwendete Modelle Fähigkeiten zur Verfügung stellen, die eine Langzeitspeicherung der systembeschreibenden Merkmale ermöglichen. Dies stellt einen Zielkonflikt zwischen möglichst geringen Rohdatenmengen und deren Vorhaltung und drohendem Informationsverlust, wenn Daten zu früh verworfen werden, dar. Eine Anforderung an das CM-System ist es daher, ein Modell mit entsprechend guter Kompressionsrate bei geringem Informationsverlust bereitzustellen.

Für die bestmögliche Anwenderakzeptanz müssen CM-Systeme mit möglichst geringem Konfigurationsaufwand (Hyperparameter) bzw. automatisierter Parametrierung

zur Verfügung gestellt werden. Auch bei einem Systemwechsel oder sich ändernden Einsatzszenarien soll die Systemfunktion gewährleistet bleiben. Zusätzlich kann Domänenwissen über die Anwendung mit in die Parametrierung der Systeme einfließen. Wenn vorhanden, können so verbleibende Hyperparameter besser eingestellt oder es kann ganz auf sie verzichtet werden. Ein entsprechendes Vorgehen wird in Abschnitt 7.3 vorgestellt.

Der geringe Aufwand für die Nutzer wird dabei auch durch die Onlinefähigkeit des Systems gefördert. Durch Wegfallen von aufwendiger Datenvorbereitung und Offline-Modeltraining steht ein solches System unmittelbar nach der Installation zur Verfügung.

5 Versuchsträger für die Untersuchung mit Acoustic Emission

Um die Nutzbarkeit von AE für die Zustandsüberwachung von Wälzkörperkontakten zu untersuchen, werden in diesem Kapitel die verwendeten Versuchsträger vorgestellt. Hierbei handelt es sich um Messtechnik, Prüfstände für Vorversuche (Axiallager) und Vorschubachsenprüfstände für die Verschleißuntersuchung von KGT.

5.1 Verwendete Acoustic Emission Messkette

Auf Basis der im vorherigen Kapitel aufgeführten Anforderungen an die Messkette wird hier das Messsystem vorgestellt, das im Rahmen dieser Arbeit verwendet wird.

Die vollständige Messkette ist schematisch in Abbildung 5-1 dargestellt. Sie besteht aus den Sensorelementen (in diesem Fall Piezosensoren), dem Ladungsverstärker und einem Microcontroller-basierten Datenlogger (hier: USB-DUXfast). Um die erfassten Signale für die Signalverarbeitung und Modellierung zur Verfügung zu stellen, wird der Datenlogger per USB ausgelesen. Beim verwendeten Datenlogger muss als Betriebssystem Linux verwendet werden. Es wird darum zusätzlich ein Industrie-PC mit Windows genutzt, der mit einem Linux-basierten Edge Gerät über Ethernet die Rohdaten austauscht. Der zusätzliche Computer dient ebenfalls zur Kommunikation und Steuerung des Prüfstands und kann je nach Anwendung auch wegelassen werden. Zur Auswahl für die Sensorelemente werden die Sensoren in Anhang A 7, Anhang A 8, Anhang A 9 und Anhang A 10 betrachtet. Die Ergebnisse der Vorversuche zur Eignung dieser Sensorelemente für die vorliegende Untersuchung werden in Abschnitt 5.5 vorgestellt.

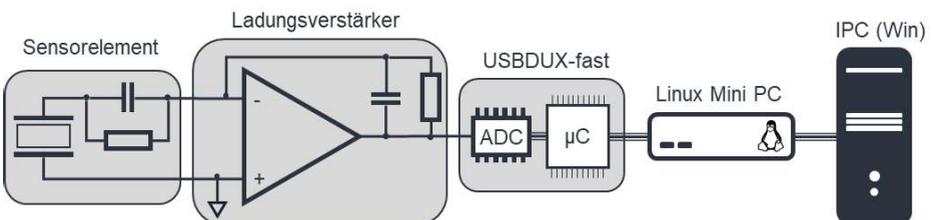


Abbildung 5-1: Verwendete Messkette zur Aufzeichnung von Acoustic Emission

Prinzipiell können die Sensorelemente in Foliensensoren und Gehäusesensoren unterschieden werden. Verschiedene Baugrößen und Formen werden auf grundsätzliche Eignung untersucht.

Die Ausgangsspannung dieser Sensorelemente muss für die digitale Erfassung verstärkt werden. Hierzu wird ein passender Verstärker der Fa. Mistras genutzt, das zugehörige Datenblatt ist in Anhang A 6 zu finden. Dieser Verstärker besitzt neben drei einstellbaren Verstärkungsstufen auch noch einsetzbare Bandpassfilter. In den Messungen dieser Arbeit wird ein Filter von 10 kHz bis 1 MHz verwendet.

Im Rahmen der Arbeit wird eine sowohl kostengünstige als auch offene Lösung für die Erfassung der AE-Daten genutzt. Kommerziell erhältliche Datenerfassungssysteme für Datenraten im Megahertz-Bereich sind mit hohen Kosten verbunden und erhöhen die Einstiegshürde für die AE-Messung an kostengünstigen bzw. Standardkomponenten wie dem KGT. Eine ausführliche Betrachtung relevanter Messtechnik fand innerhalb der Abschlussarbeit von (A_Meyer-Garcia 2018) statt.

Gemäß Abschnitt 4.2 können die Kriterien der Anforderungsanalyse für die AE-Messkette wie in Tabelle 5-1 bewertet werden. Mit + wird hierbei die vollständige Erfüllung, mit o eine teilweise Erfüllung und mit - ein nicht erfülltes Kriterium dokumentiert.

Tabelle 5-1: Erfüllung der Anforderungen bezüglich der AE-Messkette

Teilsystem	Kriterium	Beschreibung	Erfüllung (+ o -)
Verstärker	Einstellbare Bandbreite	- Einstellbare Filter (Tief-, Hoch- oder Bandpass)	+
Verstärker	Verstärkung	- Mindestanforderung: 60 dB Verstärkung (Verstärkungsfaktor 1000) - Einstellbare Verstärkungsstufen	+
Verstärker	Bauform	- Portables Gerät - Platzsparendes Design für Anbringung direkt an Maschinenschlitten	+
Verstärker	Schnittstellen	- Einheitliche Verbindungsschnittstelle (z. B. BNC)	+
DSP	Samplingrate	- mind. 1 MHz	+
DSP	Speichertiefe	- 12-24 bit	+
DSP	Kommunikationsprotokoll	- PC-basierte Kommunikation (USB oder Ethernet)	+
DSP	Analog-Input	- Standard-Schnittstelle (z. B. BNC) - Mehrere Kanäle	o +
DSP	Nutzerschnittstelle	- API oder OpenSource	+
DSP	Datenverarbeitung	- Kontinuierlicher Rohdatenstream - Gebufferte Samples - Getriggerte Messung	+
			+
			-

Für das Teilsystem Verstärker können die gestellten Anforderungen mit der Auswahl des Vorverstärkers erfüllt werden. Auch für das Teilsystem DSP können die meisten Anforderungen abgedeckt werden. Die Standardschnittstelle mit BNC konnte durch eine Adapterschaltung nachgerüstet werden, um die Kompatibilität zum Verstärker sicherzustellen. Die einzige fehlende Funktionalität ist die getriggerte Messung. Diese ist hardwareseitig mit dem USB-DUXFast verfügbar und ist nur softwareseitig nicht umgesetzt.

Messungen mit dieser Messkette finden auf den nachfolgend beschriebenen Prüfständen statt.

5.2 1-Achs-Axiallager-Prüfstand

Dieser Prüfstand dient zur Untersuchung von Wälzkontakten unter Last und mit verschiedenen Drehzahlen. Als Versuchsobjekte werden Axial- oder Schrägkugellager genutzt, die in einer rotatorisch verdrehbaren und einer translatorisch verschiebbaren Aufnahme gelagert werden. Ein Pneumatikzylinder ermöglicht in diesem Aufbau das Aufprägen von Belastungen (max. 12 kN) im Betrieb. Ein Schrittmotor am Ende der drehbar gelagerten Welle erzeugt das notwendige Drehmoment (max. 14 Nm bei 300 U/min) für die Drehbewegung des Lagers. Der einfache Aufbau ermöglicht eine gute Zugänglichkeit des Wälzkontaktes. Durch Anheben des Zylinders lassen sich beispielsweise bei Verwendung von Axiallagern die beiden Lagerhälften visuell inspizieren. Steuerungsseitig ermöglicht die verwendete Hardware in Form eines Pixtend (<https://www.pixtend.de/>) sowohl den drehzahlgesteuerten Betrieb als auch eine Positionssteuerung, die einen Schwenkbetrieb bewerkstelligt.

Zusätzlich wird innerhalb der oberen Lageraufnahme ein AE-Sensor untergebracht, der das Aufzeichnen von AE in unmittelbarer Nähe des Wälzkontaktes erlaubt (siehe Abbildung 5-2 Mitte). Die Datenquellen für den Versuchsträger sind in Tabelle 5-2 angegeben. Die auf dem Prüfstand durchgeführten Versuchsreihen werden in Kapitel 6.2 näher erläutert.

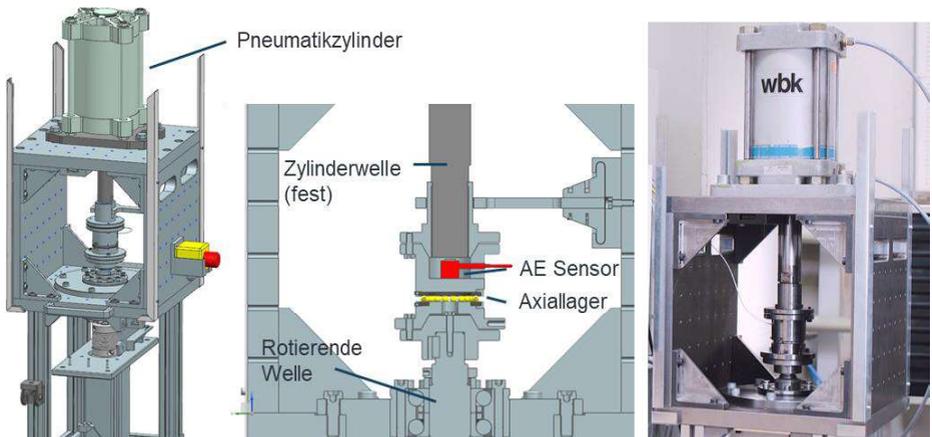


Abbildung 5-2: CAD-Modell des Axiallagerprüfstands (links), Schnittbild der Sensoranbringung (Mitte) und realer Aufbau (rechts) (A_Detroy 2020; A_Osen 2020)

Tabelle 5-2: Datenquellen von Versuchsträger 1-Achs-Axiallager

Sensor	Gerät und Datenquelle (Hersteller)
Axialkraft aus Druckregler 0-6 bar	Pixtend-Steuerung mit Analogklemme
Drehzahl des Schrittmotor-Encoders	Pixtend-Steuerung mit Analogklemme
AE-Sensor	USB-DuxFast

5.3 2-Achs-KGT-RZA-Prüfstand

Dieser Aufbau basiert auf den Arbeiten von (Ehrmann 2019). Hierbei wurde ein Ritzel-Zahnstangen-Antrieb (RZA) als lineare Vorschubachse ebenfalls mit AE untersucht. Die Konstruktion wurde im Rahmen der vorliegenden Arbeit um eine weitere Vorschubachse in Form eines KGT ergänzt. Steuerungsseitig werden die KGT-Achse als Positionierachse und der RZA momentengeregelt betrieben. In diesem Aufbau kann für den KGT eine dynamische Last durch die zweite Achse simuliert werden. Es können bis zu zwei RZA installiert werden (siehe Abbildung 5-3 links), die sich elektrisch verspannen lassen, um die Genauigkeit und Steifigkeit zu erhöhen. Im Versuchsaufbau für die vorliegende Arbeit wird nur ein RZA benötigt (maximale Vorschubkraft von 3 kN). Als Erweiterung für den Prüfstand wurde in (A_Schwab 2021) ein Modul zur Steifigkeits- und Reibmomentenmessung aufgebaut. Mit Hilfe der Messaufbauten können die mechanischen Kennwerte des KGT aufgezeichnet und später mit den AE-Messungen korreliert werden.

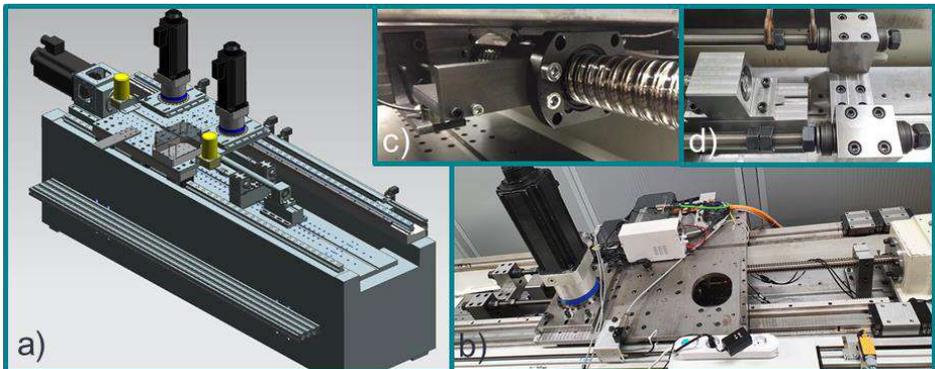


Abbildung 5-3: CAD-Modell des Prüfstands 2-Achs-KGT-RZA in a) und realer Aufbau in b)-d)

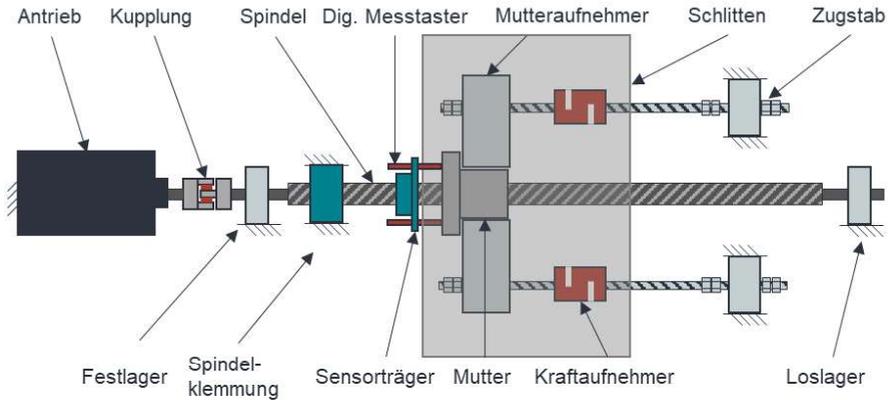


Abbildung 5-4: Prinzipskizze der Steifigkeitsmessung

Die Umbaumaßnahme und Prüfstandserweiterung fand im Rahmen des DFG-Projektes 388141462 statt (DFG 2017). Die ausgewählten Kraftaufnehmer von HBK (Anhang A 11) ermöglichen die Messung von Druck- und Zugkräften. Der Aufbau mit Gewindestangen als Zugstäbe ermöglicht die Beaufschlagung der KGT-Mutter mit Kräften in beide Richtungen, um eine Weg-Kraft-Kurve für die Steifigkeit zu erfassen (siehe Abbildung 5-4). Die Verlagerung aufgrund der axialen Belastung wird mit digitalen Messtastern (GT2-P12K) von Keyence GmbH erfasst.

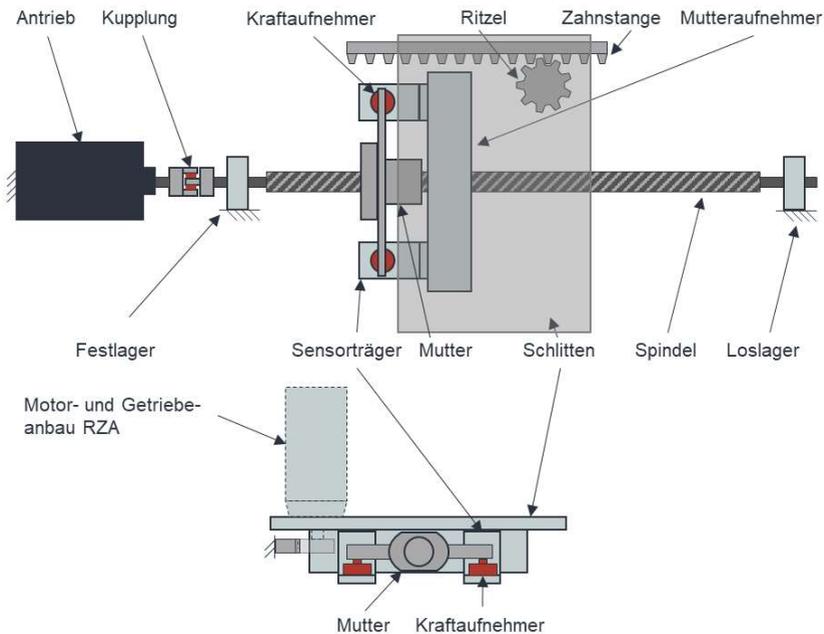


Abbildung 5-5: Prinzipskizze der Reibmomentmessung

Das Reibmomentenmesssystem besteht aus zwei Sensorhalterungen mit weiteren Kraftaufnehmern von HBK (Anhang A 11), die symmetrisch um die Mutter angeordnet sind. An der Mutter sind jeweils zwei Hebelarme befestigt, die bei Rotation der Spindel auf den jeweiligen Kraftaufnehmer drücken. Über den definierten Hebelarm können darüber die Leerlaufdrehmomente des KGT erfasst werden. Um die Translationsbewegung der Mutter bei Drehung der Spindel auszugleichen, kann die RZA-Achse benutzt werden, um den Schlitten mit den Sensorhalterungen mitzubewegen (siehe Abbildung 5-5). Die Datenquellen für den Versuchsträger sind in Tabelle 5-3 angegeben.

Tabelle 5-3: Datenquellen für Versuchsträger 2-Achs-KGT-RZA

Sensor	Gerät und Datenquelle (Hersteller)
Kraftsensoren bis 50 kN	Ethernet-Datenlogger (HBK)
Kraftsensoren bis 200 N	Ethernet-Datenlogger (HBK)
Digitale Messtaster	Ethernet-Datenlogger (Keyence)
AE-Sensor	USB-DUXFast
Motorstrom Antrieb	Antriebsdaten aus Steuerung (Beckhoff)
Position (Glasmaßstab)	Antriebsdaten aus Steuerung (Beckhoff)

Die KGT für diesen Prüfstand werden manuell nach Herstellerangabe gefettet (z. B. mit Dynalub 510 von Bosch Rexroth AG, siehe Anhang A 4) oder mit zusätzlich zu installierendem Schmierstoffgeber versorgt. Der RZA wird ebenfalls über einen Schmierstoffgeber versorgt. Eine detaillierte Herleitung für das Konzept und den Aufbau der Messtechnik ist in (A_Schwab 2021) aufbereitet.

5.4 5-Achs-Prüfstand

Ein weiterer Aufbau für die Untersuchung des Verschleißverhaltens von KGT ist der Lebensdauerprüfstand in Abbildung 5-6. Dieser Prüfstand geht auf Arbeiten von (Schopp 2009) zurück, der den Ermüdungverschleiß mit Hilfe von Luftschall- und Beschleunigungssensoren untersuchte. Für die vorliegende Arbeit wurden die Prüfstandmechanik und Steuerungshardware überholt und es wurde eine neue Sensorik für die Erfassung von Last und Temperatur installiert. Insgesamt kann der Prüfstand fünf Spindeln mit jeweils zwei gegeneinander verspannten Muttern aufnehmen. Diese lassen sich jeweils paarweise mit einer definierten axialen Last im Bereich von 0 bis 80 kN beaufschlagen. Spindeldrehzahlen bis 2000 U/min sind erreichbar.

Die konstruktive Ausführung des Prüfstands (siehe Abbildung 5-7) ermöglicht die symmetrische Krafteinleitung der axialen Belastung in die KGT. Die Spindellagerung muss daher nur Reibmomente und Beschleunigungskräfte aufnehmen. Während der Versuche werden die in Tabelle 5-4 aufgeführten Sensoren von Datenloggern erfasst und für die Offline-Verwendung in CSV-Dateien gespeichert. Die Abtastperiode kann auf bis zu 30 ms oder höher eingestellt werden.

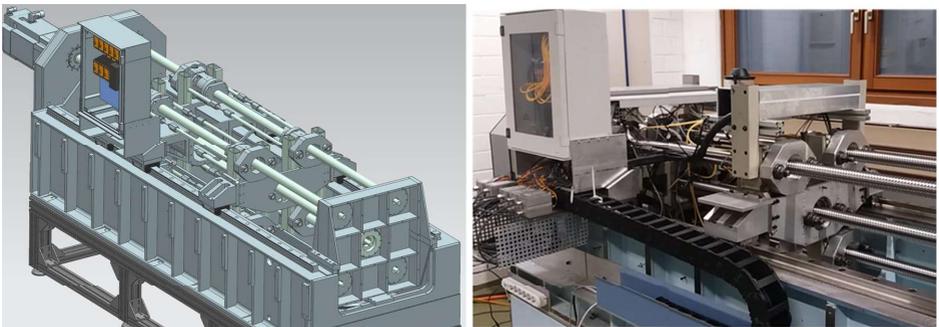


Abbildung 5-6: CAD-Modell des 5-Achs-KGT-Prüfstands (links) und realer Aufbau (rechts)

Tabelle 5-4: Datenquellen für Versuchsträger 5-Achs-KGT

Sensor	Gerät und Datenquelle (Hersteller)
Dehnmessstreifen und Verstärker	QuantumX über UDP (HBK)
Temperatursensorik	VSE100 über OPC DA (ifm diagnostics)
Beschleunigungssensorik	VSE100 über OPC DA (ifm diagnostics)
Motorstrom Antrieb	S7-1500 über OPC UA (Siemens)
Position (Drehgeber Motor)	S7-1500 über OPC UA (Siemens)
Drehzahl (Spindel)	S7-1500 über OPC UA (Siemens)
Zyklenzähler	S7-1500 über OPC UA (Siemens)

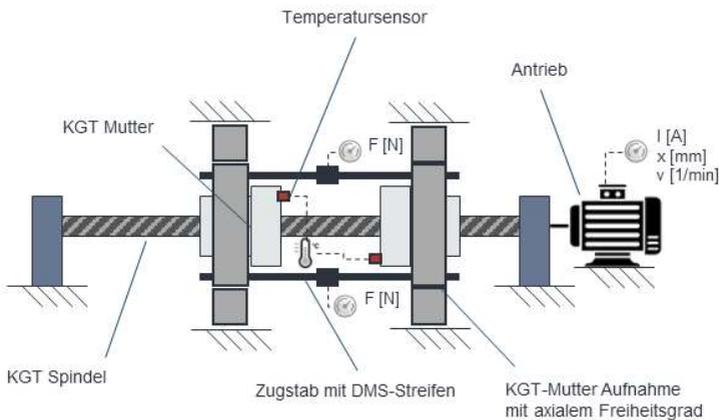


Abbildung 5-7: Prinzipskizze der KGT-Mutteraufnahme des 5-Achs-Prüfstands

Zur Schmierung der Muttern wird eine zentrale, intervallgesteuerte Schmierpumpe eingesetzt. Bei Bedarf und unterschiedlichen Belastungen pro Spindel können weitere Pumpen installiert werden. Es handelt sich um eine automatische Nachschmierung nach Herstellervorgabe. Bei den Versuchen dieser Arbeit wird mit dem Fließfett Divinol Lithogrease 000 gearbeitet (siehe Anhang A 5).

5.5 Aufbau und Integration der Messtechnik am Kugelgewindeantrieb

Für die Integration von AE-Sensorik am KGT bzw. später für mehrere Achsen in der Werkzeugmaschine müssen verschiedene Anforderungen erfüllt werden.

Für die einfache Installation in Prüfständen mit Vorschubachsen bzw. später in Werkzeugmaschinen ist die Aufteilung von Verstärker und digitaler Signalverarbeitung auf

zwei Geräte sinnvoll. So können in direkter Nähe zum Sensor Verstärker auf den Maschinenschlitten platziert werden, um die unverstärkte Kabellänge so kurz wie möglich zu halten. Signalstörungen und -verluste können so vermieden werden. Gleichzeitig kann jede Achse mit Sensor und Verstärker an einen zentralen Datenlogger angeschlossen werden. Dieser Systemaufbau erfüllt demnach auch die Anforderung der mehrkanaligen Aufzeichnung, die in Tabelle 4-3 genannt ist.

Ergebnisse aus den Vorversuchen, die später in Abschnitt 6.1 vorgestellt werden, ergeben die Notwendigkeit der Sensornähe zur Signalquelle. Im Rahmen der Arbeit werden daher drei Installationsmöglichkeiten (siehe Abbildung 5-8) untersucht. In der Grafik sind drei Alternativen angedeutet (*Sensor0*, *Sensor1* und *Sensor2*). Mit *Sensor0* kommt der aktuelle Stand der Technik für Vibrationssensoren zur Anwendung. Die Befestigung erfolgt meist über ein Gewinde, das auch am KGT-Mutterflansch vorgesehen werden muss. Stellvertretend für diese Art der Installation können VSP001-Sensoren der Firma ifm genutzt werden (<https://www.ifm.com/de/en/product/VSP001>).

Die Installation mit *Sensor1* wird bereits in der Publikation von (Nurudeen Alegeh et al. 2020) verwendet. Diese Installation wird in der vorliegenden Arbeit durch die Annäherung an die Signalquelle (Laufbahnkontakt zwischen Kugel und Mutter bzw. Spindel) verbessert. Durch Anbringen eines erodierten Absatzes auf der Mutteraußenfläche wird der Abstand zwischen Sensor und Signalquelle verringert.

Mit *Sensor2* wird eine Erweiterung untersucht, die die unmittelbare Auswertung am Signalursprung erlaubt.

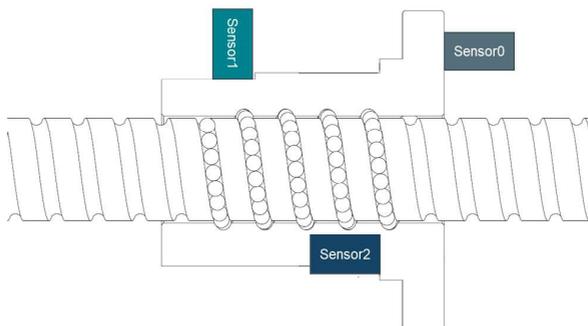


Abbildung 5-8: Alternative Installationsmöglichkeiten für AE-Sensorelemente

Das Sensorelement wird hierfür in einer Tasche untergebracht, durch deren Materialentfernung die Tragfähigkeit des KGT nicht beeinträchtigt wird. Die Installation geht auf ein Patent (Kathan 2017) zurück (siehe Abbildung 5-9). Im Patent wird die Anwendung mit DMS-Sensorik und Piezo-Sensorik vorgeschlagen. Für die DMS-Applikation wird am Markt bereits das *Guard-Plus* System der Firma August Steinmeyer geführt (Veith et al. 2020). Eine publizierte Verwendung mit AE-Sensoren liegt nicht vor. Auf Basis dieser Möglichkeiten werden die nachstehenden Konstruktionen in die Versuchsträger integriert. Die Installation mit *Sensor1* wird für beide KGT-Prüfstände realisiert. In Abbildung 5-10 und Abbildung 5-11 ist jeweils auf der linken Seite das CAD-Schnittbild die Konstruktion dargestellt und auf der rechten Seite eine reale Aufnahme des Prüfstands.

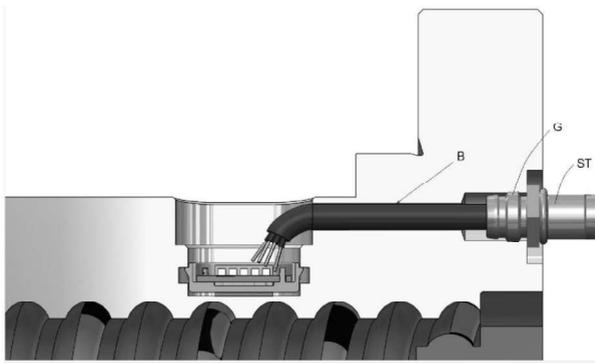


Abbildung 5-9: Schnittbild der Sensoranbringung im Patent (Kathan 2017)

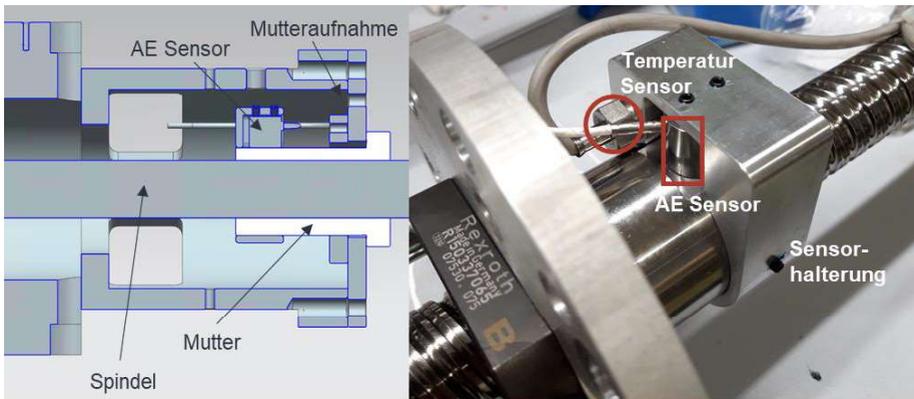


Abbildung 5-10: Installation nach Sensor1 am Versuchsträger 5-Achs-KGT

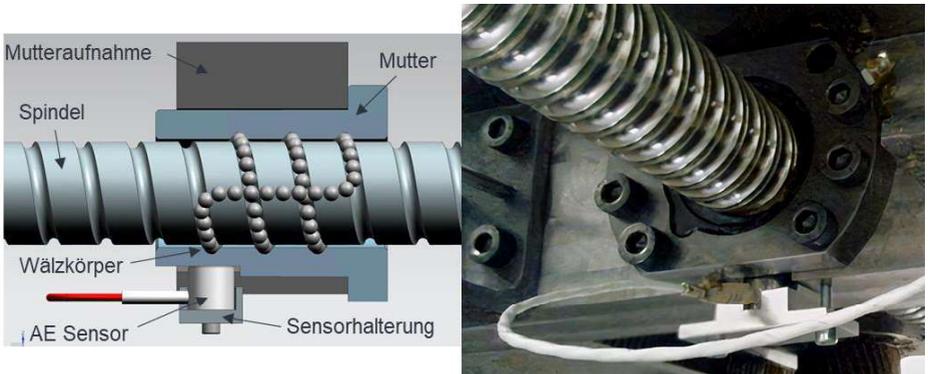


Abbildung 5-11: Installation nach Sensor1 am Versuchsträger 2-Achs-KGT-RZA

Bei beiden Sensorhalterungen handelt es sich um einfache Klemmverschraubungen, die das Sensorelement auf die planare Aussparung an der Mutteraußenfläche drücken. Diese Form der Anbringung ermöglicht auch für nachträgliche Installationen eine einfache Integration, wenn eine entsprechende Aussparung an der Mutter angebracht wird.

Abbildung 5-12 zeigt die Realisierung des Patents für einen AE-Sensor in CAD. Für die Unterbringung in der Tasche kommen nur Sensoren mit kleinen Abmaßen in Betracht (Anhang A 9). KGT mit Taschenaussparung sind auch nur für bestimmte Baugrößen beim Hersteller August Steinmeyer verfügbar. Die Installation für *Sensor2* findet deshalb nur für die KGT-Baugröße in Anhang A 3 statt. Dafür werden die KGT mit eingelassener Tasche vom Hersteller bezogen und nachträglich mit AE-Sensor versehen, der über Klebeverbindung und Sensorhalterung fixiert wird.

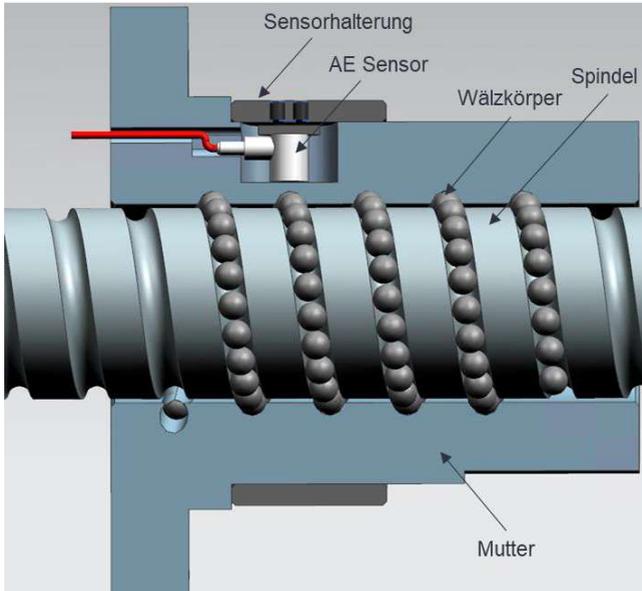


Abbildung 5-12: Installation nach Sensor2 am Versuchsträger 5-Achs-KGT

Zur Bewertung der Anforderungserfüllung werden Ergebnisse aus Abschnitt 6.1 und den zuvor vorgestellten Sensorinstallationen aus diesem Abschnitt genutzt und in der nachstehenden Tabelle 5-5 dargestellt. Die vorgezogenen Ergebnisse aus Abschnitt 6.1 beinhalten Erkenntnisse aus Vorversuchen und werden im folgenden Kapitel mit den anderen Vorversuchen detaillierter beschrieben.

Ein Defizit bezüglich des Bauraums weist die AE-Sensor-Integration hinsichtlich der Beschränkung auf bestimmte Baugrößen des KGT und Sensors auf. Wie weiter oben bereits beschrieben, kann nur für bestimmte KGT die Installation *Sensor2* mit dem Sensor in Anhang A 9 realisiert werden. Da die anderen Installationen eine Vergrößerung des notwendigen Bauraums bedeuten, wird das Kriterium nur teilweise erfüllt. In Abschnitt 6.1 wird die Sensitivität der untersuchten Sensorelemente aufgezeigt. Der betrachtete Foliensensor schließt hierbei deutlich schlechter ab als die anderen Elemente und wird deshalb für die Validierungsversuche nicht in Betracht gezogen. Aus diesem Grund wird auch hier nur eine teilweise Erfüllung vermerkt. Die anderen Kriterien für die AE-Sensorelemente können alle mit „vollständig erfüllt“ bewertet werden.

Tabelle 5-5: Erfüllung der Anforderungen bezüglich Sensorelement

Teilsystem	Kriterium	Beschreibung	Erfüllung (+ o -)
Sensor	Bauform	- Verschraubung oder Klemmung - Optional: Klebung	+ +
Sensor	Bauraum	- Platzsparendes Design für Unterbringung direkt an oder in KGT-Mutter	o
Sensor	Genauigkeit/Sensitivität	- Möglichst lineares Übertragungsverhalten über gesamte Bandbreite	o
Sensor	Schnittstellen	- Standardisierter Verbinder (z. B. BNC) für Kompatibilität mit Mess-equipment	+
Sensor	Bandbreite	- Hohe Bandbreite, um großes Signalspektrum übertragen zu können	+

6 Vorversuche zur Überwachung des Wälzkontakts

Zur Bestimmung der Fähigkeit von AE am KGT werden die Einflussgrößen auf die Installation der Sensorelemente an Probekörpern und die Diagnosefähigkeit an Axiallagern, als kinematisch ähnliche Komponente, untersucht.

6.1 Untersuchung von Acoustic Emission Sensorelementen

Es werden zwei Bauformen untersucht: piezokeramische Gehäuse-Sensoren und Foliensensoren aus polarisierten, fluoropolymeren und polyvinyliden Fluoriden (PVDF). Die Sensoren sind in den Datenblättern in Anhang A 7 bis Anhang A 10 beschrieben. Eine detaillierte Ausführung der Versuche und deren Auswertung sind im Rahmen der Arbeit von (A_Xia 2020) angefertigt worden. Die Haupteckdaten der Arbeit in Bezug auf Einflussgrößen bei der Installation dieser Sensoren sollen hier zusammenfassend dargestellt werden und qualitative Schlussfolgerungen für die spätere Applikation im KGT ermöglichen. Zu den untersuchten Einflüssen gehören die Kriterien in Tabelle 6-1.

Tabelle 6-1: Untersuchte Einflussgrößen der AE-Sensorelemente, nach (A_Xia 2020)

Einflussgröße	Beschreibung
Anpresskraft/Klemmkraft bei Installation (Gehäusesensor)	<ul style="list-style-type: none"> - Wie wirken sich große und kleine Anpressdrücke auf die Signalamplitude (Dämpfung) aus? - Ist eine Klemmung notwendig oder eine Klebung ausreichend?
Distanz zur Anregungsquelle	<ul style="list-style-type: none"> - Welchen Einfluss hat die Länge des Signalwegs zwischen AE-Sensor und Anregungsquelle auf die Signalamplitude (Materialdämpfung)?
Anregungsenergie	<ul style="list-style-type: none"> - Welchen Einfluss hat die Anregungsenergie auf die Signalstärke am Sensor?
Klebstoff in Übertragungsstrecke	<ul style="list-style-type: none"> - Welchen Einfluss hat ein zweites (Koppel-)Medium zwischen Metalloberfläche und AE-Sensor auf die Signalstärke?
Rauheit von Oberflächen	<ul style="list-style-type: none"> - Welchen Einfluss haben verschiedene Rauheitspaarungen auf das AE-Signal, bei Reibversuchen mit Schleifpapier? Makroskopischer Analogieversuch für technische Oberflächen mit Rauheiten
Gleitgeschwindigkeit von Kontaktpartnern	<ul style="list-style-type: none"> - Welchen Einfluss hat die Gleitbewegung von Kontaktpartnern auf die Signalamplitude?

Von besonderem Einfluss für die spätere Installation sind die Klemmung bzw. die Anpresskraft und die notwendige Nähe zur Signalquelle. Beide Einflüsse wurden für insgesamt vier Sensoren (zwei verschiedene Bauformen) untersucht. In Abbildung 6-1 ist exemplarisch der Einfluss der Anpresskraft dargestellt. Es wurde in diesen Versuchen nur qualitativ in hohe und niedrige Anpresskraft durch den Anzug von Befestigungsschrauben unterschieden. Durch Erhöhen der Anzugskraft wird eine Steigerung der Signalsensitivität ermöglicht. Als Maß für die im Signal enthaltene Anregungsenergie werden das RMS- und Peak-2-Peak-Merkmal aus der Tabelle in Anhang A 14 verwendet.

In Abbildung 6-2 wird der Einfluss des Signalwegs zwischen Erreger und Empfänger abgebildet. Im Schaubild kann durchschnittlich eine 33-prozentige Abnahme des Signals über einen Weg von 10 cm festgestellt werden.

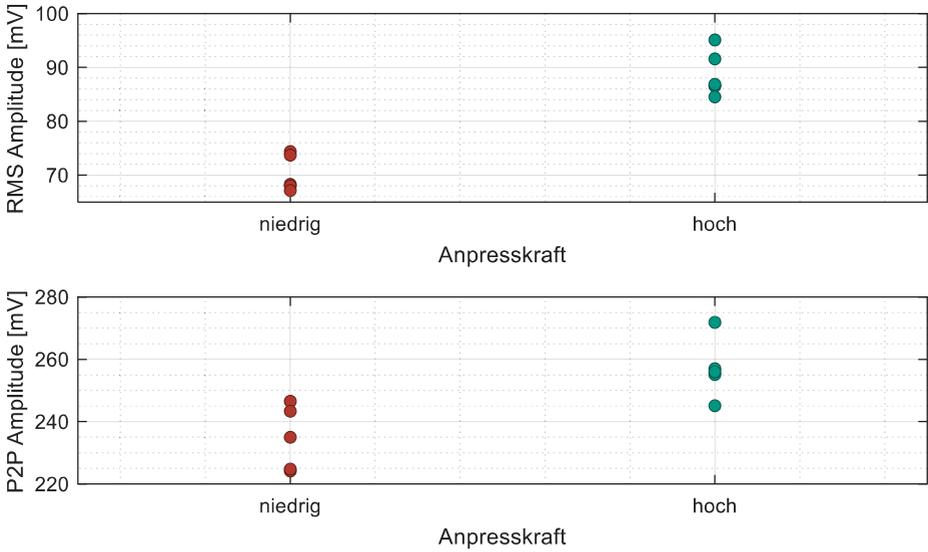


Abbildung 6-1: Abhängigkeit der Signalamplitude von der Anpresskraft der Befestigung

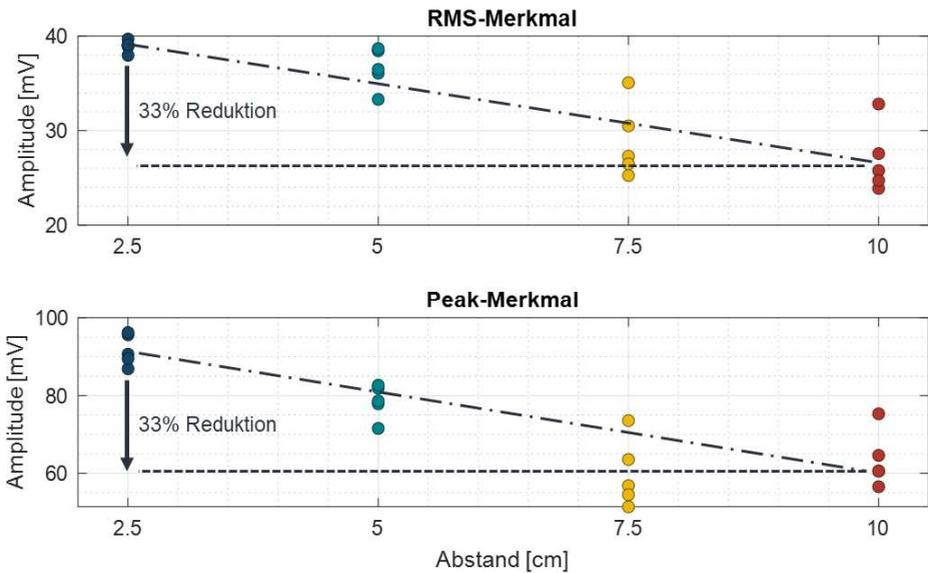


Abbildung 6-2: Abhängigkeit der Signalamplitude von der Nähe zum Sensor

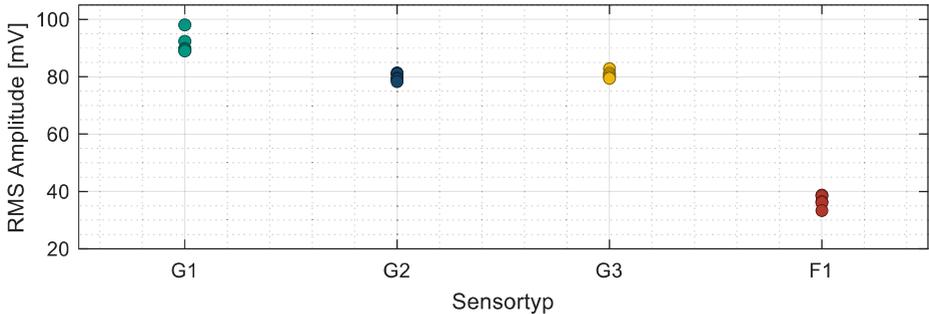


Abbildung 6-3: Vergleich der Sensitivitäten für unterschiedliche Sensoren

Eine weitere Erkenntnis für die Sensorelemente ergibt sich aus der Betrachtung von Abbildung 6-3. Hier werden die Signalamplituden aller Sensoren bei gleichen Versuchsrandbedingungen und gleicher Anregung dargestellt. G1 (Anhang A 7), G2 (Anhang A 7) und G3 (Anhang A 8) entsprechen Gehäusesensoren und F1 ist der Foliensensor in Anhang A 10. Für letzteren wird in diesem Vergleich eine deutlich geringere Sensitivität in den Versuchen ermittelt.

Die Ergebnisse der Arbeit von (A_Xia 2020) fließen in eine Vorauswahl für die eingesetzte Sensorik in weiteren Versuchen ein. Der Einsatz des Foliensensors wird für die weitere Arbeit aufgrund der geringeren Sensitivität nicht weiter betrachtet, trotz wirtschaftlicher und bauraumbedingter Vorteile. Bei der Applikation der Sensorik soll besonders die Nähe zur betrachteten Signalquelle berücksichtigt werden, da dieser Einfluss in den Untersuchungen von (A_Xia 2020) als nicht vernachlässigbar identifiziert wurde.

6.2 Untersuchung am Beispiel des Axialwälzlagers

Die Kinematik von Wälzlagerern ähnelt der von KGT. Die Wälzkörper führen zwar nicht die charakteristische helixförmige Schraubbewegung aus, sie teilen aber Gemeinsamkeiten in der theoretischen Auslegung und vorherrschenden Schadensmechanismen.

Die Eignung von hochfrequenten AE-Messungen wurde zum Stand der Forschung an Wälzlagerern bereits einschlägig diskutiert und als aussagekräftiges Sensor-System vorgeschlagen. Aufgrund der besseren Zugänglichkeit und der Inspektionsmöglichkeiten liegen Vorversuche mit Wälzlagerern daher nahe. Erkenntnisse und Vorentwicklungen in

Bezug auf Signalverarbeitung und Modellierung können später auf die Applikation am KGT übertragen werden.

Die durchgeführten Untersuchungen fanden im Kontext des DFG-Projektes 388141462 statt (DFG 2017). Die Ergebnisse wurden im Rahmen der Arbeit von (A_Detroy 2020) und der Publikation von (Hillenbrand et al. 2021) erstellt und dokumentiert. Für die Untersuchung der Axiallager wurden Experimente in fünf verschiedenen Szenarien am Versuchsträger (vgl. Abbildung 5-2) durchgeführt.

Teil der Untersuchung war die Konzeption einer Signalverarbeitung und Merkmalsextraktion, die das Detektieren der unterschiedlichen Szenarien in Tabelle 6-2 ermöglicht. Im Fokus stand dabei der Entwurf einer Vorgehensweise zur unüberwachten Selektion von Merkmalen, die auf dem Markt bereits verfügbar sind (siehe Anhang A 14). Als Inputgrößen des Systems dienen die aufgezeichneten Sensorrohdaten des AE-Sensors und ein Merkmalskatalog. Ohne auf zugehörige Labels der Rohdaten angewiesen zu sein, werden mit Hilfe eines Filtermodells die berechneten Merkmale hinsichtlich ihrer Eignung gewichtet. Eine unüberwachte Variante dieser Filterung ist mit dem sogenannten Laplace-Score möglich (Xiaofei He, Deng Cai & Partha Niyogi 2001). Der Laplace-Score bedient sich der Bedingung, dass für ein gutes Merkmal zwei Datenpunkte nur beieinander liegen, wenn tatsächlich eine Ähnlichkeit vorliegt.

Gute Merkmale besitzen einen kleinen Laplace-Score. Ermittelt man für alle betrachteten Merkmale den Laplace-Score, so können sie nach ihrer Bedeutung gewichtet werden. Der Laplace-Score kann auf den gesamten Datensatz oder nur einen (verfügbaren) Teil angewendet werden. Zudem können Labels, falls vorhanden, mit in die Gewichtung der Merkmale einfließen. Es ist eine Methode, die somit überwacht wie unüberwacht eingesetzt werden kann.

Tabelle 6-2: Versuchsszenarien am Axiallager

Szenario	vorrangiger Schadensmechanismus / Betriebsart
Verschmutztes Schmiermedium	Abrasivverschleiß
Mangelschmierung/Trockenlauf	Adhäsionsverschleiß und tribochemischer Verschleiß
Pittings auf Laufbahn	Ermüdung und Oberflächenzerrüttung
Drehzahlvariation	Änderung von Betriebsbedingung
Lastvariation	Änderung von Betriebsbedingung

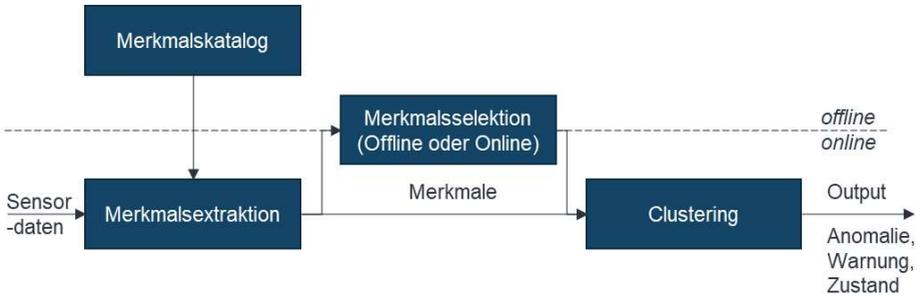


Abbildung 6-4: Schematisches Ablaufdiagramm der unüberwachten Merkmalsextraktion, nach (Hillenbrand et al. 2021)

An dieser Stelle wird auf eine genauere Herleitung und Funktionserläuterung des Algorithmus verzichtet und auf die Arbeiten von (Xiaofei He, Deng Cai & Partha Niyogi 2001) und (A_Detroy 2020) verwiesen. Ein schematischer Ablauf der Teilschritte ist in Abbildung 6-4 dargestellt.

Wertet man den Laplace-Score für die in Tabelle 6-2 aufgeführten Szenarien aus, so ergibt sich die Merkmalsauswahl in Abbildung 6-5 (links). Hierbei wurden alle Merkmale in Anhang A 14 betrachtet. Zwecks Visualisierung wurden die drei besten Merkmale für die weitere Auswertung benutzt. In Abbildung 6-5 (rechts) ist der Merkmalsraum für die drei Merkmale dargestellt. Die unterschiedlichen Szenarien wurden für eine konstante Drehzahl betrachtet. Aus der Darstellung ist ersichtlich, dass die Trennung der unterschiedlichen Zustände über die ausgewählten Merkmale vorgenommen werden kann. Mit Ausnahme des Pittingszenarios sind die Klassen vollständig voneinander separierbar. Eine weitere Beobachtung ist, dass die entstehenden Cluster nicht ausschließlich konvexe Formen (kugelförmige Cluster) annehmen, sondern auch andere Verteilungen vorliegen. Diese Tatsache muss bei der Auswahl des Clusteralgorithmus berücksichtigt werden. Darüber hinaus ist im Vorfeld der Applikation des CM-Systems die Anzahl an auftretenden Zuständen nicht bekannt und kann sich über die Zeit ändern. Der Clusteralgorithmus muss diesen Umstand entsprechend mitberücksichtigen.

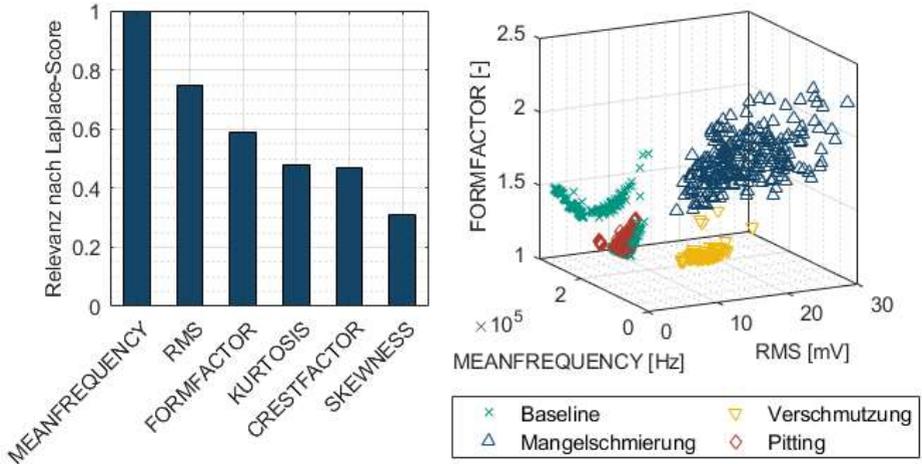


Abbildung 6-5: Merkmalsselektion mit Laplace-Score (links), Merkmalsraum für ausgewählte Merkmale bei konstanter Drehzahl (rechts), nach (Hillenbrand et al. 2021)

Werden unterschiedliche Zustände in Form von Last- und Drehzahlstufen überlagert und gemeinsam im Merkmalsraum dargestellt, so ergibt sich Abbildung 6-6. Gegenüber der vorherigen Abbildung ist deutlich zu erkennen, dass sich die Merkmalsräume der unterschiedlichen Szenarien überdecken. Eine eindeutige Zuordnung lässt sich bei Betrachtung mit unterschiedlichen Last- und Drehzahlrandbedingungen nicht mehr vornehmen. Die Merkmalsselektion basiert hier weiterhin auf der Vorauswahl für eine Drehzahl. In unüberwachten Szenarien ist jedoch eine Auswahl auf Basis aller bekannter Zustände nicht möglich, da die Daten erst entstehen und nicht a-priori bekannt sind. Die aufgezeichneten Merkmale weisen ebenfalls eine starke Abhängigkeit von der jeweiligen Drehzahlstufe auf.

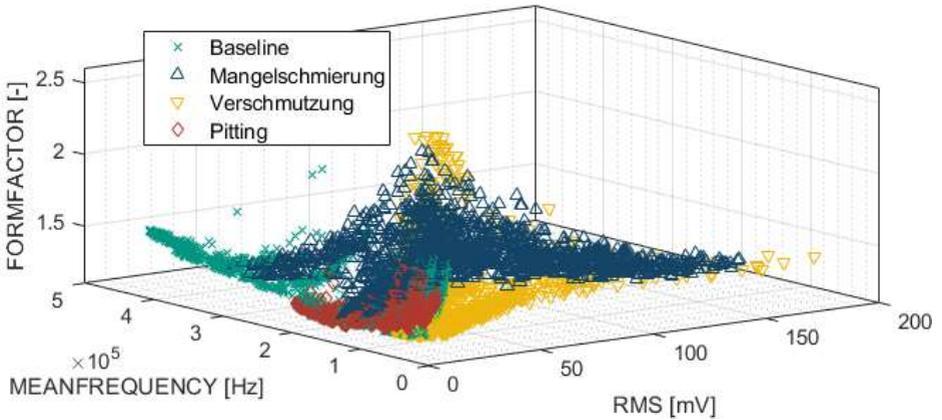


Abbildung 6-6: Merkmalsraum für alle Axiallager-Versuchsreihen und Zustände, nach (Hillenbrand et al. 2021)

Aus den Ergebnissen dieser Vorversuche können folgende Erkenntnisse für die weitere Betrachtung am KGT abgeleitet werden:

- Es liegt eine eindeutige Drehzahlabhängigkeit des AE-Signals bei Axiallagern vor. Das Phänomen kann über die zur Verfügung gestellte kinetische Energie erklärt werden. Je höher die Drehzahl, desto mehr kinetische Energie steht zur Verfügung, die potenziell auch in Körperschallschwingungen dissipiert werden und dann AE emittieren kann. Für eine robuste Auswertung im Kontext unterschiedlicher Zustände kann daher eine Betrachtung der Drehzahl als zusätzliches Merkmal notwendig sein. Ein ähnliches Verhalten am KGT ist zu überprüfen.
- Bei der Auswahl von Clusteralgorithmen müssen die Form der entstehenden Cluster und die notwendigen Hyperparameter des Algorithmus mit in die Betrachtung einfließen. Für die AE-Daten am Axiallager konnte festgestellt werden, dass beliebige Clusterformen entstehen können, die nicht durch konvexe Formen angenähert werden können, siehe Abbildung 6-6. Zentrumsbasierte Ansätze wie KMeans (MacQueen 1967), die noch dazu die Anzahl der Cluster im Voraus kennen müssen, sind daher keine geeignete Wahl. Die Auswahl eines geeigneten Clusteralgorithmus muss folglich erarbeitet werden.
- Problematisch ist ebenfalls die Merkmalsselektion. In Abbildung 6-6 kann nachvollzogen werden, was passiert, wenn die Selektion von a-priori-Merkmalen für neu hinzukommende Daten und deren Merkmale nicht mehr funktioniert. Werden

Merkmale für einen initialen Zustand „erlernt“ bzw. selektiert, so gibt es keine Garantie bei konventionellen Clustermethoden bzw. -modellen, dass die Modellgüte bei zeitlich veränderlichen Inputdaten nicht abnimmt. Dieses Problem wird durch die bereits in Abschnitt 2.3.2 eingeführte *Concept Drift* beschrieben. Darüber hinaus müssen unterschiedliche Zustände durch Merkmale beschrieben werden, die sich voneinander trennen lassen. Überlagern sich Merkmalsräume unterschiedlicher Klassen/Zustände, so kann auch ein Clusteralgorithmus keine Zuordnung vornehmen. Abhilfe schafft dann die entsprechende Wahl von anderen Merkmalen.

7 Entwicklung des Unsupervised Condition-Monitoring-Systems

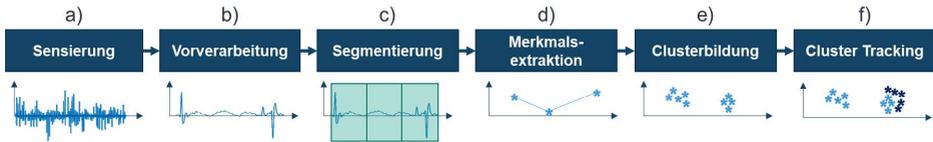


Abbildung 7-1: Teilsysteme der Datenverarbeitung in CM-Systemen

Dieses Kapitel beschäftigt sich mit der Konzeption und Implementierung eines unüberwachten Zustandsüberwachungssystems. Innerhalb dieses Abschnitts werden der Aufbau des softwareseitigen Gesamtsystems beschrieben und entworfene Algorithmen und das Unsupervised Modell zur Überwachung im Kontext von CM erklärt. Eine Aufteilung dieses Gesamtsystems ist in Abbildung 7-1 dargestellt. Dabei bilden die Teile a) bis e) die klassischen Elemente eines Systems zur Mustererkennung (Beyerer, Richter & Nagel 2018).

Mit dem Baustein f) wird ein weiterer Teilschritt eingeführt, der die zeitliche Beschreibung des Überwachungsobjekts ermöglicht. Cluster-Tracking beschreibt hier die Überwachung der zeitlichen Entwicklung von Clusterzuständen, die Systemzuständen oder Anomalien zugeordnet werden können.

Wie in Abschnitt 3.2 bereits geschildert, ist die Zielstellung die Reduktion der für das Gesamtsystem notwendigen Hyperparameter oder deren automatisierte Parametrierung, unabhängig vom Anwendungsfall. Um den Status quo für diese Datenverarbeitung darzustellen, werden nachfolgend die Teilsysteme a) bis f) hinsichtlich ihrer Hyperparameter beschrieben. Im Rahmen der Arbeit werden Systemparameter wie die Abtastrate oder der eingestellte Verstärkungsfaktor ebenfalls unter dem Begriff Hyperparameter geführt. Die nachstehende Sammlung an Hyperparametern hat nicht den Anspruch auf Vollständigkeit, berücksichtigt aber die wichtigsten Parameter in CM-Systemen.

- a) **Sensierung** beschreibt alle Schritte zur Aufzeichnung der Sensorwerte und deren Verfügbarmachung für die nachgelagerten Systeme. Die Wahl des Sensorelements ist hierbei bereits durchgeführt und es werden die Hyperparameter betrachtet, die aufgrund der Auswahl von ADC und DSP relevant sein können.

Zugehörige Hyperparameter:

- Bit-Auflösung b_{res} [bit]
- Verstärkung g [dB]
- Bandpassverhalten von (Verstärker)-Schaltung $\Delta f = [f_{low}, f_{high}]$ [Hz]
- Abtastrate f_s [Hz]

b) **Vorverarbeitung** beinhaltet Schritte zur Filterung und Bereinigung von Messfehlern in den Sensordaten. Hier werden Filterverfahren und Bereinigungsverfahren ausgewählt und angewendet.

Zugehörige Hyperparameter:

- Tiefpassfilter f_{low} [Hz]
- Hochpassfilter f_{high} [Hz]
- Clipping $\Delta\tau = [\tau_{low}, \tau_{high}]$ (Meyer 2017, S. 237)
- Ausreißer entfernen
- Gleitender Mittelwert, Fenstergröße w
- Einhüllende Fenstergröße w (Weidenfeller 2002, S. 429)

c) **Segmentierung** umfasst Methoden zur Unterteilung von Rohsignalabschnitten in kleinere Fenster bzw. Segmente. Hier können unterschiedlichste Verfahren zum Einsatz kommen.

Zugehörige Hyperparameter:

- Wahl des Segmentierungsverfahrens: Dazu gehören einfache Methoden wie *Moving-Window-Modelle* (Silva et al. 2013), Schwellwertverfahren oder Extremwertstellensuche, aber auch anspruchsvollere und komplexere Verfahren (z. B. die strukturelle Merkmalsextraktion), wie sie in der Arbeit von (Olszewski 2001) diskutiert werden.
- Im Fall von *Moving-Window-Modellen* sind die Fenstergröße w und Schrittweite s zu nennen. Andere Segmentierungsverfahren besitzen jeweils eigene Hyperparameter.

d) **Merkmalsextraktion** beschreibt Verfahren, die einen Rohdatenabschnitt x_n in einen Merkmalsvektor f_m (en. *feature*) abbilden. Dabei gilt zumeist $n \gg m$, es findet somit eine Reduktion der Dimension statt. Die Funktion $f: R^n \rightarrow R^m$ kann hierbei verschiedenste Formen annehmen. Hauptvertreter im Bereich der Vibrationsanalyse sind in der Tabelle im Anhang A 14 aufgeführt.

Zugehörige Hyperparameter:

- Auswahl der Merkmale f
- Anzahl an Merkmalen m
- Hyperparameter der Merkmale f

e) **Clusterbildung** repräsentiert Clusteralgorithmen zur Gruppierung der Datenpunkte. Die Hyperparameter hängen vom verwendeten Algorithmus ab. Beispielfähig sind hier nach dem Stand der Forschung häufig vertretene Algorithmen aufgeführt und ihre Hyperparameter. Eine detaillierte Sammlung von Clusteralgorithmen und ihrer Eigenschaften wurde von (A_Zipperling 2020) erstellt.

Zugehörige Hyperparameter für verschiedene Clusteralgorithmen:

- K-Means
 - Anzahl an Cluster k
- DBSCAN
 - Mindestanzahl an Objekten in einem Cluster $minPts$
 - Maximaler Radius zum nächsten Nachbarobjekt ε
- Meanshift
 - Bandbreite h

f) **Cluster-Tracking** beschreibt Ansätze zur zeitlichen Überwachung der Cluster-Ergebnisse. Hyperparameter entstehen hier in Form von Festlegungen von Grenzwerten für Clusterübergänge. Nach dem Stand der Forschung und Technik ist das Framework *MONIC* (Spiliopoulou et al. 2006), das bereits in Abschnitt 2.3.2.2 vorgestellt wurde, zu erwähnen.

Zugehörige Hyperparameter:

- Modell für Cluster Match
- Schwellwert für Cluster Match $\tau_{match} = [0.5..1]$
- Schwellwert für Cluster Split $\tau_{split} = [0.1..0.3]$

Betrachtet man die Menge an Hyperparametern, die insbesondere durch Integration von ML-Verfahren entlang eines CM-Systems anfallen können, entsteht schnell ein Bedarf nach Entscheidungsunterstützung oder Automatismen, die bei der Wahl oder Einstellung dieser Parameter helfen.

Als anschauliches Beispiel soll ein Neuronales Netz (NN) betrachtet werden. Ein NN kann beispielsweise in Teilmodul d) oder e) zum Einsatz kommen. Anhand von Abbildung 2-22 und Formel 2-24 kann die Anzahl der Modellparameter bzw. Hyperparameter

bestimmt werden. Es ergeben sich mehr als 12 Modellparameter, die festgelegt werden müssen, u. a. die Anzahl an Input, Output und Hidden Layer Neuronen, die Anzahl an Hidden Layer, Transferfunktionen, der Trainingsalgorithmus, die Lernrate, Trainings-epochen, Regularisierungsterme, Batch Size und weitere (Scherer 1997, 45ff).

Wenn bereits für eine Teilfunktion derart viele Hyperparameter anfallen, so steigert sich der Aufwand für die Parametrierung bei komplexeren CM-Systemen zu einer für Laien großen Hürde bei der Verwendung und Anpassung. Speziell für Anwendungen in unterschiedlichen Domänen mit zugrunde liegenden Eigenheiten müssen solche Systeme immer wieder adaptiert werden.

In den nachfolgenden Unterkapiteln wird für die Teilfunktionen a) bis f) ein CM-System entworfen. Dabei werden die notwendigen Hyperparameter automatisch bestimmt oder während des Betriebs berechnet.

Für die Implementierung des Zustandsüberwachungssystems wird die Software MATLAB verwendet. Der Quellcode für das entwickelte CM-System steht auf Github (<https://github.com/jhillenbrand/CMSystem>) zur Verfügung.

7.1 Teilsystem Sensierung

Für die Sensierung der Acoustic Emission Daten wird die vorgestellte Messkette in Abschnitt 5.1 verwendet. Diese definiert aufgrund der Wahl der Hardware bereits einige Systemparameter für die Erfassung des analogen Sensorsignals und dessen Digitalisierung. Folgende Parameter sind fest eingestellt und müssen nicht ermittelt werden:

- Bandpass von 20 kHz bis 1000 kHz,
- Speichertiefe 12 bit,
- Abtastrate 2000 kHz,
- Verstärkung (20/40/60 dB).

Die Abtastrate kann am verwendeten Datenlogger zwar eingestellt werden, wird im Kontext dieser Arbeit aber als fest angenommen und nicht weiter variiert. Die Verstärkung muss manuell am Vorverstärker (siehe Anhang A 6) eingestellt werden und wird deshalb für die automatische Parametrierung des CM-Systems nicht betrachtet.

Um die Daten von der Messhardware in das CM-System zu übertragen, ist eine Schnittstelle notwendig. Für den Fall der kontinuierlichen Aufzeichnung und Verarbeitung der Daten wird TCP/IP verwendet und eine entsprechende Client-Applikation für MATLAB zur Verfügung gestellt. Darüber hinaus wird mit einem weiteren Adapter auch das

Einlesen von bereits erfassten Daten und erneutes Abspielen als Rohdatenstream benötigt.

Für den Fall des Datenstreams dient ein Softwarebaustein zur Rohdatenabfrage des AE-Sensorsystems. Hierbei ist zu beachten, dass die Sensordaten nicht persistiert werden. Verläuft demnach mehr Zeit bei der Weiterverarbeitung als für das Befüllen eines Buffers mit definierter Größe vergeht, gehen Rohdaten verloren.

Um dies zu vermeiden, ist zunächst eine Persistierung (Speicherung) der Sensordaten auf dem lokalen Speicher des Messcomputers sinnvoll. Die abgespeicherten Daten können dann über einen entsprechenden Adapter erneut abgespielt und an das CM-System übertragen werden. Dabei wird sich auch eines gebufferten Konzepts bedient, dass das effiziente Abarbeiten der großen Datenmengen erlaubt. Mit dem vorläufigen Abspeichern der Daten und nachgelagerter Weiterverarbeitung können Stillstandszeiten des betrachteten Systems dazu benutzt werden, um die Weiterverarbeitung der Daten nachzuholen.

7.2 Teilsystem Vorverarbeitung

Zur Vorverarbeitung der Daten gehören Schritte wie Bereinigung (z. B. Ausreißerentfernung), Glättung, Filterung, Skalierung oder ähnliche Operationen. Im Unterschied zur Merkmalsextraktion (siehe Abschnitt 7.4) wird die Dimension der Daten bzw. Datenfenster nicht reduziert. Die Vorverarbeitung ist demnach eine Abbildung f nach Formel 7-1, die die Dimensionalität und Länge des Inputs nicht verändert, sondern nur die Werte.

$$f(x_i) \rightarrow \tilde{x}_i \text{ mit } x_i \text{ und } \tilde{x}_i \in R^{n \times m} \quad 7-1$$

Für den vorliegenden Fall der AE-Daten kommen zwei Verfahren der Vorverarbeitung als Signalverarbeitungsbausteine zur Anwendung.

Zum einen werden Ausreißer aus den 12-bit-Ganzzahlen entfernt, die über den TCP/IP Client empfangen und zwischengespeichert werden. Bei der Analog-zu-Digital-Wandlung kann es aufgrund von Störungen oder Aussetzern des ADC zu falschen Übertragungen von Zahlenwerten kommen. Diese werden meist mit den jeweiligen Grenzwerten der entsprechenden Speichertiefe übertragen. Bei richtig eingestelltem Signalbereich des Verstärkers können diese jedoch nicht auftreten. Ist dies trotzdem der Fall, können sie als Ausreißer aus den Daten entfernt werden. Zur Filterung dient ein

Baustein, der als Information die Speichertiefe und die Art der Signierung (signed/unsigned) erhält.

Als weiterer Baustein wird die Skalierung der Bit-Werte in Spannung realisiert. Der verwendete Datenlogger hat einen Eingangsbereich von $-/+ 0,75\text{ V}$ und eine 12-Bit-Speichertiefe, wobei die Samples als Ganzzahl übertragen werden. Der Schritt der Vorverarbeitung kann weiterhin Bausteine wie Tief-, Hoch- und Bandpassfilter enthalten. Auf die Darstellung der Funktionsweise wird hier verzichtet (mehr Details zu analogen Filtern finden sich in der Arbeit von (Meyer 2017, S. 123ff)).

7.3 Teilsystem Segmentierung

Für robuste und zuverlässige CM-Systeme bedarf es der korrekten Auswahl von repräsentativen Signalabschnitten (Segmenten). Dabei gelten folgende Anforderungen an die Segmentierung:

- Die Segmente sollen stationären Systemzuständen entsprechen, beispielsweise das Aufzeichnen während konstanter Vorschubgeschwindigkeit anstatt in der Beschleunigungsphase.
- Die Segmentierung soll irrelevante Datenabschnitte aus den Rohsignalen entfernen. Eine Reduktion der Datenmenge wird angestrebt, da dies vor allem bei Langzeitmessungen ausschlaggebend ist.

Häufig müssen diese Signalabschnitte aufgrund der Komplexität der Aufgabe manuell ausgewählt und ausgewertet werden. Damit einher gehen menschliche Fehler und hohe Zeitaufwände (Bombiński et al. 2016). Die Performanzsteigerung durch Segmentierung für nachgelagerte Clustering- und/oder Klassifikationsmodelle wird auch in den Arbeiten von (Netzer, Michelberger & Fleischer 2020) hervorgehoben.

Ein einfaches exemplarisches Beispiel zur Verdeutlichung ist in Abbildung 7-2 dargestellt. In der Grafik wird ein mit Bursts (Stößen) versehenes Signal mit Hilfe des RMS-Merkmals analysiert. Die gelben und roten Punkte geben den RMS-Wert des jeweiligen Segments wieder. Die Segmentierung wird in dem Fall über ein einfaches *Moving-Window* gelöst. Die Größe der Fenster sind mit den eingezeichneten transparenten Rechtecken visualisiert.

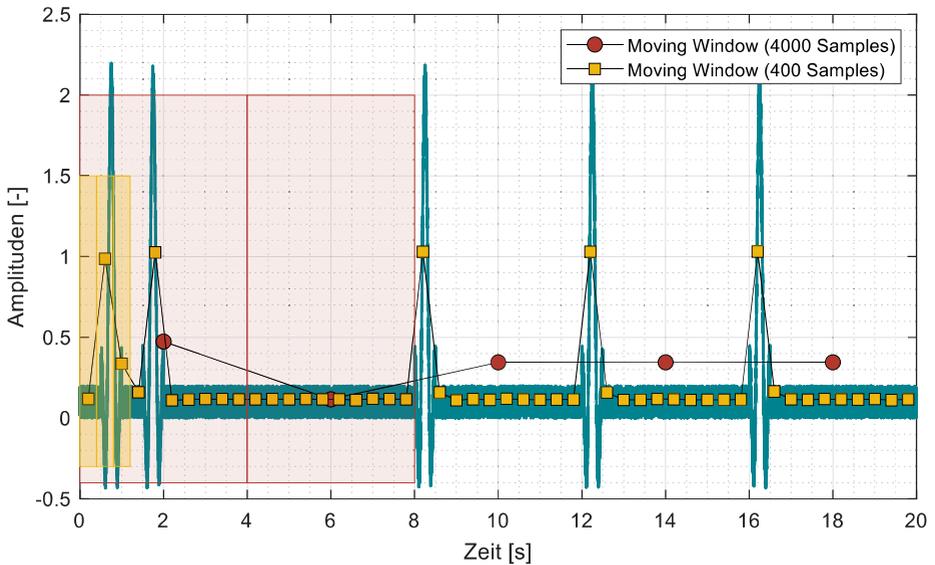


Abbildung 7-2: Beispiel für den Effekt der Fensterlänge für Moving-Window-Segmentierung

Anhand der Verläufe der Merkmale für die unterschiedlichen Fenstergrößen ist der Effekt einer geschickten Fensterung leicht zu beobachten: Bei Wahl eines großen Fensters in stark verrauschten Daten mit wenig Nutzsignalanteil (Charakteristika eines Burst-Signals) sind Abschnitte mit Ausreißern nur schwer von Signalfenstern mit Nutzsignal zu unterscheiden. Wird die Fensterung hingegen feiner gewählt, so sind Signalausschläge der Bursts auch im RMS-Merkmal wieder zu finden.

Im Vorfeld zur Datenaufzeichnung und Überwachung die richtige Wahl der Fenstergröße zu treffen, ist eine komplexe Aufgabe. Häufig entsteht eine Kompromisslösung zwischen hoher Auflösung und Datenreduktion. Eine Segmentierung zu entwerfen, die sich selbstständig an die Input-Daten anpasst, auch während des Betriebs, ist keine triviale Aufgabe. Hierzu wird im Kontext dieser Arbeit ein Ansatz vorgestellt, der vorhandenes Domänenwissen über die Komponente nutzt, um die Segmentierung zu steuern. Dabei wird die KGT-Kinematik verwendet, um die Segmentierung zu parametrieren.

Die Kenntnis über die Wälzkörperbewegung im KGT und damit verbundene AE-Emissionen können als Zusatzinformation für die Parametrierung des automatisierten Clusteringverfahrens genutzt werden.

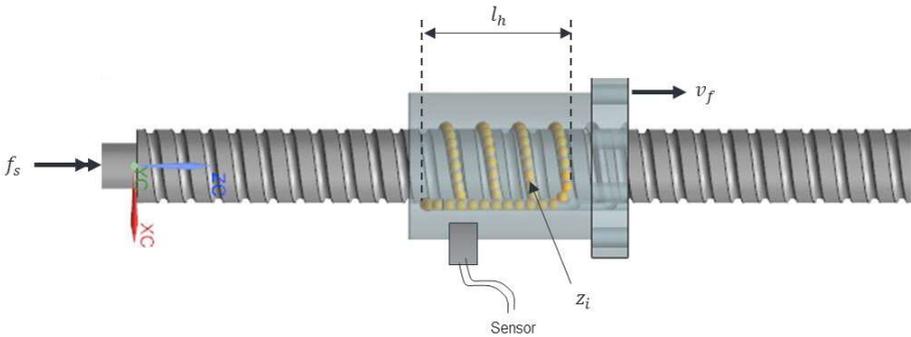


Abbildung 7-3: Kinematische Größen für die Lokalisierung von Defekten

Auftretende Strukturschwingungen und Stöße, die durch die Wälzbewegung der umlaufenden Kugeln und den Ein- und Austritt aus der Rückführung verursacht werden, sind durch die kinematischen Zusammenhänge der Komponente zeitlich korreliert. Unter Kenntnis der Geometrie und Spindeldrehzahl f_{sp} können kinematische Frequenzen für die Wälzkörperbewegung errechnet und für die

Konfiguration der Signalverarbeitungskette (Fensterung, Merkmalsextraktion etc.) verwendet werden. Werden die möglichen auftretenden Frequenzen im Zusammenhang überwacht, so kann durch geschickte Kombination und Ausschlussverfahren auch eine Lokalisierung der abnormalen Komponente vorgenommen werden.

Defektszenarien aufgrund der kinematischen Zusammenhänge

In Kapitel 2.1.1 sind die zum Stand der Technik und Forschung zugänglichen Formeln für die Herleitung kinematischer Frequenzen am KGT vorgestellt worden. Unter Kombination und gemeinsamer Betrachtung mit den Komponenten des KGT (siehe Abbildung 7-3) können folgende Szenarien zur Detektion von Defekten aufgrund der kinematischen Zusammenhänge abgeleitet werden:

a) Defekt in Mutter:

Ein abnormales Merkmal tritt mit der Frequenz $f_{b,n}$ auf und ist unabhängig von der aktuellen Position des Hubs s .

b) Defekt auf der Spindel:

Ein abnormales Merkmal tritt mit der Frequenz $f_{b,s}$ und einer Dauer von $t_{d,s} = \frac{L_h}{v_f}$ auf (L_h ist die Höhe der Helix-Laufbahn). Das Merkmal kann nur auftreten, wenn die Mutter über die defekte Spindelstelle fährt. Das Merkmal ist damit abhängig

von der aktuellen Position der Mutter auf der Spindel und zeitlich über die Vorschubgeschwindigkeit v_f begrenzt.

c) Defekt an Einzelkugel:

Ein abnormales Merkmal tritt mit der Frequenz $f_{b,2P/AP}$ auf. Es liegt ein Defekt entlang der Abrolllinie bzw. -linien entlang des Wälzkörperumfangs vor (im Fall von 4-Punkt-Kontakt). Bei jeder Umdrehung um die eigene Drehachse der Kugel wird dieses Merkmal erzeugt. Darüber hinaus können Merkmale mit der Frequenz $f_{b,t}$ auftreten. Dabei wandert eine defekte Kugel einmal durch die gesamte Kugellaufbahn (inklusive Rückführung) und kommt am Sensor vorbei.

Außerdem können Plan- oder Rundlauffehler mit der Spindelfrequenz f_s vorkommen.

Auf Basis dieser Frequenzen können Zeitfenster T_{seg} bestimmt werden, die als Fenstergröße für die Auswertung der AE-Daten verwendet werden können:

$$T_{seg}: \left\{ \frac{1}{f_s}, \frac{1}{f_{b,n}}, \frac{1}{f_{b,s}}, t_{d,s}, \frac{1}{f_{b,2P/AP}}, \frac{1}{f_{b,t}} \right\} \quad 7-2$$

Diese Segmente werden in Abbildung 7-4 exemplarisch für den KGT in Anhang A 2 dargestellt. Bei einer Drehzahl $f_s = 150 \frac{1}{min} = 2.5 \text{ Hz}$ ergeben sich die Frequenzen in Abbildung 7-4 für die Segmentierung. Auf der x-Achse des Diagramms ist die auftretende Komponentenfrequenz und auf der y-Achse eine Relevanz zwischen 0 und 1 aufgetragen. Die Relevanz beschreibt hierbei die relative Nähe des Signalentstehungsorts zum installierten Sensor (Referenzinstallation ist *Sensor1*, wie in Abschnitt 5.5 beschrieben). Mit einer 1 wird ausgedrückt, dass die Frequenz aufgrund der Position des Sensors und der Kinematik von hoher Relevanz ist. Die 0 entspricht einer geringen Relevanz.

Werden die unterschiedlichen Segmentgrößen aus Formel 7-2 zusammen mit einer Prüfstandsfahrt und dem zugehörigen AE-Signal abgebildet, ergibt sich Abbildung 7-5. Im Diagramm sind die jeweiligen Frequenzen und ihre zugehörigen Fenstergrößen über die Sensordaten und die Drehzahl dargestellt.

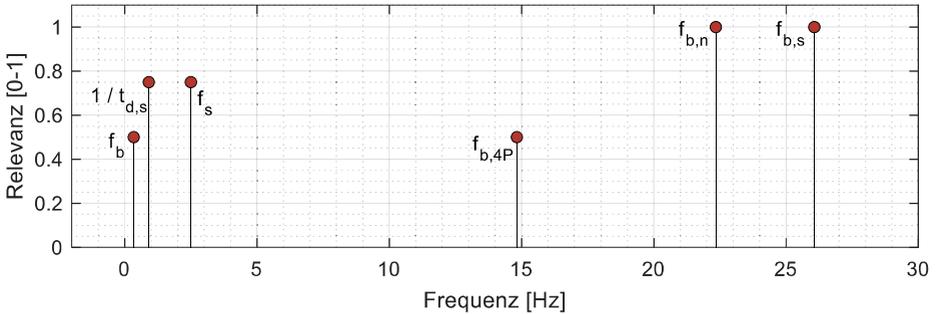


Abbildung 7-4: Ermittelte Komponentenfrequenzen für Spindeldrehzahl 150 1/min

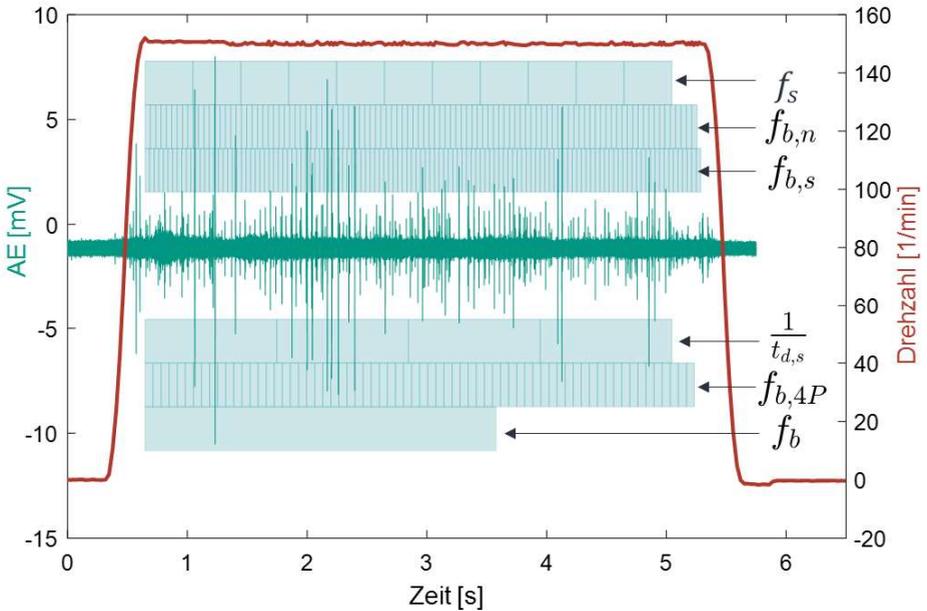


Abbildung 7-5: Fensterung eines AE-Signals für die sechs Teilsegmente

Weitere Frequenzen, die mit in der Segmentierung berücksichtigt werden können, sind zum Beispiel Eigenfrequenzen der Komponente, die experimentell mittels Modalanalyse oder analytisch ermittelt werden können. Der Ansatz zur Segmentierung lässt sich leicht erweitern und auf andere Maschinenelemente übertragen.

Darüber hinaus können auch weitere (Defekt-)Frequenzen aus dem Prozess herangezogen werden, beispielweise die Eingriffsfrequenzen eines Werkzeugs beim

Zerspanen. Im Rahmen der Arbeit sind diese Frequenzen aufgrund des Abstands der Signalquelle zum Sensor vernachlässigt worden. Die hohe Signaldämpfung von AE, die in Abschnitt 2.2.3 beschrieben wird, führt zur Verringerung des Einflusses dieser Signalquellen.

Zur Integration in das CM-System wird ein spezieller Signalverarbeitungsbaustein entworfen, der verschiedene *Moving-Window*-Segmente auf Basis der KGT-Geometrie und Spindeldrehzahl berechnet und an die folgende Signalverarbeitung weitergibt.

7.4 Teilsystem Merkmalsextraktion

Ein entscheidender Schritt in der Signalverarbeitungskette von Daten generell, aber AE im Besonderen, ist die Merkmalsextraktion. Aufgrund der hohen Datenrate der AE-Daten ist eine Kompression sinnvoll, bei der jedoch keine relevanten Informationen verloren gehen dürfen. Häufig kommt der Merkmalsextraktion mehr Bedeutung zu als der Auswahl des Lernverfahrens, da die ausgewählten bzw. extrahierten Merkmale eine entscheidende Bedeutung für den Erfolg der nachgelagerten Modellierung haben. In der Fachliteratur zum maschinellen Lernen wird vom *Curse of Dimensionality* (Fluch der Dimension), d. h. der Größe eines Merkmalvektors $f_j \in R^m$ für einen gegebenen Inputvektor $x_i \in R^n$, gesprochen. (Joshi 2020, S. 13) fordert deshalb die aufmerksame Prüfung der Datendimension bei der Anwendung in ML-Modellen. Übertragen auf das vorliegende Problem der AE-Daten bedeutet dies, dass die Sinnhaftigkeit der Weitergabe der gesamten Rohdaten im Zeitbereich bzw. in den Segmenten zu prüfen ist. Diese Erkenntnis ist vor allem auch praktischer Natur, da viele Algorithmen nur für geringe Dimensionen effizient berechnet werden können bzw. die Dimension exponentiell oder quadratisch in die Laufzeit eingeht (Beyer et al. 1999).

DEFINITION 9. Merkmalsextraktion

Im Kontext der Arbeit lässt sich die Merkmalsextraktion beschreiben als eine Funktion $g: R^n \rightarrow R^m$, die einen Vektor x_i (z. B. eine Zeitreihe) auf den Vektor f_j (en. feature) abbildet. Dabei ist $n \gg m$ und $x_i \in R^n, f_j \in R^m$. Die Größe m bezeichnet damit die Dimensionalität des Merkmalsraums von g .

In der Technik und Forschung ist die Merkmalsextraktion schon lange etabliert. Im Kontext der Vibrationsanalyse, speziell auch im Bereich der Überwachung von Wälzlagern, stehen mehrere Merkmale, die sensitiv für Signaländerungen sind, zur Verfügung. Die Merkmale erstrecken sich von einfachen Zeitmerkmalen wie Kurtosis (KU), Formfaktor

(FF), Marginfaktor (MAF), Crestfaktor (CF), Peak-Faktor (PF) und Root-Mean-Square-Faktor (RMS) über komplexe Zeit-Frequenz-Merkmale wie die Wavelet-Dekomposition. Je nach beobachteter Maschinenkomponente sind diese Merkmale mehr oder weniger aussagekräftig und anwendbar. Besonders bei instationären Vorgängen und Systemen mit Einlaufverhalten ist mit diesen einfachen Merkmalen oftmals nicht die ganze Komplexität des überwachten Systems abbildbar (Kimothe & Sextro 2014; Galar et al. 2012; Zhang, Huang & Wang 2012).

Eine Übersicht dieser klassisch verwendeten Merkmale enthält Anhang A 14. Die Merkmale werden auch im Rahmen dieser Arbeit vergleichend herangezogen. Darüber hinaus wird ein Ansatz auf Basis von Autoencoder-Netzwerken, der bereits in Abschnitt 2.3.1 eingeführt wurde, betrachtet. Besonders unter dem Aspekt der unüberwachten Merkmalsextraktion stellen Autoencoder eine geeignete Lösung dar. Im Kontext von CM-Systemen kann durch Einsatz von Autoencodern der Aufwand bei der Wahl von Merkmalen und notwendiger Datenkompression verringert werden. Im Folgenden wird zur Beurteilung der Verwendung eine Gegenüberstellung mit herkömmlichen Signalmerkmalen vorgenommen.

7.4.1 Gegenüberstellung von Merkmalen einschließlich Rekonstruktionsfehler

Verglichen werden fünf Merkmale (inklusive Rekonstruktionsfehler des AEN) für vier verschiedene Szenarien, die klassische Störungen, Drifts oder Anomalieeffekte in Zeitreihendaten repräsentieren.

Der Autoencoder wird in jedem Szenario unter gleichen Randbedingungen trainiert. Die Trainingsdauer umfasst 2000 Epochen und als Architektur wird nur eine versteckte Schicht gewählt. Die Anzahl der versteckten Neuronen wird auf 1 % der ursprünglichen Signalgröße festgelegt. Damit wird der Autoencoder gezwungen, eine deutlich geringere dimensionale Repräsentation der Daten zu erlernen.

Die simulierten Rohdatenabschnitte sind unterteilt in 20 Sekunden bei einer Abtastrate von 1 kHz im Grundzustand und anschließend 8 Sekunden mit Anomalien oder Änderungen, die erkannt werden sollen. Nur der 20-Sekunden-Abschnitt mit Normaldaten wird zum Training herangezogen. Das Training des Autoencoders dauert für kein Szenario länger als 15 Sekunden auf einem Intel(R) Core(TM) i7-10750H CPU @ 2.60GHz. Die nachfolgenden Bilder zur Veranschaulichung des Potenzials der Autoencoder sind wie folgt aufgebaut: Die Abbildung 7-6 bis Abbildung 7-9 besitzen jeweils zwei Spalten.

Die Teilplots der linken Spalte beschreiben das Rohsignal (oben links) des betrachteten Szenarios und die extrahierten Merkmale. Die betrachteten Merkmale sind RMS, PF, MF, Envelope-Energy (EE) und als Autoencoder-Merkmal MSE. In der zweiten Spalte rechts wird für das jeweilige Merkmal ein Boxplot abgebildet, der die Separationsgüte zwischen Grundzustand (en. *baseline*, B) und Anomalie (A) zeigt. Überdecken sich die Bereiche von A und B, ist das Merkmal für diese Art von Rohdaten nicht geeignet, eine eindeutige Unterscheidung zwischen normalem und abnormalem Zustand herzustellen. Ziel bei der automatisierten bzw. unüberwachten Merkmalsextraktion für eine Vielzahl an Szenarien ist, das richtige Merkmal für die Anomalieerkennung zu finden.

Szenario: Defektfrequenz

Der Rohdatenverlauf beginnt mit einer Sinuswelle bei Frequenz $f_1 = 1 \text{ Hz}$ und geht im Anomaliebereich auf eine Frequenz $f_2 = 5 \text{ Hz}$ bei gleicher Amplitude über. Dem Sinusverlauf wird dabei weißes Rauschen mit 10 % der Schwingungsamplitude überlagert. Der Verlauf repräsentiert die Eigenschaft von Signalen, die durch unterschiedliche Frequenzinhalte oder Verteilungen in der Frequenzdomäne charakterisiert sind.

Für das Szenario Defektfrequenz ist in Abbildung 7-6 zu erkennen, dass RMS und PF nicht zur Separation der Segmente geeignet sind. Beide Merkmale sind bei einer Sinusschwingung auf Änderungen der Amplitude angewiesen. Formeltechnisch kann sogar für den RMS-Wert gezeigt werden, dass dieser im Fall einer harmonischen Schwingung nur von der Amplitude abhängt (Schrüfer, Reindl & Zagar 2012, 95ff). Gemäß Anhang A 1 ist *PF* nur von der Spanne des Signals abhängig und damit auch unempfindlich gegenüber einer Frequenzänderung. Nur MF, EE und MSE zeigen in ihrem jeweiligen Wertebereich gute Separationseigenschaften für dieses Szenario.

Das Szenario zeigt, dass der Autoencoder es schafft, die Signalcharakteristik der Sinuswelle zu erlernen. Somit können auch Störfrequenzen detektiert werden, die beispielsweise nur mit speziellen Frequenzdomänen-Merkmalen wie dem MF oder rechenintensiven Merkmalen wie dem EE detektiert werden.

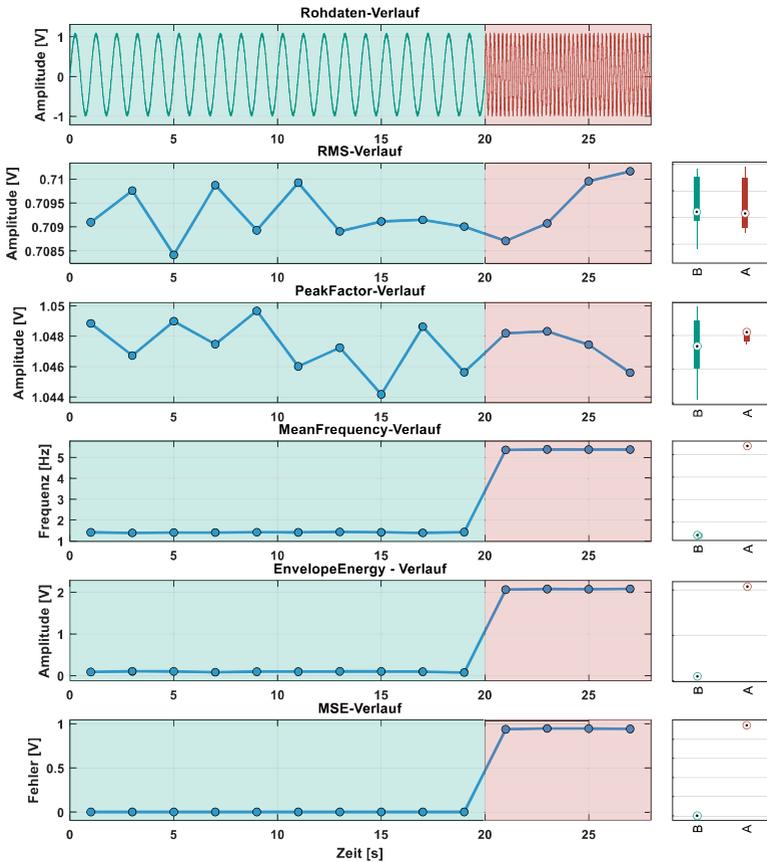


Abbildung 7-6: Simuliertes Szenario „Defektfrequenz“ und zugehörige Merkmale

a) Szenario: Amplitudendrift

Der Grundzustandsabschnitt dieses Szenarios stellt wieder eine harmonische Schwingung dar, die im Anomalieabschnitt mit zunehmender Amplitude weiter-schwingt. Der Verlauf ist einer driftenden Mess- oder Prozessgröße nachemp-funden.

Die besten Separationseigenschaften bietet hier nun das Merkmal PF, da es spe-ziell die Amplitudenunterschiede berechnet. Prinzipiell ist die Signaldrift dieser Art mit allen Merkmalen anhand der Boxplots in Abbildung 7-7 unterscheidbar. Nur Merkmal MF schneidet hier in Absolutwerten schlechter ab, da es sich im Rohsignal um die gleiche Frequenz in beiden Bereichen handelt und diese nur

aufgrund von Rauschen und Leakage-Effekten leicht verändert ist. Eine Separation auf Basis der Mittelfrequenz ist daher nur eingeschränkt möglich. Das Szenario Amplitudendrift wird sowohl von den gängigen benutzerdefinierten Merkmalen als auch dem MSE detektiert.

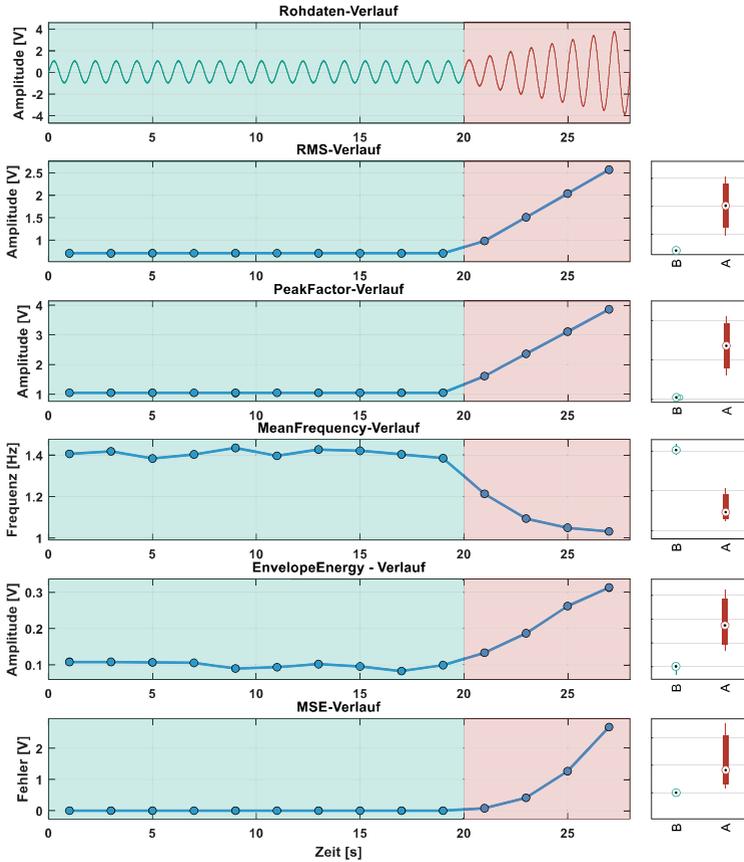


Abbildung 7-7: Simuliertes Szenario „Amplitudendrift“ und zugehörige Merkmale

b) Szenario: Burst

Der Rohdatenverlauf enthält im Grundzustand Bursts (stoßähnliche Signalspitzen). Diese unterscheiden sich im Anomaliebereich hinsichtlich Häufigkeit und Form, besitzen jedoch die gleichen Amplituden. Klassische AE-Ereignisse entstehen häufig in Form solcher Burstsignale.

Das einzige Merkmal ohne Überdeckung des Wertebereichs in den Boxplots in Abbildung 7-8 für das Burst-Szenario stellt das MSE-Merkmal dar. Alle anderen Merkmalsbereiche überdecken sich und sind daher für eine robuste Separation ungeeignet. Komplexe und transiente Signalformen wie das Burstsignal lassen sich durch einfache skalare Merkmalsgrößen nur schwer beschreiben. Da das MSE-Merkmal auf einem spezifischen Datenabschnitt angelernt wird, wird eine starke Anpassung (Overfitting) auf diesen Signalabschnitt erreicht und es sind damit Abweichungen von diesen Signalcharakteristiken leicht detektierbar.

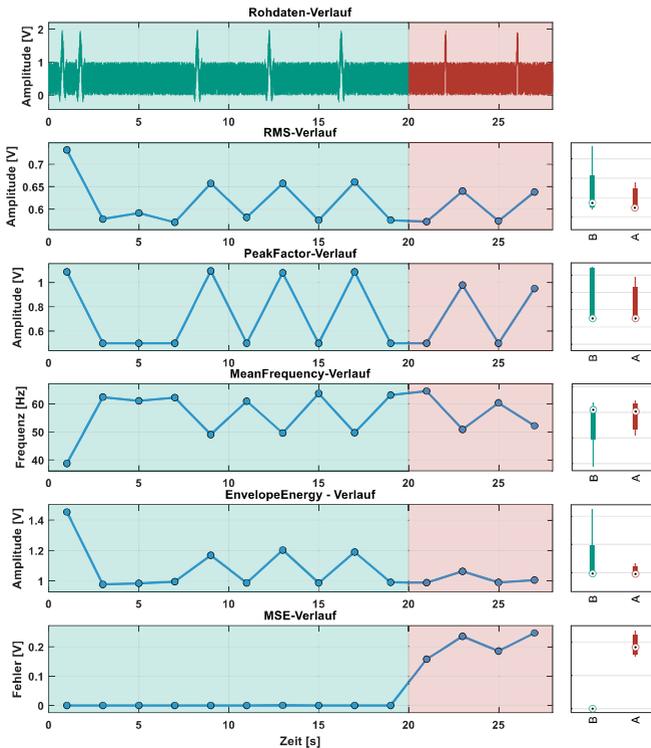


Abbildung 7-8: Simuliertes Szenario „Burst“ und zugehörige Merkmale

c) Szenario: Muster

Der Rohdatenverlauf enthält im Grundzustand und Anomaliebereich einen Amplituden-Zeit-Verlauf, der dem Verfahrprofil einer Vorschubachse nachempfunden ist. Dabei hat das Anomalie-Profil einen unterbrochenen Verlauf mit zusätzlicher Haltezeit.

Eine eindeutige Separation der Signalabschnitte lässt nur das MSE-Merkmal zu, wobei auch der PF noch ausreichend gute Trennbarkeit aufweist. Andere Merkmale versagen beim Detektieren eines Unterschieds der Abschnitte in Abbildung 7-9.

Das MSE-Merkmal des Autoencoders ermöglicht das Erlernen eines repräsentativen Signalverlaufs. Nimmt dieser eine andere Ausprägung an, so spiegelt sich dies im Rekonstruktionsfehler wider. Damit können neben eher klassischen Vibrationssignalen (Burst, Sinuswelle) auch Zeitreihenmuster erlernt werden.

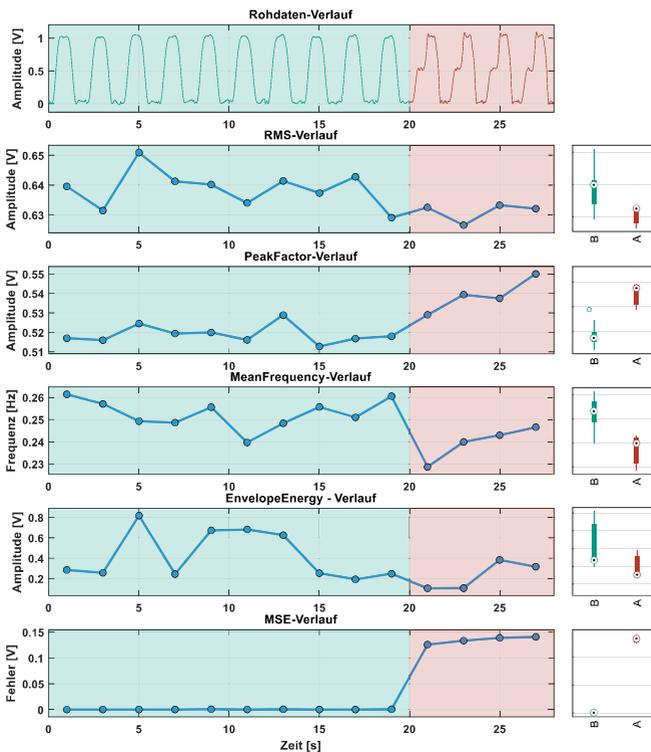


Abbildung 7-9: Simuliertes Szenario „Muster“ und zugehörige Merkmale

Tabelle 7-1 Eignung der Merkmale für verschiedene Szenarien

Szenario	a) Defekt- frequenz	b) Amplituden- drift	c) Burst	d) Muster
Merkmals				
RMS	-	+	-	-
PF	-	+	-	+
MF	+	o	-	o
EE	+	+	-	-
MSE	+	+	+	+
+ <i>beschreibt eine eindeutige Identifikation der Anomalie</i> o <i>beschreibt eine nur mäßige Separation zwischen Normal- und Anomaliezustand</i> - <i>beschreibt eine fehlgeschlagene Identifikation</i>				

In der durchgeführten Verifikationsstudie konnte die Funktionalität des AEN bzw. des Rekonstruktionsfehlers mit Hilfe von MSE als Merkmal für die Anomalieerkennung bestätigt werden. Er konnte in allen Szenarien erfolgreich die Abschnitte separieren und war teilweise sogar das einzige aussagekräftige Merkmal. Es handelt sich bei den obigen Abbildungen zwar um simulierte Daten, diese wurden aber realen Signalverläufen nachempfunden und mit Rauschen versehen, um sie realistischer zu gestalten. Tabelle 7-1 fasst die Eignung der Merkmale je Szenario zusammen.

Die Studie bestätigt den Einsatz des MSE-Merkmals von AEN als aussagekräftiges und erlernbares Merkmal für die Anomaliedetektion. Um den Rekonstruktionsfehler im Sinne der hyperparameterfreien Merkmalsextraktion zu befähigen, muss eine Vorgehensweise für die Konfiguration des AEN gefunden werden, die dem Nutzer keine weiteren Hyperparameter auferlegt, da sonst der Vorteil gegenüber benutzerdefinierten Merkmalen verloren geht. Dabei geht es vor allem um die Definition der Netzarchitektur und deren Hyperparameter. Ein entsprechender Ansatz wird im folgenden Abschnitt präsentiert.

7.4.2 Auto-Konfiguration von Autoencodern für die Anomaliedetektion

Gegenüber der Verwendung von konventionellen Merkmalen bei der Merkmalsextraktion von Schwingungsdaten muss für den AEN eine entsprechende Netztopologie gefunden werden. Das Vorgehen in diesem Abschnitt basiert auf den Vorarbeiten von (Hillenbrand & Fleischer 2020) und (A_Kistner 2021).

Die Eignung von AEN zur Anomalieerkennung wurde bereits in Abschnitt 2.3.1 beschrieben. Lernt das AEN die Signalcharakteristik von normalen Daten, so können bei

der Anwendung mit neuen Daten Abweichungen der Prädiktion als Hinweis für Anomalien benutzt werden.

Die Problematik, die bei einem solchen Trainingssetup entsteht, ist folgende:

- Wie groß müssen Signalabschnitte gewählt werden?
- Welche Netztopologie eignet sich für den Autoencoder?
- Wie muss der Autoencoder trainiert werden?

In den Vorarbeiten wurde ein datenbasiertes Vorgehen vorgeschlagen, das eine schnelle Schätzung der Neuronenanzahl der versteckten Schicht des AEN ermöglicht. Damit wird die Konfiguration des neuronalen Netzes im Betrieb möglich und kann in der jeweiligen Applikation ohne zusätzliche Offline-Trainingsphase trainiert werden. Außerdem beeinflusst die Ausprägung der versteckten Schicht maßgeblich Speicherplatzbedarf und Abstraktionsgüte beim Erlernen des Signals bzw. Overfitting der Trainingsdaten (siehe Abschnitt 2.3.1).

Damit stützt dieses Teilmodul die Gesamtzielstellung zur automatischen Konfiguration von CM-Systemen ohne bzw. mit geringem Vorwissen über das zu beobachtende System. Ziel der Vorgehensweise ist die Ermittlung einer hinreichenden Anzahl an Neuronen für die versteckte Schicht des AEN. Dabei wird folgende Grundidee angewandt: Betrachtet man den Signalinhalt eines Vibrationssignals (AE-Schwingungen), so kann dieser gemäß der Fourier-Theorie in eine Reihendarstellung nach Formel 7-3 zerlegt werden. Sind die Hauptfrequenzen (Frequenzen mit dem größten Amplitudenbeitrag) bekannt, so kann die Formel als Näherung des ursprünglichen Signals auf Formel 7-4 reduziert werden. Wird nun beim Training des AEN genau diese Anzahl an

Freiheitsgraden als Anzahl der Neuronen der versteckten Schicht gewählt, so wird das Netz zum Erlernen der Hauptfrequenzen des Signals gezwungen. Damit entsteht ein Autoencoder, der mit sehr wenigen Merkmalen (Neuronen in der versteckten Schicht) Signale rekonstruiert, aus deren Datenverteilung er beim Training lernen konnte.

$$f(t) = a_0 + \sum_{n=1}^{\infty} (c_n \cos(2\pi f_n t) + s_n \sin(2\pi f_n t)) \quad 7-3$$

Aus Formel 7-3 wird ersichtlich, dass für die Schätzung eines Zeitsignals $f(t)$ insgesamt $N_H = 1 + 3 \cdot N_f$ Koeffizienten notwendig sind. Dabei entspricht N_f der Anzahl an Hauptfrequenzen im Signal. Es folgt:

$$f(t) \cong a_0 + \sum_{n=1}^{N_c} (c_n \cos(2\pi f_n t) + s_n \sin(2\pi f_n t)) \quad 7-4$$

N_H entspricht damit auch der Anzahl an Merkmalen bzw. der Anzahl an Neuronen in der versteckten Schicht des AEN. Wird anstatt des Zeitsignals $f(t)$ versucht, das Frequenzspektrum $F(\omega)$ zu erlernen, so reduziert sich die Anzahl an Merkmalen auf $N_H = N_f$.

Für die Bestimmung der Hauptfrequenzen wurde von (Hillenbrand & Fleischer 2020) ein Vorgehen zur Selektion dieser Frequenzen entwickelt. In der Arbeit von (A_Kistner 2021) wurde dieses Vorgehen um Funktionen zur verbesserten Bestimmung der Frequenzen unter Einfluss von Rauschen und der Abtastrate erweitert.

Das Bestimmen von Hauptfrequenzen unterliegt einer prinzipbedingten Subjektivität, da der Begriff Hauptfrequenz eine gewisse Unschärfe aufweist bzw. nicht eindeutig definierbar ist. Dazu kommt eine Abhängigkeit von der betrachteten Anwendung. Im Kontext der Vorarbeiten wurden deshalb empirische Studien durchgeführt und es erfolgte eine Absicherung durch Anwendung von repräsentativen Datensätzen (A_Kistner 2021). Die Vorgehensweise der Teilschritte a) bis e) in

Abbildung 7-10 wird nachstehend erläutert.

- a) Der Teilschritt *Sensierung* bezieht sich auf den bereits vorgestellten Abschnitt 7.1. Hier werden die Rohdaten aufgezeichnet und dem Rest der Signalanalyse zur Verfügung gestellt.

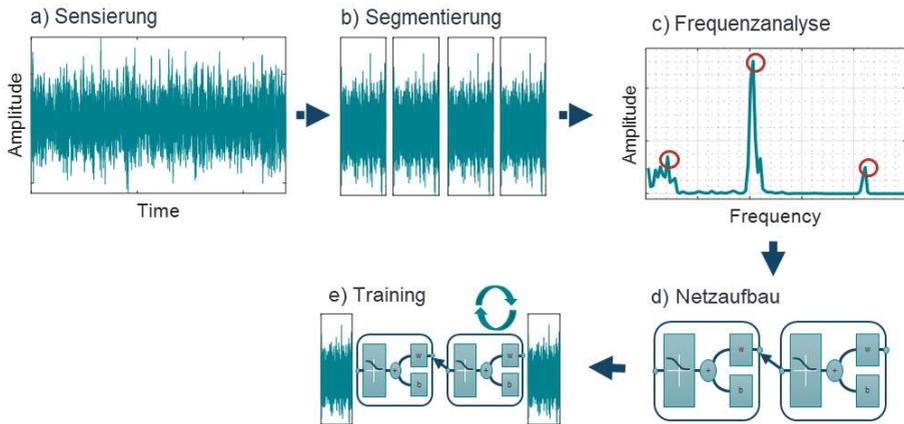


Abbildung 7-10: Schematischer Ablauf der Auto-Konfiguration des Autoencoders

- b) Im Teilschritt *Segmentierung* wird der Rohdatenstream in Fenster zerlegt. Dies kann im einfachsten Fall durch Moving-Windows vorgenommen werden. Die Fenstergröße w ergibt sich durch die gewünschte Frequenzauflösung f_{res} und Abtastrate f_{sr} nach Formel 7-5. Nach dem Segmentieren erfolgt die Ermittlung des Frequenzspektrums mittels Fast-Fourier-Transformation (FFT).

Wenn Vorwissen zur Bestimmung der Hauptfrequenzen des Systems existiert, kann dies bei der Berechnung mit einfließen. Der Ansatz für KGT ist bereits in Abschnitt 7.3 beschrieben worden. Der Ansatz über die gewünschte Frequenzauflösung ist jedoch allgemeingültig und kann immer angewendet werden.

$$w = \frac{f_{sr}}{f_{res}}. \quad 7-5$$

- c) Nach der Aufteilung der Daten in Segmente werden diese nach Hauptfrequenzen untersucht. Dabei kommen zwei Algorithmen zum Einsatz, Recursive-Peak-Finding und Kniepunktsuche. Beide Ansätze arbeiten auf der Grundlage, dass große Frequenz-Bins, d. h. Frequenzanteile mit großen Amplituden, Hauptfrequenzen entsprechen. Die Größe der Amplitudenanteile muss jedoch nicht über einen Mindestgrenzwert vorgegeben werden, sondern wird auf Basis der Verteilung der gesamten Frequenzen im Spektrum ermittelt. Der Algorithmus für die Recursive-Peak-Finding-Methode wird in der Arbeit von (A_Kistner 2021) erläutert. Die detaillierte Funktionsweise für die Kniepunktsuche wird nachstehend erläutert. Der Algorithmus zur Kniepunktsuche (auch als Ellbogensuche bezeichnet) wurde bereits von (Satopaa et al. 2011) vorgestellt: Dynamische Systeme erreichen häufig Punkte, an denen die Kosten, einen einstellbaren Parameter weiter zu verändern bzw. zu erhöhen, keine nennenswerte Ertragssteigerung hervorrufen. Diese Punkte werden aufgrund der Analogie zur Krümmung eines Knies mit Kniepunkt bezeichnet. Sucht man nach dem Kniepunkt in einem Frequenzspektrum $\{f_i, p_i\}$, kann der Programmcode in Anhang A 16 verwendet werden. f_i bezeichnet dabei die diskreten Frequenzen und p_i die zugehörigen Amplitudenanteile.

Der Kniepunkt stellt im Fall des Spektrums den Punkt dar, ab dem alle weiteren Frequenz-Bins (nach Sortierung) keinen wesentlichen Beitrag mehr zur Leistung des Spektrums liefern. Punkte, die rechts (x-Achse) vom Kniepunkt liegen, können demnach vernachlässigt werden bei der Bestimmung der Hauptfrequenzen. Veranschaulicht wird dies in der Abfolge in Abbildung 7-11.

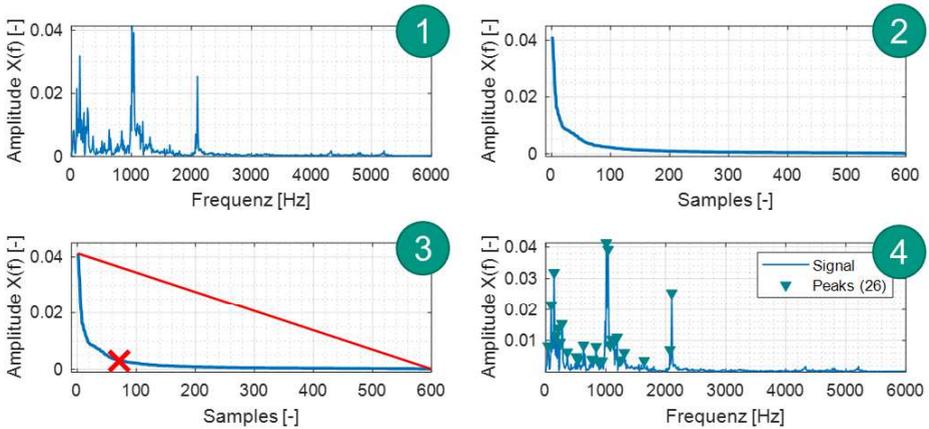


Abbildung 7-11: Visualisierung der Kniepunktsuche an einem beispielhaften Spektrum

In dem Beispiel reduziert der Algorithmus das Spektrum von 6000 diskreten Frequenz-Bins auf 26 Hauptfrequenzen, ohne dabei speziell auf das Spektrum abgestimmt zu sein. Hierfür ist lediglich die Vorgabe der Frequenzauflösung f_{res} notwendig, um diesen zusätzlichen Hyperparameter aufzulösen. Es kann die Vorgehensweise für die Kinematik des KGT genutzt werden, die in Abschnitt 7.3 vorgestellt wurde.

- d) Nach Erfassung der Hauptfrequenzen wird deren Anzahl N_f für die Bestimmung der Neuronen in den Schichten des Autoencoders genutzt.

Die Anzahl der Neuronen der Inputschicht entspricht dabei der Fenstergröße w der Rohdaten bzw. des FFT-Spektrums und für die Anzahl an versteckten Neuronen gilt $N_H = N_f$. Soll ein Autoencoder mit mehreren versteckten Schichten verwendet werden, wird die Anzahl der Neuronen jeweils so gewählt, dass von außen zur mittleren (versteckten) Schicht immer die gleiche Kompressionsrate vorliegt (siehe (A_Kistner 2021)).

Durch Einführen des AEN werden zunächst neue Hyperparameter genutzt, die es zu konfigurieren gilt. Ein großer Teil dieser Hyperparameter kann a-priori bestimmt und muss damit nicht von Nutzern in neuen Applikationen definiert werden. Trifft man bei der Auswahl der möglichen Hyperparameter einige Einschränkungen, so kann das Training des AEN komplett ohne Nutzereingabe stattfinden. Damit wird die Anomalieerkennung mittels AEN und MSE-Merkmal auch für Laien realisierbar.

Abbildung 7-12 zeigt grundsätzliche Einstellmöglichkeiten bei der Konfiguration von AEN. Rote Markierungen deuten an, dass diese Parameter in der vorliegenden Arbeit nicht betrachtet werden. Von (A_Kistner 2021) wurden diese Ausprägungen untersucht und es konnte gezeigt werden, dass sie bei der automatischen Konfiguration vernachlässigt werden können. Beispielsweise haben Regularisierungs- und Sparsity-Optionen zusammen mit dem Ansatz zur Bestimmung der Hauptfrequenzen für die Anzahl an versteckten Neuronen keine Verbesserung ergeben. Diese Hyperparameter werden daher nicht weiter betrachtet bzw. mit ihren Standardeinstellungen verwendet.

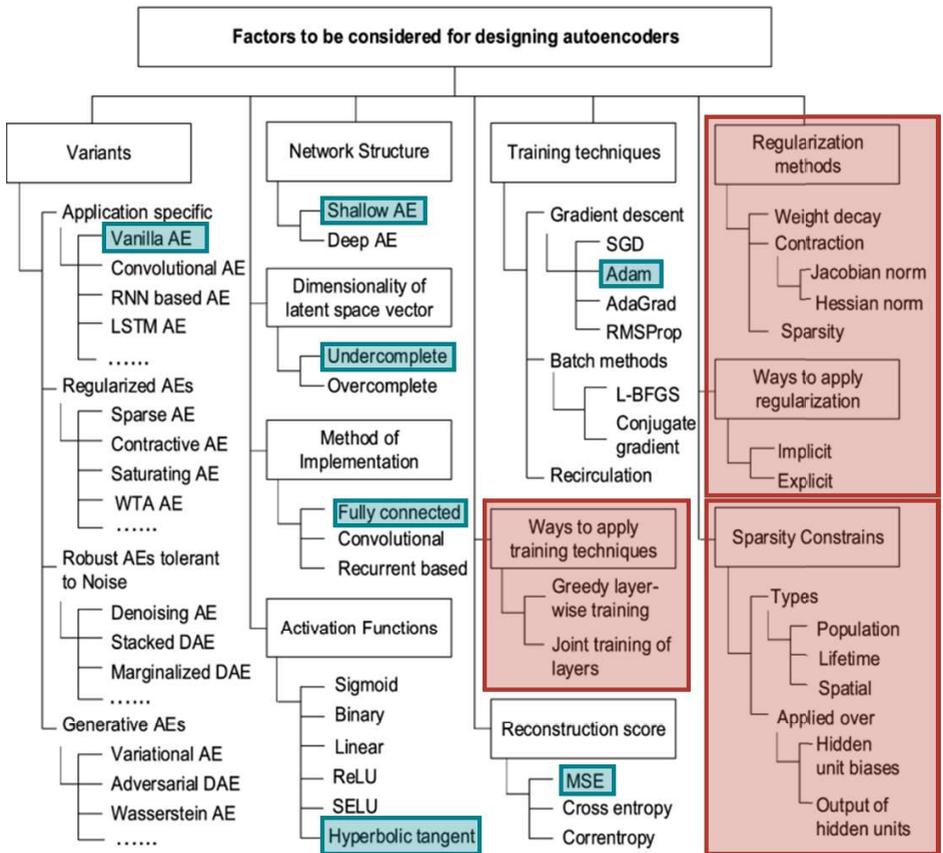


Abbildung 7-12: Übersicht der Einstellmöglichkeiten von Autoencodern (Pawar & Attar 2020)

Grün markiert sind Auswahlmöglichkeiten, welche bereits im Vorfeld getroffen werden können (empirisch oder durch Literaturrecherche begründet). Der Vanilla-Autoencoder wird als zugrunde liegende Architektur aufgrund seines einfachen Aufbaus ausgewählt. Durch (A_Kistner 2021) konnte weiterhin gezeigt werden, dass die Erhöhung der Anzahl an verdeckten Schichten im Sinne eines Deep-Autoencoders keine grundsätzliche Verbesserung gegenüber dem Shallow-Autoencoder (eine verdeckte Schicht) ergibt. AEN-Familie und Netzstruktur können somit schon im Vorfeld festgelegt werden. Diese Einschränkung ist nicht allgemeingültig, konnte aber für die verwendeten repräsentativen Datensätze gezeigt werden.

Aufgrund der Auswahl weniger Hauptfrequenzen N_f ist der AEN immer *under-complete*, d. h., er besitzt mehr Input-Neuronen als Neuronen in der versteckten Schicht. Die Schichten werden *fully-connected* ausgeführt, um den einfachen Netzaufbau abzurunden.

Die Aktivierungsfunktion in der Ein- und Ausgabeschicht wurde ebenfalls (A_Kistner 2021) anhand von Versuchen mit mehreren Datensätzen untersucht und bewertet. Für den finalen Modellaufbau wird folgende Konfiguration gewählt:

- Aktivierungsfunktion mit *Tangens hyperbolicus* (tanh), aufgrund der schnelleren Konvergenzeigenschaften beim Training (Pawar & Attar 2020),
- Ausgabeschicht: linear, besser geeignet für Regressionsaufgaben als die *Sigmoid*-Funktion (Géron 2019).

e) Nach dem Netzaufbau erfolgt das Training des AEN. Die Rohdaten für das Training erhält der AEN im laufenden Betrieb oder als historische Daten im Vorfeld. Damit verbleibt als wichtiger Hyperparameter noch die Anzahl an Trainingsepochen, die bestimmen, wie lange trainiert werden soll. Um hier keine Voreinstellungen vornehmen zu müssen, wird die Anzahl auf einen beliebig hohen Wert eingestellt, das Training aber mit *Early Stopping* ausgeführt (Montavon, Orr & Müller 2012, S. 53). Damit kann auch die Anzahl an Epochen datengetrieben gesteuert werden ohne a-priori-Angabe.

Als einziger Hyperparameter verbleibt somit f_{Res} für die Bestimmung der Hauptfrequenzen. Die Einschränkung und Festlegung von anderen Hyperparametern sowie das Design des AEN wurden von (A_Kistner 2021) umfangreich untersucht und die Erkenntnisse für die Parametrierung in dieser Arbeit übernommen.

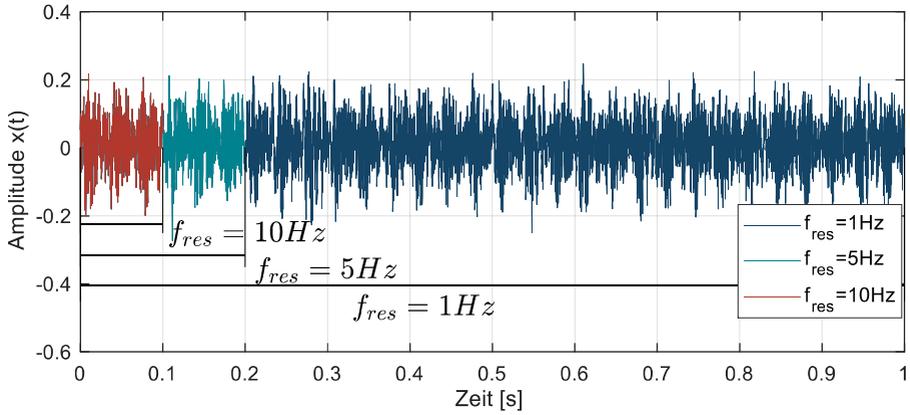
Im folgenden Abschnitt wird die Vorgehensweise an einem Benchmark-Datensatz erläutert.

Beispielhafte Anwendung an Vibrationsdaten von Motorkugellagern

Um die Autokonfiguration zu visualisieren, wird ein Datensatz mit Vibrationsdaten von Kugellagern verwendet (Bearing Data Center 2004). Der Datensatz umfasst Rohdaten von Vibrationssensoren, die während Baseline-Messungen und Messungen mit künstlichen Schäden aufgezeichnet wurden. Es handelt sich um Beschleunigungssensoren, die mit 12 kHz abgetastet wurden. In Abbildung 7-13 sind die Spektren eines Rohdatenabschnitts für verschiedene Frequenzauflösungen dargestellt. Das Verringern der Frequenzauflösung hat einen glättenden Effekt auf die Verteilung der Frequenzspitzen im Spektrum. Wird die Frequenzauflösung zu klein gewählt (große Abstände zwischen benachbarten Peaks), so kann Information über die Hauptfrequenzen verloren gehen.

Für das abgebildete Beispiel ist eine Frequenzauflösung $f_{res} = 10 \text{ Hz}$ ausreichend und wird für die verbleibende Berechnung verwendet.

a) Zeitverlauf



b) Frequenzspektrum für verschiedene Auflösungen

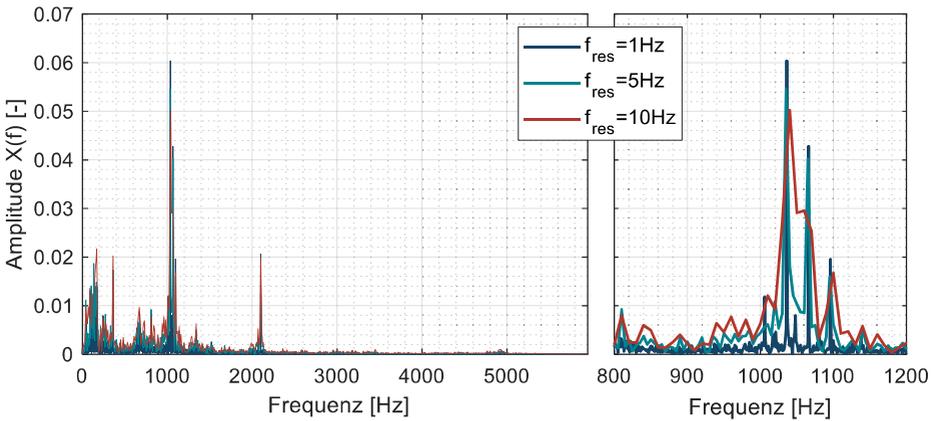


Abbildung 7-13: Einfluss der Frequenzauflösung auf das entstehende Spektrum

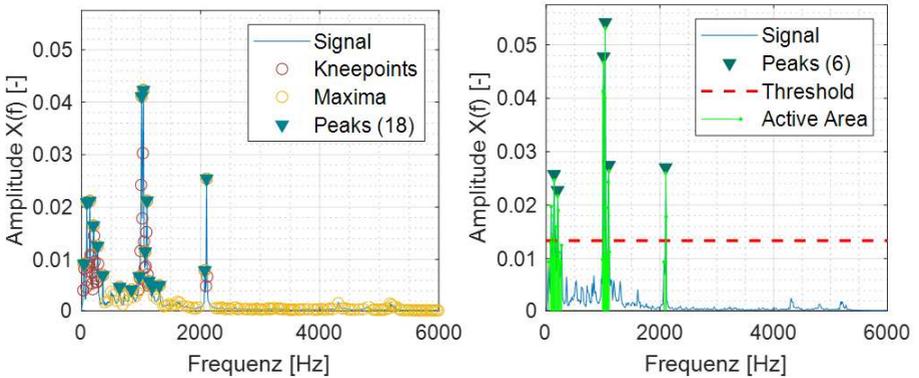


Abbildung 7-14: Kniepunktsuche (links) und Recursive-Peak-Finding (rechts)

Mit $f_{res} = 10 \text{ Hz}$ und $f_{sr} = 12 \text{ kHz}$ sind damit alle Hyperparameter für die Suche der Hauptfrequenzen bekannt. In Abbildung 7-14 sind die Detektionsergebnisse für die zwei Varianten des Peak-Finders dargestellt. Die beiden Verfahren liefern aufgrund ihrer Konzeption unterschiedliche Ergebnisse. Dabei ist die Kniepunktsuche konservativer und liefert mehr Hauptfrequenzen. Recursive-Peak-Finding bietet hingegen mit dem Grenzwert-Ansatz und der rekursiven Berechnung gute Ergebnisse für stark veräuschte Spektren (ist im Gegenzug aber rechenintensiver).

Für die weiteren Berechnungen wird $N_f = N_H = 18$ verwendet. Mit der gewählten Einstellung und den Randbedingungen, die oben beschrieben werden, wird nun ein AEN aufgebaut und mit Daten aus dem Baseline-Datensatz trainiert. Dabei wird ein 70-30-Split für Trainings- und Testdaten verwendet.

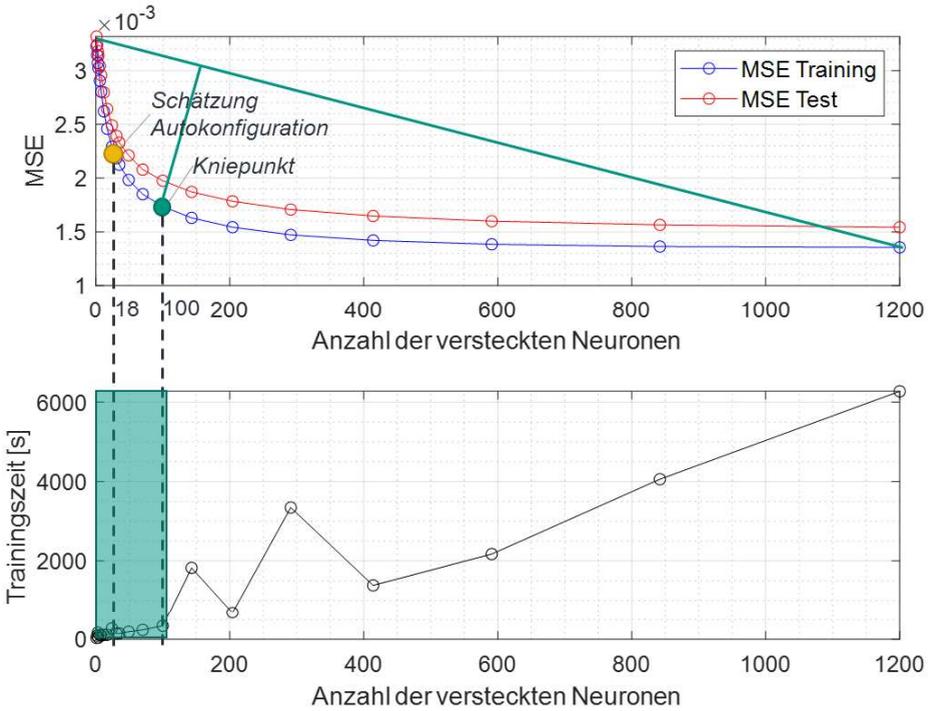


Abbildung 7-15: Rekonstruktionsfehler in Abhängigkeit der Neuronen im Hidden Layer
 Mit der Autokonfigurationsmethode soll eine schnelle Schätzung der notwendigen Neuronen ermöglicht werden. Es handelt sich jedoch nicht automatisch um die optimale Lösung. Abbildung 7-15 veranschaulicht den Zusammenhang zwischen Trainings- bzw. Testfehler, der Anzahl an versteckten Neuronen und der benötigten Trainingszeit.

Grundsätzlich soll der Autoencoder eine möglichst gute Abstraktion des Signals erreichen, dabei möglichst wenig Zeit zum Training benötigen und mit wenigen charakteristischen Peaks bzw. einer geringen Anzahl an Neuronen in der versteckten Schicht auskommen.

Im oberen Graph in Abbildung 7-15 ist für den Beispieldatensatz der Rekonstruktionsfehler über die Anzahl der Neuronen aufgetragen. Gelb markiert sind die geschätzten N_H auf Basis der Hauptfrequenzsuche und in Grün ist der Punkt markiert, der den Ellbogenpunkt der Kurve darstellt.

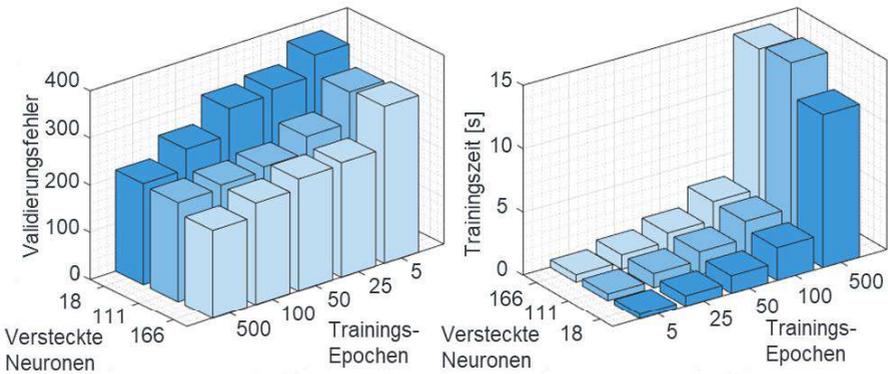


Abbildung 7-16: Validierungsfehler und Trainingszeit über Epochen und Größe des Hidden-Layer

Dieser Punkt gibt an, dass bei weiterer Erhöhung der Anzahl an Neuronen nur wenig Besserung des Trainingsfehlers erreichbar ist. Zusätzlich zeigt das untere Diagramm, dass für mehr Neuronen auch deutlich höhere Trainingszeiten entstehen. Natürlich können in offline und überwachten Trainingsszenarien diese Ellbogenpunkte für die beste AEN-Konfiguration automatisch gefunden werden. Solche AutoML-Ansätze sind jedoch rechenintensiv und lassen keine a-priori-Schätzung zu, wenn die Daten nicht bereits bekannt sind (He, Zhao & Chu 2021). Die Schätzung des Parameters mittels Hauptfrequenzanalyse stellt daher einen guten Kompromiss dar, der auch online aufgrund des geringeren Rechenaufwands durchgeführt werden kann.

In Abbildung 7-16 kann darüber hinaus bestätigt werden, dass bereits mit geringer Anzahl an Trainingsepochen ein Validierungsfehler erreicht wird, der bei längerem Training nur geringfügig besser wird. Hierbei werden drei verschiedene AEN gegenübergestellt, wobei einer mit $N_H = 18$ aus der Schätzung trainiert wurde. Der Einfluss der Anzahl an Neuronen bei steigender Anzahl an Trainingsepochen nimmt dabei drastisch ab. Bei 100 Trainingsepochen ist dieser Unterschied im Validierungsfehler nur noch sehr gering zwischen den einzelnen AEN. Er ließe sich zwar mit längerer Trainingszeit noch weiter reduzieren (500 Epochen). Es gilt jedoch ein sinnvolles Abbruchkriterium für das Training zu finden, da mit zunehmender Anzahl der Epochen die Trainingszeit ansteigt. Wie bereits oben beschrieben, wird hierfür in dieser Arbeit *Early Stopping* eingesetzt.

7.5 Teilsystem Clusterbildung

Ganz allgemein verstehen sich die Begriffe Clustering bzw. Clusteranalyse als das Gruppieren von ähnlichen bzw. gleichen Datenpunkten. Beim Entstehen dieser Gruppen bzw. Cluster kommen in der Literatur unterschiedliche Algorithmen und Methoden zum Einsatz. Bei der Auswahl des richtigen Clusteralgorithmus gibt es nicht nur eine optimale Lösung. Je nach Anwendung, Problemstellung und Daten muss eine systematische Vorauswahl getroffen werden, die das Feld der möglichen Algorithmen einschränkt. Von (Wegmann et al. 2021) wird eine systematische Vorgehensweise für die Clusteranalyse vorgeschlagen und ein Nachschlagewerk zur Auswahl eines Algorithmus bereitgestellt (https://jhillenbrand.github.io/cluster_table.html). Im Rahmen dieser Arbeit wird die Vorgehensweise angewendet, um einen Clusteralgorithmus für das CM-System auszuwählen.

Die Möglichkeiten der Clusterbildung sollen im Rahmen der Arbeit für die Beschreibung von Systemzuständen verwendet werden. In Abschnitt 3.2 wurde der Begriff des Zustands bereits eingeführt. Um eine datengetriebene Erfassung eines Zustands im Sinne der Zustandsüberwachung bzw. Anomaliedetektion zu ermöglichen, muss der Begriff Zustand im Kontext der Clusterbildung definiert werden. Die bisherige DEFINITION 7 muss hierfür erweitert werden, um den Zusammenhang mit den erfassten Sensordaten bzw. daraus extrahierten Merkmalen herzustellen:

DEFINITION 10. Zustand im Kontext Clusterbildung

Gegeben sei $f_{m,i}$ als Merkmalsvektor zum Zeitpunkt t_i und Ω_{S_j} als Menge von Merkmalsvektoren, die den Zustand S_j im Merkmalsraum R^m begrenzen. Ein gemessenes Merkmal $f_{m,i}$ kann in einem System E dem Zustand S_j zugewiesen werden, wenn $f_{m,i} \cap \Omega_{S_j} \neq \emptyset$. Die Intersektion der Teilmengen kann in Form einer Hypersphäre $H \in R^m$, die Ω_{S_j} repräsentiert, geprüft werden. Liegt $f_{m,i}$ innerhalb der Hypersphäre H , entspricht das gemessene Merkmal zum Zeitpunkt t_i dem Zustand S_j .

In Abbildung 7-17 ist DEFINITION 10 für den 2D-Fall visualisiert. Abgebildet ist der Merkmalsraum, der von den beiden Merkmalen $\{f_1, f_2\}$ aufgespannt wird. Es sind zwei Zustände S_1 und S_2 vorhanden, die durch die Ränder $\Omega_{S_1}, \Omega_{S_2}$ gebildet werden. Die Ränder bzw. Grenzen entstehen durch Gruppierung der verschiedenen Merkmalsvektoren $f_{m,i}$. Je nach räumlicher Lage von weiteren Merkmalsvektoren können diese einem bestehenden Zustand zugewiesen werden.

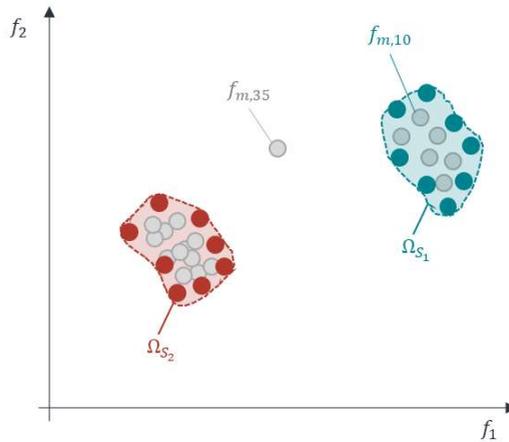


Abbildung 7-17: Schematische Darstellung von Merkmalen und Zuständen im R^2

So gehört $f_{m,10}$ zu Zustand S_1 und $f_{m,35}$ kann keinem Zustand zugeordnet werden, es handelt sich (zu diesem Zeitpunkt) um einen Ausreißer oder eine Anomalie.

Aus der Definition ergeben sich zwei Fragestellungen:

- Wie können die Ränder Ω_{S_j} ermittelt werden, die die Zustände S_j begrenzen?
- Wie wird die Zuordnung eines Merkmalsvektors $f_{m,i}$ zu einem Zustand S_j hergestellt?

Für die Bestimmung der Grenzen (en. *boundaries*) können sogenannte α -Shapes verwendet werden. Dabei handelt es sich um eine Verallgemeinerung der konvexen Hülle einer Form. Mit dem Algorithmus von (Edelsbrunner & Mücke 1994) können diese Formen auf 2D/3D-Punktwolken bestimmt werden. Über die entstehenden α -Shapes können dann auch die Punkte, die die Grenzen der Punktwolke definieren, bestimmt werden. Für höher dimensionale Räume stehen Hypersphären bzw. deren Oberflächen als einschließende Mannigfaltigkeiten zur Verfügung. In dieser Arbeit werden jedoch nur Merkmalsräume in R^3 betrachtet.

Unter Fragestellung b) kann die klassische Clusterbildung verstanden werden, die in Abschnitt 2.3.2 eingeführt wurde. Damit stellen Clusterverfahren eine bereits mathematisch formalisierte Möglichkeit zur Detektion von Zuständen dar. Das Ergebnis der Clusteringverfahren sind Gruppierungen im Merkmalsraum, die als Zustände interpretiert werden können. Auf Basis des erlernten Clustermodells kann für folgende Datenpunkte

(neue Messungen) entschieden werden, ob sie zu bereits erfassten Zuständen gehören oder eine Anomalie bzw. einen neuen Zustand darstellen. Wird zusätzlich die zeitliche Komponente der Clusterergebnisse berücksichtigt, kann die zeitliche Entwicklung von Zuständen mit betrachtet werden.

Als Clusterverfahren kommt eine Vielzahl von Algorithmen infrage. Mit Hilfe der Vorgehensweise von (Wegmann et al. 2021) konnte bereits im Vorfeld der Arbeit DBSCAN als geeigneter Clusteralgorithmus identifiziert werden. Unter Berücksichtigung der Kriterien in Abschnitt 4.3 stellt er eine passende Wahl für Cluster mit Ausreißern, wenigen Hyperparametern und einer im Vorfeld unbekanntem Clusteranzahl dar. Die Funktion von DBSCAN wird von (Ester et al. 1996) erstmals eingeführt und im Programmcode in Anhang A 17 beschrieben.

Ein wichtiger Gesichtspunkt bei der Anwendung von Clusterverfahren für die Anwendung in der Zustandsüberwachung ist ihre Eignung für *Datenstreams* (siehe Abschnitt 2.3.2.1). Neben schnellen Ausführzeiten ist vor allem in Langzeitüberwachungsszenarien eine speichereffiziente Vorhaltung der bisherigen Clusterergebnisse und deren inkrementelles Update von Vorteil.

Konventionelle Clusteralgorithmen arbeiten mit globalen Modellupdates (*Oneshot-Clustering*) über den gesamten Datensatz. Kommt ein neuer Datenpunkt hinzu, muss der vollständige Datensatz erneut geclustert werden. Abhilfe schaffen Clusterverfahren, wie das *Data Stream Clustering* (siehe Abschnitt 2.3.2.1), durch Verwerfen von alten Daten und einem inkrementellen Modellupdate.

Im Kontext von CM-Applikationen entsteht hierbei ein Konflikt, der von konventionellen *Data Stream Clustering* Verfahren nicht adressiert wird: Da sich die Zeitspanne, in der sich ein Systemzustand verschlechtert (Wochen, Monate oder gar Jahre), deutlich von den Abstraten herkömmlicher Sensoren (wenige Hertz bis zu mehreren Megahertz) unterscheidet, müssen die Daten kontinuierlich komprimiert und weiterverarbeitet werden. Ansonsten müssen historische Daten verworfen werden. Beim CM können jedoch lange zurückliegende Daten und deren Merkmale entscheidend für die Bewertung eines Systemzustands sein, beispielsweise bei langsam fortschreitendem Verschleiß.

Zur Lösung dieser Problematik wird im Kontext dieser Arbeit ein neues Clustermodell verwendet, das von (Hillenbrand & Fleischer 2021) bereits vorgestellt wurde. Der neue Ansatz, *Cluster-Boundary-Tracking*, stellt eine neue Datenstruktur, Clustermechanismen und Möglichkeiten zur Beschreibung zeitlicher Clusterentwicklung vor. Er verfolgt

das Ziel, sowohl die Clusterhistorie effizient im Speicher vorzuhalten als auch geringe Ausführzeiten für kontinuierliche Datenströme zu gewährleisten.

Wie der Name bereits verrät, findet die Identifikation bzw. Beschreibung eines Clusters durch die Menge an Randpunkten statt, die im Folgenden mit *Boundary*-Punkten bezeichnet werden. Dadurch unterscheidet sich das Datenmodell von klassischen Ansätzen im *Data Stream Clustering*, die hauptsächlich sogenannte Merkmalsvektoren (en. *feature vectors*) zur Beschreibung eines Clusters einsetzen. Diese lassen sich inkrementell aktualisieren, wenn neue Datenpunkte dazukommen. Allerdings geht die Information über die Form des Clusters verloren, da sie das Cluster als Zentroiden mit Radius R annähern und keine Dichteinformation speichern. Das *Cluster-Boundary*-Modell stellt im Kontext von *Data Stream Clustering* eine *Prototyparray*-Variante dar (Silva et al. 2013) und setzt sich für ein Cluster C_j wie folgt zusammen:

- Anzahl der Datenpunkte N_j , aus dem das Cluster besteht,
- Menge an *Boundary*-Punkten $\{b_l\}_j$,
- Volumen V_j , das vom Cluster eingenommen wird,
- Dichte ρ_j des Clusters.

Durch diese Art der Speicherung ergeben sich folgende Vorteile:

- Information über die Form und Dichte des Clusters kann beibehalten werden,
- inkrementelles Cluster-Update möglich, durch Prüfung, ob neue Punkte innerhalb der *Boundary*-Punkte liegen,
- Rekonstruktion der bereits verworfenen Datenpunkte durch Clusterdichte ρ_j und Anzahl der enthaltenen Datenpunkte N_j .

Werden lediglich die *Boundary*-Punkte vorgehalten und die inneren Clusterpunkte verworfen, ergeben sich enorme Speichereffizienzvorteile. In Abbildung 7-18 ist der Unterschied der beiden Modellvarianten grafisch dargestellt.

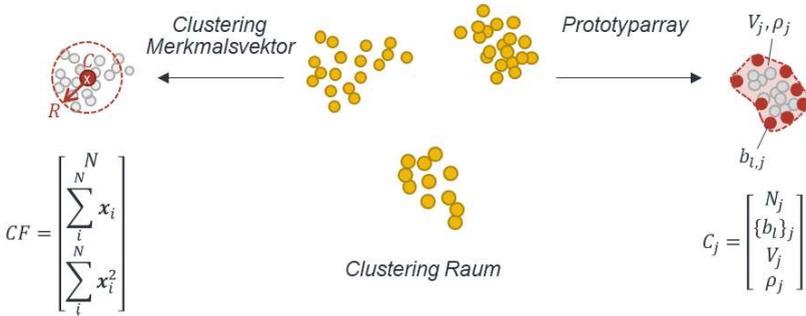


Abbildung 7-18: Clustermodellvarianten: Merkmalsvektor (links) und Prototyparray bzw. Cluster-Boundary-Modell (rechts)

Die inneren Clusterpunkte sind der größte Bestandteil an Datenpunkten in einem Clustering. In Abbildung 7-19 wird die exemplarische Entwicklung der Verteilung von Datenpunkten auf die drei Gruppen *Ausreißer*, *Boundary*- und innere Clusterpunkte aufgezeigt. Die Zunahme von inneren Clusterpunkten ist bei kontinuierlich abgetasteten Datenströmen linear. Je nach zugrunde liegender Datenverteilung fällt die Zunahme der *Boundary*-Punkte mit deutlich geringerer Steigung aus oder kann sogar ein degresives Wachstum vorweisen, besonders bei konvexen Clusterformen. In jedem Fall sind im Modell deutlich weniger *Boundary*-Punkte zu berücksichtigen, als wenn alle Datenpunkte berücksichtigt werden müssen. Wenn neue Datenpunkte hinzukommen, muss mit Clusterverfahren wie dem DBSCAN vollständig neu geclustert werden. Um die Rechenzeit zu verringern, wird in der vorliegenden Arbeit vor dem Neoclustern geprüft, ob der neue Datenpunkt bereits zu einem existierenden Cluster gehört. In diesem Fall wird auf erneutes Clustern verzichtet und der Datenpunkt wird einfach zum Cluster hinzugefügt bzw. die Dichte und die Anzahl der Datenpunkte im Clustermodell werden aktualisiert.

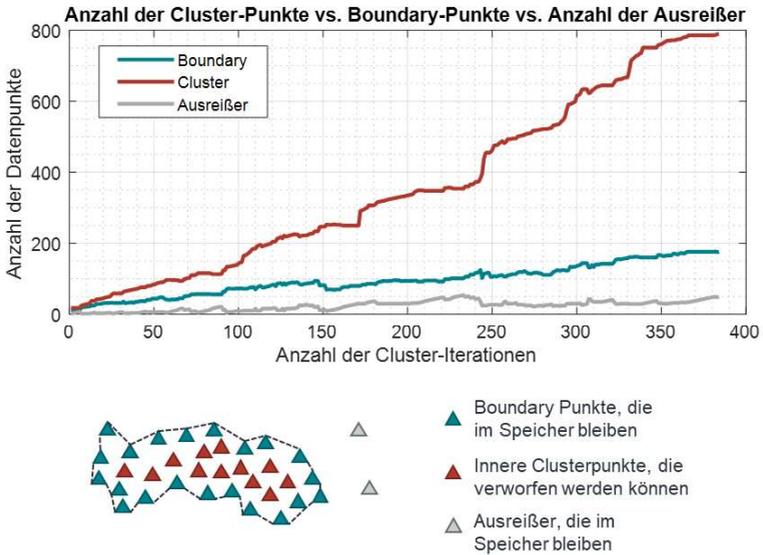


Abbildung 7-19: Verteilung der Datenpunkte innerhalb eines Clusterings über die Anzahl an Iterationen, nach (Hillenbrand & Fleischer 2021)

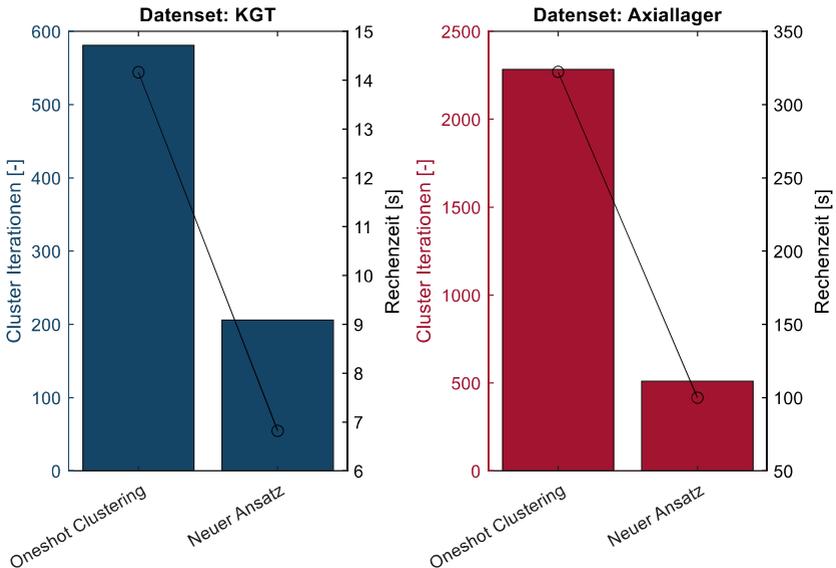


Abbildung 7-20: Zeitersparnis durch den neuen Ansatz, nach (Hillenbrand & Fleischer 2021)

Das Potenzial dieser Zeitersparnis ist in Abbildung 7-20 dargestellt. Von (Hillenbrand & Fleischer 2021) wurden Experimente mit zwei Datensätzen durchgeführt, um das *Cluster-Boundary*-Modell und dessen Eigenschaften zu untersuchen. Mit dem *Cluster-Boundary*-Modell lässt sich zu jedem Zeitpunkt das gesamte Clustering beschreiben und daraus ableiten, in welchem Zustand (*Boundary*) sich der aktuelle Datenpunkt, d. h. das System, befindet. Um auch eine Detektion der Zustandsänderungen zu ermöglichen, wird im nächsten Abschnitt das Cluster-Tracking erläutert.

7.6 Teilsystem Cluster-Tracking

In Abschnitt 2.3.2.2 wurde der Begriff Cluster-Tracking bereits eingeführt. Hier wird nun die Implementierung für das CM-Problem, das der Arbeit zugrunde liegt, veranschaulicht. Ziel des Cluster-Trackings ist eine automatisierte Beschreibung der zeitlichen Clusterevolution. Richtig erfasst kann diese Information genutzt werden, um die Aussagequalität von CM-Systemen zu verbessern, ohne auf Supervised Training mit Labels für die Systemzustände angewiesen zu sein.

Mit dem im vorherigen Abschnitt erwähnten *Cluster-Boundary*-Modell können auch über lange Zeiträume Informationen vorgehalten werden, ohne dass Datenpunkte verworfen werden müssen. Um die entstehenden Cluster über die Zeit zu beobachten und Cluster-Transitionen gemäß (Spiliopoulou et al. 2006) festzustellen, wird eine eigene Version von *MONIC* implementiert.

Wie in der Original-Implementierung wird zwischen externen und internen Transitionen unterschieden. Eine Transition ist intern, wenn sie die Form und den Inhalt eines Clusters betrifft. Sie ist extern, wenn sie die Beziehung zu anderen Clustern im Clustering-Ergebnis charakterisiert. Kernfunktion des Tracking-Mechanismus ist die Feststellung von übereinstimmenden Clustern zwischen den aufeinanderfolgenden Zeitpunkten. Die Implementierung unterscheidet sich vom Original in der Umsetzung der Funktion zur Ermittlung dieser Übereinstimmung von Clustern. Als Kriterium für die Übereinstimmung zwischen Cluster X und Y wird bestimmt, ob die Datenpunkte $x_i \in X$ Teilmenge von $y_j \in Y$ sind. Im Fall von Objekten im R^m werden Objekte mit gleichen Merkmalen als Übereinstimmung markiert. Eine grafische Erklärung ist in Abbildung 7-21 dargestellt. Die verwendeten Funktionen werden in Anhang A 18 erläutert.

Zu jeder Cluster-Tracking-Iteration wird für die Datensets D_i und D_j die Funktion *areClusterMatches* aufgerufen, die die Übereinstimmungsmatrix *matchMatrix* und Überlappmatrix *overlapMatrix* bestimmt. Über die beiden Matrizen können im nächsten

Schritt mit den Anweisungen in Anhang A 19 die externen Transitionen bestimmt werden. Dazu gehören die *Create*, *Merge*, *Split*, *Vanish* und *Survive* Transition. In Abschnitt 2.3.2.2 sind diese externen Transitionen bis auf die *Survive* Transition schematisch abgebildet. Bei der *Survive* Transition bleibt das Cluster erhalten, ohne dass externe Änderungen auftreten, und wird daher nicht zusätzlich aufgeführt.

Ein Beispiel für die Bestimmung der Transitionen anhand der *overlapMatrix* wird in Abbildung 7-22 veranschaulicht.

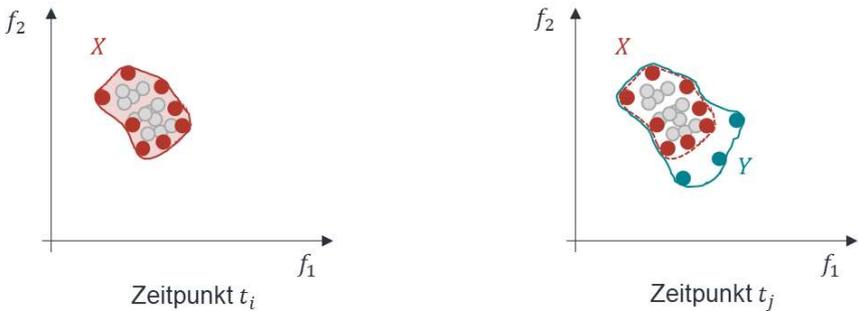


Abbildung 7-21: Visualisierung einer Cluster-Übereinstimmung

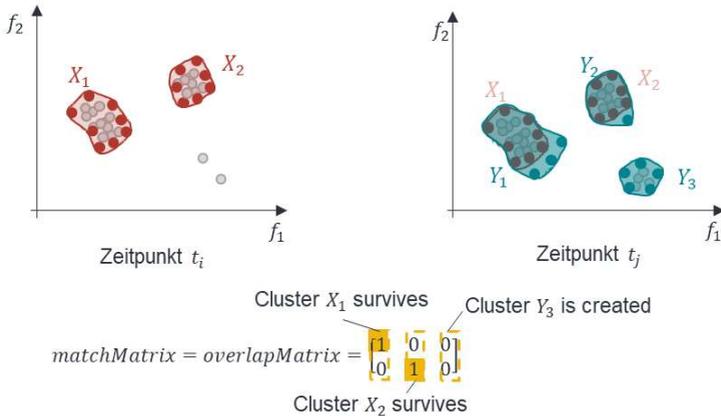


Abbildung 7-22: Grafische Visualisierung der Clustertransitions-Berechnung

Als interne Transitionen werden wie in *MONIC* die Größenentwicklung der Cluster (*Size Transition*) und die Intra-Cluster-Distribution (*IntraCluster Transition*) betrachtet.

Der Grenzwert, ab dem ein Cluster als wachsend bzw. schrumpfend bezeichnet wird, wird in dieser Arbeit über einen Kurvenfit-Ansatz (datengetriebenen Ansatz) vorgenommen. Dadurch muss kein neuer Hyperparameter für einen Grenzwert eingeführt werden.

Hierzu wird für jedes Cluster C_i im Datenset D_j zu jeder Iteration j die Größe des Clusters V_{C_i} , sofern $V_{C_i,j} > V_{C_i,j-1}$, gespeichert. Dadurch kann der Verlauf von wachsenden Clustern verfolgt werden. Schrumpfende Cluster sind aufgrund der Implementierung ohne Vergessmechanismus nicht notwendig (vgl. (Silva et al. 2013)). Auf die sich entwickelnden Clustergrößenverläufe werden Kurvenfits mit verschiedenen Ansatzfunktionen angewandt. Hierzu gehören konstante, lineare, kubische, hyperbolische, exponentielle, logarithmische und normalverteilte Ansatzfunktionen, die in Anhang A 23 aufgelistet sind. Zu jeder Clusteriteration werden nun die Ansatzfunktionen auf den Verlauf der Clustergröße gefittet. In Abbildung 7-23 wird dies exemplarisch am Beispiel der konstanten und exponentiellen Kurvenanpassung visualisiert. Es ist die zeitliche Entwicklung der Clustergröße über die Zeitpunkte t_1 bis t_3 dargestellt. Der exemplarische Verlauf zeigt die Funktionsweise für die Detektion von *Size Transition*. Die Funktion mit dem geringsten Fehler wird als repräsentatives Modell bestimmt.

Anstatt einen Grenzwert festzulegen, wird die *Size Transition* über ihren charakteristischen Verlauf definiert.

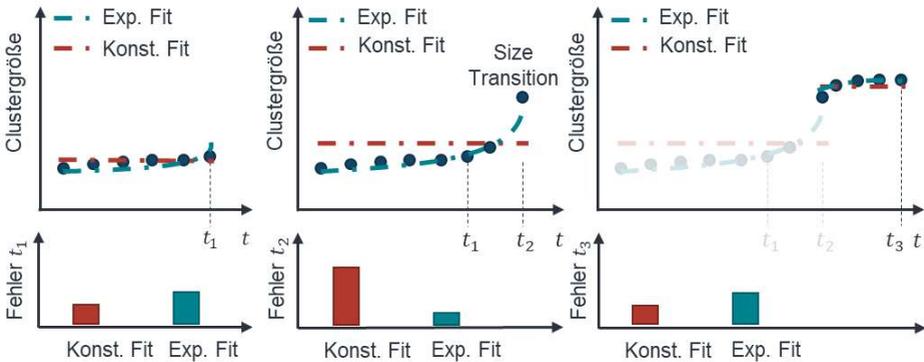


Abbildung 7-23: Verlauf der Clustergröße und des Curve-Fitting-Fehlers

Für das Bestehen eines stabilen Clusterwachstums wird entweder konstantes oder logarithmisches Wachstum festgelegt. Ergibt sich für eine andere Ansatzfunktionen eine bessere Kurvenanpassung, so wird eine *Size* Transition ausgelöst (mittleres Bild, Abbildung 7-23). Nach dem Auftreten einer Transition wird der vorige Verlauf verworfen und das Tracking beginnt von vorne (rechter Teil der Grafik in Abbildung 7-23).

Zudem werden in *MONIC* eine *Location* Transition und *Compactness* Transition eingeführt. Für die *Location* Transition wird die Bewegung des Clusterzentrums innerhalb eines Clusters über die Zeit herangezogen. Um keine Grenzwertdefinition vornehmen zu müssen, wird auch hier auf die Kurvenanpassung zurückgegriffen. Abbildung 7-24 veranschaulicht die Bedeutung dieser Transition und wie sie verfolgt werden kann. Derselbe Mechanismus wird auch für die *Compactness* Transition, die als Referenzgröße die Dichte des Clusters betrachtet, angewendet. Darüber hinaus wird die *IntraCluster* Transition eingeführt. Als Maß für eine *IntraCluster* Transition wird die Intra-Cluster-Varianz gewählt. Die Varianz und der zugehörige Erwartungswert (Mittelwert) werden für gleichverteilte Messungen wie folgt berechnet (Georgii 2015):

$$\begin{aligned}\mathbb{E}(X) &= \mu = \frac{1}{n} \sum_{i=1}^n x_i \\ \mathbb{V}(X) &= \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\end{aligned}\tag{7-6}$$

In der *Cluster-Boundary-Tracking*-Anwendung stehen die Clusterpunkte vom vorherigen Schritt jedoch nicht mehr zur Verfügung, da sie durch die *Boundary* vereinfacht und verworfen werden. Um dennoch zu jedem Zeitschritt den Mittelwert und die Varianz eines Clusters zu berechnen, müssen diese inkrementell aktualisiert werden. Eine stetige Neuberechnung wäre darüber hinaus nicht recheneffizient. In Formel 7-7 ist die Vorschrift für das inkrementelle Update der beiden Größen Mittelwert μ und Varianz σ^2 beschrieben:

$$\begin{aligned}\mu_{n+1} &= \frac{1}{n+1} (n \cdot \mu_n + x_{n+1}) \\ \sigma_{n+1}^2 &= \frac{1}{n+1} (n \cdot \sigma_n^2 + (x_{n+1} - \mu_{n+1})^2)\end{aligned}\tag{7-7}$$

Zusätzlich zu den anderen Ansatzfunktionen wird auch die Normalverteilung f_7 herangezogen (siehe Anhang A 23). Die *IntraCluster* Transition beschreibt dabei eine Änderung der Verteilung der Merkmale innerhalb eines Clusters. Sie dient zur Detektion von Clustern innerhalb anderer Cluster. Dies ist notwendig, wenn beispielsweise ein Clusteringmodell auf Daten mit großen Vibrationsamplituden trainiert wird, dann aber lange Zeit ein Bereich mit kleinen Vibrationsdaten vorliegt. Dort kann es passieren, je nach

gewählten Merkmalen, dass der Bereich mit geringen Amplituden einfach innerhalb des ursprünglichen Clusters verschwindet. Tritt dieses Verhalten beim Cluster-Tracking ein, so wird eine *IntraCluster* Transition ausgelöst.

In Abbildung 7-24 wird dieser Umstand visualisiert. In der Grafik wird ein Clustering gezeigt für zwei unterschiedliche Fälle: gleichverteilte Messpunkte und ungleich verteilte Messpunkte, die zur *IntraCluster* Transition führen. Zunächst wird in der oberen Grafik a) das graue Cluster betrachtet. In dieses Cluster kommen neue Datenpunkte hinzu (rot), die der gleichen Verteilung entsprechen wie die bisherigen Punkte. Im zugehörigen Fenster *Location* Transition ist die Bewegung des Clusterzentrums zu beobachten und im Fenster *Intracluster-Varianz* ist die Standardabweichung abgebildet. Für das gleichverteilte Cluster findet in diesen Fenstern nahezu keine Änderung statt. Anders verhält es sich mit neuen Datenpunkten, die einer anderen Datenverteilung (möglicher neuer Zustand), siehe hierzu Grafik b), entstammen. Die markierten roten Datenpunkte entstehen lediglich in einem Teilvolumen des bisherigen Clusters. Daher verschiebt sich der Mittelpunkt des Clusters. Dies lässt sich anhand der linearen Drift des Clusterzentrums in Grafik b) oben rechts erkennen. Eine ähnliche Abweichung ist bei der *Intracluster-Varianz* in Grafik b) unten rechts zu beobachten.

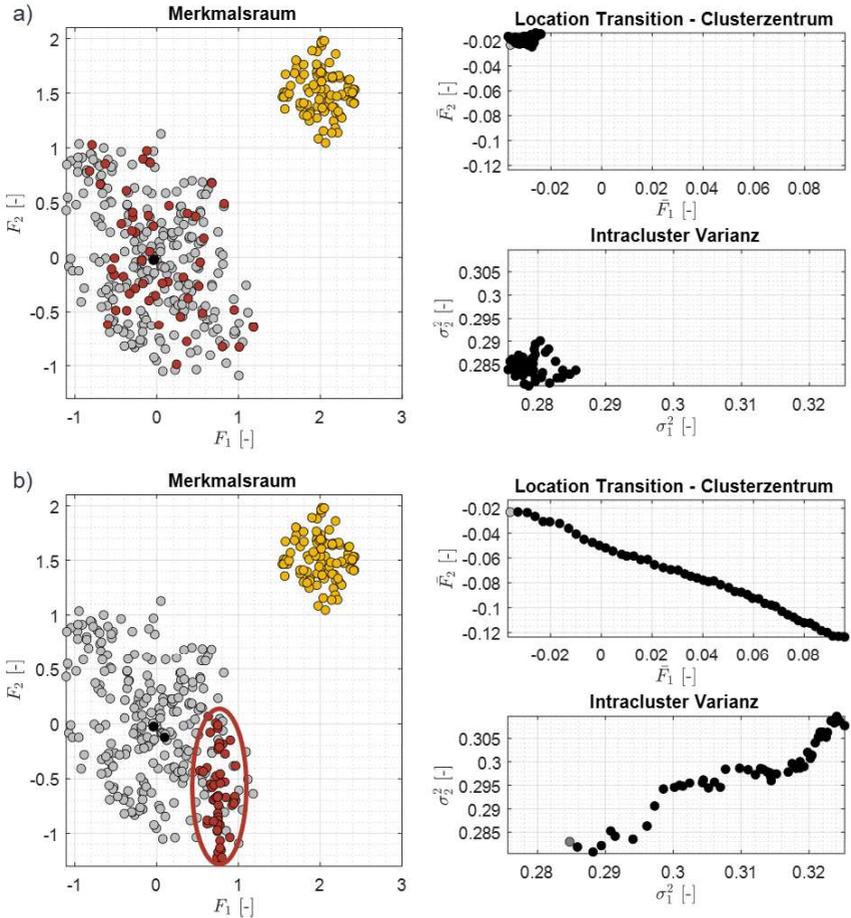


Abbildung 7-24: IntraCluster-Verteilungen: a) gleichverteilt und b) mit IntraCluster

Bei den Clusterräumen in Abbildung 7-24 handelt es sich um simulierte Normalverteilungen, die der Streuung von Sensorwerten nachempfunden sind. Exemplarisch lässt sich damit der Effekt von Intracluster-Varianz aufzeigen und die Bedeutung ihrer Überwachung nachvollziehen.

Neben den bereits in *MONIC* definierten Cluster-Transitionen wird im Rahmen dieser Arbeit außerdem die Evolution von Ausreißern betrachtet. Clusteralgorithmen wie DBSCAN geben bereits Ausreißer in ihren Clusterergebnissen an. Die zeitliche Entwicklung dieser Ausreißer kann im Cluster-Tracking mitberücksichtigt werden.

Die Transitionen beziehen sich dabei auf das gesamte Clustering eines Zeitpunkts und werden deshalb in einer eigenen Kategorie (globale Transitionen) geführt. Es werden im Rahmen der Arbeit zwei Ausreißer-Transitionen unterschieden: Die *OutlierCreate* Transition und die *OutlierVanish* Transition. In Abbildung 7-25 sind die beiden Transitionen exemplarisch dargestellt: Die *OutlierCreate* Transition wird ausgelöst, wenn die Anzahl an neu hinzugekommenen Ausreißern im Vergleich zum vorherigen Clustering eine definierte Anzahl überschreitet. Im Fall des DBSCAN-Algorithmus kann hier der Hyperparameter *MinPts* als Grenzwert gewählt werden. Dadurch werden keine weitere Hyperparameter eingeführt und es kommt zum Ausdruck, dass ein neues Cluster hätte entstehen können, aber die Ausreißer nicht dicht genug beieinander liegen. Die *OutlierVanish* Transition wird ausgelöst, wenn zwischen D_i und D_{i+1} Ausreißer um einen beliebigen Grenzwert abnehmen (dieser wird wie zuvor als *MinPts* bestimmt). Die Transition stellt das Pendant zu *OutlierCreate* Transitionen dar, die Transitionen können sich gegenseitig aufheben. Wird zum Beispiel die Anzahl von *OutlierCreate* Transitionen dazu genutzt, um eine Frühwarnung auszulösen, so kann die Anzahl der *OutlierVanish* Transitionen abgezogen werden, um eine zu sensitive Anomalieerkennung zu verhindern.

Die Cluster-Transitionen lassen sich auch in eine CM-Perspektive übertragen. Ein Vorschlag hierzu wurde bereits von (Hillenbrand & Fleischer 2021) veröffentlicht. Die Tabelle 7-2 gibt eine Übersicht über die Interpretation aus Sicht der Zustandsüberwachung.

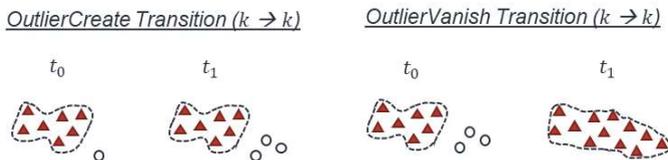


Abbildung 7-25: Schematische Abbildung der Ausreißer-Transitionen

Tabelle 7-2: Transitionen und ihre Bedeutung für die Zustandsüberwachung

Transition	Typ	Beschreibung
<i>Create</i>	extern	Die Cluster-Neuentstehung (Creation) kündigt einen neuen Betriebsmodus oder Verschleißzustand/Ausfall an.
<i>Merge</i>	extern	Es können zwei Operationsmodi existieren, zwischen welchen oft gewechselt wird und die sich dadurch irgendwann zu einem Cluster verbinden (<i>Merge</i>).
<i>Split</i>	extern	Tritt nur auf, wenn Cluster-Objekte mit einem Alterungsgewicht (<i>age</i>) in das Clustering eingehen. Im Kontext dieser Arbeit findet diese Transition keine Anwendung.
<i>Vanish</i>	extern	siehe <i>Split</i>
<i>Survive</i>	extern	Neue Datenpunkte werden einzig und allein dem aktuellen Cluster zugeordnet. Das System wird in einem stationären Zustand betrieben und zeigt keine Anzeichen von Verschleiß.
<i>Size</i>	intern	Wenn die Clustergröße (<i>Size</i>) zunimmt, kann das auf Instabilitäten im Prozess oder in den Betriebsbedingungen hinweisen oder allgemein als Streuung interpretiert werden. Der Fall von kleiner werdenden Clustern wird in dem Kontext der Arbeit vernachlässigt, siehe <i>Split</i> .
<i>Location</i>	intern	Ein Clusterzentrum (Schwerpunkt) bewegt sich von seiner ursprünglichen Position weg. Es liegt eine Sensor-Drift oder langsamer Verschleißprozess vor.
<i>Compactness</i>	intern	Wenn die Kompaktheit (<i>Compactness</i>) zunimmt und die Clustergröße gleich bleibt, befindet sich das beobachtete System in einem stationären Zustand. Für den Fall, dass die Kompaktheit abnimmt, siehe <i>Split</i> .
<i>IntraCluster</i>	intern	Wenn sich innerhalb eines Clusters die Verteilung verschiebt, kann eine Concept Drift vorliegen. Ein Zustand innerhalb eines Zustands kann vorliegen. Ein Neutraining des Clustermodells sollte vorgenommen werden.
<i>OutlierCreate</i>	global	Die Entstehung von Ausreißern kündigt das Entstehen eines neuen Zustands an oder eine abrupte Änderung. Die Beobachtung kann Früh Schäden oder einen Ausfall ankündigen.
<i>OutlierVanish</i>	global	Die Transition neutralisiert eine vorige <i>OutlierCreate</i> Transition. Das Aufheben von zuvor erkannten Ausreißern entspricht dem Stabilisieren oder sich Ausbreiten/Ausweiten eines Zustands, vgl. <i>Size</i> .

Eine Lücke, die bisher noch nicht über das Cluster-Tracking abgedeckt wird, ist die Interpretation von wiederkehrenden Zuständen. Neue Datenpunkte gehören nicht mehr zum aktuellen Cluster, es kommt aber zu einem späteren Zeitpunkt zur Rückkehr in dieses Cluster. Die Detektion dieser Zustandsübergänge kann verwendet werden, um Zustände von Anomalien zu unterscheiden.

Die bereits eingeführte DEFINITION 7 kann zur formellen Zusammenführung des Cluster- und Trackingergebnisses mit der Interpretation als Zustandsänderung genutzt werden. Die Überführung der Clusterergebnisse und Cluster-Transitionen in ein Zustandsmodell gemäß dieser Definition erlaubt die Berücksichtigung der zeitlichen Dauer eines Zustands und der Häufigkeit seines Auftretens.

Aus der Definition lassen sich Regeln für die Bestimmung der Zustandsänderung ableiten:

a) Für stabile Zustände kann folgender Formalismus definiert werden:

$$S_i^t: \{d_i, \sum_{m=1}^N \sum_{m=1}^N p_{m,m}\}, \text{ mit } p_{m,m} > p_{stable} \text{ und } d_i > d_{stable} \tag{7-8}$$

b) Zwei Zustände können als reversibel bezeichnet werden, wenn gilt:

$$p_{i,j}^1 > p_{rev} > 0 \text{ und } p_{j,i}^2 > p_{rev} > 0 \tag{7-9}$$

c) Ein Zustand S_i^t ist eine Anomalie, wenn für alle $S_k^t \in E^t$ gilt:

$$\sum_{k=1}^N \sum_{i=1}^N p_{k,i} < p_{anomaly} \text{ und } d_i < d_{anomaly} \tag{7-10}$$

Für jedes Cluster, das sich über die Zeit entwickelt, wird ein Zustand angelegt. Das Zustandsmodell beschreibt den Systemzustand in Form einer Zuordnung zu einem der in Tabelle 7-3 dargestellten Zustände. Die Berechnung der Zustände wird anhand des Schemas in Abbildung 7-26 verdeutlicht. Als Input für die Berechnung dient die Historie der Clusterergebnisse und der Transitionen. In jeder Cluster-Tracking-Iteration wird hiermit das Zustandsmodell aktualisiert, d. h., für jedes vorhandene oder neue Cluster und für detektierte Ausreißer wird in der Tabelle eine Bewertung hinsichtlich des Zustands auf Basis der möglichen Kategorien vorgenommen.

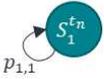
Diese Berechnungen bzw. Zustandszuweisungen werden in einem Zustandsmodell (Objekt) gespeichert, um später in einer Visualisierung wiederverwendet zu werden.

Tabelle 7-3: Zustandszuordnung im Cluster-Tracking-Modell

Zustand	
1. Normal	2. Anomalie
1.1 inaktiv	2.1 inaktiv
1.2 aktiv	2.2 aktiv
1.2.1 Ausbreitung	2.2.1 Ausbreitung
1.2.2 Abnahme	2.2.2 Abnahme
	2.3 Intracluster

Externe Transitionen

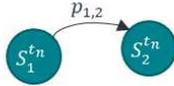
1) Survive Transition



$$p_{1,1} = p_{1,1} + 1$$

Normal aktiv

2) Creation Transition



$$p_{1,2} = 1$$

$$d_2 = 0$$

Normal aktiv

3) Merge Transition



$$d_i = \max(d_i, d_{i+1})$$

$$p_{1,2} = 0$$

Normal Ausbreitung

Globale Transitionen

4) OutlierCreate Transition



$$d_{-1} = d_{-1} + 1$$

Anomalie Ausbreitung

5) OutlierVanish Transition



$$d_{-1} = d_{-1} - 1$$

Anomalie Abnahme

Interne Transitionen

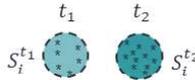
6) Size Transition



$$d_i = \max(d_i, d_{i+1})$$

Normal Ausbreitung

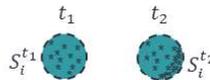
7) Compactness Transition



$$\rho_{t_1} < \rho_{t_2}$$

Normal

8) IntraCluster Transition



$$\sigma_{t_1}^2 \ll \sigma_{t_2}^2$$

Anomalie IntraCluster

Legende:

Zugeordneter Zustand

Abbildung 7-26: Aktualisierungsvorschrift für ein Zustandsmodell

Die im Vorfeld definierten externen Transitionen können für die Beschreibung von normalen Zuständen wie folgt interpretiert werden: Ein normaler Zustand liegt vor, wenn *Survive* Transitionen erfolgen, neue Datenpunkte somit dem vorherigen, aktuellen Cluster zugeordnet werden können. Ein Systemzustand gilt ebenfalls als normal, wenn eine *Create* Transition entsteht. Ausnahmen bilden Systeme, die nur einen normalen Zustand einnehmen können. Entsteht für diese Systeme ein weiteres Cluster, kann von

einer Anomalie ausgegangen werden. Beim Auftreten von *Merge* Transitionen verbinden sich die Merkmalsräume zweier Cluster bzw. Zustände. Das System befindet sich weiter im Normalzustand, es können jedoch Wechsel zwischen verschiedenen Betriebszuständen vorliegen, die ähnlich sind. Die globalen Transitionen *OutlierCreate* und *OutlierVanish* beschreiben die Zu- oder Abnahme von Anomalien. Je nach gewünschter Sensibilität kann das CM-System auf jede Anomalie reagieren oder erst dann, wenn ein Grenzwert $d_{anomaly}$ überschritten wird. Das Zusammenspiel zwischen *OutlierCreate* und *OutlierVanish* gibt wieder, dass entstandene Anomalien wieder in *normale* Datenpunkte umgewandelt werden können. Das Entstehen eines neuen Zustands kann zu Beginn ebenso als Anomalie verstanden werden. Daher muss dem Cluster-Tracking-Modell die Möglichkeit eingeräumt werden, diese Anomaliezuordnung wieder aufzuheben.

Informationen, die während des Cluster-Trackings entstehen, werden in einem Schaubild konsolidiert, das die detektierten Zustände beschreibt und Übergänge zwischen diesen festhält. Für den Kontext dieser Arbeit wird dieses Schaubild als Zustandsdiagramm bezeichnet, da es von der Darstellung von Zustandsautomaten aus dem Bereich UML-Modellierung abgeleitet ist (Seemann 2006, S. 108). Beispielhafte Zustandsdiagramme und deren Elemente sind in Anhang A 22 abgebildet.

8 Validierung des Unsupervised Condition-Monitoring-Systems

Zur Validierung der Unsupervised Architektur, die in den vorherigen Abschnitten hergeleitet worden ist, werden im Folgenden zwei Architekturvarianten vorgestellt. Diese werden mit Hilfe von mehreren Datensätzen validiert und im Anschluss bezüglich Automatisierungsgrad und Detektionsgüte bewertet. Die Daten, die zur Validierung dienen, werden im Abschnitt 8.2 im Rahmen der durchgeführten Versuchsreihen vorgestellt. Die Datensätze können für die Validierung automatisiert als simulierter Rohdatenstream zur Verfügung gestellt werden. Somit wird die Funktion unter realen Bedingungen sichergestellt. Für die unterschiedlichen Validierungsversuche werden die Architekturvariante, das (Verschleiß-)Szenario und der Prüfstand unterschieden. Insgesamt ergeben sich 20 Untersuchungen auf Basis von zwei Architekturvarianten, sieben (Verschleiß-)Szenarien und zwei Prüfständen. In Tabelle 8-1 sind diese aufgelistet und werden eindeutig mit der ID (Architekturvariante-Szenario-Prüfstand) beschrieben. Die Nomenklatur für die ID der Untersuchungen (siehe Tabelle 8-1) ergibt sich wie folgt:

Architekturvariante:

- 1: Vordefinierte Merkmalsextraktion (RMS, MF, P2P)
- 2: MSE-Merkmalsextraktion

(Verschleiß-)Szenario:

- 1: Verschiedene Drehzahlen
- 2: Verschiedene Lasten bei konstanter Drehzahl
- 3: Mangelschmierung
- 4: Partikeleinbringung
- 5: Vorspannungsstufen bei konstanter Drehzahl
- 6: Vorspannungsstufen bei verschiedenen Drehzahlen
- 7: Ermüdung durch erhöhte Last

Prüfstand:

- 1: 2-Achs-KGT-RZA
- 2: 5-Achs-KGT

Tabelle 8-1: Untersuchungsvarianten der Unsupervised Architektur

#ID	Architekturvariante	(Verschleiß-)Szenario	Prüfstand
1-1-1	Vordefinierte Merkmalsextraktion	Verschiedene Drehzahlen	2-Achs-KGT-RZA
1-2-1	Vordefinierte Merkmalsextraktion	Verschiedene Lasten bei konstanter Drehzahl	2-Achs-KGT-RZA
1-3-1	Vordefinierte Merkmalsextraktion	Mangelschmierung	2-Achs-KGT-RZA
1-4-1	Vordefinierte Merkmalsextraktion	Partikeleinbringung	2-Achs-KGT-RZA
1-5-1	Vordefinierte Merkmalsextraktion	Vorspannungsstufen bei konstanter Drehzahl	2-Achs-KGT-RZA
1-6-1	Vordefinierte Merkmalsextraktion	Vorspannungsstufen bei versch. Drehzahlen	2-Achs-KGT-RZA
2-1-1	MSE-Merkmalsextraktion	Verschiedene Drehzahlen	2-Achs-KGT-RZA
2-2-1	MSE-Merkmalsextraktion	Verschiedene Lasten bei konstanter Drehzahl	2-Achs-KGT-RZA
2-3-1	MSE-Merkmalsextraktion	Mangelschmierung	2-Achs-KGT-RZA
2-4-1	MSE-Merkmalsextraktion	Partikeleinbringung	2-Achs-KGT-RZA
2-5-1	MSE-Merkmalsextraktion	Vorspannungsstufen bei konstanter Drehzahl	2-Achs-KGT-RZA
2-6-1	MSE-Merkmalsextraktion	Vorspannungsstufen bei versch. Drehzahlen	2-Achs-KGT-RZA
1-1-2	Vordefinierte Merkmalsextraktion	Verschiedene Drehzahlen	5-Achs-KGT
1-2-2	Vordefinierte Merkmalsextraktion	Verschiedene Lasten bei konstanter Drehzahl	5-Achs-KGT
1-4-2	Vordefinierte Merkmalsextraktion	Partikeleinbringung	5-Achs-KGT
1-7-2	Vordefinierte Merkmalsextraktion	Ermüdungsversuch mit erhöhter Last	5-Achs-KGT
2-1-2	MSE-Merkmalsextraktion	Verschiedene Drehzahlen	5-Achs-KGT
2-2-2	MSE-Merkmalsextraktion	Verschiedene Lasten bei konstanter Drehzahl	5-Achs-KGT
2-4-2	MSE-Merkmalsextraktion	Partikeleinbringung	5-Achs-KGT
2-7-2	MSE-Merkmalsextraktion	Partikeleinbringung	5-Achs-KGT

Die hier eingeführten Architekturvarianten werden in Abschnitt 8.1 beschrieben und stellen unterschiedliche Ausprägungsstufen hinsichtlich Automationsgrad und Integration von Domänenwissen dar. Die Versuchsszenarien werden im darauffolgenden Abschnitt 8.2 vorgestellt. Die Beschreibung der Prüfstände hat bereits in Kapitel 5 stattgefunden.

Durch Betrachtung der unterschiedlichen Szenarien auf verschiedenen Prüfständen mit verschiedenen Architekturvarianten soll die Generalität des Ansatzes validiert werden. Im folgenden Abschnitt werden Unsupervised Systeme vorgestellt, die aus den in Kapitel 7 vorgestellten Teilsystemen bestehen.

8.1 Unsupervised Architekturvarianten

Die nachfolgenden Architekturvarianten bestehen aus den Teilsystemen, wie sie in Kapitel 7.1 bis 7.6 beschrieben werden. Die Ausprägung der einzelnen Teilsysteme weicht dabei voneinander ab. Gemeinsam ist den Varianten jedoch der Teil der Clusterbildung und des Cluster-Trackings. Es werden die gleichen Systeme zur Erkennung von Zuständen und Anomalien für alle drei Varianten verwendet (DBSCAN als Clusteralgorithmus und *Cluster-Boundary-Tracking* als neu eingeführtes System zur Zustandserkennung und Anomaliedetektion). Im Besonderen unterscheiden sich die Kategorien Segmentierung und Merkmalsextraktion hinsichtlich ihres Automationsgrades, der verwendeten Datenquellen und der Nutzung von Domänenwissen.

Die zwei Architekturvarianten werden im Folgenden vorgestellt und auf Unterschiede verglichen. Im Betrieb wird für die Architekturvarianten, wenn für die Konfiguration des Systems erforderlich, eine Initialisierungs- und eine Monitoringphase unterschieden. In der Initialisierungsphase wird das System vollständig auf Basis von Rohdaten parametrisiert oder wartet auf ausreichend viele Daten für die datengetriebene Konfiguration. Systeme wechseln in die Monitoringphase, wenn die notwendigen Teilsysteme vollständig konfiguriert sind. Diese Phase entspricht dem Online-Betrieb des Überwachungssystems. Während des Betriebs kann jederzeit von der Monitoringphase in die Initialisierungsphase zurückgegangen werden, um eine Konfiguration zu optimieren oder das System neu anzulernen oder weiter zu trainieren.

Variante 1 – Vordefinierte Merkmalsextraktion

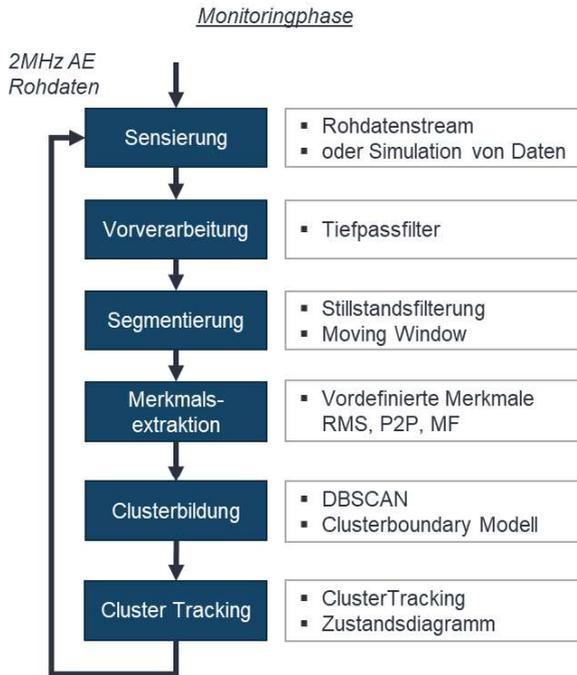


Abbildung 8-1: Variante 1 – Vordefinierte Merkmalsextraktion

Abbildung 8-1 zeigt den Aufbau von Architekturvariante 1. Die Rohdaten werden dem System als Rohdatenstream oder simulierte Rohdaten zur Verfügung gestellt. Als Vorbearbeitungsstufe dient ein Tiefpassfilter, der Rauschen im Rohsignal unterdrückt.

Die Segmentierung ist mit zwei Teilfunktionen ausgeführt: Zuerst durchläuft das Signal einen Stillstandsfilter, der alle Signalabschnitte, die für einen bestimmten Zeitraum $t_{min,Stillstand}$ unterhalb eines Stillstandsgrenzwerts $\tau_{Stillstand}$ bleiben, entfernt. Danach werden die übrigen Signalabschnitte mit Hilfe eines *Moving-Window-Filters* in kleinere Signalabschnitte für die Merkmalsextraktion zerlegt.

Für die Merkmalsextraktion werden in dieser Architektur drei Merkmale aus Anhang A 14 verwendet. Es handelt sich hierbei um die Merkmale RMS, P2P und MF. Die Vorauswahl dieser Merkmale fand auf Basis von Vorversuchen statt (siehe Abschnitt 6.2) und setzt damit bereits eine Vorarbeit voraus, die nicht unüberwacht (Unsupervised) stattgefunden hat.

Nach Berechnung der Merkmale werden diese mit dem DBSCAN-Algorithmus geclustert und kontinuierlich mit Hilfe des *Cluster-Boundary*-Modells überwacht.

Die Clusterergebnisse werden, wie in Abschnitt 7.6 beschrieben, mit Bausteinen zum Cluster-Tracking in Zustandsdiagrammen dargestellt.

Variante 2 – Allgemeine Unsupervised Architektur mit MSE-Merkmalsextraktion

Variante 2 unterscheidet sich von Variante 1 vor allem bei der Merkmalsextraktion. Als Baustein für die Merkmalsextraktion wird ein Autoencoder mit seinem Rekonstruktionsfehler verwendet, wie er in Abschnitt 7.4.2 beschrieben wird. In der Monitoringphase sind sonst alle Teilsysteme gleich gestaltet. Um den Autoencoder anfänglich zu konfigurieren, ist jedoch eine Initialisierungsphase notwendig. In dieser wird die Autokonfiguration des Autoencoders auf Basis der Inputdaten vorgenommen, siehe Abschnitt 7.4.2. Sobald ein trainierter Autoencoder zur Verfügung steht, wird dieser in der Monitoring-Phase benutzt, um Zustände und Anomalien zu detektieren.

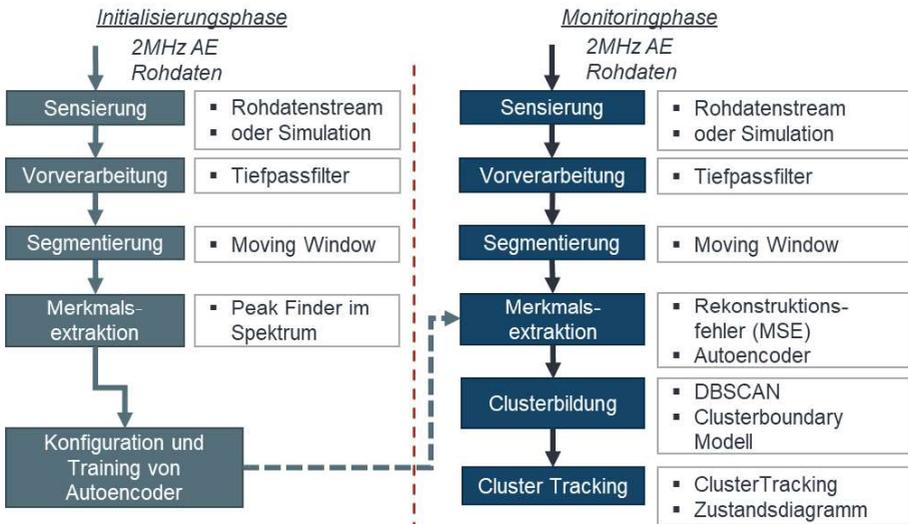


Abbildung 8-2: Variante 2 – Allgemeine Unsupervised Architektur mit MSE-Merkmals-extraktion

8.2 Untersuchung des Kugelgewindetriebs mit Acoustic Emission

Nach der vorläufigen und prinzipiellen Untersuchung von AE im Kontext der Überwachung von Wälzkontakten am Beispiel von Axialkugellagern soll die Zielanwendung von KGT nun genauer untersucht werden.

Reales Verschleißverhalten von Maschinenelementen ist häufig mit sehr langen Laufzeiten verbunden. Wird beispielsweise ein KGT (Beispiel gemäß Anhang A 2) mit einer dynamischen Tragzahl $C_{dyn} = 23.6 \text{ kN}$ betrachtet, der mit einer üblichen Last in Werkzeugmaschinen von 10 bis 15 Prozent von C_{Dyn} betrieben wird, so ergeben sich nach den Formeln 8-1 und 8-2 bei einer mittleren Geschwindigkeit von $\varnothing n_s = 1250 \text{ 1/min}$ Laufzeiten von $t_{L_{10}} = 165 - 555$ Tagen, bis 100 Prozent der theoretischen Lebensdauer erreicht sind. Diese langen Betriebszeiten sind im Rahmen von Forschungsprojekten nicht abdeckbar und würden bei der Durchführung an einer Werkzeugmaschine sehr lange den Normalbetrieb verhindern. Im Kontext von Forschungsarbeiten zur Komponente wird deshalb zumeist auf Prüfstände zurückgegriffen, die eine Betrachtung des Verschleiß- oder Betriebsverhaltens außerhalb des Störungseinflusses der Gesamtmaschine ermöglichen.

$$L_{10} = \left(\frac{C_{dyn}}{F} \right)^3 \cdot 10^6 \quad 8-1$$

$$t_{L_{10}} = \frac{L_{10}}{\varnothing n_s \cdot 24 \cdot 60} \quad 8-2$$

Um darüber hinaus lange Versuchsdauern zu verkürzen und natürlichen Verschleiß an Wälzkörperlaufbahnen hervorzurufen, sind in der Technik und Forschung verschiedene Vorgehensweisen bekannt. Eine Übersicht liefert Tabelle 8-2. Einige dieser Methoden sind im Kontext von Wälzlagern entstanden, sie lassen sich aber auf KGT-Laufbahnen übertragen.

Tabelle 8-2: Künstliche Schadensformen für die Untersuchung von KGT

Simulierter Schaden	Methode	Beschreibung	Quelle
Grübchen Abrasiveverschleiß	Funkenerosion	Erzeugung geschlitzter Oberflächenschäden mit Erodiermaschine	(Smith & Randall 2015, S. 102) (Lessmeier et al. 2016, S. 5)
Pitting	Bohrungen	Laufbahn und Kontaktstelle der Kugeln werden mit Bohrungen versehen	(Lee et al. 2015) (Lessmeier et al. 2016)
Abrasiveverschleiß	Kontaminierter Schmierstoff	Einbringung von Fremdpartikeln in Wälzkontakt über Schmierstoff	(Verl et al. 2009, S. 376)
Eindrücke Oberflächenzerrüttung	Rockwell-Eindrücke	Erstellung von V-förmigen Eindrücken mittels Rockwell-Prüfkörper	(Sommer, Heinz & Schöfer 2014, S. 246)
Rissbildung	Handbohrer	Einbringung eines Schlitzes auf der Laufbahn	(Omoregbee & Heyns 2018, S. 20)
Mangelschmierung Adhäsionsverschleiß	geringe Schmierung/Entfettung	Durch Entfernen des schützenden Schmierfilms kann frühzeitiger Adhäsionsverschleiß hervorgerufen werden	(Sommer, Heinz & Schöfer 2014, S. 18)
Pitting	elektrisches Gravurgerät	Erstellung künstlicher Pittings ohne abrupte Übergänge von beschädigter zu unbeschädigter Oberfläche	(Lessmeier et al. 2016)
Vorspannungsverlust	Wahl unterschiedlicher Kugeldurchmesser	KGT wird mit Kugelsätzen unterschiedlichen Aufmaßes betrieben	(Denkena, Bergmann & Schmidt 2021)
Vorspannungsverlust	unterschiedliche Vorspannungsklassen	KGT gleicher Baugröße werden mit unterschiedlichen Vorspannungsklassen betrieben	(Tsai, Cheng & Hwang 2014)
Vorspannungsverlust	Doppelmutter mit einstellbarem Abstandshalter/Displacer	Variation des Abstandshalters ermöglicht das Einstellen von unterschiedlichen Vorspannungsniveaus	(Nguyen, Ro & Park 2019)
Ermüdung	überhöhte Last	Betrieb des KGT mit Lasten deutlich über den in Werkzeugmaschinen üblichen 10-15 % der dynamischen Tragzahl C_{dyn}	(Schopp 2009, S. 94)

Die Schadensphänomene, die im Rahmen dieser Arbeit betrachtet werden, sind Abrasiveverschleiß durch Partikeleintrag, Mangelschmierung, Vorspannungsverlust durch unterschiedliche Vorspannungsklassen und Ermüdungsverschleiß durch zeitgeraffte Versuche mit überhöhter Last (graue Markierungen in Tabelle 8-2). Die Untersuchung beschränkt sich auf diese Szenarien aufgrund der Relevanz der Ausfallmechanismen für den KGT. Insbesondere Mangelschmierung, Verunreinigung und Vorspannungsverlust sind im Bereich der Werkzeugmaschinen weit verbreitet (vgl. auch Abbildung 1-2).

Vor den jeweiligen Versuchsszenarien werden die KGT jeweils Messungen zu unterschiedlichen Last- und Geschwindigkeitsprofilen unterzogen. Diese Messungen werden im Folgenden mit Baseline-Messung bezeichnet. Im folgenden Abschnitt werden die Versuchsmodalitäten weiter detailliert und vorgestellt. Die Versuchsreihen dienen als repräsentative Signalquellen für den Betrieb von KGT und werden zur Entwicklung des CM-Systems eingesetzt. Teile dieser Versuchsreihen sind im Rahmen des DFG-Projektes mit Projektnummer 388141462 entstanden (DFG 2017). Die Versuchsreihen entsprechen dabei den genannten Szenarien in Tabelle 8-1 und werden nachfolgend eingeführt.

Szenario 1 und 2 – Baseline-Messungen (Drehzahl und Last)

Eine Teilaufgabe des zu entwerfenden CM-Systems ist das Erkennen von Zustandsänderungen, die durch neue Betriebszustände repräsentiert werden können. Diese Betriebsänderung hat nichts mit auftretendem Verschleiß oder Anomalien zu tun und muss daher ebenso robust detektiert werden. Zu diesem Zweck werden im Fall KGT die zwei Betriebszustandsänderungen Axialkraft- und Drehzahlvariation betrachtet. Die Variation der beiden Faktoren wird als Baseline-Messung, d. h. als Aufzeichnung des Normalzustands, bezeichnet. Im Besonderen konnte bereits in den Vorversuchen am Axiallager in Abschnitt 6.2 die Drehzahländerung als Faktor mit starkem Einfluss auf das AE-Signal festgestellt werden. Eine robuste Unterscheidung, ob es sich bei dem sich ändernden Signal um eine Drehzahländerung oder um Verschleiß handelt, ist daher essenziell für ein gelungenes CM-System.

Für die Baseline-Messungen sind Versuchsfahrten an den jeweiligen Versuchsträgern für verschiedene KGT durchgeführt worden. In Tabelle 8-3 ist exemplarisch der Versuchsplan für den Versuchsträger 5-Achs-KGT für Axialkraft und Drehzahl dargestellt.

Tabelle 8-3: Versuchsplan für Geschwindigkeiten und Axiallasten an 5-Achs-KGT

		Anzahl an Versuchen		
Faktor Axiallast [kN]	2.5	6	6	6
	12	6	6	6
		200	400	600
		Faktor Drehzahl [1/min]		

Die Faktorstufen unterscheiden sich je nach verwendetem Versuchsträger und eingebautem KGT, die Faktoren (Drehzahl und Axialkraft) und das Untersuchungsziel bleiben jedoch gleich.

Ein Versuch innerhalb des Versuchsplans besteht aus einer Hin- und Rückfahrt mit definiertem Hub und den variierenden Faktoren des Versuchsplans. Während der Fahrten werden entsprechend den verfügbaren Datenquellen Messdaten aufgezeichnet, die für die Versuchsträger in Abschnitt 5 vorgestellt worden sind.

Abbildung 8-3 stellt exemplarisch eine Versuchsfahrt bei einer Drehzahl $n_s = 600 \frac{1}{min}$ dar. Die Fahrt besteht aus den Segmenten Stillstand (1) und Anfahrtsrampe (2a), dem Konstantfahrbereich (3), dem Abbremsen (2b) und einem erneuten Stillstand. Durch Wahl einer ausreichend großen Stillstandszeit wird sichergestellt, dass Schwingungen aus der vorherigen Fahrt keinen Einfluss auf die nächste Messung haben. Außerdem wird sichergestellt, dass keine Temperatureffekte auftreten, die in Anhang A 15 als ein Nachteil der piezoelektrischen Sensoren aufgeführt werden, da die Achse so genug Zeit zum Abkühlen bekommt.

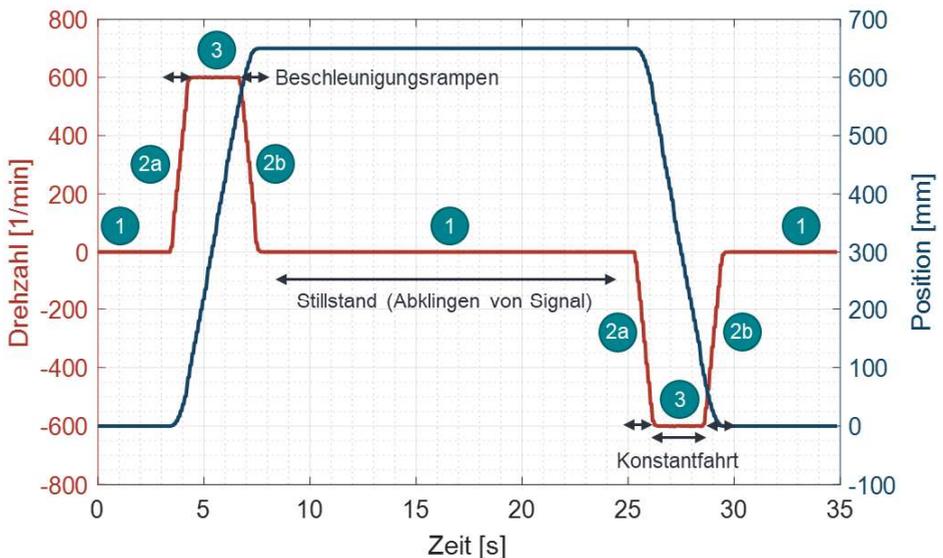


Abbildung 8-3: Hin- und Rückfahrt einer Versuchsfahrt mit Segmenten bei einer Drehzahl von 600 U/min

Szenario 3 – Mangelschmierung

In dieser Versuchsreihe wird der KGT in einem mangelgeschmierten Zustand und einem ordentlich geschmierten Zustand verglichen. Um im Wälzkontakt des KGT Adhäsionseffekte zu simulieren, die unter langfristiger Wirkung zu erhöhtem (adhäsivem) Verschleiß führen, wird die Linearachse unter Ausschluss von Fettschmierung, nur mit der vom Hersteller applizierten initialen Konservierung (einem Öl) betrieben. Durch die Abwesenheit ausreichender Schmierung im Wälzkontakt kann sich in der Wälzkontaktzone kein elasto-hydrodynamischer Schmierzustand (EHD) ausbilden. Das führt zur Bildung direkter Metall-Metall-Kontaktstellen ohne schützenden Schmierfilm. Die entstehende Reibung, das Schließen und Aufbrechen dieser Adhäsionsstellen führt zu AE. Liegen die Adhäsionsstellen zu lange ohne ausreichenden Schmierstoff vor, so kommt es zum typischen Schadensbild Fressen (vgl. (NSK Europe LTD 2017)).

Aufgrund der besseren Montierbarkeit werden die Einzelversuche am Versuchsträger 2-Achs-KGT-RZA an jeweils drei KGT mit unterschiedlicher Vorspannung (siehe Anhang A 2) durchgeführt. In den zwei Schmierzuständen werden erneut die Drehzahl und die Last variiert. Es entsteht ein vollfaktorieller Versuchsplan (siehe Abbildung 8-4), für den jede Faktorstufenkombination fünf Mal wiederholt wird. Es ergeben sich 300 Versuchsfahrten pro Achse, für die AE- und Antriebsdaten aufgezeichnet werden.

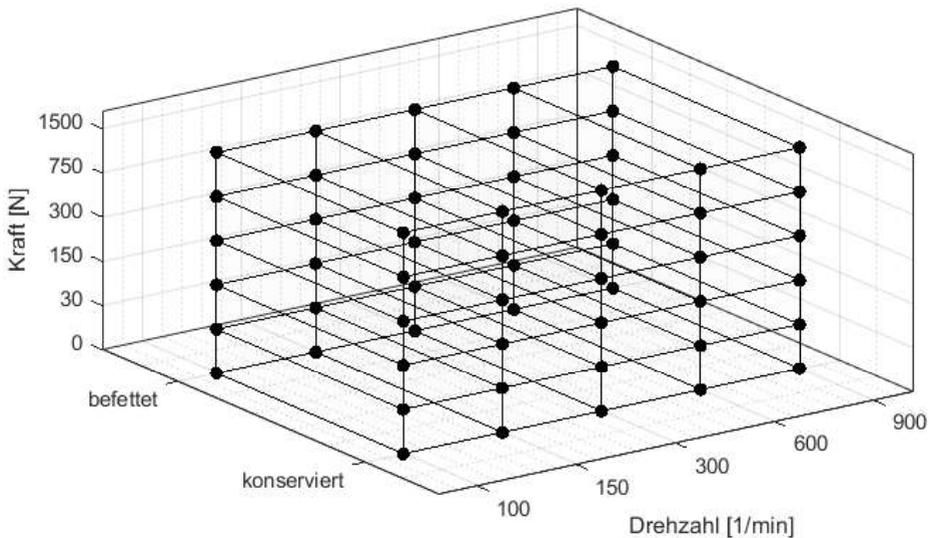


Abbildung 8-4: Versuchsplan für Mangelschmierung am 2-Achs-KGT-RZA

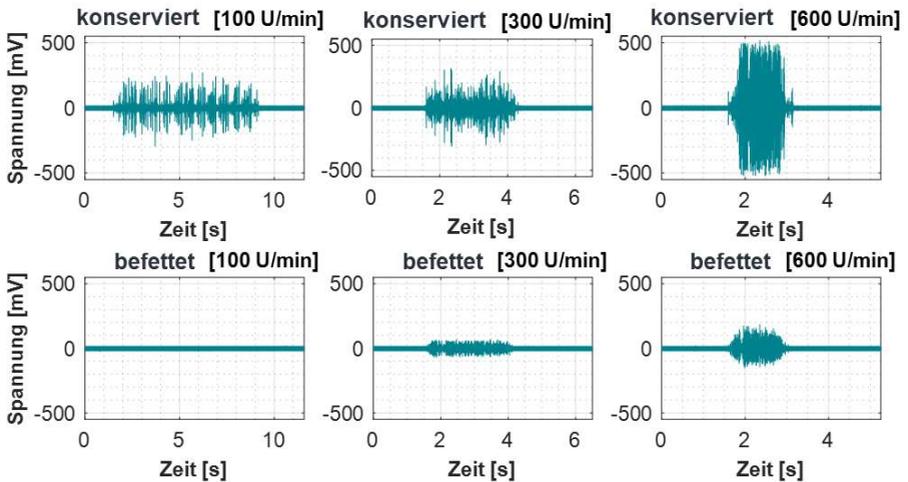


Abbildung 8-5: Vergleich von konserviertem und geschmiertem KGT

Am Beispiel von Abbildung 8-5 kann der Effekt der Mangelschmierung mittels AE-Signal deutlich aufgezeigt werden. Vergleicht man die AE-Amplituden für gleiche Geschwindigkeiten bei unterschiedlichen Schmierzuständen, kann der unerwünschte Zustand eindeutig der Signalausprägung zugeordnet werden. In der Arbeit von (Klein 2011, S. 44–45) wird als weitere Erklärung die Anregung der Komponenten durch Überrollen der Oberflächenrauigkeiten angeführt. Bei Abwesenheit eines trennenden Schmierfilms regen diese durch ihre statistische Verteilung ein breitbandiges AE-Signal an. AE bietet somit ein großes Potenzial für die Schadensfrüherkennung im Sinne der Prävention gegen Mangelschmierung und Adhäsivverschleiß. Ein automatisiertes Erkennen dieses Missstands liefert damit einen Beitrag zur präventiven Zustandsüberwachung von KGT, da ein Eingreifen, bevor irreversible Schäden entstehen können, ermöglicht wird.

Szenario 4 – Partikeleinbringung

Mit dieser Versuchsreihe werden zwei Fragestellungen untersucht. Zum einen wird festgestellt, welche Menge eines abrasiven Mediums ausreicht, um das AE-Signal signifikant zu verändern. Zweitens wird mit der Verunreinigung ein Abrasivverschleiß am KGT verursacht, der zum Vorspannungsverlust der Achse führt. Mit Hilfe der AE-Messung kann im Anschluss an die Schädigung eine Zuordnung von Schadenssignalen zum AE-Merkmal vorgenommen werden.

Tabelle 8-4: Versuchsplan für die Partikelmenge im Abrasiv-Verschleißversuch

		Anzahl an Versuchen					
Faktor Drehzahl [1/min]	100	3	3	3	3	3	3
		2	5	7	10	15	20
		Faktor Partikelmenge [mg]					

Der erste Teil der Untersuchung wird an beiden Versuchsträgern für KGT durchgeführt. Für die jeweilige Installation von Sensor und KGT wird die Änderung des AE-Signals bei Einbringung von Partikeln betrachtet. Bei den Partikeln handelt es sich um handelsübliche Schleifpaste, die Korngrößen zwischen 55 und 88 μm aufweist. Jeder KGT wird auf Position 0 mm des Prüfstands positioniert und dann zwischen dieser Position und einer Endposition mit definiertem Hub (in Abbildung 8-6 mit $x = 650 \text{ mm}$) traversiert. Es werden mehrere Fahrten zu Versuchsbeginn ohne Beeinträchtigung durchgeführt (siehe 1-3 in Abbildung 8-6). In der dritten Rückfahrt wird die Achse pausiert und die Partikel werden aufgebracht. Nach Einbringung des Mediums werden erneut Fahrten ohne weitere Beeinträchtigung durchgeführt. In diesen Fahrten können sich die Abrasivpartikel in der Mutter und auf der Spindel verteilen (Fahrt 4 und 5). Die Einbringung von Partikeln wird wiederholt (Fahrt 6) und das Verteilen der Partikel in der Achse wird erneut beobachtet. Nach Einbringung der Partikel weist die Achse irreversible Verschleißschäden auf.

Insgesamt werden die in Tabelle 8-4 aufgezeigten Partikelmengen wiederholt. Mit der Abstufung der eingebrachten Partikelmenge wird die Sensitivität des AE-Signals auf Fremdpartikel untersucht. Die geringste Menge an Partikeln (2 mg) ist experimentell im Versuch bestimmt worden als kleinste Menge, ab der keine sichtbare Änderung im AE-Signal mehr auftritt. Während der Versuche ist das Überfahren des Abrasivmediums deutlich am spontanen Ausschlag des AE-Signals (rote Farbe in Abbildung 8-6) zu erkennen. Der abrupte Signalanstieg kann auf die Überrollung der Partikel zurückgeführt werden, die zusätzliche Stöße während der Abrollbewegung der Kugel auslösen. Zudem bildet sich eine Mischung aus Partikeln und Schmiermedium im Wälzkontakt aus, deren Überrollung zusätzliches AE emittieren kann.

Im zweiten Teil des Experiments wird die Achse zyklisch weiterverfahren, bis die Auswirkungen des abrasiven Mediums im Signal nicht mehr auftreten. Es sind 500 Zyklen verfahren worden.

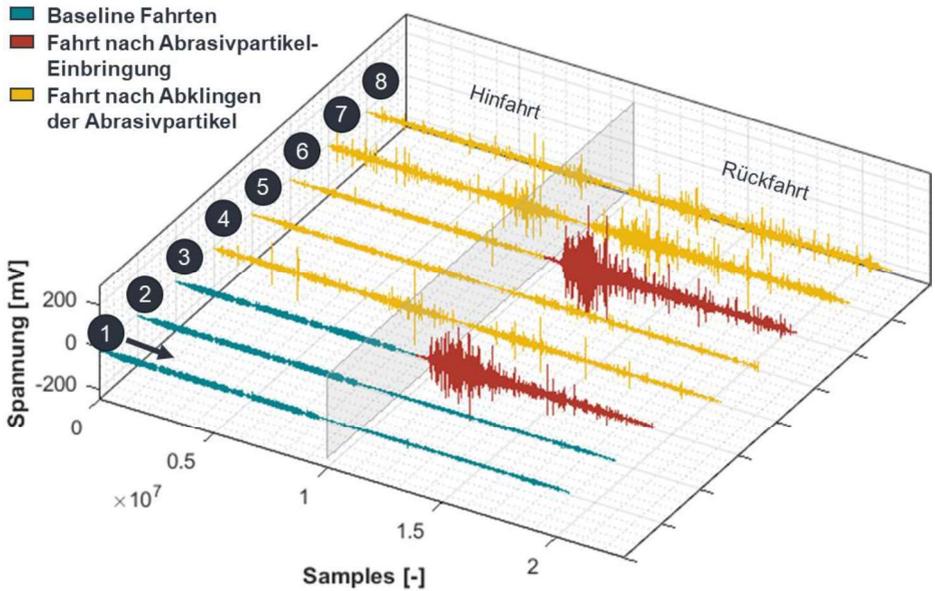


Abbildung 8-6: Versuchsreihe zur Einbringung von abrasiven Partikeln in KGT

Danach ist die gesamte Mutter und überrollte Spindellaufbahn mit dem Verschleißpartikel beeinträchtigt worden. AE-Signale dieser Achse können nun mit vorherigen Baseline-Messungen verglichen werden, um den Einfluss des Partikelverschleißes aufzuzeigen.

Dieser Vergleich und eine Gegenüberstellung der Reib- und Steifigkeitsverläufe im Vorher-Nachher-Zustand werden im nächsten Szenario vorgestellt.

Szenario 5 und 6 – Vorspannungsstufen

Im Rahmen des Projekts (DFG 2017) wurde neben dem Ermüdungverschleiß auch der Einfluss der mechanischen Kennwerte auf AE-Merkmale untersucht. Zu diesen Kennwerten zählen Leerlaufreibmomente bzw. -kräfte, die Steifigkeit des KGT und seine Vorspannungsklasse. Naheliegender Erkenntnis war die Zunahme der Reibkräfte mit zunehmender Vorspannung. Der Einfluss des Schmierzustands und Abrasivverschleißes ist in Abbildung 8-7 festgehalten. Die Messungen wurden mit dem Prüfstand 2-Achs-KGT-RZA aus Abschnitt 5.3 vorgenommen. Dabei liegt ein geringer

Unterschied zwischen dem be fetteten und dem konservierten (Mangelschmierungs-) Zustand vor. Im konservierten Zustand sinkt die Reibkraft geringfügig aufgrund der Abwesenheit von Fett (es liegt nur eine Ölkonservierung vor). Beim Vergleich mit dem Abrasivmedium vorher und nachher ergibt sich hingegen eine Senkung der Reibkraft zwischen 16,17 % und 34,7 % durch den Verschleiß mit Partikeln.

Erklärbar ist dieser Verlust mit der Abnahme der Steifigkeit, da durch das wiederholte Verfahren mit dem Abrasivmedium Material von den Laufbahnen und Wälzkörpern abgetragen wird. Alle drei untersuchten Vorspannungsstufen weisen dieses Verhalten auf. Exemplarisch wird dies im Steifigkeitsdiagramm in Abbildung 8-8 veranschaulicht. Es entsteht ein nachgiebigerer KGT (Markierung 1), da weniger Kraft für eine größere Streckung/Stauchung benötigt wird und ein Umkehrspiel (Markierung 2) entsteht.

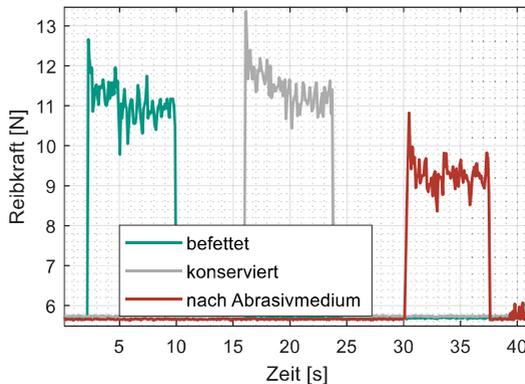


Abbildung 8-7: Gegenüberstellung von Leerlaufreibkräften für verschiedene KGT-Zustände

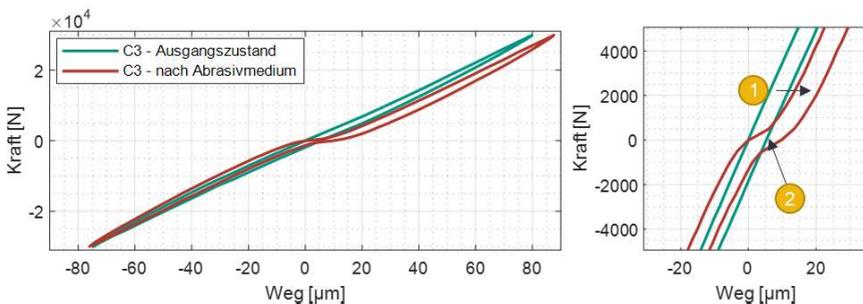


Abbildung 8-8: Steifigkeitsabnahme nach Abrasivverschleiß

Diese mechanischen Kennwerte des KGT wurden mit AE-Merkmalen verglichen. Im Rahmen des DFG-Arbeitsprogramms wurde eine Auswertemethodik entworfen, die automatisiert erfolgversprechende Merkmale ermittelt und diese dann einer nachgelagerten Korrelation und schließlich Klassifikation zuführt. Vorgehensweise und Ergebnisse werden in der Arbeit von (A_Schaible 2021) näher erläutert und diskutiert.

Die Versuchsreihen umfassen Messdaten, die zur Detektion von KGT-Zuständen bei unterschiedlichen Vorspannungsniveaus und Betriebszuständen (wie Schmierung und Drehzahl) herangezogen werden können.

Beispielhafte Ergebnisse für die Unterscheidung von Betriebszuständen sind in Abbildung 8-9 dargestellt. In der Abbildung rechts ist die Geschwindigkeits- und Schmierzustandsabhängigkeit der AE-basierten Auswertung ersichtlich. Es werden für eine Vorspannungsstufe mehrere Geschwindigkeiten und die Szenarien geschmiert (lub) und konserviert (no lub) dargestellt. In der Abbildung ist zu erkennen, dass bei zunehmender Geschwindigkeit die Intraclusterdistanz zwischen den Zuständen geschmiert und konserviert deutlich abnimmt. Damit wird eine eindeutige Separation der Zustände bei hohen Geschwindigkeiten erschwert. Diese Abhängigkeit kann allgemein für AE beobachtet werden (je größer die kinetische Energie im System, desto stärker die AE-Amplituden). Wenn bei hohen Geschwindigkeiten dann andere Defekte hinzukommen, sind diese schwieriger zu identifizieren als bei geringen Geschwindigkeiten. In der Abbildung links wird beispielhaft bei konstanter Drehzahl und im geschmierten Zustand der Merkmalsraum der betrachteten Merkmale für drei Vorspannungszustände abgebildet. Die beiden Zustände mit Vorspannung (C2, C3) treten hierbei eindeutig als separate Cluster auf. Nur der Zustand mit Spiel (C0) entsteht als verteiltes Cluster, aber mit deutlich anderen Merkmalswerten als die beiden anderen Zustände. Unter Einsatz von Referenzfahrten ließe sich damit im Betrieb die Überwachung der Vorspannung realisieren. Voraussetzung hierfür ist jedoch die a-priori-Messung des zu überwachten Betriebs an einem Prüfling und Implementierung einer entsprechenden Referenzfahrtlogik (in der Maschine).

Die nachträgliche Integration solcher Applikationen sind für Maschinenbetreiber und -programmierer meist mit erhöhtem Aufwand verbunden, da in das bereits vorhandene Maschinensystem und dessen Programmierung eingegriffen werden muss.

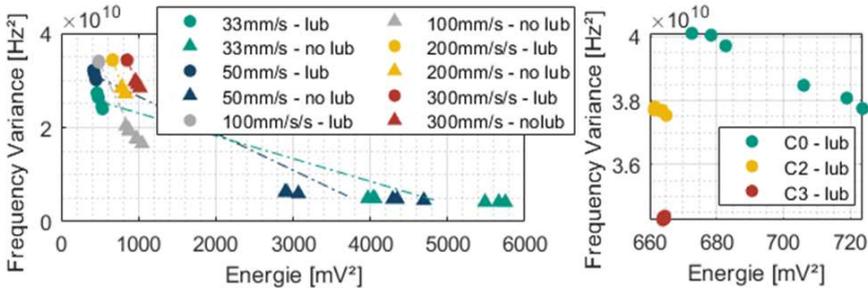


Abbildung 8-9: Unterscheidung in verschiedene Betriebszustände mit AE-Merkmalen (DFG 2017)

Eine Problematik, die bei den Untersuchungen von (A_Schaible 2021) und (Hillenbrand et al. 2021) offenbleibt und auch bereits in anderen Arbeiten thematisiert wird, ist der hohe Aufwand im Vorfeld zur Erzeugung einer Baseline bzw. von Referenzdaten. Sind Zustände oder Defekte im Vorfeld nicht bekannt und damit in Trainingsdaten nicht enthalten, können überwachte Modellansätze keine Aussage über diese bei späterem Auftreten treffen (Schlagenhauf & Scheurenbrand 2022; Netzer et al. 2022). Mit den unüberwachten CM-Architekturen, die im vorherigen Abschnitt vorgestellt wurden, sollen diese Problemstellungen gelöst werden.

Szenario 7 – Ermüdungsversuch mit erhöhter Last

Versuche zur Ermüdungslebensdauer wurden an acht KGT im Rahmen des Projekts (DFG 2017) durchgeführt. Hiervon wurden vier der KGT sensorisch mit AE überwacht. Über die gesamte Versuchsdauer wurden Temperatur, Motorstrom, Drehzahl und Axialkraft der KGT aufgezeichnet. Diese Datengrundlage ermöglicht die Gegenüberstellung von AE-Merkmalen mit dem Verlauf der theoretischen Lebensdauer nach DIN ISO 3408-5. Exemplarisch wird dies für einen KGT in Abbildung 8-10 dargestellt. Die Unterbrechungen im Drehzahl-Axialkraft-Verlauf entsprechen Versuchspausen aufgrund der Inspektion der Muttern und der Wartung des Prüfstands. Als Versuchsobjekte wurden KGT von Bosch Rexroth mit Nenndurchmesser 32 mm und Steigung 20 mm (siehe Anhang A 1) verwendet. Aufgrund der Menge an Daten, die im Zeitraum von 80 Tagen anfallen würden, wird bei diesen Experimenten auf die kontinuierliche Aufzeichnung von AE-Signalen verzichtet.

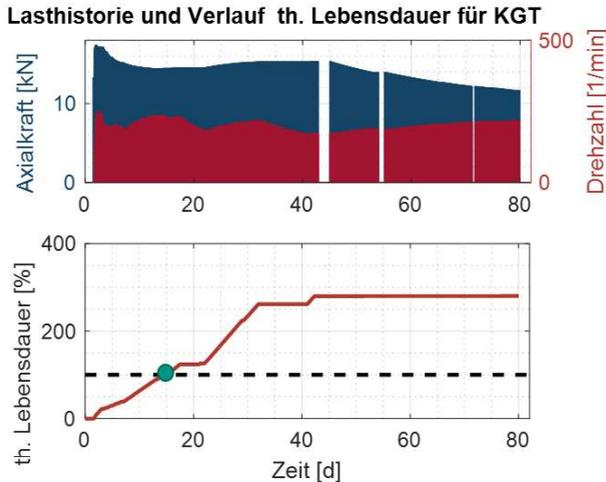


Abbildung 8-10: Durchschnittliches Last- und Drehzahlprofil (oben) und zugehörige erreichte theoretische Lebensdauer (unten)

Stattdessen werden Messungen nur alle 50 Zyklen (d. h. nach 50 Hin- und Herfahrten) aufgezeichnet. Diese Einschränkung ist vorgenommen worden, da die kontinuierliche Überwachung durch ein unüberwachtes Modell zu diesem Zeitpunkt noch nicht abgeschlossen und die dauerhafte Speicherung der AE-Daten für jeden Zyklus nicht abbildbar war (im Laufe der 80 Versuchstage wären bei kontinuierlicher Messung pro Sensor 27,6 TByte entstanden).

Zur Untersuchung der Eignung von AE bei Ermüdung können die extrahierten AE-Merkmale auf Anomalien bzw. Trends in den Daten über die Versuchsdauer untersucht werden. Da bereits nach ca. 20 Tagen bei eingestellter Last und Drehzahl die theoretische Lebensdauer überschritten wird, dient dieser Punkt als Referenzpunkt bei der Auswertung, ab dem Defekte erwartet werden. Im unteren Teil des Diagramms in Abbildung 8-10 ist der Punkt grün markiert. Die prozentuelle theoretische Lebensdauer ist auf Basis der bereits ertragenen Last- und Drehzahlkollektive ermittelt worden. 100 Prozent theoretische Lebensdauer entspricht exakt dem Zeitpunkt (in Versuchstagen), an dem bereits so viele Überrollungen ertragen wurden, dass laut der Norm Ermüdung eintreten kann.

Im folgenden Abschnitt werden die vorgestellten CM-Architekturvarianten anhand der Rohdaten aus den beschriebenen Szenarien validiert.

8.3 Unsupervised Condition-Monitoring in den Validierungsexperimenten

Im Folgenden werden Ergebnisse für ausgewählte Architektur-Szenario-Kombinationen vorgestellt und hinsichtlich ihrer Detektionsgüte und Aussagekraft untersucht.

Die Visualisierung der CM-Systeme ist stets vergleichbar aufgebaut und besteht aus vier Grundelementen: der Rohdatenansicht (und eventueller Vorverarbeitung), dem Clustering-Ergebnis, dem Cluster-Tracking-Ergebnis und dem Zustandsdiagramm. Diese vier Elemente (a-d) werden in Abbildung 8-11 schematisch dargestellt. Dieser Aufbau liegt allen Architekturen zugrunde und unterscheidet sich meist nur in den verarbeiteten Rohdaten und/oder Vorverarbeitungsschritten.

Im Bereich a werden die aktuell zu verarbeitenden Rohdaten dargestellt und es erfolgt, falls definiert, deren Darstellung nach einer Vorverarbeitung. Die Rohdaten werden in den Anwendungen dieser Arbeit gefenstert eingelesen, d. h., es werden immer mehrere Datenpunkte auf einmal verarbeitet. Die Größe dieser Rohdatenfenster definiert das CM-System selbstständig bei Initialisierung (siehe 7.4.2).

Der Bereich b der Visualisierung stellt das aktuelle Clustereergebnis vor. Er teilt sich auf in eine Teilgrafik für die Clusteregebnisse des verwendeten Clusteralgorithmus und eine für die tatsächliche Clusterzuordnung (en. *Ground Truth*).

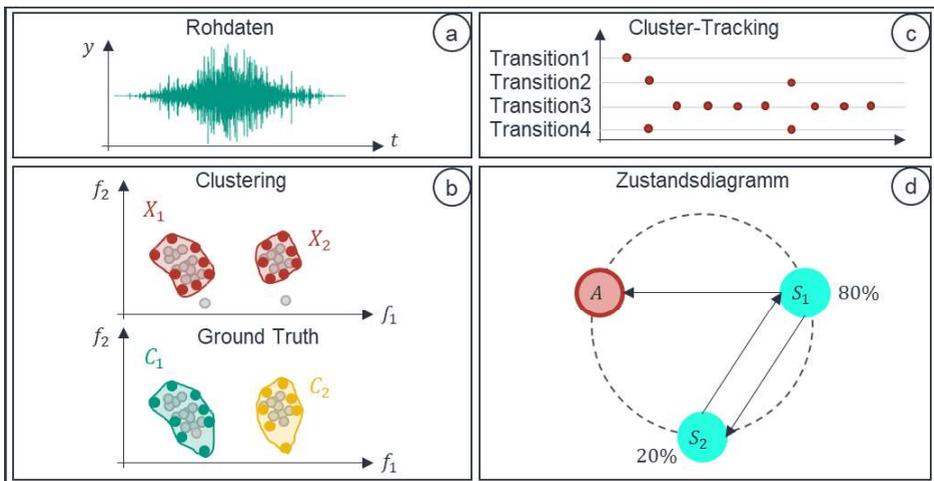


Abbildung 8-11: Schematische Darstellung der CM-System-Visualisierung

In der späteren Anwendung für ein neues, unbekanntes System würde der *Ground Truth* nicht zur Verfügung stehen, er wird hier jedoch zur besseren Ergebnisinterpretation abgebildet. Der Abgleich zwischen dem ermittelten Clusterergebnis und *Ground Truth* wird später zur Bewertung anhand von Metriken genutzt. In Anhang A 20 wird der Diagrammtyp für verschiedene Merkmalsdimensionen näher erläutert.

Um zeitliche Ereignisse während der Clusterbildung festzuhalten, wird Bereich c genutzt. Er hält die auftretenden Clustertransitionen, die in Abschnitt 7.6 eingeführt wurden, fest. Das zugehörige Schaubild (siehe auch Anhang A 21) führt auf der Abszisse die einzelnen Transitionereignisse und auf der Ordinate die Ausprägung der jeweiligen Transition (siehe Kategorien in Tabelle 7-2). Jeder Punkt im Cluster-Tracking-Schaubild entspricht einer Transition, die beim Clustern des zugehörigen Datenfensters auftritt. Das Schaubild gibt damit die Historie der Clusterereignisse wieder und kann zur Interpretation des Systemzustands herangezogen werden.

Der letzte Teil (Bereich d) ist das Zustandsdiagramm. Dieses Schaubild gibt den auf Basis der Cluster- und Trackingergebnisse abgeleiteten Systemzustand wieder. Es werden folgende Informationen in Form von kreisförmigen Zustandsknoten in der Grafik dargestellt (siehe auch Anhang A 22): aktueller Zustand, Anzahl der detektierten Zustände (Anzahl der Cluster), Häufigkeit der Zustände und Übergänge bzw. Wechsel zwischen Zuständen.

Zusammen ermöglichen die vier Bereiche die Interpretation des überwachten Systems hinsichtlich seiner Zustände, Anomalien und zeitlichen Entwicklung. Da es sich bei den überwachten Szenarien allerdings nicht um statische Vorgänge handelt, ist innerhalb eines Ergebnisschaubilds nur der Endzustand der Überwachung darstellbar. Um trotzdem einen Eindruck vom zeitlichen Ablauf während der Überwachung zu bekommen, stehen am Ende jedes Abschnitts Videos für die jeweiligen Szenarien und Architekturvarianten zur Verfügung.

Der nächste Unterabschnitt zeigt zunächst am Beispiel des Szenarios Amplitudendrift aus Abschnitt 7.4.1 schematisch den Ablauf des Cluster-Trackings in Form von mehreren Bildfolgen. In den weiteren Unterabschnitten wird für ausgewählte Szenarien aus Tabelle 8-1 der Ablauf der Überwachung mit CM-System beschrieben. Außerdem werden die Ergebnisse für die beiden Architekturvarianten aus Abschnitt 8.1 dargestellt.

8.3.1 Visualisierung des Cluster-Tracking-Prozesses im CM-System

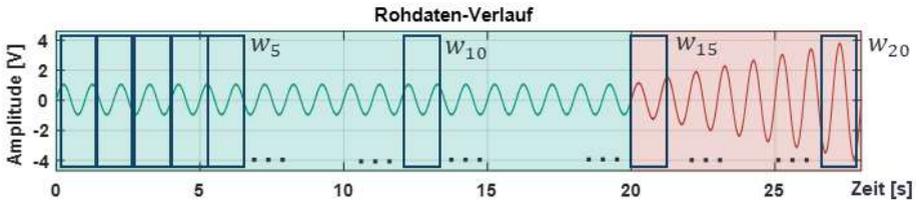


Abbildung 8-12: Visualisierung Cluster-Tracking – Rohdaten Amplitudendrift

Am Beispiel des Szenarios Amplitudendrift in Abbildung 8-12 kann der sequenzielle Aufbau der Visualisierung für die CM-System-Ergebnisse erklärt werden. In der Abbildung ist ein Rohdatenabschnitt dargestellt, wie er bereits in Abschnitt 7.4.1 zur Erklärung der MSE-Merkmalsextraktion genutzt wurde. Grün hinterlegt sind Rohdatenabschnitte des Gutzustands in Form einer Sinusschwingung und der rot hinterlegte Bereich repräsentiert eine Anomalie in Form einer langsamen Amplitudendrift dieser Schwingung. An das CM-System werden diese Rohdaten in Form der Fenster w_i nacheinander übergeben. Für jedes Fenster durchläuft das CM-System eine neue Iteration. Die verwendete Architektur ist die MSE-Merkmalsextraktion, d. h., aus jedem Rohdatenfenster wird nach entsprechender Verarbeitung der Architektur ein MSE-Fehler (Rekonstruktionsfehler) berechnet und für das Cluster-Tracking verwendet.

In Abbildung 8-13 ist die Visualisierung der ersten fünf Iterationen abgebildet. Die Grafik teilt sich auf in vier Teildiagramme gemäß Abbildung 8-11. Die ersten Iterationen werden hier in einem Bild zusammengefasst, da der Clusteralgorithmus erst eine definierte Anzahl an Datenpunkten aus den Rohdatenfenstern erstellen muss, um mit der Clusterbildung beginnen zu können. Cluster aus nur einem oder zwei Datenpunkten sind kaum aussagefähig. Daher wird eine Mindestanzahl von fünf Datenpunkten für das Beispiel verwendet. Diese fünf Rohdatenabschnitte sind in Abbildung 8-13a dargestellt. Erst wenn diese ersten Datenpunkte erfasst sind, beginnt auch die Clusterbildung in Abbildung 8-13b. Mit Hilfe des Clusteralgorithmus werden die MSE-Fehler-Datenpunkte zum ersten Cluster c_1 zusammengefasst. Der letzte hinzugefügte Datenpunkt wird entsprechend der Legende ebenfalls markiert. In der unteren Teilgrafik in b wird der *Ground Truth* abgebildet, der wie oben beschrieben für den grün hinterlegten Bereich dem Gutzustand entspricht. Aus dem Clusterergebnis können dann die Teilgrafiken c und d abgeleitet werden.

Iteration 1-5:

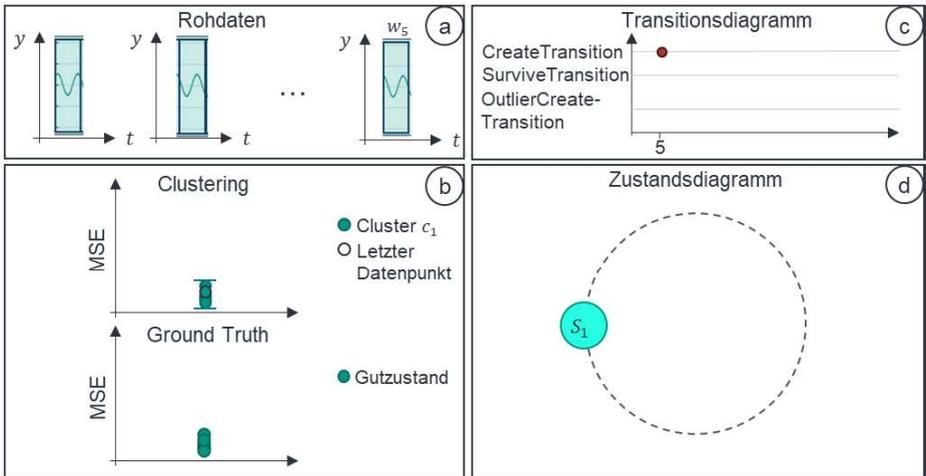


Abbildung 8-13: Visualisierung Cluster-Tracking – Iteration 1 bis 5

Das Transitionsdiagramm (Abbildung 8-13c) beschränkt sich auf die Anzeige der für dieses Beispiel relevanten Transitions (hier: *Create*, *Survive* und *OutlierCreate* Transitions). Nach der fünften Iteration liegt lediglich eine *Create* Transition vor. Diese entspricht der Entstehung des ersten Clusters. Für die früheren Datenpunkte entsteht noch keine Transition, da sie noch keine Cluster hervorrufen bzw. noch nicht geclustert wurden. Im zugehörigen Zustandsdiagramm ist deshalb auch nur ein Zustandsknoten S_1 vorhanden.

Mit Iteration 10 in Abbildung 8-14 wird der nächste Zustand der Beispielsequenz festgehalten. Es wurde das zehnte Rohdatenfenster w_{10} verarbeitet. Zwischen Iteration fünf und zehn sind weitere Rohdatenfenster zu MSE-Fehlern für das Clusterdiagramm verarbeitet worden. In Abbildung 8-14b sind hierbei neue Datenpunkte im Cluster c_1 hinzugekommen und der Grundzustand wird um neue Datenpunkte erweitert. Dieses Größenwachstum bzw. die anhaltende Dauer von Cluster c_1 wird auch mit dem Wachstum des Zustandsknotens S_1 repräsentiert (siehe Abbildung 8-14d). Im Transitionsdiagramm Abbildung 8-14c wird das Vergrößern des Clusters bzw. das Verbleiben des Systems in diesem Zustand anhand der *Survive* Transitions detektiert. Zwischen Iteration fünf und zehn sind hier für jede Iteration, in der das Cluster c_1 besteht, *Survive* Transitions entstanden. Bis auf die Größenänderung des Zustandsknotens verbleibt das Zustandsdiagramm ohne Änderung.

Iteration 10:

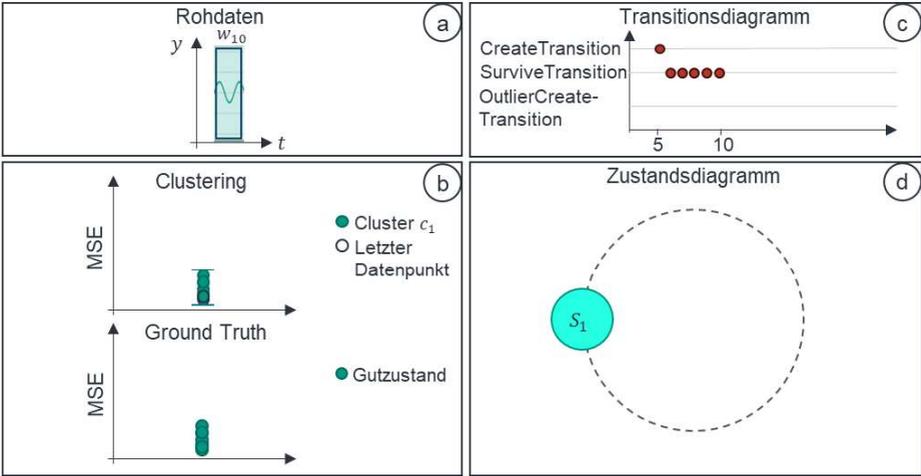


Abbildung 8-14: Visualisierung Cluster-Tracking – Iteration 10

Für Iteration 15 wird das erste Datenfenster mit abnormalen Daten verarbeitet. In Abbildung 8-15a ist das Rohdatenfenster entsprechend mit w_{15} gekennzeichnet. Dieses neue Datenfenster erzeugt einen MSE-Fehler, der einen deutlichen Abstand von den bisherigen Rekonstruktionsfehlern hat. Da ein neues Muster in den Rohdaten vorliegt, ergibt sich hier eine schlechtere Rekonstruktion durch den eingesetzten Autoencoder. In Abbildung 8-15b taucht deshalb ein Ausreißer als letzter Datenpunkt oberhalb des Clusters c_1 auf. Gemäß der Zuordnung der Originaldaten wird diesem Punkt auch in der unteren Grafik für den *Ground Truth* eine Anomalie zugewiesen. Entsprechend sind auch neue Transitionen im Transitionsdiagramm (siehe Abbildung 8-15c) detektiert worden. Zunächst sind weitere *Survive* Transitionen zwischen Iteration 10 und 15 hinzugekommen, da weitere Datenpunkte mit Gutzustand detektiert werden. Allerdings kommt nun eine *OutlierCreate* Transition hinzu, die die Detektion eines Ausreißers festhält. Diese Änderung wird auch im Transitionsdiagramm (siehe Abbildung 8-15d) dargestellt. Es kommt ein roter Zustandsknoten A für den Ausreißer hinzu. Außerdem ist der Zustandsknoten S_1 erneut angewachsen, da zwischen Iteration 10 und 15 weitere Datenpunkte für Cluster c_1 hinzukamen.

Iteration 15:

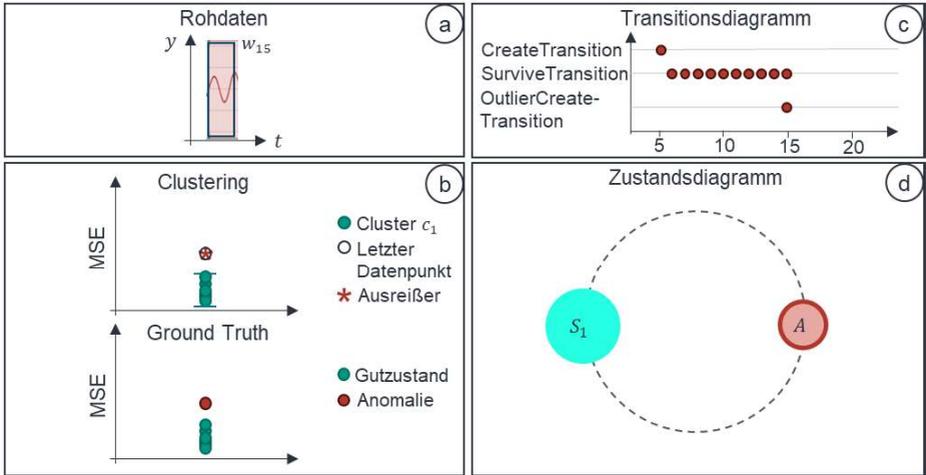


Abbildung 8-15: Visualisierung Cluster-Tracking – Iteration 15

Die finale Iteration 20 erweitert das Clusterergebnis um weitere detektierte Ausreißer. Das Fenster w_{20} in der Teilgrafik Abbildung 8-16a hat offensichtlich die größte Abweichung vom Muster der Rohdatenabschnitte im Gutzustand. Entsprechend ergibt sich auch im Clusterdiagramm in Abbildung 8-16b der letzte Datenpunkt mit dem größten MSE-Fehler. Im Clusterergebnis ist außerdem erkennbar, dass alle Fenster zwischen Iteration 15 und 20 ebenfalls als Ausreißer detektiert werden. Das Cluster c_1 ist nicht größer geworden, sondern verbleibt bei der zuvor erreichten Größe. Im vorliegenden Beispiel entstehen die Ausreißer im Merkmalsraum mit einem so großen Abstand untereinander, dass sich kein neues Cluster für die Anomalie-Datenpunkte ergibt, sondern diese vom Algorithmus als Ausreißer deklariert werden. Vollständigkeitshalber sei hier erwähnt, dass dieses Verhalten dem Anschauungsbeispiel einfach zugrunde gelegt wird. In einem realen Anwendungsfall könnte aufgrund der Datenverteilung die Anomalie auch als zweites Cluster entstehen. Im unteren Teilschaubild in Abbildung 8-16b für den *Ground Truth* teilen sich nun alle Datenpunkte in Gutzustand und Anomalie gemäß dem dargestellten Rohdatenabschnitt in Abbildung 8-12 auf. Im Transitionsdiagramm sind für die finale Iteration weitere *Survive* und *OutlierCreate* Transitionen hinzugekommen. Für jeden Ausreißer zwischen Iteration 15 und 20 ist eine entsprechende *OutlierCreate* Transition in Abbildung 8-16c markiert. Gleiches gilt für weitere *Survive* Transition, da das Cluster c_1 bis zum Ende der Rohdaten bestehen bleibt.

Iteration 20:

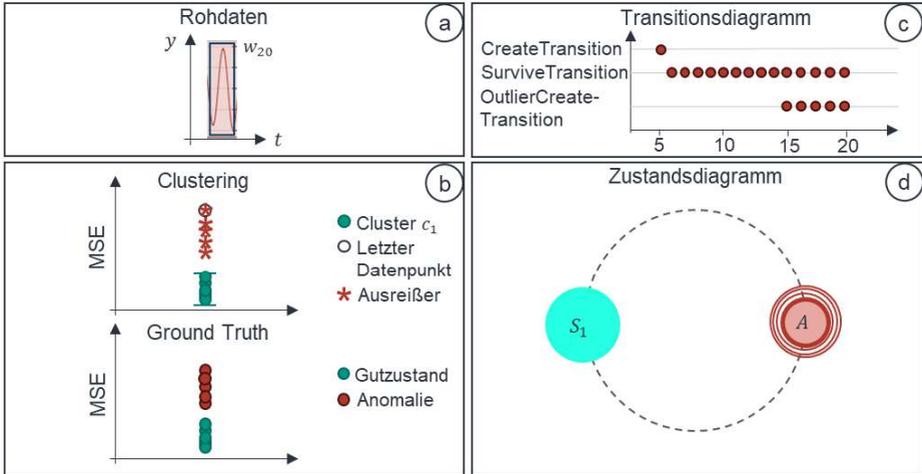


Abbildung 8-16: Visualisierung Cluster-Tracking – Iteration 20

Die Visualisierung des CM-Systems endet mit der Darstellung des Zustandsdiagramms in Abbildung 8-16d. Hier werden weitere Ringe um den roten Anomalieknoten A abgebildet, da es zur Detektion weiterer Ausreißer gekommen ist. Mit jedem weiteren Ausreißer ab Iteration 15 wird ein neuer Ring hinzugefügt. Der Zustandsknoten S_1 bleibt bis zum Ende erhalten, da es weiterhin nur ein bestehendes Cluster c_1 gibt.

Damit ist mit dieser Bildfolge einmal die Entstehung der Visualisierung des CM-Systems mit Cluster-Tracking erläutert worden. In den nachfolgenden Szenarios mit realen AE-Daten des KGT wird auf die ausführliche schrittweise Darstellung aus Platzgründen verzichtet und das Ergebnis anhand der (in zeitlicher Hinsicht) jeweils letzten Cluster-, Transitions- und Zustandsdiagramme vorgestellt und erläutert.

8.3.2 Szenario 1 – Geschwindigkeitsstufen

In diesem Szenario werden die Architekturen mit folgender Aufgabe konfrontiert:

- Die Messdaten bestehen aus Fahrten mit unterschiedlichen, konstanten Geschwindigkeiten (siehe Abbildung 8-3). Insgesamt wird mit den Geschwindigkeiten 33 mm/s, 50 mm/s, 100 mm/s, 200 mm/s und 300 mm/s verfahren.

- Jede Fahrt wird dreimal wiederholt. Damit stehen 15 Fahrten für die Auswertung zur Verfügung.
- Das CM-System soll automatisch erkennen, dass fünf verschiedene Drehzahlstufen vorliegen. Dabei wird dem System zu Beginn nur die Vorschubgeschwindigkeit 33 mm/s zur Lernphase übergeben. Danach nimmt das System den Betrieb auf und arbeitet unüberwacht.

Architekturvariante – vordefinierte Merkmale

Für die Architektur mit vordefinierten Merkmalen ergibt sich das Clusterergebnis in Abbildung 8-17. Von den fünf Zuständen mit unterschiedlicher Vorschubgeschwindigkeit wird vom Clusterverfahren nur ein Cluster richtig (100 mm/s) erkannt. Die zwei Zustände mit den geringsten Geschwindigkeiten (33 und 50 mm/s) sind im Merkmalsraum so ähnlich, dass sie einem gemeinsamen Cluster zugeordnet werden. Die zwei Geschwindigkeiten werden als ein Zustand geclustert. Die beiden anderen Cluster mit hohen Vorschüben werden nicht als Cluster identifiziert, sondern lediglich als Ausreißer deklariert. Die Änderung der Geschwindigkeit wirkt sich markant auf die Ausprägung der Merkmale auf Basis der AE-Rohdaten aus (vgl. Abschnitt 6.2). Allerdings tritt mit zunehmender Geschwindigkeit ein größerer Abstand zwischen den Clusterdatenpunkten auf. Der Clusteralgorithmus (hier: DBSCAN) hat ein Defizit für Cluster mit veränderlicher Dichte. Deshalb ist keine korrekte Zuordnung aller Geschwindigkeitsstufen zu einem Cluster möglich. Dem Anwender des CM-Systems würde in diesem Fall eine Anomalie berichtet werden, obwohl tatsächlich nur eine weitere Geschwindigkeit gefahren wird. Prinzipiell operiert das unüberwachte System jedoch richtig, da es sich definitiv um eine Neuheit handelt. Lediglich die Deklaration als Anomalie anstatt als Zustand ist defizitär.

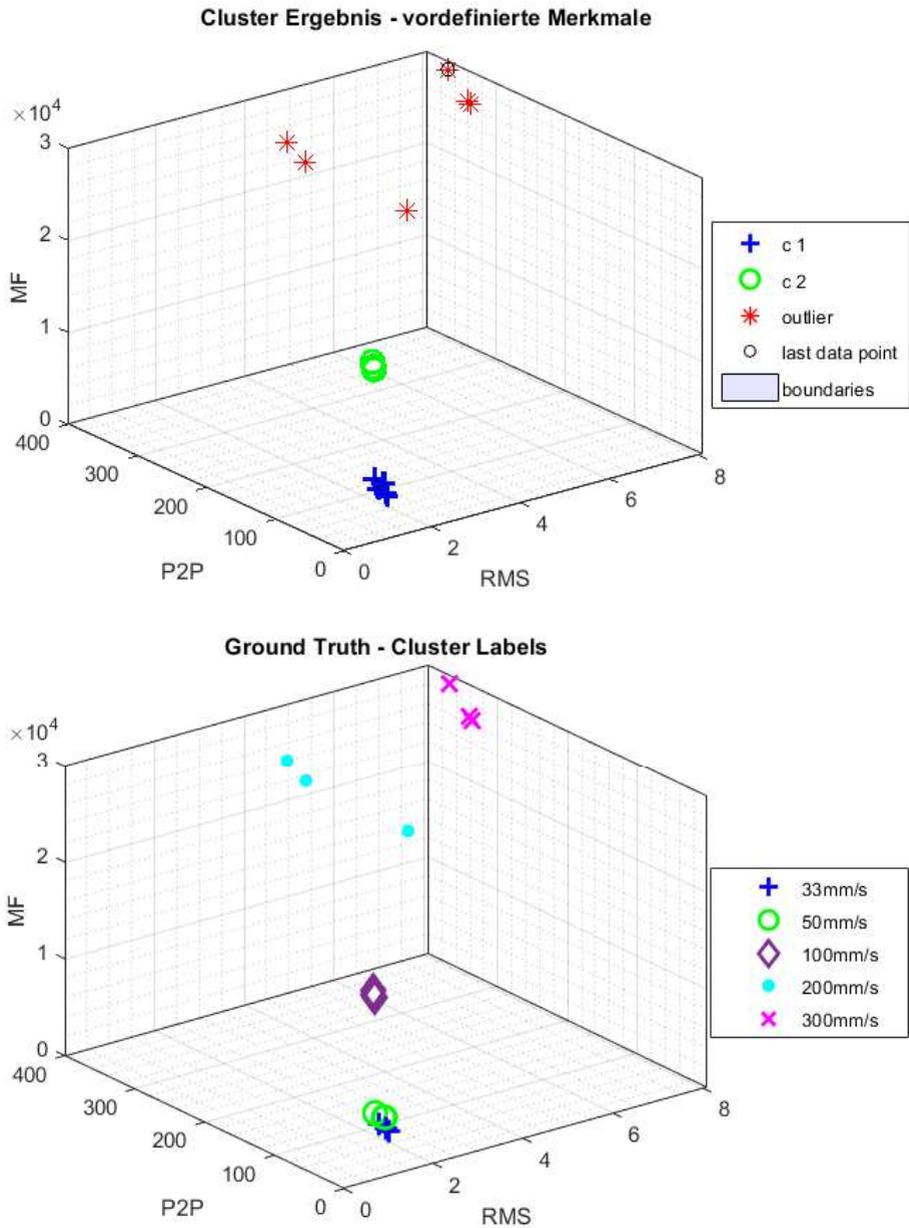


Abbildung 8-17: Clusterergebnis für Szenario 1 mit vordefinierten Merkmalen

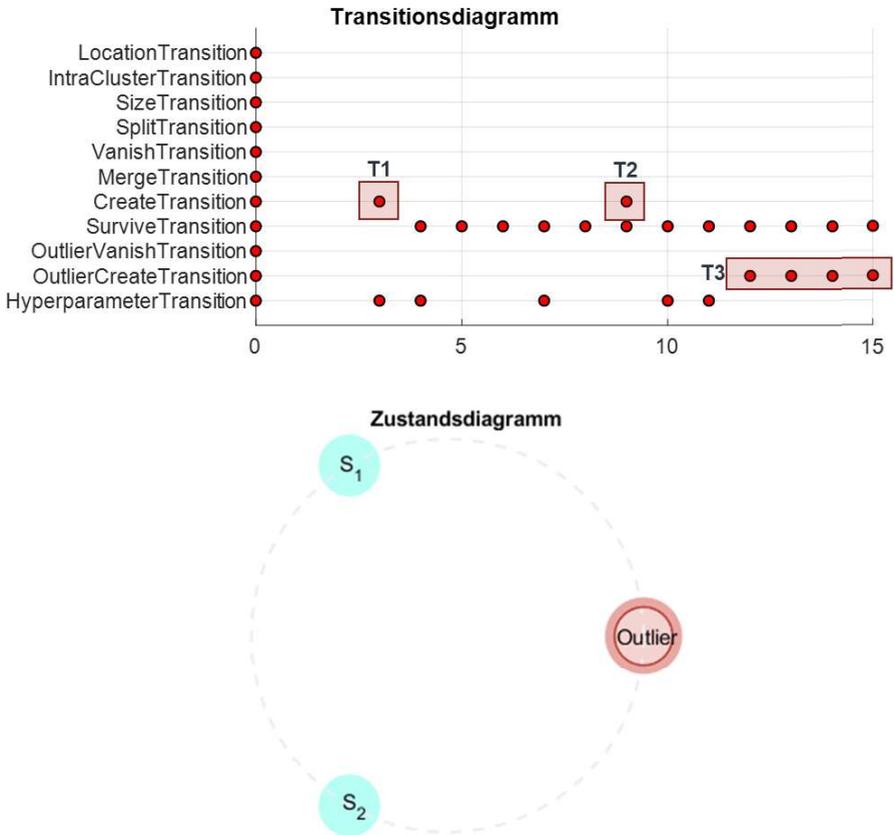


Abbildung 8-18: Cluster-Tracking-Ergebnis für Szenario 1 mit vordefinierten Merkmalen

Im Transitionsdiagramm (Abbildung 8-18) der Architekturvariante mit vordefinierten Merkmalen treten drei signifikante Transitionen auf. Transition T1 entspricht der Detektion des ersten Clusters. Erst mit dem Auftauchen der dritten Geschwindigkeit entsteht ein neues Cluster (Markierung T2). Weitere Datenfenster mit höheren Geschwindigkeiten werden, wie oben bereits erwähnt, als Ausreißer erkannt. Diese Datenpunkte erzeugen daher *OutlierCreate* Transitionen (Markierung T3). Im Zustandsdiagramm werden nur zwei der fünf Zustände (Geschwindigkeiten) vermerkt. Die restlichen Datenpunkte sind Ausreißern zugeordnet und mit dem roten Anomalieknoten im Diagramm vermerkt.

Der zeitliche Verlauf des Cluster-Trackings ist unter nachstehendem Link als Video zugänglich: https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#FEATURE_2Achser_Speeds.

Architekturvariante – MSE-Merkmalsextraktion

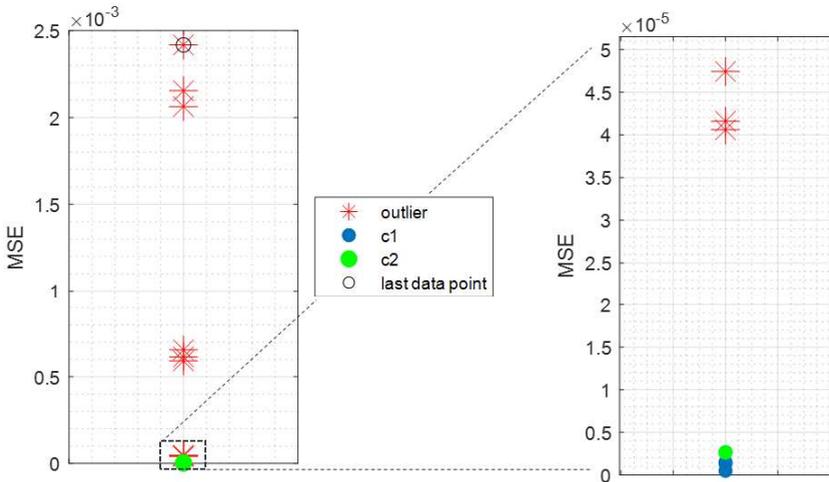
Mit der MSE-Merkmalsextraktion wird das Clusterergebnis in Abbildung 8-19 erzielt. Auch hier werden nur zwei Cluster erkannt. Aufgrund des sich ergebenden Wertebereichs des MSE-Merkmals werden die Clusterergebnisse und der *Ground Truth* mit einer zusätzlichen Detailansicht (rechts in Abbildung 8-19) dargestellt.

Im Unterschied zu der Architektur mit vordefinierten Merkmalen ermöglicht das Training des Autoencoders die Trennung der beiden Zustände mit den geringsten Geschwindigkeiten (33 mm/s und 50 mm/s) in zwei verschiedene Cluster. Der vergrößerte Ausschnitt in Abbildung 8-19 rechts oben zeigt die beiden Cluster auf der MSE-Achse. Alle weiteren Geschwindigkeitsstufen unterscheiden sich von den erlernten Merkmalen so stark, dass MSE-Fehler entstehen, die vom Clusteralgorithmus aufgrund zu unterschiedlicher Abstände keine neuen Cluster ergeben. Daher werden die anderen Datenpunkte im Merkmalsraum als Ausreißer deklariert. Dieser Umstand kann auf ein Overfitting des Autoencoders zurückgeführt werden. Wenn der Autoencoder die Merkmale des Ausgangszustandes (33 mm/s) so detailliert erlernt, dass alle weiteren Zustände kaum Ähnlichkeit haben, so entstehen sehr große MSE-Fehler, die wiederum vom Clusteralgorithmus als alleinstehende Ausreißer identifiziert werden. Damit ergeben sich keine neuen Cluster.

Im Transitionsdiagramm (Abbildung 8-20) ist der Unterschied der beiden Architekturvarianten ebenfalls erkennbar: Zwischen Markierung T1 und T2 liegen mit der MSE-Merkmalsextraktion deutlich weniger Datenpunkte, da das zweite Cluster bereits mit Datenpunkten der Geschwindigkeit 50 mm/s entsteht. Alle folgenden Datenpunkte der anderen Geschwindigkeitsstufen werden, wie bereits erwähnt, als Ausreißer deklariert (Markierung T3).

Das Zustandsdiagramm in Abbildung 8-20 enthält ebenfalls nur zwei detektierte Zustände, wobei der rote Zustandsknoten für die Markierung der Ausreißer größer ausfällt als bei der vorigen Architekturvariante, da insgesamt mehr Datenpunkte den Ausreißern anstatt einem Cluster zugewiesen worden sind.

Clusterergebnis - MSE Merkmalsextraktion



Ground Truth - Cluster Labels

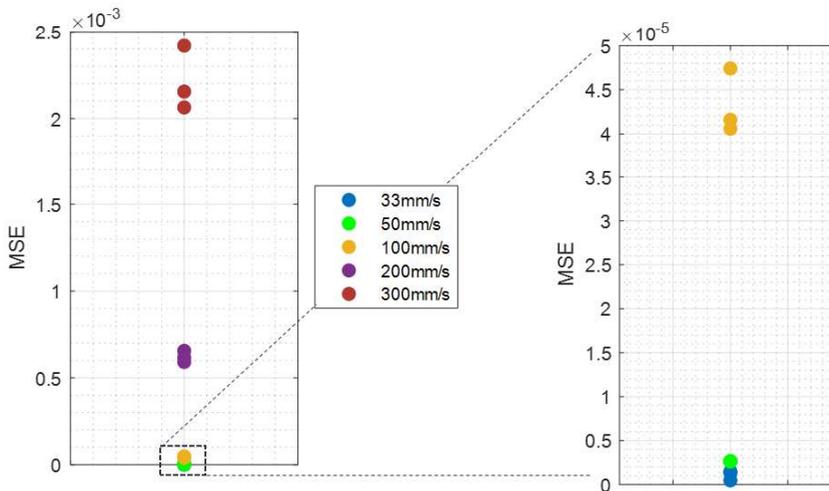


Abbildung 8-19: Clusterergebnis für Szenario 1 mit MSE-Merkmalsextraktion

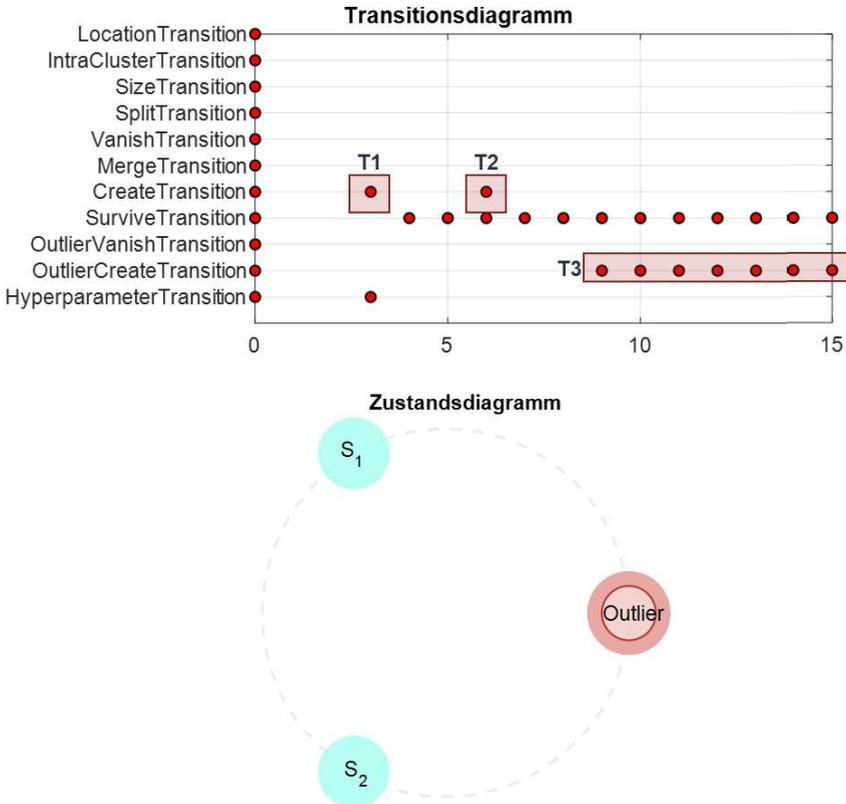


Abbildung 8-20: Cluster-Tracking-Ergebnis für Szenario 1 mit MSE-Merkmalsextraktion

Der zeitliche Verlauf des Cluster-Trackings ist unter nachstehendem Link als Video zugänglich: https://jhillenbrand.github.io/CMSsystem/videos/other_scenarios.html#MSE_2Achser_Speeds.

8.3.3 Szenario 3 – Mangelschmierung

Die Architekturen sollen den Eintritt von Mangelschmierung detektieren:

- Die AE-Rohdaten, die verarbeitet werden, repräsentieren Fahrten mit ausreichender Schmierung und Fahrten, bei denen die Achse zuvor von der Fettschmierung befreit wurde. Die Achse ist dann nur noch mit einem leichten Ölfilm benetzt (konserviert). Beide Zustände werden mit gleicher Geschwindigkeit durchfahren ($v_f = 100$ mm/s).
- Das CM-System kann die ersten drei Fahrten zur Autokonfiguration nutzen (Ausgangszustand) und arbeitet dann unüberwacht.
- Das System soll weitere Fahrten mit ausreichender Schmierung als gleichen Zustand erkennen. Sobald Fahrten mit Mangelschmierung verarbeitet werden, sollen diese als Anomalie oder neuer Zustand erkannt werden.

Architekturvariante – vordefinierte Merkmale

In diesem Szenario ergibt sich für die vordefinierte Merkmalsextraktion das Clusterergebnis in Abbildung 8-21. Es zeigt, dass nur einer der beiden Schmierzustände durch den Clusteralgorithmus als Cluster erkannt wird. Der zweite Zustand (konserviert) wird als Ansammlung von Ausreißern deklariert. Die geringe Dichte bzw. der große Abstand der Datenpunkte des zweiten Zustands (konserviert bzw. Mangelschmierung) sorgen dafür, dass dieser nicht als Cluster durch DBSCAN erkannt wird. Die Detektion der Mangelschmierungsanomalie ist jedoch gegeben und die Systemfunktion somit erfüllt.

Zu diesem Clusterergebnis gehören zwei Transitionen im Transitionsdiagramm in Abbildung 8-22: Markierung T1 entspricht der Detektion des Clusters. Mit Markierung T2 wird die Anhäufung von Ausreißern festgehalten.

Entsprechend folgt auch die Darstellung im Zustandsdiagramm mit einem Kreis für Zustand S_1 und einem Knoten für die Ausreißer.

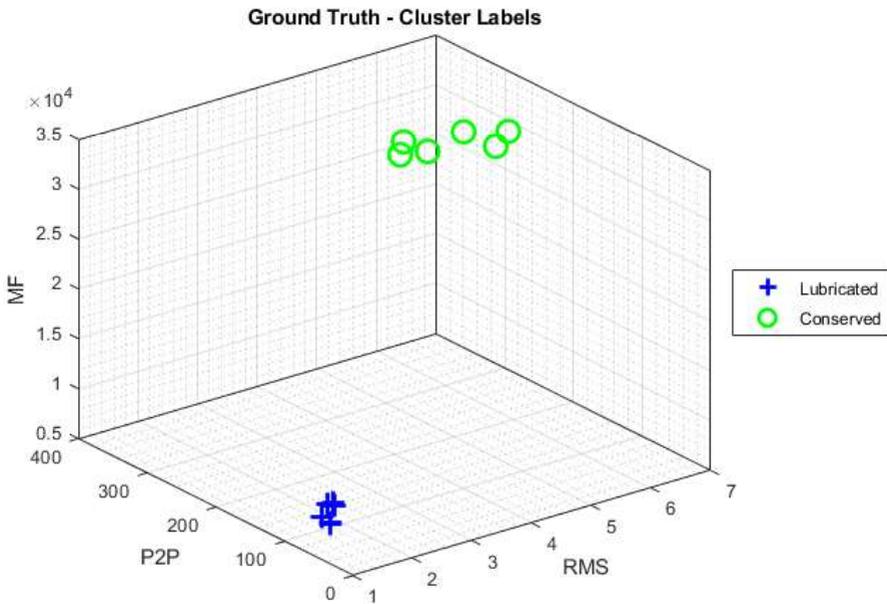
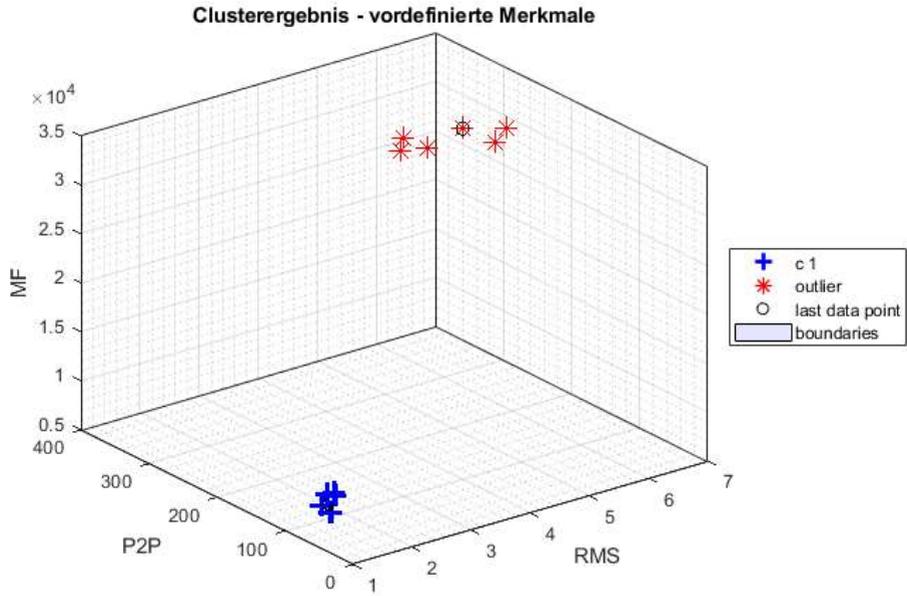


Abbildung 8-21: Clusteregebnis für Szenario 3 mit vordefinierter Merkmalsextraktion

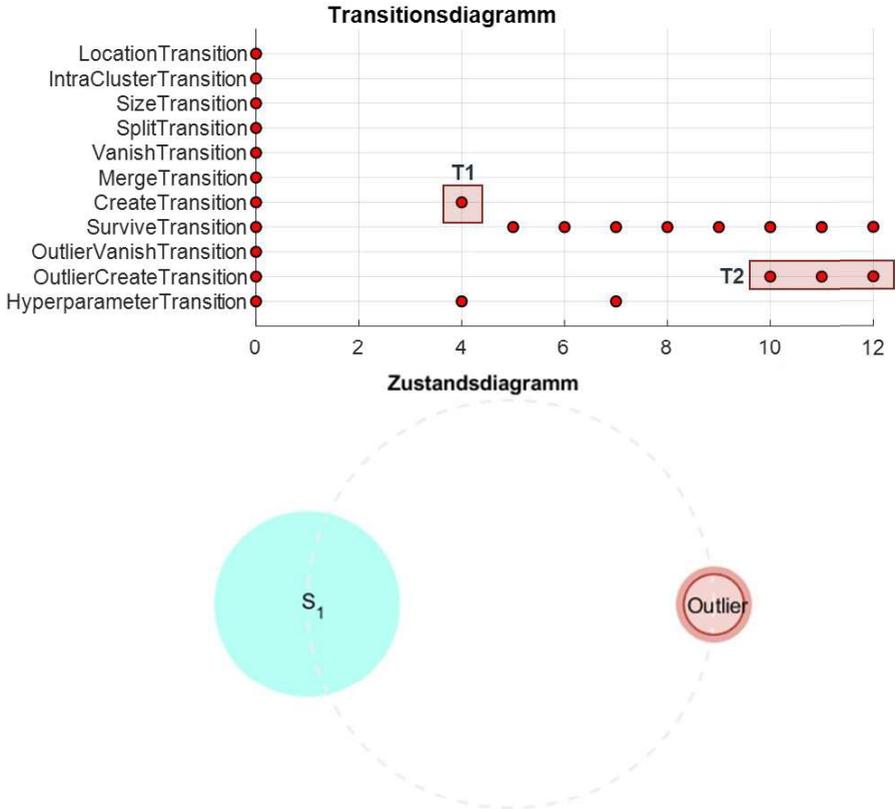


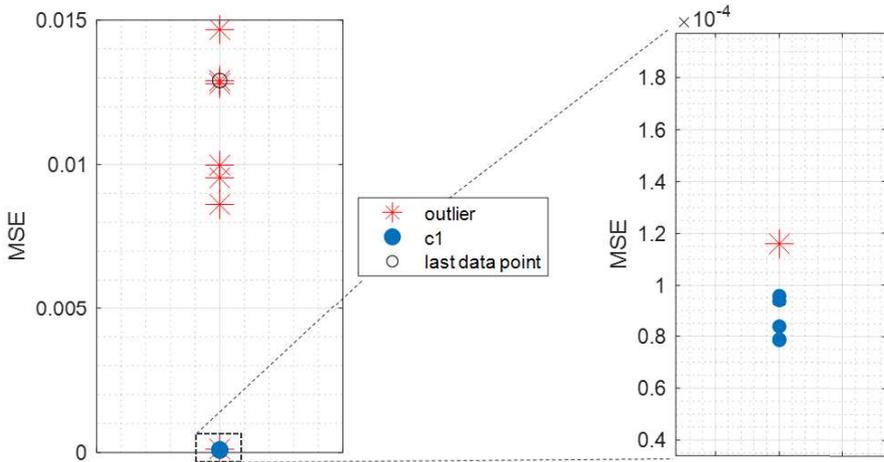
Abbildung 8-22: Cluster-Tracking-Ergebnis für Szenario 3 für vordefinierte Merkmale

Der zeitliche Verlauf des Cluster-Trackings ist unter nachstehendem Link als Video zugänglich: https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#FEATURE_2Achser_Lubricated.

Architekturvariante – MSE-Merkmalsextraktion

Die Architekturvariante MSE-Merkmalsextraktion liefert das gleiche Clusterergebnis, wobei einer der Datenpunkte des Clusters mit ausreichender Schmierung ebenfalls den Ausreißern zugeordnet wird. Dies ist in Abbildung 8-23 in der rechten Teilgrafik zu erkennen. Der Effekt entsteht durch *Overfitting* in der Trainingsphase.

Clusterergebnis - MSE Merkmalsextraktion



Ground Truth - Cluster Labels

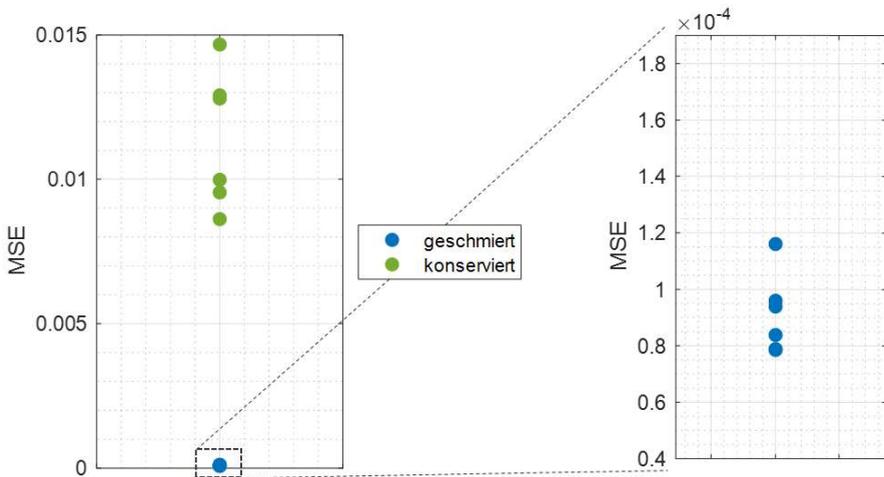


Abbildung 8-23: Clusterergebnis für Szenario 3 mit MSE-Merkmalsextraktion

Dementsprechend ergeben sich auch das Transitions- und Zustandsdiagramm in Abbildung 8-24. Im Transitionsdiagramm sind nur zwei markante Transitions zu erkennen. Mit T1 wird die *Create* Transition markiert, die das Auftreten des detektierten

Clusters für den Gutzustand repräsentiert. Mit T2 wird die Gruppe an *OutlierCreate* Transitionen markiert, die ab dem Zeitpunkt des Auftretens der Mangelschmierung entstehen.

Dass Transition T2 früher mit Variante 2 detektiert wird, hängt mit der falschen Zuordnung einer der Datenpunkte des geschmierten Zustands zusammen. Es ist kein Indiz dafür, dass die MSE-Merkmalsextraktion in diesem Beispiel sensibler auf Mangelschmierung reagiert.

Das folgende Video stellt den zeitlichen Verlauf für diese Architekturvariante im Szenario Mangelschmierung dar: https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#MSE_2Achser_Lubricated.

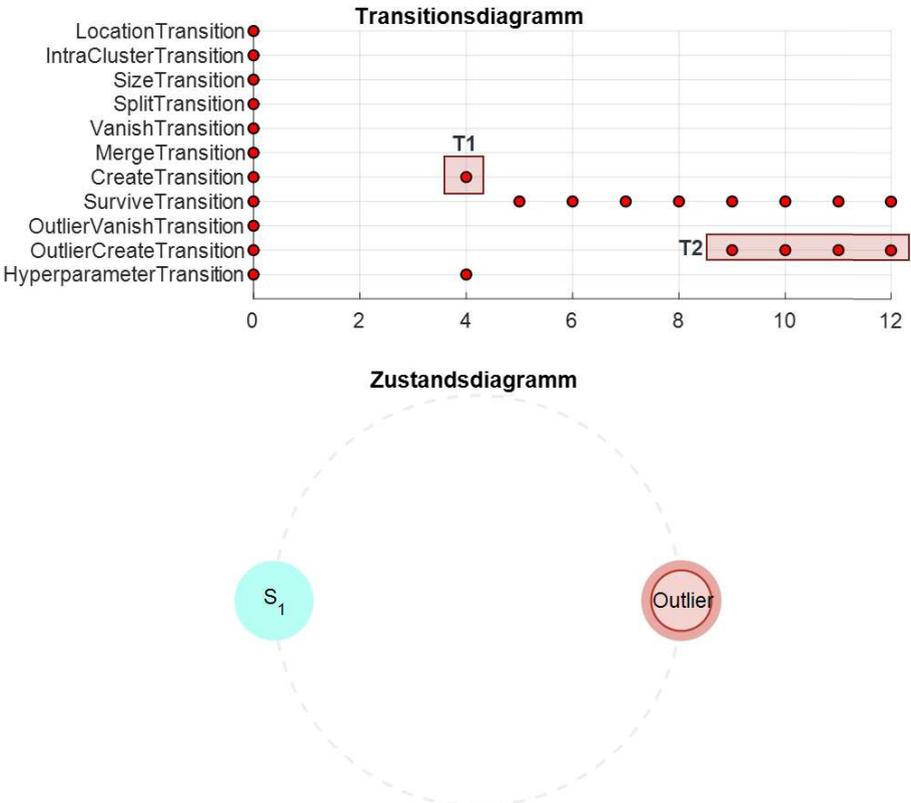


Abbildung 8-24: Cluster-Tracking-Ergebnis für Szenario 3 für MSE-Merkmalsextraktion

8.3.4 Szenario 4 – Partikeleinbringung

Die Architekturen sollen erkennen, wenn die Fahrt der Vorschubachse durch Abrasivpartikel beeinträchtigt wird. Dieses Szenario simuliert Verschmutzungs- bzw. Partikeleintrag in die Vorschubachse und kann bei erfolgreicher Detektion Anstoß zur Wartung oder Reinigung der Achse geben:

- Die Rohdaten, die verarbeitet werden, repräsentieren Fahrten mit konstanter Drehzahl über einen definierten Hub. Die Fahrten werden mit und ohne Beeinflussung durch Abrasivpartikel durchgeführt.
- Die Fahrten vor Einbringung dienen als Referenzdaten bzw. Trainingsdaten zum Erlernen des Gutzustands. Nach dem Anlernen mit einigen dieser Fahrten wird das CM-System in den unüberwachten Modus gesetzt.
- Insgesamt können drei unterschiedliche Systemzustände in diesem Szenario erkannt werden: Zustand vor Partikeleinbringung, Zustand während der Einbringung und Zustand nach Verteilung der Partikel.

Architekturvariante – vordefinierte Merkmale

Die Architekturvariante mit vordefinierten Merkmalen erreicht das Clusterergebnis in Abbildung 8-25. Dabei werden die beiden Zustände mit vielen Datenpunkten, der Grundzustand und die Phase nach der Partikeleinbringung, richtig als einzelne Cluster erkannt. Die zwei Datenfenster für die Überfahrt der Partikel werden lediglich als Ausreißer identifiziert, da diese Merkmale mit einem ganz anderen Wertebereich ergeben.

Wird jedoch die relevante CM-Interpretation berücksichtigt, so entspricht die Anomalie-detektion an dieser Stelle am besten dem erwarteten CM-System-Ergebnis bei der Partikeleinbringung. Denn die Detektion der Partikel stellt keinen Systemzustand dar, sondern lediglich eine Störung bzw. Anomalie. Sind die Partikel erst einmal überrollt, stellt sich nach initialer Verteilung der Verunreinigung ein neuer Systemzustand ein, der mittels Clusterverfahren auch erkannt wird. Deutlich sichtbar im Merkmalsraum ist auch die Nähe der beiden Cluster, d. h. die Ähnlichkeit der Merkmale. Es ist naheliegend, dass der Gutzustand dem Zustand nach der Verteilung der Partikel ähnlicher ist als dem Überrollen der Partikel.

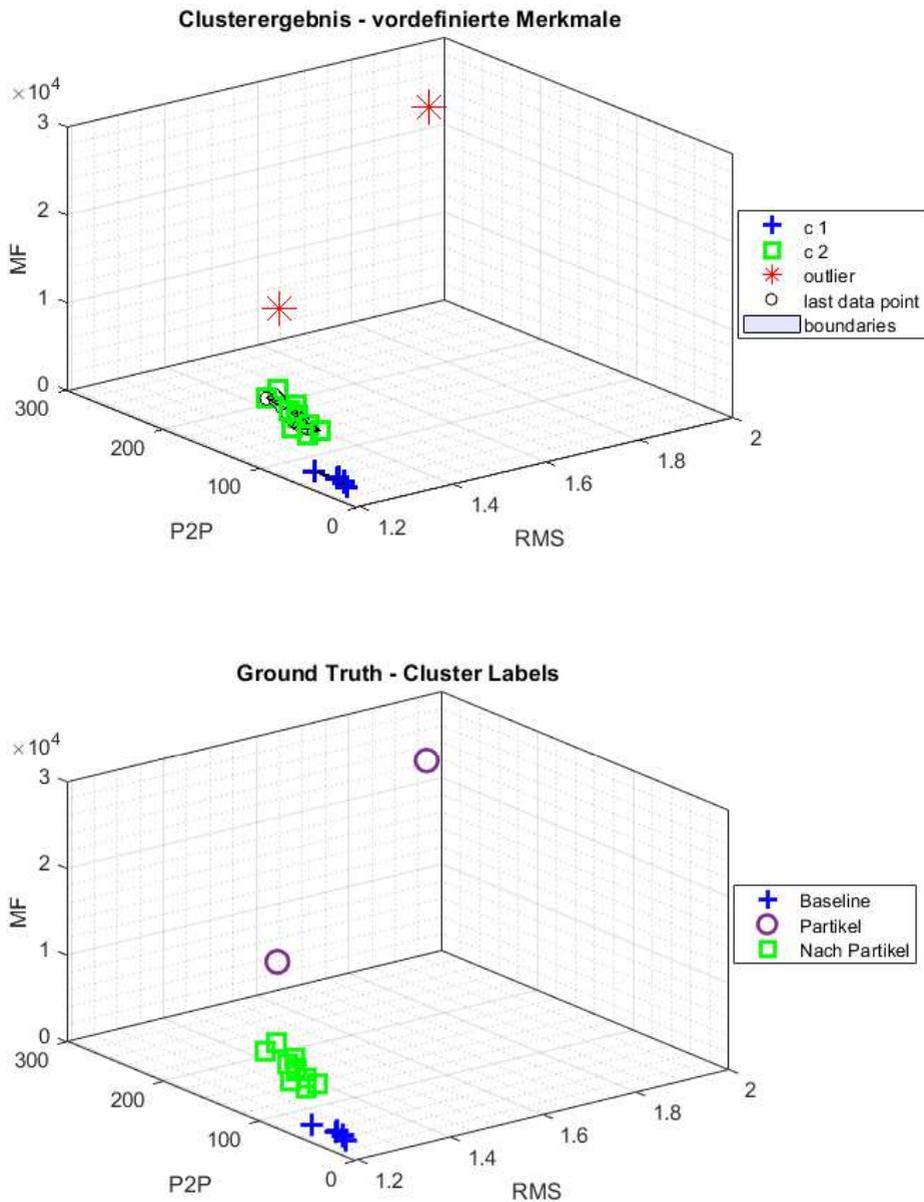


Abbildung 8-25: Clusterergebnis für Szenario 4 mit vordefinierten Merkmalen

Im Transitionsdiagramm (siehe Abbildung 8-26) der vordefinierten Merkmalsextraktion finden drei markante Transitionen statt (markiert mit T1, T2, T3). Mit Hilfe dieser Transitionereignisse kann auch die zeitliche Abfolge der Zustände nachvollzogen werden: Der Grundzustand entsteht als neues Cluster (T1), bis zur Partikeleinbringung entstehen dann erstmal keine Transitionen (nur *Survive* Transitionen). Die Partikeleinbringung selbst wird als Anomalie (T2) erkannt. Danach kommt es erneut zur Clusterbildung (T3) in der Phase nach der Partikeleinbringung, wenn die Partikel sich im System (Mutter und Spindel) verteilen.

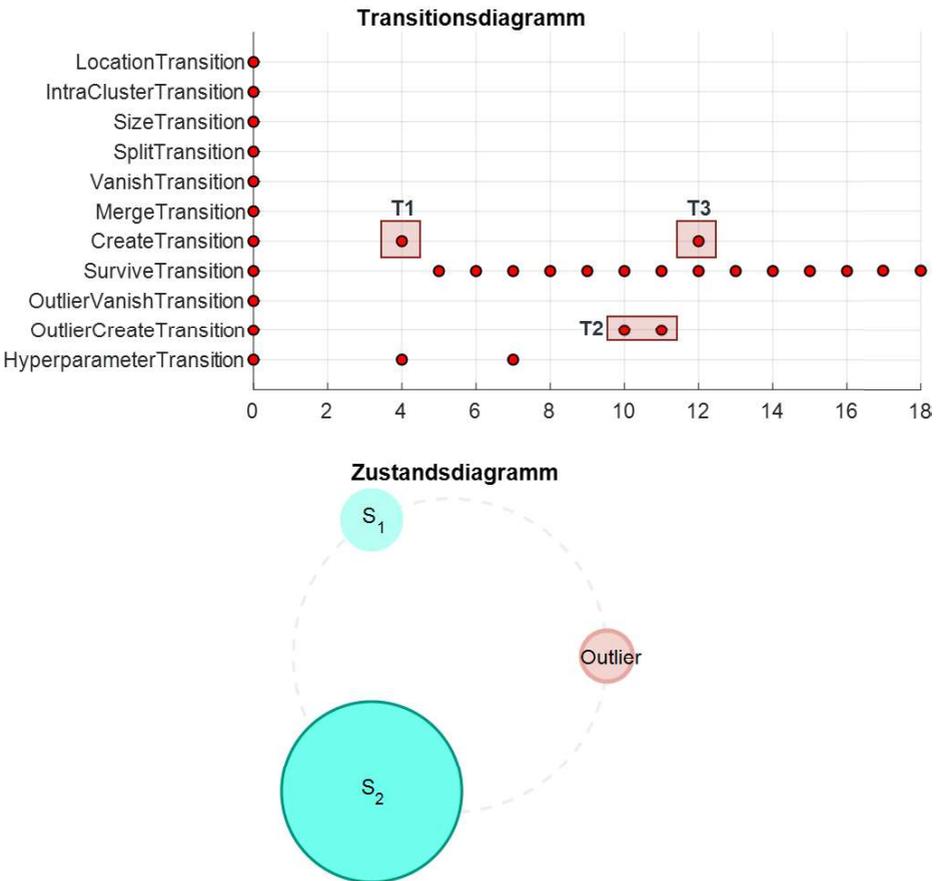


Abbildung 8-26: Cluster-Tracking-Ergebnis für Szenario 4 mit vordefinierten Merkmalen

Entsprechend ergibt sich das Zustandsdiagramm in Abbildung 8-26 unten mit zwei Zuständen S_1 , S_2 und einem roten Zustandsknoten für die detektierten Ausreißer. Zustand S_2 erhält hierbei einen größeren Radius als S_1 , um die Clustergröße zu symbolisieren. Die Datenpunkte in diesem Cluster streuen stärker, weshalb sich ein größeres Cluster ergibt. Der Zustand nach der Verunreinigung ist auch erwartungsgemäß undefinierter, weshalb die detektierten AE-Sensorwerte stärker streuen.

Die zeitliche Betrachtung dieser Architekturvariante ist in folgendem Video möglich: https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#FEATURE_2Achser_Particles.

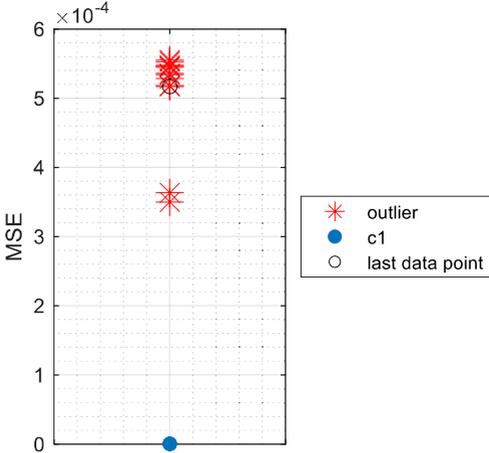
Architekturvariante – MSE-Merkmalsextraktion

Die MSE-Architekturvariante erreicht weniger Detektionsgüte. Die Clusterergebnisse sind in Abbildung 8-27 dargestellt. Da beim Erlernen des Grundzustands ein *Overfitting* stattfindet, ergeben die anderen Datenfenster MSE-Fehler mit zu großen Abständen zueinander. Der Clusteralgorithmus kann diese nicht mehr erfolgreich einem neuen Cluster zuordnen. Sowohl die Partikeleinbringung als auch die Phase nach der Partikeleinbringung werden mit MSE-Fehlern rekonstruiert, die so große Abstände im Merkmalsraum aufweisen, dass keine neuen Cluster entstehen. Die Anomalie-Detektionsgüte beträgt aber auch für diese Variante 100 Prozent, da alle vom Grundzustand abweichenden Datenfenster zumindest als Anomalie deklariert werden.

Das Zustandsdiagramm besteht deshalb nur aus einem Zustandsknoten S_1 und einem Knoten für die Anomalien. Die wichtigen Transitionen sind in Abbildung 8-28 mit T1 und T2 markiert. Es wird, wie oben bereits angemerkt, nur der Grundzustand als Cluster erkannt. Alle weiteren Datenpunkte der anderen Klassen (Partikeleinbringung und Phase nach Partikel) ergeben *OutlierCreate* Transitionen (Markierung T2).

Die Architekturvariante schafft es daher lediglich, eine Abweichung vom Grundzustand zu erkennen. Sie kann keine Unterscheidung in Partikeleinbringung und Phase nach der Partikeleinbringung vornehmen.

Clusteregebnis - MSE Merkmalsextraktion



Ground Truth - Cluster Labels

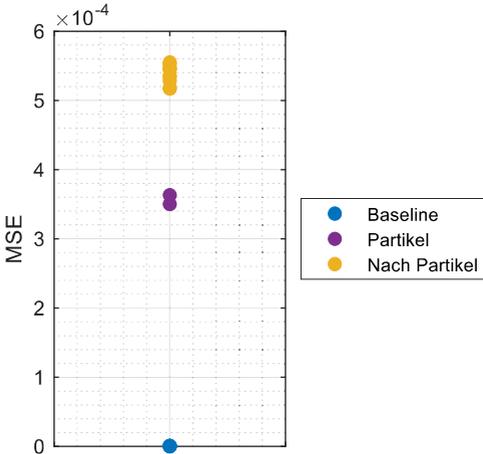


Abbildung 8-27: Clusteregebnis für Szenario 4 mit MSE-Merkmalsextraktion

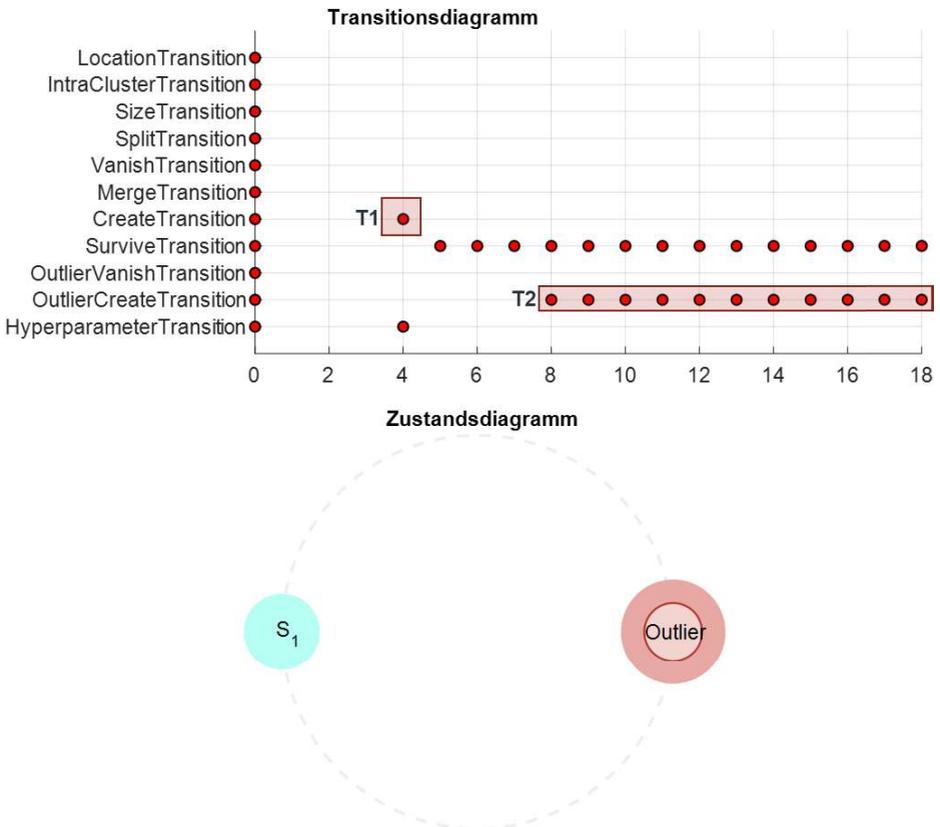


Abbildung 8-28: Cluster-Tracking-Ergebnis für Szenario 4 mit MSE-Merkmalsextraktion

Die zeitliche Betrachtung der Clusterergebnisse für das Szenario Partikeleinbringung und diese Architekturvariante wird durch folgendes Video beschrieben: https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#MSE_2Achser_Particles.

8.3.5 Szenario 6 – Vorspannungsstufen bei verschiedenen Drehzahlen

In diesem Szenario ändern sich zwei Randbedingungen während des Versuchs: das Vorspannungslevel und die Vorschubgeschwindigkeit. Aufgrund der langen Versuchszeit, die eine Betrachtung des natürlichen Verschleißes bis zur Abnahme der Vorspannung in Anspruch nimmt, werden in diesem Szenario KGT gleicher Baugröße mit unterschiedlichen Vorspannungslevels (siehe Anhang A 2) verglichen. Das Szenario dient

der Bewertung der Architekturen zur Detektion von Vorspannungsverlusten bei sich verändernden Randbedingungen (hier die Vorschubgeschwindigkeit):

- Als Rohdaten dienen Fahrten von drei betrachteten KGT, die unterschiedliche Vorspannlevel aufweisen (C0, C2 und C3). Für die Triebe sind Konstantfahrten mit unterschiedlichen Geschwindigkeiten aufgezeichnet worden.
- Als Baseline zum Erstellen des Gutzustands werden drei Fahrten mit mittlerer Geschwindigkeit (100 mm/s) und größtem Vorspannungslevel (C3) verwendet. Das Clustermodell wird auf dieser Basis angelemt. Für alle weiteren Zustände wird das CM-System unüberwacht betrieben.
- Insgesamt sind neun Systemzustände detektierbar (jeweils drei Geschwindigkeiten pro Vorspannungslevel).

Architekturvariante – vordefinierte Merkmale

Mit der vordefinierten Merkmalsextraktion lassen sich sieben der neun Zustände (siehe Abbildung 8-29) zuordnen. Die nicht erkannten Zustände werden zumindest korrekt als zusätzliche Anomalien erkannt und nicht fälschlicherweise anderen Clustern zugeordnet. Der Abstand dieser Datenpunkte im Merkmalsraum sorgt dafür, dass diese zwei Zustände kein eigenes Cluster mittels DBSCAN erhalten. Bei den nicht erkannten Zuständen handelt es sich einmal um den Vorspannungszustand C3 mit Vorschubgeschwindigkeit 200 mm/s und den Vorspannungszustand C0 mit 100 mm/s. Dabei ist keine physikalische Erklärung nötig, dass ausgerechnet diese beiden Zustände nicht geclustert werden können. Vielmehr liegt hier die Fehlzuordnung an der automatisch erstellten Parametrierung des Clusteralgorithmus. Durch Feintuning dieser Parameter ließe sich auch eine Konfiguration des Clusteralgorithmus erreichen, der alle Cluster-Datenpunkte korrekt zuordnet. Das kann dann allerdings nur als Offline-Training ausgeführt werden und erfolgt nicht mehr unüberwacht.

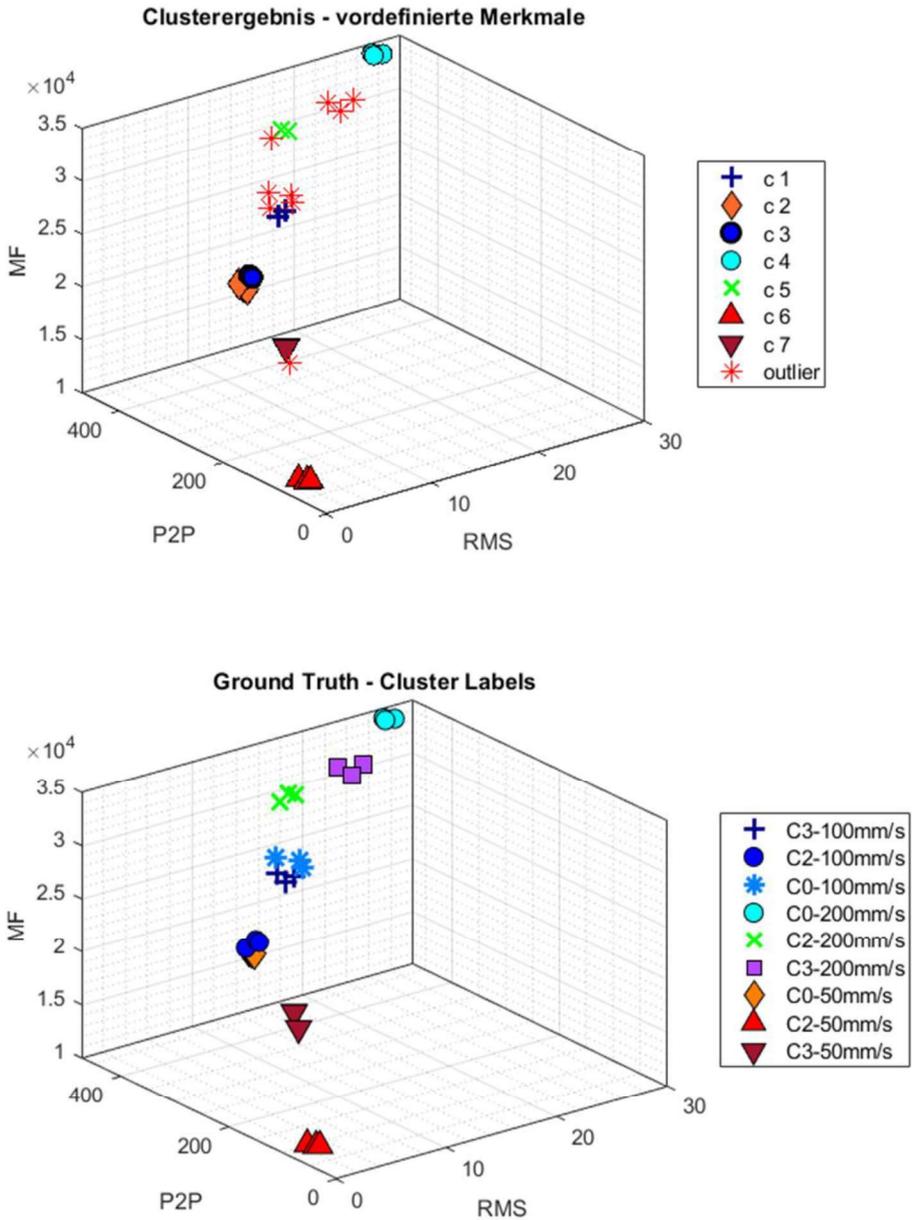


Abbildung 8-29: Clusterergebnis für Szenario 6 mit vordefinierten Merkmalen

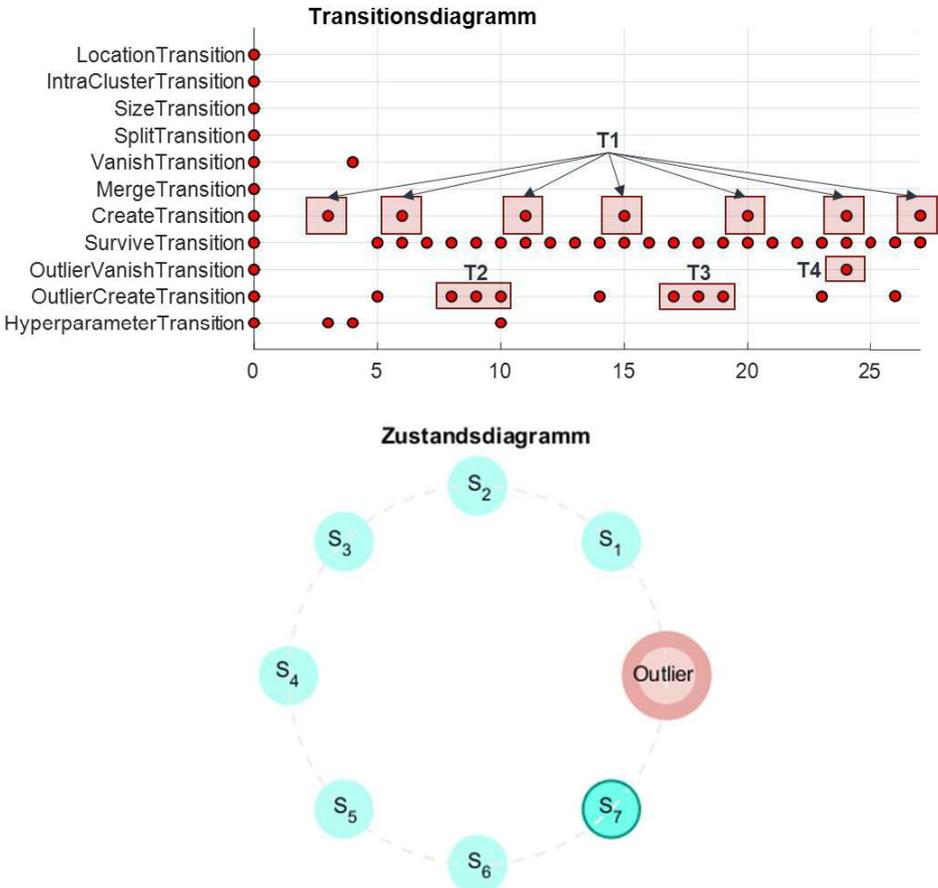


Abbildung 8-30: Cluster-Tracking-Ergebnis für Szenario 6 mit vordefinierten Merkmalen

Im Cluster-Tracking entstehen die Diagramme in Abbildung 8-30. Es liegen vier relevante Transitionen vor: Die sieben entstehenden Cluster werden der Reihe nach mit *Create* Transitionen (T1) erfasst, die dem Auftreten neuer Zustände entsprechen. Zusätzlich zu den Clustern werden mit T2 und T3 zwei Ausreißergruppen erkannt, die die tatsächlichen Zustände wiedergeben. Eine Besonderheit in diesem Transitionsdiagramm ist das Auftreten der *OutlierVanish* Transition (Markierung T4). Dieses Ereignis findet statt, wenn aus zuvor als Ausreißer deklarierten Datenpunkten nachträglich ein Cluster (Zustand) entsteht. Im Zustandsdiagramm in Abbildung 8-30 sind zu den

detektierten Zuständen auch sieben Zustandsknoten dargestellt sowie ein Knoten für die Ansammlung von Ausreißern. Die Zustandsknoten S_{1-7} sind gleich groß, da jeweils drei Fahrten pro Vorspannungslevel und Geschwindigkeit ausgeführt wurden.

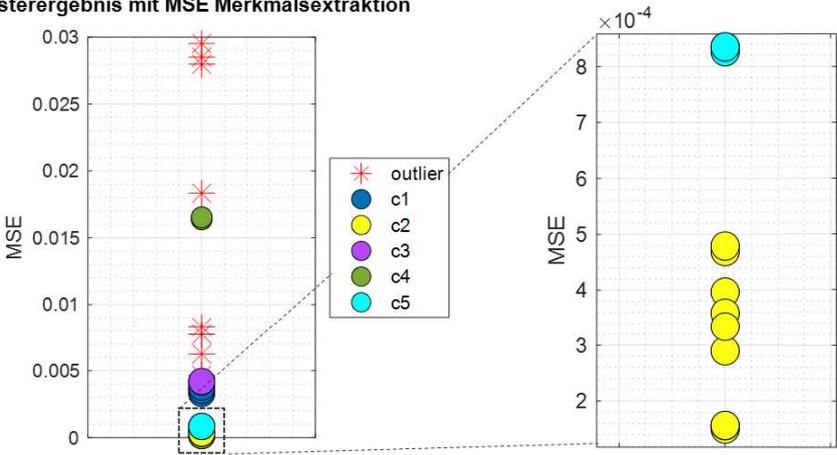
Der gesamte Verlauf des Cluster-Trackings für diese Architekturvariante kann in folgendem Video nachvollzogen werden: https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#FEATURE_2Achser_PreloadLevelVar.

Architekturvariante – MSE-Merkmalsextraktion

Mit der MSE-Merkmalsextraktion in Abbildung 8-31 können dagegen nur fünf Cluster zugeordnet werden. Im Detailbereich auf der rechten Seite der Abbildung lässt sich der Unterschied zu Variante 1 erkennen: Die Zustände C2 (50 mm/s), C3 (50 mm/s) und C2 (100 mm/s) werden als ein zusammengehöriges Cluster deklariert. Aufgrund der ähnlichen Merkmalsräume und engen Abstände kann keine Unterscheidung in separate Cluster vom DBSCAN-Algorithmus vorgenommen werden. Damit entsteht der Unterschied zwischen fünf und sieben erfolgreich erkannten Zuständen. Auch mit Variante 2 werden die Zustände C3 mit Vorschubgeschwindigkeit 200 mm/s und C0 mit 100 mm/s nur als Ausreißer deklariert.

Das Transitions- und das Zustandsdiagramm für die MSE-Merkmalsextraktion unterscheiden sich aufgrund der nicht erkannten Zustände deutlich von der ersten Variante. In Abbildung 8-32 sind nur fünf *Create* Transitionen im Diagramm zu erkennen (markiert mit T1). Die Ausreißergruppe, die mit T2 im Diagramm markiert ist, entsteht aus den nicht als Cluster erkannten Zuständen C0 (200 mm/s) und C2 (200 mm/s). Wie bereits oben für das Clusterergebnis erwähnt, sind die Zustände C2 (50 mm/s), C3 (50 mm/s) und C2 (100 mm/s) als ein zusammengehöriges Cluster deklariert worden. Dadurch entsteht im Zustandsdiagramm auch ein Pfeil von Zustand S_5 zurück zu S_2 , der einen Zustandswechsel in einen vorherigen Zustand beschreibt. In diesem Fall ist der Wechsel zwar inkorrekt bezüglich der tatsächlichen Klassenzuordnung, zeigt aber die Fähigkeit des CM-Systems, solche Ereignisse auch zu beschreiben. Im Grunde sollten diese Datenpunkte zwei neue Cluster entstehen lassen, führen aufgrund der Zuordnung zu einem existierenden Cluster aber nur zum Zustandswechselfeile und den *Survive* Transitionen in Markierung T3.

Clusterergebnis mit MSE Merkmalsextraktion



Ground Truth - Cluster Labels

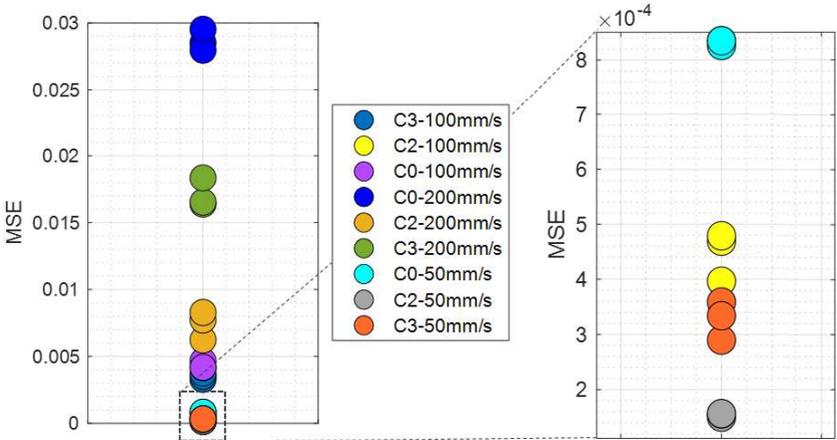


Abbildung 8-31: Clusterergebnis für Szenario 6 mit MSE-Merkmalsextraktion

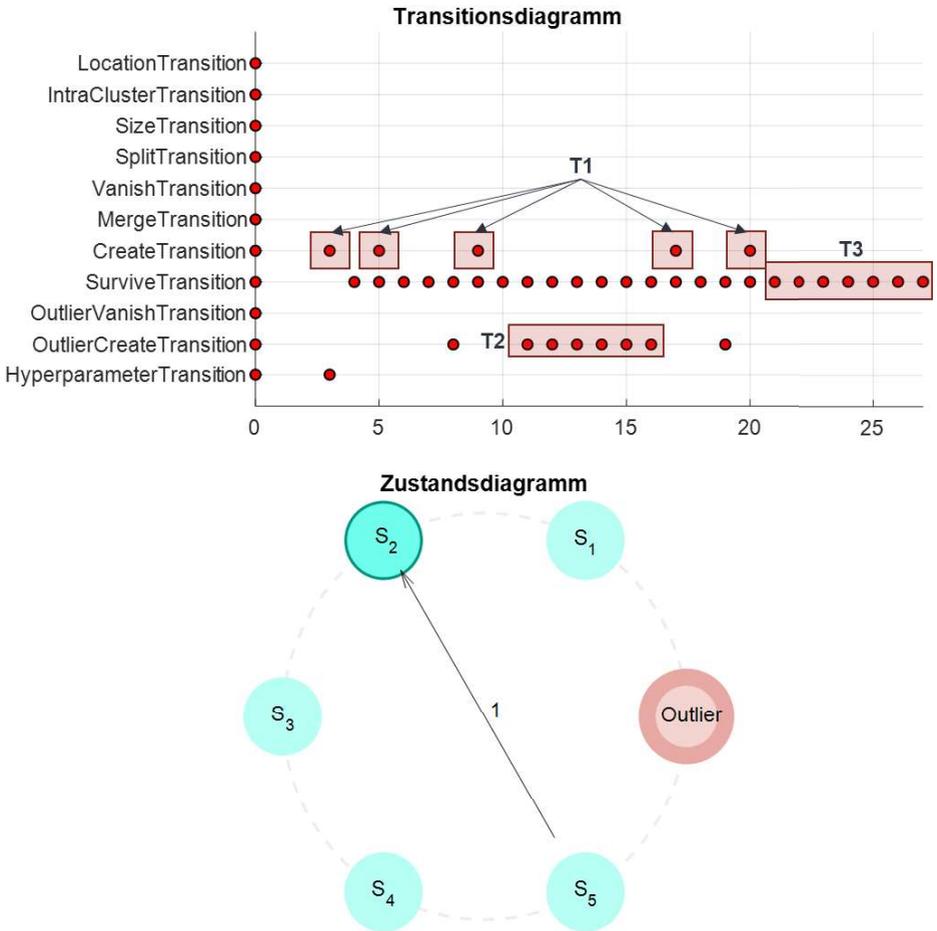


Abbildung 8-32: Cluster-Tracking-Ergebnis für Szenario 6 mit MSE-Merkmalsextraktion

Der gesamte Verlauf des Cluster-Trackings für diese Architekturvariante kann in folgendem Video betrachtet werden: https://jhillenbrand.github.io/CMSsystem/videos/other_scenarios.html#MSE_2Achser_PreloadLevelVar.

8.3.6 Detektionsgüte der Architekturvarianten für unterschiedliche Szenarien

Die Gesamtheit der Ergebnisse aus den unterschiedlichen Szenarien für die zwei Architekturvarianten sollen nun anhand von zwei Kriterien bewertet werden: Zustand-Detektionsgüte Q_S und Anomalie-Detektionsgüte Q_A . Die Zustand-Detektionsgüte Q_S wird dabei als F_1 -Score berechnet (Raschka 2016, S. 192). Er setzt sich zusammen aus den Metriken *Precision* und *Recall* (siehe Formel 8-3) und ist eine etablierte Metrik im Bereich des maschinellen Lernens zur Bewertung von Modellergebnissen. Der F_1 -Score ist zu verwenden, wenn beide Metriken ausgewogen und hoch sein sollen. Dabei drückt eine hohe *Precision* aus, dass die positive Vorhersage (im Fall von binären Klassifikationen) zutrifft. Ein hoher *Recall* bringt dagegen zum Ausdruck, dass viele der positiven Kandidaten erkannt werden (Oppermann 2021; Japkowicz & Shah 2014).

$$Q_S = 2 \cdot \frac{\textit{Precision} \cdot \textit{Recall}}{\textit{Precision} + \textit{Recall}}$$

mit

$$\textit{Precision} = \frac{\textit{True Positives}}{\textit{True Positives} + \textit{False Positives}} \quad 8-3$$

und

$$\textit{Recall} = \frac{\textit{True Positives}}{\textit{False Negatives} + \textit{True Positives}}$$

Im Fall von mehreren Ergebnisklassen, die allgemein bei Clusterproblemen auftreten können, wird für die Berechnung der Metrik folgende Vorgehensweise verwendet (Vijini Mallawaarachchi 2020): Für die möglichen Klassen c und Cluster k Zuordnungen wird die Matrix A_{ck} konstruiert (Formel 8-5). Dabei gibt das Element a_{ij} der Matrix an, wie viele Objekte dem i -ten Cluster zugeordnet wurden und einem Objekt der j -ten Klasse entsprechen.

$$A_{ck} = \begin{bmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{c1} & \cdots & a_{ck} \end{bmatrix} \quad 8-4$$

Für den Spezialfall, dass die Anzahl der Cluster auch der Anzahl der Klassen entspricht und die richtige Zuordnung gefunden wird, gibt es nur Einträge auf der Diagonalen der Matrix ($a_{ii} \neq 0$).

Für die Berechnung von *Precision* und *Recall* folgt damit:

$$Precision = \frac{\sum_{j=1}^k \max_{i=1..c}(a_{ij})}{\sum_{i=1}^c \sum_{j=1}^k a_{ij}}$$

Für jedes Cluster wird die Klasse mit der größten Zugehörigkeit gesucht. Die Anzahl der zugeordneten Objekte wird summiert und durch die Gesamtanzahl aller zugeordneten Objekte geteilt.

$$Recall = \frac{\sum_{i=1}^c \max_{j=1..k}(a_{ij})}{\sum_{i=1}^c \sum_{j=1}^k a_{ij} + n_{out}}$$

8-5

Für jede Klasse wird das Cluster mit der größten Zugehörigkeit gesucht. Die Anzahl der zugeordneten Objekte wird summiert und durch die Gesamtanzahl aller Zuordnungen und die Summe aller nicht zugeordneten Objekte geteilt (Ausreißer n_{out}).

Die Anomalie-Detektionsgüte Q_A dient als Begleitkriterium für die Zustand-Detektionsgüte und beschreibt, inwieweit Datenpunkte, die nicht einem Cluster zugeordnet werden, korrekt als Anomalie erfasst werden. Aufgrund der Verteilungsdichte und räumlichen Abstände können die Merkmalsräume von Datenpunkten, die dem gleichen Zustand angehören, als Ausreißer fehlinterpretiert werden. Diese Unschärfe liegt dem verwendeten Clusteralgorithmus zugrunde. Werden Datenpunkte fälschlicherweise einem Cluster zugeordnet, zu dem sie nicht gehören, so fällt die Anomalie-Detektionsgüte gering aus. Werden die Datenpunkte vom Algorithmus jedoch als Ausreißer markiert, nimmt die Güte zu.

Da es für ein CM-System ausreichend sein kann, neue Zustände als Anomalie zu interpretieren, wird die Anomalie-Detektionsgüte als weitere Bewertungsgröße mit eingeführt. Im Kontext dieser Arbeit wird definiert:

$$Q_A = \begin{cases} 0\%, & \text{Fall a)} \\ 50\%, & \text{Fall b)} \\ 100\% & \text{Fall c)} \end{cases}$$

Für Fall a) gilt: Keine Zustände* werden als Anomalie detektiert.

Für Fall b) gilt: Nur ein Teil der Zustände* wird als Anomalie detektiert.

Für Fall c) gilt: Alle Zustände* werden als Anomalie detektiert.

8-6

* Zustände, die nicht geclustert oder falsch geclustert wurden

Tabelle 8-5: Übersicht der erreichten Detektionsgüte je Szenario und Architektur

#	Prüfstand	Szenario	Vordefinierte Merkmalsextraktion		MSE-Merkmalsextraktion	
			Zustand Detektionsgüte	Anomalie Detektionsgüte	Zustand Detektionsgüte	Anomalie Detektionsgüte
1	2-Achs-KGT-RZA	Verschiedene Drehzahlen	63,15%	100%	57,14%	100%
2	5-Achs-KGT	Verschiedene Drehzahlen	85,71%	100%	33,33%	50%
3	2-Achs-KGT-RZA	Verschiedene Lasten bei konstanter Drehzahl	33,33%	50%	77,42%	50%
4	2-Achs-KGT-RZA	Verschiedene Lasten bei konstanter Drehzahl	34,85%	0%	81,63%	100%
5	2-Achs-KGT-RZA	Mangelschmierung	66,66%	100%	58,82%	100%
6	2-Achs-KGT-RZA	Partikeleinbringung	94,11%	100%	50%	100%
7	5-Achs-KGT	Partikeleinbringung	61,76%	100%	61,5%	100%
8	2-Achs-KGT-RZA	Vorspannungsstufen bei konst. Drehzahl	94,11%	100%	80%	100%
9	2-Achs-KGT-RZA	Vorspannungsstufen bei versch. Drehzahlen	75,55%	50%	65,88%	50%
10	5-Achs-KGT	Ermüdungsversuch mit erhöhter Last	40%	50%	40%	50%

In Tabelle 8-5 werden für die im vorherigen Abschnitt vorgestellten Architekturvarianten die Ergebnisse für die Detektionsgüte aufgeführt. In einer Zeile werden hier jeweils pro Szenario beide Varianten verglichen hinsichtlich Zustand- und Anomalie-Detektionsgüte. Wurde ein Szenario zusätzlich auf beiden Prüfständen durchgeführt, so taucht es zweimal auf. Die Tabelle beinhaltet auch Untersuchungsergebnisse an Prüfständen für Szenarien, die in den vorigen Abschnitten nicht aufgeführt wurden. Auf die detaillierte Darstellung aller Ergebnisse in Form von Cluster- und Zustandsdiagrammen wird hier verzichtet (eine vollständige Übersicht ist unter https://jhillenbrand.github.io/CMSsystem/videos/other_scenarios.html verfügbar).

Das Szenario *Verschiedene Drehzahlen* ist mit der Architekturvariante vordefinierte Merkmalsextraktion besser überwachbar (Zeile 1 und 2 in Tabelle 8-5). Die Zustand-Detektionsgüte liegt zwischen 63 und 85 Prozent. Mit der MSE-Merkmalsextraktion sind nur 33 bis 57 Prozent erreichbar. Der Vorteil für die vordefinierten Merkmale liegt hier in einer geschickten Auswahl begründet. Der entstehende Merkmalsraum für die Variante ist besser separierbar als derjenige, der für die MSE-Merkmalsextraktion entsteht. Ein Defizit, das beide Varianten für dieses Szenario aufweisen, ist, dass sich mit

zunehmender Geschwindigkeit Datenpunkte bilden, die durch den Clusteralgorithmus nicht mehr als zusammengehöriges Cluster identifiziert werden. Sie werden als Ausreißer markiert, jedoch nicht als erfasster Zustand ausgewiesen (Anomalie-Detektionsgüte von 100 %). Das CM-System interpretiert hier eine Anomalie und nicht einen Zustand. Die Detektion einer Änderung/Neuheit ist damit jedoch gegeben.

Für das Szenario *Verschiedene Lasten bei konstanter Drehzahl* erzielt die vordefinierte Merkmalsextraktion eine sehr geringe Detektionsgüte. Die ausgewählten Merkmale sind hier schlicht ungeeignet für die Detektion der verschiedenen Lastunterschiede. Hingegen kann die MSE-Merkmalsextraktion erfolgreich eingesetzt werden, um genau die richtige Repräsentation der Daten zu erlernen und einen gut separierbaren Merkmalsraum zur Verfügung zu stellen. Es lassen sich Zustand-Detektionsgüten bis 81 Prozent erreichen. Dieses Verhalten ist auf beiden verwendeten Prüfständen reproduzierbar.

Beide Varianten schneiden für das Szenario *Mangelschmierung* nahezu gleich gut ab und erreichen Zustand-Detektionsgüten zwischen 58 und 66 Prozent. Die geringe Güte entsteht, da Merkmale auftreten, die aufgrund des Abstands im Merkmalsraum nicht einem gemeinsamen Cluster zugeordnet werden können. Die primäre Zielstellung, die Mangelschmierung als abnormalen Zustand zu erkennen, ist trotzdem gegeben, da alle Datenpunkte im Mangelschmierungszustand als Ausreißer erfasst werden (Anomalie-Detektionsgüte von 100 %).

Die vordefinierte Merkmalsextraktion weist für das Szenario *Partikeleinbringung* zumindest an einem der beiden Prüfstände einen klaren Vorteil auf. Es werden bis zu 94 Prozent für die Zustand-Detektionsgüte erreicht. Hier werden alle Zustände erkannt und die auftretenden Anomalien bei Partikeleinbringung ebenfalls richtig detektiert. Mit der anderen Variante (MSE-Merkmalsextraktion) und am anderen Prüfstand sind die erreichbaren Ergebnisse schlechter. (Die Unterschiede lassen sich unter anderem auf die Verwendung unterschiedlicher AE-Sensoren zurückführen.) Hier wird nur der Gutzustand erkannt und die restlichen Datenpunkte werden Anomalien zugeordnet. Es ergeben sich daher nur Zustand-Detektionsgüten bis 61 Prozent. In allen Situationen ist die Anomalie-Detektionsgüte jedoch zu 100 Prozent erfolgreich.

Im Szenario der *Vorspannungsstufen bei konstanter Drehzahl* erreichen beide Architekturvarianten nahezu perfekte Ergebnisse. Die vordefinierte Merkmalsextraktion schneidet mit 94 Prozent erneut am besten ab, gefolgt von der MSE-

Merkmalsextraktion mit 80 Prozent am ersten Prüfstand. Die vordefinierten Merkmale schaffen auch hier wiederum einen besser separierbaren Merkmalsraum, der zu einer besseren Performance des Clusteralgorithmus führt.

Wenn zusätzlich die Geschwindigkeiten variiert werden (Szenario *Vorspannungsstufen bei verschiedenen Drehzahlen*), verschlechtern sich die Ergebnisse jeweils für die beiden Varianten auf 74 bzw. 65 Prozent Zustand-Detektionsgüte. Im Szenario müssen neun verschiedene Zustände unterschieden werden. Im Fall der vordefinierten Merkmale werden davon sieben richtig erkannt, im Fall der MSE-Merkmalsextraktion sind es nur fünf. Gegenüber dem Szenario *Verschiedene Drehzahlen*, wo nur Drehzahlen zu erkennen sind, ist jedoch eine Verbesserung der erreichbaren Detektionsgüten festzustellen. Beide Architekturvarianten weisen die Fähigkeit auf, unterschiedliche Vorspannungsstufen als Zustände zu detektieren und eine Differenzierung in Drehzahlstufen vorzunehmen. Variante 1 mit den vordefinierten Merkmalen schließt hierbei besser ab, da die gewählten Merkmale eine bessere Separation der Cluster im entstehenden Merkmalsraum ermöglichen.

Ein Szenario, für das keine guten Ergebnisse erzielt werden konnten, ist der *Ermüdungsversuch mit erhöhter Last*. In diesem Szenario überwacht das CM-System einen Lebensdauerversuch mit AE-Daten. Der Versuch wurde bis zum Erreichen von Ermüdungserscheinungen auf der Laufbahn der Spindel durchgeführt. Ziel war die eindeutige Erkennung einer Degradation der Komponente mittels AE-Sensorik. Es konnten jedoch keine Zustände neben dem anfänglichen Gutzustand detektiert werden. Die Sensordaten unterlagen einer großen Streuung über den Überwachungszeitraum. Von den erwarteten Clustertransitionen *Location* Transition und *IntraCluster* Transition, die als Anzeichen von Verschleiß interpretiert werden können, taucht lediglich am Ende des Versuchs eine *Location* Transition auf. Mit den automatisiert erstellten Architekturvarianten ließ sich nicht die gewünschte Überwachung und Dateninterpretation realisieren. Für dieses Szenario wären weitere Anpassungen der Architektur notwendig. Letztlich ließ auch eine manuelle Analyse der Rohdaten kein eindeutiges Indiz auf den Verschleiß zu.

Die Ergebnisse lassen sich wie folgt zusammenfassen: Beide Systeme ergeben in einer Vielzahl der Szenarien eine moderate Zustand-Detektionsgüte. Durch die Fähigkeit des Clusterverfahrens, sowohl Cluster als auch Ausreißer zu detektieren, kann diese Detektionsgüte weiter gesteigert werden (Anomalie-Detektionsgüte). Dies gilt, auch wenn die Zustand-Detektionsgüte nicht hoch ausfällt, wie im Fall des Szenarios *verschiedene*

Drehzahlen. So wird durch Detektion der Anomalien dennoch eine Aussage möglich. Als Ganzes betrachtet ergibt sich ein erfolgreiches CM-System.

Entscheidend für hohe Detektionsergebnisse in den Szenarien ist die Fähigkeit der Variante, einen gut separierbaren Merkmalsraum zu liefern (beispielhaft dargestellt in Abbildung 8-33). Eine Metrik, mit der diese Fähigkeit beschrieben werden kann, ist die Intercluster-Distanz (Everitt 2012, S. 61). Die Intercluster-Distanz weist in den betrachteten Szenarien, aber auch im Allgemeinen, eine Abhängigkeit von den zugrunde liegenden Daten auf. Das hat für die Auswahl der Unsupervised-Variante folgende Konsequenz: Sofern Merkmale aus Vorversuchen, ähnlichen Anwendungen oder aufgrund von Vorwissen bekannt sind, die gut separierbare Merkmalsräume entstehen lassen, kann die Architektur mit vordefinierten Merkmalen ausgewählt werden. Sind jedoch bisher kein Wissen, keine Vorversuche und auch keine Zeit vorhanden, um diese zu erhalten, so liefert die Architektur mit MSE-Merkmalsextraktion ein adäquates CM-System. Vor allem in Anwendungen mit hohem Versuchsaufwand oder zeitkritischen Randbedingungen kann diese Architekturvariante vorgezogen werden.

Am aussagefähigsten ist das CM-System (unabhängig von der Variante), wenn nur die Unterscheidung in einen initialen Gutzustand und einen abnormalen Zustand bzw. eine Anomalie getätigt werden muss. Mit zunehmender Anzahl an möglichen Systemzuständen und einer Überlagerung mit Verschleiß- oder Defektphänomenen wird eine eindeutige Zuordnung (Clustering) erschwert. Dies beeinträchtigt die Aussagequalität über den Systemzustand.

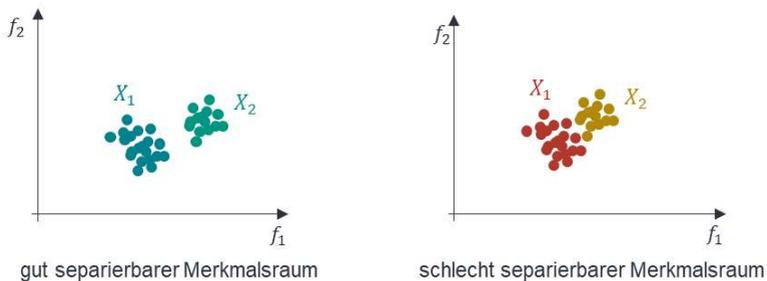


Abbildung 8-33: Vergleich für gut und schlecht separierbare Merkmalsräume

8.4 Verbesserung der Segmentierung durch domänenbasierte Konfiguration

In den vorherigen Abschnitten und Vorversuchen konnte eine starke Abhängigkeit der AE-Daten von der Geschwindigkeit der Vorschubachse bzw. der Spindeldrehzahl festgestellt werden. Zurückzuführen ist dieser Zusammenhang vor allem auf die zunehmende kinetische Energie bei höheren Drehzahlen, die zwangsläufig zu höherer Schwingungsanregung bzw. höheren Signalamplituden des AE-Signals führt.

Zur weiteren Erhöhung der Modellgüte und Berücksichtigung dieser Abhängigkeit kann der charakteristische Aufbau der Komponente für die bessere Parametrierung einer Segmentierung bei der Signalvorverarbeitung herangezogen werden. Unter Berücksichtigung der komponentenintrinsischen Anregungsfrequenzen, die bereits in Abschnitt 7.3 für den KGT vorgestellt worden sind, soll das CM-System weiter verbessert werden.

Allgemein können für die meisten Maschinenelemente der heutigen Antriebstechnik kinematische Systemfrequenzen gefunden werden, die aufgrund von Aufbau und Kinematik systeminhärent sind. Hierzu gehören beispielsweise Riemenschwingungen, Eingriffsfrequenzen bei Zahnradern, Überrollfrequenzen bei Wälzlagern, aber eben auch die vorgestellten Defektfrequenzen des KGT in Abschnitt 7.3.

Zur Veranschaulichung wird der Fall in Abbildung 8-34 betrachtet. Der Fall entspricht dem Szenario 4 Partikeleinbringung aus Abschnitt 8.3.4. Eine Verunreinigung (Ansammlung von Partikeln) wird entlang der Spindelaufbahn lokal konzentriert aufgebracht. Sobald die Mutter über diese Stelle fährt, wird ein deutlich stärkeres AE-Signal aufgezeichnet. Nun werden in der Abbildung unter a) und b) unterschiedliche Fensterlängen gewählt und es wird ein Merkmal für jeden Fensterabschnitt berechnet. Das Fenster in b) entspricht hierbei nahezu der Länge des Abschnitts des Signalanstiegs aufgrund der Überfahrt des Defekts. Die Fensterlänge a) wird deutlich kleiner gewählt, sodass sie mehrere Male in den Defektabschnitt passt (transparenter roter Bereich).

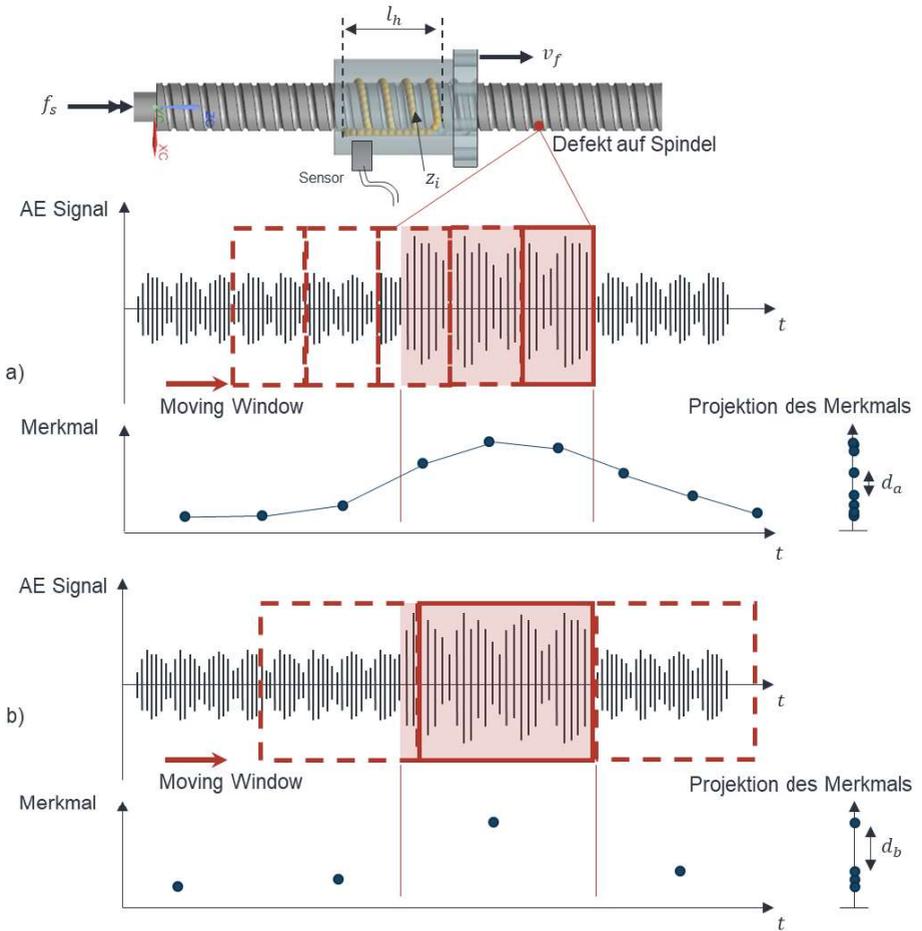


Abbildung 8-34: Schematische Darstellung des Einflusses der Fensterlänge für die Segmentierung am Beispiel eines Defektes auf der Spindel

Am rechten Rand des Schaubilds werden die entstehenden Merkmalswerte auf eine gemeinsame Achse projiziert und der Abstand zwischen den entstehenden Merkmalsgruppen mit d_a und d_b veranschaulicht. An diesem Anschauungsbeispiel wird ersichtlich, dass bei Übereinstimmung der Fensterlänge mit der zeitlichen Dauer des Defektes eine deutlich bessere Separation des Defektmerkmals vom Merkmalsbereich des Gutzustandes vorgenommen werden kann.

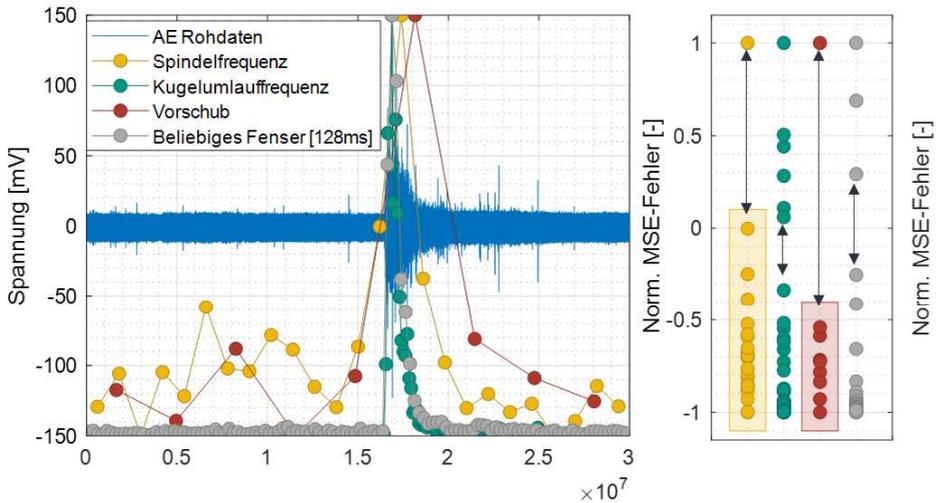


Abbildung 8-35: MSE-Fehler für verschiedene Segmentierungsfenster

Diese Tatsache kann mit Hilfe der vorgestellten Defektfrequenzen des KGT genutzt werden, um eine Lokalisierung, Kategorisierung oder allgemein eine bessere Defekterkennung zu ermöglichen.

In Abbildung 8-35 kann dieses Verhalten auch an realen Daten aus dem Partikeleinbringungsversuch (Szenario 4) gezeigt werden. In der Abbildung ist der Rohdatenabschnitt des AE-Signals dargestellt, wenn die Mutter über eine Partikelansammlung in der Mitte der Spindel rollt (blaues Signal). Dabei handelt es sich um ein Diagramm mit doppelter y-Achse: Das blaue Rohdatensignal wird mit Spannung (in mV) und die Datenpunkte des MSE-Fehlers mit einem normierten Rekonstruktionsfehler beschrieben. Im Vorfeld wurden vier verschiedene AEN auf Daten im Grundzustand trainiert, die Sensordaten mit unterschiedlicher Segmentierung erhalten haben. Dabei wird segmentiert mit Signalabschnitten, die der Spindelfrequenz f_s , der Kugelumlauf Frequenz $f_{b,n}$, dem Zeitabschnitt der Verweildauer $t_{d,s}$ der Mutter während des Vorschubs über einem Spindelabschnitt und einem beliebigen Fensterabschnitt (hier: 128 ms) entsprechen. Wird nun der abgebildete Rohdatenabschnitt mit den Partikeln zur Auswertung an die AEN übergeben, so entsteht das Diagramm im Schaubild links. Je nach Fensterwahl (entspricht den unterschiedlich farbigen Datenpunkten des MSE-Fehlers) entstehen andere Verläufe, die hier zu Vergleichszwecken normiert werden.

Naheliegender ist, dass alle AEN ihren Peak im Bereich des AE-Bursts aufgrund der Partikelüberrollung haben. Mit kleiner werdender Fenstergröße werden jedoch auch die benachbarten Segmente mit ähnlichem MSE-Merkmal berechnet. Damit entsteht beispielsweise für die Fensterung mit Kugelumlauffrequenz und beliebigem Fenster von 128 ms ein kontinuierlicher Übergang im Merkmalsbereich (siehe Abbildung 8-35 rechts). Besser nachzuvollziehen ist dieser Zusammenhang im rechten Diagrammteil, dort werden die normierten MSE-Fehler auf eine Werteachse projiziert. Die größten Abstände (Intercluster-Distanz) im Merkmalsbereich zwischen Segmenten des Grundzustands und Segmenten mit Partikelüberrollung erreicht die Segmentierung Vorschub. Dies deckt sich auch mit der Erwartung, dass bei Überrollung von Partikeln genau der Zeitabschnitt, der bei dieser Vorschubgeschwindigkeit der Mutterlänge entspricht, mit markanten AE-Amplituden auftaucht.

Die domänenbasierte (die Kinematik des KGT betreffende) Parametrierung der Datenverarbeitung (hier die Segmentierung) trägt daher zu einer verbesserten Identifizierung und im weiteren Sinne zur Lokalisierung von Defekten im überwachten System bei. Voraussetzung für die Verwendung dieses Ansatzes im Kontext von KGT ist die Verfügbarkeit der Drehzahl- oder Positionsinformationen der Achse. Um die systeminhärenten Defektfrequenzen zu bestimmen, wird zumeist die Spindelfrequenz f_s benötigt. Diese Informationen lassen sich meistens in modernen Werkzeugmaschinen oder Anwendungen mit Vorschubachse abfragen und können zudem in die AE-Auswertung einfließen.

8.5 Übertragbarkeit der Anomalieerkennung auf andere Problemstellungen

Um den flexiblen Einsatz und die Anpassungsfähigkeit der CM-System Architektur(en) nachzuweisen, werden im Folgenden zwei weitere Anwendungen betrachtet.

Zum einen wird mit Axiallagern eine weitere Komponente betrachtet, die ebenfalls mit AE-Sensoren überwacht wurde. Zum anderen werden Versuchsdaten aus einem KGT-Lebensdauerversuch herangezogen, der mit Temperatur- und Motorstromwerten überwacht wurde. Die Ergebnisse dieser Untersuchungen wurden im Zusammenhang der Ausarbeitungen von (Hillenbrand et al. 2021) und (Hillenbrand & Fleischer 2021) bereits präsentiert und dienen hier wiederum als Nachweis für die flexible Anwendung der CM-Systemarchitektur.

Die beiden Datensets stehen unter (Hillenbrand 2020b) und (Hillenbrand 2020a) zur Weiterverwendung bereit.

8.5.1 Übertragbarkeit des CM-Systems am Beispiel Axiallager

Die Versuchsreihe zur Überwachung von Axiallagern entstand im Rahmen des DFG-Projekts (DFG 2017) und ist bereits in Abschnitt 6.2 vorgestellt worden. Zur Veranschaulichung der Übertragbarkeit sollen die Daten hier erneut mit der Architekturvariante 1 mit vordefinierten Merkmalen untersucht werden. Als Merkmale werden hierzu der RMS- und Peak-Faktor verwendet. Diese wurden aus während des Betriebs aufgezeichneten AE-Rohsignalen errechnet (siehe Abschnitt 5.1 für den Prüfstands Aufbau). Als Szenario wird der Wechsel zwischen unterschiedlichen Geschwindigkeitsstufen verwendet. Der Test beginnt mit einer Drehzahl von 150 U/min, die stufenförmig bis 500 U/min gesteigert wird, um dann wieder zur geringsten Drehzahl zurückzukehren und den Vorgang zu wiederholen. Insgesamt liegen fünf Drehzahlstufen vor und damit fünf zu detektierende Zustände. Darüber hinaus findet die Rückkehr in bereits vorhandene Zustände statt, die über das Zustandsdiagramm visualisiert werden sollen.

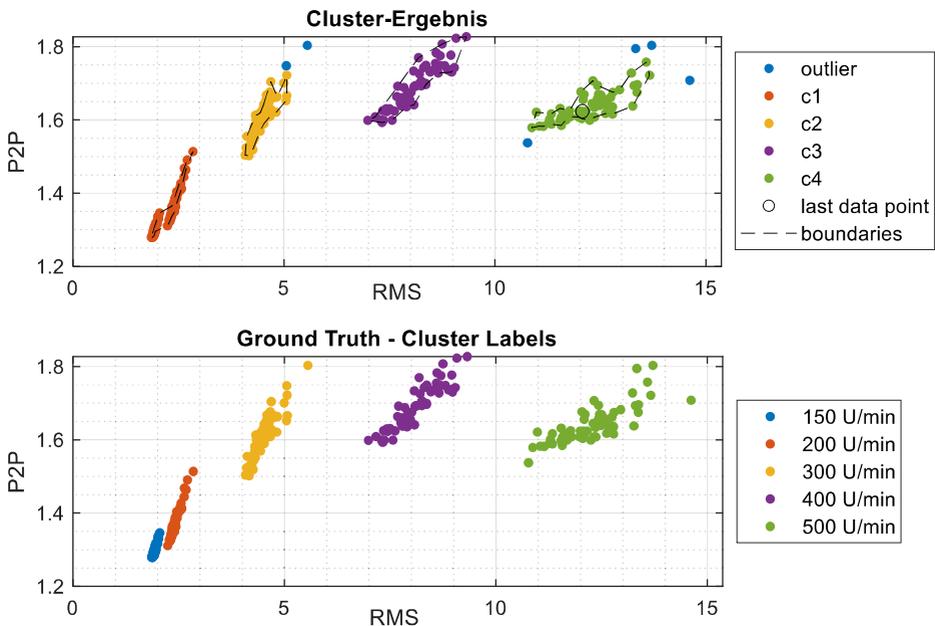


Abbildung 8-36: Clusterergebnis für den Datensatz Axiallager

In Abbildung 8-36 wird das Ergebnis des CM-Systems für die Überwachung des Axial-lagers durch die unterschiedlichen Drehzahlstufen dargestellt. Die vorliegenden Drehzahlen werden bis auf die kleinste Drehzahl von 150 U/min durch den Clusteralgorithmus richtig aufgelöst. Drehzahl 150 U/min und Drehzahl 200 U/min werden aufgrund der räumlichen Nähe im Merkmalsraum zusammen geclustert. Eine Zustand-Detektionsgüte von 87,84 % wird erreicht.

Das wiederholte Auftreten und Durchlaufen der Geschwindigkeitszustände kann in Abbildung 8-37 unten nachvollzogen werden. Das Zustandsdiagramm zeigt per Pfeil den Zyklus an, den das System kontinuierlich durchläuft: von Drehzahl 150 U/min bis 500 U/min in drei Wiederholungen.

Das System erkennt bereits im ersten Durchlauf alle Systemzustände (bis auf Drehzahl 150 U/min), siehe Markierung T1 in Abbildung 8-37. Teilweise werden kurzzeitig zu viele Cluster erkannt, die dann allerdings wieder mit einer *Merge* Transition auf ein Cluster reduziert werden. Im markierten Bereich T1 entstehen sechs *Create* Transitionen und zwei *Merge* Transitionen, d. h. letztlich vier detektierte Zustände. Im weiteren Verlauf der sich wiederholenden Drehzahlen sind in T2 und T3 *Size* Transitionen und *Location* Transitionen zu beobachten. Dies ist ein Zeichen für die Streuung der AE-Messung trotz gleichbleibender Randbedingung innerhalb einer Drehzahlstufe.

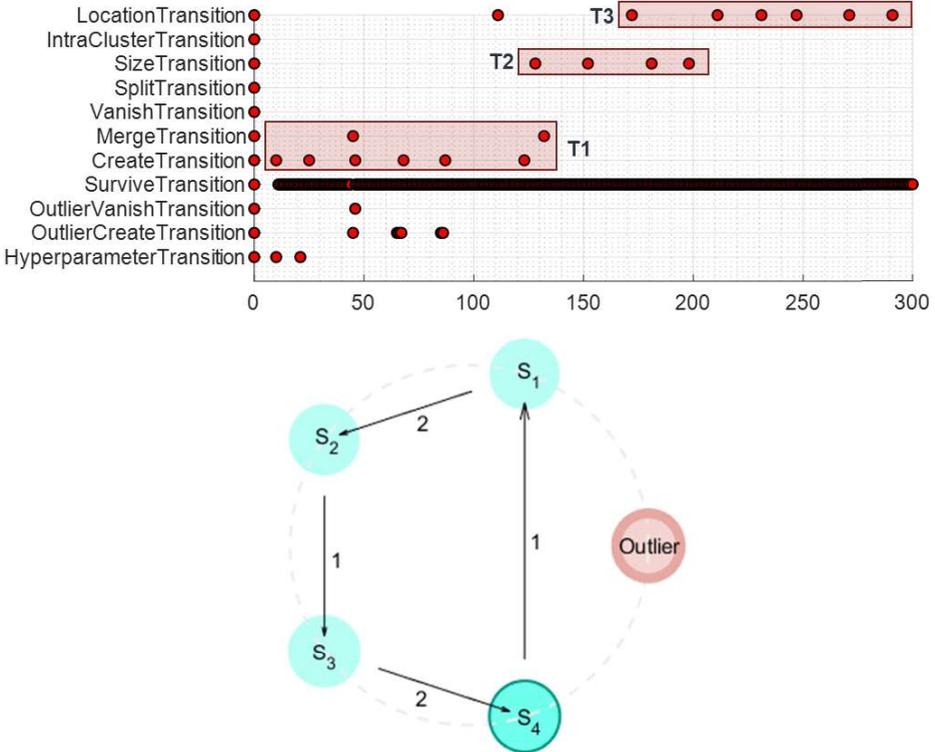


Abbildung 8-37: Transitions- und Zustandsdiagramm für den Datensatz Axiallager

Für die Betrachtung der zeitlichen Entwicklung des Clusterergebnisses dient das Video unter:

https://jhillenbrand.github.io/CMSystem/videos/other_scenarios.html#FEATURE_1AchserBearing_Speeds.

Die Applikation des CM-Systems für den Axiallager-Datensatz bestätigt den allgemeingültigen Ansatz und ist ein gutes Beispiel für die Fähigkeit der Architektur, wiederkehrende Zustände zu erkennen und auch als diese zu markieren.

8.5.2 Übertragbarkeit des CM-Systems am Beispiel Motorstrom und Temperatur

Das zweite Datenset besteht aus Messungen, die am 5-Achs-Prüfstand (siehe Abschnitt 5) durchgeführt wurden. Es handelt sich um einen Lebensdauerversuch, für den zwei KGT (siehe Anhang A 3) gegeneinander verspannt und mit verschiedenen Lastkollektiven bis zur Ermüdung beansprucht wurden. Das Schadensbild, das dabei zum Ende des Versuches auftrat, war der Bruch eines Laufbahnabschnitts in einer der Muttern.

Die Messdaten setzen sich zusammen aus Positions-, Drehzahl-, Motorstrom-, Axialkraft- und Temperaturwerten. Die Versuchszeit belief sich auf 28 Tage. Für diesen Versuchszeitraum wurden Temperatur- und Motorstrommaximalwerte aufgezeichnet. Diese Werte werden dem CM-System in Variante 1 (vordefinierte Merkmale) übergeben. Das Datenset durchläuft fünf Zustände, davon sind drei auf unterschiedliche Laststufen zurückzuführen. Nach Einwirkung dieser Laststufen kommt es während des Versuch zum Bruch der Mutterlaufbahn in einer der verspannten Muttern. Daraufhin wechselt das System in seinen letzten Zustand, mit geringer Last bzw. geringem Motorstrom. Das CM-System detektiert diese fünf Zustände mit nahezu vollständiger Detektionsgüte von 96,43 % (siehe Abbildung 8-38). Ungenauigkeiten der Detektion kommen von falschen Zuordnungen im Übergangsbereich von Laufbahnbruch und System nach Bruch. Hier lässt jedoch auch der Merkmalsbereich keine bessere Trennung der Zustände zu.

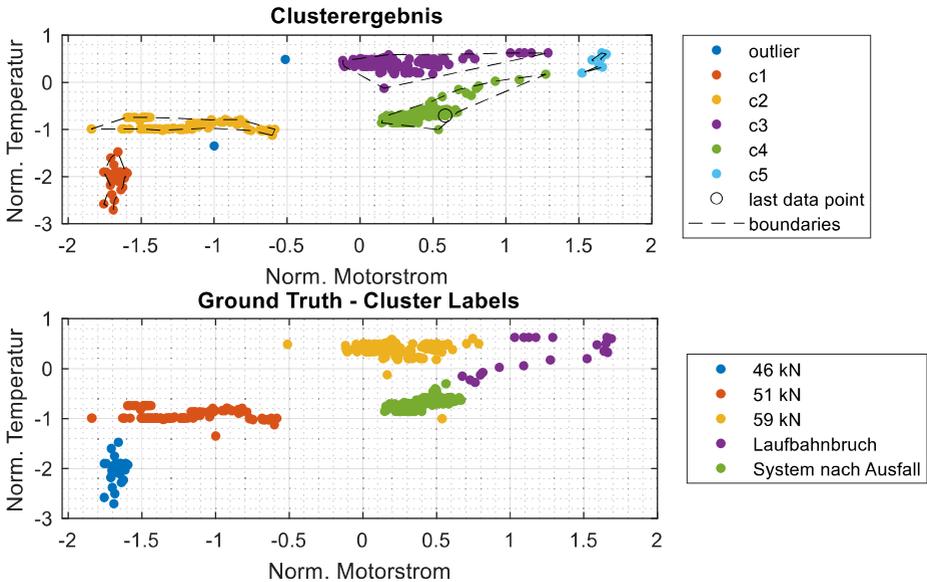


Abbildung 8-38: Clusterergebnis für den Datensatz Laufbahnbruch am 5-Achser-KGT

Die zeitliche Entstehung der unterschiedlichen Zustände kann im Transitionsplot in der Abbildung 8-39 oben nachvollzogen werden. Die Markierung T1 gibt alle auftretenden Clusterentstehungen wieder, wobei die Laststufen im Versuch für unterschiedliche Zeiträume gehalten wurden. Entsprechend unterliegen die verschiedenen Cluster größeren Schwankungen, die durch Markierung T2 für die entstandenen *Location* Transitionen festgehalten werden. Die Tatsache kann auf die Versuchsdurchführung zurückgeführt werden, bei der immer wieder auch Stillstandszeiten (durch Wartungsarbeiten am Prüfstand) während der Messungen auftraten. Für die Betrachtung der zeitlichen Entwicklung des Clusterergebnis dient das Video unter: https://jhillenbrand.github.io/CMSsystem/videos/other_scenarios.html#FEATURE_5Achser_CurrentTemp. Die Applikation mit diesem Datensatz dient als Beispiel für den generellen Einsatz des Ansatzes unabhängig von Sensortypen und -daten (in diesem Fall Temperatur und Motorstrom anstatt AE). Allgemein kann damit eine gute Übertragbarkeit der Vorgehensweise für andere Systeme gewährleistet werden. Dies wird erreicht durch den hohen Anteil an automatischer Konfiguration. Denn es gibt neben der Segmentierung (Abschnitt 8.4) kein Element des CM-Systems, das auf das zu überwachende System maßgeschneidert werden muss.

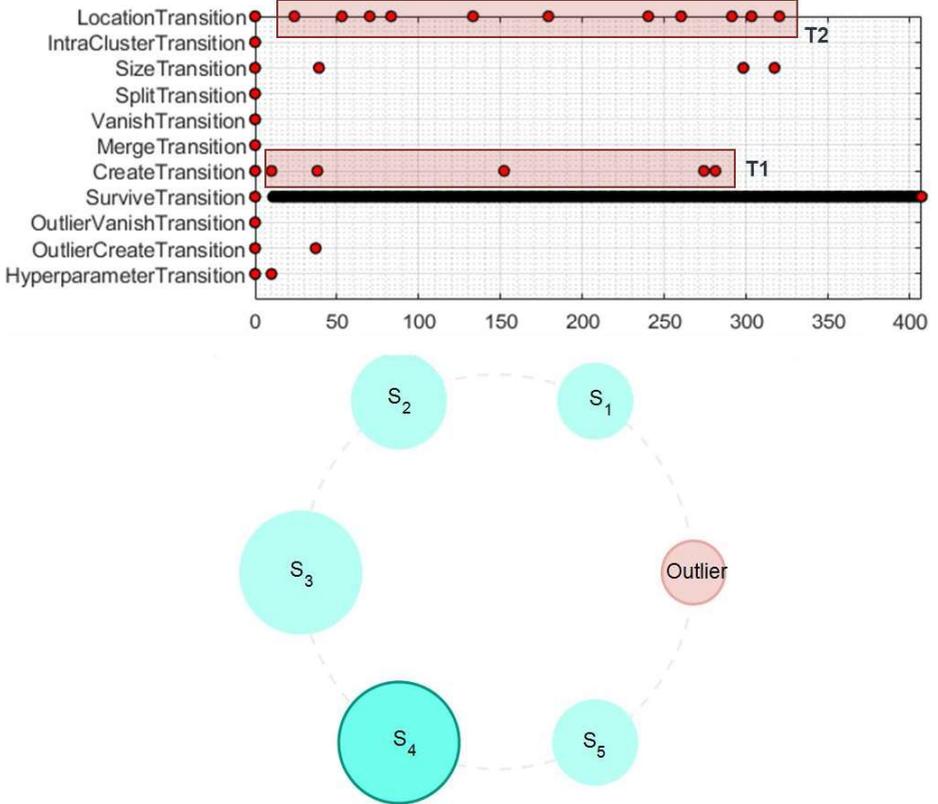


Abbildung 8-39: Transitions- und Zustandsdiagramm für den Datensatz Laufbahnbruch am 5-Achser-KGT

9 Bewertung

In den folgenden Abschnitten werden die erarbeiteten Inhalte dieser Arbeit bewertet. Dabei wird unterteilt in die Betrachtung von AE als Rohdatenquelle zur Überwachung von Wälzkontakten (im Besonderen für KGT), die Beurteilung des in dieser Arbeit eingeführten CM-Systems mit Unsupervised Strategie und schließlich die Beantwortung der Forschungsfragen, die in Kapitel 3 vorgestellt wurden.

9.1 Bewertung von Acoustic Emission zur Diagnose von Wälzkontakten

In den Experimenten (vgl. Kapitel 6 sowie die Abschnitte 8.2 und 8.3) konnte gezeigt werden, dass AE zur sensorischen Erfassung vieler Verschleißkriterien von Wälzkontakten geeignet ist. Sowohl bei Versuchen im Labormaßstab (Abschnitt 6.1) als auch an Axiallagern (Abschnitt 6.2) und an KGT (Abschnitt 8.2) konnte eine Vielzahl von Verschleiß-, Ermüdungs- und Verunreinigungsdefekten untersucht werden. In Tabelle 9-1 wird die Eignung von AE zur Überwachung von verschiedenen Betriebs- und Schadensszenarien zusammengefasst. Die Übersicht bezieht sich auf die Ergebnisse aus den Vorversuchen und die Validierungsergebnisse, die in Tabelle 8-5 aufgeführt sind. Dabei bezeichnet die Angabe -, wenn mit der AE-Sensorik ein Szenario nicht oder nur ansatzweise detektiert wird. Das Symbol **o** zeigt an, dass das Szenario bzw. Systemzustände während des Szenarios teilweise erkannt werden, aber keine vollständige Übereinstimmung vorliegt.

Tabelle 9-1: Übersicht der AE-Eignung für verschiedene Szenarien

Szenario	AE-Eignung (+ o -)
Verschiedene Drehzahlen	+
Verschiedene Lasten bei konstanter Drehzahl	o
Mangelschmierung	o
Partikeleinbringung, Verunreinigung	+
Vorspannungsstufen bei konstanter Drehzahl	+
Vorspannungsstufen bei verschiedenen Drehzahlen	o
Ermüdungsversuch mit erhöhter Last	o
Künstliche Pittings (Axiallager)	-

Hingegen markiert + eine besonders gute Eignung von AE für das jeweils markierte Szenario und eine (nahezu) vollständige Erkennung der Systemzustände.

Besonders gute Detektionsergebnisse werden erreicht im Bereich der Erkennung von unterschiedlichen Drehzahlstufen, bei der Detektion der Partikeleinbringung und dem Erkennen von Vorspannungsstufen bei gleichen sonstigen Randbedingungen.

In den Ermüdungslebensdauerversuchen konnte hingegen kein Merkmal festgestellt werden, das direkt mit der Versuchsdauer bzw. Lebensdauer korreliert. Es wurde lediglich eine Merkmalsdrift festgestellt, die per Schwellwertüberschreitung im Betrieb einen Alarm auslösen könnte. Auch bei vorherigen Versuchen am Axiallager war die Detektion von künstlichen Pittings äußerst fehlerbehaftet.

Schwierigkeiten weist die Überwachung mit AE beim gemeinsamen Auftreten von mehreren Defekten bzw. unter Variation von Betriebsrandbedingungen auf (siehe Szenario Vorspannungsstufen bei verschiedenen Drehzahlen oder verschiedenen Laststufen). Die direkte Schadensklassifikation bei gleichzeitigem Auftreten mehrerer Schadensphänomene gestaltet sich daher schwierig. Diese Problematik hat mehrere Ursprünge: Zunächst handelt es sich bei AE-Signalen um eindimensionale Vibrationssignale. Somit ist grundsätzlich erstmal nur die Schwingungsinformation am Ort der Sensoranbringung (und in dessen Einflusszone) vorhanden. Bedingt durch das Messprinzip, handelt es sich bei AE-Sensoren meist um stark rauschbehaftete Sensoren, die außerdem durch die Umgebungsbedingungen beeinflusst werden (u. a. Temperatur und EMV).

Ein praktischer Einsatz für die konkrete Zuordnung von Verschleißmechanismen, die in den Vorarbeiten (DFG 2017; A_Detroy 2020; A_Schaible 2021) untersucht wurden, kann daher nicht ohne Weiteres realisiert werden. Die Ansätze basierten auf überwachten (supervised) Lernverfahren, die jedoch immer einen hohen Datenvorbereitungs- und Offline-Trainingsaufwand erfordern. Im Rahmen dieser Arbeit wurde auf die Untersuchung einer Supervised Alternative verzichtet, da die Eingrenzung der Zielstellung und Problemformulierung der Arbeit Supervised Ansätze prinzipbedingt als Lösung ausschließt.

Auf Basis dieser Erkenntnis sind in dieser Arbeit Unsupervised Architekturen untersucht worden. Diese stellen ohne existierende gelabelte Trainingsdaten bzw. Referenzversuche und damit ohne einen hohen Modellierungs- und Experimentieraufwand

Anomaliedetektions- und Zustandserkennungsfunktionen bei verschiedenen Schadensbildern und Betriebsszenarien zur Verfügung.

9.2 Bewertung der Unsupervised Strategie

Tabelle 9-12 zeigt den Erfüllungsgrad der Anforderungen aus Abschnitt 4.3 für die Auswertungs- und Überwachungslösung. Verglichen werden die beiden vorgestellten und in den Validierungsexperimenten gegenübergestellten Architekturvarianten. Mit + wird die vollständige Erfüllung, mit o eine teilweise Erfüllung und mit - ein nicht erfülltes Kriterium dokumentiert.

Beide Architekturvarianten erfüllen die Anforderungen für Messgröße, Dimensionalität, Ausreißerdetektion und Hyperparameter. Eine generelle Einschränkung für beide Varianten muss in puncto Sensorplatzierung und hinsichtlich der Unabhängigkeit gegenüber der Auswahl des Sensorelementes vorgenommen werden. In den Abschnitten 5.5 und 6 konnte gezeigt werden, dass es beschränkende Faktoren bei der Applikation der Sensorik gibt. Diese müssen grundsätzlich eingehalten werden, damit ein repräsentatives Signal am Sensorausgang entsteht, das in ein CM-System gespeist werden kann.

Ein Defizit im Bereich Modellausgabe, das bei der Variante 2 mit Autoencodern festgestellt wurde, ist die Overfitting-Problematik bei der Modellerstellung. In einigen Szenarien hat der Autoencoder die Daten des Grundzustands so gut erlernt, dass alle weiteren Daten aus anderen Zuständen für ihn Anomalien darstellten, da sehr große MSE-Rekonstruktionsfehler entstanden. Damit ist die Anforderung nach mehr als einer Ausgabeklasse bzw. den entsprechenden Zuständen verletzt. Die Architektur mit AEN weist daher eine bessere Eignung in Szenarios mit wenigen stationären Zuständen auf, die auf Anomalien überwacht werden sollen.

Abstriche hinsichtlich des Automatisierungsgrades müssen hingegen bei Variante 1 mit a priori definierten Merkmalen hingenommen werden. Die Auswahl dieser Merkmale muss im Vorfeld der Anwendung getroffen werden. Daher ist eine Offlinephase mit Merkmalsauswahl und -verifikation erforderlich. Die Auswahl von Merkmalen für die Merkmalsextraktion ist eine Aufgabe, die stark von der Anwendung und der vorliegenden Problemstellung abhängt. Damit ist diese Aufgabe nicht ohne Weiteres von Laien zu bewältigen. Der Stand der Technik bietet jedoch eine Vielzahl von Merkmalen, die sich in Bereichen wie Schwingungsanalyse und CM bewährt haben (Anhang A 14). Sind Merkmale bekannt, die für den betrachteten Problemfall geeignet sind, so kann das System aufgrund geringerer Komplexität schnell aufgebaut werden.

Ein CM-System auf Basis von Variante 2 konfiguriert sich hingegen vollkommen selbstständig entlang der gesamten Signalverarbeitung. Damit hat diese Variante den größten Automationsgrad. Der Aufbau der Architektur ist aufgrund der verwendeten Bausteine (wie Autoencoder) komplexer als Variante 1, die Nutzer müssen jedoch selbst keine Eingabe bei der Verwendung des Systems vornehmen.

Tabelle 9-2: Bewertung der Architekturvarianten gemäß Anforderungsanalyse

Kriterium	Beschreibung	Variante 1: vordefinierte Merkmale	Variante 2: MSE-Merk- malsextraktion
Messgröße	- nur ein Rohdatensignal (AE) - keine Kontextinformation	+	+
Modellausgabe	- Erkennen von Betriebszuständen und Anomalien (wiederkehrende Ereignisse vs. Ausreißer) - mehr als eine Output-Klasse (normal vs. Anomalie) möglich	+	o
Dimensionalität	- hohe Kompressionsrate nötig aufgrund großer Datenmenge und langer Überwachungszeiträume	+	+
Adaptivität/ Flexibilität	- Funktion ist unabhängig von Sensorplatzierung und Baugröße/Bauform des KGT zu gewährleisten	o	o
Rauschen/ Ausreißer	- Signalverarbeitung muss mit verrauschten AE-Daten umgehen können. Ausreißer müssen vom Algorithmus erkannt werden.	+	+
Hyperparameter	- geringe Anzahl an Hyperparametern	+	+
Automatisierungsgrad	- automatisierte Konfiguration mit Hilfe von Daten und/oder Domänenwissen	-	+
Online-Fähigkeit	- Training und Prädiktion sollen während des Betriebs stattfinden.	o	+

Werden die Inbetriebnahme und der Entwicklungsprozess von CM-Systemen betrachtet, so ermöglicht das vorgeschlagene System einen deutlich verringerten Aufwand gegenüber herkömmlichen Ansätzen. Nach dem Stand der Technik wird in der (DIN ISO 17359) ein allgemeines Vorgehen zur Implementierung von Zustandsüberwachungsprojekten dargestellt. Dort werden zwei Phasen beschrieben: die Auswahl der Überwachungsmethode sowie die Datenaufnahme und -analyse. Diese Phasen stehen auch wesentlich im Fokus dieser Arbeit. Speziell die Phase der Datenaufnahme kann weiter untergliedert werden (siehe Abbildung 9-1). Mit der Einführung des Unsupervised CM-Systems dieser Arbeit kann eine Vielzahl von Schritten, die in herkömmlichen CM-Systemen benötigt werden, vollständig durch Automatismen ersetzt oder deutlich im Aufwand reduziert werden. In Abbildung 9-1 werden wegfallende Schritte weiß und Schritte mit erheblich geringerem Aufwand grau markiert, während blau markierte Prozessschritte erhalten bleiben.

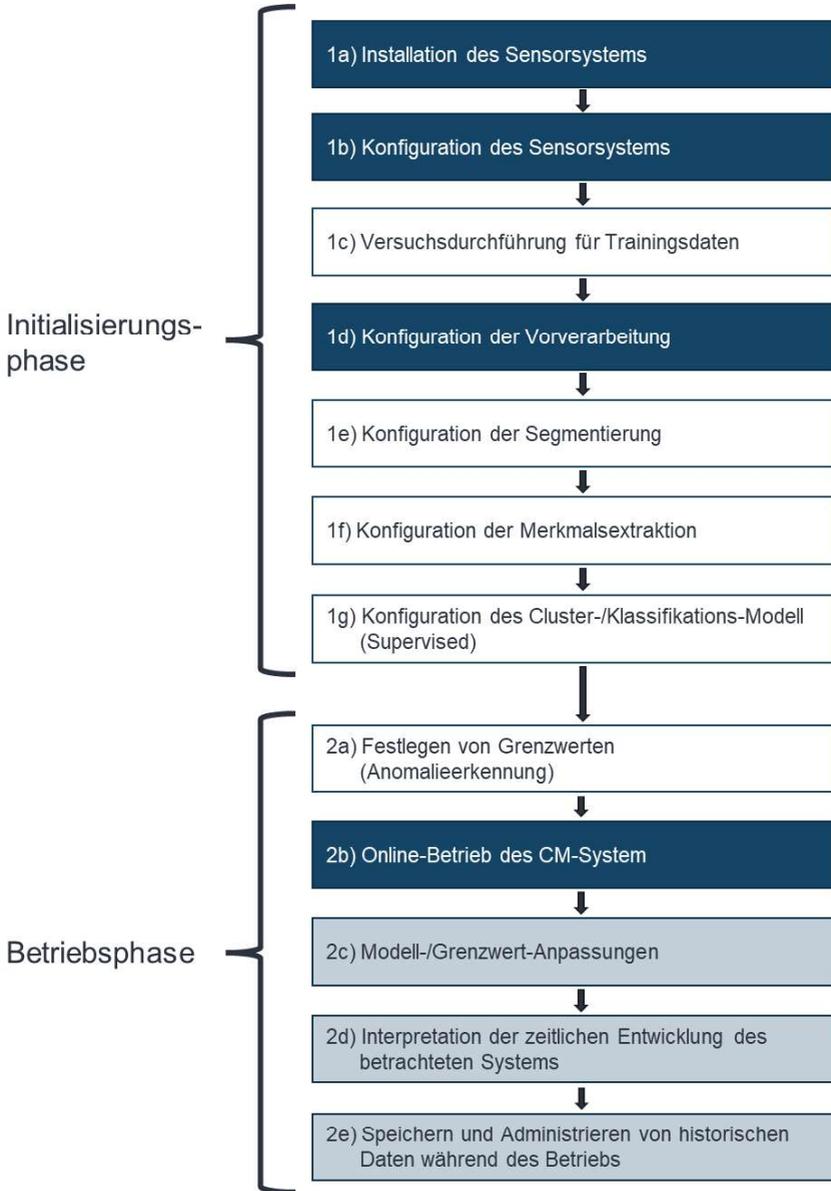


Abbildung 9-1: Workflow zur Inbetriebnahme eines CM-Systems

Mit dem vorgestellten Aufbau des CM-Systems können daher Aufwände während der Initialisierung und des Betriebs beträchtlich gesenkt werden. Dadurch entsteht ein deutlich anwendungsfreundlicheres System, das durch eine automatisierte Konfiguration und Parametrierung den Einsatz in den verschiedensten Szenarien ermöglicht. Das Wegfallen von zeitaufwendigen Trainings und der Offlinephase ermöglicht den unmittelbaren Einsatz in neuen Anwendungen und Applikationen.

Das zugrunde liegende Softwarekonzept ist offen und erweiterbar gestaltet, sodass jederzeit Bausteine angepasst und ausgetauscht werden können. Die Teilsysteme sind so konzipiert, dass Parametrierung und Konfiguration des CM-Systems weitgehend automatisiert gesteuert werden. Dem Nutzer wird somit eine einfache Handhabung der Software ermöglicht und es wird eine schnelle Inbetriebnahme sichergestellt.

9.2.1 Bewertung der Autoencoder für Anomalie- und Zustandserkennung

Die allgemeine Funktion der automatisierten Merkmalsextraktion mit Hilfe von Autoencodern konnte in den Vorversuchen, Validierungsexperimenten und Transferszenarien bestätigt werden. Durch den Aufbau und die Wirkungsweise dieser neuronalen Netze kann die klassische Merkmalsextraktion im Bereich CM ersetzt und deutlich im Aufwand reduziert werden. Wird die Methode mit der klassischen Merkmalsextraktion verglichen, ergeben sich folgende Vor- und Nachteile:

Vorteile:

- + Es ist kein Vorwissen oder Domänenwissen zur Auswahl relevanter Merkmale notwendig.
- + Es ist keine Offlinephase zur Auswahl von relevanten Merkmalen notwendig.
- + Der MSE-Rekonstruktionsfehler hat eine geringe Dimension (1D) und damit eine hohe Kompressionsrate. Dies bietet Vorteile bei langen Überwachungszeiträumen.

Nachteile:

- Es besteht eine Anfälligkeit für Overfitting (allgemeines Problem von Neuronalen Netzen).
- Im Neuronalen Netz und damit Blackbox-Modell geht die Erklärbarkeit verloren. Merkmale sind nicht mit herkömmlichen Merkmalsdefinitionen vergleichbar.
- Die geringe Dimensionalität (1D) des MSE-Merkmals kann die Separierbarkeit im Merkmalsraum erschweren.

Aufgrund der Vor- und Nachteile ist ein abgewogener Einsatz der Autoencoder notwendig. In Applikationen, wo kein Vorwissen vorhanden ist und nur wenige bis gar keine Versuchsdaten existieren, ist der Einsatz mit geringem Aufwand verbunden und sinnvoll. Wenn bereits Wissen vorhanden ist und es bereits etablierte Merkmale gibt, so sollten diese auch verwendet werden. Der Einsatz von Autoencodern fokussiert sich daher auf neu zu erschließende Applikationen, Systeme in Vorserie und im Prototypenstadium oder Retrofitlösungen, die bisher noch nicht überwacht werden.

Nachteile bzw. Defizite, wie das genannte Overfitting, können mit Hilfe von entsprechenden Maßnahmen bei der Modellentwicklung, wie der Regularisierung (Buhmann et al. 2010), kompensiert werden. Aufgrund der Art und Weise, wie die Autoencoder im Kontext dieser Arbeit trainiert werden, ist eine bessere Erklärbarkeit der entstehenden Merkmale im Hidden-Layer des AEN möglich. Mittels strikter Vorgabe der Anzahl an versteckten Neuronen durch Ermittlung der Hauptfrequenzen in den Trainingsdaten bei Initialisierung des Netzes ergibt sich im Umkehrschluss auch die Interpretation als solche im entstehenden AEN-Modell.

9.2.2 Bewertung des Cluster-Boundary-Trackings

Mit dem Ansatz des *Cluster-Boundary-Trackings*, das in dieser Arbeit entwickelt wird, steht ein neuer Condition-Monitoring-Ansatz zur Verfügung, der den Einsatz in Applikationen mit unvollständigem oder nicht vorhandenem Vorwissen ermöglicht. Die Kombination von Clusterverfahren und Cluster-Tracking lässt die Beschreibung punktueller Zustände und der zeitlichen Entwicklung von Systemen auf Basis der übergebenen Sensordaten zu. Speziell für den Bereich CM wird ein Clustermodell vorgeschlagen, das eine speichereffiziente Vorhaltung von historischen Ereignissen erlaubt und somit Langzeitüberwachungen ohne Datenverlust zulässt. Dafür ist eine Speicherung der entstehenden Rohdaten nicht mehr notwendig.

Die Nachverfolgung der Clustertransitionen und deren Beschreibung als Zustände ermöglicht, Aussagen über den Systemzustand zu treffen, die zuvor nur Modellen mit tatsächlichen Klassenzuordnungen, im Sinne von Supervised Learning, möglich waren. Zu erwartende Systemzustände, -anomalien und -defekte müssen daher nicht im Vorfeld bekannt sein, sondern können während des Betriebs abgeleitet (erlernt) werden.

Mit der Wahl von DBSCAN als zugrunde gelegtem Algorithmus steht ein robustes Clusterverfahren zur Verfügung, das sowohl komplexe Clusterformen als auch die Detektion

von Ausreißern abdeckt. Der flexible Aufbau der Teilsysteme erlaubt zudem den einfachen Austausch von Modulen innerhalb der Datenverarbeitung.

Clusterverfahren und Cluster-Tracking erhöhen dadurch zusammen die Aussagequalität gegenüber herkömmlichen Cluster- bzw. Unsupervised-Ansätzen und tragen zu den erreichten Detektionsgütern (Zustand und Anomalie) in Tabelle 8-5 bei. Außerdem wird durch entsprechende Validierungsdatensätze die allgemeine Übertragbarkeit auf unterschiedliche Arten von Sensordaten gezeigt. Der Ansatz ist daher nicht auf die Auswertung und Überwachung mittels AE begrenzt.

Bedingt durch den Aufbau und die Funktionsweise des Ansatzes, liegen noch folgende Defizite vor:

- Der Einsatz von DBSCAN ist mit dem Nachteil behaftet, dass Cluster mit stark unterschiedlicher Dichte nur schwer erkannt werden. Diese Cluster mit variabler Dichteverteilung liegen teilweise auch in den Datensätzen der AE-Untersuchungen vor. Somit werden hier Cluster weniger erfolgreich zugeordnet. Durch Wahl eines anderen Clusteralgorithmus entsprechend dem Stand der Technik kann dieses Defizit umgangen werden.
- Aussagen gemäß Tabelle 7-2 über Transitionen und ihre CM-Perspektiven bleiben zunächst eine hypothetische Annahme über das System. Der Anspruch auf Generalität ist hier stärker gewichtet als die konkrete Aussage über ein bestimmtes System oder eine bestimmte Maschinenkomponente. Prinzipbedingt bleibt die Aussage über den Systemzustand mit einer Unschärfe behaftet, da keine Labels zur Zuordnung zur Verfügung stehen (Unsupervised).
- Die aktuelle Software erlaubt keine Interaktion mit dem Nutzer, damit dieser die automatisierten Systemaussagen und die Zustandsdetektion mit eigenem Wissen anreichert. Eine Erweiterung im Sinne von Semi-Supervised Learning könnte hier die Aussagequalität weiter steigern.
- Die aktuelle Implementierung sieht nur Merkmalsvektoren bis zur dritten Dimension vor. Für die Verwendung in mehrdimensionalen Räumen muss die Definition der *Clusterboundary* für den Merkmalsraum R^n erweitert werden.

9.3 Beantwortung der Forschungsfragen

Zu Beginn der Arbeit sind vier Forschungsfragen (siehe Kapitel 3) formuliert worden. In diesem Abschnitt soll deren Beantwortung auf Basis der erreichten Ergebnisse und der Bewertung vorgenommen werden.

- I. Ist Acoustic Emission zur Überwachung der Verschleißursachen und zugehörigen Schadensbilder des Kugelgewindetriebs geeignet?

AE-Messungen können erfolgreich zur Detektion von Schadensbildern und Verschleiß am KGT eingesetzt werden. In dieser Arbeit sind Abrasiv- und Ermüdungverschleiß als klassische Verschleißmechanismen betrachtet worden. Weiterhin sind Ursachen wie Mangelschmierung und Verunreinigung untersucht worden. Die vollständige und robuste Detektion dieser Defekte ist in singulären Versuchen durch AE erfolgt. Treten Defekte gleichzeitig auf oder werden von sich ändernden Betriebsbedingungen überlagert, so wird die Erfassung erschwert und ist nur noch teilweise möglich. Die tatsächliche Schadenszuordnung ist daher sehr komplex und der Nutzen von AE überwiegend in der reinen Anomalieerkennung zu finden.

- II. Welche Methoden und Ansätze können für die Umsetzung eines unüberwachten Condition-Monitoring-Systems auf Basis von AE-Daten ohne vorheriges Training verwendet werden?

Mit der Forderung nach einem CM-System, das ohne Trainingsdaten mit Labels bzw. ohne Vorwissen über das zu überwachende System agieren soll, begrenzt sich die Wahl von Algorithmen und Methoden auf den Bereich der Mustererkennung (auch Unsupervised Learning). Hauptvertreter dieser Gruppe sind Clusterverfahren zur Gruppierung von nicht gelabelten Datensätzen. Darüber hinaus werden Autoencoder als besondere Art von neuronalen Netzen betrachtet und zur automatischen Merkmalsextraktion für das Clusterverfahren genutzt. Es ergibt sich ein zweistufiges Vorgehen, bestehend aus automatischer Merkmalsextraktion und nachgeschaltetem Clustering dieser Merkmale bzw. dieses Merkmals (im Fall des MSE-Rekonstruktionsfehlers). Die Auswahl der Verfahren fand mittels Literaturrecherche und Erprobung an Benchmark-Datensätzen statt.

- III. Wie kann eine Modellarchitektur für die Überwachung des Betriebszustands sowie die zeitliche Entwicklung von Zustandsänderungen aussehen?

Zur Abbildung der zeitlichen Entwicklung von Clusterzuständen und einer effizienten Speicherung des Systemzustands wird das Clusterverfahren um zwei wesentliche Aspekte erweitert. Unter dem Namen *Cluster-Boundary-Tracking* wird eine neue Vorgehensweise zur zeitlichen und räumlichen Beobachtung von Clusterzuständen und deren Übergängen (Transitionen) entworfen. Kern des

neuen Clustermodells ist die Zusammenfassung eines Clusters im Merkmalsraum über seine Randpunkte. Das Entstehen, Verbinden, Verschwinden und die Vergrößerung oder Verkleinerung dieser Cluster wird mit Hilfe eines verfügbaren Frameworks zur Beschreibung von zeitlichen Clustervorgängen vorgenommen (siehe (Spiliopoulou et al. 2006)). Als Gesamtheit entsteht eine Methode zur ganzheitlichen Beschreibung von räumlichen und zeitlichen Vorgängen für die Cluster. Der Clusterzustand wird dann als Systemzustand interpretiert und ermöglicht Aussagen über das überwachte System. Da in einem CM-System immer ein kontinuierlicher Datenstrom vorliegt, wird die Clustermethode erweitert, um ein kontinuierliches Clustering der eingehenden Datenpunkte zu realisieren.

- IV. Wie kann die Anzahl an Modellparametern in der Datenverarbeitungskette reduziert bzw. durch Domänenwissen oder datengetrieben bestimmt werden?

Ein gefordertes Ziel dieser Arbeit ist die Aufwandsreduktion bei der Erstellung und Konfiguration von CM-Systemen. Hierzu gehört die Reduktion von Hyperparametern in der Modellierung bzw. Parametrierung der Datenverarbeitungskette. In den Hauptteilen der Datenverarbeitungskette, der Merkmalsextraktion und dem Clustering, erfolgt dies durch automatisierte Hyperparameterwahl. Hierzu wird beispielsweise die Autokonfiguration von Autoencodern auf Basis von Hauptfrequenzen in den Sensordaten entwickelt. Im Bereich Clusterverfahren werden die Hyperparameter des DBSCAN-Algorithmus durch einen datengetriebenen Ansatz vorgelegt und müssen nicht mehr vom Nutzer bestimmt werden. Einen weiteren Schritt bei der automatisierten Konfiguration des CM-Systems stellt die Bestimmung der Hyperparameter der Segmentierung mit Hilfe von Domänenwissen dar. Mit den kinematischen Frequenzen des KGT in der Verfahrensbewegung werden Hyperparameter für die Segmentierung bestimmt.

Als wesentliches Ergebnis der Arbeit liegt damit eine neue Unsupervised Architektur vor. Sie erbringt, unabhängig von den Sensordaten und vom Szenario, einen Beitrag zur Überwachung von KGT. Vom Anwender werden weder aufwendig erzeugte Trainingsdaten noch Domänen- bzw. Vorwissen benötigt.

10 Zusammenfassung

Das Ziel der vorliegenden Dissertation ist es, ein aufwandsarmes und möglichst autarkes Condition-Monitoring (CM) für Kugelgewindetriebe (KGT) zu realisieren. Im Kontext der technischen Verfügbarkeit von Maschinen und Anlagen hat dieses Thema besondere Relevanz bei Anwendern und Herstellern von Werkzeugmaschinen. Durch seine vielfältigen und sich überlagernden Ausfallmechanismen und eine komplexe Kinematik stellt der KGT eine der Hauptausfallursachen von Werkzeugmaschinen dar. Ein besonderes Augenmerk muss daher auf den Entwurf, die Installation und den Betrieb von CM-Systemen gelegt werden, verbunden mit möglichst geringen finanziellen wie personellen Aufwendungen.

Mit dem Entwurf und der Entwicklung von CM-Systemen für KGT haben sich bereits zahlreiche Forschungsarbeiten intensiv beschäftigt. Hierbei stehen die frühzeitige Detektion eines Defekts, Verschleißes oder dessen Ursache im Vordergrund der Überwachung. Die Vermeidung von Stillstand hat für den Produktionsbetrieb von Maschinen und Anlagen oberste Priorität. Jedoch hat sich keiner der untersuchten Ansätze oder industriellen Lösungen bislang am Werkzeugmaschinenmarkt etabliert. Fehlende Flexibilität und/oder Robustheit, hohe Anschaffungskosten und die Aufwendungen für die benötigte Datenauswertung können hierfür als Gründe angeführt werden.

In der vorliegenden Dissertation werden daher zwei Aspekte zur Lösung dieser Defizite betrachtet. Zum einen wird Acoustic Emission (AE) als Messsystem zur Überwachung des KGT untersucht. Die enge Verbundenheit der AE-Anregungsmechanismen mit den KGT-Schadensmechanismen birgt großes Potenzial für die Verschleißüberwachung am KGT. Zum anderen wird dieses Messsystem in ein neuartiges CM-System eingebettet, das ohne a-priori-Wissen über das zu überwachende System auskommt. Das Messsystem soll Zustände und Anomalien des Systems erkennen und langfristig überwachen. Der Fokus bei der Gestaltung des CM-Systems liegt dabei auf automatisierter Konfiguration der Datenverarbeitung und Reduktion des Aufwands für den Nutzer.

Die Arbeit beginnt mit der Untersuchung des aktuellen Stands der Technik und Forschung. Dieser unterteilt sich in die Fachbereiche KGT, AE und Unsupervised Learning. Für den KGT werden die kinematischen Grundlagen, Verschleißursachen und existierenden CM-Anwendungen vorgestellt. Darauf folgt die Darstellung der AE-Messtechnik und ihrer Applikationen. Es schließt sich ein Einblick in Unsupervised Learning als

Teilbereich des maschinellen Lernens an. Der Fokus liegt hierbei auf dem Einsatz im Kontext von CM und der Einführung von relevanten Methoden für die vorliegende Arbeit.

Aus dem aktuellen Stand der Technik und Forschung können Defizite in Bezug auf die Untersuchung von AE im Kontext von KGT und aufwandsarmen bzw. automatisierten CM-Systemen identifiziert werden. Essenziell für die Umsetzung eines solchen Systems sind die Qualifizierung von AE für die Ausfallszenarien am KGT, die Reduktion der Modellparameter in der Datenverarbeitung und ein hoher Automatisierungsgrad bei der Erstellung und Konfiguration.

Der im Rahmen der Dissertation erarbeitete Lösungsansatz besteht aus einem Unsupervised CM-System, das mittels AE-Sensordaten Anomalien und Systemzustände der Vorschubachse detektiert. In der praktischen Anwendung soll auf gelabelte Trainingsdaten und Vorwissen über das zu überwachende System verzichtet werden.

Das hierzu benötigte Sensorsystem wird in Vorversuchen und Prototypen verifiziert. Neben der mechanischen Installation und den Anbringungsorten wird auch die Signalqualität in Abhängigkeit der Sensorarten und -größen untersucht. Nach geeigneter Qualifikation eines Sensortyps wird dieser für die weiteren Validierungsversuche genutzt.

Auf Basis der Erkenntnisse aus Vorversuch und Stand der Technik und Forschung wird das unüberwachte CM-System entworfen. Dabei wird die Entwicklung des Gesamtsystems in die Teilbereiche Sensierung, Vorverarbeitung, Segmentierung, Merkmalsextraktion und Clusterbildung unterteilt. Dies entspricht dem klassischen Aufbau von Systemen zur Mustererkennung. Erweitert wird dieser Aufbau um den Baustein Cluster-Tracking. Damit wird gegenüber der herkömmlichen Vorgehensweise auch die zeitliche Beschreibung von Clustern möglich. Die Implementierung des Gesamtsystems zeichnet sich durch einfache Erweiterbarkeit, Austauschbarkeit und Konfiguration der Teilsysteme aus. Für jedes Teilsystem werden Maßnahmen und Methoden vorgestellt, die die Konfiguration des Systems mit möglichst wenig Hyperparametern realisieren. Der Bereich Merkmalsextraktion wird zum Beispiel mit Autoencodern umgesetzt, deren Netzaufbau vollständig automatisiert stattfindet.

Wesentlicher Baustein der Unsupervised-Architektur ist das Cluster-Tracking. Ein neuartiges Clustermodell ermöglicht die speichereffiziente Abbildung von räumlichen und zeitlichen Clusterstrukturen. Im Sinne der CM-Perspektive werden diese Cluster und

deren Entwicklung als Systemzustände interpretiert und es wird damit eine Aussage über den überwachten KGT getroffen.

Im Rahmen der Validierung des entwickelten CM-Systems werden KGT auf unterschiedlichen Prüfständen hinsichtlich verschiedener Szenarien geprüft. Insgesamt werden sechs verschiedene Szenarien betrachtet: Vorspannungsverlust, Partikeleintrag, Mangelschmierung, Ermüdung und verschiedene Last- und Drehzahlzustände. Alle Szenarien werden jeweils mit zwei verschiedenen Unsupervised Architekturen untersucht: eine mit vordefinierten Merkmalen und eine mit Autoencodern zur Merkmalsextraktion. Je nach Architekturvariante und Szenario ergeben sich Detektionsgüten für die jeweiligen Zustände zwischen 65 und 95 Prozent. Anomalien werden nahezu vollständig als solche während der Experimente erkannt. Eine Ausnahme bildet das Szenario Ermüdung, das nicht erfolgreich detektiert werden konnte.

Als zusätzliche Validierung findet außerdem die Übertragung des CM-Systems auf weitere Datensätze mit anderen Sensoren im Kontext der verwendeten KGT-Prüfstände statt. Hier kann der neue Ansatz an Motorstrom- und Temperaturdaten eines Lebensdauerversuchs erprobt werden. Mit einem weiteren Datensatz wird die Übertragbarkeit auf die Axiallagerüberwachung mittels AE untersucht. In beiden Fällen lassen sich ohne manuelle Anpassung des CM-Systems Detektionsgüten von über 87 Prozent erreichen.

Damit wird in der vorliegenden Dissertation ein CM-System zur Verfügung gestellt, das ganz ohne gelabelte Datensätze aufwandsarm und automatisch durch Verwendung von Unsupervised Methoden konfiguriert werden kann. Darüber hinaus wird mit AE eine weitere Messtechnik zur Überwachung von KGT qualifiziert.

Ausblick

In der vorliegenden Dissertation wird als einzige Datenquelle AE-Sensorik verwendet. Die Informationstiefe wird damit auf das Schwingungssignal des AE-Sensors beschränkt. In Folgearbeiten könnte die Fusion von mehreren Datenquellen betrachtet werden. Insbesondere könnte die Kombination mit bereits vorhandenen Antriebsdaten aus der Maschinensteuerung (wie Drehzahl, Positionssignal oder Motorstrom) helfen, einen besseren Auswertekontext für die AE-Daten zur Verfügung zu stellen. In Abschnitt 8.4 wird bereits dargestellt, wie die Nutzung der Spindeldrehzahl als Input in die Segmentierung zur verbesserten Auswertestrategie genutzt werden kann. Generell kann das Hinzufügen von Antriebsdaten dabei helfen, die Überlagerung von Betriebszuständen und Verschleißzuständen besser voneinander zu trennen.

Ebenso können ähnliche Maschinenelemente wie Wälzlager, Zahnräder oder Getriebe betrachtet werden. Diese Komponenten besitzen kinematische Zusammenhänge, die ähnlich wie die KGT-Kinematik für die automatisierte Parametrierung der Datenverarbeitung verwendet werden können.

Mit Blick auf die Merkmalsextraktion und Clusterbildung gibt es ebenfalls weiteres Optimierungspotenzial. Ein Defizit, das bei der Verwendung von DBSCAN festgestellt wurde, ist die mangelnde Sensitivität gegenüber Clustern mit variabler Dichteverteilung. Hier kann die Untersuchung und Implementierung weiterer dichte-sensitiver Clusteralgorithmen weiterhelfen (Ankerst et al. 1999). Eine zusätzliche Chance für die Steigerung der Robustheit sind Fuzzy-Clustering-Ansätze (Gupta, Yadav & Gupta 2020).

Im Hinblick auf die Verbesserung der Merkmalsextraktion können der Autoencoder und Modellvarianten erneut betrachtet werden. Bisher sind beispielsweise keine Long-Short-Term-Memory-Netze untersucht worden. Diese Art der Neuronalen Netze ermöglicht die Darstellung von Langzeitabhängigkeiten in den Daten und die Modellierung der zeitlichen Reihenfolge (Marchi et al. 2015).

Des Weiteren können zur Reduktion des Overfitting-Problems des Autoencoders, das im Bewertungskapitel erwähnt wird, ein iteratives Neutraining bzw. ein nochmaliges Training des Autoencoders angestoßen werden. Alternativ wird, sobald der Autoencoder ein neues Cluster detektiert, das Training eines weiteren Autoencoders angeregt. Ab diesem Zeitpunkt konkurrieren diese und weitere Autoencoder um den geringsten Rekonstruktionsfehler. Neue Datenpunkte gehören dann zu jenem Autoencoder, der sie am besten rekonstruiert. Dadurch wäre auch ein Mechanismus implementiert, der *Concept Drift* (Gama et al. 2004) bei der Prädiktion der Datenpunkte vorbeugt.

Ein zentraler Aspekt dieser Arbeit ist die automatisierte Konfiguration von CM-Systemen. Im Fokus stehen hierbei die Merkmalsextraktion und die Clusterbildung. Darüber hinaus können auch die anderen Teilschritte der Datenverarbeitung weiter automatisiert werden. Zum Beispiel können im Kontext der Sensierung bereits Maßnahmen zur Reduktion des Aufwands für den Nutzer entworfen werden. Eine der ersten Aufgaben beim Entwurf von Sensorsystemen ist die Definition einer geeigneten Abtastrate und Speichertiefe. Oft sind diese Werte softwareseitig einstellbar und können erste Schwierigkeiten bei ungeschulten Anwendern verursachen. Diese Einstellungen immer auf Maximalwerte zu setzen, ist nicht unbedingt notwendig und hinsichtlich der entstehenden Datenmenge auch nicht effizient. Hier kann ein Automatismus ansetzen, der

aufgrund des detektierten Frequenzinhaltes entscheidet, wie groß die Abtastrate sein muss. Diese wird dann künstlich herabgesetzt oder nach Möglichkeit direkt im Sensorsystem eingestellt.

Auf diese Weise können weitere Automatismen und Mechanismen entworfen werden, die entweder auf Basis von Domänenwissen oder datengetrieben den Konfigurationsaufwand innerhalb des CM-Systems reduzieren.

Die finale Ausbaustufe eines solchen CM-Systems ist die Erweiterung durch automatische Generierung der Datenverarbeitungsbausteine. Sie werden in dem Fall nicht nur konfiguriert, sondern über eine Entscheidungslogik tatsächlich im Anwendungsfall erstellt (online). Als Eingabegrößen für ein solches System sind dann nur noch die verfügbaren Datenquellen notwendig (Sensoren) und die Vorgabe, welches CM-Problem gelöst werden soll (Anomaliedetektion, Schwellwertüberwachung, Zustandsüberwachung oder Ähnliches). So kann ganz im Sinne von Abbildung 1-1 eine neue Stufe an Autonomie für CM in Werkzeugmaschinen und zugehörigen Komponenten erreicht werden.

Literaturverzeichnis

Verweise gemäß Schema *A_Nachname* beziehen sich auf studentische Abschlussarbeiten, die vom Verfasser dieser Arbeit betreut wurden.

A_Detroy 2020

Detroy, J. (2020), *Untersuchung von Verschleiß im Wälzkörperkontakt in Maschinenelementen mittels Acoustic Emission und maschinellem Lernen*. Bachelorthesis, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Kistner 2021

Kistner, J. (2021), *Anomalieerkennung in Schwingungsdaten mit Hilfe von Autoencoder Netzwerken*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Meyer-Garcia 2018

Meyer-Garcia, M. (2018), *Machbarkeitsstudie, Auswahl und Evaluation eines Messsystems zur Aufzeichnung von Körperschallschwingungen im Ultraschallbereich*. Bachelorthesis, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Osen 2020

Osen, G. (2020), *Modulares Konzept für Sensorhalterungen an offenen Wälzkörpergetrieben*. Bachelorthesis, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Schaible 2021

Schaible, P. (2021), *Korrelation von Reibmoment- und Steifigkeitsverhalten von Kugelgewindtrieben mit hochfrequenten Körperschallmessungen*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Schwab 2021

Schwab, F. (2021), *Entwurf und Implementierung einer integrierten Reibmoment- und Steifigkeitsmessung für den Kugelgewindtrieb*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Xia 2020

Xia, Y. (2020), *Experimental Investigation of acoustic emission propagation in roll*

and slide contacts. Masterthesis, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Zipperling 2020

Zipperling, D. (2020), *Cluster Validation and Clustering of time-evolving data*. Seminararbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Insitut für Produktionstechnik.

Ahmad et al. 2021

Ahmad, S.; Styp-Rekowski, K.; Nedelkoski, S. & Kao, O. (27. Januar 2021), *Auto-encoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines*. <https://arxiv.org/pdf/2101.11539>.

Ankerst et al. 1999

Ankerst, M.; Breunig, M. M.; Kriegel, H.-P. & Sander, J. (1999), „OPTICS: Ordering Points To Identify the Clustering Structure“, *SIGMOD Rec*, 28(2), S. 49–60. DOI: 10.1145/304181.304187.

Arellano-Espitia et al. 2019

Arellano-Espitia, F.; Saucedo, J. J.; Prieto, M. D. & Osornio-Rios, R. A. (2019), „Autoencoder based feature reduction analysis applied to electromechanical systems condition monitoring“, *24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, Zaragoza, Spain, S. 891–897.

August Steinmeyer GmbH & Co. KG 2017

August Steinmeyer GmbH & Co. KG (2017), *Guard Plus. Zustandsüberwachung von Kugelgewindetrieben*, Albstadt. https://antriebstechnik.steinmeyer.com/fileadmin/media/downloads/de/Guard_Plus_Broschuere_DE.pdf.

August Steinmeyer GmbH & Co. KG 2021

August Steinmeyer GmbH & Co. KG (2021), *Mutternbauformen*, Albstadt. <https://www.steinmeyer.com/de/technik/mutternvorspannung-steifigkeit/mutternbauformen/> [09.01.2021].

Bearing Data Center 2004

Bearing Data Center (2004), Case Western Reserve University. <http://cse-groups.case.edu/bearingdatacenter/home>.

Bengio, Courville & Vincent 2012

Bengio, Y.; Courville, A. & Vincent, P. (2012), *Representation Learning: A Review and New Perspectives*. <http://arxiv.org/pdf/1206.5538v3>.

Benker, Kleinwort & Zah 2019

Benker, M.; Kleinwort, R. & Zah, M. F. (2019), „Estimating remaining useful life of machine tool ball screws via probabilistic classification“, *IEEE International Conference on Prognostics and Health Management*, Hrsg. IEEE, San Francisco, USA, S. 1–7.

Beyer et al. 1999

Beyer, K.; Goldstein, J.; Ramakrishnan, R. & Shaft, U. (1999), „When Is “Nearest Neighbor” Meaningful?“ in *Database Theory - ICDT'99*, Hrsg. G. Goos, J. Hartmanis, J. van Leeuwen, C. Beeri & P. Buneman, Springer, Berlin, Heidelberg, S. 217–235. ISBN: 978-3-540-65452-0.

Beyerer, Richter & Nagel 2018

Beyerer, J.; Richter, M. & Nagel, M. (2018), *Pattern recognition. Introduction, features, classifiers and principles*, De Gruyter, Berlin. ISBN: 9783110537963.

Böge 2017

Böge, A. (2017), *Handbuch Maschinenbau. Grundlagen und Anwendungen der Maschinenbau-Technik*, Springer Vieweg, Wiesbaden. ISBN: 9783658125295.

Bombiński et al. 2016

Bombiński, S.; Błażej, K.; Nejman, M. & Jemielniak, K. (2016), „Sensor Signal Segmentation for Tool Condition Monitoring“, *Procedia CIRP*, 46, S. 155–160. DOI: 10.1016/j.procir.2016.03.203.

Bosch Rexroth AG 2006

Bosch Rexroth AG (2006), *Handbuch Lineartechnik*, Schweinfurt. <https://www.pts-automation.de/wp-content/uploads/2019/08/Handbuch-Lineartechnik.pdf>.

Brecher 2022

Brecher (2022), *Machine Tools Production Systems 3*, Springer, Wiesbaden. ISBN: 9783658346218.

Brecher & Weck 2017

Brecher, C. & Weck, M. (2017), *Werkzeugmaschinen - Fertigungssysteme 2*.

Konstruktion, Berechnung und messtechnische Beurteilung, Springer, Berlin, Heidelberg. ISBN: 9783662465660.

Buhmann et al. 2010

Buhmann, M. D.; Melville, P.; Sindhwani, V.; Quadrianto, N.; Buntine, W. L.; Torgo, L.; Zhang, X.; Stone, P.; Struyf, J.; Blockeel, H.; Driessens, K.; Miikkulainen, R.; Wiewiora, E.; Peters, J.; Tedrake, R.; Roy, N.; Morimoto, J.; Flach, P. A. & Fürnkranz, J. (2010), „Regularization“ in *Encyclopedia of Machine Learning*, Hrsg. C. Sammut, Springer, Boston, MA, USA, S. 845–849. ISBN: 9780387301648.

Carpinteri et al. 2013

Carpinteri, A.; Lacidogna, G.; Invernizzi, S. & Accornero, F. (2013), „The Sacred Mountain of Varallo in Italy: seismic risk assessment by acoustic emission and structural numerical models“, *The Scientific World Journal*. DOI: 10.1155/2013/170291.

Celebi & Aydin 2016

Celebi, M. E. & Aydin, K. (2016), *Unsupervised Learning Algorithms*, Springer, Cham. ISBN: 978-3-319-24211-8.

Chalapathy & Chawla 2019

Chalapathy, R. & Chawla, S. (10. Januar 2019), *Deep Learning for Anomaly Detection: A Survey*. <http://arxiv.org/pdf/1901.03407v2>.

Chandola, Banerjee & Kumar 2009

Chandola, V.; Banerjee, A. & Kumar, V. (2009), „Anomaly detection: A survey“, *ACM Computing Surveys*, 41(3), S. 1–58. DOI: 10.1145/1541880.1541882.

Cioffi et al. 2020

Cioffi, R.; Travagliani, M.; Piscitelli, G.; Petrillo, A. & Felice, F. de (2020), „Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions“, *Sustainability*, 12(2), S. 492. DOI: 10.3390/su12020492.

Claesen & Moor 2015

Claesen, M. & Moor, B. D. (07. Februar 2015), *Hyperparameter Search in Machine Learning*. <http://arxiv.org/pdf/1502.02127v2>.

Clark et al. 2017

Clark, A.; Kaewunruen, S.; Janeliukstis, R. & Papaelias, M. (2017), „Damage

Detection in Railway Prestressed Concrete Sleepers using Acoustic Emission“, *IOP Conference Series: Materials Science and Engineering*, 251, S. 12068. DOI: 10.1088/1757-899X/251/1/012068.

Cohen & Singer 2021

Cohen, Y. & Singer, G. (2021), „A smart process controller framework for Industry 4.0 settings“, *Journal of Intelligent Manufacturing*, 32(7), S. 1975–1995. DOI: 10.1007/s10845-021-01748-5.

Deckers 2001

Deckers, J. (2001), *Entwicklung einer Low-Cost-Körperschallsensorik zur Überwachung des Verschleißverhaltens von wälz- und gleitgelagerten Kreislumpenkleiner Leistung*. Dissertation, VDI-Verlag, Düsseldorf. ISBN: 3183300117.

D'Emilia et al. 2018

D'Emilia, G.; Gaspari, A.; Hohwieler, E.; Laghmouchi, A. & Uhlmann, E. (2018), „Improvement of Defect Detectability in Machine Tools Using Sensor-based Condition Monitoring Applications“, *Procedia CIRP*, 67, S. 325–331. DOI: 10.1016/j.procir.2017.12.221.

Denkena, Bergmann & Schmidt 2021

Denkena, B.; Bergmann, B. & Schmidt, A. (2021), „Preload monitoring of single nut ball screws based on sensor fusion“, *CIRP Journal of Manufacturing Science and Technology*, 33, S. 63–70. DOI: 10.1016/j.cirpj.2021.02.006.

DIN ISO 17359

DIN ISO 17359 (2011), *Zustandsüberwachung und -diagnostik von Maschinen - Allgemeine Anleitungen*, Deutsches Institut für Normung e.V., Beuth Verlag GmbH, Berlin.

DIN ISO 3408-5

DIN ISO 3408-5 (2011), *Kugelgewindetriebe - Teil 5: Statische und dynamische axiale Tragzahl und Lebensdauer*, Deutsches Institut für Normung e.V., Beuth Verlag GmbH, Berlin.

DFG 2017

DFG (2017), *Erweiterung der Lebensdauertheorie durch Korrelation des Verschleißes mit Acoustic Emission (AE) zu den mechanischen Kennwerten des*

Kugelgewindetriebes. Förderprojekt, Deutsche Forschungsgemeinschaft.
<https://gepris.dfg.de/gepris/projekt/388141462>.

Droubi et al. 2017

Droubi, M. G.; Faisal, N. H.; Orr, F.; Steel, J. A. & El-Shaib, M. (2017), „Acoustic emission method for defect detection and identification in carbon steel welded joints“, *Journal of Constructional Steel Research*, 134, S. 28–37. DOI: 10.1016/j.jcsr.2017.03.012.

Edelsbrunner & Mücke 1994

Edelsbrunner, H. & Mücke, E. P. (1994), „Three-dimensional alpha shapes“, *ACM Transactions on Graphics*, 13(1), S. 43–72. DOI: 10.1145/174462.156635.

Eftekharijad 2010

Eftekharijad, B. (2010), „Monitoring Natural Pitting Progress on Helical Gear Mesh Using Acoustic Emission and Vibration“, *International Journal of Experimental Mechanics*.

Ehrmann 2019

Ehrmann, C. (2019), *Ausfallfrüherkennung von Ritzel-Zahnstangen-Trieben mittels Acoustic Emission*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

Eschner 2021

Eschner, J. N. (2021), *Entwicklung einer akustischen Prozessüberwachung zur Porenbestimmung im Laserstrahlschmelzen*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik. ISBN: 978-3-8440-7966-1.

Ester et al. 1996

Ester, M.; Kriegel, H.-P.; Sander, J. & Xu, X. (1996), „A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise“ in *AAAI (Hg.) KDD-96 Proceedings*.

Everitt 2012

Everitt, B. (2012), *Cluster analysis*, Wiley, London. ISBN: 978-0-470-74991-3.

F.N. Oliveira et al. 2019

F.N. Oliveira, D.; Neves, M. M.; Vismari, L. F.; Almeida, J. R. de; Cugnasca, P. S.;

- Camargo, J. B.; Marreto, E.; Doimo, D. R.; Almeida, L. P. F. de & Gripp, R. (2019), „Evaluating Unsupervised Anomaly Detection Models to Detect Faults in Heavy Haul Railway Operations“, S. 1016–1022. DOI: 10.1109/ICMLA.2019.00172.
- Fleischer, Puchta & Gönninger 2021
- Fleischer, J.; Puchta, A. & Gönninger, P. (2021), „Seamless and Modular Architecture for Autonomous Machine Tools“, *Journal of Machine Engineering*. DOI: 10.36897/jme/141565.
- Galar et al. 2012
- Galar, D.; Kumar, U.; Lee, J. & Zhao, W. (2012), „Remaining Useful Life Estimation using Time Trajectory Tracking and Support Vector Machines“, *Journal of Physics: Conference Series*, 364, S. 12063. DOI: 10.1088/1742-6596/364/1/012063.
- Gama et al. 2004
- Gama, J.; Medas, P.; Castillo, G. & Rodrigues, P. (2004), „Learning with Drift Detection“ in *Advances in Artificial Intelligence – SBIA 2004*, Hrsg. D. Hutchison, T. Kanade, J. Kittler, J. M. Kleinberg, F. Mattern, J. C. Mitchell, M. Naor, O. Nierstrasz, C. Pandu Rangan, B. Steffen, M. Sudan, D. Terzopoulos, D. Tygar, M. Y. Vardi, G. Weikum, A. L. C. Bazzan & S. Labidi, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 286–295. ISBN: 978-3-540-23237-7.
- Georgii 2015
- Georgii, H.-O. (2015), *Stochastik. Einführung in die Wahrscheinlichkeitstheorie und Statistik*, De Gruyter, Berlin.
- Géron 2019
- Géron, A. (2019), *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. Concepts, tools, and techniques to build intelligent systems*. ISBN: 9781492032618.
- GfM 2022
- GfM (2022), *Condition Monitoring*, Gesellschaft für Maschinendiagnose. https://maschinendiagnose.de/mosaic/_M_userfiles/PDF/Downloads_DE/Katalog.pdf.
- Goldstein & Uchida 2016
- Goldstein, M. & Uchida, S. (2016), „A Comparative Evaluation of Unsupervised

Anomaly Detection Algorithms for Multivariate Data“, *PLoS one*, 11(4), e0152173.
DOI: 10.1371/journal.pone.0152173.

Gunopulos 2009

Gunopulos, D. (2009), „Clustering Overview and Applications“ in *Encyclopedia of Database Systems*, Hrsg. L. LIU & M. T. Özsu, Springer US, Boston, MA, S. 383–387. ISBN: 978-0-387-35544-3.

Gupta, Yadav & Gupta 2020

Gupta, S. B.; Yadav, R. & Gupta, S. (2020), „A Systematic Comparative Analysis of Clustering Techniques“, *Applied Computer Systems*, 25(2), S. 87–104.
<https://www.sciendo.com/article/10.2478/acss-2020-0011>. DOI: 10.2478/acss-2020-0011.

Haberkern 1998

Haberkern, A. (1998), *Leistungsfähigere Kugelgewindetriebe durch Beschichtung*. Dissertation, Universität Karlsruhe, Karlsruhe, Institut für Werkzeugmaschinen und Betriebstechnik.

Hase 2020

Hase, A. (2020), „Early Detection and Identification of Fatigue Damage in Thrust Ball Bearings by an Acoustic Emission Technique“, *Lubricants*, 8(3), S. 37. DOI: 10.3390/lubricants8030037.

He, Zhao & Chu 2021

He, X.; Zhao, K. & Chu, X. (2021), *AutoML: A Survey of the State-of-the-Art*. Knowledge-Based Systems, Volume 212.

Hennrich 2013

Hennrich, H. (2013), *Aufbau eines kombinierten belastungs- und zustandsorientierten Diagnose- und Prognosesystems für Kugelgewindetriebe*. Dissertation, Shaker Verl., Karlsruhe, Karlsruher Institut für Technologie (KIT). ISBN: 9783844023121.

Hillenbrand 2020a

Hillenbrand, J. (2020), *Ball Screw Failure - Dataset v1*. Datensatz, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.
https://git.scc.kit.edu/ml-wzmm_public/ballscrewloadfailure_v1.

Hillenbrand 2020b

Hillenbrand, J. (2020), *Axial Ball Bearing Speeds -Dataset v1*. Datensatz, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik. https://git.scc.kit.edu/ml-wzmm_public/Axial_Ball_Bearing_Speeds_v1.

Hillenbrand et al. 2021

Hillenbrand, J.; Detroy, J.; Fleischer, J.; Hillenbrand, J.; Detroy, J. & Fleischer, J. (2021), „Investigation of Defects in Roll Contacts of Machine Elements with Acoustic Emission and Unsupervised Machine Learning“ in *IOP Conference Series: Materials Science and Engineering*, Hrsg. IOP.

Hillenbrand & Fleischer 2020

Hillenbrand, J. & Fleischer, J. (2020), „Autoconfiguration of a Vibration-Based Anomaly Detection System with Sparse a-priori Knowledge Using Autoencoder Networks“ in *Production at the leading edge of technology. Proceedings of the 10th Congress of the German Academic Association for Production Technology (WGP), Dresden, 23-24 September 2020*, Hrsg. J. P. Wulfsberg, W. Hintze, B.-A. Behrens, A. Brosius & S. Ihlenfeldt, Springer Berlin; Springer, Berlin, S. 518–527. ISBN: 978-3-662-62137-0.

Hillenbrand & Fleischer 2021

Hillenbrand, J. & Fleischer, J. (2021), „Unsupervised Detection of State Changes During Operation of Machine Elements“, *Journal of Machine Engineering*, S. 35–46. DOI: 10.36897/jme/136311.

Hilmer 1978

Hilmer, H. (1978), *Rechnergestützte Auslegung und Berechnung von Kugelgewindespindeln*. Dissertation, Technischer Verlag Resch KG, München, Institut für Fertigungstechnik und Spanenden Werkzeugmaschinen (IFW).

Hosseini et al. 2020

Hosseini, M.-P.; Lu, S.; Kamaraj, K.; Slowikowski, A. & Venkatesh, H. C. (2020), „Deep Learning Architectures“ in *Deep Learning: Concepts and Architectures*, Hrsg. W. Pedrycz & S.-M. Chen, Springer International Publishing, Cham, S. 1–24. ISBN: 978-3-030-31755-3.

Hoyer & Drescher 2013

Hoyer, H. G. & Drescher, U. (2013), *Reibung und ihr Einfluss auf Funktion und Lebensdauer von Kugelgewindetrieben*, Konstruktionspraxis.

<https://www.konstruktionspraxis.vogel.de/reibung-und-ihr-einfluss-auf-funktion-und-lebensdauer-von-kugelgewindetrieben-gal-409487> [09.01.2021].

Huf 2012

Huf, A. (2012), *Kumulative Lastermittlung aus Antriebsdaten zur Zustandsbewertung von Werkzeugmaschinenkomponenten*, Jost-Jetter, Heimsheim. ISBN: 978-3-939890-96-6.

ISO 281

ISO 281 (2007), *Rolling bearings - Dynamic load ratings and rating life*, International Organization for Standardization.

ISO 22096

ISO 22096 (2007), *Condition monitoring and diagnostics of machines - Acoustic emission*, International Organization for Standardization.

ISO 13372

ISO 13372 (2012), *Condition Monitoring and diagnostics of machines - Vocabulary*, International Organization for Standardization.

Ismail, Balaban & Spangenberg 2016

Ismail, M. A. A.; Balaban, E. & Spangenberg, H. (2016), „Fault detection and classification for flight control electromechanical actuators“, *IEEE Aerospace Conference*, IEEE, S. 1–10. ISBN: 9781467376761.

Jacobsen 2012

Jacobsen, J. (2012), *Einsatz von Körperschall-Sensorik zur Analyse der Prozessdynamik und zur aktiven Unwuchtkompensation beim Außenrundschleifen*. Dissertation, Leibniz-Universität, Hannover, Institut für Fertigungstechnik und Werkzeugmaschinen. ISBN: 9783943104370.

Japkowicz & Shah 2014

Japkowicz, N. & Shah, M. (2014), *Evaluating learning algorithms. A classification perspective*, Cambridge University Press, New York. ISBN: 978-0-521-19600-0.

Jarosch 2008

Jarosch, P. (2008), *Zur Lebensdauerprognose zyklisch hoch belasteter Kugelgewindetriebe*. Dissertation, Shaker Verlag, Aachen. ISBN: 9783832272838.

Joshi 2020

Joshi, A. V. (2020), *Machine Learning and Artificial Intelligence*, Springer International Publishing, Cham. ISBN: 978-3-030-26621-9.

Kathan 2017

Kathan, B. (2017), *ifm electronic GmbH - Patent Kugelgewindetrieb*. Patentschrift. <https://worldwide.espacenet.com/publicationDetails/biblio?CC=DE&NR=102016210284A1&KC=A1&FT=D#>.

Kelemen 2012

Kelemen, S. G. (2012), *Potentiale der Schallemissionsanalyse zur Charakterisierung von trockenlaufenden Friktionssystemen*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, Institut für Produktentwicklung (IPEK).

Khan & Yairi 2018

Khan, S. & Yairi, T. (2018), „A review on the application of deep learning in system health management“, *Mechanical Systems and Signal Processing*, 107, S. 241–265. DOI: 10.1016/j.ymssp.2017.11.024.

Kimotho & Sextro 2014

Kimotho, J. K. & Sextro, W. (2014), „An approach for feature extraction and selection from non-trending data for machinery prognosis“.

Klein 2011

Klein, W. H. (2011), *Zustandsüberwachung von Rollen-Profileschienenführungen und Kugelgewindetrieben*. Dissertation, RWTH, Aachen, Werkzeugmaschinenlabor (WZL).

Kovtun, Boiko & Petrashchuk 2017

Kovtun, I.; Boiko, J. & Petrashchuk, S. (2017), „Nondestructive strength diagnostics of solder joints on printed circuit boards“, *International Conference on Information and Telecommunication Technologies and Radio Electronics*, IEEE, Piscataway, New Jersey, USA, S. 1–4. ISBN: 9781538610565.

Kuttner 2015

Kuttner, T. (2015), *Praxiswissen Schwingungsmesstechnik*, Springer Fachmedien, Wiesbaden. ISBN: 9783658046378.

Lee et al. 2015

Lee; Gi, W.; Woo, J.; Hong; Sung, M.; Nam; Sung-Ho; Jeon; YongHo; G, M. &

Corporation, H. P. (2015), *Failure Diagnosis System for a Ball-Screw by Using Vibration Signals*, Hindawi Publishing Corporation.

Lee et al. 2006

Lee, D. E.; Hwang, I.; Valente, C.; Oliveira, J. & Dornfeld, D. A. (2006), „Precision manufacturing process monitoring with acoustic emission“, *International Journal of Machine Tools and Manufacture*, 46(2), S. 176–188. DOI: 10.1016/j.ijmachtools.2005.04.001.

Lessmeier et al. 2016

Lessmeier, C.; Kimotho, J. K.; Zimmer, D. & Sextro, W. (2016), „Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification“, *European Conference of Prognostics and Health Management*.

Li et al. 2020

Li, K.; Qiu, C.; Li, C.; He, S.; Li, B.; Luo, B. & Liu, H. (2020), „Vibration-based health monitoring of ball screw in changing operational conditions“, *Journal of Manufacturing Processes*, 53, S. 55–68. DOI: 10.1016/j.jmapro.2020.02.008.

Lv et al. 2017

Lv, Q.; Ying, C.; Wang, X. & Chen, M. (2017), „Parametric Analysis Method for Acoustic Emission Test of High Pressure Gas Cylinder Materials“ in *Advances in Mechanical Design. Proceedings of the 2017 International Conference on Mechanical Design (ICMD2017)*, Hrsg. J. Tan, F. Gao & C. Xiang, Springer, Singapore, S. 1613–1620. ISBN: 978-981-10-6552-1.

MacQueen 1967

MacQueen, J. (1967), „Some methods for classification and analysis of multivariate observations“ in *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability. Volume 1: Statistics*, University of California, Los Angeles, S. 281–297. https://digitalassets.lib.berkeley.edu/math/ucb/text/math_s5_v1_article-17.pdf.

Maier 2013

Maier, J. (2013), *Dynamische Simulation des Reibdrehmoments in einem Kugelgewindetrieb*. Diplomarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

Marchi et al. 2015

Marchi, E.; Vesperini, F.; Eyben, F.; Squartini, S. & Schuller, B. (2015), „A novel approach for automatic acoustic novelty detection using a denoising autoencoder with bidirectional LSTM neural networks“ in *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Hrsg. IEEE, S. 1996–2000.

März 2017

März, M. (2017), „Maintenance 4.0 bestimmt Profitabilität der Fabrik von morgen. White Paper zu Predictive Maintenance, Mobile Instandhaltung und Asset Innovation“, *VDI-Z Integrierte Produktion*, 159(10), S. 52–53.

Meyer 2017

Meyer, M. (2017), *Signalverarbeitung. Analoge und digitale Signale, Systeme und Filter*, Springer Fachmedien, Wiesbaden. ISBN: 9783658183202.

Michau et al. 2019

Michau, G.; Fink, O.; Hu, Y. & Palmé, T. (2019), „Feature learning for fault detection in high dimensional condition monitoring signals“, *Journal of Risk and Reliability*, 234(1), S. 104–115. DOI: 10.1177/1748006X19868335.

Mistras Group 2011

Mistras Group (2011), *WD Sensor. Wideband Differential Sensor*.

Mitchell 1997

Mitchell, T. M. (1997), *Machine learning*, McGraw-Hill, New York, NY. ISBN: 0-07-115467-1.

Mizutani 2016

Mizutani, Y. (2016), *Practical Acoustic Emission Testing*, Springer Japan, Tokyo. ISBN: 9784431550716.

Möhring & Bertram 2012

Möhring, H.-C. & Bertram, O. (2012), „Integrated autonomous monitoring of ball screw drives“, *CIRP Annals - Manufacturing Technology*, 61(1), S. 355–358. DOI: 10.1016/j.cirp.2012.03.138.

Montavon, Orr & Müller 2012

Montavon, G.; Orr, G. B. & Müller, K.-R. (2012), *Neural Networks: Tricks of the Trade*, Springer Berlin Heidelberg, Berlin, Heidelberg. ISBN: 978-3-642-35288-1.

Moriarty 2015

Moriarty, T. (2015), *Getting ROI from condition monitoring*. <https://www.plant-services.com/articles/2015/human-capital-roi-condition-monitoring>.

Möser 2018

Möser, M. (Hrsg.) (2018), *Körperschall-Messtechnik*, Springer Vieweg, Berlin. ISBN: 9783662566206.

Münzing 2017

Münzing, T. (2017), *Auslegung von Kugelgewindetrieben bei oszillierenden Bewegungen und dynamischer Belastung*. Dissertation, Universität Stuttgart, Stuttgart, Institut für Konstruktionstechnik und Technisches Design.

Muravin 2009

Muravin, B. (2009), „Acoustic Emission. Science and Technology“ in *Journal of Building and Infrastructure Engineering of the Israeli Association of Engineers and Architects*.

Netzer et al. 2022

Netzer, M.; Bach, J.; Puchta, A.; Gönneheimer, P. & Fleischer, J. (2022), „Process Segmented based Intelligent Anomaly Detection in Highly Flexible Production Machines under Low Machine Data Availability“, *Procedia CIRP*, 107, S. 647–652. DOI: 10.1016/j.procir.2022.05.040.

Netzer, Michelberger & Fleischer 2020

Netzer, M.; Michelberger, J. & Fleischer, J. (2020), „Intelligent Anomaly Detection of Machine Tools based on Mean Shift Clustering“, *Procedia CIRP*, 93, S. 1448–1453. DOI: 10.1016/j.procir.2020.03.043.

Nguyen, Ro & Park 2019

Nguyen, T. L.; Ro, S.-K. & Park, J.-K. (2019), „Study of ball screw system preload monitoring during operation based on the motor current and screw-nut vibration“, *Mechanical Systems and Signal Processing*, 131, S. 18–32. DOI: 10.1016/j.ymsp.2019.05.036.

NI 2017

NI, X. (2017), „Study on Waveform Acoustic Emission Technique for Monitoring Corrosion in Reinforced Concrete“, *DEStech Transactions on Computer Science and Engineering(aiea)*. DOI: 10.12783/dtcse/aiea2017/15008.

Niu 2017

Niu, G. (2017), *Data-driven technology for engineering systems health management. Design approach, feature construction, fault diagnosis, prognosis, fusion and decision*, Springer Science Press, Singapore, Beijing.

NSK Europe LTD 2017

NSK Europe LTD (2017), *Schadensdiagnose bei Kugelgewindetrieben*.
<http://www.nskeurope.de/kugelgewindetriebe-136.htm> [31.01.2017].

NSK Europe LTD 2021

NSK Europe LTD (2021), *Kugelgewindetriebe. Schadensdiagnose*.
<https://www.nskeurope.de/de/linear-motion-control/services/troubleshooting/ball-screws.html> [13.11.2021].

Nurudeen Alegeh et al. 2020

Nurudeen Alegeh; Abubaker Shagluf; Andrew Longstaff & Simon Fletcher (2020), „Degradation monitoring of machine tool ballscrew using deep convolution neural network“, *Proceedings of the 20th International Conference of the European Society for Precision Engineering and Nanotechnology*, Hrsg. R. K. Leach, D. Billington, C. Nisbet & D. Phillips, euspen, United Kingdom, S. 209–212. ISBN: 9780995775176.

Oh & Yun 2018

Oh, D. Y. & Yun, I. D. (2018), „Residual Error Based Anomaly Detection Using Auto-Encoder in SMD Machine Sound“, *Sensors (Basel, Switzerland)*, 18(5). DOI: 10.3390/s18051308.

Olszewski 2001

Olszewski, R. T. (2001), *Generalized Feature Extraction for Structural Pattern Recognition in Time-Series Data*. Dissertation, Pittsburgh, Carnegie Mellon University. <https://www.cs.cmu.edu/~bobski/pubs/tr01108-twosided.pdf>.

Omoregbee & Heyns 2018

Omoregbee, O. H. & Heyns, P. S. (2018), „Low speed rolling bearing diagnostics using acoustic emission and higher order statistics technique“, *Journal of Mechanical Engineering Research & Developments (JMERRD)*, 41(3), S. 18–23. DOI: 10.26480/jmerrd.03.2018.18.23.

Oppermann 2021

Oppermann, A. (2021), *Accuracy, Precision, Recall, F1-Score und Specificity. Evaluationsmetriken*. <https://artemoppermann.com/de/accuracy-precision-recall-f1-score-und-specificity/>.

Pawar & Attar 2020

Pawar, K. & Attar, V. Z. (2020), „Assessment of Autoencoder Architectures for Data Representation“ in *Deep Learning: Concepts and Architectures*, Hrsg. W. Pedrycz & S.-M. Chen, Springer International Publishing, Cham, S. 101–132. ISBN: 978-3-030-31755-3.

Putri et al. 2019

Putri, G. H.; Read, M. N.; Koprinska, I.; Singh, D.; Röhm, U.; Ashhurst, T. M. & King, N. J. (2019), „ChronoClust: Density-based clustering and cluster tracking in high-dimensional time-series data“, *Knowledge-Based Systems*, 174, S. 9–26. DOI: 10.1016/j.knosys.2019.02.018.

Raschka 2016

Raschka, S. (2016), *Python machine learning. Unlock deeper insights into machine learning with this vital guide to cutting-edge predictive analytics*, Packt Publishing Ltd., Birmingham. ISBN: 978-1-78355-513-0.

Reichel, Müller & Mandelartz 2009

Reichel, J.; Müller, G. & Mandelartz, J. (2009), *Betriebliche Instandhaltung*, Springer, Berlin, Heidelberg.

Rose 2004

Rose, J. L. (2004), *Ultrasonic waves in solid media*, Cambridge Univ. Press, Cambridge. <http://www.loc.gov/catdir/description/cam029/98045447.html>. ISBN: 0521640431.

Roy et al. 2018

Roy, M.; Bose, S. K.; Kar, B.; Gopalakrishnan, P. K. & Basu, A. (2018), „A Stacked Autoencoder Neural Network based Automated Feature Extraction Method for Anomaly detection in On-line Condition Monitoring“ in *Symposium Series on Computational Intelligence (SSCI)*, Hrsg. IEEE, S. 1501–1507.

Rupitsch 2019

Rupitsch, S. J. (2019), *Piezoelectric Sensors and Actuators. Fundamentals and Applications*, Springer, Berlin, Heidelberg. ISBN: 978-3-662-57532-1.

Sammut 2010

Sammut, C. (Hrsg.) (2010), *Encyclopedia of Machine Learning*, Springer, Boston, MA, USA. ISBN: 9780387301648.

Satopaa et al. 2011

Satopaa, V.; Albrecht, J.; Irwin, D. & Raghavan, B. (2011), „Finding a "Kneedle" in a Haystack: Detecting Knee Points in System Behavior“, *31st International Conference on Distributed Computing Systems Workshops (ICDCSW 2011)*, IEEE, Piscataway, NJ, S. 166–171. ISBN: 978-1-4577-0384-3.

Schäfer 2013

Schäfer, C. (2013), *Signaltechnische Voraussetzungen und Analyseverfahren zur Überwachung von Präzisions- und Ultrapräzisionsbearbeitungsverfahren*, Shaker, Aachen. ISBN: 978-3-8440-2286-5.

Scherer 1997

Scherer, A. (1997), *Neuronale Netze. Grundlagen und Anwendungen*, Vieweg+Teubner Verlag, Wiesbaden. ISBN: 9783528054656.

Schlagenhauf et al. 2019

Schlagenhauf, T.; Feuring, C.-P.; Hillenbrand, J. & Fleischer, J. (2019), „Camera Based Ball Screw Spindle Defect Classification System“ in *Production at the leading edge of technology*, Hrsg. J. P. Wulfsberg, W. Hintze & B.-A. Behrens, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 503–512. ISBN: 978-3-662-60416-8.

Schlagenhauf & Scheurenbrand 2022

Schlagenhauf, T. & Scheurenbrand, T. (2022), *Cross-domain Transfer of defect features in technical domains based on partial target data*.
<https://arxiv.org/abs/2211.13662v3>.

Schopp 2009

Schopp, M. (2009), *Sensorbasierte Zustandsdiagnose und -prognose von Kugelgewindetrieben*. Dissertation, Shaker, Karlsruhe, wbk Institut für Produktionstechnik. ISBN: 9783832287337.

Schrüfer, Reindl & Zagar 2012

Schrüfer, E.; Reindl, L. & Zagar, B. (2012), *Elektrische Messtechnik*, Carl Hanser Verlag GmbH & Co. KG, München.

Scrubby 1987

Scrubby, C. B. (1987), „An introduction to acoustic emission“, *Journal of Physics E: Scientific Instruments*, 20(8), S. 946–953. DOI: 10.1088/0022-3735/20/8/001.

Seemann 2006

Seemann, J. (2006), *Software-Entwurf mit UML 2. Objektorientierte Modellierung mit Beispielen in Java*, Springer, Berlin. <https://link.springer.com/book/10.1007/3-540-30950-0>.

Sikorska & Mba 2008

Sikorska, J. Z. & Mba, D. (2008), „Challenges and obstacles in the application of acoustic emission to process machinery“, *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 222(1), S. 1–19. DOI: 10.1243/09544089JPME111.

Silva et al. 2013

Silva, J. A.; Faria, E. R.; Barros, R. C.; Hruschka, E. R.; Carvalho, A. C. P. L. F. de & Gama, J. (2013), „Data stream clustering“, *ACM Computing Surveys*, 46(1), S. 1–31. DOI: 10.1145/2522968.2522981.

Smith & Randall 2015

Smith, W. A. & Randall, R. B. (2015), „Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study“, *Mechanical Systems and Signal Processing*, 64-65, S. 100–131. DOI: 10.1016/j.ymsp.2015.04.021.

Sohaib & Kim 2018

Sohaib, M. & Kim, J.-M. (2018), „Reliable Fault Diagnosis of Rotary Machine Bearings Using a Stacked Sparse Autoencoder-Based Deep Neural Network“, *Shock and Vibration*, 2018, S. 1–11. DOI: 10.1155/2018/2919637.

Sommer, Heinz & Schöfer 2014

Sommer, K.; Heinz, R. & Schöfer, J. (2014), *Verschleiß metallischer Werkstoffe*, Springer Fachmedien, Wiesbaden. ISBN: 9783835101265.

Spath et al. 1995

Spath, D.; Rosum, J.; Haberkern, A. & Weule, H. (1995), „Kinematics, Frictional Characteristics and Wear Reduction by PVD Coating on Ball Screw Drives“, *CIRP Annals - Manufacturing Technology*, 44(1), S. 349–352. DOI: 10.1016/S0007-8506(07)62340-3.

Spiliopoulou et al. 2006

Spiliopoulou, M.; Ntoutsis, I.; Theodoridis, Y. & Schult, R. (2006), „MONIC. modeling and monitoring cluster transitions“, *Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining - KDD '06*, Hrsg. L. Ungar, M. Craven, D. Gunopulos & T. Eliassi-Rad, ACM Press, New York, New York, USA, S. 706. ISBN: 1595933395.

Steinwendner & Schwaiger 2020

Steinwendner, J. & Schwaiger, R. (2020), *Neuronale Netze programmieren mit Python*, Rheinwerk Computing, Bonn. ISBN: 978-3-8362-7450-0.

Tandon & Choudhury 1999

Tandon, N. & Choudhury, A. (1999), „A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings“, *Tribology International*(32), S. 469–480. DOI: 10.1016/S0301-679X(99)00077-8.

Tichý et al. 2010

Tichý, J.; Erhart, J.; Kittinger, E. & Přivratská, J. (2010), *Fundamentals of piezoelectric sensorics. Mechanical, dielectric, and thermodynamical properties of piezoelectric materials*, Springer, Berlin, Heidelberg. ISBN: 978-3-540-43966-0.

Tsai, Cheng & Hwang 2014

Tsai, P. C.; Cheng, C. C. & Hwang, Y. C. (2014), „Ball screw preload loss detection using ball pass frequency“, *Mechanical Systems and Signal Processing*, 48(1-2), S. 77–91. DOI: 10.1016/j.ymssp.2014.02.017.

Veith et al. 2020

Veith, M.; Zimmermann, A.; Hillenbrand, J. & Fleischer, J. (2020), „Detektion des Vorspannungsverlusts in Kugelgewindetrieben“, *wt Werkstattstechnik online*(7/8), S. 485. <https://e-paper.vdi-fachmedien.de/werkstattstechnik/2020#03-08-2020> [06.10.2020].

Verl et al. 2009

Verl, A.; Heisel, U.; Walther, M. & Maier, D. (2009), „Sensorless automated condition monitoring for the control of the predictive maintenance of machine tools“, *CIRP Annals*, 58(1), S. 375–378. DOI: 10.1016/j.cirp.2009.03.039.

Vijini Mallawaarachchi 2020

Vijini Mallawaarachchi (2020), *Evaluating Clustering Results. The criteria used to evaluate clustering results*. <https://towardsdatascience.com/evaluating-clustering-results-f13552ee7603>.

Walther 2011

Walther, M. (2011), *Antriebsbasierte Zustandsdiagnose von Vorschubantrieben*. Dissertation, Universität Stuttgart, Institut für Steuerungstechnik der Werkzeugmaschinen. ISBN: 9783939890775.

Wantzen 2020

Wantzen, K. (2020), *Methode zur Entwicklung merkmalsbasierter Zustandsüberwachungssysteme mittels der Körperschallmesstechnik*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, Institut für Produktentwicklung (IPEK).

Weck & Brecher 2006

Weck, M. & Brecher, C. (2006), *Werkzeugmaschinen 3. Mechatronische Systeme, Vorschubantriebe, Prozessdiagnose*, Springer-Verlag Berlin Heidelberg, Berlin, Heidelberg. ISBN: 9783540225065.

Wegmann et al. 2021

Wegmann, M.; Zipperling, D.; Hillenbrand, J. & Fleischer, J. (24. Juni 2021), *A review of systematic selection of clustering algorithms and their evaluation*. <http://arxiv.org/pdf/2106.12792v1>.

Wei & Lin 2003

Wei, C. C. & Lin, J. F. (2003), „Kinematic analysis of the ball screw mechanism considering variable contact angles and elastic deformations // Kinematic Analysis of the Ball Screw Mechanism Considering Variable Contact Angles and Elastic Deformations“, *Journal of mechanical design*, 125(4), S. 717–733. DOI: 10.1115/1.1623761.

Weidenfeller 2002

Weidenfeller, H. (2002), *Grundlagen der Kommunikationstechnik*, Vieweg+Teubner Verlag, Wiesbaden. ISBN: 978-3-663-07806-7.

Widmer & Kubat 1996

Widmer, G. & Kubat, M. (1996), „Learning in the presence of concept drift and hidden contexts“, *Machine Learning*, 23(1), S. 69–101. DOI: 10.1007/BF00116900.

Wieser 2008

Wieser, J. (2008), *Intelligente Instandhaltung von Werkzeugmaschinen*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik. ISBN: 978-3-8322-7882-3.

Xiaofei He, Deng Cai & Partha Niyogi 2001

Xiaofei He; Deng Cai & Partha Niyogi (2001), „Laplacian Score for Feature Selection“ in *Advances in neural information processing systems. Proceedings of the first 12 conferences*, Hrsg. M. I. Jordan, MIT Press, Cambridge, Mass., S. 507–514. ISBN: 9780262561457.

Yagmur 2014

Yagmur, T. (2014), *Analyse, Verbesserung und Beschreibung des Verschleißverhaltens von Kugelgewindetrieben für Werkzeugmaschinen*. Dissertation, Apprimus-Verlag, Aachen, Werkzeugmaschinenlabor (WZL). ISBN: 9783863591915.

Yang 2003

Yang, J. (2003), „Dynamic clustering of evolving streams with a single pass“, *Proceedings 19th International Conference on Data Engineering (Cat. No.03CH37405)*, IEEE, S. 695–697. ISBN: 0-7803-7665-X.

Zhang, Huang & Wang 2012

Zhang, J. M.; Huang, Y. H. & Wang, S. M. (2012), „Fault Diagnosis Method for the Rolling Bearing Based on Information Fusion and BP Neural Network“, *Advanced Materials Research*, 538-541, S. 1956–1961. DOI: 10.4028/www.scientific.net/AMR.538-541.1956.

Zhang et al. 2019

Zhang, L.; Basantes-Defaz, A. C.; Ozevin, D. & Indacochea, E. (2019), „Real-time monitoring of welding process using air-coupled ultrasonics and acoustic

emission“, *The International Journal of Advanced Manufacturing Technology*, 101(5-8), S. 1623–1634. DOI: 10.1007/s00170-018-3042-2.

Abbildungsverzeichnis

Abbildung 1-1: Autonome Funktionen im Lebenszyklus der Werkzeugmaschine, nach (Fleischer, Puchta & Gönzheimer 2021)	2
Abbildung 1-2: Aufteilung der Ausfälle nach Vorschubachsenkomponenten (links) und Verteilung der Ausfallursachen für Vorschubachsen (rechts) (Schopp 2009; Wieser 2008)	3
Abbildung 1-3: Kapitelaufbau dieser Arbeit	6
Abbildung 2-1: Aufbau eines Kugelgewindetriebs (Brecher 2022, S. 84)	7
Abbildung 2-2: Umlenkung mit interner Gesamtumlenkung (links), externer Gesamtumlenkung (Mitte) und Einzelgangumlenkung (rechts) (Weck & Brecher 2006)	8
Abbildung 2-3: Vorspannungsarten und KGT-Bauformen, nach (August Steinmeyer GmbH & Co. KG 2021)	9
Abbildung 2-4: Verschiedene Kontaktgeometrien im Wälzkontakt des Kugelgewindetriebs (Hoyer & Drescher 2013)	9
Abbildung 2-5: Geometrische Größen am Kugelgewindetrieb nach DIN ISO 3408-1 (Walther 2011)	10
Abbildung 2-6: Kontaktverhältnisse (2-Punkt-Kontakt links, 4-Punkt-Kontakt rechts), nach (Maier 2013)	12
Abbildung 2-7: Kugelumlauflinien in Drahtansicht eines KGT und Helixbahn der Umläufe	14
Abbildung 2-8: Geometrische Zusammenhänge der Kugelrückführung	15
Abbildung 2-9: Einflüsse auf den Verschleiß von KGT, adaptiert nach (Bosch Rexroth AG 2006)	18
Abbildung 2-10: Schadensmechanismen und Schadensformen, nach (Münzing 2017; Haberkern 1998)	19
Abbildung 2-11: Schadensursachen und Schadensbilder am KGT, eigene Darstellung nach (Haberkern 1998) und (Böge 2017, S. 511–512)	20
Abbildung 2-12: Anregungsmechanismen von AE, nach (Muravin 2009; Schäfer 2013)	26

Abbildung 2-13: Aufbau eines Piezo-Sensor-Elements (Rupitsch 2019, S. 419)	27
Abbildung 2-14: Übertragungsverhalten eines AE-Sensors (Mistras Group 2011)	27
Abbildung 2-15: Beispiel für ein Burst- (oben) und kontinuierliches AE-Signal (unten)	28
Abbildung 2-16: Potenzial von Acoustic Emission, nach (Reichel, Müller & Mandelartz 2009)	29
Abbildung 2-17: AE-Anregungsquellen im Bereich der Materialzerspannung (Lee et al. 2006)	31
Abbildung 2-18: Unterschied im Detektionsbereich zwischen AE- und herkömmlichen Vibrations-Methoden für Wälzkörper (Hase 2020)	32
Abbildung 2-19: Zusammenhang zwischen den AE-Anregungsmechanismen und KGT-Schadensursachen	35
Abbildung 2-20: Abgrenzung von Begriffen im Kontext von CM	36
Abbildung 2-21: Unterschied zwischen den Machine Learning Arten (Goldstein & Uchida 2016)	37
Abbildung 2-22: Aufbau eines Vanilla-Autoencoders (eigene Darstellung)	40
Abbildung 2-23: Prozessfolge für die Verwendung von Autoencodern in CM-Applikationen	41
Abbildung 2-24: Externe Cluster-Transitionen, nach (Spiliopoulou et al. 2006)	45
Abbildung 2-25: Interne Transitionen, nach (Spiliopoulou et al. 2006)	45
Abbildung 3-1: Darstellung von vorherrschenden Defiziten sowie Lösungen und Zielstellungen der Arbeit	50
Abbildung 3-2: Aufteilung der Inhalte in Arbeitspakete	53
Abbildung 3-3: Schematische Darstellung der Systemgrenzen und Teilsysteme	54
Abbildung 3-4: Abstrakte Beschreibung eines Systems zu unterschiedlichen Zeitpunkten	56
Abbildung 5-1: Verwendete Messkette zur Aufzeichnung von Acoustic Emission	63

Abbildung 5-2: CAD-Modell des Axiallagerprüfstands (links), Schnittbild der Sensoranbringung (Mitte) und realer Aufbau (rechts) (A_Detroy 2020; A_Osen 2020)	66
Abbildung 5-3: CAD-Modell des Prüfstands 2-Achs-KGT-RZA in a) und realer Aufbau in b)-d)	67
Abbildung 5-4: Prinzipskizze der Steifigkeitsmessung	68
Abbildung 5-5: Prinzipskizze der Reibmomentmessung	69
Abbildung 5-6: CAD-Modell des 5-Achs-KGT-Prüfstands (links) und realer Aufbau (rechts)	70
Abbildung 5-7: Prinzipskizze der KGT-Mutteraufnahme des 5-Achs-Prüfstands	71
Abbildung 5-8: Alternative Installationsmöglichkeiten für AE-Sensorelemente	72
Abbildung 5-9: Schnittbild der Sensoranbringung im Patent (Kathan 2017)	73
Abbildung 5-10: Installation nach Sensor1 am Versuchsträger 5-Achs-KGT	73
Abbildung 5-11: Installation nach Sensor1 am Versuchsträger 2-Achs-KGT-RZA74	74
Abbildung 5-12: Installation nach Sensor2 am Versuchsträger 5-Achs-KGT	75
Abbildung 6-1: Abhängigkeit der Signalamplitude von der Anpresskraft der Befestigung	79
Abbildung 6-2: Abhängigkeit der Signalamplitude von der Nähe zum Sensor	80
Abbildung 6-3: Vergleich der Sensitivitäten für unterschiedliche Sensoren	80
Abbildung 6-4: Schematisches Ablaufdiagramm der unüberwachten Merkmalsextraktion, nach (Hillenbrand et al. 2021)	82
Abbildung 6-5: Merkmalsselektion mit Laplace-Score (links), Merkmalsraum für ausgewählte Merkmale bei konstanter Drehzahl (rechts), nach (Hillenbrand et al. 2021)	83
Abbildung 6-6: Merkmalsraum für alle Axiallager-Versuchsreihen und Zustände, nach (Hillenbrand et al. 2021)	84
Abbildung 7-1: Teilsysteme der Datenverarbeitung in CM-Systemen	86
Abbildung 7-2: Beispiel für den Effekt der Fensterlänge für Moving-Window-Segmentierung	92

Abbildung 7-3: Kinematische Größen für die Lokalisierung von Defekten	93
Abbildung 7-4: Ermittelte Komponentenfrequenzen für Spindeldrehzahl 150 1/min	95
Abbildung 7-5: Fensterung eines AE-Signals für die sechs Teilsegmente	95
Abbildung 7-6: Simuliertes Szenario „Defektfrequenz“ und zugehörige Merkmale	99
Abbildung 7-7: Simuliertes Szenario „Amplitudendrift“ und zugehörige Merkmale	100
Abbildung 7-8: Simuliertes Szenario „Burst“ und zugehörige Merkmale	101
Abbildung 7-9: Simuliertes Szenario „Muster“ und zugehörige Merkmale	102
Abbildung 7-10: Schematischer Ablauf der Auto-Konfiguration des Autoencoders	105
Abbildung 7-11: Visualisierung der Kniepunktsuche an einem beispielhaften Spektrum	107
Abbildung 7-12: Übersicht der Einstellmöglichkeiten von Autoencodern (Pawar & Attar 2020)	108
Abbildung 7-13: Einfluss der Frequenzauflösung auf das entstehende Spektrum	111
Abbildung 7-14: Kniepunktsuche (links) und Recursive-Peak-Finding (rechts)	112
Abbildung 7-15: Rekonstruktionsfehler in Abhängigkeit der Neuronen im Hidden Layer	113
Abbildung 7-16: Validierungsfehler und Trainingszeit über Epochen und Größe des Hidden-Layer	114
Abbildung 7-17: Schematische Darstellung von Merkmalen und Zuständen im $R2$	116
Abbildung 7-18: Clustermodellvarianten: Merkmalsvektor (links) und Prototyparray bzw. Cluster-Boundary-Modell (rechts)	119
Abbildung 7-19: Verteilung der Datenpunkte innerhalb eines Clusterings über die Anzahl an Iterationen, nach (Hillenbrand & Fleischer 2021)	120
Abbildung 7-20: Zeitersparnis durch den neuen Ansatz, nach (Hillenbrand & Fleischer 2021)	120
Abbildung 7-21: Visualisierung einer Cluster-Übereinstimmung	122
Abbildung 7-22: Grafische Visualisierung der Clustertransitions-Berechnung	122

Abbildung 7-23: Verlauf der Clustergröße und des Curve-Fitting-Fehlers	123
Abbildung 7-24: IntraCluster-Verteilungen: a) gleichverteilt und b) mit IntraCluster126	
Abbildung 7-25: Schematische Abbildung der Ausreißer-Transitionen	127
Abbildung 7-26: Aktualisierungsvorschrift für ein Zustandsmodell	130
Abbildung 8-1: Variante 1 – Vordefinierte Merkmalsextraktion	135
Abbildung 8-2: Variante 2 – Allgemeine Unsupervised Architektur mit MSE-Merkmalsextraktion	136
Abbildung 8-3: Hin- und Rückfahrt einer Versuchsfahrt mit Segmenten bei einer Drehzahl von 600 U/min	140
Abbildung 8-4: Versuchsplan für Mangelschmierung am 2-Achs-KGT-RZA	141
Abbildung 8-5: Vergleich von konserviertem und geschmiertem KGT	142
Abbildung 8-6: Versuchsreihe zur Einbringung von abrasiven Partikeln in KGT144	
Abbildung 8-7: Gegenüberstellung von Leerlaufreibkräften für verschiedene KGT-Zustände	145
Abbildung 8-8: Steifigkeitsabnahme nach Abrasivverschleiß	145
Abbildung 8-9: Unterscheidung in verschiedene Betriebszustände mit AE-Merkmalen (DFG 2017)	147
Abbildung 8-10: Durchschnittliches Last- und Drehzahlprofil (oben) und zugehörige erreichte theoretische Lebensdauer (unten)	148
Abbildung 8-11: Schematische Darstellung der CM-System-Visualisierung	149
Abbildung 8-12: Visualisierung Cluster-Tracking – Rohdaten Amplitudendrift	151
Abbildung 8-13: Visualisierung Cluster-Tracking – Iteration 1 bis 5	152
Abbildung 8-14: Visualisierung Cluster-Tracking – Iteration 10	153
Abbildung 8-15: Visualisierung Cluster-Tracking – Iteration 15	154
Abbildung 8-16: Visualisierung Cluster-Tracking – Iteration 20	155
Abbildung 8-17: Clusterergebnis für Szenario 1 mit vordefinierten Merkmalen	157
Abbildung 8-18: Cluster-Tracking-Ergebnis für Szenario 1 mit vordefinierten Merkmalen	158

Abbildung 8-19: Clusterergebnis für Szenario 1 mit MSE-Merkmalsextraktion	160
Abbildung 8-20: Cluster-Tracking-Ergebnis für Szenario 1 mit MSE-Merkmalsextraktion	161
Abbildung 8-21: Clusterergebnis für Szenario 3 mit vordefinierter Merkmalsextraktion	163
Abbildung 8-22: Cluster-Tracking-Ergebnis für Szenario 3 für vordefinierte Merkmale	164
Abbildung 8-23: Clusterergebnis für Szenario 3 mit MSE-Merkmalsextraktion	165
Abbildung 8-24: Cluster-Tracking-Ergebnis für Szenario 3 für MSE-Merkmalsextraktion	166
Abbildung 8-25: Clusterergebnis für Szenario 4 mit vordefinierten Merkmalen	168
Abbildung 8-26: Cluster-Tracking-Ergebnis für Szenario 4 mit vordefinierten Merkmalen	169
Abbildung 8-27: Clusterergebnis für Szenario 4 mit MSE-Merkmalsextraktion	171
Abbildung 8-28: Cluster-Tracking-Ergebnis für Szenario 4 mit MSE-Merkmalsextraktion	172
Abbildung 8-29: Clusterergebnis für Szenario 6 mit vordefinierten Merkmalen	174
Abbildung 8-30: Cluster-Tracking-Ergebnis für Szenario 6 mit vordefinierten Merkmalen	175
Abbildung 8-31: Clusterergebnis für Szenario 6 mit MSE-Merkmalsextraktion	177
Abbildung 8-32: Cluster-Tracking-Ergebnis für Szenario 6 mit MSE-Merkmalsextraktion	178
Abbildung 8-33: Vergleich für gut und schlecht separierbare Merkmalsräume	184
Abbildung 8-34: Schematische Darstellung des Einflusses der Fensterlänge für die Segmentierung am Beispiel eines Defektes auf der Spindel	186
Abbildung 8-35: MSE-Fehler für verschiedene Segmentierungsfenster	187
Abbildung 8-36: Clusterergebnis für den Datensatz Axiallager	189

Abbildung 8-37: Transitions- und Zustandsdiagramm für den Datensatz Axiallager	191
Abbildung 8-38: Clusterergebnis für den Datensatz Laufbahnbruch am 5-Achser-KGT	193
Abbildung 8-39: Transitions- und Zustandsdiagramm für den Datensatz Laufbahnbruch am 5-Achser-KGT	194
Abbildung 9-1: Workflow zur Inbetriebnahme eines CM-Systems	200

Tabellenverzeichnis

Tabelle 2-1: Übersicht vorhandener CM-Ansätze für KGT	24
Tabelle 4-1: Anforderungskriterien an Piezo-Sensoren	58
Tabelle 4-2: Anforderungskriterien an Vorverstärker	59
Tabelle 4-3: Anforderungen an Messsystem und Digitale Signalverarbeitung	60
Tabelle 4-4: Anforderungen an die Auswertungs- und Überwachungslösung	60
Tabelle 5-1: Erfüllung der Anforderungen bezüglich der AE-Messkette	65
Tabelle 5-2: Datenquellen von Versuchsträger 1-Achs-Axiallager	67
Tabelle 5-3: Datenquellen für Versuchsträger 2-Achs-KGT-RZA	69
Tabelle 5-4: Datenquellen für Versuchsträger 5-Achs-KGT	71
Tabelle 5-5: Erfüllung der Anforderungen bezüglich Sensorelement	76
Tabelle 6-1: Untersuchte Einflussgrößen der AE-Sensorelemente, nach (A_Xia 2020)	78
Tabelle 6-2: Versuchsszenarien am Axiallager	81
Tabelle 7-1 Eignung der Merkmale für verschiedene Szenarien	103
Tabelle 7-2: Transitionen und ihre Bedeutung für die Zustandsüberwachung	128
Tabelle 7-3: Zustandszuordnung im Cluster-Tracking-Modell	129
Tabelle 8-1: Untersuchungsvarianten der Unsupervised Architektur	133
Tabelle 8-2: Künstliche Schadensformen für die Untersuchung von KGT	138
Tabelle 8-3: Versuchsplan für Geschwindigkeiten und Axiallasten an 5-Achs-KGT	139
Tabelle 8-4: Versuchsplan für die Partikelmenge im Abrasiv-Verschleißversuch	143
Tabelle 8-5: Übersicht der erreichten Detektionsgüte je Szenario und Architektur	181
Tabelle 9-1: Übersicht der AE-Eignung für verschiedene Szenarien	195
Tabelle 9-2: Bewertung der Architekturvarianten gemäß Anforderungsanalyse	198

Anhang

Im Anhang werden Datenblätter, Programmcode und größere Tabellen aufgeführt.

Anhang A 1 – Kugelgewindetrieb Rexroth FEM-E-B 32X20RX3.969-3	XXXII
Anhang A 2 - Kugelgewindetrieb Rexroth FEM-E-B 40X20RX6-3	XXXIII
Anhang A 3 – Kugelgewindetrieb August Steinmeyer ETA+ 3524.20.50	XXXIV
Anhang A 4 – Dynalub 510 Produktinformation	XXXV
Anhang A 5 – Divinol Lithogrease 000 Datenblatt	XXXVI
Anhang A 6 – Mistras Group Inc. Vorverstärker	XXXVII
Anhang A 7 – Mistras WD AE-Sensor	XXXVIII
Anhang A 8 – Mistras Micro80D AE-Sensor	XXXIX
Anhang A 9 – Mistras Micro80 Sensor	XL
Anhang A 10 – TE Piezo Film Sensor	XLI
Anhang A 11 – Kraftsensoren für Zug- und Druckbelastung	XLII
Anhang A 12 – USB-DUXfast Specifications	XLVI
Anhang A 13 – Schadensbilder KGT	XLVII
Anhang A 14 – Merkmalstabelle mit Definitionen	LI
Anhang A 15 – Vergleich von Körperschallwandlern	LII
Anhang A 16 – Programmcode für Kniepunktsuche	LIV
Anhang A 17 – Programmcode für DBSCAN	LV
Anhang A 18 – Programmcode für Cluster Match	LVI
Anhang A 19 – Programmcode für Externe Transitionen	LVII
Anhang A 20 – Clusterergebnis-Diagramme	LVIII
Anhang A 21 – Transitionsdiagramm	LXI
Anhang A 22 – Zustandsdiagramme	LXII
Anhang A 23 – Ansatzfunktion für Clustergrößenverlauf	LXIII

Anhang A 1 – Kugelgewindetrieb Rexroth FEM-E-B 32X20RX3.969-3

Eigenschaft	Wert
Nenn Durchmesser	32 mm
Kugelmittendurchmesser	n.a.
Kugeldurchmesser	3.969 mm
Steigung	20 mm
Umläufe	3
Reihen	1
Kontaktwinkel	45°
Schmiegung	0.55 (Annahme)
Kontaktart	4P
Vorspannung	0 N (C0)
Statische Tragzahl	33.7 kN
Dynamische Tragzahl	23.6 kN

Anhang A 2 - Kugelgewindetrieb Rexroth FEM-E-B 40X20RX6-3

<i>Eigenschaft</i>	<i>Wert</i>
Nenn Durchmesser	40 mm
Kugelmittendurchmesser	39.976 mm (Annahme)
Kugeldurchmesser	6 mm
Steigung	20 mm
Umläufe	3
Reihen	1
Kontaktwinkel	45°
Schmiegun	0.55 (Annahme)
Kontaktart	4P
Vorspannung	0 kN (C0), 1.14 kN (C2), 1.9 kN (C3)
Statische Tragzahl	62.8 kN
Dynamische Tragzahl	45.5 kN

Anhang A 3 – Kugelgewindetrieb August Steinmeyer ETA+ 3524.20.50

Eigenschaft	Wert
Nenn Durchmesser	50 mm
Kugelmittendurchmesser	n.a.
Kugeldurchmesser	7.5 mm
Steigung	20 mm
Umläufe	5
Reihen	2
Kontaktwinkel	n.a.
Schmiegung	n.a.
Kontaktart	3P
Vorspannung	10.82 kN
Statische Tragzahl	176.6 kN
Dynamische Tragzahl	108.2 kN

Anhang A 4 – Dynalub 510 Produktinformation

Dynalub 510 ist ein speziell auf die Lineare Bewegungstechnik abgestimmtes, lithiumverseiftes Hochleistungsfett der NLGI-Klasse 2. Es zeichnet sich durch gute Wasserbeständigkeit und Korrosionsschutz aus und ist in einem Temperaturbereich von -20 °C bis $+80\text{ °C}$ einsetzbar.

Anwendungsbereich

Das kurzfasrige und homogene Fett eignet sich bei konventionellen Umgebungsbedingungen hervorragend zur Schmierung von Linearelementen:

- Bei Lasten bis zu $0,5C_{dyn}$
- Auch bei Kurzhubanwendungen ≥ 1 (mm)

Chemische Zusammensetzung	Mineralöl, Lithiumspezialseife, Wirkstoffe	
Kennzeichnung	KP2K-20	DIN 51 825
Aussehen	hellbraun-beige, kurzfasrig	
Gebrauchstemperaturbereich	-20 °C bis $+80\text{ °C}$	
NLGI-Klasse	2	
Walkpenetration	265-295 1/10 mm	DIN ISO 2137
Wasserbeständigkeit	0-60, 1-90	DIN 51 807 T1
Tropfpunkt in °C	> 165	DIN ISO 2176
Flammpunkt in °C	> 200-Grundöl	DIN ISO 2592
Grundölviskosität	100 mm ² /s 40 °C	DIN 51 562
	10 mm ² /s 100 °C	
Fließdruck bei -20 °C	< 1 400 hPa	DIN 51 805
EMCOR-Test	0/0	DIN 51 802
Dichte bei $+25\text{ °C}$	ca. 0,92 g/cm ³	DIN 51 757
Kupferkorrosion	2 (24 h/120 °C)	DIN 51 811
VKA-Schweißkraft	> 2 000 N	DIN 51 350 T4
VKA-Kalottendurchmesser	0,93 (400 N, 1 h)	DIN 51 350 T5
Lagerdauer im Gebinde	2 Jahre	

Anhang A 5 – Divinol Lithogrease 000 Datenblatt

Produkteigenschaften:

Typische Kennzahlen

FARBE / AUSSEHEN	gelb
VERDICKER	Lithiumkomplexseife
TEMPERATUREINSATZBEREICH	-30°C - -140°C
NLGI-KLASSE / DIN 51818	000
GRUNDÖLVISKOSITÄT 40°C / ASTM D 7042	380 mm ² /s
TROPFPUNKT / DIN ISO 22286	> 160 °C
WALKPENETRATION 60 DOPPELHÜBE / DIN ISO 2137	460,0
WALKPENETRATION 5000 DOPPELHÜBE / DIN ISO 2137	465,0
FLIESSDRUCK BEI -20°C / DIN 51805-2	300 hPa
ÖLABSCHEIDUNG 18H / 40 °C / DIN 51817	5 %
KORROSIONSWIRKUNG AUF KUPFER 24H/100°C / DIN 51811	Korrosionsgrad 1
VKA SCHWEISSKRAFT / DIN 51350-4	2800 N
FZG-TEST A/2,8/50 – SCHADENSKRAFTSTUFE / DIN ISO 14635-3	> 12
FZG-TEST A/2,8/50 – SPEZIFISCHER GEWICHTSVERLUST / DIN ISO 14635-3	01 mg/kWh

Anwendung:

Divinol Lithogrease 000 wird zur Rollenschmierung von Linearführungen an Werkzeugmaschinen eingesetzt. Es ist ebenfalls zur Schmierung von mechanisch hochbelasteten Getrieben geeignet. Das Produkt ist in Zentralschmieranlagen gut förderbar. Durch seine niedrige Viskosität besitzt Divinol Lithogrease 000 ein deutlich besseres Nachfließverhalten als ein vergleichbares Fett der NLGI-Klasse 00.

<https://www.zeller-gmelin.de/zgSite/de/Lubricants/Powertrain/Schmierfette/Divinol-Lithogrease-000/p/22320?s=4301A3ED2A38461776E88124022E3B9411F657AF>

Anhang A 6 – Mistras Group Inc. Vorverstärker



Products & Systems
Division

2/4/6 Preamplifier

Description:

The 2/4/6 preamplifier was designed to be used with all available AE systems that have power supplied via the output signal BNC. It is supplied with 20/40/60 dB gain (switch selectable) and operates with either a single ended or differential sensor. Plug-in filters provide the user with flexibility to optimize sensor selectivity and noise rejection. These filters are provided in the Low Pass (LP), High Pass (HP), and Band Pass (BP) configurations, and offers constant insertion loss for easy filter swapping without the need for recalibration. Automatic Sensor Test (AST) is standard. This option provides the sensor with the ability to characterize its own condition as well as send out a simulated acoustic emission wave that other sensors can detect.

Features:

- 20/40/60 Selectable Gain
- Wide Dynamic Range > 90dB Standard
- Low Noise < 2 μ V (With Standard* Filter & Input Shorted)
- Large Output Signal 20Vpp into 50 Ω
- Single Power/Signal BNC or Optional Separate Power/Signal BNC
- Plug-in Filters (Utilizes the same filter as the SPARTAN 2000)
- High Input Impedance
- Standard Auto Sensor Test
- Input Protection



Electrical Specifications:

- Gain Selectable: 20/40/60 dB + 0.5% dB
- Input Impedance: 10K Ω // 15pF
- Power Required: 18-28V DC
- Operating Current: 30mA (With AST Installed)
28mA (Without AST Installed)
- Dynamic Range: 80dB (Utilizing an R15 Sensor)
90dB (50 Ω Input)

Environmental Specifications:

- Temperature: -40 C to +65 C

Gain Selection	20dB	40dB	60dB
• Bandwidth (-3dB):	10kHz-2.5MHz	10kHz-2.0MHz	10kHz-900kHz
• Output Voltage (50 Ω Load):	6Vpp	20Vpp	20Vpp
• CMRR (500kHz):	42dB	42dB	42dB
• Noise (RMS rti):			

Filter Frequency Response Hz	20dB	40dB	60dB	20dB	40dB	60dB
	With R15 Sensor	With R15 Sensor	With R15 Sensor	Input Shorted	Input Shorted	Input Shorted
135k-185k	3 μ V	1.4 μ V	1.5 μ V	2.0 μ V	0.6 μ V	0.42 μ V
100k-300k*	3 μ V	1.8 μ V	1.8 μ V	2.3 μ V	1 μ V	0.8 μ V
10k-2.0M	5 μ V	4 μ V	3 μ V	4 μ V	3 μ V	2.5 μ V

*Standard filter

https://www.physicalacoustics.com/content/literature/preamplifiers/2-4-6_Preamplifier_Product_Data_Sheet.pdf

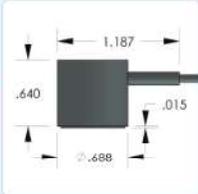
Anhang A 7 – Mistras WD AE-Sensor



PRODUCT DATA SHEET

WD Sensor

Wideband Differential Sensor

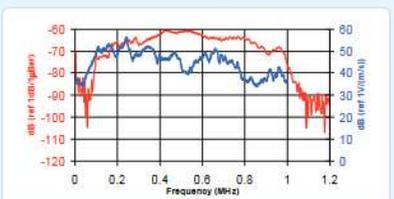


DESCRIPTION AND FEATURES

WD is a true differential wideband sensor with a very high sensitivity and bandwidth. It has a very good frequency response over the range of 100 – 900 kHz. Differential sensors differ from their general purpose counterparts by employing two sensing elements with opposite polarization directions. The two signal leads feed into a differential pre-amplifier which eliminates common-mode noise resulting in a lower noise output from the pre-amplifier. Noise improvements to the tune of 2 dB can be achieved using differential sensors over a single ended sensor. This sensor features a rugged steel construction with an integrated twin axial cable exiting on the side.

APPLICATIONS

This sensor is well suited for structural health monitoring of large structures like storage tanks, pipelines etc. This sensor is an ideal candidate for applications requiring high bandwidth for frequency analysis of the AE signals for noise discrimination and source identification. Wideband sensors are particularly well suited for research applications where a high fidelity AE response is required. It can be easily mounted using epoxy.



OPERATING SPECIFICATIONS

<i>Dynamic</i>	
Peak Sensitivity, Ref V/(m/s) 56 dB
Peak Sensitivity, Ref V/μbar -61 dB
Operating Frequency Range 125-1000 kHz
Resonant Frequency, Ref V/(m/s) 125 kHz
Resonant Frequency, Ref V/μbar 450 kHz
Directionality +/-1.5 dB
<i>Environmental</i>	
Temperature Range -65 to 177°C
Shock Limit 500 g
Completely enclosed crystal for RFI/EMI immunity	
<i>Physical</i>	
Dimensions 0.7"OD X 0.65"H
 17.8 mm OD X 16.5 mm H
Weight 20 grams
Case Material Stainless Steel
Face Material Ceramic
Connector BNC
Connector Locations Side

ORDERING INFORMATION AND ACCESSORIES

WU	WU
Cable (specify length in '-XX' m at end of PIN)	1 m
Magnetic Hold-Down	MHSTO
Pre-Amplifier	0/2/4, 2/4/6
Preamp to System Cable (specify length in 'm')	1234-X
Amplifier Subsystems	AE2A or AE5A

Sensors include
NIST Calibration Certificate & Warranty



Anhang A 8 – Mistras Micro80D AE-Sensor

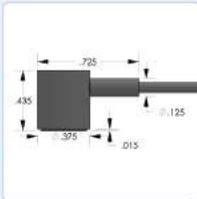


Products & Systems
Division



Micro80D Sensor

Miniature Differential Sensor

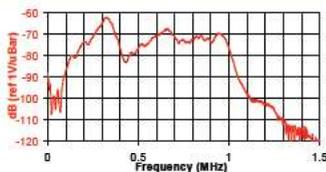


DESCRIPTION AND FEATURES

MICRO80D is a differential sensor designed to isolate the sensing terminals electrically from the cavity. This electrical isolation makes the sensor particularly useful for applications where high background electrical noise is a major concern. The sensor has a very high sensitivity and bandwidth. It has a good frequency response over the range of 175–900 kHz. The two signal leads from the sensing element feed into a differential pre-amplifier which eliminates common-mode noise resulting in a lower noise output from the pre-amplifier. This sensor features a rugged steel construction and a dual BNC connector with an integrated twin axial cable exiting on the side.

APPLICATIONS

This sensor is well suited for structural health monitoring of large structures like storage tanks, pipelines etc. Wideband sensors are well suited for research applications where a high fidelity AE response is required. It can be easily mounted using epoxy.



PRODUCT DATA SHEET

OPERATING SPECIFICATIONS

Dynamic

Peak Sensitivity, Ref V/(m/s)	57 dB
Peak Sensitivity, Ref V/√bar	-65 dB
Operating Frequency Range	175-900 kHz
Resonant Frequency, Ref V/(m/s)	250 kHz
Resonant Frequency, Ref V/√bar	325 kHz
Directionality	+/-1.5 dB

Environmental

Temperature Range	-65 to 177°C
Shock Limit	500 g
Completely enclosed crystal for RFI/EMI immunity	

Physical

Dimensions	0.4" OD X 0.5" H
	10 mm OD X 12 mm H
Weight	5 grams
Case Material	Stainless steel
Face Material	Ceramic
Connector	Dual BNC
Connector Locations	side

ORDERING INFORMATION AND ACCESSORIES

Micro80D	Micro80D
Cable (specify length -'XX' m at end of PIN)	1 m
Pre-amplifier	0/2/4, 2/4/6, 1220, IL400
Amplifier Subsystems	AE2A, AESA
Cable (Pre-amplifier to system)	1243-X

Sensors include

NIST Calibration Certificate & Warranty.



Nicht mehr länger verfügbar

Anhang A 9 – Mistras Micro80 Sensor



MISTRAS
A World of NDT Solutions

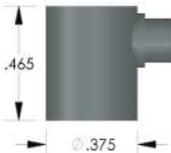
Products & Systems
Division



PRODUCT DATA SHEET

Micro80 Sensor

Very Wideband Frequency Miniature Sensor

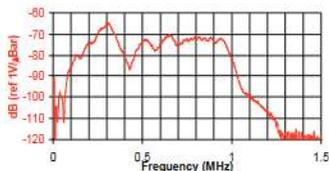


DESCRIPTION AND FEATURES

Micro80 sensor has a good frequency response over the range of 200 – 900 kHz. It has good sensitivity to AE signals even in presence of high background noise. Its small size and high bandwidth makes the sensor an ideal candidate for applications that have size and weight constraints on the sensors. The sensor features a small diameter, microdot connector exiting from the side of the sensor.

APPLICATIONS

The high sensitivity and bandwidth makes them ideal for structural health monitoring of critical structures like aircrafts, storage tanks etc. Typical applications include monitoring for fatigue and corrosion cracking in metals, delaminations and fiber breakage in composites. It can be mounted easily using epoxy.



OPERATING SPECIFICATIONS

Dynamic

Peak Sensitivity, Ref V/(m/s)57 dB
Peak Sensitivity, Ref V/μbar-65 dB
Operating Frequency Range200-900 kHz
Resonant Frequency, Ref V/(m/s)250 kHz
Resonant Frequency, Ref V/μbar325 kHz
Directionality+/- 1.5 dB

Environmental

Temperature Range-65 to 177°C
Shock Limit500 g
Completely enclosed crystal for RF/EMI immunity	

Physical

Dimensions0.4" OD X 0.5" H
10 mm OD X 12 mm H
Weight5 grams
Case MaterialStainless steel
Face MaterialCeramic
ConnectorMicrodot, 10-32
Connector LocationsSide

ORDERING INFORMATION AND ACCESSORIES

Micro80Micro80
Cable (specify cable length)1232-1
Preamp to System Cable1234-X
Pre-amplifier0/2/4, 2/4/6
Amplifier SubsystemsAE2A, AESA

Sensors include

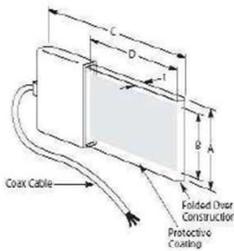
NIST Calibration Certificate & Warranty



Anhang A 10 – TE Piezo Film Sensor



DIMENSIONS



DIMENSION IN INCHES (mm)

A Film	B Electrode	C Film	D Electrode	t (μ m)	Cap (nF)
.640 (16)	.520 (13)	1.64 (41)	1.18 (30)	75	2.78

SDT SHIELDED PIEZO SENSORS

SPECIFICATIONS

- Shielded coaxial cable lead
- Shielded sensor
- Low noise
- Flexible
- Multi-purpose
- Piezo film Technology

The “S” in SDT stands for “Shielded Sensor.” SDT1 Piezo Film Sensors consist of a rectangular element of Piezo film together with a molded plastic housing and 18” of coaxial cable. The film element, screen printed with silver ink, is folded over on itself, providing self-shielding of the transducer area. This is important in applications in high EMI environments.

The SDT1 can be adhered to other surfaces using double sided adhesives, epoxy or cyanoacrylate (super glue). Care should be taken if the sensor is to be removed, as the double-side adhesive can peel the metallization from the film.

When adhered to a surface in this manner, the SDT1 is an excellent contact microphone or dynamic strain gage. The output from the SDT1 can input directly to an oscilloscope (10 M Ω preferred input impedance) or a signal analyzer.

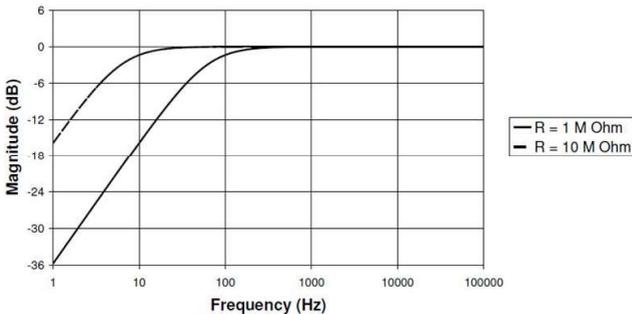
FEATURES

- Shielded piezo film sensor
- High longitudinal strain coefficient
- Integral coax cable
- Wide frequency response

APPLICATIONS

- Machine monitoring
- Acoustic emission detection
- Contact microphone
- Vibration / impact sensing
- Detecting machine tool chatter
- Acoustic pickup
- Vibration analysis for equipment and product design

SDT1-028K Low Frequency Response



Anhang A 11 – Kraftsensoren für Zug- und Druckbelastung

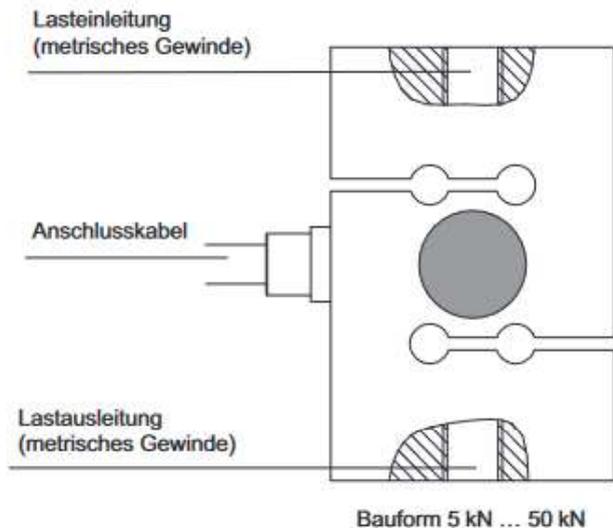
<https://www.hbm.com/fileadmin/mediapool/hbmdoc/technical/B03021.pdf>

S9M

Kraftaufnehmer

Charakteristische Merkmale

- Zug-/Druckkraftaufnehmer
- Genauigkeitsklasse 0,02
- Hermetisch gekapselt (IP68)
- Nichtrostende Materialien
- Auf Wunsch in verschiedenen Kabellängen und mit Steckermontage
- TEDS auf Wunsch



Technische Daten

Typ			S9M							
Nennkraft	F_{nom}	kN	0.5	1	2	5	10	20	50	
Genauigkeit										
Genauigkeitsklasse			0,02							
Relative Spannweite in unveränderter Einbaulage	b_{rg}	%	0,02							
Rel. Umkehrspanne	v		0,02							
Linearitätsabweichung	d_{lin}		0,02							
Relatives Kriechen	d_{Grf+E}		0,02							
Temperatureinfluss auf den Kennwert	TK_C		0,02							
Temperatureinfluss auf das Nullsignal	TK_0	%/10K	0,02							
Elektrische Kennwerte										
Nennkennwert	C_{nom}	mV/V	2							
Relative Abweichung des Nullsignals	$d_{s,0}$	%	5							
Kennwertabweichung	d_c		0,25							
Kennwertunterschied Zug/Druck	$d_{z/d}$		0,1							
Eingangswiderstand	R_e	Ω	389 ±15							
Ausgangswiderstand	R_a		350 ±1,5							
Isolationswiderstand	R_{is}	Giga Ω	>2							
Gebrauchsbereich der Speisespannung	$B_{u,gt}$	V	0,5...12							
Referenzspeisespannung	U_{ref}		5							
Anschluss			6-Leiterschaltung							
Temperatur										
Referenztemperatur	T_{ref}	°C	+23							
Nenntemperaturbereich	$B_{t,nom}$		-10...+70							
Gebrauchstemperaturbereich	$B_{t,g}$		-30...+85							
Lagertemperaturbereich	$B_{t,s}$		-30...+85							
Mechanische Kenngrößen										
Maximale Gebrauchskraft	F_G	% von F_{nom}	150							
Grenzkraft	F_L		150							
Bruchkraft	F_B		200	300			200			
Grenzdrehmoment	$M_{G,zul}$	Nm	25	50	90		150			
Statische Grenzquerkraft	F_q	% von F_{nom}	10							
Nennmessweg	s_{nom}	mm	0,35	0,4	0,35	0,1	0,2	0,2	0,4	
Grundresonanzfrequenz	f_G	kHz	0,6	0,9	1	1,7	2,1	2,3	2,5	
Relative zulässige Schwingbeanspruchung	F_{rb}	% von F_{nom}	100						70	
Allgemein Angaben										
Schutzart nach EN 60529			IP68 Prüfbedingung 1 m Wassersäule / 100 Stunden							
Federkörperwerkstoff			Rostfreier Stahl nach EN 10088-1							
Messstellenschutz			Hermetisch verschweißtes Gehäuse							

<https://www.hbm.com/fileadmin/mediapool/hbmdoc/technical/A03729.pdf>

C9C

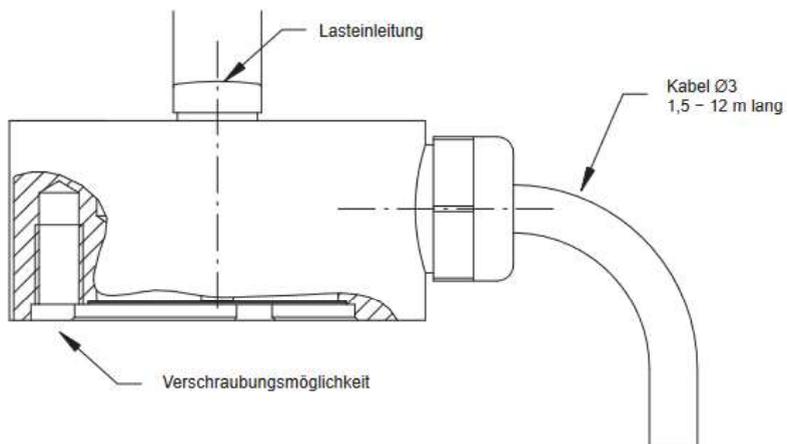
Kraftaufnehmer



Charakteristische Merkmale

- Druckkraftaufnehmer in kleiner Bauform
- Genauigkeitsklasse 0,2
- Nennkräfte 50 N ... 50 kN
- Auf Wunsch als Messkette mit fest angeschlossenem Inline-Verstärker verfügbar
- Konfigurierbar mit verschiedenen Kabellängen, auf Wunsch Stecker montage und TEDS
- Aus rostfreien Materialien hergestellt
- Hohe Steifigkeit, hervorragend für dynamische Messaufgaben geeignet
- Schleppkettentaugliches Kabel

Prinzip Kraftaufnehmer C9C



Kraftaufnehmer C9C

Nennkraft	F_{nom}	N	50 100 200						
			kN						
			0,5	1	2	5	10	20	50
Genauigkeit									
Genauigkeitsklasse									0,2
Relative Spannweite in unveränderter Einbaulage	b_{rg}	%							< 0,2
Relative Umkehrspanne	v	%							< 0,2
Linearitätsabweichung	d_{lin}	%							< 0,2
Relatives Kriechen	$d_{\text{crf+E}}$	%	< 0,2						< 0,1
Temperatureinfluss auf den Kennwert									
Im Nenntemperaturbereich	TK_C	% / 10 K							< 0,2
Im Gebrauchstemperaturbereich									
Temperatureinfluss auf das Nullsignal									
Im Nenntemperaturbereich	TK_0	% / 10 K							< 0,2
Im Gebrauchstemperaturbereich									
Elektrische Kennwerte									
Nennkennwert	C_{nom}	mV/V							1
Relative Abweichung des Nullsignals	$d_{s,0}$	mV/V							$\pm 0,2$
Kennwertabweichung	d_c	%							< 1
Eingangswiderstand	R_e	Ω	250 - 400						300 - 450
Ausgangswiderstand	R_a	Ω	200 - 400						100 - 450
Isolationswiderstand	R_{is}	Ω							$> 1 \cdot 10^9$
Gebrauchsbereich der Speisespannung	$B_{u,gt}$	V							0,5...12
Referenzspeisespannung	U_{ref}	V							5
Anschluss									4-Leiterschaltung
Temperatur									
Referenztemperatur	t_{ref}	$^{\circ}\text{C}$							23

Anhang A 12 – USB-DUXfast Specifications

↳ USB-DUXfast: Technical Specification



General

- USB 2.0, only
- Comedi Driver: www.comedi.org.
- Asynchronous sampling. This means that sampling can be performed in the background while the main application is doing something else (see comedi's 'cmd').
- Power supply via the USB, no external supply
- Asynchronous acquisition holds for up to 16 USB devices (subject to resources/ processor speed).

A/D converter

- 16 channels
- 12 bit resolution
- Single ended
- Input range (can be set by software): -0.5V, . . . , +0.5V, -0.75, . . . , +0.75V
- Input resistance: 185k (unbuffered multiplexer input)
- Recommended source resistance: less than 50R (to minimise crosstalk between inputs)
- Sampling rate (asynchronously in the background): Continuous: max 1MHz, Burst: max 30MHz (256 samples)

Digital I/O

We recommend to use the parallel printer port as digital I/O device. Comedi provides a driver which establishes a very fast digital I/O device. To synchronise a digital trigger with the analogue input feed the digital trigger into one of the analogue inputs of the USBDUXfast board. Alternatively, you can also use an USB-DUX for digital I/O. We decided against a digital I/O port at the USBDUXfast because of bandwidth limitations which would cause long latencies.

Connectivity

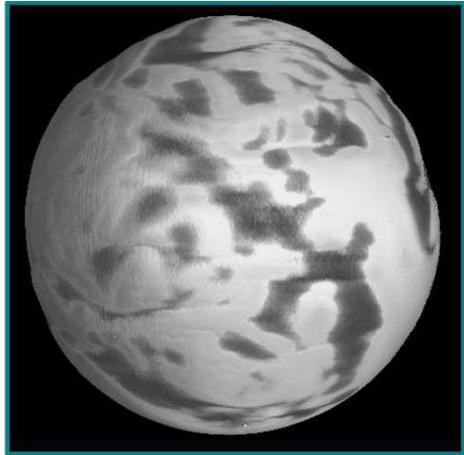
- Female 44 pin HD connector

Physical Dimensions

- Enclosure: 144x90x30mm
- Board: 136x80x15mm

<https://github.com/glasgowneuro/usbdx>

Anhang A 13 – Schadensbilder KGT



Ermüdung Kugel: Bild einer Kugel mit Ermüdungsschäden (links), Computertomographischer Scan der Kugel (rechts)



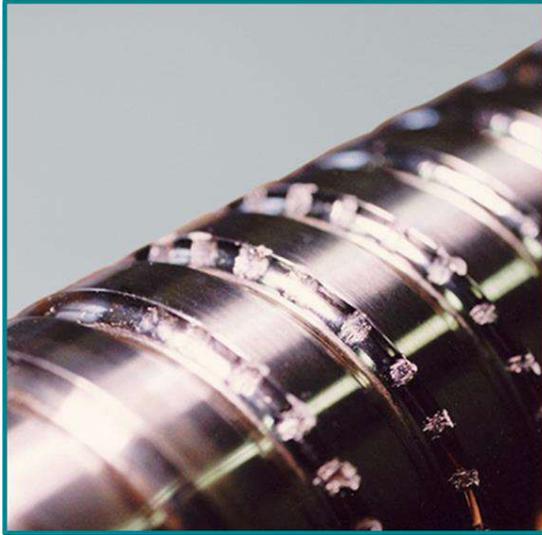
Ermüdung der Spindellaufbahn: Grübchenbildung auf Spindellaufbahn nach Ermüdungsversuch



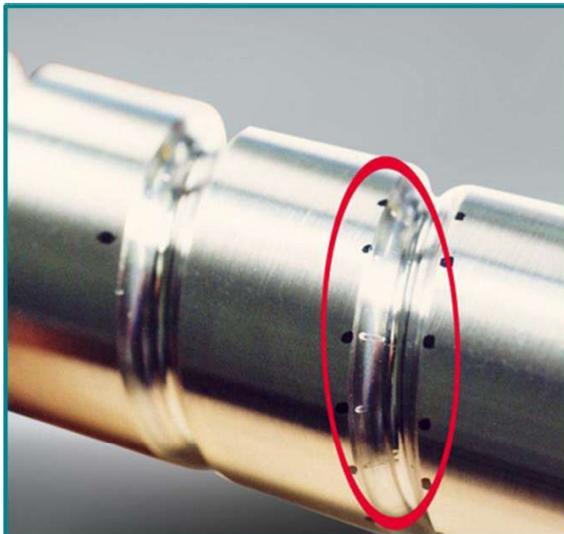
Ermüdung der Mutter: Grübchenbildung auf Muttergewindengang



Heißlaufschiäden: Verfärbung aufgrund von hohem Hitzeeintrag (ebenfalls Abplatzung von Ermüdungsschäden)



Passungsrost: (NSK Europe LTD 2021)



Eindrücke auf Laufbahn: Hervorgerufen durch Fremdpartikel oder Stöße (NSK Europe LTD 2021)



Partikel in der Mutter: durch Verschmutzung oder Verschleiß hervorgerufene Partikel in der Mutter (NSK Europe LTD 2021)



Bauteilversagen Umlenkung: Bruch der Umlenkung durch Überlast oder Verklemmen (NSK Europe LTD 2021)

Anhang A 14 – Merkmalstabelle mit Definitionen

<p>Root Mean Square</p> $RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$	<p>Standardabweichung</p> $STD = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$	<p>Envelope-Energy</p> $EE = \frac{1}{\Delta t} \int (s_u(t) - s_l(t)) dt$ <p>Berechnet die Energie der oberen $s_u(t)$ und unteren Einhüllenden $s_l(t)$ des Signals. Die Einhüllenden werden als Splines durch die lokalen Maxima bzw. Minima des Signals ermittelt.</p>
<p>Peak Faktor</p> $PF = \frac{\max\{x_i\} - \min\{x_i\}}{2}$	<p>Kurtosis</p> $KU = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s}\right)^4$	<p>Mittlere Frequenz</p> $MF = \frac{1}{N} \sum_{i=1}^N X_i$ <p>X_i ist der Amplitudenanteil des Spektrums für Frequenz-Bin f_i</p>
<p>Formfaktor</p> $FF = \frac{RMS}{\frac{1}{n} \sum_{i=1}^n x_i }$	<p>Peak-2-Peak</p> $P2P = \max\{x_i\} - \min\{x_i\}$	<p>Root Mean Square Frequenz</p> $FRMS = \sqrt{\frac{\sum_{i=1}^N f_i^2 \cdot X_i}{\sum_{i=1}^N X_i}}$
<p>Crest Faktor</p> $CF = \frac{\max\{x_i\}}{RMS}$	<p>Skewness</p> $SK = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s}\right)^3$	<p>Frequenz-Zentrum</p> $FC = \frac{\sum_{i=1}^N f_i \cdot X_i}{\sum_{i=1}^N X_i}$
<p>Margin Faktor</p> $MAF = \frac{\max\{x_i\}}{\left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i }\right)^2}$	<p>Energie</p> $E = \int x(t) ^2 dt$	
<p>Impuls Faktor</p> $IF = \frac{\max\{x_i\}}{\frac{1}{n} \sum_{i=1}^n x_i }$	<p>Mittelwert</p> $M = \sum_{i=1}^n x_i$	
<p>Zerocrossing-Rate</p> $ZCR = \frac{1}{n-1} \cdot \sum_{i=1}^{n-1} I_{R<0}(x_i, x_{i-1})$ <p>n ist die Länge des Signals x_i $I_{R<0}(x_i, x_{i-1})$ ist eine Indikator-Funktion, die angibt, ob ein Signalwert von positiv nach negativ wechselt gegenüber seinem Vorgänger</p>	<p>Binned Entropie</p> $BE = - \sum_{i=1}^n p_i \ln p_i$ <p>p_i ist die Wahrscheinlichkeit von Messwert x_i</p>	

Legende:

Zeitdomäne
Frequenzdomäne

Anhang A 15 – Vergleich von Körperschallwandlern

Wandlerprinzip	Vorteile	Nachteile
Mechanischer Taster	<ul style="list-style-type: none"> keine elektrische Speisespannung notwendig einfache Datenaufzeichnung geringe Anschaffungskosten 	<ul style="list-style-type: none"> unempfindlich, d. h. nur für große Schwingungsamplituden nur bei tiefen Frequenzen verwendbar Fühlerspitze nutzt durch mechanischen Kontakt ab kein elektrisches Ausgangssignal für die Weiterverarbeitung die schwingende Struktur wird durch den Sensor belastet richtungsempfindlich
Wirbelstromwandler	<ul style="list-style-type: none"> berührungsfrei verschleißfrei elektrisches Ausgangssignal (proportional der Relativbewegung) Frequenzbereich praktisch von 0 Hz bis etwa 2 kHz 	<ul style="list-style-type: none"> benötigt Versorgungsspannung Messobjekt muss elektromagnetisch leitend sein geringe Messdynamik Veränderungen der magnetischen Eigenschaften oder geometrische Ungenauigkeiten des zu messenden Objektes können fehlerhafte Signalanteile verursachen
Elektrodynamischer Wandler	<ul style="list-style-type: none"> keine Versorgungsspannung das Ausgangssignal hat eine niedrige Impedanz, kann also über lange Verbindungskabel geführt werden 	<ul style="list-style-type: none"> misst erst ab ca. 10 Hz bis maximal etwa 1 kHz (hoch abgestimmtes System) bewegliche Teile (Verschleiß) i.A. groß und schwer beeinflusst mit seiner Masse den Prüfling richtungsempfindlich unterliegt magnetischen Einflüssen (z. B. bei der Messung elektrischer Motoren)
Elektromagnetischer Wandler	<ul style="list-style-type: none"> berührungsfreie Messung, d. h. Messobjekt wird mechanisch nicht belastet keine Versorgungsspannung keine beweglichen Teile niederohmig kann invers auch als Anregesystem verwendet werden (typische Spulenwechselspannung 70 V) 	<ul style="list-style-type: none"> linearer Frequenzumfang nur bis etwa 2 kHz Empfindlichkeit hängt vom Ruheabstand ab Messobjekt muss magnetisch leitend sein nur Relativmessungen schwer zu kalibrieren wegen nichtlinearer Verzerrungen nur für relativ kleine Bewegungsamplituden geeignet

Wandlerprinzip	• Vorteile	• Nachteile
Laser-Dopplervibrometer	<ul style="list-style-type: none"> • berührungslose Messung • Hohe Dynamik (80 dB) • Breiter Messfrequenzbereich bis 20 kHz 	<ul style="list-style-type: none"> • Oberfläche des Messobjektes muss das Laserlicht reflektieren können • Anschaffungskosten relativ hoch • mechanische Abmessungen von Geräten nicht klein
Piezoelektrischer Wandler	<ul style="list-style-type: none"> • hohe Dynamik (160 dB) • keine beweglichen Teile • je nach Bauform großer Frequenzbereich und große Empfindlichkeit • kleine sehr leichte Bauformen möglich • in allen drei Raumrichtungen montierbar • hohe Stabilität der Eigenschaften 	<ul style="list-style-type: none"> • Hochohmigkeit erfordert entsprechende Signalaufbereitung • keine wirkliche statische Messung • möglicher störender Einfluss durch äußere Temperaturgradienten
Kapazitiver Wandler	<ul style="list-style-type: none"> • Messung auch quasistatischer Beschleunigungen • hohe Empfindlichkeit • eingebaute Elektronik möglich • potenzialfreies Gehäuse 	<ul style="list-style-type: none"> • benötigt externe elektrische Versorgungsspannung • Nullabgleich vor jeder Messung nötig • Frequenzbereich auf tiefe Frequenzen beschränkt (z. B. 0 bis 150 Hz) • eingeschränkte Messdynamik • möglicher Einfluss von Streu- oder Kabelkapazitäten
Piezoresistiver Wandler	<ul style="list-style-type: none"> • integrierter kompakter und leichter Aufbau auf einem Chip • relativ hohe Empfindlichkeit (einige mV/g) • breiter Frequenzbereich (einige tausend Hertz bis hinunter zu statischen Messungen) • unkomplizierte Signalaufbereitung • geringe innere Dämpfung und damit auch wenig Phasenverfälschungen • keine Anfälligkeit gegenüber Streu- oder Kabelkapazitäten. 	<ul style="list-style-type: none"> • benötigt externe elektrische Versorgungsspannung • relativ großer Messfehler (typisch 5 bis 10 %) • Offsetspannungen erfordern Nullabgleich • Temperaturabhängigkeiten (ein ΔT von 5 °C verursacht etwa 1% Änderung in der Empfindlichkeit)
Optisches Mikrofon (©Xarion)	<ul style="list-style-type: none"> • Membranfreies Mikrofon • Berührungslos • Hohe Bandbreite: 50kHz bis 2 MHz • Geringes Eigenrauschen • Hoher Dynamikbereich: 30-130 dB 	<ul style="list-style-type: none"> • Es wird nur indirekt über den emittierten Luftschall der eigentliche Körperschall gemessen • Hohe Anschaffungskosten • Neues Produkt

Entnommen aus (Möser 2018) und <https://xarion.com>

Anhang A 16 – Programmcode für Kniepunktsuche

Kniepunkt-Suche – Pseudo Code	
	Input: f_i Frequenzen im Spektrum, p_i Amplitudenwerte im Spektrum
1.	function $[f_c, p_c] = \text{kneePointSearch}(f_i, p_i)$
2.	$[f_{is}, p_{is}] = \text{sort}(p_i, \text{Descending})$ # Sortiere die Frequenzinhalte absteigend nach Größe
3.	$\text{line} = p_{i,\text{end}} - p_{i,1}$ # Konstruiere Gerade zwischen Start und Endpunkt von p_i
4.	$d_i = \text{distance}(\text{line}, p_i)$ # Bestimme Abstand der Geraden zu jedem Wert in p_i
5.	$[f_{kp}, p_{kp}] = \text{max}(d_i)$ # Das Maxima in d_i entspricht dem Kniepunkt p_{kp} und zugehöriger Frequenz f_{kp}
6.	Find all $p_c = p_{is} > p_{kp}$ and corresponding f_c
7.	end
	Output: f_c, p_c Hauptfrequenzen

Anhang A 17 – Programmcode für DBSCAN

DBSCAN Algorithmus - Pseudo Code

Input: D Distanzmatrix der zu clusternden Punkte, eps Radius der benachbarten Clusterpunkte, $minPts$ Mindestanzahl der Datenpunkte pro Cluster

```

1. function DBSCAN( $D, eps, minPts$ )
2.      $C=0$ 
3.     for each unvisited point  $P$  in dataset  $D$ 
4.         mark  $P$  as visited
5.          $NeighborPts = regionQuery(P, eps)$ 
6.         if  $sizeof(NeighborPts) < minPts$ 
7.             mark  $P$  as NOISE
8.         else
9.              $C = \text{next Cluster}$ 
10.             $expandCluster(P, NeighborPts, C, eps, minPts)$ 
11.        end
12.    end
13.
14.    function expandCluster( $P, NeighborPts, C, eps, minPts$ )
15.        add  $P$  to cluster  $C$ 
16.        for each point  $P'$  in  $NeighborPts$ 
17.            if  $P'$  is not visited
18.                mark  $P'$  as visited
19.                 $NeighborPts' = regionQuery(P', eps)$ 
20.                if  $sizeof(NeighborPts') \geq minPts$ 
21.                     $NeighborPts = NeighborPts.join(NeighborPts')$ 
22.            end
23.        end
24.        if  $P'$  is not yet member of any cluster
25.            add  $P'$  to cluster  $C$ 
26.        end
27.    end
28. end
29.
30. function regionQuery( $P, eps$ )
31.    return all points within  $P$ 's  $eps$ -neighborhood (including  $P$ )
32. end
Output: ClusterIndices  $C$ 

```

Anhang A 18 – Programmcode für Cluster Match

Cluster Match - Pseudo Code

Input: D_i, D_j sind Datensets zum Zeitpunkt t_i und t_j , mit $t_j > t_i$, $D_i: \{X_k\}$ und $D_j: \{Y_m\}$
 X_k und Y_m sind die in den Datensets enthaltenen Cluster
 τ_{match} ist ein Grenzwert, ab dem zwei Cluster als übereinstimmend definiert werden (hier: 0.7)

1. **function** *areClusterMatches* (D_i, D_j, τ_{match})
2. overlapMatrix = **0** # initialisieren
3. **for** $k = 1$ **to** sizeof($D_i, 1$)
4. **for** $m = 1$ **to** sizeof($D_j, 1$)
5. $X_k = D_i[k]$
6. $Y_m = D_j[m]$
7. overlap = *getClusterOverlap* (X_k, Y_m)
8. overlapMatrix(k, m) = overlap
9. **end**
10. **end**
11. matchMatrix = overlapMatrix
12. matchMatrix(matchMatrix > τ_{match}) = 1
13. matchMatrix(matchMatrix ≤ τ_{match}) = 0
14. **return** matchMatrix, overlapMatrix
15. **end**
- 16.
17. **function** *getClusterOverlap* (X, Y)
18. M = ismember(X, Y) # returns the elements of X in Y
19. overlap = sizeof(M) / sizeof(X)
20. **return** overlap
21. **end**

Ausgabe: boolean true/false

Anhang A 19 – Programmcode für Externe Transitionen

External Transitions – Pseudo Code

```

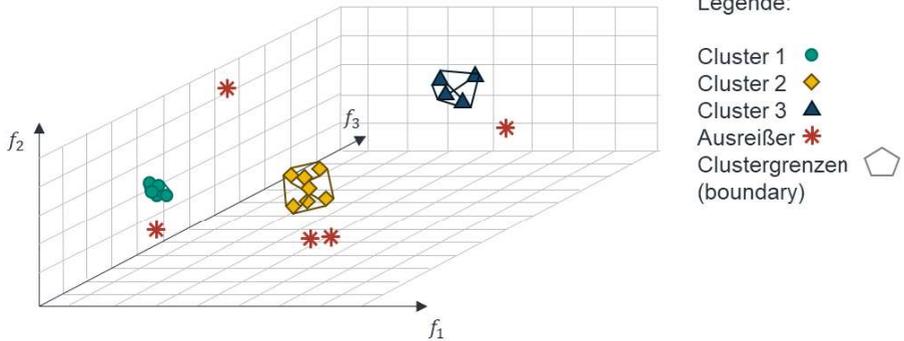
Input:  $D_i, D_j$  sind Datensets zum Zeitpunkt  $t_i$  und  $t_j$ , mit  $t_j > t_i$ ,  $D_i: \{X_k\}$  und  $D_j: \{Y_m\}$ 
 $X_k$  und  $Y_m$  sind die in den Datensets enthaltenen Cluster
1. function trackExternalTransitions ( $D_i, D_j$ )
2.   matchMatrix, overlapMatrix = areClusterMatches( $D_i, D_j, \tau_{match}$ )
3.   transitions = {} # list of transitions
4.   mergedColumns = {} # list of columns that have been merged already
5.   for r = 1 to sizeof(matchMatrix, 1)
6.     matchRow = matchMatrix(r, :) # extrahiere Zeile aus Matrix
7.     if sum(matchRow == 1) == 1 # prüfe, ob genau ein Match Eintrag in Zeile ist
8.       matchColumn = matchRow == 1 # extrahiere Spaltenindex mit Match
          Eintrag
9.       if sum(matchMatrix(:, matchColumn) == 1) == 1
10.        transitions.add(SURVIVE_TRANSITION)
11.       else if sum(matchMatrix(:, matchColumn) == 1) > 1
12.         if not empty(mergedColumn)
13.           if sum(mergedColumns == matchColumn) == 0
14.             inds = (matchMatrix(:, matchColumn) == 1)
15.             if not empty(inds)
16.               transitions.add(MERGE_TRANSITION)
17.             end
18.           end
19.         else
20.           inds = (matchMatrix(:, matchColumn) == 1)
21.           if not empty(inds)
22.             transitions.add(MERGE_TRANSITION)
23.           end
24.         end
25.       else
26.         overlapRow = overlapMatrix(r, :)
27.         if sum(overlapRow >  $\tau_{split}$ ) > 1
28.           if sum(overlapRow) >  $\tau_{match}$ 
29.             transitions.add(SPLIT_TRANSITION)
30.           end
31.         else transitions.add(VANISH_TRANSITION)
32.       end
33.     end
34.   end
35.   for c = 1 to sizeof(overlapMatrix, 2)
36.     overlapColumn = overlapMatrix(:, c) # extrahiere Spalte aus Matrix
37.     if sum(overlapColumn <  $\tau_{split}$ ) == sizeof(overlapMatrix, 1)
38.       transitions.add(CREATE_TRANSITION)
39.     end
40.   end
41.   return transitions
42. end
Ausgabe: gibt die gefundenen Transitionen zurück

```

Anhang A 20 – Clusterergebnis-Diagramme

Clustering – 3D Merkmalsraum

Clusterergebnis

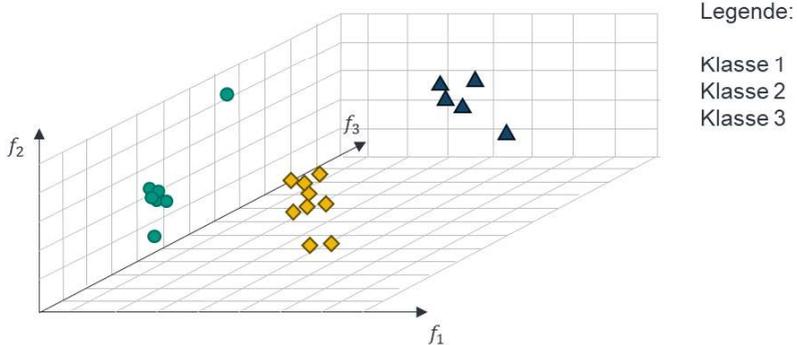


f_i sind Merkmale, die für das Clustern genutzt werden.

Ausreißer (en. *outlier*) werden mit * markiert, diese Datenpunkte können während der Clusterbildung keinem Cluster zugeordnet werden.

Je Cluster lassen sich Clustergrenzen berechnen, die alle Punkte des Clusters einschließen.

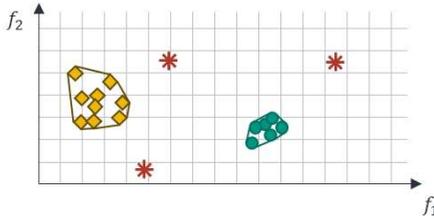
Ground Truth



Der *ground truth* beschreibt die tatsächliche Klassenzugehörigkeit einzelner Datenpunkte. Er wird dargestellt, um die Güte der eigentlichen Clusteroperation (oben) zu bewerten.

Clustering – 2D Merkmalsraum

Clusterergebnis



Legende:

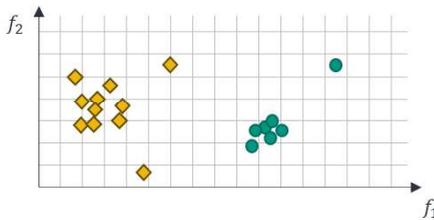
- Cluster 1 ●
- Cluster 2 ◆
- Ausreißer *
- Clustergrenzen (boundary) ◻

f_i sind Merkmale, die für das Clustern genutzt werden.

Ausreißer (en. *outlier*) werden mit * markiert, diese Datenpunkte konnte während der Clusterbildung keinem Cluster zugeordnet werden.

Je Cluster lassen sich Clustergrenzen berechnen, die alle Punkte des Clusters einschließen.

Ground Truth



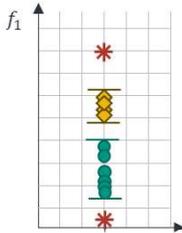
Legende:

- Klasse 1 ●
- Klasse 2 ◆

Der *ground truth* beschreibt die tatsächlichen Klassenzugehörigkeit einzelner Datenpunkte. Er wird dargestellt, um die Güte der eigentlichen Clusteroperation (oben) zu bewerten.

Clustering – 1D Merkmalsraum

Clusterergebnis



Legende:

- Cluster 1 ●
- Cluster 2 ◆
- Ausreißer *
- Clustergrenzen — (boundary)

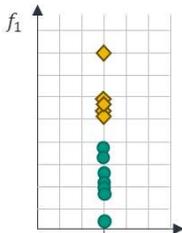
f_i sind Merkmale, die für das Clustern genutzt werden.

Ausreißer (en. *outlier*) werden mit * markiert, diese Datenpunkte konnte während der Clusterbildung keinem Cluster zugeordnet werden.

Je Cluster lassen sich Clustergrenzen berechnen, die alle Punkte des Clusters einschließen.

Für den 1D-Fall sind alle Merkmale auf einer Linie angeordnet (Beispiel: MSE-Merkmal). Cluster ergeben sich, wenn auf dieser Linie Gruppierungen entstehen, die die Ähnlichkeitskriterien des Clusteralgorithmus erfüllen.

Ground Truth



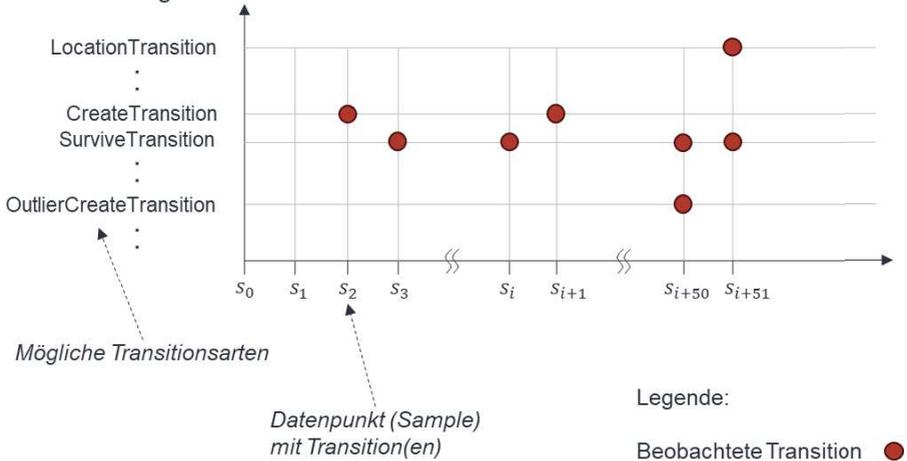
Legende:

- Klasse 1 ●
- Klasse 2 ◆

Der *ground truth* beschreibt die tatsächlichen Klassenzugehörigkeit einzelner Datenpunkte. Er wird dargestellt, um die Güte der eigentlichen Clusteroperation (oben) zu bewerten.

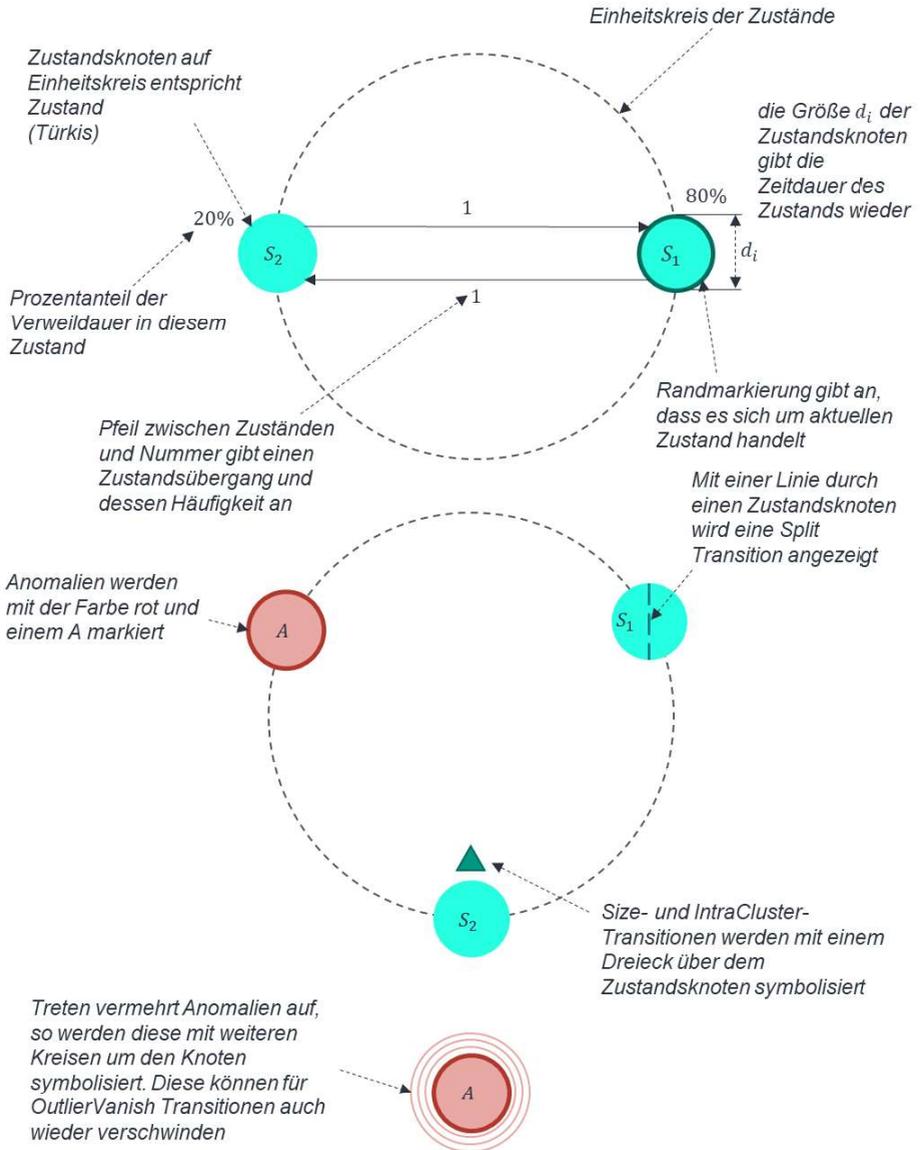
Anhang A 21 – Transitionsdiagramm

Transitionsdiagramm



Das Diagramm zeigt die Gesamtheit der detektierten Transitionen im Beobachtungszeitraum. Die Abzisse (x-Achse) stellt die Zeitachse bzw. Anzahl der Datenpunkte dar. Für jeden Datenpunkt, der geclustert wurde, werden die auch die Transitionen erfasst. Diese werden für jeden Datenpunkt auf der Ordinate (y-Achse) aufgetragen. Liegen eine oder mehrere Transitionen für einen Datenpunkt vor, so wird dies mit den roten Markierungen für den jeweiligen Datenpunkt festgehalten.

Anhang A 22 – Zustandsdiagramme



Anhang A 23 – Ansatzfunktion für Clustergrößenverlauf

$$f_1(t) = a_1$$

$$f_2(t) = a_1 + a_2 \cdot t$$

$$f_3(t) = a_1 + a_2 \cdot t^2$$

$$f_4(t) = a_1 + a_2 \cdot \frac{a_3 \cdot e^t + a_4 \cdot e^{-t}}{2}$$

$$f_5(t) = a_1 + a_2 \cdot e^{a_3 t}$$

$$f_6(t) = a_1 + a_2 \cdot \log(a_3 \cdot t)$$

$$f_7(t) = a_1 + \frac{1}{\sqrt{2\pi \cdot \sigma^2}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Veröffentlichungen des Autors

Spohrer et al. 2017

Spohrer, A.; Leitold, L.; Straub, F.; Hillenbrand, J. & Fleischer, J. (2017), *Ressourceneffizienter Kugelgewindetrieb durch adaptive Schmierung. Reibung, Schmierung und Verschleiß - Forschung und praktische Anwendungen*, GfT, Aachen, Gesellschaft für Tribologie e.V. ISBN: 978-3-9817451-2-2.

Hillenbrand, Spohrer & Fleischer 2018

Hillenbrand, J.; Spohrer, A. & Fleischer, J. (2018), „Zustandsüberwachung bei Kugelgewindetrieben. Integration von DMS-Sensorik in Kugelgewindetriebemuttern“, *wt Werkstattstechnik online*(7/8) [13.02.2019].

Gönnheimer et al. 2019

Gönnheimer, P.; Hillenbrand, J.; Betz-Mors, T.; Bischof, P.; Mohr, L. & Fleischer, J. (2019), „Auto-configuration of a digital twin for machine tools by intelligent crawling“ in *Production at the leading edge of technology*, Hrsg. J. P. Wulfsberg, W. Hintze & B.-A. Behrens, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 543–552. ISBN: 978-3-662-60416-8.

Hillenbrand & Fleischer 2020

Hillenbrand, J. & Fleischer, J. (2020), „Autoconfiguration of a Vibration-Based Anomaly Detection System with Sparse a-priori Knowledge Using Autoencoder Networks“ in *Production at the leading edge of technology. Proceedings of the 10th Congress of the German Academic Association for Production Technology (WGP), Dresden, 23-24 September 2020*, Hrsg. J. P. Wulfsberg, W. Hintze, B.-A. Behrens, A. Brosius & S. Ihlenfeldt, Springer Berlin; Springer, Berlin, S. 518–527. ISBN: 978-3-662-62137-0.

Veith et al. 2020

Veith, M.; Zimmermann, A.; Hillenbrand, J. & Fleischer, J. (2020), „Detektion des Vorspannungsverlusts in Kugelgewindetrieben“, *wt Werkstattstechnik online*(7/8), S. 485. <https://e-paper.vdi-fachmedien.de/werkstattstechnik/2020#03-08-2020> [06.10.2020].

Hillenbrand, Detroy & Fleischer 2021

Hillenbrand, J.; Detroy, J. & Fleischer, J. (2021), „Investigation of defects in roll contacts of machine elements with Acoustic Emission and Unsupervised Machine Learning“, *IOP Conference Series: Materials Science and Engineering*, 1193(1), S. 12085. DOI: 10.1088/1757-899X/1193/1/012085.

Hillenbrand & Fleischer 2021

Hillenbrand, J. & Fleischer, J. (2021), „Unsupervised Detection of State Changes During Operation of Machine Elements“, *Journal of Machine Engineering*, S. 35–46. DOI: 10.36897/jme/136311.

Hillenbrand et al. 2021

Hillenbrand, J.; Gönzheimer, P.; Gerlitz, E. & Fleischer, J. (2021), „Design and implementation of a holistic framework for data integration in industrial machine and sensor networks“, *Procedia CIRP*, 104, S. 1771–1776. DOI: 10.1016/j.procir.2021.11.298.

Wegmann et al. 2021

Wegmann, M.; Zipperling, D.; Hillenbrand, J. & Fleischer, J. (24. Juni 2021), *A review of systematic selection of clustering algorithms and their evaluation*. <http://arxiv.org/pdf/2106.12792v1>.

Band 7

Dr.-Ing. Paul Stauss

Automatisierte Inbetriebnahme und Sicherung der Zuverlässigkeit und Verfügbarkeit numerisch gesteuerter Fertigungseinrichtungen

Band 8

Dr.-Ing. Günter Möckesch

Konzeption und Realisierung eines strategischen, integrierten Gesamtplanungs- und -bearbeitungssystems zur Optimierung der Drehteilorganisation für auftragsbezogene Drehereien

Band 9

Dr.-Ing. Thomas Oestreicher

Rechnergestützte Projektierung von Steuerungen

Band 10

Dr.-Ing. Thomas Selinger

Teilautomatisierte werkstattnahe NC-Programmerstellung im Umfeld einer integrierten Informationsverarbeitung

Band 11

Dr.-Ing. Thomas Buchholz

Prozessmodell Fräsen, Rechnerunterstützte Analyse, Optimierung und Überwachung

Band 12

Dr.-Ing. Bernhard Reichling

Lasergestützte Positions- und Bahnvermessung von Industrierobotern

Band 13

Dr.-Ing. Hans-Jürgen Lesser

Rechnergestützte Methoden zur Auswahl anforderungsgerechter Verbindungselemente

Band 14

Dr.-Ing. Hans-Jürgen Lauffer

Einsatz von Prozessmodellen zur rechnerunterstützten Auslegung von Räumwerkzeugen

Band 15

Dr.-Ing. Michael C. Wilhelm

Rechnergestützte Prüfplanung im Informationsverbund moderner Produktionssysteme

Band 16

Dr.-Ing. Martin Ochs

Entwurf eines Programmsystems zur wissensbasierten Planung und Konfigurierung

Band 17

Dr.-Ing. Heinz-Joachim Schneider

Erhöhung der Verfügbarkeit von hochautomatisierten Produktionseinrichtungen mit Hilfe der Fertigungsleittechnik

Band 18

Dr.-Ing. Hans-Reiner Ludwig

Beanspruchungsanalyse der Werkzeugschneiden beim Stirnplanfräsen

Band 19

Dr.-Ing. Rudolf Wieser

Methoden zur rechnergestützten Konfigurierung von Fertigungsanlagen

Band 20

Dr.-Ing. Edgar Schmitt

Werkstattsteuerung bei wechselnder Auftragsstruktur

Band 21

Dr.-Ing. Wilhelm Enderle

Verfügbarkeitssteigerung automatisierter Montagesysteme durch selbsttätige Behebung prozessbedingter Störungen

Band 22

Dr.-Ing. Dieter Buchberger

Rechnergestützte Strukturplanung von Produktionssystemen

Band 23

Prof. Dr.-Ing. Jürgen Fleischer

Rechnerunterstützte Technologieplanung für die flexibel automatisierte Fertigung von Abkantteilen

Band 24

Dr.-Ing. Lukas Loeffler

Adaptierbare und adaptive Benutzerschnittstellen

Band 25

Dr.-Ing. Thomas Friedmann

Integration von Produktentwicklung und Montageplanung durch neue rechnergestützte Verfahren

Band 26

Dr.-Ing. Robert Zurrin

Variables Formhonen durch rechnergestützte Hornprozesssteuerung

Band 27

Dr.-Ing. Karl-Heinz Bergen

Langhub-Innenrundhonen von Grauguss und Stahl mit einem elektromechanischem Vorschubsystem

Band 28

Dr.-Ing. Andreas Liebisch

Einflüsse des Festwalzens auf die Eigenspannungsverteilung und die Dauerfestigkeit einsatzgehärteter Zahnräder

Band 29

Dr.-Ing. Rolf Ziegler

Auslegung und Optimierung schneller Servopumpen

Band 30

Dr.-Ing. Rainer Bartl

Datenmodellgestützte Wissensverarbeitung zur Diagnose und Informationsunterstützung in technischen Systemen

Band 31

Dr.-Ing. Ulrich Golz

Analyse, Modellbildung und Optimierung des Betriebsverhaltens von Kugelgewindetrieben

Band 32

Dr.-Ing. Stephan Timmermann

Automatisierung der Feinbearbeitung in der Fertigung von Hohlformwerkzeugen

Band 33

Dr.-Ing. Thomas Noe

Rechnergestützter Wissenserwerb zur Erstellung von Überwachungs- und Diagnoseexpertensystemen für hydraulische Anlagen

Band 34

Dr.-Ing. Ralf Lenschow

Rechnerintegrierte Erstellung und Verifikation von Steuerungsprogrammen als Komponente einer durchgängigen Planungsmethodik

Band 35

Dr.-Ing. Matthias Kallabis

Räumen gehärteter Werkstoffe mit kristallinen Hartstoffen

Band 36

Dr.-Ing. Heiner-Michael Honeck

Rückführung von Fertigungsdaten zur Unterstützung einer fertigungsgerechten Konstruktion

Band 37

Dr.-Ing. Manfred Rohr

Automatisierte Technologieplanung am Beispiel der Komplettbearbeitung auf Dreh-/Fräszellen

Band 38

Dr.-Ing. Martin Steuer

Entwicklung von Softwarewerkzeugen zur wissensbasierten Inbetriebnahme von komplexen Serienmaschinen

Band 39

Dr.-Ing. Siegfried Beichter

Rechnergestützte technische Problemlösung bei der Angebotserstellung von flexiblen Drehzellen

Band 40

Dr.-Ing. Thomas Steitz

Methodik zur marktorientierten Entwicklung von Werkzeugmaschinen mit Integration von funktionsbasierter Strukturierung und Kostenschätzung

Band 41

Dr.-Ing. Michael Richter

Wissensbasierte Projektierung elektrohydraulischer Regelungen

Band 42

Dr.-Ing. Roman Kuhn

Technologieplanungssystem Fräsen. Wissensbasierte Auswahl von Werkzeugen, Schneidkörpern und Schnittbedingungen für das Fertigingsverfahren Fräsen

Band 43

Dr.-Ing. Hubert Klein

Rechnerunterstützte Qualitätssicherung bei der Produktion von Bauteilen mit frei geformten Oberflächen

Band 44

Dr.-Ing. Christian Hoffmann

Konzeption und Realisierung eines fertigungsintegrierten Koordinatenmessgerätes

Band 45

Dr.-Ing. Volker Frey

Planung der Leittechnik für flexible Fertigungsanlagen

Band 46

Dr.-Ing. Achim Feller

Kalkulation in der Angebotsphase mit dem selbsttätig abgeleiteten Erfahrungswissen der Arbeitsplanung

Band 47

Dr.-Ing. Markus Klaiber

Produktivitätssteigerung durch rechnerunterstütztes Einfahren von NC-Programmen

Band 48

Dr.-Ing. Roland Minges

Verbesserung der Genauigkeit beim fünffachsignen Fräsen von Freiformflächen

Band 49

Dr.-Ing. Wolfgang Bernhart

Beitrag zur Bewertung von Montagevarianten: Rechnergestützte Hilfsmittel zur kostenorientierten, parallelen Entwicklung von Produkt und Montage system

Band 50

Dr.-Ing. Peter Ganghoff

**Wissensbasierte Unterstützung der Planung technischer Systeme:
Konzeption eines Planungswerkzeuges und exemplarische Anwendung
im Bereich der Montagesystemplanung**

Band 51

Dr.-Ing. Frank Maier

**Rechnergestützte Prozessregelung beim flexiblen Gesenkbiegen durch
Rückführung von Qualitätsinformationen**

Band 52

Dr.-Ing. Frank Debus

**Ansatz eines rechnerunterstützten Planungsmanagements für die Planung
in verteilten Strukturen**

Band 53

Dr.-Ing. Joachim Weinbrecht

**Ein Verfahren zur zielorientierten Reaktion auf Planabweichungen in der
Werkstattregelung**

Band 54

Dr.-Ing. Gerd Herrmann

**Reduzierung des Entwicklungsaufwandes für anwendungsspezifische
Zellenrechnersoftware durch Rechnerunterstützung**

Band 55

Dr.-Ing. Robert Wassmer

**Verschleissentwicklung im tribologischen System Fräsen: Beiträge
zur Methodik der Prozessmodellierung auf der Basis tribologischer
Untersuchungen beim Fräsen**

Band 56

Dr.-Ing. Peter Uebelhoer

Inprocess-Geometriemessung beim Honen

Band 57

Dr.-Ing. Hans-Joachim Schelberg

Objektorientierte Projektierung von SPS-Software

Band 58

Dr.-Ing. Klaus Boes

Integration der Qualitätsentwicklung in featurebasierte CAD/CAM-Prozessketten

Band 59

Dr.-Ing. Martin Schreiber

Wirtschaftliche Investitionsbewertung komplexer Produktionssysteme unter Berücksichtigung von Unsicherheit

Band 60

Dr.-Ing. Ralf Steuernagel

Offenes adaptives Engineering-Werkzeug zur automatisierten Erstellung von entscheidungsunterstützenden Informationssystemen

Band 62

Dr.-Ing. Uwe Schauer

Qualitätsorientierte Feinbearbeitung mit Industrierobotern: Regelungsansatz für die Freiformflächenfertigung des Werkzeug- und Formenbaus

Band 63

Dr.-Ing. Simone Loeper

Kennzahlengestütztes Beratungssystem zur Verbesserung der Logistikleistung in der Werkstattfertigung

Band 64

Dr.-Ing. Achim Raab

Räumen mit hartstoffbeschichteten HSS-Werkzeugen

Band 65,

Dr.-Ing. Jan Erik Burghardt

Unterstützung der NC-Verfahrenskette durch ein bearbeitungselementorientiertes, lernfähiges Technologieplanungssystem

Band 66

Dr.-Ing. Christian Tritsch

Flexible Demontage technischer Gebrauchsgüter: Ansatz zur Planung und (teil-)automatisierten Durchführung industrieller Demontageprozesse

Band 67

Dr.-Ing. Oliver Eitrich

Prozessorientiertes Kostenmodell für die entwicklungsbegleitende Vorkalkulation

Band 68

Dr.-Ing. Oliver Wilke

Optimierte Antriebskonzepte für Räummaschinen - Potentiale zur Leistungssteigerung

Band 69

Dr.-Ing. Thilo Sieth

Rechnergestützte Modellierungsmethodik zerspantechnologischer Prozesse

Band 70

Dr.-Ing. Jan Linnenbuerger

Entwicklung neuer Verfahren zur automatisierten Erfassung der geometrischen Abweichungen an Linearachsen und Drehschwenkköpfen

Band 71

Dr.-Ing. Mathias Klimmek

Fraktionierung technischer Produkte mittels eines frei beweglichen Wasserstrahlwerkzeuges

Band 72

Dr.-Ing. Marko Hartel

Kennzahlenbasiertes Bewertungssystem zur Beurteilung der Demontage- und Recyclingeignung von Produkten

Band 73

Dr.-Ing. Jörg Schaupp

Wechselwirkung zwischen der Maschinen- und Hauptspindeltriebsdynamik und dem Zerspanprozess beim Fräsen

Band 74

Dr.-Ing. Bernhard Neisius

Konzeption und Realisierung eines experimentellen Telemanipulators für die Laparoskopie

Band 75

Dr.-Ing. Wolfgang Walter

Erfolgsversprechende Muster für betriebliche Ideenfindungsprozesse. Ein Beitrag zur Steigerung der Innovationsfähigkeit

Band 76

Dr.-Ing. Julian Weber

Ein Ansatz zur Bewertung von Entwicklungsergebnissen in virtuellen Szenarien

Band 77

Dr.-Ing. Dipl. Wirtsch.-Ing. Markus Posur

Unterstützung der Auftragsdurchsetzung in der Fertigung durch Kommunikation über mobile Rechner

Band 78

Dr.-Ing. Frank Fleissner

Prozessorientierte Prüfplanung auf Basis von Bearbeitungsobjekten für die Kleinserienfertigung am Beispiel der Bohr- und Fräsbearbeitung

Band 79

Dr.-Ing. Anton Haberkern

Leistungsfähigere Kugelgewindetriebe durch Beschichtung

Band 80

Dr.-Ing. Dominik Matt

Objektorientierte Prozess- und Strukturinnovation (OPUS)

Band 81

Dr.-Ing. Jürgen Andres

Robotersysteme für den Wohnungsbau: Beitrag zur Automatisierung des Mauerwerkbaus und der Elektroinstallation auf Baustellen

Band 82

Dr.-Ing. Dipl. Wirtschaftsing. Simone Riedmiller

Der Prozesskalender - Eine Methodik zur marktorientierten Entwicklung von Prozessen

Band 83

Dr.-Ing. Dietmar Tilch

Analyse der Geometrieparameter von Präzisionsgewinden auf der Basis einer Least-Squares-Estimation

Band 84

Dr.-Ing. Dipl.-Kfm. Oliver Stiefbold

Konzeption eines reaktionsschnellen Planungssystems für Logistikketten auf Basis von Software-Agenten

Band 85

Dr.-Ing. Ulrich Walter

Einfluss von Kühlschmierstoff auf den Zerspanprozess beim Fräsen: Beitrag zum Prozessverständnis auf Basis von zerspantechnischen Untersuchungen

Band 86

Dr.-Ing. Bernd Werner

Konzeption von teilautonomer Gruppenarbeit unter Berücksichtigung kultureller Einflüsse

Band 87

Dr.-Ing. Ulf Osmers

Projektieren Speicherprogrammierbarer Steuerungen mit Virtual Reality

Band 88

Dr.-Ing. Oliver Doerfel

Optimierung der Zerspantechnik beim Fertigungsverfahren Wälzstossen: Analyse des Potentials zur Trockenbearbeitung

Band 89

Dr.-Ing. Peter Baumgartner

Stufenmethode zur Schnittstellengestaltung in der internationalen Produktion

Band 90

Dr.-Ing. Dirk Vossmann

Wissensmanagement in der Produktentwicklung durch Qualitätsmethodenverbund und Qualitätsmethodenintegration

Band 91

Dr.-Ing. Martin Plass

Beitrag zur Optimierung des Honprozesses durch den Aufbau einer Honprozessregelung

Band 92

Dr.-Ing. Titus Konold

Optimierung der Fünfschfräsbearbeitung durch eine kennzahlenunterstützte CAM-Umgebung

Band 93

Dr.-Ing. Jürgen Brath

Unterstützung der Produktionsplanung in der Halbleiterfertigung durch risikoberücksichtigende Betriebskennlinien

Band 94

Dr.-Ing. Dirk Geisinger

Ein Konzept zur marktorientierten Produktentwicklung

Band 95

Dr.-Ing. Marco Lanza

Entwurf der Systemunterstützung des verteilten Engineering mit Axiomatic Design

Band 96

Dr.-Ing. Volker Hüntrup

Untersuchungen zur Mikrostrukturierbarkeit von Stählen durch das Fertigungsverfahren Fräsen

Band 97

Dr.-Ing. Frank Reinboth

Interne Stützung zur Genauigkeitsverbesserung in der Inertialmesstechnik: Beitrag zur Senkung der Anforderungen an Inertialsensoren

Band 98

Dr.-Ing. Lutz Trender

Entwicklungintegrierte Kalkulation von Produktlebenszykluskosten auf Basis der ressourcenorientierten Prozesskostenrechnung

Band 99

Dr.-Ing. Cornelia Kafka

Konzeption und Umsetzung eines Leitfadens zum industriellen Einsatz von Data-Mining

Band 100

Dr.-Ing. Gebhard Selinger

Rechnerunterstützung der informellen Kommunikation in verteilten Unternehmensstrukturen

Band 101

Dr.-Ing. Thomas Windmüller

Verbesserung bestehender Geschäftsprozesse durch eine mitarbeiterorientierte Informationsversorgung

Band 102

Dr.-Ing. Knud Lembke

Theoretische und experimentelle Untersuchung eines bistabilen elektrohydraulischen Linearantriebs

Band 103

Dr.-Ing. Ulrich Thies

Methode zur Unterstützung der variantengerechten Konstruktion von industriell eingesetzten Kleingeräten

Band 104

Dr.-Ing. Andreas Schmälzle

Bewertungssystem für die Generalüberholung von Montageanlagen –Ein Beitrag zur wirtschaftlichen Gestaltung geschlossener Facility- Management-Systeme im Anlagenbau

Band 105

Dr.-Ing. Thorsten Frank

Vergleichende Untersuchungen schneller elektromechanischer Vorschubachsen mit Kugelgewindetrieb

Band 106

Dr.-Ing. Achim Agostini

Reihenfolgeplanung unter Berücksichtigung von Interaktionen: Beitrag zur ganzheitlichen Strukturierung und Verarbeitung von Interaktionen von Bearbeitungsobjekten

Band 107

Dr.-Ing. Thomas Barrho

Flexible, zeitfenstergesteuerte Auftragseinplanung in segmentierten Fertigungsstrukturen

Band 108

Dr.-Ing. Michael Scharer

Quality Gate-Ansatz mit integriertem Risikomanagement

Band 109

Dr.-Ing. Ulrich Suchy

**Entwicklung und Untersuchung eines neuartigen Mischkopfes für das Wasser
Abrasive Strahlschneiden**

Band 110

Dr.-Ing. Sellal Mussa

Aktive Korrektur von Verlagerungsfehlern in Werkzeugmaschinen

Band 111

Dr.-Ing. Andreas Hühsam

Modellbildung und experimentelle Untersuchung des Wälzschälprozesses

Band 112

Dr.-Ing. Axel Plutowsky

**Charakterisierung eines optischen Messsystems und den Bedingungen des
Arbeitsraums einer Werkzeugmaschine**

Band 113

Dr.-Ing. Robert Landwehr

**Konsequent dezentralisierte Steuerung mit Industrial Ethernet und offenen
Applikationsprotokollen**

Band 114

Dr.-Ing. Christoph Dill

Turbulenzreaktionsprozesse

Band 115

Dr.-Ing. Michael Baumeister

Fabrikplanung im turbulenten Umfeld

Band 116

Dr.-Ing. Christoph Gönninger

**Konzept zur Verbesserung der Elektromagnetischen Verträglichkeit (EMV) in
Produktionssystemen durch intelligente Sensor/Aktor-Anbindung**

Band 117

Dr.-Ing. Lutz Demuß

**Ein Reifemodell für die Bewertung und Entwicklung von Dienstleistungs-
organisationen: Das Service Management Maturity Modell (SMMM)**

Band 118

Dr.-Ing. Jörg Söhner

Beitrag zur Simulation zerspanungstechnologischer Vorgänge mit Hilfe der Finite-Element-Methode

Band 119

Dr.-Ing. Judith Elsner

Informationsmanagement für mehrstufige Mikro-Fertigungsprozesse

Band 120

Dr.-Ing. Lijing Xie

Estimation Of Two-dimension Tool Wear Based On Finite Element Method

Band 121

Dr.-Ing. Ansgar Blessing

Geometrischer Entwurf mikromechatronischer Systeme

Band 122

Dr.-Ing. Rainer Ebner

Steigerung der Effizienz mehrachsiger Fräsprozesse durch neue Planungsmethoden mit hoher Benutzerunterstützung

Band 123

Dr.-Ing. Silja Klinkel

Multikriterielle Feinplanung in teilautonomen Produktionsbereichen – Ein Beitrag zur produkt- und prozessorientierten Planung und Steuerung

Band 124

Dr.-Ing. Wolfgang Neithardt

Methodik zur Simulation und Optimierung von Werkzeugmaschinen in der Konzept- und Entwurfsphase auf Basis der Mehrkörpersimulation

Band 125

Dr.-Ing. Andreas Mehr

Hartfeinbearbeitung von Verzahnungen mit kristallinen diamantbeschichteten Werkzeugen beim Fertigungsverfahren Wälzstoßen

Band 126

Dr.-Ing. Martin Gutmann

Entwicklung einer methodischen Vorgehensweise zur Diagnose von hydraulischen Produktionsmaschinen

Band 127

Dr.-Ing. Gisela Lanza

Simulative Anlaufunterstützung auf Basis der Qualitätsfähigkeiten von Produktionsprozessen

Band 128

Dr.-Ing. Ulf Dambacher

Kugelgewindetrieb mit hohem Druckwinkel

Band 129

Dr.-Ing. Carsten Buchholz

Systematische Konzeption und Aufbau einer automatisierten Produktionszelle für pulverspritzgegossene Mikromauteile

Band 130

Dr.-Ing. Heiner Lang

Trocken-Räumen mit hohen Schnittgeschwindigkeiten

Band 131

Dr.-Ing. Daniel Nesges

Prognose operationeller Verfügbarkeiten von Werkzeugmaschinen unter Berücksichtigung von Serviceleistungen

Im Shaker Verlag erschienene Bände:

Band 132

Dr.-Ing. Andreas Bechle

Beitrag zur prozesssicheren Bearbeitung beim Hochleistungsfertigungsverfahren Wälzschälen

Band 133

Dr.-Ing. Markus Herm

Konfiguration globaler Wertschöpfungsnetzwerke auf Basis von Business Capabilities

Band 134

Dr.-Ing. Hanno Tritschler

Werkzeug- und Zerspanprozessoptimierung beim Hartfräsen von Mikrostrukturen in Stahl

Band 135

Dr.-Ing. Christian Munzinger

**Adaptronische Strebe zur Steifigkeitssteigerung
von Werkzeugmaschinen**

Band 136

Dr.-Ing. Andreas Stepping

**Fabrikplanung im Umfeld von Wertschöpfungsnetzwerken und
ganzheitlichen Produktionssystemen**

Band 137

Dr.-Ing. Martin Dyck

**Beitrag zur Analyse thermische bedingter Werkstückdeformationen
in Trockenbearbeitungsprozessen**

Band 138

Dr.-Ing. Siegfried Schmalzried

**Dreidimensionales optisches Messsystem für eine effizientere
geometrische Maschinenbeurteilung**

Band 139

Dr.-Ing. Marc Wawerla

Risikomanagement von Garantieleistungen

Band 140

Dr.-Ing. Ivesa Buchholz

**Strategien zur Qualitätssicherung mikromechanischer Bauteile
mittels multisensorieller Koordinatenmesstechnik**

Band 141

Dr.-Ing. Jan Kotschenreuther

**Empirische Erweiterung von Modellen der Makrozerspanung
auf den Bereich der Mikrobearbeitung**

Band 142

Dr.-Ing. Andreas Knödel

Adaptronische hydrostatische Drucktascheneinheit

Band 143

Dr.-Ing. Gregor Stengel

**Fliegendes Abtrennen räumlich gekrümmter Strangpressprofile mittels
Industrierobotern**

Band 144

Dr.-Ing. Udo Weismann

Lebenszyklusorientiertes interorganisationelles Anlagencontrolling

Band 145

Dr.-Ing. Rüdiger Pabst

Mathematische Modellierung der Wärmestromdichte zur Simulation des thermischen Bauteilverhaltens bei der Trockenbearbeitung

Band 146

Dr.-Ing. Jan Wieser

Intelligente Instandhaltung zur Verfügbarkeitssteigerung von Werkzeugmaschinen

Band 147

Dr.-Ing. Sebastian Haupt

Effiziente und kostenoptimale Herstellung von Mikrostrukturen durch eine Verfahrenskombination von Bahnerosion und Laserablation

Band 148

Dr.-Ing. Matthias Schlipf

Statistische Prozessregelung von Fertigungs- und Messprozess zur Erreichung einer variabilitätsarmen Produktion mikromechanischer Bauteile

Band 149

Dr.-Ing. Jan Philipp Schmidt-Ewig

Methodische Erarbeitung und Umsetzung eines neuartigen Maschinenkonzeptes zur produktflexiblen Bearbeitung räumlich gekrümmter Strangpressprofile

Band 150

Dr.-Ing. Thomas Ender

Prognose von Personalbedarfen im Produktionsanlauf unter Berücksichtigung dynamischer Planungsgrößen

Band 151

Dr.-Ing. Kathrin Peter

Bewertung und Optimierung der Effektivität von Lean Methoden in der Kleinserienproduktion

Band 152

Dr.-Ing. Matthias Schopp

Sensorbasierte Zustandsdiagnose und -prognose von Kugelgewindetrieben

Band 153

Dr.-Ing. Martin Kipfmüller

Aufwandsoptimierte Simulation von Werkzeugmaschinen

Band 154

Dr.-Ing. Carsten Schmidt

Development of a database to consider multi wear mechanisms within chip forming simulation

Band 155

Dr.-Ing. Stephan Niggeschmidt

Ausfallgerechte Ersatzteilbereitstellung im Maschinen- und Anlagenbau mittels lastabhängiger Lebensdauerprognose

Band 156

Dr.-Ing. Jochen Conrad Peters

Bewertung des Einflusses von Formabweichungen in der Mikro-Koordinatenmesstechnik

Band 157

Dr.-Ing. Jörg Ude

Entscheidungsunterstützung für die Konfiguration globaler Wertschöpfungsnetzwerke

Band 158

Dr.-Ing. Stefan Weiler

Strategien zur wirtschaftlichen Gestaltung der globalen Beschaffung

Band 159

Dr.-Ing. Jan Rühl

Monetäre Flexibilitäts- und Risikobewertung

Band 160

Dr.-Ing. Daniel Ruch

Positions- und Konturerfassung räumlich gekrümmter Profile auf Basis bauteilimmanenter Markierungen

Band 161

Dr.-Ing. Manuel Tröndle

Flexible Zuführung von Mikrobauteilen mit piezoelektrischen Schwingförderern

Band 162

Dr.-Ing. Benjamin Viering

Mikroverzahnungsnormal

Band 163

Dr.-Ing. Chris Becke

Prozesskrafttrichtungsangepasste Frässtrategien zur schädigungsarmen Bohrungsbearbeitung an faserverstärkten Kunststoffen

Band 164

Dr.-Ing. Patrick Werner

Dynamische Optimierung und Unsicherheitsbewertung der lastabhängigen präventiven Instandhaltung von Maschinenkomponenten

Band 165

Dr.-Ing. Martin Weis

Kompensation systematischer Fehler bei Werkzeugmaschinen durch self-sensing Aktoren

Band 166

Dr.-Ing. Markus Schneider

Kompensation von Konturabweichungen bei gerundeten Strangpressprofilen durch robotergestützte Führungswerkzeuge

Band 167

Dr.-Ing. Ester M. R. Ruprecht

Prozesskette zur Herstellung schichtbasierter Systeme mit integrierten Kavitäten

Band 168

Dr.-Ing. Alexander Broos

Simulationsgestützte Ermittlung der Komponentenbelastung für die Lebensdauerprognose an Werkzeugmaschinen

Band 169

Dr.-Ing. Frederik Zanger

Segmentspanbildung, Werkzeugverschleiß, Randschichtzustand und Bauteileigenschaften: Numerische Analysen zur Optimierung des Zerspanungsprozesses am Beispiel von Ti-6Al-4V

Band 170

Dr.-Ing. Benjamin Behmann

Servicefähigkeit

Band 171

Dr.-Ing. Annabel Gabriele Jondral

Simulationsgestützte Optimierung und Wirtschaftlichkeitsbewertung des Lean-Methodeneinsatzes

Band 172

Dr.-Ing. Christoph Ruhs

Automatisierte Prozessabfolge zur qualitätssicheren Herstellung von Kavitäten mittels Mikrobahnerosion

Band 173

Dr.-Ing. Steven Peters

Markoffsche Entscheidungsprozesse zur Kapazitäts- und Investitionsplanung von Produktionssystemen

Band 174

Dr.-Ing. Christoph Kühlewein

Untersuchung und Optimierung des Wälzschälverfahrens mit Hilfe von 3D-FEM-Simulation – 3D-FEM Kinematik- und Spanbildungssimulation

Band 175

Dr.-Ing. Adam-Mwanga Dieckmann

Auslegung und Fertigungsprozessgestaltung sintergefügter Verbindungen für μ MIM-Bauteile

Band 176

Dr.-Ing. Heiko Hennrich

Aufbau eines kombinierten belastungs- und zustandsorientierten Diagnose- und Prognosesystems für Kugelgewindetriebe

Band 177

Dr.-Ing. Stefan Herder

Piezoelektrischer Self-Sensing-Aktor zur Vorspannungsregelung in adaptronischen Kugelgewindetriebe

Band 178

Dr.-Ing. Alexander Ochs

Ultraschall-Strömungsgreifer für die Handhabung textiler Halbzeuge bei der automatisierten Fertigung von RTM-Bauteilen

Band 179

Dr.-Ing. Jürgen Michna

Numerische und experimentelle Untersuchung zerspanungsbedingter Gefügeumwandlungen und Modellierung des thermo-mechanischen Lastkollektivs beim Bohren von 42CrMo4

Band 180

Dr.-Ing. Jörg Elser

Vorrichtungsfreie räumliche Anordnung von Fügepartnern auf Basis von Bauteilmarkierungen

Band 181

Dr.-Ing. Katharina Klimscha

Einfluss des Fügespalts auf die erreichbare Verbindungsqualität beim Sinterfügen

Band 182

Dr.-Ing. Patricia Weber

Steigerung der Prozesswiederholbarkeit mittels Analyse akustischer Emissionen bei der Mikrolaserablation mit UV-Pikosekundenlasern

Band 183

Dr.-Ing. Jochen Schädel

Automatisiertes Fügen von Tragprofilen mittels Faserwickeln

Band 184

Dr.-Ing. Martin Krauß

Aufwandsoptimierte Simulation von Produktionsanlagen durch Vergrößerung der Geltungsbereiche von Teilmodellen

Band 185

Dr.-Ing. Raphael Moser

Strategische Planung globaler Produktionsnetzwerke

Bestimmung von Wandlungsbedarf und Wandlungszeitpunkt mittels multikriterieller Optimierung

Band 186

Dr.-Ing. Martin Otter

Methode zur Kompensation fertigungsbedingter Gestaltabweichungen für die Montage von Aluminium Space-Frame-Strukturen

Band 187

Dr.-Ing. Urs Leberle

Produktive und flexible Gleitförderung kleiner Bauteile auf phasenflexiblen Schwingförderern mit piezoelektrischen 2D-Antriebs-elementen

Band 188

Dr.-Ing. Johannes Book

Modellierung und Bewertung von Qualitätsmanagementstrategien in globalen Wertschöpfungsnetzwerken

Band 189

Dr.-Ing. Florian Ambrosy

Optimierung von Zerspanungsprozessen zur prozesssicheren Fertigung nanokristalliner Randschichten am Beispiel von 42CrMo4

Band 190

Dr.-Ing. Adrian Kölmel

Integrierte Messtechnik für Prozessketten unreifer Technologien am Beispiel der Batterieproduktion für Elektrofahrzeuge

Band 191

Dr.-Ing. Henning Wagner

Featurebasierte Technologieplanung zum Preforming von textilen Halbzeugen

Band 192

Dr.-Ing. Johannes Gebhardt

Strukturoptimierung von in FVK eingebetteten metallischen Lasteinleitungselementen

Band 193

Dr.-Ing. Jörg Bauer

Hochintegriertes hydraulisches Vorschubsystem für die Bearbeitung kleiner Werkstücke mit hohen Fertigungsanforderungen

Band 194

Dr.-Ing. Nicole Stricker

Robustheit verketteter Produktionssysteme

Robustheitsevaluation und Selektion des Kennzahlensystems der Robustheit

Band 195

Dr.-Ing. Anna Sauer

Konfiguration von Montagelinien unreifer Produkttechnologien am Beispiel der Batteriemontage für Elektrofahrzeuge

Band 196

Dr.-Ing. Florian Sell-Le Blanc

Prozessmodell für das Linearwickeln unrunder Zahnspulen

Ein Beitrag zur orthozyklischen Spulenwickeltechnik

Band 197

Dr.-Ing. Frederic Förster

Geregeltes Handhabungssystem zum zuverlässigen und energieeffizienten Handling textiler Kohlenstofffaserzuschnitte

Band 198

Dr.-Ing. Nikolay Boev

Numerische Beschreibung von Wechselwirkungen zwischen Zerspanprozess und Maschine am Beispiel Räumen

Band 199

Dr.-Ing. Sebastian Greinacher

Simulationsgestützte Mehrzieloptimierung schlanker und ressourceneffizienter Produktionssysteme

Band 200

Dr.-Ing. Benjamin Häfner

Lebensdauerprognose in Abhängigkeit der Fertigungsabweichungen bei Mikroverzahnungen

Band 201

Dr.-Ing. Stefan Klotz

Dynamische Parameteranpassung bei der Bohrungsherstellung in faserverstärkten Kunststoffen unter zusätzlicher Berücksichtigung der Einspannsituation

Band 202

Dr.-Ing. Johannes Stoll

Bewertung konkurrierender Fertigungsfolgen mittels Kostensimulation und stochastischer Mehrzieloptimierung

Anwendung am Beispiel der Blechpaketfertigung für automobiler Elektromotoren

Band 203

Dr.-Ing. Simon-Frederik Koch

Fügen von Metall-Faserverbund-Hybridwellen im Schleuderverfahren

ein Beitrag zur fertigungsgerechten intrinsischen Hybridisierung

Band 204

Dr.-Ing. Julius Ficht

Numerische Untersuchung der Eigenspannungsentwicklung für sequenzielle Zerspanungsprozesse

Band 205

Dr.-Ing. Manuel Baumeister

Automatisierte Fertigung von Einzelblattstapeln in der Lithium-Ionen-Zellproduktion

Band 206

Dr.-Ing. Daniel Bertsch

Optimierung der Werkzeug- und Prozessauslegung für das Wälzschälen von Innenverzahnungen

Band 207

Dr.-Ing. Kyle James Kippenbrock

Deconvolution of Industrial Measurement and Manufacturing Processes for Improved Process Capability Assessments

Band 208

Dr.-Ing. Farboud Bejnoud

Experimentelle Prozesskettenbetrachtung für Räumbauteile am Beispiel einer einsatzgehärteten PKW-Schiebemuffe

Band 209

Dr.-Ing. Steffen Dosch

Herstellungsübergreifende Informationsübertragung zur effizienten Produktion von Werkzeugmaschinen am Beispiel von Kugelgewindetrieben

Band 210

Dr.-Ing. Emanuel Moser

Migrationsplanung globaler Produktionsnetzwerke

Bestimmung robuster Migrationspfade und risiko-effizienter Wandlungsbefähiger

Band 211

Dr.-Ing. Jan Hochdörffer

Integrierte Produktallokationsstrategie und Konfigurationssequenz in globalen Produktionsnetzwerken

Band 212

Dr.-Ing. Tobias Arndt

Bewertung und Steigerung der Prozessqualität in globalen Produktionsnetzwerken

Band 213

Dr.-Ing. Manuel Peter

Unwuchtminimale Montage von Permanentmagnetrotoren durch modellbasierte Online-Optimierung

Band 214

Dr.-Ing. Robin Kopf

Kostenorientierte Planung von Fertigungsfolgen additiver Technologien

Band 215

Dr.-Ing. Harald Meier

**Einfluss des Räumens auf den Bauteilzustand in der Prozesskette
Weichbearbeitung – Wärmebehandlung – Hartbearbeitung**

Band 216

Dr.-Ing. Daniel Brabandt

**Qualitätssicherung von textilen Kohlenstofffaser-Preforms mittels
optischer Messtechnik**

Band 217

Dr.-Ing. Alexandra Schabunow

**Einstellung von Aufnahmeparametern mittels projektionsbasierter Qualitäts-
kenngrößen in der industriellen Röntgen-Computertomographie**

Band 218

Dr.-Ing. Jens Bürgin

Robuste Auftragsplanung in Produktionsnetzwerken

Mittelfristige Planung der variantenreichen Serienproduktion unter Unsicher-
heit der Kundenauftragskonfigurationen

Band 219

Dr.-Ing. Michael Gerstenmeyer

**Entwicklung und Analyse eines mechanischen Oberflächenbehandlungs-
verfahrens unter Verwendung des Zerspanungswerkzeuges**

Band 220

Dr.-Ing. Jacques Burtscher

**Erhöhung der Bearbeitungsstabilität von Werkzeugmaschinen durch
semi-passive masseneinstellbare Dämpfungssysteme**

Band 221

Dr.-Ing. Dietrich Berger

**Qualitätssicherung von textilen Kohlenstofffaser-Preforms mittels prozess-
integrierter Wirbelstromsensor-Arrays**

Band 222

Dr.-Ing. Fabian Johannes Ballier

Systematic gripper arrangement for a handling device in lightweight production processes

Band 223

Dr.-Ing. Marielouise Schäferling, geb. Zaiß

Development of a Data Fusion-Based Multi-Sensor System for Hybrid Sheet Molding Compound

Band 224

Dr.-Ing. Quirin Spiller

Additive Herstellung von Metallbauteilen mit dem ARBURG Kunststoff-Freiformen

Band 225

Dr.-Ing. Andreas Spohrer

Steigerung der Ressourceneffizienz und Verfügbarkeit von Kugelgewindetrieben durch adaptive Schmierung

Band 226

Dr.-Ing. Johannes Fisel

Veränderungsfähigkeit getakteter Fließmontagesysteme

Planung der Fließbandabstimmung am Beispiel der Automobilmontage

Band 227

Dr.-Ing. Patrick Bollig

Numerische Entwicklung von Strategien zur Kompensation thermisch bedingter Verzüge beim Bohren von 42CrMo4

Band 228

Dr.-Ing. Ramona Pfeiffer, geb. Singer

Untersuchung der prozessbestimmenden Größen für die anforderungsgerechte Gestaltung von Pouchzellen-Verpackungen

Band 229

Dr.-Ing. Florian Baumann

Additive Fertigung von endlosfaserverstärkten Kunststoffen mit dem ARBURG Kunststoff-Freiform Verfahren

Band 230

Dr.-Ing. Tom Stähr

Methodik zur Planung und Konfigurationsauswahl skalierbarer Montage-systeme – Ein Beitrag zur skalierbaren Automatisierung

Band 231

Dr.-Ing. Jan Schwennen

Einbringung und Gestaltung von Lasteinleitungsstrukturen für im RTM-Verfahren hergestellte FVK-Sandwichbauteile

Band 232

Dr.-Ing. Sven Coutandin

Prozessstrategien für das automatisierte Preforming von bebinderten textilen Halbzeugen mit einem segmentierten Werkzeugsystem

Band 233

Dr.-Ing. Christoph Liebrecht

Entscheidungsunterstützung für den Industrie 4.0-Methodeneinsatz
Strukturierung, Bewertung und Ableitung von Implementierungsreihenfolgen

Band 234

Dr.-Ing. Stefan Treber

Transparenzsteigerung in Produktionsnetzwerken
Verbesserung des Störungsmanagements durch verstärkten Informationsaustausch

Band 235

Dr.-Ing. Marius Dackweiler

Modellierung des Fügewickelprozesses zur Herstellung von leichten Fachwerkstrukturen

Band 236

Dr.-Ing. Fabio Echsler Minguillon

Prädiktiv-reaktives Scheduling zur Steigerung der Robustheit in der Matrix-Produktion

Band 237

Dr.-Ing. Sebastian Haag

Entwicklung eines Verfahrensablaufes zur Herstellung von Batteriezellstapeln mit großformatigem, rechteckigem Stapelformat und kontinuierlichen Materialbahnen

Band 238

Dr.-Ing. Raphael Wagner

Strategien zur funktionsorientierten Qualitätsregelung in der Serienproduktion

Band 239

Dr.-Ing. Christopher Ehrmann

Ausfallfrüherkennung von Ritzel-Zahnstangen- Trieben mittels Acoustic Emission

Band 240

Dr.-Ing. Janna Hofmann

Prozessmodellierung des Fünf-Achs-Nadelwickelns zur Implementierung einer trajektoriebasierten Drahtzugkraftregelung

Band 241

Dr.-Ing. Andreas Kuhnle

Adaptive Order Dispatching based on Reinforcement Learning Application in a Complex Job Shop in the Semiconductor Industry

Band 242

Dr.-Ing. Andreas Greiber

Fertigung optimierter technischer Oberflächen durch eine Verfahrenskombination aus Fliehkraft-Tauchgleitschleifen und Laserablation Prozesseinflüsse und Prozessauslegung

Band 243

Dr.-Ing. Jan Niclas Eschner

Entwicklung einer akustischen Prozessüberwachung zur Porenbestimmung im Laserstrahlschmelzen

Band 244

Dr.-Ing. Sven Roth

Schädigungsfreie Anbindung von hybriden FVK/Metall-Bauteilen an metallische Tragstrukturen durch Widerstandspunktschweißen

Band 245

Dr.-Ing. Sina Kathrin Peukert

Robustheitssteigerung in Produktionsnetzwerken mithilfe eines integrierten Störungsmanagements

Band 246

Dr.-Ing. Alexander Jacob

Hochiterative Technologieplanung

Rekursive Optimierung produkt- und fertigungsbezogener Freiheitsgrade am Beispiel der hybrid-additiven Fertigung

Band 247

Dr.-Ing. Patrick Moll

Ressourceneffiziente Herstellung von Langfaser-Preforms im Faserblasverfahren

Band 248

Dr.-Ing. Eric Thore Segebadé

Erhöhung der Verschleißbeständigkeit von Bauteilen aus Ti-6Al-4V mittels simulationsgestützter Zerspanung und mechanischer Mikrotextrurierung

Band 249

Dr.-Ing. Shun Yang

Regionalized implementation strategy of smart automation within assembly systems in China

Band 250

Dr.-Ing. Constantin Carl Hofmann

Vorausschauende und reaktive Mehrzieloptimierung für die Produktionssteuerung einer Matrixproduktion

Band 251

Dr.-Ing. Paul Ruhland

Prozesskette zur Herstellung von hybriden Faser-Metall-Preforms

Modellbildung und Optimierung des Binderauftrags und der Drapierung für stabförmige Bauteile

Band 252

Dr.-Ing. Leonard Schild

Erzeugung und Verwendung von Anwendungswissen in der industriellen Computertomographie

Band 253

Dr.-Ing. Benedikt Klee

Analyse von Phaseninformationen in Videodaten zur Identifikation von Schwingungen in Werkzeugmaschinen

Band 254

Dr.-Ing. Bruno Vargas

Wälzschälern mit kleinen Achskreuzwinkeln

Prozessgrenzen und Umsetzbarkeit

Band 255

Dr.-Ing. Lucas Bretz

Function-oriented in-line quality assurance of hybrid sheet molding compound

Band 256

Dr.-Ing. Bastian Rothaupt

Dämpfung von Bauteilschwingungen durch einstellbare Werkstückdirektspannung mit Hydrodehnspanntechnik

Band 257

Dr.-Ing. Daniel Kupzik

Robotic Swing Folding of three-dimensional UD-tape-based Reinforcement Structures

Band 258

Dr.-Ing. Bastian Verhaelen

(De-)Zentralisierung von Entscheidungen in globalen Produktionsnetzwerken
Strategie- und komplexitätsorientierte Gestaltung der Entscheidungsautonomie

Band 259

Dr.-Ing. Hannes Wilhelm Weinmann

Integration des Vereinzelungs- und Stapelbildungsprozesses in ein flexibel und kontinuierlich arbeitendes Anlagenmodul für die Li-Ionen Batteriezellfertigung

Band 260

Dr.-Ing. Florian Stamer

Dynamische Lieferzeit-Preisgestaltung in variantenreicher Produktion

Ein adaptiver Ansatz mithilfe von Reinforcement Learning

Band 261

Dr.-Ing. Patrick Neuenfeldt

Modellbildung des Tauchgleitschleifens zur Abtrag- und

Topografievorhersage an komplexen Geometrien

Band 262

Dr.-Ing. Boris Matuschka

Energieeffizienz in Prozessketten: Analyse und Optimierung von

Energieflüssen bei der Herstellung eines PKW-Getriebebauteils aus 16MnCr5

Band 263

Dr.-Ing. Tobias Schlagenhaut

Bildbasierte Quantifizierung und Prognose des Verschleißes an

Kugelgewindetriebsspindeln

Ein Beitrag zur Zustandsüberwachung von Kugelgewindetrieben mittels

Methoden des maschinellen Lernens

Band 264

Dr.-Ing. Benedict Stampfer

Entwicklung eines multimodalen Prozessmodells zur

Oberflächenkonditionierung beim Außenlängsdrehen von 42CrMo4

Band 265

Dr.-Ing. Carmen Maria Krahe

KI-gestützte produktionsgerechte Produktentwicklung

Automatisierte Wissensextraktion aus vorhandenen Produktgenerationen

Band 266

Dr.-Ing. Markus Netzer

Intelligente Anomalieerkennung für hochflexible Produktionsmaschinen

Prozessüberwachung in der Brownfield Produktion

Band 267

Dr.-Ing. Simon Raphael Merz

Analyse der Kinematik und Kinetik von Planetenwalgwindtrieben

Band 268

Dr.-Ing. Rainer Maria Silbernagel

Funktionsorientierte Qualitatsregelung in Produktionsnetzwerken

Qualitatsmanagement in der Produktion hochpraziser Produkte durch netzwerkweite Datenintegration

Band 269

Dr.-Ing. Jonas Nieschlag

Gestaltung und Prozessanalyse fur im Schleuderverfahren hergestellte FKV-Metall-Hohlstrukturen

Band 270

Dr.-Ing. Lukas Matthias Weiser

In-Process Porositatserkennung fur den PBF-LB/M-Prozess

Band 271

Dr.-Ing. Leonard Vincent Overbeck

Digital Twins of production systems

Automated validation and update of material flow simulation models with real data

Band 272

Dr.-Ing. Felix Klenk

Transparenzsteigerung in der Ruckfuhrungslogistik zur Verbesserung der Materialbedarfsplanung fur das Remanufacturing

Band 273

Dr.-Ing. Benjamin Bold

Kompensation der Wrinkle-Bildung beim Kalandrieren von Lithium-Ionen-Kathoden

Vom Prozessverstandnis des Kalandrierens bis zur Prozessoptimierung mittels Anti-Wrinkle-Modul

Band 274

Dr.-Ing. Daniel Gauder

Adaptive in-line Qualitatsregelung in der Mikro-Verzahnungsfertigung

Band 275

Dr.-Ing. Fabian Sasse

**Ontologie-basierte Entscheidungsunterstützung für die Auswahl von
Messsystemen in unreifen Produktionsprozessen**

Band 276

Dr.-Ing. Jonas Hillenbrand

**Unsupervised Condition-Monitoring für Kugelgewindetriebe mittels Acoustic
Emission**

