

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

Markus Netzer

**Intelligente Anomalieerkennung
für hochflexible Produktionsmaschinen**
Prozessüberwachung in der
Brownfield Produktion

Band 266



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

Markus Netzer

**Intelligente Anomalieerkennung für hochflexible
Produktionsmaschinen**
Prozessüberwachung in der Brownfield Produktion

Band 266

**Intelligente Anomalieerkennung für hochflexible
Produktionsmaschinen**
Prozessüberwachung in der Brownfield Produktion

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.Eng. Markus Netzer

Tag der mündlichen Prüfung: 16.02.2023
Hauptreferent: Prof. Dr.-Ing. Jürgen Fleischer
Korreferent: Prof. Dr.-Ing. Jan C. Aurich

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., 2023

Copyright Shaker Verlag 2023

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

Printed in Germany.

ISBN 978-3-8440-9011-6

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 soll im Rahmen dieser Schriftenreihe über aktuelle Forschungsergebnisse des Instituts für Produktionstechnik (wbk) am Karlsruher Institut für Technologie (KIT) berichtet werden. Unsere Forschungsarbeiten beschäftigen sich sowohl mit der Leistungssteigerung von Fertigungsverfahren und zugehörigen Werkzeugmaschinen- und Handhabungstechnologien als auch mit der ganzheitlichen Betrachtung und Optimierung des gesamten Produktionssystems. 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

Vorwort des Verfassers

Diese Dissertation entstand während meiner Tätigkeit als akademischer Mitarbeiter am Institut für Produktionstechnik (wbk) des Karlsruher Instituts für Technologie (KIT).

Mein besonderer Dank gilt Herrn Prof. Dr.-Ing. Jürgen Fleischer für sein Vertrauen, die Betreuung der wissenschaftlichen Arbeit mit Übernahme des Hauptreferats, sowie für die inspirierende persönliche Förderung in den vergangenen Jahren. Herrn Prof. Dr.-Ing. Jan C. Aurich danke ich für die Übernahme des Korreferats sowie den wissenschaftlich fachlichen Austausch. Prof. Dr.-Ing. Marcus Geimer danke ich für die Übernahme des Prüfungsvorsitzes.

Bei allen Kolleginnen und Kollegen des wbk möchte ich mich für den engen Zusammenhalt und die andauernde Unterstützung bedanken. Die gemeinsame Zeit am Institut werde ich immer in bester Erinnerung wahren. Allen technischen und organisatorischen Mitarbeitenden des wbk möchte ich für die immerwährende Unterstützung danken. Bei meinen Kollegen und Freunden Philipp Gönzheimer, Tobias Schlagenhauf, Tobias Storz, Florian Oexle und Aaron Schmidt möchte ich mich im Besonderen bedanken.

Allen studentischen Mitarbeitenden möchte ich besonderen Dank aussprechen, da sie wesentlich zum Erfolg dieser Dissertation beigetragen haben. Besonders bedanken möchte ich mich bei Julian Martin, Jonas Michelberger, Lukas Winkler, Eva Begemann, Christopher Baier, Philipp Alexander, Philipp Wurche, Lutz Köhler, Robin Kopp, Patrick Horlacher und Yannic Palenga.

Meinen herzlichsten Dank möchte ich abschließend meiner Familie aussprechen. Der andauernde Rückhalt ermöglichte mir das Studium und die Promotion. Allen voran gilt der Dank meiner Freundin Marion, meinen Eltern Anita und Siegfried Netzer und meiner Schwester Stefanie.

Karlsruhe, 16. Februar 2023

Markus Netzer

Abstract

Under the term "Industry 4.0" approaches of data infrastructure in productions have been developed and applied to a large extent in the last decade. Nevertheless, the full potential of data-driven analyses can hardly be exploited, as many production machines are characterized by a high degree of complexity and diversity of processes. Furthermore, the amount and variance of data in brownfield applications is usually too small to apply self-learning methods. The integration of user knowledge to data-driven methods has not been holistically researched. In this dissertation approaches for fault detection in different highly flexible production machines and the integration of domain knowledge of a user are introduced. While existing methods are focused on model training of repetitive processes, the novel approach of this dissertation is to create a concept to detect faults with a very small amount of data. Intervention limits of the logic are self-learning and adapt themselves in case of a process or product change. Process differentiation is based on process segmentation using pattern recognition methods. After segmenting historical data streams and determining representative patterns, the segments are redetected in online signals. After a similar segment has been detected, unsupervised anomaly detection is performed. An anomaly classification by using self-learning methods and the formalized domain knowledge enables the output of recommended actions for the user or machine operator. All developed methods are validated on three selected industrially relevant application examples. The methods are implemented in an app.

Kurzfassung

Unter dem Begriff "Industrie 4.0" wurden im letzten Jahrzehnt Ansätze der Dateninfrastruktur in Produktionen entwickelt und in großem Umfang angewendet. Dennoch kann das volle Potenzial datengetriebener Analysen kaum ausgeschöpft werden, da viele Produktionsanlagen durch eine hohe Komplexität und Prozessvielfalt gekennzeichnet sind. Zudem ist die Datenmenge in der Praxis meist zu gering, um selbstlernende Methoden anzuwenden. Die Integration von Anwenderwissen in datengetriebenen Methoden ist bisher nicht ganzheitlich erforscht. In dieser Dissertation werden Ansätze zur Anomalieerkennung in verschiedenen hochflexiblen Produktionsmaschinen und die Integration von Domänenwissen eines Anwenders vorgestellt. Während sich bestehende Methoden auf das Modelltraining von sich wiederholenden gleichen Prozessen konzentrieren, besteht der neuartige Ansatz dieser Arbeit darin, ein Konzept zur Fehlererkennung mit einer sehr geringen Datenmenge zu entwickeln. Eingriffsgrenzen sind variabel und lassen sich durch selbstlernende Algorithmen im Falle einer Prozess- oder Produktänderung anpassen. Die Prozessdifferenzierung basiert auf einer Prozesssegmentierung mit Methoden der Mustererkennung. Nach der Segmentierung historischer Datenströme und der Bestimmung repräsentativer Muster werden die Segmente in Online-Signalen wiedererkannt. Nachdem ein ähnliches Segment erkannt wurde, wird eine unüberwachte Anomalieerkennung durchgeführt. Eine Anomalie-Klassifikation mit Hilfe selbstlernender Methoden und des formalisierten Domänenwissens ermöglicht die Ausgabe von Handlungsempfehlungen für den Benutzer oder Maschinenbediener. Alle entwickelten Methoden werden an drei ausgewählten industriell relevanten Anwendungsbeispielen validiert. Die Methoden werden in einer App implementiert.

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Formelzeichen und Abkürzungen	VI
Begriffserklärung	VII
1 Einleitung	1
1.1 Motivation	1
1.2 Zielsetzung und Aufbau der Arbeit	3
2 Stand von Forschung und Technik	7
2.1 Die Produktionsmaschine – Grundverständnis	7
2.1.1 Fertigungsverfahren	7
2.1.2 Produktionskennzahlen	8
2.1.3 Lebensphasen einer Maschine	8
2.2 Störungsarten und deren Herausforderungen in Produktionsmaschinen	9
2.2.1 Störungen in Produktionsmaschinen	9
2.2.2 Herausforderungen und Auswirkungen von Störungen	10
2.2.3 Instandhaltungsstrategien	12
2.3 Industrie 4.0	13
2.3.1 Datentypen	13
2.3.2 Zeitreihenanalyse	13
2.3.3 Datenaufnahme bei Produktionsmaschinen	14
2.3.4 Herausforderungen in Brownfield Anwendungen	15
2.4 Condition Monitoring im Kontext von Industrie 4.0	16
2.4.1 Arten der Zustandserkennung	17
2.4.2 Schematischer Aufbau eines Condition Monitoring Systems	18
2.4.3 Herausforderungen bei der Anwendung von Condition Monitoring Systemen	19
2.4.4 Zusammenfassung und Bewertung von industriellen Condition Monitoring Systemen	20
2.5 Mustererkennung und Zeitreihen	21
2.5.1 Datenrepräsentation	25

2.5.2	Features	26
2.5.3	Distanzmetriken	27
2.5.4	Clusteralgorithmen	29
2.5.5	Fazit zu Clusterverfahren	32
2.5.6	Zusammenfassung und Bewertung der Mustererkennung	32
2.6	Anomalieerkennung	32
2.6.1	Anomalieerkennung in Zeitreihen	36
2.6.2	Zusammenfassung und Bewertung der Anomalieerkennung	43
2.7	Wissensbasiertes Expertensystem zur Integration von Anwenderwissen	44
2.7.1	Wissenshierarchie	45
2.7.2	Wissensbasierte Methoden zur Merkmalsextraktion	45
2.7.3	Wissensrepräsentation	46
2.7.4	Qualitative Trendanalyse	47
2.7.5	Zusammenfassung und Bewertung der wissensbasierten Ansätze	49
2.8	Bewertung des Standes von Forschung und Technik	49
2.9	Fazit zum Stand von Forschung und Technik	49
2.10	Aktuelle Defizite in Forschung und Technik	50
2.11	Zusammenfassung der Defizite und Lösungsansätze	52
3	Präzisierte Zielsetzung und Vorgehensweise	54
3.1	Präzisierung der Zielsetzung	54
3.2	Vorgehensweise zur Zielerfüllung	56
4	Einflussanalyse und Detektierbarkeit von Störungen	58
4.1	Motivation und Abstrahierung als System	58
4.2	Methodische Analyse der Einflussgrößen	59
4.2.1	Ableitung generischer Störungsgruppen	59
4.2.2	Analyse der Einflussgrößen	60
4.3	Auswertung und Interpretation der Erkenntnisse	62
4.4	Grenzen der Verfahren in der praktischen Anwendung	62
4.5	Fazit der Detektierbarkeit von Störungen	63

5	Mustererkennung in Zeitreihen	64
5.1	Datenvorbereitung / Glättung	66
5.1.1	Ableitung der Anforderungen	67
5.1.2	Diskussion über mögliche Konzepte zur Rauschhandhabung	68
5.1.3	Konzeptauswahl	70
5.1.4	Implementierung	70
5.1.5	Aufteilung der geglätteten Zeitreihe in Segmente	72
5.1.6	Fazit der Rauschminderung	73
5.2	Distanzbestimmung mittels einer Metrik	75
5.2.1	Bewertung	79
5.2.2	Fazit der Distanzbestimmung und Normierung	80
5.3	Dichtebasiertes Clusterverfahren	80
5.3.1	Bewertung zur Wahl des Clusteransatzes	81
5.3.2	Wahl und Optimierung des Such-Parameters	82
5.3.3	Fazit der erweiterten Bandwidth Berechnung	83
5.4	Berechnung eines repräsentativen multidimensionalen Musters	84
5.5	Fazit der Offline-Datensegmentierung	87
5.6	Wiederfinden von Mustern in Online-Signalen	88
5.6.1	Referenz- und Informationssignale	88
5.6.2	Aktualisieren des Puffers	91
5.6.3	Parameterwahl	93
5.6.4	Kennzahlberechnung	94
5.7	Fazit der Datensegmentierung und der Online-Mustererkennung	98
6	Anomalieerkennung	99
6.1	Prinzip der Anomalieerkennung	99
6.1.1	Leistungsspektrum	99
6.1.2	Distanzbestimmung	100
6.1.3	Anomaliedetektion anhand eines Toleranzbandes	100
6.1.4	Schwellwertbasiertes Toleranzband	101

6.1.5	Hüllkurvenbasiertes Toleranzband	102
6.1.6	Fazit der unüberwachten Anomalieerkennung	103
7	Post-Processing – Klassifikation von Anomalien	104
7.1	Feedback-Loop des Anwenders	104
7.2	Fazit des Feedback-Loops des Anwenders	105
7.3	Integration eines Labels zur Klassifikation von Anomalien	105
7.3.1	Lösungsansatz	106
7.3.2	Vergleichslogiken	108
7.3.3	Statistische Ansätze	108
7.3.4	Ansätze unter Verwendung von Methoden des maschinellen Lernens	110
7.3.5	Bewertung des Ansatzes mittels Verfahren des Maschinellen Lernens	112
8	Integration von Domänenwissen	113
8.1	Formalisierung von Domänenwissen zur Beschreibung von Wissen	115
8.1.1	Einführung lokaler Trendstrukturen	115
8.1.2	Nomenklatur und Anomaliesyntax	117
8.1.3	Beispielhafter Anwendungsfall Fräsprozess – Lunker/Poren	119
8.2	Automatisierte Klassifikation über formalisiertes Domänenwissen	120
8.2.1	Lokale Extremstellensuche	120
8.2.2	Autoskalierung	121
8.2.3	Ermittlung lokaler Trendstrukturen	121
8.2.4	Anomalieprofil-Abgleich	122
8.2.5	Fazit der Formalisierung von Domänenwissen	124
9	Umsetzung und Validierung der Anomalieerkennung	125
9.1	MVC Ansatz – Die Architektur	125
9.2	Aufbau und Funktionsweise der Anomalieerkennungs-App	127
9.3	Anwendung 1: Prozessüberwachung bei der Zerspanung	130
9.3.1	Versuchsdurchführung und Ergebnisse	131
9.3.2	Bewertung und Grenzen	138
9.4	Anwendung 2: Bauteilverlustüberwachung einer Transportkinematik	139

9.4.1	Versuchsdurchführung und Ergebnisse	140
9.4.2	Bewertung und Grenzen	144
9.5	Anwendung 3: Prozessüberwachung bei der Elektromotoren-Produktion	145
9.5.1	Versuchsdurchführung und Ergebnisse	146
9.5.2	Bewertung und Grenzen	148
9.6	Zusammenfassende Bewertung der Validierung	148
10	Zusammenfassung und Ausblick	149
	Publikationsliste des Autors	I
	Literaturverzeichnis	III
	Abbildungsverzeichnis	XVIII
	Tabellenverzeichnis	XXIV
	Anhang	XXV

Formelzeichen und Abkürzungen

Alle Formelzeichen und Abkürzungen sind an entsprechenden Stellen im Dokument erläutert. Es wird daher aufgrund der Übersichtlichkeit auf ein dediziertes Formelverzeichnis verzichtet.

Begriffserklärung

Alle im Text erstmalig in *kursiv* beschriebenen Notationen werden nachfolgend in ihrer Bedeutung erläutert oder sind im Text nach ihrer Einführung erklärt.

Es werden grundsätzlich, soweit möglich, genderneutrale Formulierungen gewählt. An manchen Stellen ist aufgrund von grammatikalischen, syntaktischen oder den lesefluss betreffenden Gründen nicht immer die genderneutrale Formulierung gewählt. Der Begriff des Expertensystems oder des sogenannten Anwenders wird in Einklang mit der Literatur im generischen Maskulin verwendet.

Begriff	Erklärung
allowedErrors	Erlaubte Datenpunkte außerhalb der Hüllkurve.
Bandweite/bandwidth	Suchweiten-Parameter des Clusterverfahrens.
DataBufferSize	Größe des Datenpuffers bei der Fensterung im Datenstreaming.
DataDelta	Datenbereich für die neu gepufferten Datenpunkte im Datenstreaming.
DetectionThreshold	Toleranzangabe der Hüllkurve bei der Anomalieerkennung.
DifferenceScore	Normierte Kennzahl der Ähnlichkeit zwischen Offline-Segment und Online-Signalabschnitt im Datenpuffer.
InDataPercentage	Prozentuale Angabe der Überschneidung von Offline-Segment im Online-Datenpuffer.
LSTM	Long-Short-Term Memory (Machine Learning Verfahren).
PredictionDifference	Genauigkeitsangabe zwischen Offline-Segment und Signalabschnitt im Online-Datenpuffer.
SVM	Support-Vector-Machine (Machine Learning Verfahren).
ThresholdMultiplier	Einstellbarer Parameter zur Offset-Verschiebung der Hüllkurve.
transfer learning	Verfahren zur Übertragung von Modellen auf neue Anlagen im Bereich des maschinellen Lernens

1 Einleitung

1.1 Motivation

Die Maximierung der Gesamtanlageneffektivität in der Produktion von Unternehmen in Hochlohnstandorten hat im 21. Jahrhundert höchste Priorität. Produzierende Unternehmen stehen im ständigen Kampf um Marktanteile mit globalen Wettbewerbern vor einer Vielzahl an umfassenden Herausforderungen. Mit zunehmenden Anforderungen an Verfügbarkeit und Lieferfähigkeit steigen gleichwohl Erwartungen an Preiselastizität, Terminflexibilität aber auch Individualität (Bauernhansl, Hompel & Vogel-Heuser 2014).

Um dem Kostendruck aus Niedriglohnländern sowie der Forderung nach Energieeffizienz im Sinne der nachhaltigen Produktion (Aurich & Ilsen et al. 2018) gerecht zu werden, stehen produzierende Unternehmen vor der Herausforderung Störungen in Produktionsanlagen frühzeitig zu erkennen. Der Ausfall von Produktionsmaschinen durch ungeplante Stillstände stellt einer der größten Risikofaktoren dar (Allianz Global Corporate & Specialty SE 2020) (Anderl, R., Picard, A., Wang, Y., Fleischer, J., Dosch, S., Klee, B., & Bauer, J. 2015). Auswirkungen von Produktionsausfällen betreffen in der Regel nicht nur das produzierende Unternehmen, sondern nach dem Bullwhip-Effekt (Lee, Padmanabhan & Whang 1997) ganze Lieferketten (Gronau, Kern & Jonitz 2019).

Eine Studie vom (Bundesverband Materialwirtschaft, Einkauf und Logistik e. V. & risk-methods GmbH 2018) zeigt auf, dass der Schaden einer Unterbrechung der Lieferkette in 20% der Fälle auf mehr als eine Millionen Euro zu beziffern ist. Bemerkenswert ist, dass die Anzahl an Störungen in den letzten Jahren zunimmt. Folglich ist die Vermeidung von Stillständen in Produktionsanlagen oder Verkettungen dieser Anlagen unabdingbar, um liefertreu sowie wettbewerbsfähig zu sein.

Ein wesentlicher Lösungsansatz ist die datengetriebene Kontrolle von Maschinen- und Prozesszuständen (engl.: condition monitoring). Die Prozessüberwachung gibt Aufschluss über den aktuellen Prozess- oder Maschinenzustand und kann durch geeignete statistische Verfahren künftige Zustände oder Handlungsempfehlungen prognostizieren. Der prominenteste Anwendungsfall ist die vorausschauende Instandhaltung (engl.: predictive maintenance). Hier werden auf Basis von datengetriebenen Approximationsverfahren Strategien zur Instandhaltung von Maschinenkomponenten abgeleitet. Erste industrielle Verfahren sind seit einigen Jahren etabliert und werden gewinnbringend in

modernen (Groß-) Serienproduktionen eingesetzt. Diese Verfahren benötigen Messdaten aus relevanten Wirkstellen der Maschine oder ihrer Komponenten. Diese Dateninfrastruktur ist in den letzten Jahren unter anderem unter dem Begriff „Industrie 4.0“ erarbeitet und zu einem großen Teil appliziert (Focke & Steinbeck 2018) (Bloching & Leutiger et al. 2015) worden. Dennoch kann das gesamte Potential datengetriebener Analysen kaum geschöpft werden, da viele Produktionsanlagen noch nicht über eine ausreichende Datenaufnahme verfügen (Netzer & Begemann et al. 2021). In den meisten Fällen fehlen Industrie 4.0-Ansätze zur Datenanbindung und -auswertung (Armbruster, Gönzheimer & Netzer 2021) (Netzer & Gönzheimer et al. 2021). Gerade Bestandsanlagen bei produzierenden Unternehmen (engl.: brownfield) bieten großes Potential zur Optimierung. Laut einer Studie ist das durchschnittliche Maschinenalter über zehn Jahre (Barton & Stamm et al. 2020). Die Maschinen sind somit kaum befähigt, dass moderne datengetriebene Analysen durchführbar sind. Nachrüstlösungen wie Zusatzsensoren sind industriell verfügbar, scheitern aber meist an hohem Applikationsaufwand sowie individuellem Parametrieren und menschlichem Bestimmen von bspw. Eingriffsgrenzen der Systeme zur Prozessüberwachung (Gönzheimer & Netzer et al. 2020) (Netzer & Gönzheimer et al. 2020).

Es zeigt sich, dass bestehende Ansätze zur Prozessüberwachung (Bender, Kaul & Sextro 2017) (Ruediger-Flore, Glatt & Aurich 2021) in Serienproduktionen und auf Basis geeigneter Zusatzsensoren anwendbar sind. Die Eingriffsgrenzen der Algorithmen werden durch Spezialisten festgelegt und sind kaum adaptierbar. Um allerdings den heutigen Anforderungen des Marktes wie Individualisierung oder Flexibilität sowie der Anwendung von Prozessüberwachungen bei Bestandsanlagen (Netzer & Begemann et al. 2021) gerecht zu werden, müssen Algorithmusarchitekturen adaptiv und selbstlernend entwickelt werden. Des Weiteren ergeben sich Anforderungen hinsichtlich der Übertragung und Skalierung dieser Anwendungen. Komplexe Produkte sind durch verschiedenste Fertigungsverfahren gekennzeichnet. Aus diesem Grund müssen Systeme zur Prozessüberwachung ohne großen Applikations- und Parametrieraufwand übertragbar sein (Netzer, Michelberger & Fleischer 2019). Zum aktuellen Zeitpunkt existiert keine Methodik, um Störungen in verschiedensten hochflexiblen Produktionsanlagen ohne großen Initialaufwand eines Modelltrainings aufzufinden und dem Anwender anschließend Handlungsempfehlungen vorzuschlagen.

Abgeleitet von dieser Motivation wird nachfolgend die Zielstellung der vorliegenden Dissertation beschrieben.

1.2 Zielsetzung und Aufbau der Arbeit

Ziel der vorliegenden Dissertation ist die Erarbeitung eines Verfahrens zur Erkennung von Störungen in verschiedenen hochflexiblen Produktionsmaschinen ohne Initialaufwand durch aufwendiges Antrainieren mit großer Datenmenge. Zudem erfolgt die Integration von Domänenwissen eines Anwenders. Während bisherige Verfahren auf das Antrainieren weniger, aber sich oft wiederholender Prozesse ausgerichtet sind, soll mit dem Ansatz aus vorliegender Dissertation ein neuartiges Konzept geschaffen werden, Störungen bei sehr geringer Datenmenge aufzufinden. Die Eingriffsgrenzen der Logik sind selbstlernend und adaptieren sich bei einem Prozess- resp. Produktwechsel selbst. Die Prozessunterscheidung erfolgt dabei auf Basis einer Prozesssegmentierung mittels Verfahren der Mustererkennung. Nach dem Segmentieren historischer Datenströme und dem Bestimmen von repräsentativen Mustern erfolgt das Wiederfinden der Segmente in Online-Signalen. Wenn ein gleiches Segment erkannt wurde, erfolgt die unüberwachte Anomalieerkennung. Eine nachgelagerte Klassifizierung durch antrainierte Fehlerklassen und durch formalisiertes Domänenwissen ermöglicht eine Ausgabe von Handlungsempfehlungen für den Anwender resp. Maschinenbediener.

In Kapitel 1 erfolgt die Erläuterung der Motivation dieser Arbeit. Zudem wird auf die Zielsetzung und den Aufbau der Arbeit eingegangen. Abbildung 1-1 zeigt ein Ablaufdiagramm, welches den Aufbau der Arbeit widerspiegelt. Zur Identifikation existierender Defizite im Stand der Forschung und Technik erfolgt zunächst in Kapitel 2 die zusammenfassende Übersicht des Kenntnisstandes. Es werden Ansätze aus den Teilbereichen der Mustererkennung sowie der Anomalieerkennung aufgezeigt und anschließend hinsichtlich der Anwendbarkeit bewertet.

Kapitel 3 leitet sich aus den in Kapitel 2 zusammenfassend dargestellten Forschungsdefiziten ab. Es wird ausgehend von den Defiziten eine präzisierte Zielstellung der Dissertation erarbeitet. Anschließend erfolgt die Ableitung einer methodischen Vorgehensweise zur Zielerreichung. Des Weiteren werden relevante forschungsleitende Fragestellungen abgeleitet, welche das Defizit des Standes der Forschung und Technik beschreiben.

In Kapitel 4 wird zunächst eine Einflussanalyse erarbeitet. Darin wird ein Verfahren beschrieben, welches aufzeigt, unter welchen Systemgrenzen die Anomalieerkennung Anwendung finden kann. Dabei werden Analogien zur Regelungs- und Systemtechnik

erarbeitet und eine methodische Analyse möglicher Einflussgrößen in Produktionsmaschinen entwickelt. Das Kapitel schließt mit der Auswertung und Interpretation und gibt im Fazit eine Einschätzung über die Anwendbarkeit und Grenzen der in der Zielstellung beschriebenen Anomalieerkennung wieder. Der Fokus der Arbeit liegt auf Prozessstörungen in Produktionsmaschinen, die einen kausalen Zusammenhang zwischen Prozesskraft und dem zu messenden Signal aufweisen. Umgebungseinflüsse und Abweichungen, welche im zugrundeliegenden Messsignal nicht erkennbar sind, werden in dieser Arbeit nicht berücksichtigt. Des Weiteren liegt der Fokus der Arbeit auf der einfachen und schnellen Anwendbarkeit an Brownfield Anlagen und somit dem Auffinden von signifikanten Anomalien auf Basis interner Steuerungsdaten der Maschine. Eine Störungserkennung auf Basis externer Sensoren wird in dieser Arbeit nicht betrachtet.

Anschließend werden in Kapitel 5 Ansätze zur Datensegmentierung mittels Methoden der Mustererkennung erarbeitet. Es erfolgt eine methodische Vorgehensweise zur Erarbeitung von Lösungen zur Datenvorbereitung, zu dichtebasierten Clusterverfahren sowie zum Bestimmen eines repräsentativen Musters in historischen Zeitreihen. Nachfolgend werden Verfahren aufgezeigt und bewertet, mit Hilfe derer berechnete Muster in Online-Signalen wiedergefunden werden können. Das Wiederfinden erfolgt über eine neuartige Kennzahlberechnung. Ein abschließendes Fazit des Kapitels zeigt die Vorteile der Ansätze und bewertet diese.

Kapitel 6 stellt die Umsetzung der Anomalieerkennung zusammenfassend dar. Dabei werden Ansätze des Erkennens von Anomalien in Zeitreihen beschrieben. Des Weiteren werden Unterschiede zwischen Toleranzbändern sowie Hüllkurven als Eingriffsgrenze aufgezeigt. Das Fazit des Kapitels gibt Aufschluss darüber, unter welchen technischen Randbedingungen die Anomalieerkennung Anwendung finden kann.

Nachdem die Anomalien (unüberwacht) erkannt wurden, erfolgt das Nachbereiten der Anomalien. In der Nachbearbeitung (engl.: post processing) erfolgt das Klassifizieren der Anomalie. In Kapitel 7 werden Ansätze der Anwender-Integration sowie der Integration eines Labels der Anomalietypen aufgezeigt. Das Fazit zeigt, inwiefern die Integration von Anwenderfeedback die Genauigkeit von Lernverfahren steigern kann.

In Kapitel 8 werden Möglichkeiten zur Integration von Domänenwissen sowie zur Generalisierung der entwickelten Verfahren erarbeitet. Es werden Ansätze zur Formalisie-

rung von Anwenderwissen aufgezeigt und methodisch erarbeitet, wie diese zur Unterstützung in einem datengetriebenen System integriert werden können. Des Weiteren wird aufgezeigt, welche Konzepte zur Generalisierung der Verfahren geeignet sind.

Anschließend werden alle erarbeiteten Verfahren in Kapitel 9 validiert. Dabei wird im ersten Schritt die Architektur der programmiertechnischen Umsetzung vorgestellt. Nachfolgend werden die Funktionsweise und der Aufbau der Anomalierkennungs-App beschrieben. Die Validierung erfolgt an drei unterschiedlichen praxisrelevanten Anwendungsfällen. Eine systematische Herleitung und Auswahl der Anwendungsfälle erfolgt an fünf Kriterien, welche zu Beginn des Kapitels eingeführt werden. Die Anwendungsfälle zeichnen sich unter anderem durch hohe industrielle Relevanz aus. Zudem sind sie repräsentativ für weitere Produktionsprozesse und -maschinen. Der erste Validierungsfall zeigt die Prozessüberwachung bei der Zerspanung zur Qualitätssicherung auf. Anschließend werden die Verfahren an einer Transportkinematik zur Bauteilverlustüberwachung erneut validiert. Abschließend wird ein Validierungsfall erläutert, bei dem mit Hilfe einer Fügeinheit bei der Elektromotorenproduktion eine Qualitätsüberwachung realisiert wurde. Auch in diesem Anwendungsfall wurden die entwickelten Verfahren eingesetzt und anschließend bewertet.

Im letzten Kapitel 10 werden die Erkenntnisse aus vorliegender Dissertation zusammenfassend eingeordnet und bewertet. Ein Ausblick zeigt auf, welche weiteren Forschungsfragen abgeleitete werden können.



Abbildung 1-1: Aufbau der Arbeit dargestellt als Ablaufdiagramm.

2 Stand von Forschung und Technik

2.1 Die Produktionsmaschine – Grundverständnis

Die Produktion wird als der Geschäftsbereich mit der höchsten Wertschöpfung bezeichnet. Zur Sicherung der Wettbewerbsfähigkeit, gerade in Hochlohnländern, werden Produktionsabläufe zunehmend automatisiert. Im nachfolgenden Kapitel wird ein Grundverständnis zu Fertigungsverfahren, deren Automatisierung sowie zu Effektivität einer Produktion vermittelt.

2.1.1 Fertigungsverfahren

Fertigungsverfahren umfassen alle Verfahren zur „Herstellung von geometrisch bestimmten [...] festen Körpern“ (Förster & Förster 2018, S. 23). Die Verfahren können entweder von Anlagen oder händisch durchgeführt werden (Förster & Förster 2018). Fertigungsverfahren werden von (Deutsches Institut für Normung 2003) in sechs Hauptgruppen unterteilt. Die sechs Hauptgruppen sind Urformen, Umformen, Trennen, Fügen, Beschichten und Stoffeigenschaften verändern und sind in Abbildung 2-1 sichtbar (Deutsches Institut für Normung 2003).

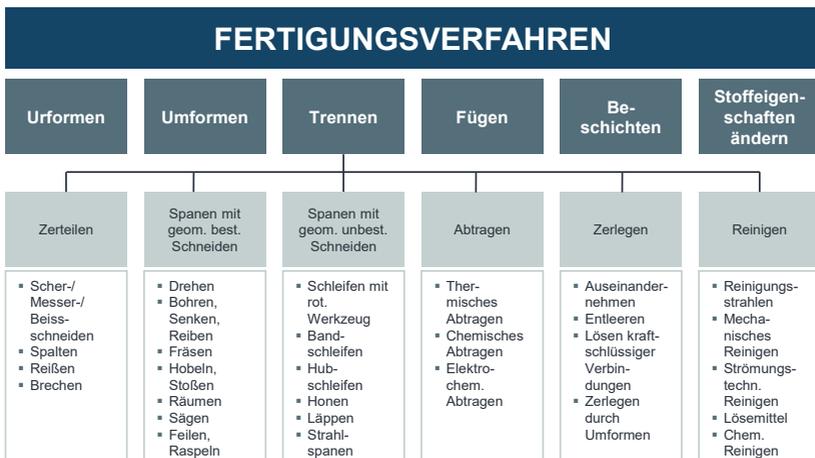


Abbildung 2-1: Ausschnitt der Fertigungsverfahren nach (Deutsches Institut für Normung 2003). Darstellung in Anlehnung an (Hirsch 2016).

Die wichtigste Hauptgruppe der DIN 8580 ist die Gruppe Trennen. Trennende Verfahren werden in Werkzeugmaschinen umgesetzt. Im Bereich der Automatisierung kommen verstärkt Industrieroboter zum Einsatz. Diese können sowohl einfache Handhabungs- als auch Montageprozesse ausführen. Die Methoden aus dieser Arbeit sind daher auf Anwendungsfälle einer Werkzeugmaschine als auch Montage und Handhabungseinrichtung ausgerichtet.

2.1.2 Produktionskennzahlen

Zur Überprüfung der Effektivität einer Produktion werden sogenannte Shopfloor-Kennzahlen verwendet. Die relevanteste Kennzahl in der Produktion ist die Gesamtanlageneffektivität (engl.: overall equipment effectiveness, im Folgenden OEE genannt) (Focke & Steinbeck 2018). Die Kennzahl setzt sich aus dem Produkt von drei Dimensionen zusammen:

$$OEE = \text{Verfügbarkeit} * \text{Leistung} * \text{Qualität} \quad 2-1$$

Der Verfügbarkeitsfaktor beschreibt das Verhältnis aus der tatsächlichen Produktionszeit zur theoretisch möglichen Produktionszeit. Der Leistungsfaktor beschreibt den Quotienten aus Ist-Ausbringung zu Soll-Ausbringung. Das Verhältnis von allen produzierten Teilen in einer bestimmten Zeit zu den Teilen, die ohne Fehler hergestellt sind, wird im Qualitätsfaktor dargestellt (Focke & Steinbeck 2018). Die OEE wird als Prozentwert zwischen 0 und i. d. R. 100% angegeben. Mithilfe dieser Kennzahl lässt sich die Effektivität einer Produktion transparent darstellen und geeignete Analysen einleiten.

2.1.3 Lebensphasen einer Maschine

Nach (Deutsches Institut für Normung 2011) werden die Lebensphasen von Maschinen in Transport, Montage, Inbetriebnahme, Betrieb, Reinigung und Wartung eingeteilt. Um eine Maschine hocheffektiv nutzen zu können, wird versucht der Anteil an Reinigung und Wartung so gering wie möglich zu gestalten, um die Produktionszeit zu maximieren. Besonders ausschlaggebend für die Effektivität einer Produktion sind die aus Störungen entstehenden ungeplanten Stillstandzeiten. Störungen durch intelligente Wartung oder Reinigung vorzubeugen bzw. diese zu vermeiden ist ein essentielles Ziel in jeder Produktion. Allerdings müssen Systeme zur Störungserkennung oder -vermeidung stets auf die individuelle Maschine angepasst und ausgelegt werden. Der Fokus

auf „Störungen und deren Ursachen (...) [ist dabei zentral, da sie] den größten Fertigungsausfall und die höchsten Folgekosten mit sich bringen“ (Brecher & Weck 2021, S. 199). Im nachfolgenden Kapitel werden Störungsarten und deren Herausforderungen erläutert.

2.2 Störungsarten und deren Herausforderungen in Produktionsmaschinen

Um Störungen in Werkzeugmaschinen zu vermeiden, muss zunächst geklärt werden wie Störungen definiert sind. Aus diesem Grund werden in den nachfolgenden Kapiteln Ausfallgründe und deren Auswirkungen in Form von Störungen aufgezeigt. Der letzte Abschnitt des Kapitels befasst sich mit Instandhaltungsstrategien und dem Einsatz von Industrie 4.0.

2.2.1 Störungen in Produktionsmaschinen

Störungen in Produktionsmaschinen und Qualitätsmängel haben Ihren Ursprung in unterschiedlichen Fehlverhalten bzw. anomalen Verhalten (Brecher & Weck 2021). In Abbildung 2-2 sind Einflussfaktoren und deren Fehlerauswirkungen auf die Funktionsfähigkeit des Fertigungsmittels sowie die Auswirkung auf die Qualität des Erzeugnisses dargestellt.

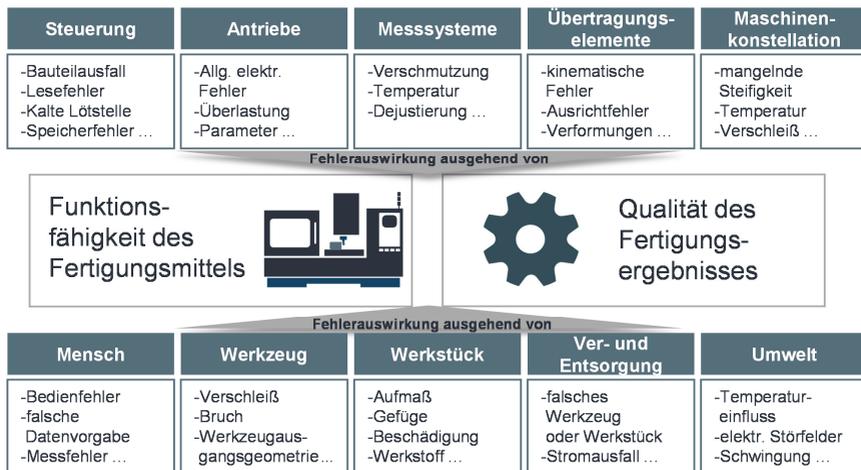


Abbildung 2-2: Einflussgrößen auf die Funktion der Fertigungsmittel und die Qualität der Produkte. Darstellung in Anlehnung an (Brecher & Weck 2021).

(Brecher & Weck 2021) beschreiben dort, dass zu den Fehlerursachen unter anderem Störungen an Werkzeug- und Werkstückkomponenten wie der Bruch des Werkzeugs oder Beschädigungen des Werkstückes gehören. Auch Fehlverhalten des Menschen durch falsche Dateneingaben oder Bedienfehler spielen eine wichtige Rolle. Der Einfluss von Störungen lässt sich durch die Auswirkung auf die bereits eingeführte Effektivitätskennzahl (OEE) verdeutlichen. Das nachfolgende Kapitel zeigt diesen Zusammenhang auf und beschreibt, welche Herausforderungen daraus resultieren.

2.2.2 Herausforderungen und Auswirkungen von Störungen

Aus den an Produktionsmaschinen auftretenden Störungen können sich zwei potenzielle Folgen entwickeln. Diese Folgen wirken sich, wie in Abbildung 2-2 sichtbar, entweder auf die Maschine aus, indem die Funktionsfähigkeit und Verfügbarkeit eingeschränkt ist, oder auf das Werkstück, indem dessen Qualität reduziert wird. Beide Folgen haben eine direkte negative Auswirkung auf die Gesamtanlageneffektivität. So kann sich beispielsweise durch den Bruch einer Maschinenkomponente, resultiert durch erheblichen Verschleiß, einerseits die Verfügbarkeit der Produktionsmaschine

reduzieren (May & Koch 2008). Andererseits wird durch einen Bedienerfehler, die Bauteilqualität maßgeblich beeinflusst.

Aufgrund des direkten Zusammenhangs zwischen Störungen und der Anlageneffektivität ist die Vermeidung von Störungen im Rahmen der OEE-Optimierung essentiell. Abbildung 2-3 zeigt beispielhaft den Zusammenhang zwischen der Reduzierung der Qualität sowie der Verfügbarkeit ausgehend von einer Störung.

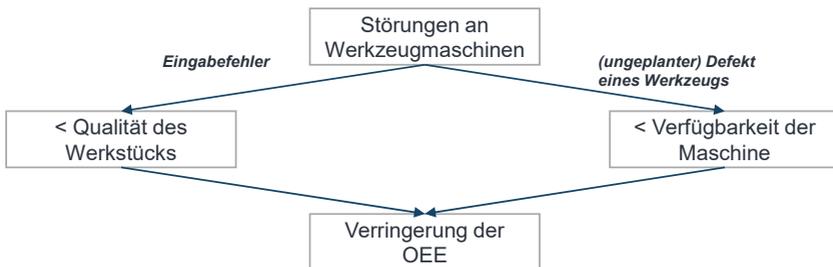


Abbildung 2-3: Beispielhafter Zusammenhang von Störungen in einer Werkzeugmaschine mit Auswirkung der OEE.

2.2.2.1 Möglichkeiten zur Optimierung der OEE

Im Rahmen des sogenannten Total Productive Management, kurz: TPM genannt, wird die Optimierung der OEE angestrebt. Hierfür beschäftigt sich das TPM großen Verlustquellen, die eine Reduzierung der OEE erklären. (Matyas 2013)

Um die OEE zu optimieren, müssen deshalb die drei Gruppen von Verlustquellen optimiert werden:

- Verlustzeiten
- Geschwindigkeitsverluste
- Fehler

Geschwindigkeitsverluste und Fehler können unter anderem durch eine inkorrekte Arbeitsweise oder durch Verschleiß herbeigeführt werden (Matyas 2013). Verlustzeiten entstehen vor allem durch „Anlagen-/Maschinenausfälle (..) [aufgrund von] Störungen“ (Matyas 2013, S. 225).

Ungeplante Stillstandzeiten von Maschinen und Anlagen bilden eine besondere Herausforderung, da sie bislang kaum vorhersagbar sind. Um das Risiko zu minimieren, müssen geeignete Maßnahmen ergriffen werden, um frühzeitig auftretende Störungen

zu erkennen. Das nachfolgende Kapitel erläutert verschiedene Maßnahmen der Instandhaltung von Maschinen und deren Komponenten und zeigt, wie mit Hilfe von Industrie 4.0 eine vorausschauende Instandhaltung realisiert werden kann.

2.2.3 Instandhaltungsstrategien

In diesem Kapitel werden relevante Instandhaltungsstrategien eingeführt und im Speziellen die vorausschauende Wartung erläutert.

2.2.3.1 Allgemeine Strategien

Instandhaltung ist die „Kombination aller technischen und administrativen Maßnahmen sowie Maßnahmen des Managements während des Lebenszyklus einer Betrachtungseinheit zur Erhaltung des funktionsfähigen Zustandes, der Rückführung in diesen, so dass sie die geforderte Funktion erfüllen kann“ (Deutsches Institut für Normung 2018, S. 6). Nach (Reichel, Müller & Haefls 2018) lassen sich vier Instandhaltungsstrategien unterscheiden:

- Ausfallbehebung
- Zeitgesteuert periodische Instandhaltung
- Zustandsorientierte Instandhaltung
- Vorrasschauende Instandhaltung

Durch vorausschauende Instandhaltung werden die Instandhaltungszeitpunkte und Instandhaltungsmaßnahmen wirtschaftlich optimal ermittelt, weshalb im Folgenden ausschließlich diese Art der Instandhaltung betrachtet wird.

2.2.3.2 Predictive Maintenance

Mit Predictive Maintenance ist es möglich einen kostengünstigen „Wartungszeitpunkt abzuleiten und somit Ressourceneinsätze proaktiv zu steuern“ (Bink & Zschech 2018, S. 554).

Um überflüssige Wartungsmaßnahmen zu umgehen, werden die Handlungen durch den aktuellen Zustand mittels Überwachung von Maschinendaten und den zukünftigen Zustand bestimmt. Um den zukünftigen Zustand adäquat zu bestimmen, müssen geeignete Indikatoren aufgenommen und analysiert werden (Bink & Zschech 2018). Durch das Fortschreiten von Industrie 4.0 und der immer zunehmenden Digitalisierung sind Grundlagen hierfür geschaffen.

2.3 Industrie 4.0

Unter dem Begriff Industrie 4.0 versteht man die „Vision der zukünftigen Produktion [...] (mit) modulare(n) und effiziente(n) Fertigungssystemen und [...] Szenarien, in denen Produkte den Herstellungsprozess selbst steuern“ (Lasi & Fettke et al. 2014, S. 261) sowie horizontal und vertikal vernetzt sind. (Lasi & Fettke et al. 2014) Einige wesentliche Konzepte von Industrie 4.0 sind Smart Factory und Cyber-Physische Systeme. Unter Smart Factory ist die vollständig mit Sensoren, Aktoren und autonomen Systemen ausgestattete Fabrik zu verstehen. Bei Cyber-Physischen Systemen findet eine „Verschmelzung [...] (von) physikalischer und digitaler Ebene statt“ (Lasi & Fettke et al. 2014, S. 262). Auch der Bereich Predictive Maintenance wird zu den Cyber-Physischen Systemen eingeordnet, da neben dem aktuellen Verschleißzustand ebenfalls Einsatzparameter digital erfasst werden. Durch die Konzepte von Industrie 4.0 sind die technischen Voraussetzungen für Datenerhebungen an den Maschinen gegeben und können direkt für intelligente Systeme zur Produktionsoptimierung genutzt werden.

Durch die implementierte Sensorik in der Smart-Factory können Daten, die für weitere Analysensysteme wie Predictive Maintenance benötigt werden, erfasst werden. Im folgenden Abschnitt werden industriell relevante Datentypen erläutert und die Datenaufnahme in Produktionsmaschinen eingeführt. Das Kapitel schließt mit den noch bestehenden Herausforderungen der Datenaufnahme bei Altsystemen, den sogenannten Brownfield Anwendungen.

2.3.1 Datentypen

Nach (Vogel 2015) unterscheidet man in der Prognosetechnik zwischen qualitativen und quantitativen Verfahren. Qualitative Verfahren sind vornehmlich subjektive Verfahren, weshalb sie in vorliegender Dissertation keine Anwendung finden. Quantitative Verfahren sind „Rechenverfahren zur Auswertung empirischer Daten“ (Vogel 2015, S. 13), die es erlauben, Vorhersagen über zukünftige Daten zu treffen. Hängen die vorherzusagenden Größen von beeinflussbaren Parametern ab, so wendet man meist Regressionsanalysen an. Hängen die vorherzusagenden Größen von nicht beeinflussbaren Größen wie bspw. Zeit ab, führt dies zu Zeitreihenanalysen.

2.3.2 Zeitreihenanalyse

Zeitreihen sind eine zeitabhängige Abfolge von Messungen (Vogel 2015). Dabei werden diskrete Messwerte, die in zeitlich endlichen Abständen anfallen, aufgezeichnet.

Zu jedem Zeitpunkt $t \in T$ liegt eine Beobachtung vor. Messdaten aus Sensoren oder internen Maschinenparametern werden als Zeitreihen aufgenommen und weisen einige Besonderheiten auf. Zeitreihenanalysen, bspw. zur Störungserkennung sind daher auf maschinen- und prozessindividuelle Besonderheiten anzupassen. Die Einflüsse sind:

- Rauschintensität u.a. durch externe Einflussgrößen, speziell im Brownfield
- Latenz (zeitlicher Verzug und Gradient des Verlaufs bei Sollwertänderungen)
- Genauigkeit (bezogen auf Abtastrate und Auflösung)

In Produktionsmaschinen ist die Erkennung und Vorhersage von Werkzeugverschleiß ein wesentliches Anwendungsgebiet von Zeitreihenanalysen. Durch eine frühzeitige Erkennung von Verschleiß und der daraus resultierenden Prognose der Restlebensdauer des Werkzeuges können Kosten für Wartung oder Ausschussteile reduziert werden (Oberlé & Schorr et al. 2020).

2.3.3 Datenaufnahme bei Produktionsmaschinen

Cyber-Physische-Systeme (CPS) bilden eine wichtige Grundlage von Industrie 4.0. Die Kommunikation zwischen Produktionssystemen untereinander wird unter dem Begriff Machine-2-Machine-Kommunikation zusammengefasst (M2M) (Mierswa 2016).

Für M2M-Kommunikation gibt es verschiedene Standardlösungen wie:

- Message Queue Telemetry Transport (MQTT)
- Data Distribution Service (DDS)
- Open Platform Communications Unified Architecture (OPC UA)

OPC UA ist ein Ordnungsrahmen im Kontext der M2M-Kommunikation. Universal Architecture (UA) bedeutet, dass die aktuellen Spezifikationen von der OPC Foundation verwendet werden. Interessant sind besonders Weiterentwicklungen von Protokollformen für Produktionsmaschinen, welche auf OPC UA basieren wie beispielsweise Umati. Dadurch wird ein „offenes Informationsmodell zur Anbindung von Maschinen unterschiedlicher Hersteller“ (Gönnheimer & Netzer et al. 2020, S. 517) geschaffen. Vorliegende Arbeit befasst sich hingegen nicht mit der Aufnahme von Daten, sondern mit deren Verarbeitung.

2.3.4 Herausforderungen in Brownfield Anwendungen

Die Anwendung von Condition Monitoring Systemen bei Brownfield Anwendungen, welche sich gerade durch sehr heterogene Hardware charakterisieren, bringt einige Herausforderungen mit sich (Netzer & Begemann et al. 2021). Nachfolgend werden Besonderheiten von Brownfield Anlagen aufgelistet, welche für die Entwicklung von datengetriebenen Verfahren relevant sind.

- Keine Zusatzsensorik verbaut. Messdaten (Antriebssignale) über die Steuerung auslesbar. Abtastfrequenz meist analog zum SPS-Takt.
- Aufgrund fortgeschrittenem Maschinenverschleiß meist hohes Signalrauschen und geringe Datenreproduzierbarkeit.
- Geringe Informationsgenauigkeit aufgrund überlagerter Einflussgrößen in der Übertragungsstrecke (vgl. Kapitel 4). (Byrne & Dornfeld et al. 1995)
- Erhöhte Latenz der Messsignale aufgrund der Bereitstellung der Daten aus der Steuerung.
- Keine direkte Prozesskraftmessung mit Antriebsdaten möglich.
- Übertragbarkeit gering, da Brownfield Maschinen immer individuelle Ausprägungen aufweisen (z.B. durch Verschleiß)

Für diese Dissertation gilt nachfolgende Definition.

Definition (Brownfield Maschine)

Eine Brownfield Maschine ist eine Produktionsmaschine, welche bereits gefertigt, seit einiger Zeit in Betrieb steht und fortgeschrittenen Verschleiß aufweisen kann. Eine Brownfield Maschine ist nicht mit externer Zusatzsensorik ausgestattet. Die Datenaufnahme (Antriebssignale) erfolgt in der Steuerung.

Auch bei Brownfield Maschinen wird eine ganzheitliche Vernetzung der Produktionsanlagen forciert, da sich gerade auch bei älteren Maschinen der Einsatz von Condition Monitoring oder Prozessüberwachungssysteme als äußerst vorteilhaft zeigt (Netzer & Begemann et al. 2021). Oftmals werden sogenannte „Retrofit“ Systeme (Barton & Stamm et al. 2020) nachgerüstet, welche eine Auswertung von direkten Messgrößen ermöglichen. Die Investition benötigter Zusatzsensorik ist allerdings in jedem Fall abzuwägen. Vorliegende Dissertation greift die Herausforderungen von Brownfield Anlagen auf und zeigt auf, wie auf Basis von vorhandenen, in der Steuerung freigegebenen und bereitgestellten, Antriebsparametern ein Condition Monitoring System umsetzbar ist. Auf die Implementierung einer Infrastruktur, bestehend aus Hardware und Software

zur Datenaufnahme, wird in dieser Arbeit nicht eingegangen. Sie ist allerdings Voraussetzung für den Einsatz von aufbauenden Condition Monitoring Lösungen. Mögliche Arten der Anbindung zeigen (Barton & Stamm et al. 2020) oder (Gönnheimer, Puchta & Fleischer 2021).

2.4 Condition Monitoring im Kontext von Industrie 4.0

Die Anwendung von software-getriebenen Optimierungsfunktionen in der Produktion ist nur möglich, wenn zeitnahe, faktenbasierte Daten, die den Betriebszustand kritischer Produktionssysteme und die Effektivität kritischer Anlagenfunktionen beschreiben, in ausreichender Menge vorliegen. Software-getriebene Funktionen wie Condition Monitoring sind dann entscheidende Werkzeuge zur stetigen Produktionsoptimierung. Condition Monitoring Systeme zeigen dem Betreiber den Zustand der Maschine oder Komponente transparent auf und können überdies weitere Strategien wie Planung von Wartungsarbeiten ableiten. Vorteile davon sind die Minimierung des Personaleinsatzes sowie die Verringerung von ungeplanten Stillständen. Dabei ist es essentiell, dass die notwendigen Daten in der richtigen Form vorliegen (Davies 2012). Durch die Überwachung von Produktionsanlagen wird erwartet, dass die Produktionskosten durch Steigerung der Gesamtanlageneffektivität (OEE) um 10 - 30 % gesenkt werden (Bauernhansl, Hompel & Vogel-Heuser 2014). Außerdem wird erwartet, dass sich die Instandhaltungskosten um 20 - 30% durch Condition Monitoring reduzieren lassen können (Bauernhansl 2016). Des Weiteren können durch Standardisierung der Datenübertragung mittels einheitlicher Protokolle weitere Potenziale erhoben werden. Das ist wichtig, da ein stetiger Rationalisierungsdruck in der Produktion herrscht, der eine möglichst effiziente Nutzung der vorhandenen technischen und personellen Ressourcen sowie schlanke organisatorische Prozesse unverzichtbar macht (Pethig, Niggemann & Walter 2017). Im Allgemeinen liegt der Fokus der Überwachung entweder auf der Maschine selbst (bspw. Leistungsüberwachung), den verwendeten Werkzeugen (bspw. Verschleißzustand), dem Werkstück (bspw. Geometrie und Oberflächenmerkmale) oder dem Prozess (bspw. Spanbildung) (Byrne & Dornfeld et al. 1995). Nachfolgendes Kapitel gibt einen Überblick der Arten der Zustandserkennung, geht anschließend auf die Funktionsweise von Condition Monitoring Systemen ein und diskutiert den schematischen Aufbau dieser. In diesem Kapitel wird ein Forschungsdefizit im Hinblick auf die Übertragung von Condition Monitoring Systemen auf weitere Maschinen aufgezeigt.

2.4.1 Arten der Zustandserkennung

Heutige Anwendungen von Condition Monitoring Systemen basieren in der Regel auf maschinellen Lernverfahren. Klassische regelbasierte Ansätze sind bei komplexer Datenstruktur sowie beim Einsatz in hochflexiblen Anlagen kaum anwendbar, da die Regelketten sehr schnell komplex und ineffizient werden (Mehdiyev & Krumeich et al. 2016). Außerdem können sich in vielen Szenarien Regeln abhängig von den Spezifikationen der Anwendungsdomäne dynamisch ändern und weiterentwickeln (Mehdiyev & Krumeich et al. 2016).

Moderne Condition Monitoring Systeme verwenden dabei meist Techniken, die dem überwachten und unüberwachten Lernen zuzuordnen sind sowie einer Kombination von beidem, dem teilüberwachten Lernen (Sathya & Abraham 2013). Durch die Komplexität des Condition Monitorings, vor allem bei flexiblen Maschinen, werden in der Anwendung oftmals semi-supervised Systeme, die sich sowohl unüberwacht als auch überwacht Lernmethoden bedienen, genutzt (Yuan & Liu 2013).

2.4.1.1 Überwachtes Lernen

Überwachtes Lernen basiert auf dem Antrainieren einer Datenstichprobe aus einer Datenbank mit bereits zugewiesener korrekter Klassifizierung (Sathya & Abraham 2013). Das bedeutet, dass der Algorithmus anhand zugewiesener Klassifikationen trainiert wird. Im Bereich des Condition Monitorings werden bestimmte Zustandslevel als Klassen definiert, mit derer sich Maßnahmen ableiten lassen. Dafür werden Daten für die jeweiligen Level benötigt. Durch Simulationen können künstlich Daten generiert werden. Im optimalen Fall werden Echtzeitdaten verwendet (Javadpour & Knapp 2003). Sind die Klassen definiert und ausreichend Daten zum Lernen vorhanden, wird der Algorithmus trainiert. Ziel ist es, dass das Verfahren die komplexen Zusammenhänge in den Daten annähert und anschließend auf Basis neuer Daten Zustandsniveaus vorherzusagen kann (Serin & Sener et al. 2020).

2.4.1.2 Unüberwachtes Lernen

Unüberwachte maschinelle Lernverfahren bestimmen Zusammenhänge in Daten und nutzen diese zur Zustandsüberwachung (Amruthnath & Gupta 2018). Hier werden oft Clustering-Ansätze verwendet. Dabei wird eine Anomaliedetektion realisiert, um Störungen im Maschinenzustand in Daten zu erkennen. Es gilt die Hypothese, dass Anomalien in Daten auf ein anormales Verhalten in der Maschine deuten (Amruthnath &

Gupta 2018) und somit zu Störungen führen. Für Maschinenkomponenten, wie z.B. Getriebe, werden häufig überwachte Lernverfahren wie Neuronale Netze oder Support Vektor Maschinen, wie auch (Praveenkumar & Saimurugan et al. 2014) (Zuber & Bajrić 2020) (Rafiee & Arvani et al. 2007) in ihren Arbeiten anschaulich aufzeigen, verwendet. Clusterverfahren stoßen ohne Vor- oder Nachverarbeitungsverfahren bei hochdimensionalen Datenstrukturen an ihre Grenzen, weshalb oftmals Verfahren zur Dimensionsreduktion Anwendung finden (Maier, Schriegel & Niggemann 2017).

Ein teilüberwachter Ansatz, also ein hybrides System, ist gerade bei Condition Monitoring Anwendungen ohne große Datenmengen wie beispielsweise bei Brownfield Anwendungen in der Produktion sinnvoll (Serin & Sener et al. 2020) (Netzer & Palenga et al. 2021).

2.4.2 Schematischer Aufbau eines Condition Monitoring Systems

Im Allgemeinen wird die Fehlerdiagnose in drei Hauptschritte unterschieden. Zuerst erfolgt eine Signalerfassung, im Anschluss die Merkmalsaufbereitung und -verarbeitung. Im dritten Schritt erfolgt die Messwertinterpretation bzw. Fehlerklassifizierung (siehe Abbildung 2-4), welche auf statistische oder lernende Verfahren basieren kann. Die Messwertaufbereitung und -verarbeitung zielt darauf ab, repräsentative Merkmale aus den gesammelten Signalen zu extrahieren. In der Fehlerklassifizierung können unter anderem Ansätze der künstlichen Intelligenz verwendet werden, um aufbereitete Merkmale anzutrainieren (Lei & Jia et al. 2016). Merkmale können auch über statistische Verfahren detektiert oder klassifiziert werden. Abbildung 2-4 zeigt, dass die verwendeten Signale zur Messwertaufnahme dabei abhängig von Objekt, Prozess und Umgebung sind. Auf Basis der Messwertinterpretation angereichert mit einem passenden Bewertungsmodell findet die Entscheidung für weitere Maßnahmen statt. So sind Condition Monitoring Systeme in der Lage, die wesentlichen Zustandsänderungen der überwachten Bauteile und mögliche Anomalien sofort zu erkennen und unter Anwendung geeigneter Modelle zu bewerten. Der generische Prozess des Condition Monitoring ist notwendig, um proaktiv Anlagenausfälle zu verhindern (Schenk 2010).

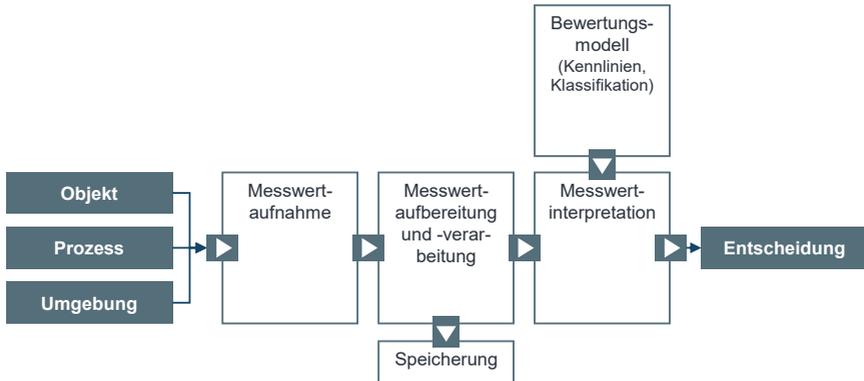


Abbildung 2-4: schematischer Aufbau eines Condition Monitoring Systems. Darstellung in Anlehnung an (Schenk 2010).

Abbildung 2-4 zeigt einen generischen Ablauf, welcher sowohl für regelbasierte als auch lernende Verfahren genutzt werden kann. Für lernende Verfahren sind die Bausteine teilweise leicht verändert angeordnet, ist allerdings an dieser Stelle irrelevant.

2.4.3 Herausforderungen bei der Anwendung von Condition Monitoring Systemen

Nachfolgend sind die zentralen Herausforderungen bei der Anwendung von Condition Monitoring Systemen erläutert.

2.4.3.1 Notwendigkeit von Referenzfahrten

Bei flexiblen Produktionsmaschinen existieren aufgrund der hohen Anzahl an verschiedenen Bearbeitungsprozessen viele maschinen- oder umweltseitige Einflussgrößen, welche bei Condition Monitoring Systemen berücksichtigt werden müssen. Aktuelle im Stand der Forschung erkennbare Arbeiten basieren in der Regel auf Referenzfahrten, damit die maschinen- oder umweltseitige Einflussgrößen über die Dauer gleich bleiben und eine relative Zustandserkennung realisiert werden kann. Dies bedeutet, dass bei Bauteil- oder Komponentenänderung eine neue Referenzfahrt notwendig ist, um die Maschine an die neuen Bedingungen anzupassen (Weck & Brecher 2013). Der Nachteil von Referenzfahrten ist, dass diese in der Regel während Maschinenhauptzeiten stattfinden und so nachteilig hinsichtlich der Maschinenverfügbarkeit sind (vgl. Kapitel 2.1.2). Beim Verzicht von Referenzfahrten, gerade in flexiblen Produktionsanlagen,

ergibt sich die Herausforderung viele manuelle feste Eingriffsgrenzen zu definieren. Die Regelkette von Condition Monitoring Systemen wird komplex und starr.

2.4.3.2 Externe Sensoren

Herkömmliche industrielle Condition Monitoring Systeme benötigen in aller Regel Daten von externen Sensoren. Externe Sensoren werden als Zusatzsensoren an einer Maschine an entsprechender Wirkstelle implementiert. Eine Nachrüstung von Zusatzsensorik ist vor allem bei alten Maschinen teuer und meist wirtschaftlich fraglich. Bei diesen Brownfield Anwendungen sollte auf bereits bestehende interne Sensorik in der Maschine zurückgegriffen werden. Daten aus internen Steuerungen bedingen die Anwendung von intelligenten Algorithmen, da die Informationsgenauigkeit aufgrund überlagerter Einflussgrößen gering ist (Byrne & Dornfeld et al. 1995). Die Herausforderung bei der Verwendung interner Steuerungsdaten ist es, mittels intelligenten Verfahren den gleichen Informationsgehalt wie bei externen Sensordaten zu extrahieren (Byrne & Dornfeld et al. 1995).

2.4.3.3 Generalisierung

Erste moderne Condition Monitoring Systeme, welche auf maschinelle Lernverfahren basieren, sind bereits erfolgreich in vielen Systemen und Anlagen implementiert. Es lässt sich allerdings beobachten, dass die Implementierung einen sehr großen Applikationsaufwand mit sich bringt (Gönnheimer & Netzer et al. 2020) (Netzer & Gönnheimer et al. 2020). Die Systeme werden in der Regel als sogenannte „Insellösung“ (Gönnheimer & Netzer et al. 2020) an einer Anlage implementiert und auf individuelle Maschineneigenschaft appliziert. Vorhandenes Wissen des Anwenders oder aus anderen Anlagen wird nicht integriert. Erste intelligente Verfahren bspw. des *transfer learnings* werden beschrieben, sind aber bei geringem „I4.0-Reifegrad“ (Anderl, R., Picard, A., Wang, Y., Fleischer, J., Dosch, S., Klee, B., & Bauer, J. 2015) in Brownfield Anlagen nicht anwendbar.

2.4.4 Zusammenfassung und Bewertung von industriellen Condition Monitoring Systemen

Condition Monitoring hat sich in den letzten Jahren deutlich weiterentwickelt und wird oft als „Enabler“-Technologie bezeichnet. Dadurch werden weiterführende Analysen wie bspw. Predictive Maintenance ermöglicht. Klassische Condition Monitoring Systeme, welche auf regelbasierten Ansätzen beruhen, sind in komplexen Anlagen kaum

anwendbar. Es zeigt sich jedoch, dass auch moderne Condition Monitoring Systeme Defizite aufweisen. Gerade die beschriebenen Defizite bei der Referenzierung, Einsatz externer Sensorik sowie Generalisierung erschweren die Anwendung der Systeme deutlich. Es eröffnen sich überdies weitere Forschungsfragen, wie Condition Monitoring Systeme ohne Referenzfahrten in der Brownfield Anwendung generalisiert anwendbar sind. Die Dissertation behandelt mitunter diese Forschungsfragen und zeigt Verfahren auf, um diese und weitere Defizite (Kapitel 2.10) zu lösen.

2.5 Mustererkennung und Zeitreihen

Wiederkehrende Muster in Zeitreihen zu erkennen bildet kontextübergreifend die Grundlage vielfältiger Analyse- und Vorhersagemethoden (Torkamani & Lohweg 2017) (Mueen 2014). So findet die Mustererkennung in Zeitreihen unter anderem Anwendung in der Analyse und Vorhersage von Finanzmärkten (Du & Jin et al. 2009), bei DNA-Sequenzanalysen (Pevzner & Sze 2000), in der Biomedizin (Balasubramanian & Prabhakaran 2013) bzw. Medizin (Ahmadi & Padoy et al. 2009) (Lin & Li 2010) (Liu & Li et al. 2015), in Soundanalysen (Gomes & Batista 2015) (Hao & Shokoohi-Yekta et al. 2013) (Muscariello, Gravier & Bimbot 2011), in Bewegungserkennungen (Murakami & Doki et al. 2005) (Minnen & Starner et al. 2006), in der Meteorologie (Cassisi & Aliotta et al. 2013) und in der Analyse von Energieprozessen (Waczowicz & Reischl et al. 2015) (Ludwig & Waczowicz et al. 2017). Dabei kommt der Definition eines Musters eine hohe Bedeutung zu, um ein wiederkehrendes Muster von andersartigen Mustern unterscheiden zu können. Da diese in der Literatur durchaus einer starken Varianz unterliegt, werden die folgenden Definitionen als Grundlage für diese Arbeit eingeführt.

Definition (Muster in Zeitreihen)

Ein Muster ist eine n -dimensionale Zeitreihen-Sequenz einer bestimmten Länge l unter Berücksichtigung von weiteren Zustandsvariablen.

Beispiel: Ein Muster in einer Produktionsmaschine kann eine Zeitreihen-Sequenz bestehend aus den Positionsverläufen X, Y und Z sowie weiteren Antriebsdaten wie Motorstrom und Drehmoment inkl. der Zustandsvariablen (Werkzeugnummer) sein.

Definition (wiederkehrendes Muster in Zeitreihen)

Ein Muster wird als wiederkehrend bezeichnet, wenn es mindestens zweimal innerhalb einer Zeitreihe vorzufinden ist und einer definierten, ausreichenden Ähnlichkeit unterliegt.

Es wird deutlich, dass die Definition des wiederkehrenden Musters maßgeblich von dem Begriff der Ähnlichkeit abhängt. Diese kann entsprechend des Anwendungsfalls unterschiedlich definiert werden. Wie in Abbildung 2-5 zu sehen, können verschiedene Fälle der Ähnlichkeit zweier Muster auftreten, welche je nach Ziel des Verfahrens unterschiedlich bewertet werden müssen. Das linke Diagramm zeigt eine kurze, aber starke Abweichung, hingegen im rechten Diagramm eine lange, aber geringe Abweichung zwischen den Zeitreihen herrscht. Die Ähnlichkeit kann in beiden Fällen anders interpretiert werden.

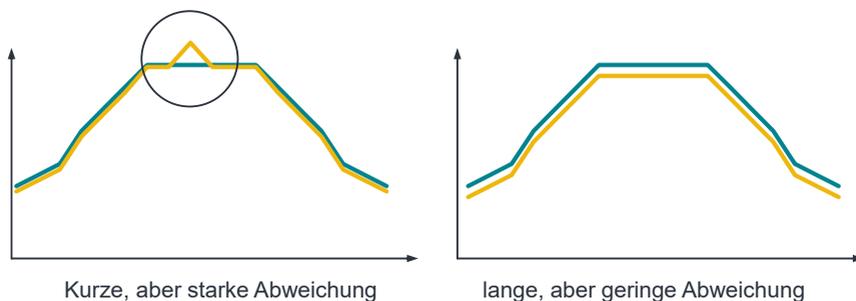


Abbildung 2-5: Links: Kurze, aber starke Abweichung. Rechts: Lange, aber geringe Abweichung), Unterschiedliche Interpretation der Ähnlichkeit von Mustern.

Basierend auf diesem Verständnis umfasst die Suche nach wiederkehrenden Mustern in Zeitreihen einerseits die Identifikation von sogenannten Segmenten und andererseits die Suche nach dem wiederholten Auftreten des Segments innerhalb der betrachteten Zeitreihe. Erfolgt lediglich eine Suche von vorgegebenen Segmenten innerhalb einer Datenreihe, kann das unterliegende Verfahren den überwachten Methoden zugeordnet werden. Sind jedoch vorab die Segmente unbekannt, so werden diese Verfahren der unüberwachten Mustererkennung zugeschrieben. Dabei können diese Schritte getrennt voneinander oder simultan durchlaufen werden, um einen Informationsgewinn aus den zugrundeliegenden Daten zu generieren. Die Mustererkennung kann zusätzlich nach der Dimensionalität der zugrundeliegenden Daten unterteilt werden. So können sowohl univariate als auch multivariate Datenreihen Muster aufweisen, welche für das jeweilige Anwendungsgebiet von Relevanz sein können.

Der Ursprung aktueller Forschungsbewegungen in der Mustererkennung in Zeitreihen geht zurück auf die clusterbasierten Verfahren, welche durch (Das & Lin et al. 1998)

initiiert wurde. Auch die Teilung von Zeitreihen mit Hilfe einer gleitenden Fensterung (engl.: sliding window) basiert darauf. Der Begriff des Musters (engl.: motif) in Zeitreihen wurde von (Patel & Keogh et al. 2002) eingeführt. Abbildung 2-6 zeigt schematisch die Funktionsweise eines sliding window Ansatzes. Es ist zu erkennen, dass ein definierter Bereich, das sogenannte Fenster (Grau gestrichelt), über die Zeitreihe mit einer definierten Schrittweite (roter Pfeil) iteriert wird, bis (Gelb markiert) ein ähnliches Muster gefunden wird.

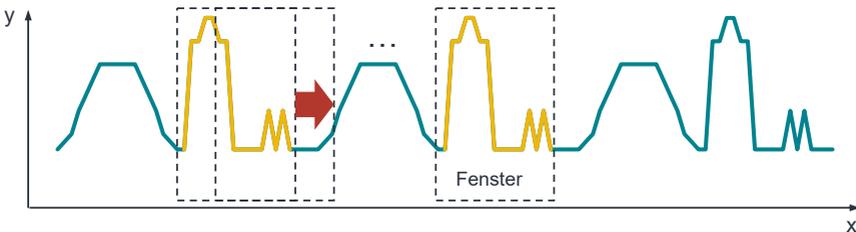


Abbildung 2-6: schematische Darstellung der Funktionsweise einer gleitenden Fensterung.

Daraus ist eine Vielzahl an Arbeiten hervorgegangen, die unterschiedliche Aspekte und Anwendungsfälle der Mustererkennung in Zeitreihen untersuchten. Nach (Keogh & Kasetty 2003) existierten bereits 2003 mehr als 1000 Publikationen zur Informationsgewinnung im Rahmen der Mustererkennung in Zeitreihen.

Abhängig von der Länge der Muster, der Datenrepräsentation, der Zeitkomplexität existieren eine große Anzahl an Arbeiten, um in univariaten wie auch multivariaten Datensätzen (Minnen & Isbell et al. 2007) wiederkehrende Muster zu erkennen. Dabei lassen sich im Wesentlichen zwei Grundarten unterscheiden:

- Clusterbasierte Verfahren und
- regelbasierte, analytische Verfahren.

Clusterbasierte Verfahren verfolgen die Grundidee, eine Zeitreihe nach Teilkriterien in Subsequenzen zu unterteilen und anschließend diese Subsequenzen oder gesamte Zeitreihen durch einen Clusteralgorithmus zu segmentieren. Diese an (Das & Lin et al. 1998) angelehnten Verfahren nutzen meist eine gleitende Fensterung mit fixierter Länge, um mögliche Muster aus der Zeitreihe zu extrahieren und anschließend den Datensatz auf ein weiteres Auftreten zu durchsuchen (Waczowicz & Reischl et al. 2015)

(Chicco 2012). Dadurch, dass alle möglichen auftretenden Musterkombinationen einer Länge verglichen werden müssen, ist dieser Ansatz auf eine Vorgabe einer fixierten Musterlänge angewiesen und weist eine erhebliche Laufzeitkomplexität auf.

Jedoch sind für die Generierung möglicher Muster auch iterative Ansätze möglich, welche über einen Bereich von möglichen Musterlängen iterieren, somit jedoch eine deutlich höhere Zeitkomplexität aufweisen (Mueen 2013) (Nunthanid, Niennattrakul & Ratanamahatana 2011) (Mohammad & Nishida 2014). Anstatt alle möglichen Musterkombinationen zu durchsuchen, stellen eventbasierte Teilungskriterien eine Möglichkeit dar lediglich die potentiell für den Anwendungsfall interessante Muster zu betrachten (Ludwig & Waczowicz et al. 2017) (Putz & Frieß et al. 2016) (Frieß & Kolouch et al. 2018). Hierzu ist jedoch ein gewisses Domänenwissen erforderlich, da ansonsten der Informationsverlust, der durch nicht betrachtete Muster entsteht, zu groß sein kann.

Regelbasierte, analytische Verfahren umfassen alle übrigen Ansätze, welche unterschiedlichste Techniken zu Generierung von Mustern und Suchverfahren innerhalb der Zeitreihe anwenden, jedoch nicht auf Clusterverfahren basieren. Wesentliche Unterscheidungen sind anhand der Datenrepräsentationen möglich. Dabei dominieren approximative Verfahren, welche auf eine SAX-Darstellung oder verwandte Approximationen aufbauen (Torkamani & Lohweg 2017) (Mueen 2014). Dadurch kann eine starke Dimensionsapproximation erreicht werden. Exakte Verfahren bieten hingegen den Vorteil, eine hohe Informationstreue aufzuweisen und somit einen stärkeren Hypothesenraumbias zu vermeiden (Mueen & Keogh et al. 2009).

Einen entscheidenden Vorteil der clusterbasierten Ansätze stellen die geringen Anforderungen an benötigtem Anwender- und Domänenwissen dar. Zudem weisen derartige Ansätze eine gewisse generische Grundcharakteristik auf, welche eine weitreichende Übertragbarkeit auf weitere Anwendungsfälle ermöglicht. Jedoch stellen (Keogh & Lin 2005) in ihren Untersuchungen fest, dass das Clustern von Zeitreihensequenzen nur eine bedingte Aussagekraft hat und gewisse Bedingungen erfüllt sein müssen, um die Aussagekraft einer Mustererkennung sicher zu stellen. Des Weiteren ist für die Gruppierung von Subsequenzen das Teilungskriterium von entscheidender Bedeutung. Dieses Kriterium legt fest, in welchem Bereich ein Ausschnitt einer Zeitreihe für das Clusterverfahren betrachtet werden soll. Schließlich ist auch der konkrete zur Anwendung kommende Clusteransatz mit seinen Besonderheiten und Anforderungen zu beachten. Hierauf wird in Abschnitt 2.5.4 näher eingegangen.

2.5.1 Datenrepräsentation

Da die Verarbeitung und Analyse umfangreicher Zeitreihen einen entsprechend hohen Rechen- und Zeitaufwand bedarf (Vogel 2015), bieten sich approximative Datenrepräsentationen an, welche die ursprüngliche hochdimensionale Datenreihe in eine niedrigdimensionalere Repräsentation transformieren. Abbildung 2-7 stellt eine Übersicht der grundlegenden Repräsentationen von Zeitreihen dar.

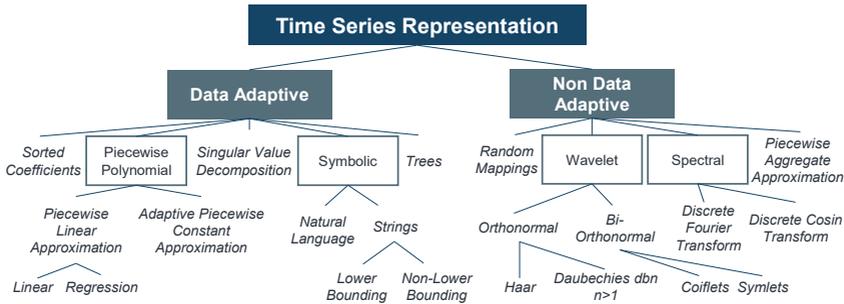


Abbildung 2-7: Hierarchie verschiedener Zeitreihendarstellungen nach (Lin & Keogh et al. 2007).

Die Grundlage approximativer Repräsentationen stellt die stückweise Diskretisierung der Ausgangszeitreihe dar, welche als Piecewise Aggregate Approximation (kurz: PAA) bekannt ist. Ein darauf aufbauender, vielversprechender Ansatz ist die Diskretisierung der Zeitreihe mittels der Symbolic Aggregate approXimation (kurz: SAX) (Keogh & Lin 2005) (Keogh, Lin & Fu 2005) (Lin & Keogh et al. 2007).

Dieses Verfahren transformiert Daten von einer Zeitreihe X mit Länge l in symbolische Strings beliebiger Länge w auf Basis eines Alphabets mit Größe $A > 2$. Der zugrundeliegende SAX-Algorithmus besteht aus zwei Phasen. Zuerst wird die Ausgangsdatenreihe in eine diskrete PAA-Repräsentation transformiert. Anschließend wird diese PAA-Repräsentation in eine Zeichenfolge überführt. Dadurch entsteht eine deutliche Dimensionsreduktion, sodass einfache Suchalgorithmen auf dem resultierenden String angewendet werden können. Abbildung 2-8 verdeutlicht dies qualitativ. Die Zeitreihe x wird in diskrete symbolische Strings (a, b oder c) mit der Länge w transformiert. Die Zeitreihe x wird also in Form einer Stringfolge (hier: $[baacbcc]$) repräsentiert. In dieser Stringfolge können dann Subfolgen als Muster berechnet werden. Durch die Einteilung der ursprünglichen Zeitreihe in das Alphabet kommt ein Informationsverlust zustande.

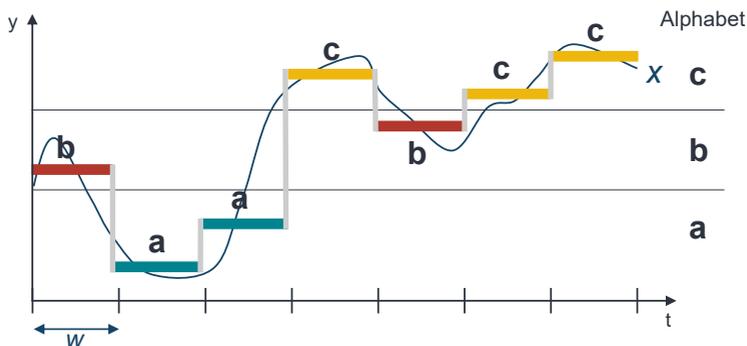


Abbildung 2-8: SAX-Transformation der Ausgangsdatenreihe in einen diskretisierten String. In Anlehnung an (Keogh & Lin 2005).

Ein entscheidender Nachteil approximativer Datenrepräsentationen ist der beschriebene Informationsverlust sowie die Gefahr, neue verzerrte Randinformationen in den bestehenden Informationssatz einzubringen. Dies gilt es gegenüber der Verarbeitungsvorteile und der damit verbunden Laufzeitvorteile bei der Wahl der Datenrepräsentation abzuwägen.

2.5.2 Features

Um zu entscheiden, ob zwei Muster als ausreichend ähnlich gelten, müssen charakteristische Eigenschaften hinzugezogen werden, um einen Vergleich durchführen zu können. Die möglichen Eigenschaften (engl.: features) lassen sich dabei in zwei wesentliche Gruppierungen einteilen. Zum einen können die Datenpunkte der zugrundeliegenden Muster jeweils direkt miteinander verglichen werden und zum anderen als Summe der Distanzen betrachtet werden. Abbildung 2-9 zeigt qualitativ die punktweise Distanzberechnung von zwei Sequenzen (gelbe (y_b) und blaue (y_a) Zeitreihe).

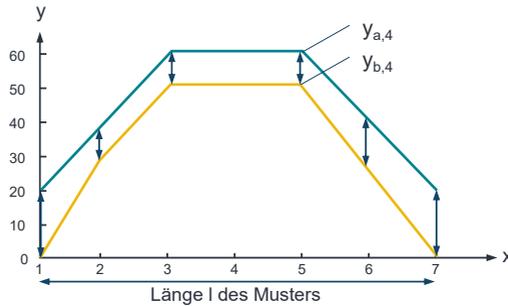


Abbildung 2-9: Punktweise Distanzberechnung zwischen zwei Sequenzen.

2.5.3 Distanzmetriken

In diesem Abschnitt werden Distanzmetriken und deren Eigenschaften betrachtet. Punktweise Distanzen zwischen Zeitreihensequenzen können ein Feature zur Bestimmung von Mustern und Ähnlichkeiten sein.

Um den Vergleich zweier Muster zu quantifizieren, wird ein Maß benötigt, welches die Abweichung bezüglich der untersuchten Eigenschaft ausdrückt. Eine Distanzmetrik charakterisiert somit die Ähnlichkeit zwischen den zugrunde liegenden Mustern. Die Wahl der Distanzmetrik steht dabei in einer wechselseitigen Beziehung mit der Wahl der untersuchten Eigenschaften und kann bei vorhandenem Anwenderwissen modifiziert werden, um der jeweiligen Definition der Ähnlichkeit zu entsprechen. Die Grundlage jeder Distanzmetrik besteht aus einer Differenz zwischen zwei Eingabewerten X_1, X_2 , wie in Formel 2-2 zu sehen ist.

$$\text{Distanz} = |(X_1 - X_2)|$$

2-2

In der Literatur werden unterschiedliche Metriken verwendet. Dabei ist eine Unterscheidung zwischen statischen und elastischen Metriken sinnvoll. Abbildung 2-10 verdeutlicht den Unterschied der statischen und elastischen Distanzmaßen grafisch. Statische Metriken (bspw. Euklidische Distanz, linkes Diagramm) beschreiben den Vergleich von Messwerten zu den jeweils identischen Zeitpunkten, während elastische Distanzmaße

(bspw. Dynamic Time Warping, rechtes Diagramm) Datenpunkte der Muster dynamisch skalieren, um ein bestimmtes Optimierungsziel zu erreichen.

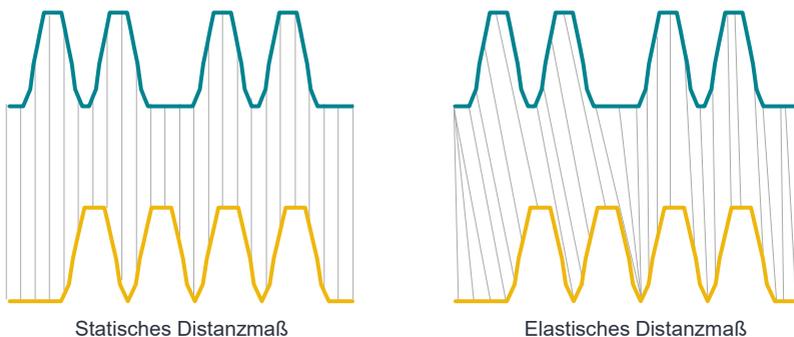


Abbildung 2-10: Links: einfaches statisches Distanzmaß (bspw. Euklidische Distanz). Rechts: elastisches Distanzmaß (bspw. Dynamic Time Warping (DTW)). Darstellung in Anlehnung an (Keogh & Lin 2005).

Im Folgenden werden die relevantesten Metriken als Grundlage dieser Arbeit eingeführt.

2.5.3.1 Manhattan-Metrik

Die Manhattan-Metrik beschreibt die von der Summennorm (L1-Norm) eines Vektorraums abgeleitete Metrik. Sie zeigt die Summe der Absolutwerte der punktwweisen Abweichungen von zwei Punkten a_i, b_i in ihren Einzelkoordinaten $i=1, \dots, l$ (vgl. Formel 2-3).

$$d(a, b) = \sum_{i=1}^l |a_i - b_i| \quad 2-3$$

2.5.3.2 Euklidische Distanz

Die euklidische Distanz beschreibt den geometrischen Abstand für zwei- und dreidimensionale Datenmengen. Abgeleitet von der euklidischen Norm (L2-Norm) setzt sie sich aus der Wurzel der Summe der quadrierten Differenzen der Punkte a_i, b_i in ihren Einzelkoordinaten $i=1, \dots, l$ (vgl. Formel 2-4) zusammen.

$$d(a, b) = \sqrt{\sum_{i=1}^l (a_i - b_i)^2} \quad 2-4$$

Der euklidische Abstand ist durch das Umschließen der äußeren Wurzel abhängig von der Anzahl der Einzelkoordinaten i . Dies führt beim Vergleich von Zeitreihen unterschiedlicher Länge zu Verzerrungen und erlaubt nur eine bedingte Vergleichbarkeit.

2.5.3.3 Tschebyscheff-Metrik

Die Tschebyscheff-Norm (Collatz & Wetterling 1971) beschreibt den Zusammenhang zweier Objekte im m -dimensionalen Zahlenraum. Die maximale Entfernung der Objekte $\in \mathbb{R}^m$ entlang einer Achse im m -dimensionalen Zahlenraum ist somit die Tschebyscheff-Distanz. Diese Metrik kann grundsätzlich direkt als Distanzmaß verwendet werden. Formel 2-5 beschreibt den mathematischen Zusammenhang:

$$d_{Tschebyscheff}(x, y) = \max_i (|x_i - y_i|) \quad 2-5$$

2.5.4 Clusteralgorithmen

Zur Identifizierung von Ballungen innerhalb eines Datensatzes eignen sich Clusteralgorithmen, welche zur Art der unüberwachten Lernverfahren zählen. Das Entdecken von Ähnlichkeitsstrukturen ist daher prädestiniert zur Erkennung wiederkehrender Muster in unterschiedlichsten Domänen. Die zugrundeliegenden Verfahren können hierarchische Verfahren oder partitionierende Verfahren sein (Jain, Murty & Flynn 1999) und sind in Abbildung 2-11 dargestellt.

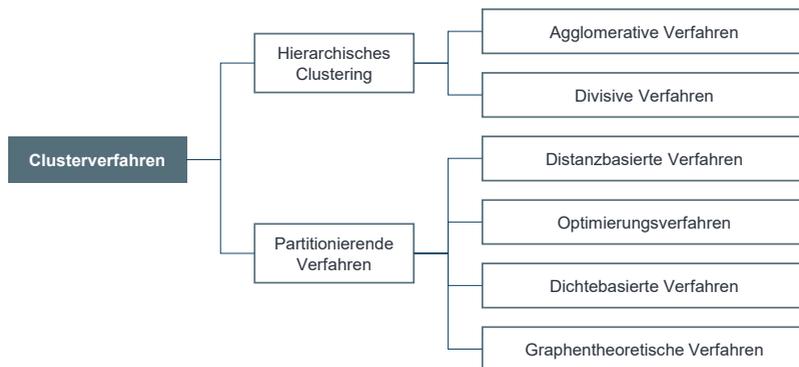


Abbildung 2-11: Übersicht Clusterverfahren in Anlehnung an (Jain, Murty & Flynn 1999).

2.5.4.1 Mean Shift-Algorithmus

Der Mean Shift Algorithmus ist ein dichte-basiertes Clusterverfahren, welches auf dem Prinzip des Bergsteigeralgorithmus beruht (Cheng 1995). Durch die iterative Berechnung des arithmetischen Mittels und das anschließende Aktualisieren der Clusterzentren, sucht dieser Ansatz den dichtesten Bereich, welcher in der Reichweite des Parameters *bandwidth*, auch Kernel genannt, liegt. Sein Ursprung geht auf die Clusteranalyse in der Bildverarbeitung und Bilderkennung zurück (Cheng 1995) (Comanicu & Meer 2002). Abbildung 2-12 stellt die Funktionsweise des Mean Shift dar. Ausgehend von einem Startpunkt, dem lokalen Zentrum (roter Punkt), folgt die iterative Berechnung bis zur Konvergenz im globalen Zentrum (gelber Punkt).

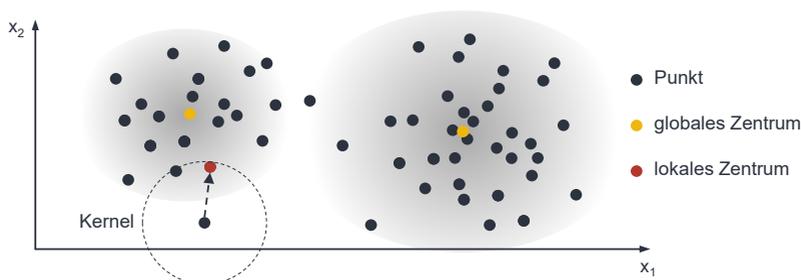


Abbildung 2-12: Automatisiertes Finden von Clusterzentren. Darstellung in Anlehnung an (Klingel 2015).

Zu den Vorteilen dieses Verfahrens zählt vor allem die variable Clusteranzahl, welche nicht vorgegeben wird, sondern durch die hierarchische Funktionsweise des Algorithmus iterativ angepasst wird. Des Weiteren sind die Formen der Cluster nicht vorgegeben oder eingeschränkt, wodurch auch konkave Mengen als Ballung eingefasst werden können. Allerdings stellt die Wahl des Bandweitenparameters w eine Herausforderung dar und ist kritisch für den Erfolg der korrekten Segmentierung. Jedoch sei hier darauf hingewiesen, dass dieser Parameter eine direkte Dependenz zu den unterliegenden Daten aufweist und somit abhängig von der Größenordnung der betrachteten Daten ist.

2.5.4.2 DBSCAN-Algorithmus

Der DBSCAN-Algorithmus (Density-Based Spatial Clustering of Applications with Noise) ist ein dichtebasiertes Verfahren, welches besonders für Anwendungen mit Rauschen entwickelt wurde. (Ester & Kriegel et al. 1996) führten diesen Algorithmus ein, um dichte Objekte (sogenannte Kernpunkte, blaue Punkte in Abbildung 2-13) mit anderen dichten und verbundenen Objekten in einer Kette zu verbinden. Daraus leitet sich der Begriff der Dichteverbundenheit ab. Innerhalb einer ε -Umgebung um einen Kernpunkt sind alle Punkte dichte-erreichbar (gelbe Punkte in Abbildung 2-13). Wenn ein Punkt in seiner ε -Umgebung eine Mindestanzahl an Datenpunkten $minPts$ besitzt, wird dieser als Kernpunkt bezeichnet. Alle nicht dichte-verbundenen Punkte (roter Punkt in Abbildung 2-13) werden als Rauschen bezeichnet.

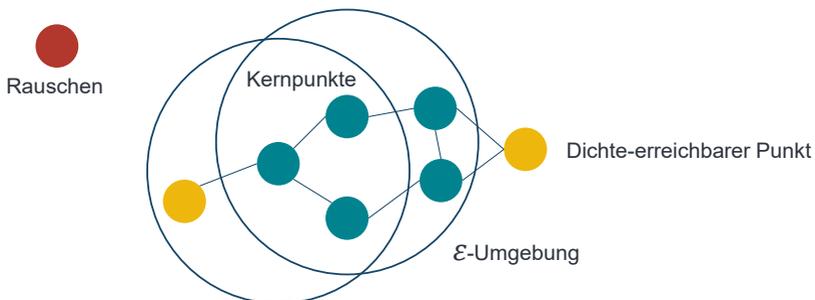


Abbildung 2-13: Vereinfachte Darstellung der Funktionsweise des DBSCAN Algorithmus. Darstellung in Anlehnung an (Zöllner 2020).

Der DBSCAN-Algorithmus besitzt dieselben Vorzüge, welche dem Mean Shift Verfahren zugeschrieben werden. Zusätzlich ist dieses Verfahren nicht iterativ, da jeder Datenpunkt im Laufe des Verfahrens nur einmal besucht wird. Somit besitzt er eine lineare Komplexität. Die Wahl der Parameter ε und *minPts* ist jedoch nicht nur von der Größenordnung der zugrundeliegenden Daten abhängig, sondern hängt sehr stark von deren Dichteverteilung ab.

2.5.5 Fazit zu Clusterverfahren

Der vorangegangene Abschnitt hat die Grundlagen von Clusteransätzen eingeführt und dabei den Mean Shift und den DBSCAN-Algorithmus erläutert. Durch ihre dichtebasierte und auf Kernpunkte fokussierte Arbeitsweise eignen sich diese besonders gut für unbekannte Ballungsformen und überzeugen durch eine hohe Robustheit. Dies ist ebenso eine Anforderung für den Einsatz in Produktionsmaschinen.

2.5.6 Zusammenfassung und Bewertung der Mustererkennung

Der starke Technologiefortschritt der letzten beiden Jahrzehnte ermöglichte erstmals komplexere Verfahren zur Mustererkennung in Zeitreihen effizient anwenden zu können. Ein sehr potenter Ansatz hierbei ist die Verwendung von Clusteralgorithmen zur Gruppierung ähnlicher Subsequenzen, welche durch vorhergegangene Teilung der Zeitreihe erzeugt werden. Entscheidende Vorteile sind die geringen Anforderungen an benötigtem Anwender- und Domänenwissen, die Robustheit und Möglichkeiten starke Laufzeitvorteile zu erzeugen. Somit können wiederkehrende Muster in Zeitreihen zuverlässig und echtzeitnah sowie weitestgehend unüberwacht gefunden werden und als Grundlage einer Anomalieerkennung dienen. Allerdings weisen diese Ansätze zur Mustererkennung in Zeitreihen erweitertes Forschungspotential in Bezug auf eine weiterführende Autonomisierung und Parametrisierung auf, um diese anwendungsfähig für den Einsatz an Produktionsmaschinen zu machen. Ohne den Einsatz von Fachpersonal, welches mit Domänenwissen die Anpassung an dynamische und unsichere Produktionsprozesse steuert, ist es bisher nicht vollständig möglich eine Anomalieerkennung auf Grundlage von Methoden der Mustererkennung einzusetzen.

2.6 Anomalieerkennung

Das Erkennen ungewöhnlicher Abweichungen von erwarteten Datenverteilungen spielt in den verschiedensten Forschungsbereichen und Anwendungen eine wichtige Rolle. So findet es unter anderem Einsatz bei der Erkennung auffälligen Internettraffics

(Thatte, Mitra & Heidemann 2011), der Medizin (Hauskrecht & Valko et al. 2007) (Spence, Parra & Sajda 2001) (Sivaraks & Ratanamahatana 2015), bei der Erkennung betrügerischer Transaktionen oder Identitätsdiebstahls (Aleskerov, Freisleben & Rao 1997) sowie in der Sensorik (Hayes & Capretz 2015) (Ramotsoela, Abu-Mahfouz & Hancke 2018). Auch im Bereich der Anomalieerkennung ist es relevant, ein einheitliches Verständnis der Begriffe Anomalie, Ausreißer und Störung zu schaffen. Für diese Arbeit sind nachfolgende Definitionen für die Begriffe Anomalie, Ausreißer und Störung gültig.

Definition (Anomalie)

Anomalien (engl.: anomalies) sind unbewertete Ausprägungen in Daten, welche nicht mit zuvor definiertem, normalem Verhalten in Daten übereinstimmen. Anomalien treten über zeitlich unbegrenzte Bereiche auf.

Definition in Anlehnung an (Chandola, Banerjee & Kumar 2009)

Beispiel: In einer aufgenommenen Messdaten-Zeitreihe (bspw. Motorstrommessung) sind über einen längeren Zeitbereich (15 Sekunden) alle Messpunkte außerhalb des vom Anwender definierten zulässigen Bereichs zu erkennen.

Definition (Ausreißer)

Ausreißer (engl.: outlier) sind unbewertete Ausprägungen in Daten, welche nicht mit zuvor definiertem, normalem Verhalten in Daten übereinstimmen. Ausreißer charakterisieren sich durch sehr kurze zeitliche Bereiche bzw. punktuellm Vorkommen. Jeder Ausreißer ist eine Anomalie.

Beispiel: In einer aufgenommenen Messdaten-Zeitreihe (bspw. Motorstrommessung) ist ein diskreter Messpunkt außerhalb des vom Anwender definierten zulässigen Bereichs zu erkennen.

Definition (Störung)

Störungen (engl.: fault) sind durch den Anwender bewertete Anomalien oder Ausreißer, welche auf anormales Verhalten in einer Maschine beruhen und somit die Folge aus einer anormalen (Daten-) Ausprägung sind. Nicht jede Anomalie oder Ausreißer führt zwangsläufig zu einer Störung.

Beispiel: In einer aufgenommenen Messdaten-Zeitreihe (bspw. Motorstrommessung) sind über einen längeren Zeitbereich (15 Sekunden) alle Messpunkte außerhalb des

vom Anwender definierten zulässigen Bereichs zu erkennen. Dies führt zu einem ungeplanten Maschinenstillstand, aufgrund eines Überlastbereichs. Störungen sind vor oder zu Beginn ihres Eintretens zu detektieren.

Die eingeführten Definitionen lassen sich anhand des folgenden Beispiels in Abbildung 2-14 exemplarisch illustrieren:

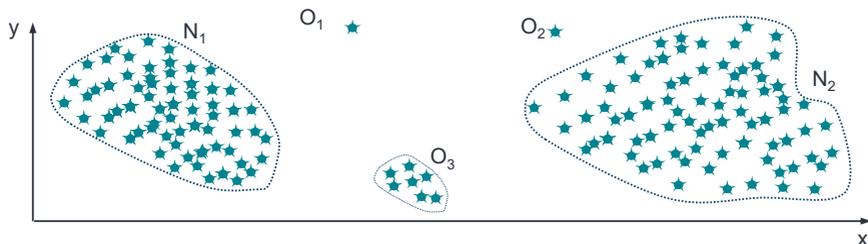


Abbildung 2-14: Ein einfaches Beispiel von Ausreißer und Anomalien in einem 2-dimensionalen Datenset. Darstellung in Anlehnung an (Chandola, Banerjee & Kumar 2009).

Dargestellt sind Datenpunkte des zweidimensionalen Raumes der beiden Attribute x und y . Die Daten O_1 , O_2 und O_3 finden sich sichtbar außerhalb der Ballungsbereiche N_1 und N_2 , die das erwartete Datenverhalten durch eine hohe Dichte hier liegender Punkte charakterisieren und stellen damit Anomalien dar. O_1 und O_2 sind punktuell Anomalien und somit definitionsgemäß Ausreißer. Wenn O_3 zu einem Stillstand der Maschine führt, ist diese Anomalie eine Störung.

Abbildung 2-15 stellt Anomalien unter stark idealisierten Begleitumständen dar. Die in der Realität meist komplexere Datenbasis erschwert die Isolation von Anomalien erheblich.

Um nachfolgend unterschiedliche Arten von Anomalien typisieren zu können, soll zuerst die Form der Daten im Umfeld klassischer Systeme dargestellt werden. In der Regel dient ein aus einzelnen, durch uni- oder multivariate Attributvektoren definierter Trainingsdatensatz als Input (Tan, Steinbach & Kumar 2005). Abhängig der Zielstellung kann dieser genutzt werden, um in den Datensätzen Anomalien zu identifizieren oder anschließend beim Auftreten neuer Instanzen eine Entscheidung über deren Zugehörigkeit zur bisherigen Verteilung zu fällen.

Anomalien lassen sich in drei grundlegende Kategorien unterteilen. Bei Punktanomalien, auch Ausreißer genannt, handelt es sich um einzelne Datenpunkte, deren Werte von der Verteilung des restlichen Datensatzes abweichen (Abbildung 2-15, grauer Marker). Kontextuelle Anomalien charakterisieren sich durch passende Werte, die allerdings in einem ungewöhnlichen Kontext auftreten. Abbildung 2-15, roter Marker, zeigt, dass der Wert mehrfach im Datensatz vorkommt, hingegen kontextlos zum erwarteten Verlauf ist. Auch bei kollektiven Anomalien stellt der Wert selbst keine unbekannte Ausprägung dar. Durch das gemeinsame Auftreten mit anderen Werten entsteht jedoch ein Kontext, welcher in der gesamtheitlichen Betrachtung der Datenbasis ungewöhnlich wird (gelber Marker).

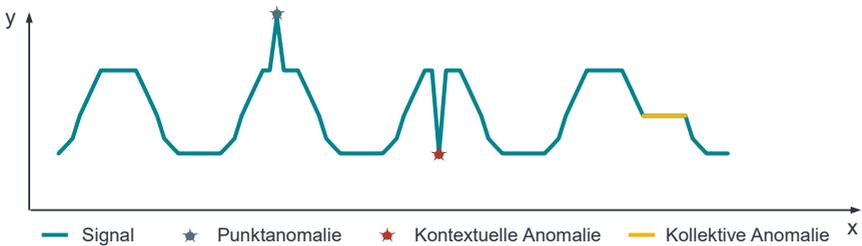


Abbildung 2-15: Darstellung unterschiedlicher Ausprägungsformen von Anomalien.

Je nach Anwendungsfall bedarf es zur Erkennung von Anomalien unterschiedlicher Problemformulierungen, welche im Wesentlichen von der Art der Daten, der vorhandenen Labels und dem Anomalietypen abhängt. Bei weitverbreiteten Ansätzen der Anomalieerkennung muss problemspezifisches und unter Berücksichtigung von Zeitinvarianzen normales Verhalten definiert werden, um im Anschluss Abweichungen feststellbar zu machen. Da Anomalien statistisch weniger oft auftreten, ist es zudem schwierig, genügend Daten ausreichender Güte zu sammeln, in denen Anomalien klar isolierbar sind. Außerdem sind Trainingsdaten häufig anwendungsbedingt mit Rauschen versehen, was klare Abgrenzungen weiter erschwert (Chandola, Banerjee & Kumar 2009).

Zur Einordnung unterschiedlicher Anomalieerkennungsmethoden soll die von (Niu & Shi et al. 2011) verwendete Unterteilung in Abbildung 2-16 genutzt werden.

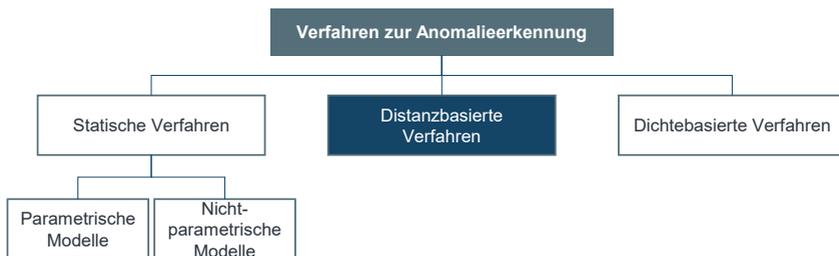


Abbildung 2-16: Einordnung der Verfahren zur Anomalieerkennung nach (Niu & Shi et al. 2011).

Statistische Verfahren (Abbildung 2-16, links) unterstellen den Daten ein zugrundeliegendes statistisches Modell und definieren Anomalien als nicht modell-konforme Beobachtungen (Chandola, Banerjee & Kumar 2009). Für parametrische Verfahren ist dieses Modell a priori festgelegt. Im Rahmen des Verfahrens werden lediglich die bestimmenden Parameter optimiert. Im Vergleich dazu ist bei nicht-parametrischen Modellen die Struktur des Modells a priori nicht definiert (Niu & Shi et al. 2011). Bei distanzbasierten Verfahren (Abbildung 2-16, mittig) wird eine Metrik verwendet, um die Distanzen von Datenpunkten zu nahen Clustern zu berechnen. Anschließend wird mittels Klassifikationsverfahren für jeden Datenpunkt entschieden, ob abhängig von der Distanz eine Anomalie vorliegt, etwa mittels des k-nearest-neighbours-Verfahrens (Ramswamy, Rastogi & Shim 2000), Random Forests oder des Local Outlier Factors (LOFs) (Sugiyama & Borgwardt 2013). Diese Verfahren werden häufig bei Produktionsmaschinen verwendet. Bei dichtebasierten Verfahren (Abbildung 2-16, rechts) werden Beobachtungen in einer Umgebung mit niedriger Dichte als Anomalie ausgewiesen. Beobachtungen in einer dichten Umgebung entsprechen normalem Verhalten (Niu & Shi et al. 2011).

2.6.1 Anomalieerkennung in Zeitreihen

Im Umfeld der Anomalieerkennung in Zeitreihen lässt sich der allgemeine Prozess dabei in zwei Komponenten unterteilen. Die erste Komponente beschäftigt sich mit der Transformation der Daten, während die zweite Komponente das Finden von Abweichungen in der zuvor transformierten Datenbasis umfasst (Cheboli 2010).

2.6.1.1 Datentransformation

Die Transformation der Daten vor der Anomalieerkennung hat unterschiedliche Motivationen. So kann einerseits eine Abbildung in einen anderen Raum Anomalien deutlicher machen, andererseits auch zur Reduktion der Berechnungskomplexität führen, was gerade im Kontext der Erkennung in Echtzeitnähe relevant ist. Falls Daten verrauscht auftreten, kann es zudem unmöglich sein Anomalien mit varianzbasierten oder verwandten Verfahren zu lokalisieren. Aus diesem Grund spielt bei der Anomalieerkennung in verrauschten Zeitreihen eine Vorverarbeitung in Form der Glättung der Daten eine ausschlaggebende Rolle.

Definition (Rauschen)

Unter dem Begriff Rauschen sind Signalabweichungen, welche gewollt oder meistens ungewollt vorkommen definiert. Diese Abweichungen resultieren durch externe oder interne Rauschquellen und können die Messgenauigkeit beeinflussen. (Heilmann 2020)

Allgemein kann anhand der Verteilung der spektralen Leistungsdichte zwischen weißem und farbigem Rauschen unterschieden werden. Die Verteilung der Frequenzen in einem Messsignal wird als Leistungsverteilung bezeichnet. Die Häufigkeit der Verteilung wird als spektrale Leistungsdichte eines Signals bezeichnet. Wird in einem Signal eine konstante spektrale Leistungsdichte vorgefunden, handelt es sich um sogenanntes weißes Rauschen. Bei weißem Rauschen liegen Störfrequenzen ganzheitlich über dem Frequenzspektrum vor. Farbigen Rauschen hingegen weist eine frequenzabhängige spektrale Leistungsdichte sowie eine vom Dirac-Stoß abweichende Autokorrelationsfunktion auf (Zwick, Zwick & Nguyen 2015).

2.6.1.2 Gleitende Fensteroperatoren

Eine Technik zur Elimination weißen Rauschens, dass in der Signalverarbeitung (zumindest approximativ) häufig auftritt, ist die Glättung des Signals durch gleitende Fensteroperationen. Es werden unterschiedliche Approximationsverfahren wie Mittelwertoperatoren angewendet, um mittels eines gleitenden Fensters das Signal zu glätten. Die Zeitreihe, bestehend aus n Datenpunkten, wird durch eine n -fache inkrementelle Ausführung der gleitenden Fensterberechnung geglättet. Zur Analyse historischer Daten zur Minimierung von Störgrößen finden sich in der Literatur viele weitere approximative bzw. filternde Verfahren sowie elastische Distanzmaße (Aghabozorgi, Seyed Shirkorshidi & Ying Wah 2015). Ein wichtiges Verfahren der Zeitreihenapproximation ist die

in (Keogh & Chakrabarti et al. 2001) publizierte stückweise Approximation (engl.: piecewise aggregate approximation resp. kurz: PAA). Auch der zuvor diskutierte SAX-Algorithmus (Kapitel 2.5.1) stellt ein approximatives Verfahren dar. Ein anderer oft zitierter Ansatz existiert in der Zeitreihenapproximation durch Fourierkoeffizienten (auf Grundlage der diskreten Fouriertransformation), wie sie (Agrawal, Faloutsos & Swami 1993) entwickelte.

2.6.1.3 Erkennen von Anomalien

Für die Erkennung von Anomalien wurden im Laufe der Jahre unterschiedlichste Ansätze vorgestellt. Bei den Verfahren findet ein lokaler Abgleich von Sequenzen der übergeordneten Zeitreihe mit einer Referenz statt, was insbesondere dann wichtig ist, wenn die Zeitreihe mehrere zugrundeliegende Prozesse vereint. Es sollen also fehlerhafte Subsequenzen innerhalb einer weitestgehend fehlerfreien übergeordneten Sequenz identifiziert werden. Für die Klassifikation von Anomalien werden unter anderem die Distanz zu den k nächsten Nachbarn (Cheboli, Chandola & Kumar 2009) oder auch One Class Support Vector Machines verwendet, die die jeweiligen Subsequenzen als Input erhalten (Ma & Perkins 2003). Durch den fensterweisen Abgleich von Test und Trainingszeitreihen ist die Komplexität der fensterbasierten Verfahren hoch (Cheboli 2010). Für die Erkennung von nicht fensterbasierten Abweichungen kommen häufig rein distanzbasierte Ansätze zum Einsatz, mittels deren Zeitreihen mit hoher Distanz als Anomalie klassifiziert werden. Diese Verfahren differieren meist nur in der Art der verwendeten Metrik, die zur Distanzberechnung verwendet wird.

Neben den distanzbasierten Verfahren kommen auch modellbasierte Verfahren mit Vorhersagecharakter zum Einsatz. Der grundlegende Aufbau eines solchen Modells ergibt sich dabei wie folgt (Cheboli, Chandola & Kumar 2009):

- Lernen eines Vorhersagemodells auf Basis des Trainingsdatensatzes. Dieses Modell nutzt die ersten m Beobachtungen einer Zeitreihe um die Beobachtung an Stelle $m+1$ vorherzusagen.
- Für eine neue Zeitreihe: Das in 1 erstellte Modell wird benutzt, um die Beobachtung jedes Zeitschrittes vorherzusagen. Der Vorhersagefehler entspricht einer Funktion des Unterschieds der vorhergesagten Zeitreihe zur tatsächlichen Zeitreihe.

Auch hier wird erneut deutlich, dass in allen Verfahren der Distanzbegriff eine entscheidende Rolle spielt. Zur modellbasierten Anomalieerkennung in Zeitreihen wurden unterschiedliche Algorithmen vorgestellt oder Verfahren aus anderen Domänen transferiert. Neben bereits früh verwendeten Techniken wie der Nutzung gleitender Durchschnitte (Chatfield 2003) oder Autoregressionsmodellen (Chatfield 2003) (Fujimaki, Yairi & Machida 2005) wurden später unter anderem auch Kombinationen dieser (Pincombea 2005) (Zare Moayedi & Masnadi-Shirazi 2008) und Kalman-Filter (Knorn & Leith 2008) eingesetzt.

2.6.1.4 Rekurrentes Neuronales Netz mit LSTM

In den vergangenen Jahren haben sich parallel zur Entwicklung in anderen Domänen viele Ansätze basierend auf Neuronalen Netzen etabliert. Diese reihen sich im Grunde in die soeben diskutierten modellbasierten Ansätze mit Vorhersagecharakter ein. So können beispielsweise Rekurrente Neuronale Netze mit Long-Short-Term-Memory (LSTM) eingesetzt werden, um regressionsbasiert Anomalien feststellen zu können. Diese 1997 eingeführte Erweiterung (Hochreiter & Schmidhuber 1997) Rekurrenter Neuronaler Netze steigerte deren Effektivität in vielen Anwendungsgebieten enorm. Ein Neuronales Netz wird rekurrent, indem der Output dem Netzwerk erneut als Input zugeführt wird. Abbildung 2-17 zeigt den Vergleich zu einem Neuronalen Netz mit einfacher Vorwärtskopplung (a). Die rechte Abbildung (b) zeigt das Rekurrente Neuronale Netz, welches den Output aus den Neuronen ebenso als Input verwendet.

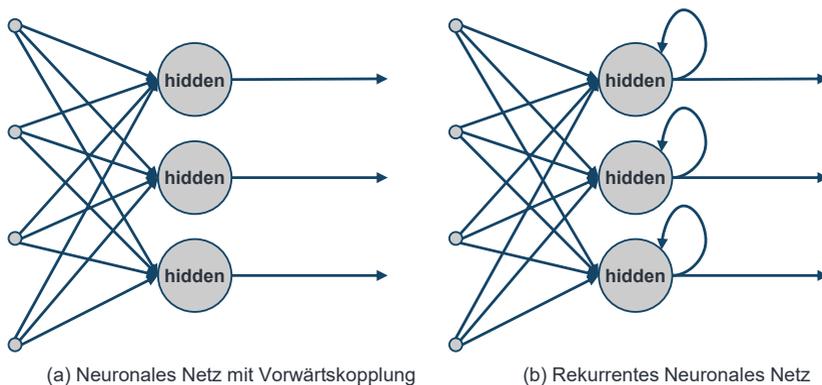


Abbildung 2-17: Vergleich von (a) Neuronales Netz mit Vorwärtskopplung und (b) Rekurrentes Neuronales Netz. Darstellung in Anlehnung an (Mulder, Bethard & Moens 2015).

2.6.1.5 Auto-Encoder zur Anomalieerkennung

Bei Autoencodern handelt es sich um spezielle Neuronale Netze, deren Training darauf abzielt, den Input nach anschließender Transformation zu rekonstruieren (Michau & Fink 2019). Abbildung 2-18 zeigt die typische Struktur eines Encoder-Decoder-Netzwerks. Dabei lässt sich das Netzwerk vereinfacht in zwei verkettete Funktionen, die Encoderfunktion $h = f(x)$, auf der linken Seite der Abbildung 2-18 und die Decoderfunktion $r = g(h)$, rechte Seite von Abbildung 2-18, gliedern.

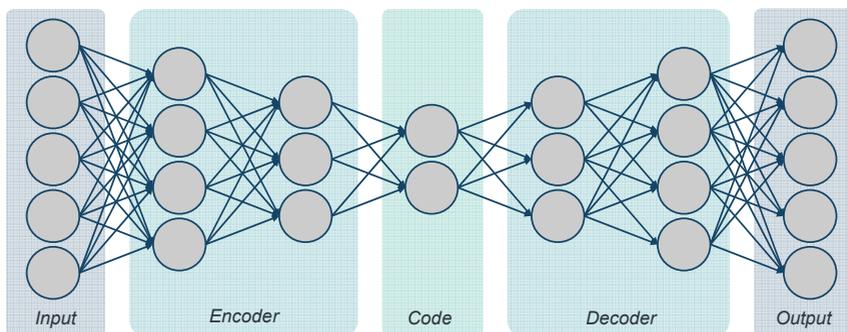


Abbildung 2-18: Typische Struktur eines Encoder-Decoder-Netzwerkes. Darstellung in Anlehnung an (Chen & Liu et al. 2020).

Zwischen x und r kann im Folgenden der sogenannte Rekonstruktionsfehler berechnet werden, der die Güte der Rekonstruktion misst. Dabei ist das Ziel allerdings kein reines Auswendiglernen der Rekonstruktion, sondern das Maximieren der Übertragungsqualität der Transformation auf neue Daten. Typischerweise wurden Autoencoder häufig genutzt, um die Dimensionalität komplexer Datensätze zu reduzieren, da anschließend mittels Rekonstruktion die hohe Dimensionalität nahezu wiederhergestellt werden kann. Da Autoencoder mittels ihres Inputs als Zielgröße trainiert werden können, lassen sie sich unter die unüberwachten Verfahren des maschinellen Lernens einordnen und somit insbesondere auch in Domänen genutzt werden, in denen gelabelte Zielvariablen untypisch sind. Im Kontext der Anomalieerkennung wird der Autoencoder dabei insbesondere eingesetzt, um komplexe Inputdaten auf eine niedrigdimensionale Repräsentation zu vereinfachen. Bei dieser Vereinfachung gehen die abweichenden Details der Anomalie häufig verloren, wodurch nach der Rekonstruktion ein höherer Rekonstruktionsfehler zwischen Input und Output entsteht, als bei Inputs, die keine Abweichungen enthalten.

2.6.1.6 Echtzeit-Anomalieerkennung

Anwendungsabhängig ist es häufig notwendig Anomalien während der eigentlichen Aufnahme ohne signifikante Verzögerungen zu erkennen. Solche Echtzeit-Systeme bestehen dabei aus einer Transformation und sowie einer möglichst laufzeiteffizienten Erkennung. Bei Echtzeitsystemen besteht die Herausforderung darin, ein System zu entwickeln, welches Daten sowohl verarbeiten kann und in gleicher Zeit neue Daten zu diesem System hinzukommen. Dabei ist die Geschwindigkeit, Latenz und Genauigkeit der Verarbeitung ausschlaggebend (Musliner & Hendler et al. 1995). Wenn Echtzeitsysteme auf Datenströme (engl.: data streams) basieren, unterliegen die Systeme weiteren Einschränkungen und Komplexitäten (Ahmad & Lavin et al. 2017):

- Es steht kein vollständiger Datensatz zur Verfügung, auf dessen Basis ein finales Modell bestimmt werden kann, sondern die Daten treffen sequentiell ein. Ein Training muss also online stattfinden.
- Da in der Regel neue Datenpunkte mit hoher Geschwindigkeit generiert werden, wird menschliches Eingreifen zum Anpassen von Parametern oder Labeln von Datenpunkten unmöglich.

- In vielen Szenarien findet mit der Zeit ein sogenannter Konzept-Drift (Gama & Zliobaite et al. 2014) statt. Die zugrundeliegende Statistik des Problems verändert sich (z.B. durch Softwareupdates, die die Art der Datenaufnahme verändern, angepasste Prozesse, etc.).

Bei der Anforderung der schnellen Laufzeit der Systeme geht es nicht alleine um das Erkennen von Ereignissen. Es müssen nach dem Erkennen möglichst schnell Maßnahmen getroffen und angestoßen werden.

Resultierend aus obigen Erläuterungen ergeben sich folgende Anforderungen an Echtzeit-Anomaliesysteme nach (Ahmad & Lavin et al. 2017):

1. Vorhersagen müssen online ablaufen, d.h. der Algorithmus muss eine Entscheidung über Zustand x_t treffen, bevor x_{t+1} eintrifft.
2. Der Algorithmus muss kontinuierlich lernen. Die Möglichkeit den gesamten Datensatz zu speichern ist nicht zwingend gegeben.
3. Der Algorithmus muss unüberwacht und automatisiert aufgebaut sein (ohne Label und manuelle Anpassungen der Systemparameter).
4. Der Algorithmus muss sich dynamischen Umgebungen und Konzept-Driften anpassen können, da zugrundeliegende Statistiken instationär sind.
5. Vorhersagen müssen so früh wie möglich stattfinden.
6. „false positive“ (vom System als wahr klassifiziert, in Realität aber unwahr) und „false negative“ (vom System als unwahr klassifiziert, in Realität aber wahr) sollen minimiert werden.

2.6.1.7 Überwachte Anomalieerkennung

Da insbesondere in der Sensorik gelabelte Daten in den meisten Fällen nicht zur Verfügung stehen, kommt der überwachten Anomalieerkennung eine deutlich geringere Bedeutung zu. Nichtsdestotrotz wurden zusammenhängend einige unterschiedliche Ansätze exploriert, die häufig bessere Ergebnisse als ihre unüberwachten Konkurrenzansätze lieferten. Im Falle vorliegender Labels reduziert sich das Problem der Anomalieerkennung auf ein Klassifikationsproblem. Statt der Erkennung ungewöhnlicher Abweichungen steht also die Zuordnung zu zwei oder mehreren Klassen im Fokus. Dabei unterscheidet sich die überwachte Anomalieerkennung anhand zusätzlicher Beschränkungen von typischen Klassifikationsproblemen (Aggarwal 2017). Oft charakterisieren sich zugrundeliegende Datensätze in vielen Fällen durch ein Missverhältnis der Klas-

sen, da Anomalien deutlich seltener auftreten als normale Beispiele. Eine weitere Problematik tritt auf, wenn während der Generierung von Daten ein neuer Anomalietypos hinzukommt, für den eigentlich keine Klasse vorgesehen ist. Der Umgang mit solchen Fällen erweist sich oft als schwierig.

Eine spezielle Form des überwachten Lernens in der Anomalieerkennung ist das *aktive Lernen* (Aggarwal 2017). Hier unterbricht ein menschlicher Experte die Prozesse, um manuell für automatisch identifizierte Kandidaten zu entscheiden, ob eine Anomalie vorliegt. Häufig können somit hybride Systeme entstehen, die beginnend unüberwacht arbeiten, später durch menschliches Expertenwissen erweitert, jedoch überwacht und damit effizienter werden. In der Literatur wurden unterschiedliche Ansätze zur überwachten Anomalieerkennung untersucht. (Kawachi, Koizumi & Harada 2018) nutzen probabilistische Modellierung und Analogien zwischen Mengen und ihrem Komplementär, um auf Verteilungen der Anomalie- und Normalklasse zu schließen. Diese Verteilungen werden anschließend einem Autoencoder übergeben, der eine Klassifikation abgibt. (Vercruyssen, Meert & Davis 2017) setzen einen indirekt überwachten Ansatz um, indem Klassenzugehörigkeiten aus einer verwandten Datenquelle mittels eines 1-Nearest-Neighbour-Klassifikators auf die ähnlichsten Datenpunkte im Zieldatensatz übertragen werden. Hingegen verwenden (Salem & Guerassimov et al. 2013) einen Entscheidungsbaum kombiniert mit linearer Regression, um basierend auf mehreren Features Instanzen als normal oder als Anomalie zu klassifizieren.

2.6.2 Zusammenfassung und Bewertung der Anomalieerkennung

Das Erkennen von Anomalien ist ein in der Forschung vielbeachtetes Aufgabengebiet, für das viele unterschiedliche Lösungsansätze entwickelt wurden. Die Menge der anwendbaren Verfahren ist dabei direkt abhängig von der verfügbaren Datenbasis. Bislang ist kein Ansatz im Stand der Forschung erkennbar, welcher ohne großen Initialaufwand eines Antrainierens realisiert werden kann. Zudem beruhen die publizierten Verfahren der Forschung auf die Anwendung in gleichbleibenden Prozessen. Variierende Anwendungen mit wechselnden Parametern können bislang kaum evaluiert werden. Aufgeführte Verfahren im eigenen Ansatz dieser Dissertation greifen diese offene Fragestellung auf und adressieren einen neuartigen Lösungsansatz durch den Einsatz einer vorgelagerten Prozessesegmentierung. Bei der Verwendung von Zeitreihen tritt in den meisten Fällen Rauschen auf und muss mit einem geeigneten Verfahren reduziert oder entfernt werden, um die unverzerrte Information der Daten betrachten zu können.

Da domänenübergreifend Datensätze aufgrund des eher seltenen Auftretens von Anomalien meist nicht mit Labels annotiert sind, spielen insbesondere unüberwachte oder semi-überwachte Verfahren eine ausschlaggebende Rolle zur eigentlichen Erkennung von Anomalien. Da Anomalien zudem häufig in zeitkritischen Systemen auftreten, sind in diesem Kontext die Online-Anomalieerkennung und begleitende Anforderungen sowie Beschränkungen ausschlaggebend für rechtzeitige Reaktionen.

2.7 Wissensbasiertes Expertensystem zur Integration von Anwenderwissen

Die nachfolgenden Kapitel führen relevante Verfahren und Ansätze zur Integration von menschlichem Wissen in datengetriebene Systeme ein und erläutern deren Funktionsfähigkeit. Es werden ausgewählte und zusammenfassend dargestellte Ansätze beschrieben. Eine umfangreiche Übersicht der publizierten Verfahren gibt (A_Alexander 2021). Zum eindeutigen Verständnis der im Stand der Technik und Forschung aufgeführten Begrifflichkeiten sind nachfolgend einige Definitionen aufgeführt.

Definition (Domäne)

Domäne beschreibt ein fokussiertes Fach- bzw. Wissensgebiet, bei dem ein sogenanntes spezifisches lösungsorientiertes Expertenwissen existiert (Durkin 1994).

In dieser Dissertation wird der Ort der Wertschöpfung darunter verstanden.

Definition (Domänenwissen)

Der Begriff beschreibt spezielle Fähigkeiten und Kenntnisse (Thommen & Achleitner et al. 2017) eines fokussierten Fach- bzw. Wissensgebiets, welche bspw. von einem Anwender zur Analyse von Produktionsprozessen eingesetzt werden.

Oft wird darunter auch das Wissen über kausale Zusammenhänge in Prozessen verstanden.

Definition (Formalisierung)

Die Formalisierung beschreibt eine Überführung von o. g. Domänenwissen zu einem computerlesbaren, standardisierten Format. Die automatische Verfügbarkeit wird dadurch sichergestellt (z. B. Regelformat)

Definition (Domänenwissen-Datenbank)

Eine Domänenwissen-Datenbank ist ein Medium, mit Hilfe dessen formalisiertes Domänenwissen gespeichert und später abgerufen werden kann.

2.7.1 Wissenshierarchie

Daten sind ein Abbild von konkreten Zeitreihen im Hinblick einer Zustandsüberwachung. Die Zeitreihe ist demnach die zeitliche Abfolge von Werten einer Variablen y . Daten und Wissen stehen miteinander in Verbindung und sind in Teilen ineinander umwandelbar. Die Vernetzung resp. der strukturelle Aufbau von Wissen und Daten beschreibt die sogenannte Wissenshierarchie (Akerkar & Sajja 2010) in Abbildung 2-19.

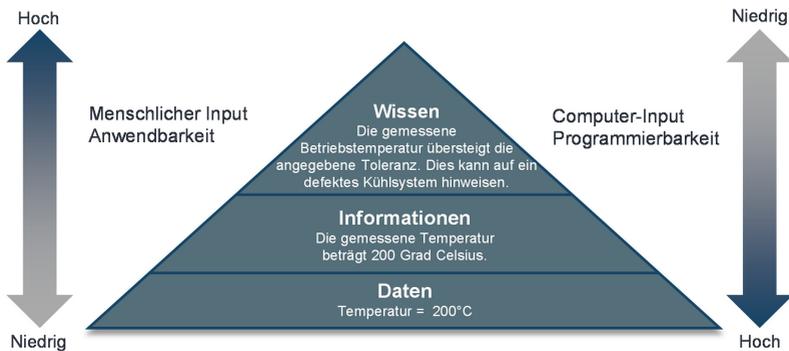


Abbildung 2-19: Wissenshierarchie. Darstellung in Anlehnung an (Akerkar & Sajja 2010) (Rowley 2007).

Die unterste Ebene der Hierarchie bilden Daten. Mit einem Aufstieg in der Hierarchie gehen eine weitere Vernetzung sowie Steigerung des Verständnisgrades einher. Es können durch den Einsatz von Datenanalysemethoden Daten aus Informationen gewonnen sowie durch die stetige Erhöhung des Verständnisgrades mit Wissen verknüpft werden (Debenham 1998) (Akerkar & Sajja 2010).

2.7.2 Wissensbasierte Methoden zur Merkmalsextraktion

Nachfolgend werden Ansätze und Verfahren zur Extraktion von Merkmalen zur Prozessüberwachung aufgeführt. Die Extraktion der Merkmale verfolgt das Ziel der späteren Klassifikation von Anomalien. Die Begriffe Wissen, Daten und Domäne sind eingeführt. (Chiang 2001) beschreibt eine Methodengliederung von wissensbasierten Anomalieerkennungungsverfahren. Ansätze zur Prozessüberwachung werden dabei meist einem oder mehreren Subverfahren zugewiesen. Im Allgemeinen werden datengesteuerte und analytische Verfahren unterschieden. Abbildung 2-20 zeigt die Einordnung der

genannten Verfahrensgruppen. Es ist zu erkennen, dass die Verfahren sowohl qualitativ als auch quantitativ umgesetzt werden können. Nachfolgend werden lediglich wissensbasierte Ansätze eingeordnet, da diese für die Anwendung in der Produktion entscheidend sind. Wissensbasierte Ansätze sind ausschließlich qualitative Verfahren, da für diese Ansätze in der Regel keine mathematische Modellierung zugrunde liegt.

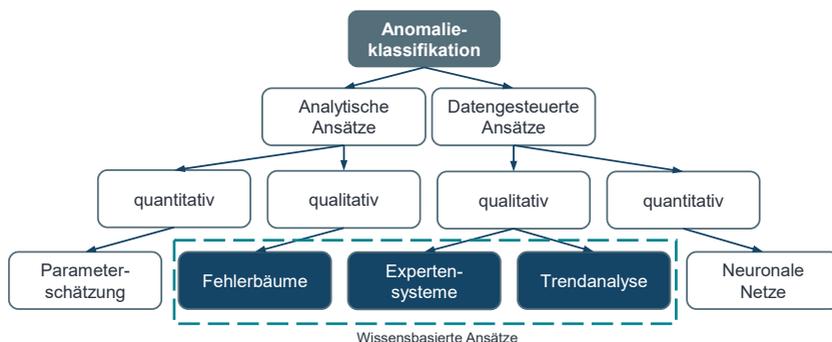


Abbildung 2-20: Methoden und Ansätze zur Anomalieklassifikation. Darstellung in Anlehnung an (Chiang 2001).

In der Produktion sind Systeme in aller Regel durch eine geringe Anzahl an Eingangs- und Ausgangsgrößen beschreibbar, weswegen sich diese Verfahrensgruppe durchgesetzt hat. Die Verfahrensgruppe der wissensbasierten Ansätze umfasst Fehlerbäume, Expertensysteme und Trendanalysen.

2.7.3 Wissensrepräsentation

Ein wesentliches Element bei der Formalisierung von Wissen ist die Repräsentation des Wissens. Hier kommen meist sogenannte *if-then*-Regeln zum Einsatz, um eine Wissensstruktur darzustellen. Die Wissensstruktur regelt die formale Grammatik der Beschreibungsform. Die Grammatik besteht aus einer spezifischen Information, welche mit einer weiteren Information oder beispielsweise Handlungsempfehlung verknüpft wird. Im *if*-Teil werden Prämissen oder Bedingungen angegeben und im *then*-Teil mit einer Konsequenz resp. Schlussfolgerung gekoppelt. Die Syntax ergibt sich zusammenfassend als:

If {Bedingung}

Then {Schlussfolgerung}

Prinzipiell gilt, dass beliebig viele weitere Bedingungen als zusätzlichen if-Teil hinzugefügt werden können. Einfache Und/Oder-Konjunktionen werden verwendet, um die Bedingungen in eine parallele oder sequenzielle Reihenfolge zu bringen. Eine Regel kann zudem auch über einen sogenannten Else-Teil verfügen. Bei der Darstellung von Domänenwissen wird von einem regelbasierten Expertensystem (EXPS) gesprochen. Ein Expertensystem speichert bestimmte Regeln ab und vergleicht diese mit entsprechenden Zuständen.

2.7.4 Qualitative Trendanalyse

Eine qualitative Trendmodellierung wird zum Erkenntnisgewinn bei variierenden Prozessereignissen, beispielsweise einer Detektion von Störungen oder deren Vorhersage angewendet. Dabei werden Signaltrends über einen definierten Intervallbereich qualitativ beschrieben. Im ersten Schritt einer qualitativen Trendanalyse (QTA) erfolgt eine Datenfilterung, da die Information aus den Daten in der Regel einem Rauschen unterliegt. Die QTA ist ein effizientes Instrument zur gezielten Analyse von Zeitreihen in genau definiertem Betrachtungsintervall. Es werden qualitative Eigenschaften aus beispielsweise Produktionsprozessen untersucht und einzelne repräsentative Signaltrends abgeleitet. Zur Identifikation oder Klassifikation von Störungen in Produktionsmaschinen leisten Trendanalysen einen wichtigen Beitrag zu deren eindeutigen und einfachen Darstellung (Venkatasubramanian & Rengaswamy et al. 2003). Abbildung 2-21 zeigt qualitativ die Funktionsweise einer QTA. Es ist eine verrauschte Original-Zeitreihe (schwarzer Verlauf) dargestellt, bei der in einem Betrachtungsintervall (violetter Bereich zwischen Datenpunkt 65 und 111) eine Trenderkennung erfolgt. Die Annäherung der originalen Zeitreihe ist im Betrachtungsintervall (violetter Bereich) durch eine lineare Trendstruktur (roter Verlauf) erfolgt.

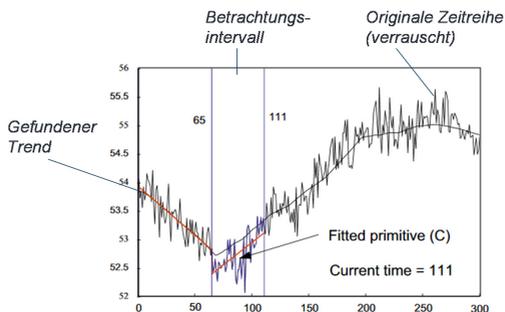


Abbildung 2-21: Merkmalsextraktion mit Hilfe einer QTA nach (Maurya & Paritosh et al. 2010).

Die Erfolgs- und Genauigkeitsgüte einer QTA wird maßgeblich durch die zugrundeliegende Intervallsegmentierung bestimmt. Hier können bestehende Algorithmen zur Aufteilung der Zeitreihe Anwendung finden. Mögliche Ansätze aus dem Stand der Technik sind beispielsweise die gleitende Fensterung, bottom-up oder top-down (Keogh & Chu et al. 2001). Ausgewählte Verfahren sind bereits in vorliegender Dissertation eingeführt. Überdies zeigen (Maurya & Paritosh et al. 2010) (Rengaswamy, Hägglund & Venkatasubramanian 2001) (Venkatasubramanian & Rengaswamy et al. 2003) weitere Mischformen von fixen Zeitfensterbetrachtungen. Fixe Zeitfensterbetrachtungen nutzen eine fest definierte Intervalllänge, um die originale Zeitreihe entsprechend aufzuteilen. Gleitende Zeitfenster hingegen bestimmen ein Segment, welches iterativ vergrößert wird und bis zu einem Abbruchkriterium wächst. Anschließend wiederholt sich die Fensterung bei einem neuen Startwert.

Im top-down Verfahren wird eine Zeitreihe aufgegliedert. Dies erfolgt rekursiv unter Beachtung aller möglichen Partitionen und hält bis zu einem Abbruchkriterium an. Es wird im ersten Schritt ein Näherungsfehler berechnet, welcher zur Entscheidung einer weiteren Aufteilung der Zeitreihe angewendet wird. Die Aufteilung erfolgt an geeigneten Stellen und wird iterativ durchgeführt. Der bottom-up Ansatz hingegen beschreibt die logische Ergänzung zum top-down Verfahren. Hier werden die Segmente permanent aufgeteilt und zusammengeführt, bis das Abbruchkriterium erfüllt ist. Ausgangspunkt ist die feinst mögliche Annäherung der Segmente (Keogh & Chu et al. 2001) (Maurya & Paritosh et al. 2010) (Rengaswamy, Hägglund & Venkatasubramanian 2001) (Venkatasubramanian & Rengaswamy et al. 2003).

2.7.5 Zusammenfassung und Bewertung der wissensbasierten Ansätze

Zusammenfassend ist zu erkennen, dass die Formalisierung von Domänenwissen in der Produktion im Kontext von Expertensystemen ein relativ neues Forschungsfeld darstellt. Im Wesentlichen lassen sich diese Verfahren in den Bereich des sogenannten Transfer Learning einordnen, welche das Ziel einer Übertragung oder Generalisierung von Wissen und Modellen hat. In vorliegenden Ansätzen sollen allerdings keine lernenden Verfahren zur Integration von Wissen untersucht werden. Im aktuellen Stand der Forschung und Technik bleibt offen, wie mittels einer QTA Anwenderwissen als a priori Wissen integriert werden kann. Es gibt keine Verfahren, welche dieses formalisierte Wissen anschließend für eine effiziente domänenübergreifende Klassifikation von Anomalien nutzen. Des Weiteren ist nicht ersichtlich, wie diese wissensbasierten Ansätze mit datenbasierten lernenden Verfahren kombiniert und gewinnbringend eingesetzt werden können. Aufgeführte Verfahren im eigenen Ansatz dieser Dissertation greifen diese offene Fragestellung auf und adressieren einen neuartigen Lösungsansatz.

2.8 Bewertung des Standes von Forschung und Technik

Nachfolgend ist eine Zusammenfassung des Standes von Forschung und Technik dargestellt. Daraus werden bestehende Defizite in Forschung und Technik abgeleitet, welche in vorliegender Dissertation gelöst werden. Das Kapitel schließt mit einer Aufstellung der Lösungsansätze, welche in nachfolgenden Kapiteln adressiert sind.

2.9 Fazit zum Stand von Forschung und Technik

Im ersten Kapitel des Standes von Forschung und Technik konnte aufgezeigt werden, dass Stillstände in der Produktion nach wie vor einer der wesentlichen Risikofaktoren für Unternehmen sind (Allianz Global Corporate & Specialty SE 2020). Stillstände zu vermeiden gilt demnach hoher Priorität, was durch den Einsatz von Industrie 4.0 Methoden zur Vernetzung der Produktionsanlagen und durch die Erkennung von Maschinen- und Prozesszuständen ermöglicht wird (Bauernhansl, Hompel & Vogel-Heuser 2014).

Zustandserkennungen, sogenannte Condition Monitoring Systeme, bieten eine wesentliche Grundlage zur weiteren Analyse und Vorhersage von Störungen in Produktionsmaschinen. Condition Monitoring Systeme sind industriell etablierte Konzepte, welche in der Regel in der Serienfertigung und auf Basis von externen Datenquellen wie Sensoren basieren (Netzer & Begemann et al. 2021). Kapitel 2.4 zeigt deutlich, dass in den

letzten Jahren verstärkt Klassifikationsverfahren im Bereich des Maschinellen Lernens entwickelt wurden. Diese modernen Verfahren benötigen eine große Anzahl an Daten aus dem Prozess, um dann Störungsklassen zu erkennen.

Kapitel 2.5ff. zeigen auf, dass in den letzten 20 Jahren sehr effiziente und leistungsstarke Algorithmen im Bereich der Mustererkennung publiziert wurden. Diese Ansätze sind allerdings im Wesentlichen in anderen Bereichen wie Medizin, Finanzmärkte oder zur Bewegungserkennung aufzufinden. Aufbauend und in Kombination mit einer Mustererkennung sind bislang keine Ansätze zur Anomalieerkennung publiziert. Systeme zur Anomalieerkennung ohne aufwendiges Antrainieren beziehen sich klassischerweise auf die Erkennung von Anomalien über fest definierte Schwellwerte oder Eingriffsgrenzen. Neue Forschungsarbeiten beschreiben im Wesentlichen Klassifikationsansätze über beispielsweise Künstliche Neuronale Netze. Aktuelle Forschungsarbeiten zeigen Ansätze zur Datentransformation und -vorverarbeitung als wesentlichen Schritt der Datenverarbeitung. In neuen Ansätzen werden zudem verstärkt Autoencoder sowie LSTM Netze beschrieben.

In Kapitel 2.7 werden Ansätze aufgezeigt, um menschliches Anwenderwissen in ein datengetriebenes System zu integrieren. Dabei werden Formen von Expertensystemen beschrieben, mit Hilfe derer Wissen gespeichert werden kann. Zum Übertragen von Wissen in ein bearbeitbares Format kommen Formalisierungen zum Einsatz. Auch in diesem Bereich werden einige aktuelle Forschungsarbeiten vorgestellt, um Wissen objektbasiert über eine zuvor festgelegte Syntax zu beschreiben.

In all den beschriebenen Arbeiten des Standes von Forschung und Technik wird die Dringlichkeit zur Vermeidung von Stillständen deutlich. Existierende Ansätze nutzen Methoden des maschinellen Lernens zum Auffinden von Anomalien in Produktionsmaschinen, sind aber im Wesentlichen aufgrund der notwendigen großen Datenmenge in Serien- oder Großserienfertigungen eingesetzt. Nachfolgend werden ausgehend von der zusammenfassenden Darstellung des Standes von Forschung und Technik aktuelle forschungs- und industrierelevante Defizite abgeleitet und aufgeführt.

2.10 Aktuelle Defizite in Forschung und Technik

Die Relevanz des beschriebenen Forschungsthemas zur intelligenten Prozessüberwachung ist durch die Anzahl publizierter Forschungsarbeiten und der außergewöhnlich hohen Forderung nach industriellen Lösungen eindeutig gegeben. Große Industrieverbände wie beispielsweise der Verband Deutscher Maschinen- und Anlagenbauer

(VDMA) oder der Verein Deutscher Ingenieure (VDI) publizierten in den letzten Jahren einige Arbeiten zur Umsetzung von digitalen Lösungen in der Produktion zur nachhaltigen Produktionsoptimierung (Anderl, R., Picard, A., Wang, Y., Fleischer, J., Dosch, S., Klee, B., & Bauer, J. 2015). In diesen und weiteren Studien (Netzer & Gönneheimer et al. 2021) (Netzer & Begemann et al. 2021) (Armbruster, Gönneheimer & Netzer 2021) wird aufschlussreich beschrieben, dass die ganzheitliche Anwendung dieser Systeme zur Prozessüberwachung aus vielen Gründen bislang nicht umgesetzt ist. Gründe hierfür sind zum einen die fehlende Infrastruktur resp. die hohen Investitionskosten für Nachrüstensensoren. Zum anderen sind bislang keine Verfahren bekannt, welche bei geringer Datenmenge wie in Klein- oder Einzelteilfertigung zuverlässige Störungserkennungen ermöglichen. Das genannte Hauptdefizit zeigt, dass Verfahren zur Störungserkennung in Produktionsanlagen auf Grundlage von internen Steuerungsdaten kaum erforscht sind.

Des Weiteren sind produzierende Unternehmen durch eine hohe Variantenvielfalt der Anlagen gekennzeichnet. Diese Vielfalt ist zum einen auf unterschiedlichen Fertigungsverfahren wie beispielsweise trennende oder umformende Produktionsmaschinen oder Handhabungsmaschinen zurückzuführen. Zum anderen ist ein hoher Altersunterschied bei Fertigungsanlagen erkennbar. Der Verband Deutscher Werkzeugmaschinen gibt an, dass das durchschnittliche Alter von Werkzeugmaschinen in produzierenden Unternehmen bei mehr als 10 Jahren liegt (Barton & Stamm et al. 2020). Durch das unterschiedliche Alter der Maschinen gehen ein unterschiedlicher Informationsgehalt in den Daten sowie externe Einflussgrößen wie Rauschen einher. Daraus lässt sich ein weiteres Forschungsdefizit ableiten. Bislang sind keine Verfahren bekannt, welche ohne großen Applikationsaufwand und Parametrierung auf unterschiedlichste Produktionsmaschinen verschiedenen Alters anwendbar sind (Gönneheimer & Netzer et al. 2020) (Netzer & Gönneheimer et al. 2020).

Einige Forschungsarbeiten zeigen Ansätze auf, um auf wechselnde Randbedingungen, sogenannte „Konzept Drifts“ (Webb & Hyde et al. 2016), reagieren zu können. Dennoch werden diese Verfahren in der Regel in der Serienproduktion eingesetzt. In hochflexiblen Produktionsmaschinen ist die Datenmenge je Prozess meist zu gering, um zuverlässige Analysen durchführen zu können. Hier beschreiben einige Arbeiten im Stand der Forschung und Technik komplexe Algorithmen aus dem Bereich des Maschinellen Lernens, welche allerdings durch ein hohes Maß an Parametrierung und Systemver-

ständnis geprägt sind. Diese Eigenschaften machen die Verfahren für die praxistaugliche Anwendung in der Produktion unbrauchbar. Ein weiteres Defizit ist, dass bislang kaum Verfahren bekannt sind, welche bei wechselnden Prozessen in hochflexiblen Produktionsmaschinen und somit geringer Datenmenge anwendbar sind.

Im Bereich der Mustererkennung sind einige vielversprechende Arbeiten erkennbar. Vorhergehendes Kapitel zeigt zusammenfassend die wichtigsten Arbeiten. Diese Ansätze setzen in der Regel a priori Wissen voraus (Netzer, Michelberger & Fleischer 2020). Dieses a priori Wissen wird beispielsweise zur Parametrierung der Verfahren, wie zur Vorgabe der Clusteranzahl oder einer festes Fensterlänge angewendet. In vorliegendem Anwendungsfall dieser Dissertation ist nicht von vorhandenem a priori Wissen auszugehen, weshalb sich bei den beschriebenen Forschungsarbeiten im Bereich Mustererkennung ein weiteres Defizit eröffnet. Bislang sind kaum Arbeiten bekannt, welche ohne a priori Wissen und auf Basis stark wechselnder Randbedingungen wie Segmentlänge oder Signalniveau anwendbar sind. Des Weiteren sind keine Arbeiten publiziert, welche eine Mustererkennung zur Prozesssegmentierung nutzen, um aufbauend darauf eine Anomalieerkennung zu realisieren.

In einer Studie (Netzer & Begemann et al. 2021) wurde zudem aufgezeigt, dass bei modernen datengetriebenen Verfahren das gesammelte Wissen der Anlagenanwender nicht integriert wird. Das sogenannte Domänenwissen, bestehend aus der Erfahrung über das Verhalten und Eintreten einer Störung sowie deren Gegenmaßnahme, wird keine datengetriebenen Ansätzen berücksichtigt. Es sind keine Forschungstätigkeiten bekannt, welche ein hybrides Wissenssystem, bestehend aus dem Wissen der Anwender sowie datengetriebenen Analysen, aufzeigen. Aus diesem Grund lässt sich hierfür ein weiteres Defizit ableiten.

2.11 Zusammenfassung der Defizite und Lösungsansätze

Der in vorliegender Dissertation entwickelte Ansatz zur Erkennung von Störungen in verschiedenen hochflexiblen Produktionsmaschinen hat großes Potential aufgeführte Defizite im Stand der Forschung und Technik zu lösen. Dadurch kann ein neuartiges Verfahren etabliert werden, um Störungen im industriellen Umfeld eindeutig erkennen zu können. Ansätze zur Erkennung von Anomalien auf Grundlage einer Prozesssegmentierung mittels Mustererkennung wurden in einigen Vorarbeiten zur vorliegenden Dissertation quantifiziert und analysiert (Armbruster, Gönzheimer & Netzer 2021) (Gönzheimer & Netzer et al. 2020) (Netzer, Michelberger & Fleischer 2020) (Netzer &

Begemann et al. 2021) (Netzer & Gönzheimer et al. 2021) (Netzer & Gönzheimer et al. 2020) (Netzer, Michelberger & Fleischer 2019) (Netzer & Palenga et al. 2021) (Netzer & Bach et al. 2022). An einem exemplarischen Beispiel von (Netzer & Palenga et al. 2021) wird aufgeführt, dass die in dieser Dissertation zusammengeführten Ergebnisse der Arbeiten unter anderem im Rahmen eines Fräsversuchs an einer Werkzeugmaschine erfolgsbringend validiert sind. Die Analyse zeigt, dass keine kostenintensiven Nachrüstsensoren verbaut werden müssen und die Logik auf weitere Anlagen übertragbar ist.

Zur Präzisierung der Zielsetzung im nachfolgenden Kapitel 3 dieser Dissertation sind auf Basis der abgeleiteten Defizite aus dem zusammenfassenden Stand der Technik und Forschung Lösungsansätze gegenübergestellt. Abbildung 2-22 zeigt die beschriebenen Defizite und die in den nachfolgenden Kapiteln erläuterten Lösungsansätze.

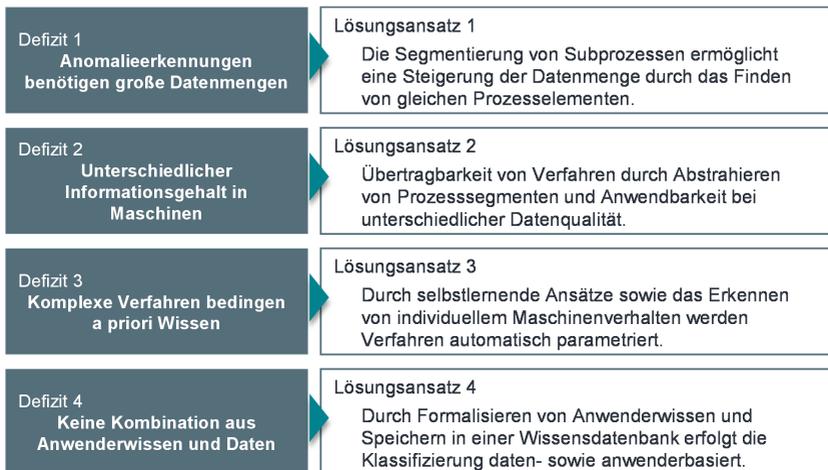


Abbildung 2-22: Aktuelle Defizite und Lösungsansätze.

3 Präzisierte Zielsetzung und Vorgehensweise

In vorliegendem Kapitel werden zunächst die im Stand von Forschung und Technik zusammengefassten Forschungsdefizite mit den angestrebten Lösungsansätzen konkretisiert. Ausgehend von der Analyse wird eine präzisierte Darstellung der angestrebten Vorgehensweise zur Zielerfüllung erarbeitet und erläutert.

3.1 Präzisierung der Zielsetzung

Ziel dieser Dissertation ist es mittels eines kombinierten Verfahrens Anomalien in hochflexiblen Produktionsmaschinen zur Prozessüberwachung aufzufinden. Dabei werden im ersten Schritt die bereits in der Maschine zur Verfügung stehenden Signalvariablen analysiert und über ein Verfahren zur Mustererkennung in einzelnen Subsegmente aufgeteilt. Anschließend erfolgen die Wiedererkennung der Segmente im Online-Signal und die darauffolgende Identifikation von Anomalien. Eine Integration von Anwenderwissen ermöglicht die Klassifikation der gefundenen Anomalien und erhöht die Klassifikationsgüte bei geringer Datenmenge. Durch ein geeignetes Zusammenspiel aus Datenaufnahme, Datenvorverarbeitung, Kombination einzelner Analysemethoden sowie Integration von Anwenderwissen in einer intelligenten Prozessüberwachung kann eine frühzeitige Störungsidentifikation erzielt werden. Gerade bei wechselnden Maschineneinflüssen oder -prozessen sind herkömmliche im Stand von Forschung und Technik beschriebenen Ansätze kaum anwendbar. Die entwickelten Verfahren sind als praxisrelevantes intuitives Softwareprogramm umgesetzt, welches ohne großen Applikationsaufwand an einem Steuerungscomputer einer Maschine angebracht werden kann. Durch die Integration von Anwenderwissen, sowohl zur Beschreibung von Störungen und deren Gegenmaßnahmen, als auch zur Abfrage von Anomalieentscheidungen kann die Akzeptanz von intelligenten Verfahren maßgeblich gesteigert werden. Somit können neben wirtschaftlichen Zielen der Prozessüberwachung auch Akzeptanzsteigerungen hinsichtlich Industrie 4.0 Technologien erreicht werden. Nachfolgend wird ausgehend von der präzisierten Beschreibung der Zielstellung eine Vorgehensweise zur Zielerfüllung abgeleitet. Die Vorgehensweise orientiert sich an den beschriebenen Lösungsansätzen, welche sich aus der Analyse der Forschungsdefizite ergeben. Abbildung 3-1 zeigt ein in die industrielle Praxis übertragenes Zielbild des Systems. Der Dateninput stammt direkt aus einer Produktionsmaschine, exemplarisch an einer Fräsmaschine im Schaubild dargestellt. Herausforderungen im Hinblick auf die Datenaufnahme sind in vorliegender Dissertation bewusst nicht adressiert. Historische Offline-Signale

werden im ersten Schritt über Methoden der Mustererkennung analysiert und daraus Prozesssegmente berechnet. Diese werden in einer sogenannten Signal-Datenbank abgespeichert. Anschließend erfolgt die Online-Identifikation von wiederkehrenden Prozesssegmenten und bei der Übereinstimmung mit der Signaldatenbank wird die Anomalieerkennung in den Signalen durchgeführt. Die Klassifikation erfolgt datenbasiert sowie aufgrund von formalisiertem Anwenderwissen. Dieses Anwenderwissen wird in einer Domänenwissensdatenbank abgespeichert. Zur erfolgreichen Fehlersuche sowie zum nachhaltigen Beheben von Störungen werden den gefundenen Anomalien Maßnahmen beigefügt. Diese werden automatisiert dem Anwender bei erneutem Störfall angegeben. Die Umsetzung der beschriebenen Verfahren erfolgt programmiertechnisch und über eine grafische Benutzeroberfläche (engl.: Graphical User Interface, kurz: GUI). Mit Hilfe dieses Ansatzes lassen sich signifikante Prozessanomalien mit einem kausalen Zusammenhang der Prozesskraft und dem zu messenden Signal auffinden. Die Störungen müssen im verrauschten Signal erkennbar sein. Kleine Abweichungen, welche bspw. durch Umgebungsbedingungen resultieren, können vom vorliegenden System nicht gefunden werden und sind auch nicht Fokus der Arbeit.

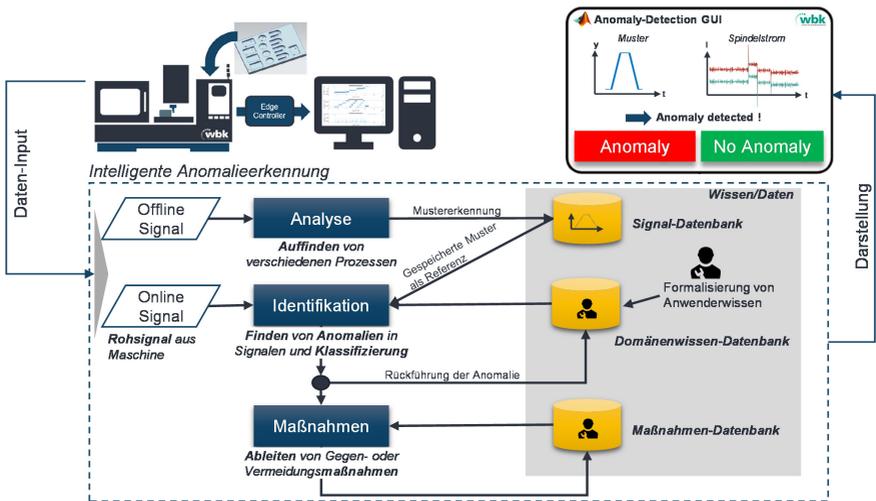


Abbildung 3-1: Schaubild der intelligenten Anomalieerkennung und Darstellung der Schnittstellen.

Nachfolgend werden Arbeitspakete abgeleitet, um die wissenschaftlichen Kernfragen beantworten zu können.

3.2 Vorgehensweise zur Zielerfüllung

Die zur Zielerfüllung angestrebte Vorgehensweise ist in Abbildung 3-2 dargestellt und visualisiert. Nachfolgend werden die relevanten Kapitel der Vorgehensweise erläutert und eingeführt.

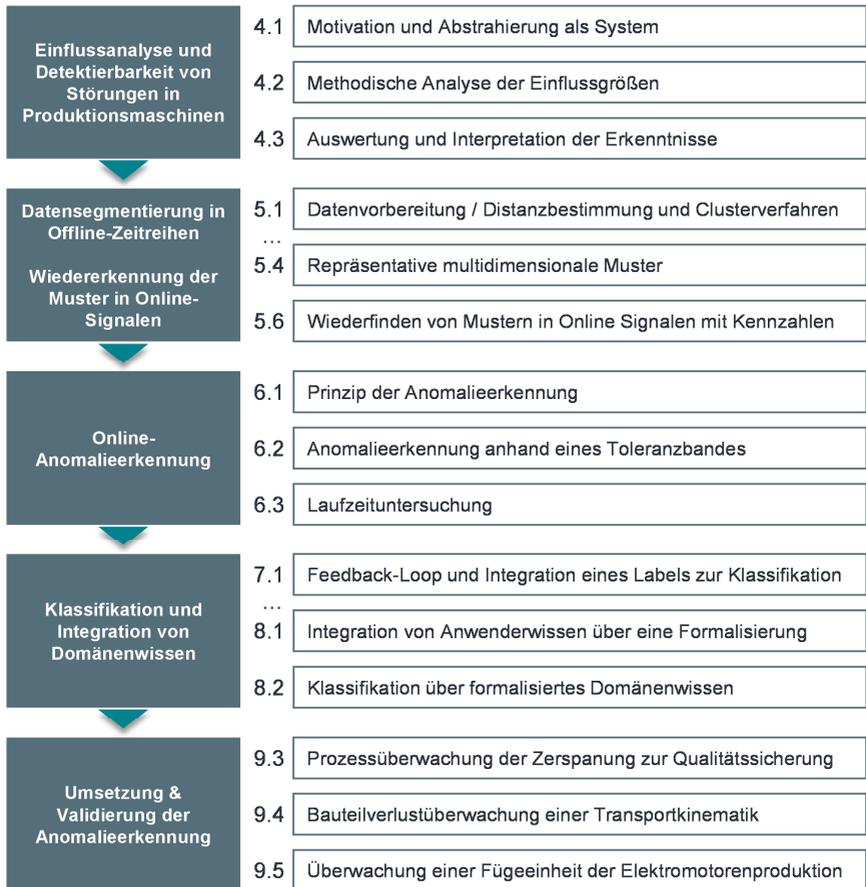


Abbildung 3-2: präzisierte Vorgehensweise zur Zielerfüllung.

Im ersten Schritt in Kapitel 4 erfolgt eine Eingrenzung der Detektierbarkeit von Störungen in Brownfield Produktionsmaschinen. Dabei wird der Begriff der prinzipiellen Messbarkeit eingeordnet und mit Hilfe von methodischen Ansätzen aus der Regelungstechnik abstrahiert. Auf Grundlage einer Eingrenzung von externen und internen Einflussgrößen von der Maschine sowie deren Umgebung erfolgt eine Bewertung und formale Beschreibung der sogenannten Messstrecke. In Anschluss daran erfolgt die Interpretation und Ableitung von Anforderungen an die Verfahren in dieser Dissertation.

Anschließend wird in Kapitel 5.1ff die Datenvorverarbeitung eingeführt. Hier werden maschinen- und anlagentypische Eigenschaften der Messreihen analysiert und durch geeignete Verfahren vorverarbeitet. In Kapitel 5.3 werden Verfahren zur Mustererkennung vorgestellt und ein eigener Ansatz präsentiert, um Prozesse in hochflexiblen Anlagen segmentieren zu können. Dies mündet in der Berechnung von multidimensionalen repräsentativen Prozessmustern. Die beschriebenen Verfahren erfolgen auf Basis historischer Messzeitreihen. Ansätze zum Wiederfinden der repräsentativen Muster in Online-Zeitreihen werden in Kapitel 5.6 beschrieben.

In Kapitel 6 erfolgt die Beschreibung der eigenen Ansätze zum Auffinden von Anomalien. Die Anomalien werden vorerst nicht klassifiziert, sondern lediglich als unerwartete Ausprägung erkannt.

In Kapitel 7 werden neuartige Ansätze vorgestellt, um ein Label zur Klassifikation der Anomalien zu integrieren. Die Klassifikation erfolgt sequenziell nach dem Auffinden der Anomalien mit dem Prinzip aus Kapitel 6 und steigert die Genauigkeit des Gesamtsystems maßgeblich. Des Weiteren ist durch die Integration eines Labels auch die Klassifikation durch den Anwender möglich. In Kapitel 8.1 werden Ansätze zur Formalisierung von bestehendem Anwenderwissen diskutiert und anschließend in Kapitel 8.2 die Klassifikation durch formalisiertes Wissen erläutert.

Alle vorgestellten Ansätze werden an repräsentativen, praxisrelevanten Anwendungsfällen validiert. Die entwickelten Verfahren werden dem Anwender über eine App bereitgestellt. Abschließend werden die Ansätze zusammengefasst analysiert und auf Basis der Validierung bewertet. Zudem erfolgt eine qualitative ökonomische Bewertung zur Anwendung in der Produktion.

4 Einflussanalyse und Detektierbarkeit von Störungen

Ziel dieses Kapitels ist die Herleitung von Einflussgrößen auf die Messbarkeit von Störungen sowie die Beschreibung einer allgemeinen Methodik zur Bewertung der Detektierbarkeit. In Brownfield Produktionsmaschinen ist es wichtig, neben der Betrachtung der methodischen Datenauswertung auch maschinenspezifische und messbedingte Einflüsse zu quantifizieren. Aufgrund der meist bereits fortgeschrittenen Lebensdauer einer Brownfield Maschine müssen die Einflüsse aus der Maschine und der Messung in der Klassifikation sowie bei der Übertragbarkeit berücksichtigt werden. Stand der Technik Ansätze beziehen sich hingegen nur auf die methodische Datenauswertung.

Zur Herleitung der Einflüsse auf die Messbarkeit wird das Gesamtsystem der Produktionsmaschine zunächst als Übertragungsstrecke analog zur Regelungstechnik abstrahiert. Anschließend erfolgen die Erläuterung der Messstrecke und die Beschreibung der spezifischen Einflüsse.

In diesem Kapitel wird gezeigt, dass die Übertragungsfunktion zwischen Prozesskraft bzw. der Messgröße und der Messaufnahme in der Steuerung verschiedenen äußeren und inneren Einflüssen unterliegt und der Erfolg der Anomalieerkennung nicht ausschließlich von der Konzeption der Datenauswertung abhängt.

Die Inhalte der folgenden Kapitel wurden im Rahmen der angeleiteten Arbeit (A_Wurche 2020) erarbeitet. Die Ergebnisse sind zusammengefasst dargestellt.

4.1 Motivation und Abstrahierung als System

Im ersten Teil des Kapitels erfolgt die Abstrahierung der Problemstellung. Dafür muss zunächst geklärt werden, was unter dem Begriff Detektierbarkeit zu verstehen ist. Eine stimmige Definition hierfür im Kontext der Anomalieerkennung bei Produktionsmaschinen wird durch die Regelungstechnik mit dem Begriff der Beobachtbarkeit bzw. der Rekonstruierbarkeit gegeben. In der Regelungstechnik wird ein Mehrgrößensystem als beobachtbar bezeichnet, sofern sich in einem endlichen Zeitintervall mittels des Verlaufs der Eingangs- und Ausgangsgrößen eindeutig der Anfangszustand des System rekonstruieren lässt (Lunze 2020b).

Wird die Übertragungsfunktion, welche bei einer Anomalieerkennung die Funktion zwischen Wirkpunkt der Störung in der Maschine (meist die Prozesskraft am Werkzeug) und der Messaufnahme in der Steuerung darstellt, in einem hinreichend kleinen Zeitin-

tervall betrachtet, sodass der Zustand einer Produktionsmaschine als stationär und linear angenommen werden kann, ist die gesamte Übertragungsfunktion eindeutig beschreibbar. Ist ein System rekonstruierbar, so heißt dies, dass sich aus den Eingangs- und Ausgangsgrößen in einem bestimmten zeitlichen Intervall T auch eindeutig der Zustandsvektor x zum Zeitpunkt t rekonstruieren lässt (Lunze 2020b). Auf Basis dieser Definitionen können Kriterien für die Beobachtbarkeit und Rekonstruierbarkeit von Systemen festgelegt werden. Weitere Erläuterungen und Ausführungen zeigen (Lunze 2020a) (Lunze 2020b) (Stiller 2006).

Die Rekonstruktion und Analyse eines Ausgangszustandes durch die Messung einer oder mehrerer Systemgrößen entspricht genau der gewünschten Funktion einer Anomalieerkennung auf maschineninternen Messdaten einer Produktionsmaschine. Jedoch kann das theoretische Wissen aus der Mess- und Regelungstechnik nur bedingt auf die reale Anwendung übertragen werden, da hierfür in der Regel ideale Systeme betrachtet werden. In der praktischen Anwendung sind jedoch nicht-ideale Einflussgrößen, bei grundsätzlich gewährleiteter Messbarkeit, entscheidend. Im Folgenden werden daher die Einflussgrößen detailliert betrachtet.

4.2 Methodische Analyse der Einflussgrößen

Im Folgenden sollen die Einflüsse aller Art auf die Messbarkeit einer Anomalie methodisch analysiert werden. Um hierbei allerdings die geforderte maximale Generalität zu gewährleisten, ist es zuvor notwendig auch den zu detektierenden Messfehler möglichst generisch zu fassen, weshalb hier ebenfalls vorab eine eingehende Analyse notwendig ist. Anschließend sollen anhand eines Leitbeispiels die spezifischen Einflussgrößen auf den Messprozess untersucht werden.

4.2.1 Ableitung generischer Störungsgruppen

Eine wichtige Überlegung der Systemtheorie ist, dass ein technisches System zur Erfüllung seiner Funktion nicht getrennt von seiner Umgebung betrachtet werden kann. (Ropohl 2009) führt in diesem Zusammenhang am Beispiel eines Computers den Begriff des sozio-technischen Systems ein. Er motiviert dies durch die Überlegung, dass ein Computer zur vollumfänglichen Erfüllung seiner Funktion eines Bedieners bedarf und dass beide für sich getrennt die an sie gestellten Forderungen nicht erfüllen können. Diese Überlegung lässt sich auf Produktionsmaschinen übertragen, da hier die Ursache für eine Prozessanomalie ebenfalls nicht allein auf der Maschinenseite liegt.

Vielmehr muss durch Verallgemeinerung der Systemgrenze ein sozio-technisches System geschaffen werden, welches alle möglichen Einflussgrößen berücksichtigt. Eine Veranschaulichung dieser Überlegung am Beispiel der Produktionsmaschine liefern (Weck & Brecher 2013) mit ihrer Auflistung aller möglichen Einflussfaktoren in Kapitel 2.2.1, Abbildung 2-2. Als Beispiel soll das Fräsen eines beliebigen Werkstückes betrachtet werden, bei welchem während des Bearbeitungsvorgangs ein Werkzeugbruch eintritt. Es werden dabei vor allem die Motorströme der Spindel sowie die Positionsdaten des Werkzeuges beobachtet.

4.2.2 Analyse der Einflussgrößen

Die beschriebene Messstrecke, siehe Abbildung 4-1, kann aus drei wesentlichen Teilsystemen und den Randbedingungen aus der Systemumgebung beschrieben werden. Beispielsweise breitet sich die Störungsinformation des gebrochenen Werkzeuges zunächst als analoges Signal über die Werkzeugmaschine aus. Dort gibt es maschinenspezifische Einflüsse, welche das Signal beeinflussen. Anschließend erfolgt die messtechnische Verarbeitung, welche ebenso Einflüssen unterliegt. Das Messsignal aus der Steuerung der Maschine wird dann über eine Methodik ausgewertet. Je nach Signalaufbereitung und Methodik wird das Signal anders evaluiert. Die gesamte Messstrecke unterliegt dabei weiteren Umgebungsbedingungen wie verfügbare Rechenleistung.

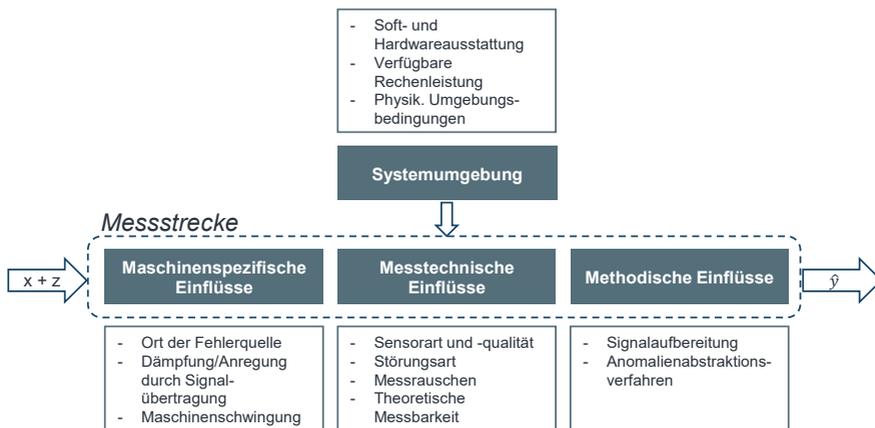


Abbildung 4-1: Systemtheoretische Betrachtung der Messstrecke mit der Messgröße x , der Anomalie z sowie der Messgröße \hat{y} .

Zusammenfassend können aus dieser Darstellung der Messstrecke vier wesentliche Einflussgrößen auf die Beobachtbarkeit bzw. Messbarkeit von Anomalien abgeleitet werden, welche im Folgenden weiter erläutert werden.

4.2.2.1 Maschinenspezifische Einflüsse

Maschinenspezifische Einflussgrößen bezeichnen physische Systemparameter, die einen signifikanten Einfluss auf die Qualität der Messgrößenerfassung haben. Beispielsweise stellt die übermäßige Dämpfung der zunächst analogen Messgröße über die physische Übertragungstrecke bis hin zum messenden Sensor eine solche Einflussgröße mit negativem Einfluss auf die Messbarkeit einer Anomalie dar.

4.2.2.2 Messtechnische Einflüsse

In die Kategorie der messtechnischen Einflussgrößen fallen alle Einflüsse, die unter messtechnischen Aspekten die Detektierbarkeit einer Anomalie beeinflussen. Ein sehr prominentes Beispiel hierfür sind beispielsweise die theoretische Messbarkeit einer Anomalie gemäß des Shannon-Nyquist-Theorems oder aber auch die Art der Störung (A_Winkler 2020).

4.2.2.3 Methodische Einflüsse

In diese Kategorie fallen alle Aspekte, welche die Anomaliedetektion von der Wandlung des analogen Signals in das korrespondierende digitale Signal, die Messung oder Detektierbarkeit einer Prozessanomalie beeinflussen. Dieser letzte Teilschritt in der Funktionslogik einer Anomalieerkennung, auch Detektionsmethodik bezeichnet, stellt den in sich flexibelsten und am einfachsten anzupassenden Teil dar. Es müssen hier vor allem die digitale, rechnergestützte Signalaufbereitung und die zugrunde liegende Detektionslogik für Anomalien berücksichtigt werden.

4.2.2.4 Systemumgebung

Die Randbedingungen leiten sich vor allem aus der umgebenden Umwelt ab. Als Randbedingungen im Kontext der qualitativ hochwertigen, kontinuierlichen Messung von Systemgrößen sind vor allem ökonomische Aspekte und Entwicklungsbarrieren zu nennen. So ist die software- und hardwaretechnische Ausstattung einer Produktionsmaschine in der Regel durch ökonomische Begrenzungen eingeschränkt, sofern sie nicht dem aktuellen Stand der Technik entspricht.

4.3 Auswertung und Interpretation der Erkenntnisse

Des Öfteren entstehen ökonomische Konflikte mit anderen Optimierungsgrößen im Hinblick auf die Detektierbarkeit von Anomalien. Dabei ist im Allgemeinen von einem Zielkonflikt die Rede, welcher durch die zuvor beschriebenen vier wesentlichen Einflussgrößen definiert ist. Ein anschauliches Beispiel für dieses Spannungsfeld ist eine besonders hochfrequente Anomalie, für die oftmals eine komplexe Messanordnung im Rahmen der technischen Möglichkeiten realisierbar wäre. Da jedoch dieses System in der Regel mit einem erheblichen finanziellen Mehraufwand verbunden ist, kann der Mehrwert in der Regel nicht positiv bewertet werden.

Bei näherer Betrachtung dieses Zielkonfliktes stellt sich konsequenterweise die Frage nach einem Optimum bezüglich der Messbarkeit einer Anomalie. Die Existenz eines solchen Optimums lässt sich durch ein klares Anwendungsprofil einer Anomalieerkennung auf Basis von internen Steuerungsdaten ableiten.

4.4 Grenzen der Verfahren in der praktischen Anwendung

Nach der theoretischen Eingrenzung erfolgt die Beschreibung der Verfahrensgrenzen in den praktischen Anwendungen. Im Allgemeinen wird bei vorliegenden Produktionsprozessen von quasi statischen Prozessen ausgegangen. Dynamische Einflüsse wie beispielsweise eine auftretende Schwingung durch externe Einflüsse wird in vorliegenden Verfahren dieser Dissertation nicht berücksichtigt. Zudem weisen die nachfolgenden Verfahren konzeptbedingt eine zeitliche Latenz beim Auswerten und Auffinden von Anomalien auf. Dies führt dazu, dass keine direkte Maschinenkoppelung, beispielsweise zum Stoppen der Maschine, umgesetzt werden kann. Die minimale Reaktionszeit beträgt konzeptbedingt < 1 sec.

Als weitere Grenze ist die selbstgelernte Eingriffsgrenze des Systems zu nennen. Das Verhältnis von Ausmaß der Störung, welche durch die Anzahl und den Absolutwert der Ausreißer-Datenpunkte gekennzeichnet sind, zur berechneten Hüllkurve ist für die Reaktionszeit resp. Sensitivität des Systems stellvertretend. Weisen Prozesse in Brownfield Maschinen eine hohe Varianz und somit Rauschen in den Daten auf, werden die Eingriffsgrenzen mit geringer Sensitivität berechnet. Demnach können kleinste Prozessanomalien, welche im Rauschen der Messdaten kaum sichtbar sind, nicht aufgefunden werden. Die Untersuchungen im Rahmen dieser Dissertation erfolgten in Laborumgebungen.

4.5 Fazit der Detektierbarkeit von Störungen

Nach der Einführung der notwendigen Begrifflichkeiten erfolgte die methodische Herleitung der wesentlichen Einflussgrößen und Randbedingungen bezogen auf die Messstrecke. Die Überlegungen und Abstrahierungen führten auf den Begriff der theoretischen Messbarkeit, anhand dessen sich die relativen Systemgrenzen als Abstandsfunktion zu einem Idealprofil ableiten lassen. Wesentliche Erkenntnis dieses Kapitels ist, dass die Systemgrenzen der Anwendung einer generischen Anomalieerkennung auf vier Eigenschaften rückführbar sind.

Die maschinenspezifischen Einflussgrößen (1), die messtechnischen Einflüsse (2), Umgebungsbedingungen (3) sowie der Detektionslogik der Anomalieerkennung (4) bestimmen die Detektierbarkeit der Störungen in Produktionsmaschinen. Die externen Einflüsse sind in der Praxis oft schwer quantifizierbar, da viele Einflussgrößen nicht messbar sind oder weitere externe Randbedingungen vorliegen. Rechtfertigt schlussendlich der technische Nutzen den allgemeinen Mehraufwand des Systems, durch Wartung und Implementierung, so ist ein positives Kosten-Nutzen Verhältnis gegeben und die Anwendung des Systems sinnvoll und empfehlenswert.

In dieser Arbeit werden die beschriebenen Einflussgrößen durch gezielt angewendete Verfahren eliminiert. Die Entwicklung der Verfahren zur Datensegmentierung umfasst gezielt Verfahren zur Eliminierung der Einflüsse aus Brownfield Maschinen wie beispielsweise starkes Rauschen aufgrund verschlissenen Maschinenkomponenten. Die messtechnischen Einflüsse sind aufgrund der Messaufnahme in der Steuerung nicht zu beeinflussen. In dieser Arbeit werden aber Mindestanforderungen der Datenaufnahme von internen Steuerungsdaten erarbeitet. Die Detektionslogik basiert auf einem hybriden System aus datengetriebenen Verfahren sowie Ansätzen auf Grundlage von Domänenwissen. So kann eine Anomalieklassifizierung auch bei geringer Datenmenge erfolgen.

5 Mustererkennung in Zeitreihen

In den nachfolgenden Kapiteln der vorliegenden Dissertation werden Lösungsansätze einer Anomalieerkennung auf Basis einer Datensegmentierung und Online-Wiedererkennung erläutert. Abbildung 5-1 zeigt den Aufbau des Gesamtablaufs und zeigt online resp. offline Bausteine auf. Der gesamte Lösungsansatz baut im ersten Schritt (Abbildung 5-1, Abschnitt 5.1-5.6) auf eine Referenzierung des vorliegenden Prozess- und Maschinenzustandes durch das Erkennen wiederkehrender Bearbeitungen durch eine Mustererkennung auf. Anschließend erfolgt eine Anomalieerkennung (Abbildung 5-1, Abschnitt 6.1) durch einen relativen Signalabgleich. Im letzten Schritt werden Ansätze diskutiert, wie die Integration von Anwenderwissen durch Labeling (supervised learning, Abbildung 5-1, Abschnitt 7.3) und durch Formalisierung von Domänenwissen zur Steigerung der Genauigkeit der Anomalieerkennung führen kann.

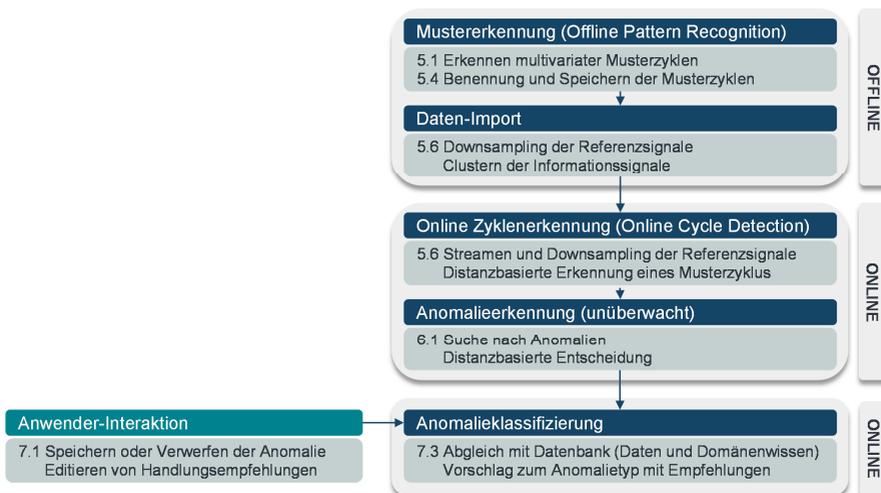


Abbildung 5-1: Modularer Aufbau des Anomalieerkennungssystems.

Die Datensegmentierung in Offline-Signalen sowie das anschließende Wiederfinden der Zeitreihensegmente im Online-Signal sind maßgeblich für den Erfolg der gesamten Anomalieerkennung verantwortlich. Das Auffinden von repräsentativen Zeitreihensequenzen ist keine triviale Aufgabe. Gemessene Daten aus Produktionsmaschinen charakterisieren sich in der Regel durch Messfehler, Rauschen und Latenz bei der Mess-

aufnahme im Brownfield. Analytische Herangehensweisen können zielführend sein, bedingen allerdings meist a priori Wissen über den Prozess oder über den Maschinenzustand. Im nachfolgenden Kapitel werden Ansätze der Offline-Datensegmentierung und der Online-Mustererkennung diskutiert, welche auf Basis der in Kapitel 4 eingegrenzten Maschinenrandbedingungen anwendbar sind. Im ersten Schritt erfolgt eine Diskussion von Ansätzen zur Datenvorbereitung resp. Glättung der Zeitreihen. Die Datenvorbereitung beschreibt mit etablierten Umsetzungsmethoden (Chapman & Clinton et al. 2000) eine der relevantesten Elemente, da sie maßgeblich zur Genauigkeitssteigerung der Ansätze durch Eliminierung von Messfehlern und Rauschen beiträgt. In Kapitel 5.1 werden Lösungen zur Filterung über gefensterete Ansätze evaluiert, bewertet und in das Gesamtsystem eingeordnet. Nachfolgend erfolgt die Bewertung der Ähnlichkeiten von aufgeteilten Subsequenzen einer Zeitreihe. Diese werden in der Regel über eine Ähnlichkeits-Kennzahl wie beispielsweise die Distanz der Abweichungen im paarweisen Vergleich bestimmt. Kapitel 5.2 beschreibt einige Lösungsalternativen und bewertet diese. Anschließend wird das dichte-basierte Clusterverfahren vorgestellt. Dadurch können auf Basis der Ähnlichkeits-Kennzahl zusammengehörende resp. in deren Dichte ähnliche Zeitreihensequenzen aufgefunden werden. Kapitel 5.3 beschreibt im Wesentlichen das Clusterverfahren sowie die Wahl der nicht-trivialen Schrittweite, der sogenannten Bandwidth. Die Bandwidth beschreibt die Schrittweite des Konvergenzverfahrens. Hier werden weitere Lösungsvarianten vorgestellt sowie eine Bewertung hinsichtlich der Umsetzung in Produktionsmaschinen abgegeben. Der letzte Schritt der Offline-Datensegmentierung ist das Berechnen eines repräsentativen Verlaufs bestehend aus allen Zeitreihensequenzen jedes Clusters. Kapitel 5.4 zeigt anschaulich Berechnungsansätze auf.

Beim anschließenden Wiederfinden der Muster im Online-Signal in Kapitel 5.6 werden unterschiedliche Berechnungsarten eines Score Wertes vorgestellt. Auch hier werden Ähnlichkeiten von Abschnitten im Online-Signal zu den bereits gefundenen Repräsentanten über einen Ähnlichkeits-Score bestimmt. Das Kapitel schließt mit einer Bewertung und Fazit ab. Im danach folgenden Kapitel wird die Anomalieerkennung eingeführt. Anomalien werden im ersten Schritt unüberwacht gefunden, um sie dann über eine Klassifikation einem bestehenden Label zuzuordnen. Dies erfolgt auf der einen Seite datenbasiert, auf der anderen Seite durch formalisiertes Domänenwissen eines Anwenders.

Die Inhalte der folgenden Kapitel wurden im Rahmen der angeleitete Arbeiten (A_Chamolias 2019) (A_Michelberger 2019) (A_Wurche 2020) (A_Mehmedovic 2020) (A_Kopp 2019) (A_Köhler 2020) (A_Winkler 2020) (A_Baier 2021) analysiert. Die Ergebnisse sind zusammengefasst dargestellt.

5.1 Datenvorbereitung / Glättung

Daten aus Brownfield Produktionsanlagen charakterisieren sich meist durch eine hohe Anzahl unerwünschter Einfluss- und Störgrößen wie beispielweise resultierende Schwingungen, Temperatureinflüsse oder die durch Verschleiß hervorgerufene Veränderungen des Messsignales. In Kapitel 4 sind diese maschinenspezifischen Einflüsse bereits generisch hergeleitet. Diese Einflüsse zeigen sich im Messsignal als Rauschen oder verzerrtes Signalverhalten. Gerade bei der Bestimmung von charakteristischen Signalpunkten wie Extremwerte können in verzerrten Signalen oder bei Rauschen kaum exakte Werte bestimmt werden. Bei der Verarbeitung von Daten aus Brownfield Produktionsanlagen ergeben sich daher notwendige Vor- und Nachverarbeitungsschritte. Ziel der vorverarbeitenden Schritte ist es, die Information im Signalverlauf von den Störeinflüssen zu extrahieren, und so Verfahren zur Anomalieerkennung in Brownfield Maschinen zu ermöglichen. Ein Informationsverlust durch den Einsatz glättender oder signalanpassender Verfahren ist stets zu vermeiden resp. gering zu halten. Eine verlorene Information zu Beginn der Datenverarbeitung lässt sich in der Regel nicht mehr wiederherstellen. Im vorliegenden Kapitel werden aus dieser Motivation begründet verschiedene Konzepte auf Basis einer Anforderungsanalyse zur Datenvorbereitung evaluiert. Das Zielkonzept wird im Folgenden näher beschrieben und die Eignung für den Anwendungsfall in der Produktionsmaschine bewertet. Zur Problembeschreibung ist in Abbildung 5-2 das verrauschte Rohsignal (Position) einer Vorschubachse einer Werkzeugmaschine ersichtlich. Im oberen Diagramm (a) ist ein Rohsignal des Positionssignals zu erkennen. Bei verrauschten Signalen ist die Berechnung des globalen Extremwertes Minimum schwierig, da oftmals durch das Signalaruschen lokale Minima als globale bestimmt werden. In Bereichen, in denen keine Maschinenbewegung stattfindet, ist das Signal durch das Rauschen dennoch nicht konstant. In der nachfolgenden Abbildung ist dies durch eine vergrößerte Darstellung (b, rot gestrichelter Bereich) ersichtlich. In diesem Bereich findet keine Maschinenbewegung statt. Aufgrund von maschinenspezifischen und messspezifischen Einflüsse (vgl. Kapitel 4) ist ein verrauschtes Messsignal zu erkennen. Eine Berechnung des Minimums ohne eine

Vorverarbeitung und Eliminierung des Rauschens führt zu falschen Start- und Endwerten des Segmentes (oberes Diagramm (a), rechter Bereich, eigentliches Segment).

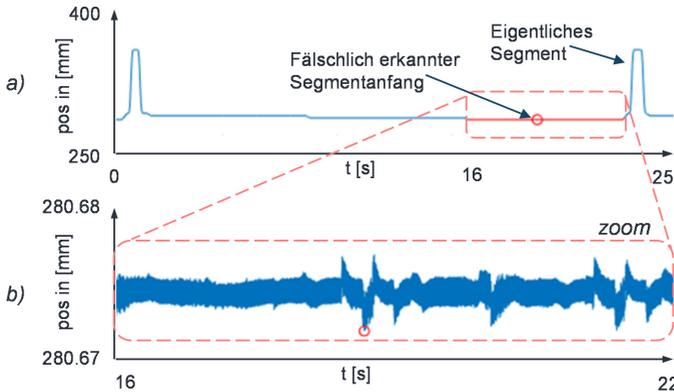


Abbildung 5-2: (a) Reale Messdaten einer Fräsmaschinenachse (Z-Achse) und Berechnung des globalen Minimums als Musteranfang. (b) Zoom in den Bereich des globalen Minimums.

Ziel des nachfolgenden Ansatzes ist es, eine Datenvorverarbeitung zu entwickeln, wodurch eine exakte Bestimmung von charakteristischen Extremwerten in Produktionsmaschinen ermöglicht wird.

5.1.1 Ableitung der Anforderungen

Aus der theoretischen Betrachtung der maschinenspezifischen Einflussgrößen sowie der Motivation im Hinblick auf eine Datenvorverarbeitung werden nachfolgende Anforderungen an ein Lösungskonzept abgeleitet. Neben obligatorischen Anforderungen, welche auf Basis maschinenspezifischer Eigenschaften notwendig sind, ergeben sich weitere vorteilhafte Anforderungen, welche für die Auswahl des optimalen Lösungskonzepts herangezogen werden. Abbildung 5-3 zeigt die Aufstellung der Anforderungen bestehend aus den obligatorischen und zusätzlichen vorteilhaften Anforderungen.

Obligatorische Anforderungen	Vorteilhafte Anforderungen
<ul style="list-style-type: none"> - Parametrisierung anhand a priori bekannter Informationen - Rauschhandhabung - Zuverlässige Extremwertsuche - Signaltrend-Erkennung 	<ul style="list-style-type: none"> - Informationsgenauigkeit - Adaptivität in der Parametrisierung - Laufzeiteffizienz - Primitivität

Abbildung 5-3: Anforderungen an die Datenvorverarbeitung.

Um eine generalisierbare Lösung auf verschiedenen Anlagen zu realisieren, ist eine Parametrisierung (Abbildung 5-3, links) notwendig. Diese Parametrisierung soll lediglich anhand von a priori Informationen der Maschine erfolgen, sodass eine schnelle Übertragbarkeit gewährleistet werden kann. Des Weiteren ist neben dem Verarbeiten von verrauschten Signalen auch eine sogenannte Trenderkennung essentiell. Ein Trend ist ein stetig monoton steigendes Signal, hervorgerufen durch eine sehr langsame Maschinenbewegung, beispielweise bei einer Feinbearbeitung. Die minimale Geschwindigkeit der Maschine ist grundsätzlich a priori bekannt. Mit Hilfe einer Trenderkennung kann zwischen einer langsamen Maschinenbewegung und einem Drift im Signal unterschieden werden. Abbildung 5-3 zeigt auf der rechten Seite weitere vorteilhafte Anforderungen, welche in die Bewertung und Auswahl der nachfolgenden Konzepte einfließen.

5.1.2 Diskussion über mögliche Konzepte zur Rauschhandhabung

Basierend auf einem Vergleich relevanter Ansätze aus der Literatur werden zur Reduzierung des Rauschens nur filternde oder approximierende Verfahren bewertet. Beim Anwendungsfall der Anomalieerkennung in Produktionsmaschinen treten bei den restlichen Verfahren entscheidende, nicht kompensierbare Nachteile auf. Im Folgenden werden im Hinblick auf die in der Literatur verwendeten Verfahren zwei Ansätze zur Rauschreduzierung evaluiert. Die anschließende Bewertung wird auf Basis relevanter Eigenschaften für die Anomalieerkennung qualitativ durchgeführt.

Eines der bedeutendsten Verfahren in der Signalverarbeitung stellt die Filterung mit Hilfe der Transformation des Signals in den Frequenzbereich dar. Nach der Transformation erfolgt die Anwendung eines Filters, wie Tiefpass- oder Hochpassfilter (Puente León & Kiencke 2013), im Frequenzbereich. Für diese Art von Signalverarbeitung, speziell der Fourier- und Wavelettransformation, existieren bereits weit verbreitete, schnelle und effiziente Algorithmen. (Agrawal, Faloutsos & Swami 1993) (Chan & Fu 1999) zeigen Verfahren zur Rauschminderung auf Basis einer Frequenztransformation

auf. Diese zeichnen sich durch eine hohe Genauigkeit aus. Transformierende Verfahren stoßen jedoch bei zunehmender Bandweite des Störsignals an ihre Grenzen. Dies zeichnet sich als der Hauptnachteil dieser Verfahren aus. Im realen Produktionsumfeld, resp. der damit verbundenen Datenaufnahme, treten zwar begrenzt, jedoch sehr breite Frequenzspektren auf. Dies verhindert die klare Definition eines Schwellwerts zur Filterung von Störfrequenzen. Problematisch ist dies, da oftmals keine Filterung ohne ein Beschneiden des tatsächlichen Signals möglich ist. Des Weiteren ist aufgrund der hohen Komplexität der Verfahren eine einfache Modellierung kaum möglich.

Ein weiteres Verfahren zur Verarbeitung von Rauschen im Signal ist die Filterung mittels mittelwertbildender Ansätze. Einflussgrößen oder Störungen im Signal werden durch eine Normalverteilung hinreichend gut beschrieben. Dadurch kann bei hinreichend häufig unabhängig wiederholten Messungen der Erwartungswert als wahrer Wert interpretiert werden. Diese Hypothese ist durch Kolmogorovs starkes Gesetz der großen Zahlen (Chow 1960) belegt. Das Gesetz sagt aus, dass bei k Wiederholungen eines Messereignisses eine sichere Konvergenz eines Mittelwertschätzers des wahren Wertes einer Messgröße vorliegt. Dabei muss allerdings k gegen unendlich gehen. Diese Annahme ist jedoch nicht zu verwechseln mit der unzulässigen Vermutung der sicheren Existenz eines Grenzwertes (Stiller 2006). Eine allgemeine Herausforderung der gleitenden Filteroperation ist das Verarbeiten der Randwerte.

Um die oben beschriebenen Ansätze weiter zu bewerten, sind die Anforderungen an Informationsgenauigkeit im Folgenden beschrieben.

Die mittelwertbasierte Glättung einer Zeitreihe ist erfolgsversprechender und wesentlich effizienter bei breiten Störgrößenverläufen. Durch den Einsatz einer Wavelettransformation anstatt der Fouriertransformation kann der Effizienznachteil kompensiert werden. Die Wavelettransformation kann im Vergleich zu einer filterbasierten Lösung jedoch nicht den größeren Informationsverlust ausgleichen.

Die mittelwertbasierte Filterung ist im Hinblick auf die Implementierungsanforderungen sowie der adaptiven Parametrisierung einer fourierbasierten Filterung vorzuziehen. Der Glättungsgrad ist bei der mittelwertbasierten Filterung lediglich von der gewählten Fensterlänge abhängig.

5.1.3 Konzeptauswahl

Ein Ausschlusskriterium bei der Signalaufbereitung mittels der Filterung im Frequenzspektrum ist das Auftreten von weißem Rauschen. Dies verstärkt die bereits beschriebenen Vorteile gleitender Fensteroperationen zur Rauschminderung bzw. -handhabung. Abbildung 5-4 zeigt die Gegenüberstellung und Bewertung der beiden Ansätze. Das Fehlen von signifikanten Mittelwerten der Rauschsignale wirkt sich des Weiteren positiv auf die Wahl des gleitenden Mittelwertfilters aus. Abbildung 5-4 zeigt zudem, dass gleitende Fensteroperatoren auch bei der Adaptivität, Effizienz und Primitivität vorteilhaft sind und somit als Lösungskonzept ausgewählt wurden.

	Frequenz- transformation	Gleitende Fensteroperatoren
Informations- genauigkeit		
Adaptivität		
Laufzeiteffizienz		
Primitivität		

Geringe Übereinstimmung
 Hohe Übereinstimmung

Abbildung 5-4: Qualitative Bewertung der Konzepte.

Im Folgenden ist bei der Verwendung der gleitenden Filterung immer eine gaußgewichtete gleitende Filterung gemeint.

5.1.4 Implementierung

Die Parametrisierung zielt auf eine spätere Anwendung ohne zusätzliche Anwenderangaben ab und stellt somit eine komplexe Herausforderung dar. Die Rauschminderung stellt in der adaptiven Parametrisierung dabei die komplexeste Anforderung dar. Eine exakte analytische Lösung zur Minderung des Rauschens im Signal ist im Stand der Technik nicht bekannt. Zur Schätzung und Messung von Rauschintensitäten sind bereits einige analytische und stochastische Ansätze veröffentlicht (Yeh, Kavantzias & Keogh 2017) (Sase & Ramírez et al. 2016). Diese bedingen meist die Bekanntheit des

wahren Signalverlaufs oder beschreiben statistische Analysen mit entsprechender Wahrheitsverzerrung.

Für den beschriebenen Gesamtansatz, der in dieser Dissertation vorgestellten Funktion zur Anomalieerkennung, ist eine hohe Anforderung hinsichtlich der Genauigkeit und des Informationsgehalts gestellt. Aus diesem Grund ist die Anwendung einer Schätzung des Rauschlevels nicht zielführend. Des Weiteren liegen in der Regel keine Sollwerte der zu untersuchenden Prozessgröße vor. Die Größen der drehmomentbildenden Stromstärke oder daraus berechneten Werte wie Drehmomente und Kräfte unterliegen einer hohen Prozess- und Einflussgrößenabhängigkeit und sind somit im Allgemeinen a priori nicht definiert. Aus dieser Analyse ergibt sich, dass lediglich eine anwendbare Konzeptionierung mittels empirischer/analytischer Modellierung unter Einbezug von Domänenwissen sowie a priori Information über die Maschinenbewegung wie beispielsweise minimalem Vorschub anwendbar ist. Neben den externen Rand- und Einflussgrößen, welche in die Gesamtproblematik der Rauschminderung eingehen, bildet die gewählte Fensterlänge zur gleitenden Glättung der Zeitreihe den relevantesten Parameter ab.

Diese qualitativen Anforderungen werden in der Implementierung durch eine a priori Information über die Bearbeitungsgeschwindigkeit in der Produktionsmaschine quantifiziert. Dabei gilt die Annahme, wie schnell eine Maschinenbewegung bei der Bearbeitung des Werkstückes erfolgen kann, als Maßgabe. Die Maschinenbewegung und draus resultierende Zeit der Bearbeitung einer minimalen Werkstückbewegung lässt sich als Produkt der Länge des kleinsten Fertigungsmusters mit maximalem Arbeitsvorschub auf jeweiligem Bearbeitungsmaßstab formulieren. Wird dies mit der Abtastfrequenz multipliziert, resultiert die quantifizierte Länge in Datenpunkten der minimalen Werkstückbewegung. Dies kann mit der Fensterlänge der Filterung gleichgesetzt werden. Die Formel 5-1 zeigt den mathematischen Zusammenhang.

$$L_{Fenster} = L_{Detail,min,DP} = L_{Detail,min} v_{Maßstab,max} f_{Abtast} = L_{Detail,min} c, \quad c = konst \quad 5-1$$

mit

$L_{Detail,min}$ = Länge des kleinsten Musters

$v_{Maßstab,max}$ = Bearbeitungsgeschwindigkeit

f_{Abtast} = Abtastrate

Die Anforderung nach Begrenzung der unbeschränkt großen Fensterlänge, aufgrund der monoton mit der Fensterlänge abnehmenden Informationsgenauigkeit, wird mit festen Grenzwerten als minimale und maximale Fensterlänge definiert. Der Suchraum ist somit fest vorgegeben.

5.1.5 Aufteilung der geglätteten Zeitreihe in Segmente

Nach der Rauschminderung erfolgt die Segmentierung der gesamten Zeitreihe nach Extremwerten. Zur späteren Untersuchung gleicher Prozess- und Maschinenzustände sowie ganzer Bewegungen müssen Start- und Endwerte von Bewegungen definiert und gefunden werden. In vorliegender Dissertation wird eine Trennung der Zeitreihe ausschließlich nach geometrischen Merkmalen realisiert. Eine Auftrennung der Zeitreihe nach Prozess- und Maschinenmerkmalen wie initialer Werkstückeingriff zur Trennung von Haupt- und Nebenzeiten wird nicht untersucht. Die Trennung der Zeitreihe nach geometrischen Merkmalen erfolgt ausschließlich an Minima-Stellen. In der Regel besitzen Bearbeitungsprozesse, ausgehend vom Werkstücknullpunkt, positive Signal-Wertebereiche, weswegen die Aufteilung der Muster an Minima-Stellen vorteilhaft ist. Eine auftretende Phasenverschiebung ist aufgrund des relativen Abgleichs in der späteren Anomalieerkennung nicht kritisch. Wichtig ist, dass ein einheitlicher Segmentierungsansatzes Anwendung findet, sodass Muster wiederkehrend gleich und reproduzierbar als Subsequenz dargestellt werden können.

Zur Findung vom Extremstellen wird in der klassischen, analytischen Mathematik eine Funktion zunächst differenziert. Durch anschließendes Nullsetzen der differenzierten Funktion lassen sich Extremstellen der ursprünglichen Funktion bestimmen. Die berechnete Nullstelle in der ersten differenzierten Form der Funktion beschreibt hingegen lediglich ein hinreichendes Kriterium für eine vorhandene Extremstelle. Die Existenz eines Sattelpunktes resp. die Art der Extremstelle muss im Allgemeinen durch Untersuchung der zweiten zeitlichen Ableitung der Funktion erfolgen. Ausgehend der Annahme einer zur Minimabestimmung hinreichend geglätteten Zeitreihe, kann die Segmentierung mit Trenderkennung als Extremwertaufgabe formuliert werden.

Daraus resultiert die Anforderung an die Überwachung eines Schwellwertes zur minimalen Maschinengeschwindigkeit. Es werden Ein- und Austrittspunkte im a priori definierten Toleranzfeld bestimmt. Es ist stets zu beachten, dass beim Eintrittspunkt, welcher als Minimum definiert werden soll, dessen Ableitung die untere Grenze des Toleranzfeldes durchschreiten muss.

Abbildung 5-5 zeigt eine Zeitreihe (rosa eingefärbt ist der originale Verlauf, schwarz eingefärbt ist die geglättete Zeitreihe) sowie deren Ableitung (unteres Diagramm) davon. Durch das a priori festgelegte Toleranzfeld (roter Bereich im unteren Diagramm), welche der kleinsten Maschinenbewegung entspricht, kann eine genaue Ermittlung der Start- und Endwerte der Zeitreihensegmente erfolgen. Dabei wird beobachtet, wann das Toleranzfeld verlassen wird und somit ein Start- resp. Endwert in die Originalzeitreihe projiziert. Innerhalb des Toleranzfeldes ist von einem Signalrauschen und keiner Maschinenbewegung auszugehen.

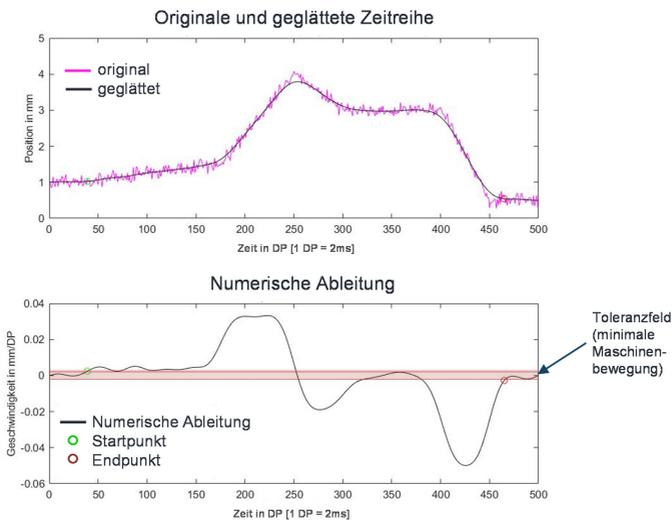


Abbildung 5-5: Originalzeitreihe sowie deren Ableitung mit gefundenen Extremwerten im Toleranzfeld. Darstellung in Anlehnung an (A_Wurche 2020).

5.1.6 Fazit der Rauschminderung

Die Rauschminderung in Zeitreihen ist maßgeblich für den Erfolg der Datensegmentierung verantwortlich, da nur bei geeigneter Verminderung des Rauschens Ähnlichkeiten von Zeitreihenmustern bestimmt werden können. Allerdings findet die Rauschminderung in Form einer gefensternten Mittelwertfilterung in vorliegendem Ansatz nur zum Finden von Extremwerten Anwendung. Die Verarbeitung einer geglätteten Zeitreihe hat ansonsten einen zu großen Informationsverlust zur Folge. Des Weiteren kann mit Hilfe von a priori Wissen über die kleinste Maschinenbewegung ein Toleranzfeld bestimmt

werden. Dadurch lässt sich Signalrauschen von Bewegungen unterscheiden und zuverlässig Muster finden. Eine komplexe Herausforderung stellt die Erkennung langsamer Maschinenbewegungen in Form einer Trenderkennung dar. Dabei ist zu unterscheiden, ob eine langsame Maschinenbewegung oder ein Drift resp. Rauschen vorliegt. Dieses Verhalten hat maßgeblichen Einfluss auf das Segmentieren von Subsequenzen einer Zeitreihe und somit auch auf die Gesamtperformanz der Anomalieerkennung. Die beschriebenen Anforderungen lassen sich auf ein Teilproblem in der differenzierten Form reduzieren.

Die Erfolgsgüte des Vorverarbeitungsansatzes wird erhöht, wenn eine maximale Anzahl an Glättungsiterationen durchgeführt wird. Dann können Extremwerte möglichst genau bestimmt werden und somit ganze Sequenzen reproduzierbar gefunden werden. Abbildung 5-6 zeigt den Unterschied zwischen einer Glättungsiteration (links) und zehn Glättungsiterationen zur Extremwertsuche (rechts) in der originalen bzw. geglätteten Zeitreihe (oberes Diagramm) sowie deren Ableitung. Die Start- und Endwerte sind wie in Abbildung 5-5 durch das Toleranzfeld (roter Bereich) definiert. Die gefundenen Start- und Endwerte werden anschließend auf die originale Zeitreihe (rosa Verlauf) projiziert.

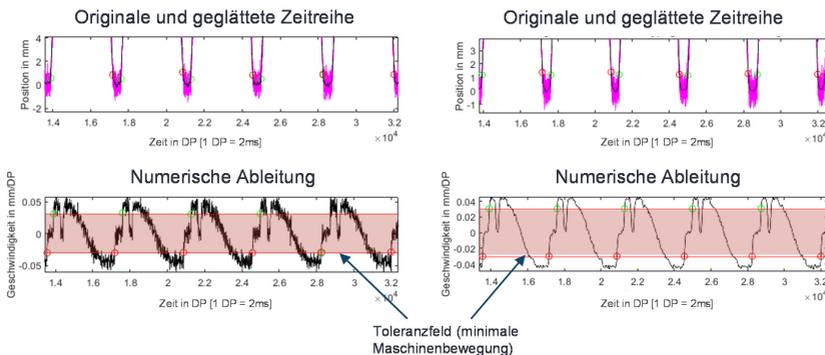


Abbildung 5-6: links: Glättungsiteration = 1; rechts: Glättungsiteration = 10 einer Messreihe einer Fräsmaschine. Darstellung in Anlehnung an (A_Wurche 2020).

Im folgenden Schritt erfolgt die Ähnlichkeitsbestimmung der segmentierten Subsequenzen der Zeitreihe. Eine Subsequenz ist durch zwei aufeinanderfolgende Minima als Start- und Endwert charakterisiert. Die Bestimmung der Ähnlichkeit erfolgt anhand der originalen, ungefilterten Zeitreihe.

5.2 Distanzbestimmung mittels einer Metrik

In vorliegendem Abschnitt, basierend auf Analysen in (Netzer, Michelberger & Fleischer 2020) (A_Michelberger 2019) (A_Baier 2021) (A_Brunnenkant 2020), wird eine Lösungsvariante der Ähnlichkeitsbestimmung diskutiert. Die korrekte Bestimmung der Ähnlichkeit über das Ähnlichkeitskriterium ist maßgeblich für die Güte des Gesamtsystems verantwortlich. Es sei darauf verwiesen, dass bestehende Metriken und Distanzmaße aus dem Stand der Forschung evaluiert und bewertet wurden. Aufgrund des Vergleichs von absoluten Werten zu einer metrischen Skala sind nur Ansätze relevant, welche ein Distanzkriterium zwischen einzelnen Messwerten von jeweils zwei Subsequenzen berechnen. Aus den bereits beschriebenen Charakteristiken von Zeitreihen ergeben sich Anforderungen an die Distanzbestimmung. Die segmentierten Subsequenzen weisen unter anderem keine einheitliche Länge auf. Dennoch sollen entsprechende Sequenzen miteinander verglichen werden. In etablierten Ansätzen zur Distanzbestimmung und Mustererkennung werden im Allgemeinen längenähnliche Sequenzen miteinander verglichen. Aus diesem Grund müssen neue Distanzmaße erarbeitet werden. Prinzipiell kann dieser Anforderung mit drei Ansätzen begegnet werden.

Die erste Möglichkeit beschreibt die Anwendung elastischer Distanzmaße. Elastische Distanzmaße bestimmen den optimalen Pfad über heuristische Ansätze, sodass unter Minimierung der summierten Abstände die Datenpunkte zweier Subsequenzen errechnet werden können. Aufgrund der in Kapitel 1 vorgestellten Problemstellung sowie dem Gesamtansatz ist eine formbasierte Ähnlichkeit als Vergleichskriterium erforderlich. Elastische Distanzmaße verzerren allerdings die Form der Zeitreihen.

Neben elastischen Maßen können Subsequenzen als zweite Möglichkeit auf eine normierte Länge zugeschnitten werden, sodass die Distanz- und Ähnlichkeitsbestimmung auf identischer Sequenzlänge basiert. Für das Anpassen der Sequenzlängen sind verschiedene Ansätze denkbar. Im Allgemeinen wird der längere Verlauf auf die kürzere Sequenz angepasst.

Der erfolgversprechendste Ansatz beschreibt die dritte Möglichkeit, das Ausrichten beider Sequenzen. Ziel ist es, die Stelle im Verlauf zu finden, an der das statische Distanzmaß den geringsten Wert aufweist. Im Anschluss daran wird die längere Sequenz an beiden Seiten auf die Länge der kürzeren Sequenz gekürzt. Auf diesen Ansatz wird im Allgemeinen bei der Synchronisierung von Signalen in der Signaltechnik zurückgegriffen (Müller 2007). Nachteil dieses Ansatzes ist der erhebliche Informationsverlust,

welcher durch das Beschneiden der längeren Sequenz entsteht. Dieser Nachteil kann allerdings vernachlässigt werden, da die im späteren Kapitel 5.3 bei der Bestimmung des optimalen Clusterparameters ein elastisches Distanzmaß Verwendung findet. Die initiale Distanzbestimmung der Subsequenzen im paarweisen Vergleich über ein statisches Distanzmaß hat deutliche Performanzvorteile und ist für eine erste Näherung ausreichend.

Zur gleichwertigen Bestimmung der Ähnlichkeit von zwei kurzen Sequenzen im Vergleich zu zwei langen Sequenzen muss eine Längennormierung eingeführt werden. Andernfalls ist die Aufsummierung von Distanzen bei langen Sequenzen naturgemäß höher als deren Distanzsumme von kürzeren. Abgeleitet aus dieser Problemstellung erfolgt die Entwicklung eines Distanzmaßes relativ zur Sequenzlänge l . Abbildung 5-7 zeigt, dass Anomalien bei kurzen Sequenzen (linkes Diagramm, a)) in der Distanzberechnung mit der Euklidischen Distanz stärker gewichtet werden als rechte Sequenzen (rechtes Diagramm, b)). Dies liegt an der äußeren Wurzel der Distanzformulierung (vgl. Formel 2-4, Kapitel 2.5.3.2). Dadurch entsteht eine Verzerrung relativ zur Musterlänge l . Folglich gilt, dass nur Distanzmaße Anwendung finden, welchen keine nicht-lineare äußere Funktion bei der Bestimmung der Summe der Distanzen haben.

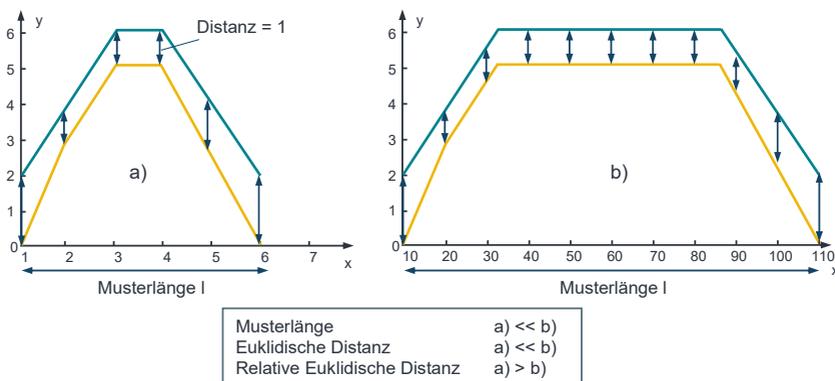


Abbildung 5-7: Beispielhafte Darstellung der Verzerrung einer Distanzberechnung bei der Verwendung der euklidischen Distanz. Links: kleines Muster. Rechts: großes Muster. Darstellung in Anlehnung an (A_Michelberger 2019).

Formel 5-2 zeigt den Zusammenhang zur allgemeinen Berechnung eines unverzerrten Distanzmaßes relativ zur Länge l für eine Potenz p . Mit Hilfe der Potenz p wird die

Gewichtung von stark ausgegrenzten Datenpunkten wie beispielsweise Ausreißer durch Messfehler eingestellt. Es gilt, dass eine höhere Potenz Ausreißer stärker gewichtet. Beschriebene Annahme gilt nur bei Distanzen > 1 . Für Distanz $y_{i,n} - y_{j,n} < 1$ gilt der inverse Effekt, sodass eine höhere Distanz geringer gewichtet wird. Daraus ergibt sich die Forderung nach einem Distanzmaß, welches keine inverse Gewichtung je Distanzwert liefert. Die trivialste Lösung ist die lineare positive Skalentransformation mittels der Addition einer reellen Zahl ≥ 1 . Der Zusammenhang mit Addition der Zahl 1 ist in Formel 5-3 sichtbar.

Allgemeines relatives Distanzmaß 5-2

$$= \frac{\sum_{n=1}^l |(y_{i,n} - y_{j,n})|^p}{l}$$

Allgemeines rel. Distanzmaß mit linearer Transformation 5-3

$$= \frac{\sum_{n=1}^l (|(y_{i,n} - y_{j,n})| + 1)^p}{l}$$

mit

l = Länge der verglichenen Mikromuster

p = beliebige Potenz

$y_{i,n}$ = n - ter Datenpunkt y des i - ten Mikromusters

i = Bezeichnung des Mikromusters

n = nummerierte Bezeichnung des Datenpunkts y

Die beschriebene statische Distanzbestimmung über das relative Distanzmaß bietet einige Vorteile gegenüber etablierten Metriken der Literatur. Dennoch ist zu beachten, dass gesamte Sequenzen, welche durch viele Datenpunkte beschrieben sind, auf lediglich einen skalaren Wert reduziert werden. Diese Reduzierung hat einen Informationsverlust zur Folge, da das charakteristische Verhalten wie Extremwerte oder repräsentative Signalcharakteristika nicht in die triviale Distanzbestimmung eingeht. Des Weiteren können sehr ähnliche Subsequenzen einer Zeitreihe im paarweisen Vergleich einen hohen Distanzwert aufweisen, wenn sich die Randwerte dieser stark voneinander unterscheiden, der restliche Verlauf aber näherungsweise identisch ist. Aus dieser

Problemstellung abgeleitet motiviert sich die Anforderung nach Erweiterung der Ähnlichkeitsbewertung um zusätzliche charakteristische Werte.

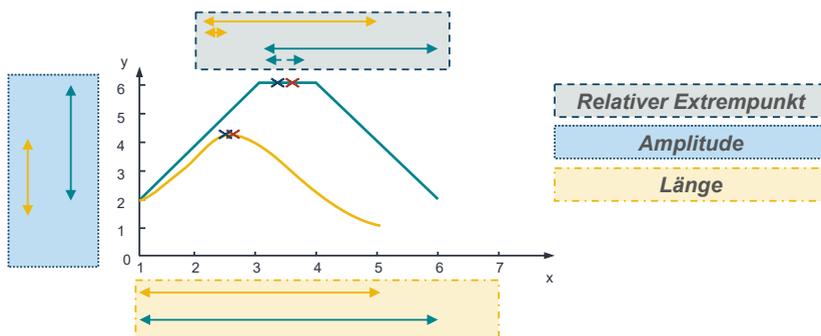


Abbildung 5-8: Darstellung zweier Sequenzen und deren Kennwerte in Anlehnung an (A_Brunnenkant 2020).

Abbildung 5-8 zeigt exemplarisch zwei Subsequenzen in gelb und blau dargestellt sowie deren Kennwerte (Amplitude, Länge und relativer Extrempunkt). Die Amplitude (blau hinterlegt) sowie die Länge (gelb hinterlegt) werden direkt ohne weitere Berechnungsschritte bestimmt.

$$y = t_{max} \qquad \forall t \in T: t_{max} \leq t \qquad 5-4$$

$$length = k \qquad \text{wobei } T := \{t_1 \dots t_k\} \qquad 5-5$$

Aufgrund der Offsetnormalisierung auf $x_0=0$ ist der kleinste Wert in der Zeitreihe gleich null. Die Amplitude y entspricht dem größten Wert in der Sequenz. Durch die konstante Messaufnahme resp. Abtastrate der Zeitreihe ist die Länge $length$ äquivalent zur Anzahl der Datenpunkte der Sequenz. Der relative Extrempunkt (Abbildung 5-8, grau hinterlegt) wird in Relation zur Länge der Subsequenz bestimmt. Dadurch ist eine repräsentative Charakteristik der Sequenz sichergestellt. Die Berechnung des Ähnlichkeitswertes erfolgt nach der Tschebyscheff-Metrik (vgl. Kapitel 2.5.3).

5.2.1 Bewertung

In vorliegender Dissertation werden die beschriebenen Ansätze der Ähnlichkeitsbestimmung anhand der Performanz und damit einhergehende Komplexität der Verfahren bewertet. Der Informationsverlust bei der Verwendung von mehreren Kennwerten ist geringer als bei der trivialen Distanzbestimmung. Allerdings ist die Komplexität der trivialen Distanzbestimmung wesentlich geringer. Da in vorliegenden Anwendungsfällen eine Online-Wiedererkennung der Muster erfolgt, ist die Komplexität und somit auch Performanz eine wichtige Anforderung. Abbildung 5-9 zeigt die relative Performanzbewertung beider Ansätze. Es ist erkennbar, dass die relative Distanzbestimmung (gelber Verlauf) einen deutlichen Performanzvorteil bei steigender Anzahl von Subsequenzen bietet. Aufgrund der in der Praxis vorliegenden hohen Anzahl an Prozessvariationen, beispielsweise bei hochflexiblen Produktionsmaschinen wie Bearbeitungszentren, wird zugunsten des relativen Distanzmaßes bewertet. Der auftretende Informationsverlust ist in keinem Fall zu vernachlässigen, wird aber durch die Anwendung eines elastischen Distanzmaßes beim Clustering relativiert. Die initiale Ähnlichkeitsbestimmung in der Datensegmentierung erfolgt aus diesem Grund auf Basis des trivialen Distanzmaßes.

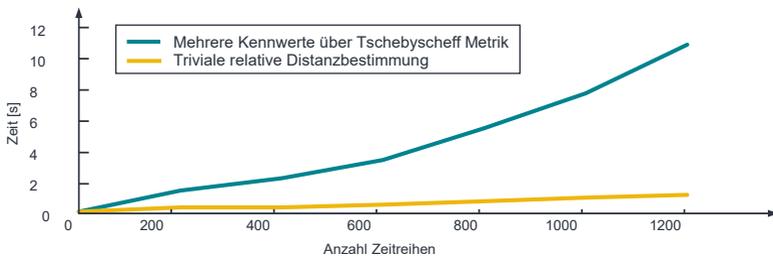


Abbildung 5-9: relative Zeitmessung beider Ansätze der Ähnlichkeitsbestimmung.

Reale Zeitreihenmessungen zeichnen sich ebenfalls durch eine hohe Varianz aufgrund der hohen Flexibilität der Maschinen aus. So können beispielsweise gleiche Bewegungen an unterschiedlichen Orten in der Maschine vorkommen. In der Signalverarbeitung ist die Bestimmung gleicher Segmente an verschiedenen Niveaus im Signal keine triviale Aufgabe. Oft wird von einem Signaloffset gesprochen. Ziel der Normierung, der sogenannten translatorischen Invarianz, ist die Generierung und Zusammenführung gleicher Segmente zu einer Datenbasis.

Aus dieser Herausforderung lässt sich ableiten, dass bei der Erkennung von Störungen in Produktionsmaschinen, welche nicht auf einen örtlichen Fehler einer Komponente wie beispielsweise einem Pitting auf einer Kugelgewindtriebsspindel (Schlagenhauf, Brander & Fleischer 2021) zurückführbar sind, eine Normierung des Signals essentiell ist.

Die Untersuchung des Standes von Forschung und Technik zeigt, dass die rotations- und translationsinvariante Erkennung von Objekten speziell im Bereich der Bildererkennung Einsatz findet. Die Ansätze werden verwendet, um für ein Roboterarm Objekte greifbar zu machen oder zur Objekterkennung in Fahrzeugen im Straßenverkehr.

Folgende Konzepte sind unter (A_Mehmedovic 2020) evaluiert und nachfolgend zusammengefasst dargestellt.

- Fourier-Transformation
- Zernike- und pseudo zernike Momente
- Wavelet-Transformation

Die Invarianzbestimmung in vorliegender Dissertation ist über die Fourier-Transformation gelöst. Dieser Ansatz erzielt die höchste Genauigkeit bei geringster Komplexität.

5.2.2 Fazit der Distanzbestimmung und Normierung

Das vorliegende Kapitel zeigt verschiedene Ansätze der Ähnlichkeitsbestimmung sowie der Normierung einer Zeitreihe. Für die praxisrelevante Anwendung der Methodik ist die Performanz ein entscheidendes Kriterium. Aus diesem Grunde ist bei geringem Informationsverlust die relative Distanzbestimmung zielführend. Hier wurde ein neuartiges, linear transformiertes, statisches Distanzmaß zum Subsequenzvergleich und dem daraus folgenden Ähnlichkeitsmaß entwickelt. Des Weiteren erfolgte eine Normierung der Zeitreihen in Hinblick auf Translation. Die Bestimmung der Invarianz-Eigenschaften beruht auf der Fourier-Transformation.

Als Ergebnis ist eine symmetrische Matrix mit allen Distanzwerten aus dem paarweisen Vergleich aller Sequenzen entstanden.

5.3 Dichtebasiertes Clusterverfahren

Grundlage für das Clusterverfahren der Mustererkennung ist die beschriebene Distanzmatrix. Das Clusterverfahren zielt auf eine schnelle und effiziente Mittelwertsuche sowie zugehörigen Sequenzen ab und kann ähnliche Subsequenzen bestimmen. Die zu

berechnenden Muster liegen in der Regel zweidimensional vor. Sie können als Visualisierung auch in Form eines trivialen Punktdiagramms dargestellt werden. Mittels eines paarweisen Vergleichs der m Subsequenzen miteinander wird ein m -dimensionaler Raum definiert. Dort sind die jeweiligen Distanzen sowie die Anzahl der Muster enthalten.

Die Auswahl eines geeigneten Verfahrens stellt eine Herausforderung dar und richtet sich nach drei Kriterien, welche aus der Problemstellung abgeleitet wurden.

- Die Anzahl der Muster und somit Bewegungen in einer Maschine ist nicht a priori bekannt.
Dies hat zur Folge, dass die Clusteranzahl unbekannt ist. Dieser Eingabeparameter ist demnach nicht vorhanden. Verfahren, welche die Anzahl an Cluster a priori benötigen sind nicht anwendbar.
- Die Form der zu erwartenden Muster ist nicht bekannt.
Auch diese Anforderung benötigen einige Clusteransätze. Wenn diese Anforderung nicht erfüllt ist, erhöht sich der Informationsverlust deutlich. Dies widerspricht den Zielkriterien der Mustererkennung.
- Laufzeit und Effizienz des Clustering sind auf hohem Niveau und entsprechen den Anforderungen.
Dichtebasierte Clusterverfahren (DBSCAN oder Mean-Shift Clustering) erfüllen diese Anforderung.

5.3.1 Bewertung zur Wahl des Clusteransatzes

Im Allgemeinen unterscheiden sich die Ansätze Mean Shift und DBSCAN in ihrer Performance und Effizienz kaum, da sie auf ähnlichen Berechnungsschritten beruhen und beides Konvergenzverfahren sind. Beide Ansätze erfüllen die beschriebenen Kriterien zur Anwendung als Mustererkennung in Produktionsmaschinen. Ein wesentliches Bewertungskriterium bei der Auswahl ist die Implementierbarkeit und Einfachheit in entsprechender Programmierumgebung. Bei der prototypischen Implementierung in Kapitel 9 wird die Programmierumgebung *MATLAB*¹ (Pietruszka & Glöckler 2021) verwendet. Der Mean-Shift Ansatz ist dort einfach zu applizieren und auf die Randbedingungen der Produktion wie Rauschen oder Laufzeitanforderung anpassbar. Aus diesem Grund wird der Mean-Shift Ansatz ausgewählt. Der Gesamterfolg der Mustererkennung wird

¹ The MathWorks Inc. (2022), MATLAB R2021a

im Wesentlichen nicht durch die Wahl des Clusteransatzes bestimmt, sondern durch die Vorverarbeitung sowie die Wahl der Eingabeparameter.

5.3.2 Wahl und Optimierung des Such-Parameters

Schon vor der Veröffentlichung des Mean-Shift-Clustering durch (Fukunaga & Hostetler 1975) war die Bestimmung des Suchweitenparameters *Bandweite* (engl.: bandwidth) ein viel diskutiertes Thema in der Statistik. Dadurch sind für die sogenannte „kernel density estimation“ (A_Baier 2021) einige Verfahren und Methoden über die Jahre entstanden. Ziel war es, diesen zentralen Parameter allgemeingültig wählen zu können. Der Parameter „bandwidth“ des Mean-Shift Clusterverfahrens wird auch als Hyperparameter bezeichnet. Die Problemstellung ist in Abbildung 5-10 sichtbar. Es zeigt sich, dass der Erfolg des Clusterverfahrens, unabhängig von der Wahl des dichtebasierten Clusteransatzes, maßgeblich durch die Eingabewerte resp. Hyperparameter bestimmt wird. Abbildung 5-10 zeigt ebenso, dass bei hohem Rauschverhalten (rechte Seite) und gleicher Wahl des Suchradius bandwidth die Güte des Clustering sinkt.

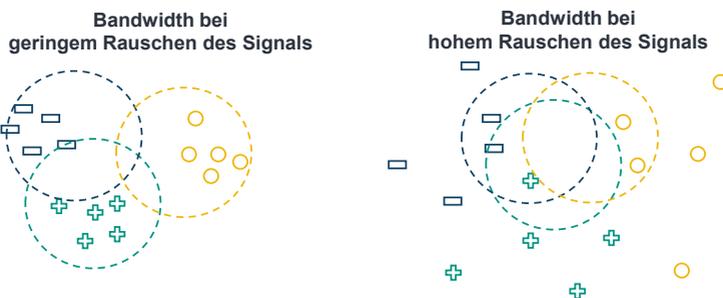


Abbildung 5-10: Einfluss des Signalrauschens auf das Mean-Shift-Clustering und die Wahl der Bandwidth.

Das Rauschverhalten einer Produktionsmaschine sowie die Diversität der Prozesse beeinflussen hauptsächlich die lokale Dichteverteilung aller Distanzen von Bearbeitungsmustern einer Produktionsmaschine. Eine minimale Verteilung tritt nur bei konstanten prozesscharakterisierenden Zuständen auf, ist allerdings vernachlässigbar. Ausgehend von dieser Herleitung kann die Problembeschreibung auf die Bestimmung der Bandwidth reduziert werden.

Mit Hilfe einer initialen Inbetriebnahmefahrt kann das Rauschverhalten der Produktionsmaschine quantitativ bestimmt werden. Die Inbetriebnahmefahrt charakterisiert sich

durch repräsentativ wechselnde Prozesszustände. Die Diversifizierung des Merkmalsraumes erlaubt überdies auch den Einsatz eines globalen Bandwidth-Parameters bei hoher Güte des Clusterings. Abbildung 5-11 zeigt das systematische Vorgehen zur Wahl des korrekten Bandwidth-Parameters. Das Ablaufdiagramm zeigt, dass die Annäherung an den globalen Bandwidth-Parameter iterativ erfolgt. Ausgehen von einem Startwert erfolgt die Überprüfung der gefunden Cluster in einer Inbetriebnahmefahrt. Mit Hilfe eines Bewertungsmaßes wird die Güte überprüft und der Startwert der Bandwidth angepasst. Nach dem die optimale Clustereinstellung gefunden wurde, ist der Inbetriebnahmeprozess abgeschlossen. Die Suche nach einem globalen Optimum der Bandwidth kann auch nach einer Maschinenwartung erneut gestartet werden, um individuelle oder veränderte Ausprägungen der Maschine abzudecken.

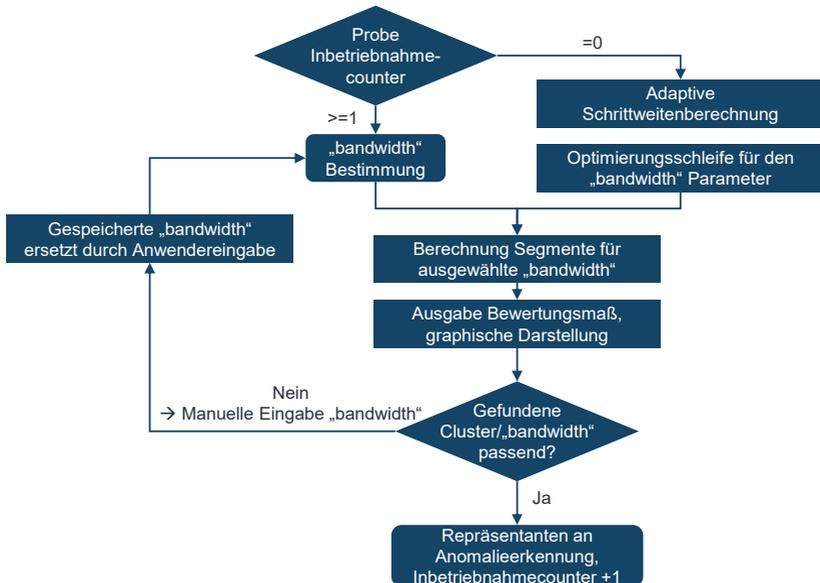


Abbildung 5-11: Ablaufdiagramm zur Bestimmung des „bandwidth“ Parameters des Clusterverfahrens.

5.3.3 Fazit der erweiterten Bandwidth Berechnung

Zusammenfassend lässt sich schlussfolgern, dass der Erfolg sowie die Genauigkeit einer dichte-basierten Mustererkennung ausschließlich auf die korrekte Wahl der Para-

meter, in vorliegendem Fall des „bandwidth“-Parameters, zurückzuführen sind. In dieser Dissertation wurde auf Basis einer Analyse in (A_Baier 2021) ein neues Verfahren entwickelt, um den optimalen „bandwidth“-Parameter quantitativ bestimmbar zu machen. Dabei sind der Anwendungsfall sowie die Randbedingungen wie Rauschen oder Abtastrate maßgeblich. In vorliegender Arbeit wurden zudem Kenngrößen entwickelt, welche dem Anwender transparent die Entscheidungsfindung der Funktionsbausteine offenlegen. Gerade in der Produktionstechnik ist eine Nachvollziehbarkeit von modernen intelligenten Verfahren essentiell. Der Einfluss des jeweiligen Clusteralgorithmus ist für die Genauigkeit weitestgehend irrelevant, hat allerdings einen Einfluss auf die Laufzeit.

Nachdem die optimale Einstellung für das Clusterverfahren bestimmt ist, erfolgt die Bildung des Repräsentanten aus den gefunden Clustern. Dieser Repräsentant beschreibt den i.O.-Zustand der Bewegungssequenz der Maschine und wird als Abgleich in der späteren Anomalieerkennung verwendet.

5.4 Berechnung eines repräsentativen multidimensionalen Musters

Nachdem das Clusterverfahren durchgeführt wurde, muss im Folgenden ein Repräsentant aus jedem Cluster berechnet werden. Dieser Repräsentant wird anschließend als Soll-Prozessvorgabe an die Anomalieerkennung weitergegeben. Es wird in jedem Fall davon ausgegangen, dass im berechneten Cluster nur i.O.-Sequenzen vorliegen und keine Anomalie angelernt wird. Dies muss unter anderem durch den Anwender sichergestellt sein. Bevor der jeweilige Repräsentant berechnet wird, ist der Begriff „repräsentativ“ im ersten Schritt genauer zu betrachten. Daraus wird anschließend ein Berechnungsverfahren im Zusammenhang einer Mustererkennung in Produktionsmaschinen entwickelt. Die Bestimmung des Repräsentanten hat einen maßgeblichen Einfluss auf den Gesamterfolg der Mustererkennung und der Anomalieerkennung. Der Repräsentant muss möglichst ähnlich zu allen in einem Cluster vorkommenden Einzelsequenzen sein. Entscheidend hierfür sind im Wesentlichen die durchschnittliche absolute Position sowie die durchschnittliche Länge. Es ist allerdings anzumerken, dass ein trivialer Ansatz über das arithmetische Mittel aller Subsequenzen eines Clusters zu einer verzerrten und nicht repräsentativen Form führt. Abbildung 5-12 zeigt in Gelb, Blau und Rot, die im Cluster enthaltenen Zeitreihensequenzen und in Grün die Verzer-

rung bei der Bestimmung des Repräsentanten über das arithmetische Mittel. Die Verzerrung ist im Wesentlichen auf die extremen Randbereiche und deren starken Variationen zurückzuführen. In Produktionsmaschinen ist in jedem Fall davon auszugehen, dass Einzelsequenzen unterschiedliche Längen aufweisen. Dies ist auf physikalisch bedingte Effekte bei der Messaufnahme sowie auf die einhergehende Messabweichung zurückzuführen. Die Berechnung über ein arithmetisches Mittel ist lediglich mit weiteren Anpassungen anwendbar. Die Berechnung der Repräsentanten wurde in den angeleiteten Arbeiten (A_Michelberger 2019) (A_Kopp 2019) evaluiert. Die Ergebnisse sind in vorliegender Dissertation dargestellt.

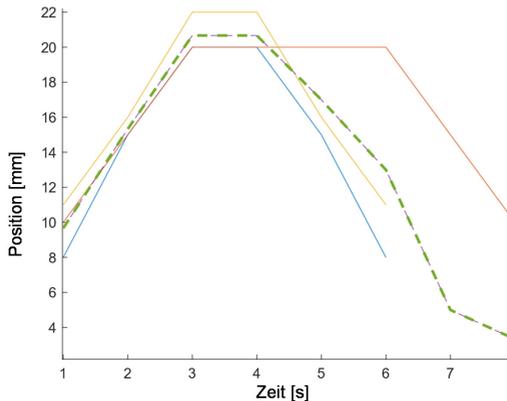


Abbildung 5-12: Bestimmung des durchschnittlichen Musters mit Hilfe der Berechnung des arithmetischen Mittels. Gelb, Blau, Rot: Im Cluster beinhaltete Sequenzen. Grün gestrichelt: Verzerrung des Repräsentanten. Darstellung nach (A_Michelberger 2019) (A_Kopp 2019).

Aus der beschriebenen Problemstellung lässt sich ein Lösungsansatz ableiten. Die Sequenzen eines Clusters bedingen ein vorheriges Ausrichten zueinander, bevor das arithmetische Mittel berechnet werden kann. Allerdings ist ein einfaches Ausrichten bezogen auf den Mittelpunkt aller Sequenzen eines Clusters nicht ausreichend, da keine Symmetrie einzelner Sequenzen vorausgesetzt werden kann und es dann zu einer einseitigen Verzerrung kommen kann. Bei der vorliegenden Herausforderung ist ein Minimierungsproblem zu erkennen, welches beschreibt, dass die Summe der paarweisen Distanzen minimiert werden muss. Dabei werden einzelne Sequenzen iterativ gegen-

einander verschoben, bis ein globales Minimum der aufsummierten Distanzen gefunden wird. Im Anschluss erfolgt die Prüfung, ob die Einstellung bei allen paarweisen Sequenzvergleichen zum Optimum führt. Es ergibt sich daraus folgende mathematische Beschreibung in Formel 5-6:

$$\min \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^l (y_{i,k} - y_{j,k}) \quad 5-6$$

mit

$y_{i,k}$ = Datenpunkt y_k der Sequenz i

m = Anzahl Sequenzen

l = Länge der Subsequenz

Start- und Endwerte der Sequenzen werden ebenfalls über das arithmetische Mittel bestimmt. Aufgrund der Verzerrungsproblematik in Randbereichen sowie bei unterschiedlichen Längen wird im Gegensatz zu den Positionsverläufen die abgeleitete Form arithmetisch gemittelt. Formeln 5-7 - 5-9 zeigen den Zusammenhang.

$$\text{Arithmetisches Mittel der Startpunkte} = \frac{\sum_{i=1}^m y_{i,1}}{m} \quad 5-7$$

$$\text{Arithmetisches Mittel der Endpunkte} = \frac{\sum_{i=1}^m y_{i,end}}{m} \quad 5-8$$

$$\text{Arithmetisches Mittel der Steigung} = \frac{\sum_{i=j}^m \hat{y}_{j,k}}{m} \quad 5-9$$

mit

$y_{i,k}$ = Datenpunkt y_k der Sequenz i

$\hat{y}_{i,k}$ = Datenpunkt \hat{y}_k der Steigung j

m = Anzahl Sequenzen

m_k = Anzahl Sequenzen auf Höhe des k – ten Datenpunktes

k = Nummerierung der Datenpunkte

l = Länge der Subsequenz

Die bestimmten mittleren Steigungen werden im Anschluss durch ein iteratives Verfahren (Formel 5-10) auf die vorherigen Werte addiert.

$$y_{\text{Durchschnittssequenz},k} = y_{\text{Durchschnittssequenz},k-1} + \text{arith. Mittel der Steigung}_k \quad 5-10$$

mit

$y_{\text{Durchschnittssequenz},k}$ = Datenpunkt y_k der Durchschnittssequenz

k = Nummerierung der Datenpunkte

Der schlussendliche Repräsentant je Cluster wird somit rekursiv gebildet. Abbildung 5-13 zeigt im linken Diagramm die ausgerichteten Sequenzen eines Clusters sowie im rechten Diagramm grafisch den Repräsentanten in Grün. Der Repräsentant weist keine Verzerrung auf und repräsentiert alle Sequenzen des Clusters hinreichend genau.

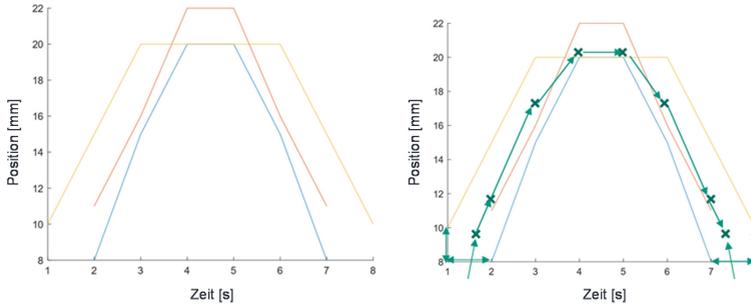


Abbildung 5-13: Links: Durch das globale Minimierungsproblem ausgerichtete Sequenzen. Rechts: Berechneter Repräsentant in Grün. Darstellung nach (A_Michelberger 2019)

Mit Hilfe des im vorliegenden Abschnitt beschriebenen Berechnungsansatzes ist es möglich, einen repräsentativen Verlauf aller Sequenzen in einem berechneten Cluster zu bestimmen. Anschließend werden die Repräsentanten an die Online-Mustererkennung übergeben. Dort erfolgt das Wiederfinden der Repräsentanten im Online-Signal, um das aktuelle Bearbeitungsszenario zu identifizieren.

5.5 Fazit der Offline-Datensegmentierung

Für den Gesamterfolg des Ansatzes zur Anomalieerkennung auf Basis wiederkehrender Segmente ist die initiale Erkennung von Repräsentanten in Offline-Zeitreihen maßgeblich. Dabei ist ersichtlich, dass die Bestimmung des optimalen Parameters bandwidth sowie die optimale Bildung der Repräsentanten der Sequenzen eines Clusters entscheidende Berechnungsschritte sind. Nachdem die Mustererkennung in Offline-Zeitreihen erfolgt ist, liegen segmentierte Zeitreihen-Repräsentanten vor, welche im nächsten Schritt in Online-Zeitreihen wiedergefunden werden, sodass eine Bearbeitungserkennung mit anschließender Anomalieerkennung realisiert werden kann. Im folgenden Kapitel werden Ansätze zum Wiederfinden der Repräsentanten in Online-Signalen diskutiert.

5.6 Wiederfinden von Mustern in Online-Signalen

Da sich verschiedene Prozessschritte in einer Produktionsmaschine stark voneinander unterscheiden können, ist das Erkennen von Anomalien keinesfalls trivial. Aufgrund der Abhängigkeit vom aktuellen Bearbeitungsschritt versagen simple schwellwert-basierte sowie prozessunabhängige Ansätze einer Anomalieerkennung. Signalverläufe sind prozessspezifisch und lassen sich demnach lediglich in gegenseitigem Zusammenhang analysieren. Besondere Herausforderung besteht darin zu unterscheiden, ob eine Signalabweichung bei einer maschinenspezifischen Tätigkeit zulässig ist, während die Signalabweichung in anderen Prozessen anomal ist. Deshalb ist das Wiedererkennen von Repräsentanten bzw. den sogenannten Bearbeitungssegmenten ein weiterer essentieller Schritt dieser Arbeit.

5.6.1 Referenz- und Informationssignale

Nach dem in historischen Daten bereits initiale Repräsentanten berechnet wurden erfolgt im nächsten Schritt (vgl. Ablaufdiagramm in Abbildung 5-1) das Online-Wiedererkennen der Muster. Je nach Prozessschritt des gesamten Verfahrens werden unterschiedliche Informationen in Form von Signalen der Produktionsmaschine benötigt. Diese Arbeit unterteilt sie in Referenz- und Informationssignale. Hierbei kann ein Signal entweder als Referenz- oder Informationssignal klassifiziert, jedoch niemals beiden Gruppen zugeordnet werden. In den nachfolgenden Kapiteln werden die unterschiedlichen Arten der Signale erläutert und eine Definition eingeführt.

5.6.1.1 Referenzsignale

Definition (Referenzsignal)

Referenzsignale sind vom Anwender festgelegte Signale, welche die prozessspezifischen Informationen enthalten, einen Bearbeitungsprozess hinlänglich genau beschreiben und definitionsgemäß keine Anomalien aufweisen.

Beispiel: In Produktionsmaschinen werden in der Regel Positionsverläufe der Achsen (X, Y, Z) zur eindeutigen Identifikation der Bearbeitungsprozesse (Repräsentanten) verwendet und sind somit Referenzsignale.

Bearbeitungssegmente sind stellvertretende charakteristische Referenzbewegungen einer Produktionsmaschine. Diese werden auch Repräsentanten genannt und durch den Verlauf ihrer n Referenzsignale eindeutig definiert. Referenzsignale repräsentieren

die Soll-Bewegungen der Achsen, welche über die Steuerung auslesbar sind und werden zusätzlich für das Wiederfinden im Online-Signal verwendet. In den Anwendungsfällen handelt es sich bei Referenzsignalen um die x -, y - und z -Positionssignale der Achsen bzw. des Tool-Center-Points einer Produktionsmaschine. Da Referenzsignale lediglich im ersten Teil des Ansatzes für den Vergleich der Repräsentanten mit den Onlinedaten relevant sind, besitzen sie per Definition keine Anomalien und haben demnach keine Bedeutung für den zweiten Teil des Ansatzes der Anomalieerkennung.

5.6.1.2 Informationssignale

Definition (Informationssignal)

Informationssignale sind vom Anwender festgelegte Signale, welche den Prozess- oder Maschinenzustand beschreiben. Die Signalausprägungen können normal oder anormal sein.

Beispiel: In Produktionsmaschinen werden in der Regel Motorströme oder Drehmomente der Antriebe zur Anomalieerkennung verwendet, da sie die Prozesskraft am besten widerspiegeln.

Im Gegensatz zu Referenzsignalen kommen Informationssignale lediglich in der Anomalieerkennung zum Einsatz. Jedem Repräsentant, welcher durch n Referenzsignalen definiert ist, kann zusätzlich eine beliebige Anzahl m Informationssignalen zugeordnet werden, siehe Abbildung 5-14. Informationssignale sind weder stellvertretend noch charakteristisch für einen Repräsentanten, sondern ergänzen diesen um weitere Signalverläufe, die während eines charakteristischen Bearbeitungssegmentes auftreten. Demzufolge kann aufgrund eines Informationssignalverlaufs kein Rückschluss auf den Repräsentanten gezogen werden. Sie können jedoch vom erwarteten i.O.-Verlauf abweichen und somit zum Erkennen von Anomalien verwendet werden.

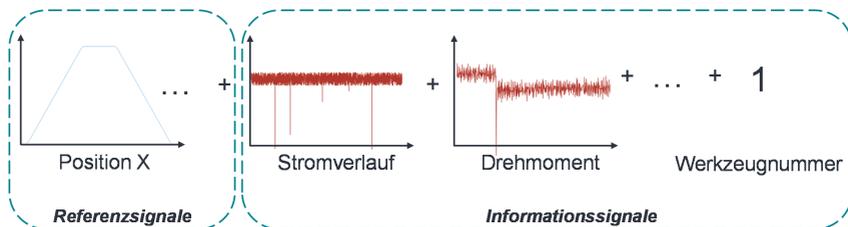


Abbildung 5-14: Bearbeitungsprozess bestehend aus Referenz- und Informationssignalen.

Die Abbildung 5-14 zeigt einen gesamten Bearbeitungsprozess, bestehend aus dem Referenzsignal der Achse X (blauer Verlauf, links) und den zugehörigen Informationssignalen Motorstrom und Drehmoment (roter Verlauf, rechts). Die Werkzeugnummer (Zustandsvariable) ist für die eindeutige Beschreibung des Bearbeitungsprozesses ebenso relevant.

Nach dem Vergleich der Referenzsignale der Repräsentanten und der Onlinedaten und dem damit verbundenen Wiedererkennen eines Repräsentanten, werden die Informationssignale des erkannten Bearbeitungssegments mit denen der Onlinedaten verglichen, um Anomalien zu erkennen. Häufige Anwendungsbeispiele für solche Signale sind vor allem Drehmomente und Motorströme der Achsen oder Spindeln einer Produktionsmaschine. Um Anomalien frühzeitig erkennen zu können, bedarf es während der gesamten Produktionsdauer aktuelle Daten. Diese werden kontinuierlich in die Mustererkennung übergeben und als Onlinedaten bezeichnet. Durch das Einführen eines Datenpuffers kann die Problemstellung stark vereinfacht werden, indem nicht stetig neue Datenpunkte eingelesen werden und damit in der Analyse berücksichtigt werden müssen. Eine dynamische Vorgehensweise birgt einige Herausforderungen und steigert die Komplexität immens. So müsste das Verfahren beispielsweise nach Analysebeginn stets neue Datenpunkte berücksichtigen, welche gerade übergeben wurden, was wiederum die Laufzeit deutlich steigert. Mit Hilfe des Datenpuffers, der vor Analysebeginn aktualisiert wird und während der Laufzeit unverändert bleibt, können die Onlinedaten segmentiert und im Anschluss verarbeitet werden, ohne dass sich der Pufferinhalt während der Analyse verändert. Ist die Bearbeitung eines Segments der Onlinedaten abgeschlossen, wird der Pufferinhalt aktualisiert und das Verfahren beginnt erneut mit der Analyse.

Ebenso wie ein Bearbeitungssegment setzt sich der Inhalt des Puffers aus n Referenz- und m Informationssignalen zusammen. Die folgende Matrix repräsentiert den Puffer in Iteration i von Zeitpunkt t bis $(t + k)$. Dabei befinden sich in den Zeilen 1 bis n die Zeitreihen der Referenzsignale und in den Zeilen $(n + 1)$ bis $(n + m)$ die Zeitreihen der Informationssignale. Der Pufferinhalt beschreibt demnach einen Ausschnitt der Onlinedaten vom Zeitpunkt t bis $(t + k)$. Die nachfolgende Abbildung 5-15 veranschaulicht den Ausschnitt der Onlinedaten, welcher im Puffer enthalten ist. Die nachfolgende Formel 5-11 zeigt den Inhalt des Puffers in Iteration i .

$$P_i = \begin{pmatrix} p_{t,1} & p_{t+1,1} & \dots & p_{t+k,1} \\ p_{t,2} & p_{t+1,2} & & p_{t+k,2} \\ \vdots & \vdots & & \vdots \\ p_{t,n} & p_{t+1,n} & & p_{t+k,n} \\ p_{t,n+1} & p_{t+1,n+1} & & p_{t+k,n+1} \\ \vdots & \vdots & & \vdots \\ p_{t,n+m} & p_{t+1,n+m} & \dots & p_{t+k,n+m} \end{pmatrix} \quad 5-11$$

In Abbildung 5-15 sind exemplarische Referenz- und Informationssignale im Zeitabschnitt t bis $(t + k)$ dargestellt. Referenzsignale (linkes Diagramm) können beispielsweise die Positionssignale aus den Achsen X (blau) und Y (gelb) sein. Durch diese Bewegung der Achsen ist der Prozess geometrisch hinlänglich bestimmt. Im Informationssignal (rechtes Diagramm) sind beispielsweise Motorstrom der Spindel (blau) sowie Drehmoment (gelb) dargestellt. Auf Basis der Referenzsignale erfolgt die Online-Wiedererkennung. Die Informationssignale werden im Anschluss in der Anomalieerkennung analysiert.

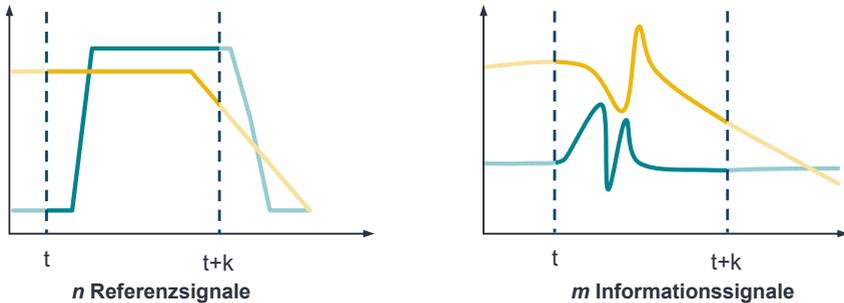


Abbildung 5-15: Beispielhafter Inhalt eines Puffers.

5.6.2 Aktualisieren des Puffers

Pro Iteration wird eine Anzahl von Datenpunkten, definiert durch den Parameter *Data-Delta* (δ_D), in den FIFO²-Puffer geschrieben. Der Inhalt dieses Puffers wird in den nachfolgenden Schritten der Online-Mustererkennung und Anomalieerkennung verwendet. Nach Beenden der Anomalieerkennung beginnt eine neue Iteration und dem Puffer

² FIFO steht für First-In-First-Out.

werden erneut *DataDelta* Datenpunkte hinzugefügt. Formel 5-12 beschreibt den Inhalt des Puffers in Iteration $i+1$ nach dem Hinzufügen von *DataDelta* neuen Datenpunkten

$$P_{i+1} = \begin{pmatrix} p_{t,1} & p_{t+1,1} & \dots & p_{t+k,1} & p_{t+k+1,1} & \dots & p_{t+k+\delta_D,1} \\ p_{t,2} & p_{t+1,2} & & p_{t+k,2} & p_{t+k+1,2} & & p_{t+k+\delta_D,2} \\ \vdots & \vdots & & \vdots & \vdots & & \vdots \\ p_{t,n} & p_{t+1,n} & & p_{t+k,n} & p_{t+k+1,n} & & p_{t+k+\delta_D,n} \\ p_{t,n+1} & p_{t+1,n+1} & & p_{t+k,n+1} & p_{t+k+1,n+1} & & p_{t+k+\delta_D,n+1} \\ \vdots & \vdots & & \vdots & \vdots & & \vdots \\ p_{t,n+m} & p_{t+1,n+m} & \dots & p_{t+k,n+m} & p_{t+k+1,n+m} & \dots & p_{t+k+\delta_D,n+m} \end{pmatrix} \quad 5-12$$

Um den Inhalt des Puffers zu verringern, wird eine obere Schranke mit dem Parameter *DataBufferSize* verwendet. Wird diese Anzahl durch das Hinzufügen neuer Beobachtungen überschritten, löscht die Komponente die ältesten Beobachtungen. Infolgedessen beinhaltet der Puffer zumeist *DataBufferSize* Datenpunkte und die Laufzeit der Analyse des Pufferinhalts wird limitiert. Lediglich in den ersten Iterationen der Online-Mustererkennung, während der Puffer zunächst noch leer ist, ist der Pufferinhalt geringer als *DataBufferSize*. Abbildung 5-16 zeigt das Hinzufügen von *DataDelta* neuen Datenpunkten in einer Iteration. Im linken Diagramm ist der Pufferinhalt vom Zeitbereich t bis $t+k$ dargestellt. Im rechten Diagramm ist der Pufferinhalt vom Zeitbereich t bis $t+k+\delta_D$ dargestellt. Der rot-markierte Bereich zeigt das Hinzufügen der neuen Datenpunkte in der Iteration $i+1$.

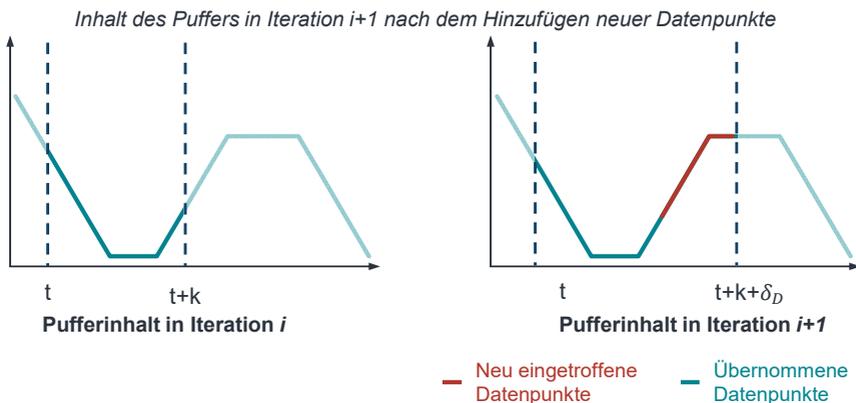


Abbildung 5-16: Iteratives Hinzufügen von *DataDelta* Datenpunkten.

5.6.3 Parameterwahl

Die Wahl der oberen Schranke *DataBufferSize* beeinflusst sowohl die Genauigkeit der Mustererkennung als auch die Laufzeit, welche linear mit der Größe des Puffers wächst. In Abbildung 5-17 ist dieser Konflikt dargestellt. Im linken Diagramm ist ein zu schmaler Puffer abgebildet. Ist der Inhalt des Puffers gering, repräsentiert er lediglich einen kurzen Ausschnitt der Onlinedaten. Da sich die in der Mustererkennung identifizierten Repräsentanten ähneln können führt ein zu kleiner Puffer zu nicht unterscheidbaren Repräsentanten und folglich zu einer geringen Genauigkeit der Mustererkennung. Darüber hinaus steigert ein kleiner Puffer die Wahrscheinlichkeit, dass sowohl Start- als auch Endzeitpunkt des gesuchten Bearbeitungssegments nicht im Puffer enthalten sind, was zu erheblichen Genauigkeitseinbußen führen kann. Im rechten Diagramm der Abbildung 5-17 ist ein zu großer Puffer dargestellt. Dies führt im Vergleich zum schmalen Puffer zu einer Zunahme der Laufzeit der Mustererkennung. Zudem ist zu nennen, dass die Genauigkeit mit der Erhöhung der Puffergröße bis zu einem Punkt zunimmt, an dem das längste Bearbeitungssegment vollständig vom Puffer überdeckt werden kann. Ein weiteres Vergrößern des Puffers, wie im rechten Diagramm dargestellt, steigert die Genauigkeit allerdings nicht weiter, sondern führt lediglich zu Laufzeiteinbußen. Im mittleren Diagramm der Abbildung 5-17 ist eine optimale Puffergröße dargestellt. Dabei muss mindestens das längste Bearbeitungssegment durch den Puffer abgedeckt werden können. Die Länge dieses Bearbeitungssegments ist ein angemessener Startwert für die Wahl von *DataBufferSize*. Das entwickelte Verfahren zur Wahl der Puffergröße sieht also vor, dass die Puffergröße mindestens der Länge des größten Bearbeitungssegmentes aus der Offline-Datensegmentierung entspricht.

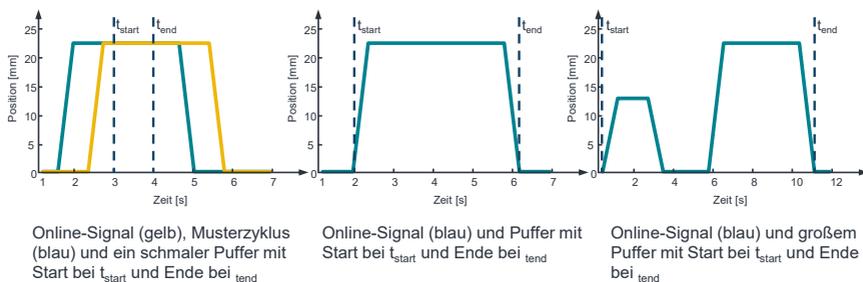


Abbildung 5-17: Veranschaulichung der Wahl von *DataBufferSize*. Darstellung in Anlehnung an (A_Martin 2020).

Der Parameter *DataDelta* hat ebenfalls Auswirkungen auf die Laufzeit und Genauigkeit der Mustererkennung. Kleine Werte für *DataDelta* reduzieren die Zeit zwischen dem Auftreten und Erkennen einer Anomalie, da dem Puffer pro Iteration weniger Datenpunkte in einer höheren Frequenz hinzugefügt werden. Allerdings wächst bei kleinen Werten der Anteil der fixen Laufzeit an der Gesamtlaufzeit, was je nach Anwendung und Abtastrate der Onlinedaten zu Laufzeitproblemen führen kann. Im Gegensatz dazu resultieren große Werte für *DataDelta* in einer Effizienzsteigerung, da fixe Programmteile weniger oft ausgeführt werden. Jedoch werden dann möglicherweise mehrere vollständige Segmente dem Puffer auf einmal hinzugefügt. Da ein Bearbeitungssegment lediglich zu einem Zeitpunkt erkannt werden kann, führen mehrere identische Bearbeitungssegmente in einem Puffer zu Schwierigkeiten in der Anomalieerkennung. Demnach ist die Länge des kleinsten Bearbeitungssegments ein angemessener Startwert für die Wahl von *DataDelta*.

5.6.4 Kennzahlberechnung

Da zur Wiedererkennung von zuvor identifizierten Mustern eine distanzbasierte Kennzahl, im Folgenden *DifferenceScore* genannt, verwendet wird, stellt die Kennzahlberechnung den wichtigsten Bestandteil der Online-Mustererkennung dar. Neben dem Parameter *DifferenceScore* werden in diesem Schritt auch die möglichen Start- und Endzeitpunkte sowie der Parameter *InDataPercentage* vorgestellt. Alle weiteren Schritte der Online-Mustererkennung bauen auf den Ergebnissen der Kennzahlberechnung auf. Da die Anomalieerkennung die Onlinedaten mit dem in der Online-Mustererkennung gefundenen Bearbeitungssegment vergleicht, ist der *DifferenceScore* auch für die Anomalieerkennung von großer Bedeutung.

Zu Beginn wird beschrieben wie die Kennzahl berechnet wird, um diese im Anschluss zu interpretieren und die verschiedenen Einflussfaktoren zu diskutieren. Eine zentrale Anforderung der gesamten Anwendung ist die Echtzeitnähe, weshalb auch die Laufzeit der Kennzahlberechnung bewertet werden muss. Kapitel 5.7 beinhaltet eine detaillierte Analyse des Ansatzes und diskutiert dessen Grenzen.

Als Grundlage der Kennzahlberechnung dienen die Datenbank der Repräsentanten sowie der Inhalt des Puffers. Die Vorgehensweise besteht aus einem iterativen Verschieben der Repräsentanten über den Puffer. Es wird der Repräsentant gesucht, welcher zu einem bestimmten Startzeitpunkt innerhalb des Puffers den geringsten *DifferenceScore* aufweist. Die Ausgabe der Kennzahlberechnung besteht dementsprechend zusätzlich zu den *DifferenceScores* der Repräsentanten auch aus den dazugehörigen Start- und Endzeitpunkten sowie den Parametern *InDataPercentage*.

Abbildung 5-18 zeigt den Ablauf der Kennzahlberechnung in seinen sechs Teilschritten. Zu Beginn werden die Signale für die nachfolgenden Schritte vorbereitet. Beispielsweise werden je nach verwendeten Einstellungen die Referenzsignale auf eine vom Anwender gewählte Abtastrate transformiert. Im zweiten Schritt werden alle Referenzsignale eines Repräsentanten auf das Niveau des dazugehörigen Startzeitpunkts innerhalb des Puffers angepasst, um im Anschluss die Distanzen zwischen Repräsentant und Puffer zu berechnen. Vor der Identifikation der *DifferenceScores* und der dazugehörigen Startzeitpunkte müssen die Distanzen normiert werden, um die Vergleichbarkeit von Repräsentanten unterschiedlicher Länge zu gewährleisten. Im letzten Schritt wird der Parameter *InDataPercentage* mit Hilfe der Startzeitpunkte errechnet.

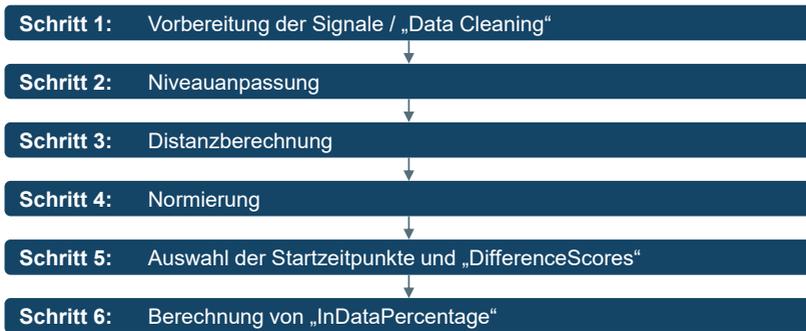


Abbildung 5-18: Ablauf der Kennzahlberechnung in sechs Schritten.

Niveauanpassung

Ein Repräsentant wird zu Beginn der Distanzberechnung auf das jeweilige Niveau des Startpunkts im Puffer geschoben. In der ersten Iteration wird der erste Datenpunkt im Puffer als Startpunkt verwendet. Dementsprechend wird jedes Referenzsignal i des Repräsentanten j um $(p_{1,i} - x_{1,i}^{j,alt})$ in y-Richtung verschoben, um im Anschluss die Distanzen zu berechnen. Ist dies geschehen, wird der Repräsentant auf das Niveau des zweiten Datenpunkts im Puffer um $(p_{2,i} - x_{1,i}^{j,alt})$ angehoben. Danach erfolgt erneut die Distanzberechnung. Dieses Vorgehen wiederholt sich für jeden Datenpunkt s im Puffer entsprechend der folgenden Formel 5-13.

$$x_{t,i}^{j,neu} = x_{t,i}^{j,alt} + (p_{s,i} - x_{1,i}^{j,alt}), \quad t = 1, \dots, l; i = 1, \dots, n; \forall k \quad 5-13$$

Distanzberechnung

Wurden die Referenzsignale des Repräsentanten an das Niveau des jeweiligen Startpunkts angepasst, werden nun die Distanzen zwischen den Datenpunkten des Repräsentanten und des Puffers berechnet. Dabei gibt es entweder l oder $(k - s)$ Summanden, abhängig vom Startzeitpunkt s , der Länge des Puffers k und der Länge des Musterzyklus l . Abschließend werden diese Summen aller Referenzsignale i summiert (Formel 5-14).

$$d_s^j = \sum_{i=1}^n \sum_{t=1}^{\min\{l, k-s\}} |x_{t,i}^{j,neu} - p_{s+t,i}| \tag{5-14}$$

Die folgende Abbildung 5-19 veranschaulicht den Berechnungsschritt zum Abgleich von Online-Puffer und den Repräsentanten in der Datenbank. Passt der Repräsentant mit dem Startzeitpunkt s vollständig in den verbleibenden Puffer (oberer Teil der Abbildung), besteht die Summe aus l Summanden. Im anderen Fall (unterer Teil der Abbildung) besteht sie aus $(k - s)$.

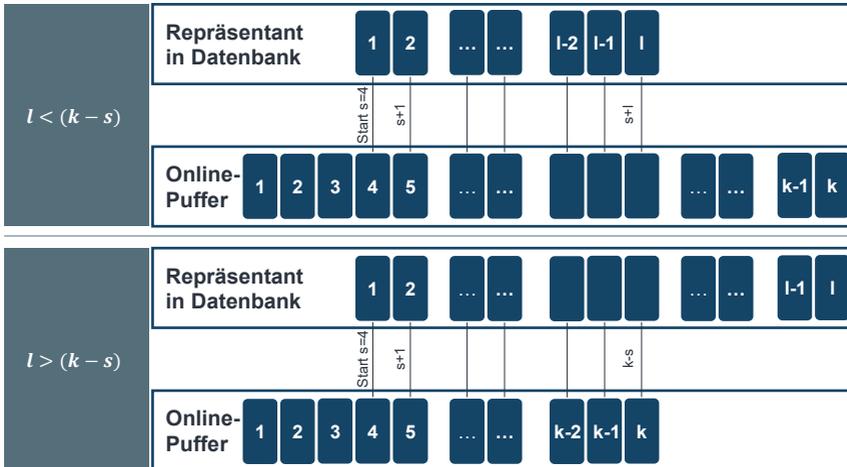


Abbildung 5-19: Veranschaulichung der Anzahl der Summanden in Abhängigkeit des Startzeitpunkts s , der Länge des Puffers k und der Länge des Repräsentanten l .

Resultierend aus den j Repräsentanten und k verschiedenen Startzeitpunkten, ergibt sich folgende Matrix D . Hierbei bezeichnet der Eintrag d_s^j die Summe der Distanzen von Repräsentant j zum Puffer ab dem Startzeitpunkt $s \in \{1, \dots, k\}$. Insbesondere besteht die letzte Spalte der Matrix D ausschließlich aus Nullen, da in diesem Fall der erste Datenpunkt des Repräsentanten auf das Niveau des letzten Datenpunktes im Puffer angehoben wird, um anschließend die Distanz zu berechnen.

$$D = \begin{pmatrix} d_1^1 & \dots & d_k^1 \\ \vdots & & \vdots \\ d_1^z & \dots & d_k^z \end{pmatrix} \tag{5-15}$$

Normierung

Um Repräsentanten unterschiedlicher Länge vergleichen zu können, werden die summierten Distanzen mit der Anzahl der inneren Summanden normiert. Das Ergebnis ist die Matrix DS , welche die *DifferenceScores* von Repräsentant j zum Startzeitpunkt s beinhaltet. Formel 5-16 zeigt die Normierung der Distanzen von Repräsentant $j \in \{1, \dots, z\}$ zum Startzeitpunkt $s \in \{1, \dots, k\}$.

$$DS_s^j = \frac{1}{\min\{l, k - s\}} \cdot d_s^j \quad 5-16$$

$$DS = \begin{pmatrix} DS_1^1 & \dots & DS_k^1 \\ \vdots & & \vdots \\ DS_1^z & \dots & DS_k^z \end{pmatrix}$$

5.7 Fazit der Datensegmentierung und der Online-Mustererkennung

Die Datensegmentierung sowie die Online-Mustererkennung in Zeitreihendaten ist ein zentrales Element zur Detektion von Störungen. Mithilfe der Datensegmentierung ist es möglich, wechselnde Prozesszustände zu bestimmen. Zentrale Herausforderungen dabei sind die korrekte Wahl des Clusterparameters Bandwidth, das Berechnen der optimalen Repräsentanten sowie das laufzeiteffiziente Wiederfinden der Repräsentanten im Online-Signal. Dazu wurden einige Parameter eingeführt und vorgestellt, welche zur Erfolgsgüte wesentlich beitragen. Vorliegende Arbeit fasst dabei die Ergebnisse aus den Entwicklungsstudien zusammen. Im nachfolgenden Kapitel werden die Verfahren der Anomalieerkennung diskutiert sowie Ansätze zum frühen Auffinden von Störungen beschrieben.

6 Anomalieerkennung

In folgendem Kapitel dieser Dissertation werden Ansätze einer Anomalieerkennung erarbeitet und diskutiert. Dabei soll auf Basis der bereits in vorigen Kapiteln erläuterten Lösungsansätze der Prozessreferenzierung über eine Mustererkennung ein modulares Konzept zum unüberwachten Auffinden von Anomalien durch einen relativen Abgleich der Signale entwickelt werden. In Kapitel 5, Abbildung 5-1, ist der modulare Ablauf des Gesamtsystems gezeigt. Im ersten Schritt der Gesamtmethodik sind die Repräsentanten durch die Offline-Datensegmentierung mit anschließender Online-Wiedererkennung im Signal identifiziert. Der nächste Schritt ist die Anomalieerkennung auf Basis der Informationssignale. Im nachfolgenden Kapitel werden unterschiedliche Prinzipien zum Erkennen von Anomalien beschrieben. Dabei werden verschiedene Lösungsansätze ausgehend von konventionellen Verfahren über einen Schwellwert bis hin zu hüllkurvenbasierten Ansätzen aufgezeigt und bewertet. Es wird das Erkennen von kontinuierlich auftretenden Anomalien erläutert und diskutiert. Zudem erfolgt die Herleitung, wie die Weiterverwendung von bereits erkannten Anomalien in Form des überwachten Lernens umgesetzt werden kann.

Die Inhalte der folgenden Kapitel wurden im Rahmen der angeleiteten Arbeiten (A_Martin 2020) (A_Winkler 2020) (A_Begemann 2021) analysiert. Die Ergebnisse sind zusammengefasst dargestellt.

6.1 Prinzip der Anomalieerkennung

Die unüberwachte Anomalieerkennung in Online-Daten gründet wie auch die Mustererkennung auf einen distanzbasierten Ansatz. Es werden die Repräsentanten aus der Mustererkennung sowie Informationssignale innerhalb des Puffers übergeben, um dann auf Basis eines Abgleichs Anomalien in den Informationssignalen aufzufinden.

6.1.1 Leistungsspektrum

Sich äußernde Anomalien in Produktionsmaschinen sind nicht de facto Abweichungen im Zeitbereich. Gerade Anomalien, welche auf Verschleiß oder Schäden an drehenden Komponenten wie Lagern rückführbar sind, äußern sich in der Regel auch durch überlagertes Schwingungsverhalten im zu messenden Signal. Die Auswirkung der Störung kann im Zeitbereich hingegen nur gering sein. Diese Anomalien, welche durch anomales Signalverhalten in Amplitude und Frequenz charakterisiert sind, werden über eine

Fast-Fourier-Transformation aufgefunden. Das Signal wird dabei in den Frequenzbereich transformiert. Eine anschließende Distanzbestimmung findet im Zeit- sowie Frequenzbereich statt. Nachfolgend wird vereinfacht auf die Distanzbestimmung im Zeitbereich eingegangen. Weiterführende Analysen sind in der angeleiteten Arbeit (A_Winkler 2020) beschrieben.

6.1.2 Distanzbestimmung

Zuerst werden punktweise Distanzen im Vergleich von Online-Signaldaten mit allen Informationssignal-Repräsentanten über eine Manhattan-Metrik berechnet. Die Signale werden zeitlich geringfügig zueinander verschoben, um Ungenauigkeiten aus der Repräsentantenberechnung ausgleichen zu können. Es werden mehrere Iterationen der Distanzberechnung durchgeführt. Maßgeblich zur weiteren Berechnung ist die geringste Distanz aus den Iterationen (A_Martin 2020).

Formel 6-1 zeigt die Berechnung der punktweisen Distanzen zweier Signale.

$$d_i = \begin{pmatrix} d_i(1) \\ d_i(2) \\ \dots \\ d_i(t) \end{pmatrix} = \begin{pmatrix} |m(1) - o(1)| \\ |m(2) - o(2)| \\ \dots \\ |m(t) - o(t)| \end{pmatrix} \quad 6-1$$

Der Vektor d_i beinhaltet die Distanzen $d_i(t)$ zu dem jeweiligen Zeitpunkt t in Cluster i . Die Variablen $m(t)$ und $o(t)$ sind die jeweiligen Messwerte der zwei Signale zum Zeitpunkt t .

Eine Anomalie wird dann ausgegeben, wenn ein Toleranzwert überschritten wird. In diesem Fall ist dieser Toleranzwert allerdings als untere Grenze zu verstehen und bedingt kein großes Anwender-Know-How. Es muss lediglich zwischen Messfehler im Signal und realistischer Signalveränderung unterschieden werden.

6.1.3 Anomaliedetektion anhand eines Toleranzbandes

Nachdem die Distanzen zwischen den Repräsentanten und dem Online-Signal bestimmt wurden erfolgt die Detektion von Anomalien. Im Folgenden werden zwei Ansätze vorgestellt, wie Anomalien im Signal detektiert werden können.

Es wird für jeden Repräsentanten ein spezifisches Toleranzband berechnet. Dieses Band beinhaltet alle bekannten Informationssignale je Repräsentant. Die Datenpunkte beinhalten auch die obere und untere Grenze. Innerhalb dieser Grenzen muss sich das zuvor berechnete Distanzmaß befinden.

Werden die Grenzwerte vom Online-Signal verletzt, erfolgt die Bewertung dieses Datenpunktes als anormal (Error). Mithilfe des Parameters *allowedErrors* erfolgt eine spezifische Eingrenzung des Systems anhand einer tolerierbaren Anzahl anormaler Datenpunkte. Diese Eingrenzung ist relevant, um zwischen Messfehlern und Anomalien unterscheiden zu können. Es erfolgt allerdings keine Einschränkung der Gesamtfunktion durch notwendiges a priori Wissen eines Anwenders.

Überschreitet also die Anzahl der anomalen Datenpunkte den Grenzwert, so wird eine Anomalie detektiert. Das Toleranzband stellt demnach den Kern der unüberwachten Anomalieerkennung dar. Dabei ist anzumerken, dass die Erfolgsgüte maßgeblich von der Wahl des Toleranzbandes und der entsprechenden Varianz abhängt.

6.1.4 Schwellwertbasiertes Toleranzband

Ein Lösungsansatz des Toleranzbandes ist das schwellwertbasierte Toleranzband. Dieser Ansatz berechnet ein Toleranzband über einen clusterspezifischen Schwellwert T_i (A_Martin 2020).

$$T_i = d_{i,max} + \sqrt{\sigma_i^2} * \varepsilon \quad \text{mit } d_{i,max} = |s_{ij} - R_i| \quad 6-2$$

Das vorzufindende Distanzmaß $d_{i,max}$ ist dabei als die maximale, punktweise berechnete Distanz aller Signalverläufe s_{ij} in einem Repräsentanten-Cluster zum jeweiligen Repräsentanten R_i zu verstehen. Des Weiteren erfolgt die Berechnung der Intra-Cluster-Varianz $\sqrt{\sigma_i^2}$ (A_Martin 2020). Diese wird als Wurzel der Standardabweichung definiert.

Zur einfachen adaptiven Anpassung zwischen unterschiedlichen Maschinen kann die Standardabweichung manuell mithilfe eines Parameters *ThresholdMultiplier* (ε) gewichtet werden. Abbildung 6-1 zeigt das Toleranzband, welches über die Schwellwertberechnung bestimmt wurde. Die schwellwertbasierte Toleranzbandbestimmung über einen clusterspezifischen Wert offenbart allerdings einige Herausforderungen, welche sich nachteilig auf die Güte der Anomalieerkennung auswirken. Abbildung 6-1 zeigt, dass das Toleranzband in Bereichen von starker Schwingung des Signals nicht ausreichend entfernt von den innerhalb liegenden Signalen ist. Dies ist deutlich in den Bereichen der Datenpunkte [180-250] zu erkennen. Die grün markierten Grenzlinien sind sehr nah an den Signalwerten und weisen keine Robustheit gegenüber natürliche Signalvarianzen auf.

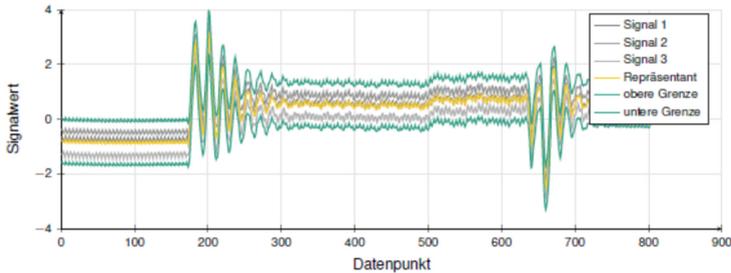


Abbildung 6-1: Veranschaulichung des Toleranzbandes mit einem Cluster-Schwellwert. Darstellung nach (Netzer, Palenga & Fleischer 2022).

Kommt es also zu starken Schwingungen im Signal resp. besitzen Signale große Gradienten wie im Diagramm sichtbar, bleibt der vertikale Toleranzabstand beinahe unverändert. Die laterale Grenze des Toleranzbandes verengt sich allerdings deutlich. Dieses Verhalten führt dazu, dass eine minimale zeitliche Verschiebung der Online-Signale direkt zu einem Verletzen der Grenzwerte und somit Ausgabe einer Anomalie führt. Bei kleiner werdendem Schwellwert wirkt sich dieser Effekt verstärkend aus. Wenn eine Glättungsfunktion im Hinblick auf das Toleranzband Anwendung findet, kann es direkt zu Grenzwertverletzungen einiger Datenpunkte innerhalb des Clusters kommen. Dieser Effekt kann auch durch weitere Berechnungsalternativen nicht eliminiert werden, weshalb ein schwellwertbasiertes Toleranzband ungeeignet für die Anwendungsfälle in der Produktion ist.

6.1.5 Hüllkurvenbasiertes Toleranzband

Um beschriebenes Problem zu lösen, wird eine Hüllkurve als Toleranzband anstatt des Schwellwertes berechnet. Hüllkurven können mit großen Gradienten und den daraus resultierenden lateralen Offsets umgehen. Bei der Hüllkurvenberechnung erfolgt die Bestimmung der Grenzwerte analog zur schwellwertbasierten Toleranzberechnung. Zunächst wird die obere Hüllkurve H_o berechnet. Diese enthält für jeden Daten- resp. Zeitpunkt den Maximalwert aller enthaltenen Signale im Cluster. Im Anschluss daran wird der gleitende Maximalwert (engl.: moving maximum) bestimmt. Eine Einstellbarkeit, aufgrund von wechselnden Signalcharakteristiken bei unterschiedlichen Maschinen wird durch die Parameter k_b und k_f gegeben, in dem sich die Fensterbreite manuell einstellen lässt. Mit Hilfe der Parameter k_1 , k_2 und k_3 erfolgt die Berücksichtigung des Rauschens der Signale, die Distanz zwischen unterer und oberer Hüllkurve, sowie der

Intra-Cluster-Varianz. Der mathematische Zusammenhang des Toleranzbandes T_0 zeigt Formel 6-3:

$$T_0 = H_0 + k_1(P_{99}) + k_2(H_0 - H_u) + k_3(\sigma^2) \quad \sigma^2 = \text{Var}(\bar{y}_i) \quad 6-3$$

Abbildung 6-2 zeigt anschaulich, wie die Hüllkurve der Signale speziell in den Bereiche mit starker Schwingungen (Datenpunkte 180-250) das Signal umspannt und somit deutlich robuster gegen zeitliche Verschiebungen ist. Die Anzahl der Ausgaben von falschen Anomalien aufgrund natürlicher Varianzen im Signal wird verringert. In Bereich mit geringer Schwingung ist die Hüllkurve beinahe identisch zum Toleranzband aus Abbildung 6-1.

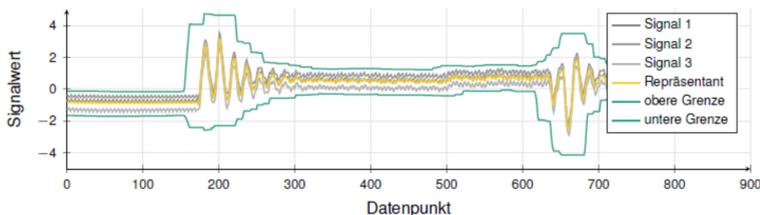


Abbildung 6-2: Hüllkurvendarstellung eines Signals. Darstellung nach (Netzer, Palenga & Fleischer 2022).

6.1.6 Fazit der unüberwachten Anomalieerkennung

Die vorliegende Dissertation diskutiert einen Lösungsansatz einer Anomalieerkennung auf Basis wiederkehrender Bearbeitungssegmente. Es zeigt sich, dass einfache schwellwertbasierte Ansätze die komplexe Problemstellung in Produktionsmaschinen nicht erfüllen. Herkömmliche indexbasierte Anomalieerkennungen können einzelne diskrete Prozesszustände erkennen, sind allerdings nicht in der Lage prozessabhängige Verläufe, wie sie in Produktionsmaschinen vorkommen, in die Berechnung miteinfließen zu lassen. Die überwachte Anomalieerkennung zeigt Erfolge bei der Anwendung einer Hüllkurve als Grenzwert. Nach Verletzen des Grenzwertes der Hüllkurve unter Berücksichtigung der Maschinenparameter erfolgt eine binäre Ausgabe einer Anomaliewarnung. Diese kann im Post-Processing weiterverarbeitet werden, sodass auch Klassifizierungsaufgaben gelöst werden können. Dieser Ansatz wird im folgenden Kapitel erläutert.

7 Post-Processing – Klassifikation von Anomalien

Die Integration von Anwenderwissen spielt bei heutigen digitalen Funktionen in Produktionsmaschinen wie Condition Monitoring oder Predictive Maintenance noch eine untergeordnete Rolle. Dies ist auf die nicht triviale Formalisierung menschlichen Wissens zurückzuführen. Im Stand der Technik gibt es bereits erste Ansätze zum übertragbaren Lernen, welche in Kapitel 2.7 näher erklärt sind. Gerade bei Anwendungen bei denen hohes Domänenwissen verlangt wird, oder bei denen sich Prozesszustände schnell ändern können, ist die Integration von Anwenderwissen essentiell. In vorliegender Dissertation werden mehrere Ansätze vorgestellt, wie durch Anwenderwissen die Genauigkeit der Anomalieerkennung gesteigert werden kann und wie weiteres vorhandenes Wissen von Anwendern integriert werden kann. Neben des Feedback-Loops des Anwenders nach dem Auffinden von Anomalien wird eine weitere Integrationsart diskutiert. Die Weiterverwendung bereits gefundener Anomalien als supervised learning zur Klassifikation wird diskutiert. Es werden konventionelle Ansätze sowie Verfahren mittels maschinellem Lernen gegenübergestellt. Bei Verfahren des maschinellen Lernens zur Klassifikation wird in der Regel zuerst eine Feature Extraktion durchgeführt. Anschließend erfolgt dann das Klassifizieren. Das Kapitel schließt mit einer Bewertung und Fazit der Konzepte ab.

Die Inhalte der folgenden Kapitel wurden im Rahmen der angeleiteten Arbeiten (A_Martin 2020) (A_Winkler 2020) (A_Begemann 2021) (A_Alexander 2021) erarbeitet. Die Ergebnisse sind zusammengefasst dargestellt.

7.1 Feedback-Loop des Anwenders

Zur Steigerung der Genauigkeit sowie zur einfachen Reaktion auf wechselnde Randbedingungen ist die Anomalieerkennung in vorliegender Dissertation so konzipiert, dass gefundene Anomalien zur Abfrage an den Anwender ausgegeben werden. Die unüberwachte Anomalieerkennung auf Basis wiederkehrender Bearbeitungssegmente findet das anormale Signal und stellt dem Anwender die Entscheidung darüber zur Abfrage aus. Demnach ergeben sich zwei Fälle bei der Ausgabe einer Anomalie.

1. Fall: Akzeptieren der gefundenen Anomalie
2. Fall: Negieren der gefundenen Anomalie

Im ersten Fall erfolgt kein Feedback-Loop in die Datenbank der Clusterrepräsentanten, da die ausgehende Annahme des n.i.O.-Verlaufs korrekt ist. In diesem Fall wird der

gefundene Verlauf der anormalen Signale in eine Anomalie-Datenbank gespeichert. Dort ist die Anomalie für das weitere Postprocessing der Klassifikation aufrufbar.

Im zweiten Fall erfolgt ein Feedback-Loop zur Repräsentantenberechnung. In diesem Fall, indem die Anomalieerkennung eine falsche Anomalie ausgibt, oder, in dem der initiale Signalverlauf anormal angelernt wurde, kann der Anwender die gefundenen Anomalie negieren. Der gefundene Signalverlauf wird zum bestehenden Cluster der Bearbeitungssegmente hinzugefügt. Dann erfolgt ein erneutes Clustern der Informationssignale dieses Repräsentanten inklusive des negierten Signalverlaufs der gefundenen Anomalie.

Dem gesamten Feedback-Loop unterliegt die Annahme, dass der Anwender das Signal interpretieren kann und ein großes System- und Signalverständnis mitbringt.

7.2 Fazit des Feedback-Loops des Anwenders

Die Entscheidung über den wahren Charakter des gefundenen Verlaufs über eine Interaktionsfläche durch den Anwender bietet entscheidende Vorteile. Zum einen wird die Genauigkeit des Gesamtsystems wesentlich verbessert, da auch initial falsch angelegte Verläufe in der Mustererkennung aufgefunden und deren Zuordnung geändert werden kann. Zum anderen wird das Lernen des Verfahrens durch die Interaktion des Anwenders transparenter. Der Anwender trägt einen wesentlichen Beitrag zur Anomalieerkennung bei.

Die Interaktion des Anwenders führt allerdings auch dazu, dass ein voll-autonomer Betrieb der Anomalieerkennung kaum möglich ist. Ein autonomes System findet in jedem Fall Anomalien und speichert diese ab. Neigt allerdings bei geringen Datenmengen und Lernraten ohne die Interaktion von Anwendern zu geringerer Genauigkeit bei der Anomalieklassifikation.

7.3 Integration eines Labels zur Klassifikation von Anomalien

Neben dem Auffinden von Anomalien durch unüberwachte Verfahren sollen Anomalien im realen Anwendungsfall einer laufenden Produktionsmaschine auch klassifiziert werden. Das bedeutet, dass auch eine Aussage über die Art der Anomalie notwendig ist. Ziel dieser Klassifikation ist, dass Optimierungen und nachgelagerte Analysen zur Fehlerursache ermöglicht werden, um so nachhaltig die Verfügbarkeit der Anlagen und Qualitätssteigerungen zu ermöglichen. Zur Vereinfachung der Störungsbehebung soll

die Anomalieerkennung eine Hilfestellung durch eine konkrete Vorhersage des Störungsgrundes ermöglichen. Dazu ist eine umfangreiche Informationsgrundlage der gefundenen Anomalien notwendig und es müssen neben der Anomaliesignale auch weitere prozessspezifische Daten abgelegt werden. Folgende Daten sind notwendig:

- Zeitpunkte der Anomaliedetektion
- zugehöriger Repräsentant der Bearbeitung
- normale Signalverläufe der Informationssignale
- anomale Signalverläufe der Informationssignale
- durch den Anwender angegebenes Label und Beschreibung der Anomalie (bspw. Werkzeugbruch)
- Erläuterung zur Anomalie über Freitext
- ggf. eine Handlungsempfehlung über Freitext
- Zustandsgrößen als Index, wie Kühlschmierstoff-Einsatz oder Material- und Werkzeugnummer

Zur Störungserkennung kann ebenfalls eine Handlungsempfehlung zur Fehlerbehebung durch den Anwender angegeben werden. Dadurch ist ein noch effizienteres Beheben der Störung möglich. Notwendige Bedingung für das Vorschlagen von Handlungsempfehlungen ist, dass der Anomlietyp resp. Label der gefundenen Anomalie auf Basis bereits historisch trainierter Verläufe zuverlässig wiedererkannt wird.

7.3.1 Lösungsansatz

Im Folgenden werden einige Lösungsansätze erläutert, um Anomaliesignale klassifizieren und wiedererkennen zu können. Die Annahme ist, dass verschiedene Anomalien in Anomalietypen kategorisiert werden können. Des Weiteren gilt die Bedingung, dass die Anomalietypen charakteristische Signalmerkmale aufweisen, welche zur eindeutigen Zuordnung des Typs notwendig sind.

Zur Merkmalsfindung sind zuerst die relevanten Signale sowie deren Vorverarbeitung zu definieren. Da sich Anomalien in unterschiedlichen Signalen und auch Ausprägungen charakterisieren, wird ein hybrider Lösungsansatz gewählt. So ist beispielsweise bei der Fräsbearbeitung und den bei Gussteilen auftretenden Lunkern/Poren ein Einbruch in der Schnittkraft zu erkennen, was sich im Signal äußert (Mohanraj & Shankar et al. 2020) (A_Ammon 2019). Ein Flankenverschleiß an bspw. einem Schafffräser zeichnet sich durch eine periodisch wiederkehrende Erhöhung der Schnittkraft aus. Im

Signal ist dieses Merkmal dann als überlagerte Frequenz der entsprechenden Spindel-drehzahl sichtbar (Mohanraj & Shankar et al. 2020). Bei einfacher Untersuchung des Zeit-Signals kann diese Anomalie nicht immer detektiert werden. Die Signal-Frequenz-spektrien sowie das Differenzspektrum (Differenz der jeweiligen Spektrien) müssen aus diesem Grund ebenso zur Anomaliedetektion verwendet werden. Abbildung 7-1 zeigt im linken Diagramm ein exemplarisches Soll- und Ist-Signal im Zeitbereich sowie im rechten Diagramm das Differenzspektrum. Es ist zu erkennen, dass es trotz ähnlichen zeitlichen Verlaufs von Ist- und Soll-Signal eine anormale Ausprägung im Differenzspektrum durch die Überlagerung eines Sinussignals (rechtes Diagramm) gibt.

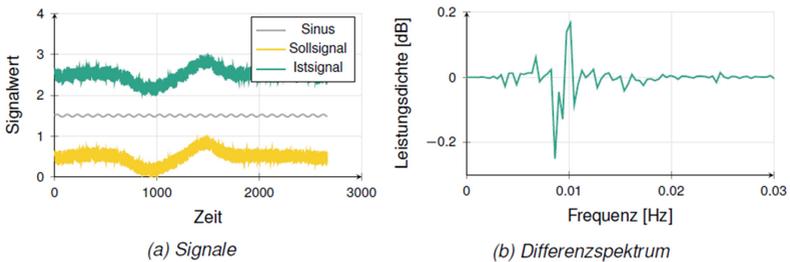


Abbildung 7-1: (a) Exemplarische Darstellung eines Soll-Signals mit einem überlagerten Sinussignal sowie resultierendem Ist-Signal. (b) zeigt das Differenzspektrum von Soll- und Ist-Signal. Darstellung nach (A_Winkler 2020).

Weiterhin ist Verschleiß im Allgemeinen auch durch ganzheitlichen Kraftanstieg zu beschreiben. Dieser ist über den Betrachtungshorizont hinaus durch einen monoton steigenden Trend im bspw. Drehmomentsignal der Achsen und/oder Spindel sichtbar. Im einfachsten Fall ist dieser Kraftanstieg als kontinuierliche Verschiebung des Signals zu höheren resp. geringeren Werten gekennzeichnet.

Um alle Merkmale und Charakteristiken zu detektieren, wird in vorliegender Dissertation ein Lösungsansatz bestehend aus Berechnungen in

- Ist-Signal (Zeitbereich)
- Ist-Signal (Frequenzbereich)
- Differenzspektrum sowie Differenzsignal zwischen Soll- und Ist-Signal verwendet.

7.3.2 Vergleichslogiken

Im vorherigen Kapitel wurde erläutert, dass nicht ausschließlich einfache Signalvektoren bei der Analyse von Anomalien als relativen Abgleich zwischen Online-Signal und Repräsentanten verwendet werden. Der Lösungsansatz dieser Arbeit baut neben den Signalvektoren auch auf Spektren, die Differenzsignale und entsprechende Differenzspektren auf. Auf Basis aller Signalarten werden nachfolgend einige Vergleichslogiken zur Anomaliedetektion beschrieben. Unter dem Begriff Vergleichslogik werden verschiedene Berechnungsarten wie konventionelle Verfahren aber auch Verfahren mittels künstlicher Intelligenz verstanden. Diese Verfahren vergleichen Merkmale der Signale zwischen unterschiedlichen Anomalietypen. Folgende Ansätze werden detailliert bewertet:

1. **Signale:** Trainings- und Testdaten bestehen aus den Signalvektoren der anomalen Signale.
2. **Spektrum:** Spektren der anomalen Signale werden als Trainings- und Testdaten verwendet.
3. **Differenzsignal:** Differenzsignale aus Soll- und Ist-Signal werden als Trainings- und Testdaten genutzt.
4. **Differenzspektrum:** Analog zu Variante 3. Es finden Differenzsignale von normalem und anomalem Signal im Frequenzbereich Anwendung.
5. **Best-Matching:** Diese Logik führt den geeignetsten Ansatz aus allen Varianten 1-4 durch. Die Klassifizierung und Auswahl des Ansatzes wird anhand eines Match-Score bestimmt. Die Berechnung des Match-Score wird im folgenden Kapitel erläutert.
6. **Combined Vector:** Die Logik wird aus den Verfahren der Signale (1), Spektren (2), Differenzsignale (3) und -spektren (4) kombiniert. Es wird ein Datenvektor erzeugt, welcher als Input zur Klassifizierung genutzt wird.

Nachfolgend werden die Ergebnisse zusammengefasst erläutert. Ausführliche Erklärungen führt die angeleitete Arbeit (A_Winkler 2020) auf.

7.3.3 Statistische Ansätze

In diesem Kapitel sind statistische Ansätze dargestellt, welche im Allgemeinen auf bewährten Methoden und Verfahren der Signaltheorie resp. Ähnlichkeitsanalyse beruhen.

Dabei erfolgt der Abgleich einer gefundenen Anomalie über ein sogenanntes Ähnlichkeitskriterium. In vorliegender Dissertation wurden folgende Methoden untersucht:

- Statistische Methoden (Kreuzkorrelationen bzw. Korrelationskoeffizienten)
- Distanzmaße

Beim Verfahren des Korrelationsansatzes erfolgt die Bestimmung über eine statistische Ähnlichkeit. Diese Ähnlichkeit wird auf Basis detektierter Anomalien zu bereits bekannten Anomalien in Zeit- und Frequenzbereich berechnet. Dabei ist zu beachten, dass bei diesem Verfahren das statistisch ähnlichste Signal immer ausgewählt wird.

Der wesentliche Nachteil dieser Verfahren liegt in der Annahme, dass die statistische Ähnlichkeit ein hinreichendes Kriterium ist. Dies ist allerdings bei genauer Betrachtung von Realdaten nicht zwangsläufig gegeben. Um auf den gleichen Anomalietyp schließen zu können, ist die statistische Ähnlichkeit kein hinreichendes Kriterium, sogar eine nicht zwangsläufig notwendige Bedingung. Demnach ist dieses konventionelle Konzept nur bedingt geeignet und kann nicht im Allgemeinen angewendet werden. Weitere Untersuchungen werden aus den oben genannten Gründen nicht weiter angestoßen.

Beim Ansatz über ein Distanzmaß wird eine Ähnlichkeit zwischen detektierter Anomalie und bekannten Anomalien auf Basis eines Distanzmaßes bestimmt. Analog zu den Vorteilen des Korrelationsansatzes wird auch hier immer die ähnlichste Anomalie gefunden. Allerdings ist bei diesem Ansatz, analog zum Korrelationsverfahren, zu nennen, dass ähnlicher Signalverläufe und -spektren als Merkmal des Anomalietyps unzulässig sind. Auf weitere Untersuchungen wurde ebenso aufgrund des Nachteils bewusst verzichtet.

Statistische Verfahren wie beispielsweise Korrelationskoeffizienten oder Distanzmaße liefern eindeutig zuverlässige Aussagen im Hinblick auf die statistische Ähnlichkeit von Zeitreihenabschnitten im Zeit- und Frequenzbereich. Des Weiteren sind diese Ansätze zur Bewertung der Ähnlichkeit einfach zu realisieren und liefern bereits bei geringer Datengrundlage zielführende Aussagen. Der Vergleich von Signalvektoren unterschiedlicher Länge stellt kein Problem bei diesen Verfahren dar.

Diese eher konventionellen Ansätze liefern allerdings lediglich Aussagen über klassische Ähnlichkeitskriterien wie statistische Werte oder Distanzen. Diese Kriterien stellen im Allgemeinen für die Charakterisierung eines Anomalietyps keine notwendige Bedingung dar. Aus diesem Grund werden Ansätze benötigt, welche charakteristische Merkmale extrahieren, um den korrekten Anomalietyp zu identifizieren.

7.3.4 Ansätze unter Verwendung von Methoden des maschinellen Lernens

Im folgenden Kapitel werden relevante Ansätze diskutiert, mithilfe derer eine eindeutige Merkmalsextraktion der Signaldaten sowie eine Klassifizierung des Anomalietyps ermöglicht wird. Ziel ist es, diese Merkmale resp. Anomaliecharakteristika je Anomalietyp anzutrainieren und im nachfolgenden Schritt zu klassifizieren.

Nachfolgende Lösungskonzepte basieren entweder auf einer Feature Extraction, mit Hilfe derer dann die Klassifikation erfolgen kann oder können ohne eine vorgelagerte Extraktion der Features resp. Merkmale auf Realdaten angewendet werden. Die eigentliche Klassifikation erfolgt dann durch Training mit bereits bekannten Anomalietypen (überwachtes Lernen). Es wird der Begriff Label resp. Klasse für den jeweiligen Anomalietyp verwendet.

Das Zielkonzept ist nachfolgend zusammengefasst dargestellt. Weiterführende Analysen sind in (A_Winkler 2020) einsehbar.

Support-Vector-Machine/DeepNet-Konzept

Als Lösungskonzept wird ein hybrider Ansatz bestehend aus einem *Support-Vector-Machine (SVM)* Konzept sowie einer Multi-Class-Klassifikation als Neuronales Netz (DeepNet) vorgestellt (A_Winkler 2020).

Bekanntheitsüberprüfung

Zur Entscheidung über die Klassifizierung des vorliegenden Signals zu einem bekannten Anomalietyp erfolgt im ersten Schritt eine Bekanntheitsprüfung. In durchgeführten Testreihen im Rahmen dieser Dissertation hat sich gezeigt, dass die Klassifizierung über das künstliche Neuronale Netz eine hohe Erfolgsgüte aufweist, wenn das vorliegende Signal resp. die unbekannte Anomalie mit Sicherheit einem der bereits bekannten Klassen zuordenbar ist. Die Klassifizierung zu keiner bereits bekannten Anomalie ist durch das Neuronale Netz mit mäßigem Erfolg geprägt. Aus diesem Grund erfolgt im ersten Schritt eine sogenannte Bekanntheitsprüfung durch eine Support-Vector-Machine, im nachfolgenden SVM genannt. Dabei geht es um die reine Bekanntheitsprüfung der unbekannt Anomalie. Die Klassifizierung zu einem bestimmten Anomalietyp ist bei der SVM vorerst irrelevant. Der maßgebliche Score (siehe Kapitel 6.1.4) wird nicht genau betrachtet. Es ist nur von Interesse, ob mindestens ein Score bezogen auf die Anomalietypen resp. Klassen positiv ist. Wenn kein Score positiv ist erfolgt eine Klassifizierung der Anomalie als unbekannt. Es erfolgt dann keine weitere Analyse des

Signals. Errechnet die SVM einen positiven Score, ist die unbekannte Anomalie einer Klasse zuordenbar und somit bekannt. Das Signal wird dann dem eigentlichen Klassifizierungsschritt übergeben.

Klassifizierung

Zum Lösen des Klassifizierungsproblems wird ein aus verschiedenen Layern bestehendes Neuronales Netz verwendet. Der Systemaufbau des Netzes ist in Abbildung 7-2 dargestellt und basiert nach der grundsätzlichen Bekanntheitsprüfung (linke Seite der Abbildung) auf einem LSTM-Netzwerk (rechte Seite der Abbildung). Auf das LSTM-Netzwerk folgt der eigentliche Classification Layer. Das Classification Layer bedarf eines vorhergehenden Softmax Layers, sodass eine Klassifizierung des Inputs erfolgen kann. Die Berechnung der Klassifikatoren mit Hilfe des Neuronalen Netzes erfolgt über eine Score-Bestimmung für jedes bekannte Label. Dieser Score stellt eine Art Wahrscheinlichkeit der unbekanntes Anomalie zu den jeweiligen Klassen dar. Das Label mit dem höchsten Score wird zur Entscheidung über die Zugehörigkeit ausgewählt.

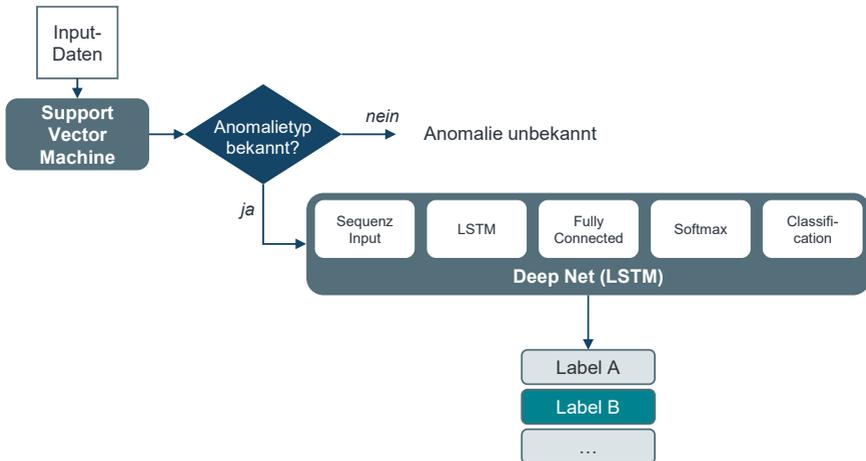


Abbildung 7-2: Architektur des SVM-DeepNet-Konzepts zur Anomalieklassifikation. Darstellung in Anlehnung an (A_Winkler 2020).

7.3.5 Bewertung des Ansatzes mittels Verfahren des Maschinellen Lernens

In diesem Kapitel wurde ein aufbauendes Verfahren beschrieben, mit Hilfe dessen eine Klassifikation von bereits gefundenen anormalen Zeitreihen-Sequenzen ermöglicht wird. Dabei sind konventionelle Verfahren aufgeführt und bewertet. Ansätze des maschinellen Lernens zeichnen sich durch ihre Robustheit und hohe Genauigkeit bei hoher Datenmenge aus. Dieser Vorteil kann im weiteren Betrieb von Produktionsmaschinen genutzt werden. Abbildung 7-3 zeigt qualitativ den geringen Klassifikationsfehler bei hoher Datenmenge (blau markierter Bereich). Auf der linken Seite (rot markierter Bereich) ist der Fehler allerdings sehr hoch, da noch keine oder wenig Daten für das Modelltraining zur Verfügung stehen. Das Domänenwissen eines Anwenders ist im Diagramm als Gerade (gestrichelter Verlauf) dargestellt. Bis zu einem Punkt ($E_K = E_T$) ist die Klassifikation auf Basis des Domänenwissens genauer. Mit steigender Anzahl an Daten sind lernende Verfahren deutlich robuster.

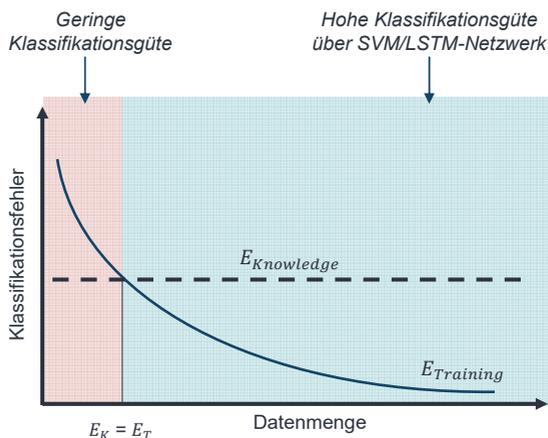


Abbildung 7-3: Qualitative Darstellung des Klassifikationsfehlers in Abhängigkeit der Datenmenge

Um diese Herausforderung zu lösen, werden im nachfolgenden Kapitel Verfahren beschrieben, wie vorhandenes Anwenderwissen formalisiert und für eine Klassifikation verwendet werden kann. Dadurch kann in allen Betriebsphasen der Maschinen eine hohe Genauigkeit bei der Anomalieklassifikation sichergestellt werden. Die initiale Anomaliedetektion bleibt von diesen aufbauenden Verfahren unberührt.

8 Integration von Domänenwissen

In diesem Kapitel wird ein neuartiges Verfahren konzeptioniert und erprobt, mit Hilfe dessen vorhandenes a priori Wissen von Anwendern in der Produktion formalisiert und in ein computergestütztes Format übertragen werden kann. Anschließend erfolgt die automatische Wiedererkennung der entwickelten Syntax, wodurch eine Klassifikation von detektierten Anomalien ermöglicht wird. Das Verfahren gliedert sich im Wesentlichen in zwei Teile, wobei der erste Schritt offline und auf Basis von Anwenderwissen erfolgen kann. Der zweite Schritt erfolgt mit Online-Daten der Maschine aus dem Prozess. Die entwickelte Logik baut auf die zuvor eingeführten Verfahren der Anomalieerkennung auf. Die nachfolgend diskutierten Verfahren werden programmieretechnisch umgesetzt und anschließend an einem industriell relevanten Anwendungsfall erprobt. Die Verfahrensentwicklung erfolgt nach der Methode „Teile-und-Herrsche-Verfahren“ (engl.: divide and conquer) (Smith 1985) (Herrmann & Schumny 1984). Dabei werden einzelne unabhängige Verfahren entwickelt, welche grundsätzlich unabhängig voneinander agieren, aber in der Gesamtheit einen Lösungsansatz fokussieren. Abbildung 8-1 zeigt die Schnittstelle der Domänenwissen-Integration im Gesamtsystem.

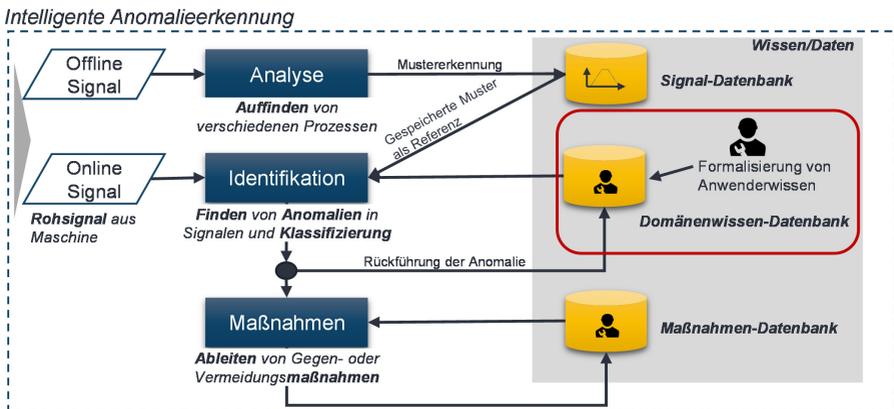


Abbildung 8-1: Aufbau Gesamtsystem und Schnittstelle Domänenwissen-Integration (rot umrandet).

Die Inhalte der folgenden Kapitel sind im Rahmen der angeleiteten Arbeit (A_Alexander 2021) entstanden. Die Ergebnisse sind nachfolgend zusammengefasst dargestellt.

Wissensformalisierung

In diesem Schritt erfolgt die Grundlage der späteren automatischen Klassifikation von Anomalien. Es werden im ersten Schritt vorhandenes Wissen und Informationen des Anwenders externalisiert und formalisiert. Dies erfolgt in Form eines sogenannten Anomalieprofils, welches in einer Domänenwissen-Datenbank abgespeichert werden kann. Dadurch kann Wissen über einen gezielten Zugriff der Datenbank zu jeder Zeit an beliebigen Orten bereitgestellt werden. Die Formalisierung erfolgt über eine eigens entwickelte Beschreibungsform einer Syntax. Diese Syntax erlaubt dem Anwender über ein systematisches Vorgehen kausale Zusammenhänge von Anomalien in ein computerlesbares Format zu übertragen und standardisiert abzuspeichern.

Online-Klassifikation durch formalisiertes Wissen

In einem zweiten Schritt der vorgestellten Logik erfolgt die automatisierte Klassifikation von datenbasierten Anomalien durch formalisiertes Anwenderwissen. Die Klassifikation erfolgt parallel zu den bereits eingeführten Verfahren aus Kapitel 7.3.4. Vorteil der Klassifikation durch formalisiertes Wissen ist die Fähigkeit bei geringer Datenmenge zuverlässige Klassifikationsergebnisse zu gewährleisten. In der Klassifikation wird im ersten Schritt das zu betrachtende Zeitintervall der detektierten Anomalie segmentiert. Im Betrachtungszeitraum erfolgt dann die Extremwertsuche analog zur Mustererkennung. Durch eine anschließende Autoskalierung werden verschiedene Anomaliefälle vergleichbar gemacht. Im eigentlichen Erkennungsschritt erfolgt die Ermittlung von lokalen Trendstrukturen gemäß der Ansätze einer qualitativen Trendanalyse. Die gefundenen Trendstrukturen werden in ein Anomalieprofil überführt und in einem Matching-Schritt mit den gespeicherten Anomalieprofilen aus der Domänenwissen-Datenbank verglichen. Die Entscheidung und Ausgabe des Anomalietyps ist probabilistisch.

Abbildung 8-2 zeigt schematisch den Aufbau der gesamten Verfahren. Im ersten Schritt erfolgt die Wissensformulierung auf Basis des Anwender-Inputs. Anschließend werden aufgefundene Anomalien klassifiziert und die Klasse dem Anwender ausgegeben. Die nachfolgenden Kapitel erläutern ausgewählte Elemente aus dem Verfahren und diskutieren deren Funktionsfähigkeit.



Abbildung 8-2: Schematischer Aufbau der Wissensformulierung und der anschließenden Klassifikation. Darstellung in Anlehnung an (A_Alexander 2021).

8.1 Formalisierung von Domänenwissen zur Beschreibung von Wissen

In nachfolgendem Kapitel erfolgt die systematische Erläuterung der Formalisierung von Domänenwissen. Anschließend werden die beschriebenen Anomalieprofile zur Klassifikation gefundener Anomalien genutzt.

8.1.1 Einführung lokaler Trendstrukturen

In einem ersten wichtigen Schritt des Offline-Verfahrens erfolgt die Einführung lokaler Trendstrukturen, mit Hilfe derer der Anwender die Anomalie beschreiben kann. Dabei sind einzelne Anomalietypen durch spezifische Trendsequenzen beschreibbar, welche im Allgemeinen in der zeitlichen Ausprägung stark unterschiedlich sein können, durch eine Normalisierung in ihrer Charakteristik aber stets identisch sind. Als Input zur Formalisierung werden bereits aufgefundene Anomalien verwendet. Dabei ist zu beachten, dass die Anomalie bezogen auf das zugrundeliegende Muster ausgegeben wird. Der anormale Bereich kann unter Umständen lediglich ein Subbereich der gesamten Ausgabe sein. Aus diesem Grund sind nachfolgend relevante lokale Trendstrukturen aufgeführt, mit Hilfe derer die Anwender einen lokalen Trend des anormalen Bereichs beschreiben können. Abbildung 8-3 zeigt verschiedene mathematische Funktionen, welche als lokale Trendstrukturen verwendet werden. Ein aufsteigender Verlauf wird mit + gekennzeichnet. Ein absteigender Verlauf wird mit – gekennzeichnet. In Anlehnung an

(Janusz & Venkatasubramanian 1991) werden zudem Subbezeichnungen eingeführt, um Anomaliebereiche in eine Syntax zu überführen.

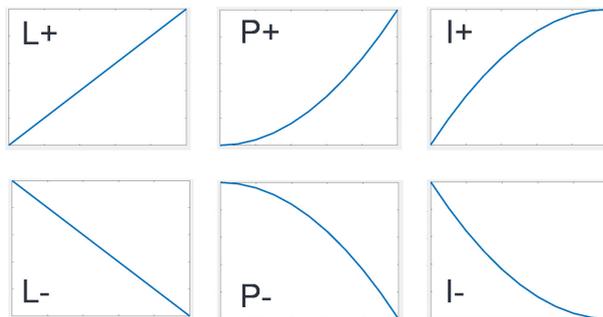


Abbildung 8-3: Trendstrukturen (lokal) in Anlehnung an (Janusz & Venkatasubramanian 1991) (A_Alexander 2021).

Die aufgeführten Trendstrukturen sind auf Basis einer Analyse von Produktionsanomalien ausgewählt. (Janusz & Venkatasubramanian 1991) sowie (Rengaswamy, Hägglund & Venkatasubramanian 2001) zeigen erste Trendarten auf, welche in vorliegender Dissertation modifiziert und auf den Anwendungsfall der Produktion resp. der Wissensformalisierung erweitert werden. Alle relevanten Anomaliebereiche haben einen definierten Start- und Endwert und können durch die dargestellten sechs Trendverläufe beschrieben werden. Die erweiterten Subbereiche beschreiben überdies ein fallendes (-) oder ein steigendes (+) Verhalten. Daraus ergibt sich folgende Nomenklatur:

Aufsteigende Verläufe:

- lineare (L+)
- polynomiale (P+)
- invers-polynomiale (I+)

Absteigende Verläufe:

- linear (L-)
- polynomial (P-)
- invers-polynomial (I-)

Ein linearer Trend approximiert einen Datenverlauf mit einer konstanten Steigung. Ein polynomial ansteigender Verlauf repräsentiert dabei eine Entwicklung der Datenreihe mit zunehmender Steigung. Der Einsatz von sechs lokalen Trendstrukturen ermöglicht

eine gewisse Eingrenzung des Handlungs- und Entscheidungsraums, lässt dem Anwender dennoch eine deutliche Variabilität und Entscheidungsfreiheit übrig. Die Erweiterung um zusätzliche Trendstrukturen zur genaueren Beschreibung von Verläufen erhöht zusätzlich die Freiheit, führt aber auch zu mehrdeutigen Beschreibungsformen und erhöht die subjektive Entscheidungsmöglichkeiten enorm.

Die Approximation korrekter Datenverläufe durch einen Anwender ohne jegliche Vorkenntnisse stellt eine gewisse Herausforderung dar. Computergestützte Werkzeuge zur Datenanalyse können hinreichend genau Verläufe approximieren. Allerdings ist ein Anwender, gerade auch bei geringer Datenmenge, in der Lage, grundlegende Verhaltensmuster von Datenverläufen zu identifizieren und steigende und fallende Trends hinreichend genau zu beschreiben. Ein Anwender kann jedoch keine weitere feine Differenzierung hinsichtlich des Funktionsgrades der Trendstrukturen durchführen. Die Wahl der Trendstrukturen ist ebenso nur unter gewissen Ungenauigkeiten möglich.

8.1.2 Nomenklatur und Anomaliesyntax

Die in den vorhergehenden Kapiteln eingeführten sechs Trendstrukturen, welche das Anomalieprofil approximiert darstellen, werden nachfolgend in eine Nomenklatur überführt. Durch die Darstellung der Trendstrukturen in eine Nomenklatur ist der Anwender in der Lage standardisierte Beschreibungen verschiedenster Anwendungsfälle zu realisieren. Des Weiteren können standardisierte Beschreibungen bei der Klassifikation automatisiert ausgewertet werden. Die eingeführte Nomenklatur beschreibt den Grundrahmen der eindeutigen Kennzeichnung von Anomaliefällen durch a priori Wissen (A_Alexander 2021).

Tabelle 1: Nomenklatur nach (A_Alexander 2021).

Kennzeichnung	Abkürzung
Normalbereich	NB
Anormalbereich	AB
Anstieg	+
Abstieg	-
Linearer Trend	L
Polynomialer Trend	P
Invers-Polynomialer Trend	I

Mit Hilfe der Nomenklatur (Tabelle 1) kann eine ganzheitliche Syntax ermittelt werden. Eine Syntax resp. Anomaliesyntax beschreibt, in welcher Form und Reihenfolge die in

der Nomenklatur aufgeführten Beschreibungsformen zusammengeführt werden können und mit einem Output, dem Anomalietyp, in Verbindung gebracht werden können. Zusätzlich zu den bereits eingeführten Anomalietrendstrukturen werden die Elemente des Normalbereichs und Anormalbereichs eingeführt. Diese globalen Verlaufsstrukturen ermöglichen eine ganzheitliche Beschreibung eines Anomalieablaufs. So können beispielweise temporär auftretende Anomaliefälle wie das Überfräsen eines Lunkers (vgl. Kapitel 9.3) durch den Wechsel von Normal- in Anormalbereich sowie dem inversen Wechsel beschrieben werden. Einhergehend mit der Einführung der Anormal- und Normalbereiche ist die Definition von Eingriffsgrenzen dieser Bereiche zu bestimmen. Dabei ist zu definieren, welche Kriterien erfüllt sein müssen, wenn ein Überschreiten resp. Unterschreiten des Normalbereichs und deren zeitlichen Entwicklung vorzufinden ist. Der Normalbereich ist definitionsgemäß der Bereich, welcher zwischen der unteren und oberen Toleranzgrenze der Anomalieerkennung liegt. Die Über- resp. Unterschreitung ist demnach eine zeitliche Entwicklung des Datenverlaufs über die Toleranzgrenzen hinweg. Es muss nicht zwangsläufig eine Rückführung aus dem anormalen in den normalen Bereich geben (bspw. bei Verschleiß). Die Anomaliesyntax kann zusammenfassend als logische Aneinanderreihung diskreter, standardisierter Zustandsgrößen der Nomenklatur angesehen werden.

Abbildung 8-4 zeigt beispielhaft die Aufschlüsselung des anormalen Bereichs (AB) als Syntax.

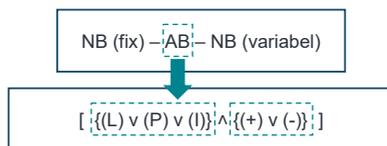


Abbildung 8-4: Beispielhafte Aufschlüsselung einer Anomaliebeschreibung.

Durch eine, wie in Abbildung 8-4 aufgezeigte, sequenzielle Aneinanderreihung einzelner Merkmale durch einen Anwender kann ein gesamter Verlauf einer Anomalie beschrieben und in ein standardisiertes, computerlesbares Format übertragen werden. Der untere Teil der Anomaliebeschreibung kann beliebig oft durchgeführt und in eine Syntax überführt werden, um den subjektiven Einfluss des Anwenders zu egalisieren oder mehrere Anomaliecharakteristiken zu beschreiben. Dennoch ist zu beachten, dass die Anzahl an formalisierten Verläufen je Anomalie gering ist. In jedem Fall wird davon

ausgegangen, dass die Fähigkeit eines Anwenders, die Anomalie auf Basis des Wissens über den Datenverlauf korrekt zu beschreiben, vorhanden ist. Der Anwender ist in der Lage Extremwerte des Trendverlaufs wie Start- und Endwerte sowie Minima oder Maxima zu identifizieren und zu analysieren. Des Weiteren ist davon auszugehen, dass der Anwender in der Lage ist, eine QTA auf Basis des zugrundeliegenden Rohsignals durchzuführen. Das Rohsignal kann unter anderem Rauschen aufweisen. Die Erfolgsgüte hängt dennoch maßgeblich von der Erfahrung und dem Prozesswissen des Anwenders ab. Analysen hinsichtlich unterschiedlichen Erfahrungswissens sind in vorliegender Dissertation nicht aufgeführt. Nachfolgend wird die Formalisierung an einem realen Anwendungsfall beispielhaft durchgeführt. Der Anwendungsfall wird ebenso in Kapitel 9.3 zur Anomaliedetektion aufgeführt.

8.1.3 Beispielhafter Anwendungsfall Fräsprozess – Lunker/Poren

Die Validierung der beschriebenen Verfahren erfolgt an einem repräsentativen Anwendungsfall, welcher ebenso als einer von drei Validierungsfällen für das Gesamtsystem in Kapitel 9 genutzt wird. Der Anwendungsfall ist repräsentativ für die Integration von Domänenwissen in Produktionsmaschinen.

Hohlräume in Gussgefügen beispielsweise durch Lufteinschlüsse werden Lunker oder Poren genannt. Meist treten Lunker in der Übergangsphase von flüssigem zu festem Material auf. Dort kommt es selten zu einer Verringerung des Volumens im Werkstück, was eine sogenannte Verlunkerung hervorruft (Degischer 2018).

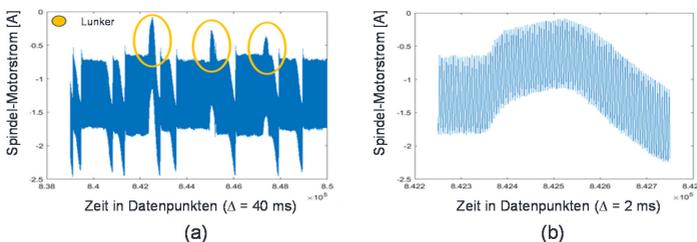


Abbildung 8-5: (a) Lunker-Anomalien in Spindel-Motorstrom, (b) Datenausschnitt eines Lunkers. Darstellung in Anlehnung an (A_Alexander 2021).

Abbildung 8-5 zeigt den Datenverlauf beim Überfräsen von künstlich erzeugten Lunckern (linkes Diagramm, gelb markierte Stromspitzen) in einem Stahlbauteil. Die Luncker sind

dabei durch zylindrische Bohrungen realisiert und entsprechen einer realistischen Ausprägung der Lunkergöße. In (a) ist der Datenverlauf des variierenden Fräsprozesses abgebildet. Es ist ersichtlich, welche Folgen im Spindelstrom beim Überfräsen von Lunkern erkennbar sind. In (b) ist ein Lunkerabschnitt vergrößert dargestellt. Dieser Abschnitt wird nachfolgend zur Formalisierung verwendet. Der Anomalieabschnitt wird von der Anomalieerkennung in entsprechender Form bereitgestellt und bietet Grundlage zur Formalisierung. Der in (b) dargestellte Anstieg des Datenverlaufs ist unter Verwendung der eingeführten Nomenklatur als invers-polynomial zu beschreiben. Der Anstieg wird durch einen nachfolgenden linearen Abstieg abgelöst. Zur eindeutigen Beschreibung der Anomalie sind weitere Angaben zum Fertigungsverfahren, der Maschine sowie dem Signal zu treffen. Anschließend wird die formalisierte Beobachtung als Anomalieprofil abgespeichert. Das Anomalieprofil ist in Tabelle 2 ersichtlich. Weitere ergänzende Regeln werden in Form der Regel-ID hinzugefügt. Dies ermöglicht eine Unterscheidung aller Regeln.

Tabelle 2: Anomalieprofil der Lunker-Anomalie nach (A_Alexander 2021).

Regel-ID: 0001	IF Anwendung = Werkzeugmaschine AND Fertigungsverfahren 1 = Trennen AND Fertigungsverfahren 2 = Fräsen AND Spindel-Motorstrom = (NEU) – (I) – (+) – (L) – (-) – (NEU) THEN Lunker
----------------	---

8.2 Automatisierte Klassifikation über formalisiertes Domänenwissen

Im nachfolgenden Kapitel werden Ansätze zur automatisierten Klassifikation auf Basis der bereits formalisierten Anomalieprofile diskutiert. Die Ergebnisse sind zusammengefasst dargestellt. Analysen und Bewertungen sind in der angeleiteten Arbeit (A_Alexander 2021) entstanden.

8.2.1 Lokale Extremstellensuche

Die Beschreibung von anormalen außenliegenden Randverläufen von Datenbereichen bestimmt die Funktionsweise einer anwendergetriebenen QTA. Diese Bedingung kann auf die rein datenbasierte QTA durch einen Computer übertragen werden. Es erfolgt im ersten Schritt eine Suche nach lokalen Extremstellen in einem definierten Zeitintervall

zwischen Marker 1 und 2. Marker 1 beschreibt den Datenpunkt, an dem der Datenverlauf bei der Anomaliedetektion die Eingriffsgrenze durchbricht. Dies ist der Startwert des Zeitintervalls zur Klassifikation. Marker 2 beschreibt den Datenpunkt, bei dem der Datenverlauf wieder aus dem anomalen Bereich zurückkehrt. Marker 2 ist der Endwert des beschriebenen Zeitintervalls.

8.2.2 Autoskalierung

Um Signalbereiche vergleichbar und analysierbar zu machen, muss eine Normierung auf eine definierte Skala erfolgen. Hierbei ist es wichtig, dass das betrachtete Zeitintervall die gleiche Größe wie das Intervall aus der anwenderseitigen QTA hat. Nur so kann ein automatisierter Abgleich zwischen den online gefundenen Anomalien zu den gespeicherten Anomalieprofilen erfolgen. Die Transformation des Datenintervalls auf eine standardisierte Skala muss unter der Vermeidung von Informationsverzerrung oder -verlust erfolgen. Die Normalisierung transformiert das Datenintervall auf den Ziel-Wertebereich $[0, 1]$. Dadurch kann jedes Subintervall separat analysiert werden. Die Analyse erfolgt schrittweise und beginnend mit dem ersten Subintervall der Anomalie.

8.2.3 Ermittlung lokaler Trendstrukturen

Nachdem die lokalen Extremstellen gefunden wurden und das jeweilige Datenintervall auf eine Normskala transformiert wurde, erfolgt die Extraktion von Merkmalen. Dies erfolgt analog zu den bereits eingeführten Ansätzen der QTA, wird allerdings rein datenanalytisch durchgeführt. Es werden einzelne normalisierte Bereiche einer Anomalie untersucht und mit definierten Trendstrukturen der Nomenklatur verglichen. Das Ergebnis dieses Vergleichs ist ein Referenzfenster, welches ebenso in spezifische Zeitreihenwerte transformiert werden kann. Nachfolgend sind die Trendstrukturen der Nomenklatur als Funktionen dargestellt:

Tabelle 3: Trendstrukturen und deren Darstellung als Funktion

Lokale Trendstruktur	Trendlabel	Umsetzung
Linearer Anstieg	L+	$f(x)_1 = y$
Linearer Abstieg	L-	$f(x)_2 = -y$
Polynomialer Anstieg	P+	$f(x)_3 = x^2$
Polynomialer Abstieg	P-	$f(x)_4 = -x^2 + 1$
Invers-Polynomialer Anstieg	I+	$f(x)_5 = x^{0,5}$
Invers-Polynomialer Abstieg	I-	$f(x)_6 = -x^{0,5} + 1$

Nach der Transformation in das beschriebene Referenzfenster erfolgt eine Fehlerberechnung. Die Fehlerberechnung beruht auf einem iterativen Abgleich der Funktionswerte der Trendstrukturen mit den normalisierten Störungsmesswerten. Bei diesem Abgleich wird ein quadratischer Fehler bestimmt. Im betrachteten Subintervall bestimmt der kleinste Gesamtwert die vorliegende Funktion der Trendstruktur. Eine gesamte Sequenz an Trendstrukturen erfolgt durch das schrittweise Ausführen. Abbildung 8-6 zeigt eine beispielhafte Zeitreihe (roter Verlauf) im Referenzfenster sowie mögliche Trendstrukturen (violette Verläufe).

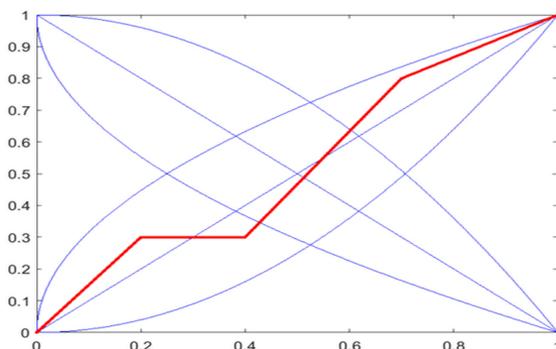


Abbildung 8-6: Beispielhafte Zeitreihe in Referenzfenster mit möglichen Trendstrukturen. Darstellung in Anlehnung an (A_Alexander 2021).

8.2.4 Anomalieprofil-Abgleich

Im letzten Schritt erfolgt der Abgleich der Anomalie, dargestellt durch eine approximierte Trendstrukturfolge mit den Anomalieprofilen aus der anwenderseitigen Formalisierung. Die Anomalieprofile sind in der sogenannten Domänenwissen-Datenbank hinterlegt. Zunächst wird aufgrund von Zustands- und Prozessgrößen eine Vorauswahl an möglichen Anomalien getroffen. Die Vorauswahl wird durch einfache Filterung hinsichtlich der Speicherstruktur durchgeführt. Merkmale der Filterung sind Anwendungsbe-
reich, Merkmalsraum und ggf. Fertigungsverfahren. Diese Filterung ist notwendig, um ähnlich verlaufende Anomalien bei unterschiedlichen Anwendungen differenzieren zu können und reduziert den Rechenaufwand deutlich. Aufgrund der ausgewählten Anwendungsbeispiele, welche lediglich durch zwei lokale Trendstrukturen beschreibbar sind, kann eine spezifische Abgleichslogik zur Wiedererkennung entwickelt werden. In

Abbildung 8-7 sind zwei Anomalietypen dargestellt. Es ist zu erkennen, dass der Abgleich der Trendstrukturen über einen Ähnlichkeitskoeffizienten erfolgt. In Gelb ist der online erkannte Ist-Verlauf der Anomalie nach Abgleich der Trendstrukturen dargestellt. Zu erkennen ist, dass der Anomalietyper 1 eine Überdeckung mit dem Ist-Verlauf von 1 hat. Anomalietyper 2 weist eine Überdeckung von 0,5 auf. Da das Ähnlichkeitsmaß $k > 0,5$ sein muss erfolgt die Ausgabe des Typs 1 (Lunker).

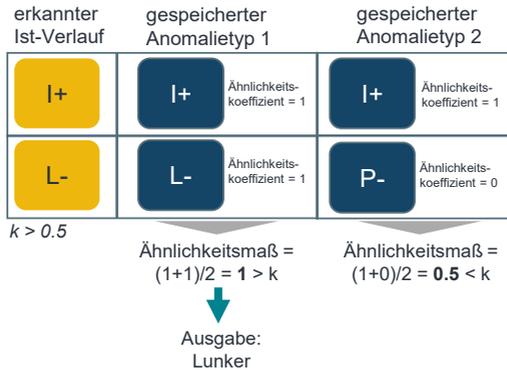


Abbildung 8-7: Ähnlichkeitsberechnung zwischen Trendsequenzen und gespeicherten Trendsequenzen. Darstellung in Anlehnung an (A_Alexander 2021).

Die Erfolgsgüte des Vergleichs und Anomalietyps hängt maßgeblich von der Implementierung und Wahl des Ähnlichkeitsmaßes ab. In vorliegender Dissertation wird im Allgemeinen zwischen drei Fällen unterschieden. Der erste Fall beschreibt die Situation, dass keine Übereinstimmung der Trendstrukturen vorliegt. Dann ergibt sich der Wert 0. Im zweiten Fall ist lediglich eine von zwei möglichen Übereinstimmungen einer Trendstruktur vorzufinden. Der Wert des Ähnlichkeitsmaßes ist dann 0,5. Eine Unterscheidung der Gleichheit erfolgt zunächst nicht. Sollte eine Gesamtübereinstimmung (Fall drei) auf allen Ebenen (Prozesszustände und Trendstrukturen) erkannt werden, ist der Wert des Ähnlichkeitsmaßes 1. In jedem Fall ist ein Grenzwert k eingeführt, welcher die Eindeutigkeit der Klassifikation gewährleistet. Der Grenzwert muss überschritten werden, sodass eine Ausgabe der Klassifikation erfolgen kann. Die Ausgabe erfolgt in Form der Anomalieerkennung-App (vgl. Kapitel 9.2)

8.2.5 Fazit der Formalisierung von Domänenwissen

Die Erprobung der beschriebenen Ansätze erfolgte anhand zwei industriell relevanter Anwendungsfälle in (A_Alexander 2021). Es konnte gezeigt werden, dass die Ansätze zur Formalisierung von Anwenderwissen sowie die Klassifikation im Allgemeinen funktionsfähig sind. Die anwendungsspezifischen Anomalien, welche zur Erprobung ausgewählt wurden, sind mittels einer Trendbeschreibung formalisiert und unter a priori Wissen zur Klassifikation angewandt.

Die eingeführte Nomenklatur, bestehend aus sechs Trendstrukturen, welche in ein Referenzfenster normiert und dann in ein Anomalieprofil überführt werden, erzielte eine hinreichende Unterscheidbarkeit der Anomalietypen. Die Einführung von Schwell- und Grenzwerten bei der Ähnlichkeitsbewertung erwies sich als zielführend. Allerdings beeinflusst die Wahl der Grenzwerte die Klassifikationsgüte entscheidend. Des Weiteren ist die Güte der Klassifikation direkt mit den Erfahrungswerten der Anwender gekoppelt. In vorliegender Dissertation erfolgte keine Validierung der Ansätze mit unterschiedlichem a priori Wissen. Dennoch kann von einem erfolgreich entwickelten Ansatz gesprochen werden, da die anwendergetriebene Klassifikation als zusätzliche Möglichkeit neben der datengetriebenen Klassifikation Anwendung finden kann. Hier ist zu beachten, dass mit großer Wahrscheinlichkeit die Klassifikationsgüte der datengetriebenen Ansätze bei steigender Datenmenge zunimmt und die Entscheidung aufgrund von Anwenderwissen abnimmt.

9 Umsetzung und Validierung der Anomalieerkennung

In den nachfolgenden Kapiteln werden die in dieser Dissertation eingeführten Verfahren validiert und in Form einer App programmieretechnisch implementiert. Zuerst wird die Architektur vorgestellt sowie der Aufbau und Funktionsweise der App beschrieben. Die Implementierung erfolgt mittels der Programmierumgebung *MATLAB*¹ (Pietruszka & Glöckler 2021). Anschließend erfolgt die Validierung der Verfahren an drei ausgewählten, industriell relevanten Anwendungsfällen. Nachfolgend werden fünf Gründe erläutert, welche für die Auswahl der Anwendungsfälle herangezogen wurden.

Die Anwendungsfälle sollen eine hohe Praxistauglichkeit (1) sowie eine Repräsentativität (2) sicherstellen. Zudem ist für die Validierung der Methodik zu gewährleisten, dass die Anwendungsfälle unterschiedliche Fertigungsverfahren (3) sowie kinematische Strukturen (4) von Maschinen widerspiegeln und damit eine Übertragbarkeit sichergestellt ist. Ein kausaler Zusammenhang (5) der Prozesskraft und damit einhergehenden Prozessstörungen am Endeffektor der Maschine mit dem zu messenden Signal muss in allen Anwendungen gewährleistet sein.

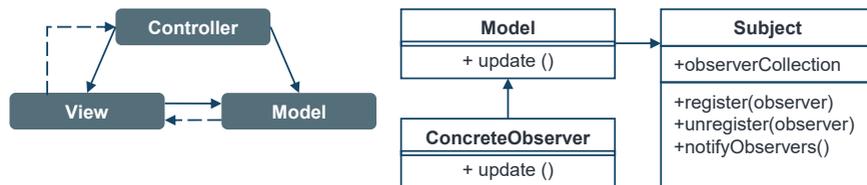
Daraus ergeben sich abgeleitet nachfolgende Anwendungen, welche für die Validierung der Verfahren genutzt werden. Im ersten Validierungsteil wird die Systematik an einer Fräsmaschine zur Qualitätsüberwachung analysiert. Anschließend erfolgt eine weitere Überprüfung der Funktionen an einer hochflexiblen Transportkinematik zur Bauteilverlustüberwachung. Der letzte Validierungsfall zeigt die Funktionsfähigkeit der Verfahren an einer gekoppelten Anlagenstruktur zum Fügen von Elektromotoren-Komponenten.

9.1 MVC Ansatz – Die Architektur

Diese Arbeit verwendet für die Implementierung der Verfahren das sogenannte *MVC*³-*Pattern* (Curry & Grace 2008). Bei diesem Architekturmuster werden die Bestandteile der Verfahren in das zugrundeliegende Datenmodell (engl.: model), die Präsentation oder Benutzeroberfläche (engl.: view) sowie die Programmsteuerung (engl.: controller) unterteilt. Das Entwurfsmuster ermöglicht die Trennung grundlegend verschiedener Programmbestandteile und damit die unabhängige Bearbeitung von Komponenten während der Softwareentwicklung. Somit lassen sich beispielsweise mehrere Varianten

³ MVC steht für Model, View und Controller.

verschiedener Klassen oder Oberflächen parallel implementieren, ohne die Funktionsweise des Datenmodells anpassen zu müssen. Abbildung 9-1 (a) veranschaulicht das Zusammenspiel von Modell, Präsentation und Steuerung.



(a) Darstellung des MVC Konzepts

(b) UML Klassendiagramm für den „observer pattern“

Abbildung 9-1: Veranschaulichung des MVC-Konzepts (a) und des Observer-Patterns (b). Darstellung nach (A_Martin 2020).

Über die Einstellungen der Verfahren können verschiedene Methoden ohne weiteres ausgetauscht werden. Diese Modularität ermöglicht das einfache Validieren und Testen unterschiedlicher Programmbestandteile sowie eine entwickler-freundliche Implementierung. Darüber hinaus vereinfachen die definierten Schnittstellen der MVC-Architektur das Hinzufügen von neuen Komponenten und Verfahren. Des Weiteren verwendet die Anwendung der Anomalieerkennung das sogenannte *Observer-Pattern* (dt.: Beobachter-Muster). Dieses ermöglicht eine vom Anwender gesteuerte und komponentenübergreifende Kommunikation. Durch das Registrieren oder Deregistrieren einer Komponente, dem Observer (dt.: Beobachter), bei einer weiteren Komponente (Subject) können weiterführende Programmbestandteile angeschlossen oder abgetrennt werden. Demnach kann beispielsweise die an die Online-Mustererkennung anschließende Anomalieerkennung bedarfsgerecht hinzugeschaltet werden. Diese Möglichkeit begünstigt vor allem das Entwickeln, Testen und Validieren einzelner Programmkomponenten unabhängig von anderen Bestandteilen und spart Rechenzeit, wenn nur Teile eines Algorithmus relevant sind. Abbildung 9-1 (b) zeigt die Funktionsweise des Observer-Patterns grafisch.

9.2 Aufbau und Funktionsweise der Anomalieerkennungs-App

Die aufgeführten Verfahren sind im nachfolgenden Kapitel in Form einer App dargestellt. Somit lassen sich Verfahren in realen Anwendungsszenarien validieren und deren Funktionsweise bewerten. Dazu wird nachfolgend zuerst der grundsätzliche Aufbau der App dargestellt. Die Interaktion der Methodenbausteine erfolgt gemäß des beschriebenen MVC-Ansatzes. Im Wesentlichen unterscheiden sich die Funktionen in der App nach Offline- und Online-Funktionalitäten. Im ersten Schritt werden aufgenommene historische Zeitreihen im sogenannten OPR-Teil (*offline pattern recognition*) nach Prozessmuster segmentiert. Abbildung 9-2 zeigt die App in ihrer Grundform im Reiter „OPR“. Die gefundenen Repräsentanten aus der Datensegmentierung können dort grafisch dargestellt und zu jeder Zeit eingesehen werden. Dies ermöglicht dem Anwender eine grafische Kontrolle der gefundenen Prozesse. Des Weiteren können über weitere Darstellungen, wie die Verteilung der Muster oder die Liste der Segmentierungs-Durchläufe, Informationen zum Betrieb der App eingesehen werden. Die Einstellungen zur Erkennung von Mustern werden im Bereich der „settings“ gewählt.

Eine Erläuterung der Settings ist in Kapitel 5ff. sowie im Anhang gegeben. Weitere ausführliche Informationen zur programmiertechnischen Umsetzung der App sind in den angeleiteten Arbeiten (A_Baier 2021) (A_Begemann 2021) (A_Winkler 2020) (A_Köhler 2020) (A_Wurche 2020) (A_Michelberger 2019) sowie der Publikation (Netzer & Palenga et al. 2021) einsehbar.

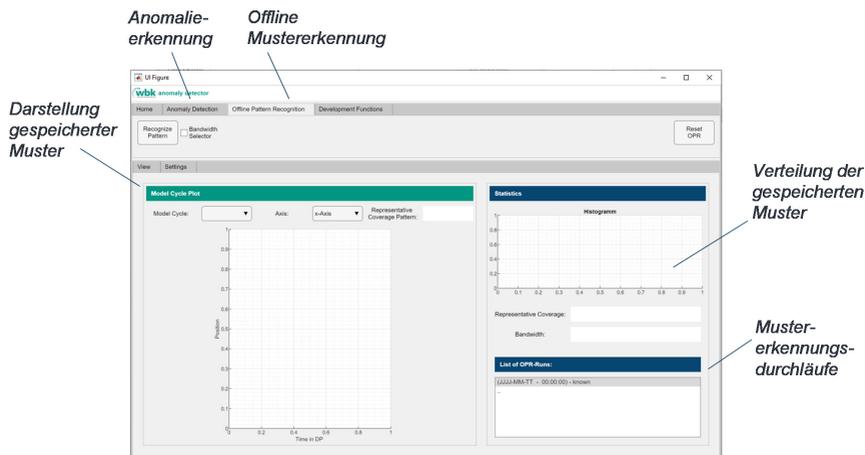


Abbildung 9-2: App zur Anomalieerkennung. Darstellung des Reiters zur Mustererkennung „OPR“.

Nach der Erkennung von Segmenten im Bereich der „OPR“ erfolgt im nächsten Schritt das Wiederfinden der Muster im Online-Signal der Maschine. Die Wiedererkennung läuft automatisch ab und der Anwender kann relevante Informationen zum „Score“ sowie einer grafischen Darstellung der wahrscheinlichsten Muster einsehen. Abbildung 9-3 zeigt den zweiten Reiter der App als „Anomaly Detection“. Dort sind zudem die Online-Referenz- sowie Informationssignale analysierbar. Des Weiteren werden Anomalien in einer Liste gespeichert, um diese nachträglich analysieren und bewerten zu können.

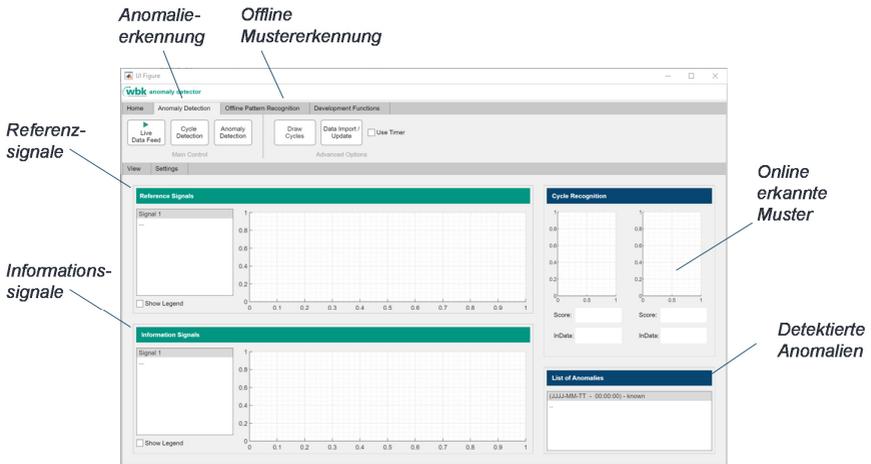


Abbildung 9-3: Darstellung des Reiters „Anomaly Detection“.

Bei einer erfolgreichen Detektion einer Anomalie öffnet sich automatisch ein weiteres Fenster (siehe Anhang, Abbildung 0-1), in dem alle Informationen über die jeweilige Anomalie dargestellt sind. Dort werden die Signale der Anomalie im Vergleich zum i.O.-Verlauf des gespeicherten Repräsentanten dargestellt. Somit kann der Anwender die Anomalie-Entscheidung einsehen und bewerten. Zur Bewertung dieser Anomalien ist ein Feedback-Loop Verfahren entwickelt. Durch Negieren oder Akzeptieren der Anomalie erfolgt ein Informationsruckfluss in das System, welcher eine Genauigkeitssteigerung bewirkt. Zudem werden dem Anwender weitere Informationen wie mögliche Klassifikationsergebnisse durch datengetriebene Klassifikation oder bereits formalisiertes Domänenwissen zur Verfügung gestellt. Der Anwender kann Handlungsempfehlungen einsehen oder, wenn diese noch nicht vorhanden sind, neue Informationen hinterlegen.

Im nachfolgenden Kapitel werden die Funktionsweise der Verfahren und die Praxistauglichkeit der App an drei industriell relevanten Beispielen validiert.

9.3 Anwendung 1: Prozessüberwachung bei der Zerspanung

Moderne Werkzeugmaschinen und Bearbeitungszentren sind durch industriell etablierte Sensorik wie bspw. den Einsatz von Körperschallsensoren oder Kamerasystemen gekennzeichnet. Dies bietet großes Potential zur Datenaufnahme und -verarbeitung hinsichtlich einer Störungserkennung. Ältere Werkzeugmaschinen sind dagegen nur eingeschränkt ausgerüstet und weisen eine geringe Datenqualität auf. Das nachfolgende Kapitel soll die Validierung der erläuterten Verfahren aufzeigen und führt ein industriell relevantes Anwendungsbeispiel (Netzer & Begemann et al. 2021) in der zerspanenden Fertigung auf. Anomalien im zerspanenden Fertigungsprozess können auf vielfältige Arten auftreten. Ein klassisches Beispiel für eine fortlaufende Anomalie ist der Verschleiß am Werkzeug oder in Komponenten der Vorschubachsen. Durch Verschleiß eines Fräsers wird beispielsweise die Prozesskraft erhöht, was sich in der Spindelleistung widerspiegelt. Dies verkürzt auf Dauer nicht nur die Lebensdauer des Antriebs, sondern kann auch zu schlechteren Oberflächenqualitäten und -toleranzen oder auch zum vollständigen Bruch des Werkzeugs führen.

Eine weitere industriell relevante Problematik bei Fräsprozessen, im Speziellen bei der Gusszerspanung, ist das Vorkommen von Lunkern oder Poren (Degischer 2018) (Netzer, Michelberger & Fleischer 2019) (Netzer & Palenga et al. 2021). Hier kommt es zu unerwünschten Lufteinschlüssen beim Erkalten des Materials. Lunker/Poren reduzieren die Festigkeit des Bauteiles maßgeblich und können oft nicht ohne größeren Mehraufwand während des Prozesses detektiert werden (Mohanraj & Shankar et al. 2020).

Für die Erkennung der Anomalien muss nun zunächst betrachtet werden, welche Daten an herkömmlichen Brownfield CNC-Maschinen als Grundlage zur Verfügung stehen. Neben den typischen Positionsdaten wie beispielsweise dem Positionsverlauf der Maschinenachsen sowie deren zeitlichen Ableitungen stehen an klassischen Werkzeugmaschinen eine Vielzahl an weiteren Informationssignalen zur Auswertung zur Verfügung. Zu den Informationssignalen gehören beispielsweise Momente resp. Motorströme aus verschiedenen Motoren. Diese Informationen stehen i.d.R. auch an älteren Maschinengenerationen zur Verfügung, werden aber in aller Regel nicht ganzheitlich ausgewertet. Nachfolgendes Anwendungsbeispiel bezieht sich auf die bereitgestellten Steuerungsdaten und geht nicht auf etwaige Herausforderungen bei der Datenaufnahme ein.

Bei Kleinserien mit geringer Stückzahl ist die aufzunehmende Datenmenge je Prozess meist gering. Die vorliegende Dissertation beschreibt ein Verfahren, mit Hilfe dessen gleiche Prozesssegmente trotz geringer Stückzahl bestimmbar sind. Abbildung 9-4 zeigt ein beispielhaftes Portfolio unterschiedlicher Bauteile, jedoch mit gleichem Prozesssegment (einer Passfedernut). Im vorliegenden Anwendungsfall ist allerdings zu beachten, dass jegliche Randbedingungen, wie zum Beispiel das verwendete Werkzeug, identisch sind. Es wird ebenso von einer Laborumgebung ausgegangen.

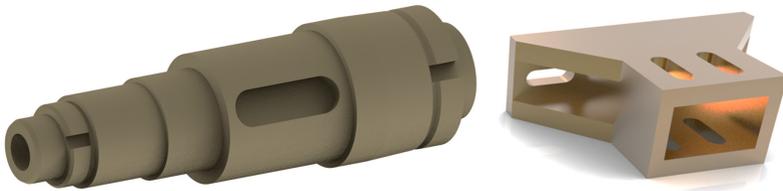


Abbildung 9-4: Beispielhaftes Produktportfolio mit gleicher Passfedernut und somit Prozesssegment.

Im Folgenden wird untersucht, ob die beschriebenen Verfahren dieser Dissertation in Form der aufgeführten App an einem realen Anwendungsfall validiert werden können. Des Weiteren werden potenzielle Einschränkungen und Verbesserungspotentiale der Verfahren abgeleitet und bewertet. In (Netzer & Palenga et al. 2021) (Netzer, Michelberger & Fleischer 2019) sowie den angeleiteten Arbeiten (A_Winkler 2020) (A_Beegmann 2021) (A_Baier 2021) sind die Versuchsreihen analysiert. Nachfolgende Erläuterungen geben die Ergebnisse zusammengefasst wieder.

9.3.1 Versuchsdurchführung und Ergebnisse

In der Versuchsreihe wurden insgesamt sieben Fräsversuche durchgeführt. Als Fräsmaschine wurde dabei eine CNC gesteuerte 6-Achs-Fräsmaschine verwendet. Pro Fräsversuch wurden dabei jeweils 16 Taschen in Form einer abgerundeten, rechteckigen Geometrie gefräst. Der Fräsprozess wurde über drei Zustellungen realisiert. Abbildung 9-5 gibt Einblick in den Fräsversuch und visualisiert im linken Bild die Bedienoberfläche der Fräsmaschinen im Prozess.

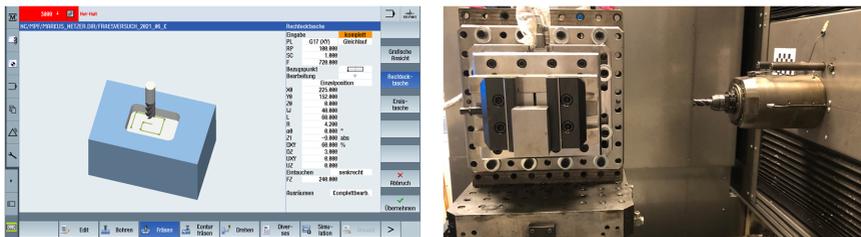


Abbildung 9-5: links: Darstellung einer Fräsoperation in Steuerungsoberfläche, rechts: Einblick in Fräsmaschine.

Ein CAD Modell des Bauteils ist in Abbildung 9-6 abgebildet. Als Halbzeug für die Fräsversuche kam ein unbearbeiteter Einsatzstahl 16MnCr5 zum Einsatz. Bei den Versuchen wurde der gleiche Stahl mit jeweils acht Bohrungen mit Durchmesser 1,5 - 3 mm verwendet. Diese Bohrungen befinden sich im Bereich der letzten vier Taschen und dienen dabei als künstlich erzeugte Lunker, siehe Abbildung 9-6. Die 16MnCr5-Platte hat eine Dicke von 15 mm. Der verwendete Schafffräser ist ein 3-Schneiden VHM-Fräser mit einem Durchmesser von 8mm. Für alle Versuche wurde der identische NC-Code verwendet.

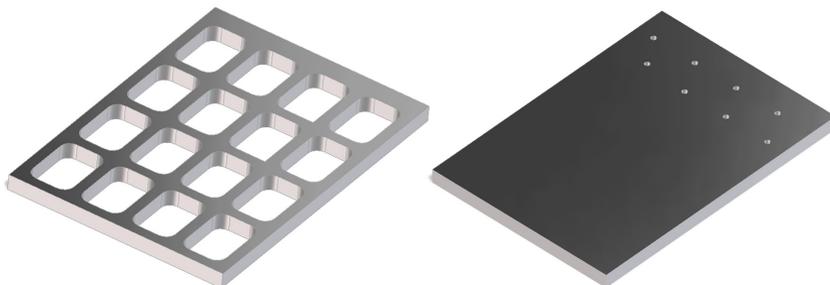


Abbildung 9-6: links: CAD Modell des fertigen Bauteils, rechts: CAD Modell des Halbzeuges.

Die hohe Anzahl an gleichen Segmenten wurde bewusst gewählt, da die Validierung der Anomalieerkennung im Vordergrund stand. Der Nachweis unterschiedliche Prozesssegmente in unterschiedlichen Bauteilen zu detektieren ist in (Netzer, Michelberger & Fleischer 2020) (Netzer, Michelberger & Fleischer 2019) einsehbar und bereits

validiert. Für die vorliegende Versuchsreihe erfolgte die Datenaufnahme über eine industrial edge⁴ einer SIEMENS-Steuerung. Die Daten wurden mit einer Frequenz von 500Hz bereitgestellt. Durch die Fräsdauer von ungefähr zwei Minuten ergeben sich dabei Zeitreihen von jeweils 1 200 000 Datenpunkten. Die bereitgestellten Datenreihen, die Signalart sowie der Verwendungszweck der jeweiligen Verfahren sind aus Tabelle 4 zu entnehmen.

Tabelle 4: Übersicht der verfügbaren Daten aus der Steuerung

Nummer	Benennung	Signalart	Verwendungszweck
1	Number of Data Point	Informationssignal	Muster-/Anomalieerkennung
2	Position X-Axis	Referenzsignal	Mustererkennung
3	Position Y-Axis	Referenzsignal	Mustererkennung
4	Position Z-Axis	Referenzsignal	Mustererkennung
5	Position rot. Axis	Informationssignal	Anomalieerkennung
6	Position Spindle Axis	Informationssignal	Anomalieerkennung
7	Motor Current X-Axis	Informationssignal	Anomalieerkennung
8	Motor Current Y-Axis	Informationssignal	Anomalieerkennung
9	Motor Current Z-Axis	Informationssignal	Anomalieerkennung
10	Motor Current rot. Axis	Informationssignal	Anomalieerkennung
11	Motor Current Spindle Axis	Informationssignal	Anomalieerkennung
12	Torque X-Axis	Informationssignal	Anomalieerkennung
13	Torque Y-Axis	Informationssignal	Anomalieerkennung
14	Torque Z-Axis	Informationssignal	Anomalieerkennung
15	Torque rot. Axis	Informationssignal	Anomalieerkennung

In Abbildung 9-7 ist der Verlauf der kartesischen Koordinatensignale während des Fräsprozesses dargestellt. Zu erkennen sind Zeitreihen der Positionsverläufe X, Y und Z. Alle Positionsverläufe sind Referenzsignale und bei jedem der sieben Versuche identisch. Der Positionsverlauf X zeigt wiederkehrende Segmente auf drei X-Niveaus. Es ist zu erkennen, dass eine Offset-Normalisierung notwendig ist, sodass alle Segmente miteinander gleichermaßen verglichen werden können.

⁴ SIEMENS AG (2022). *industrial edge*, Abgerufen am 20.01.2022, von <https://new.siemens.com/de/de/produkte/automatisierung/themenfelder/industrial-edge/werkzeugmaschinen.html>

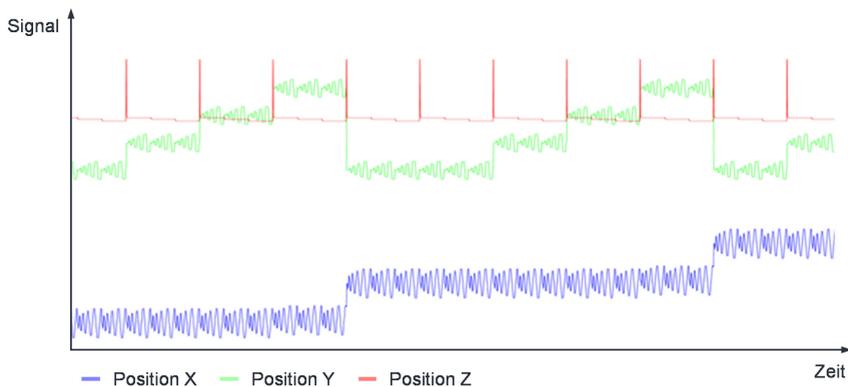


Abbildung 9-7: Darstellung der Referenzsignale (Achsen X,Y,Z) für die Datensegmentierung.

Anschließend erfolgt der Import der Daten in die initiale Datensegmentierung. Hier erfolgt die automatische Bestimmung der Prozesssegmente auf Basis derer anschließend die Anomalieerkennung durchgeführt werden kann. In der Validierungsumgebung wurde die Anzahl der zu detektierenden Muster für jede der drei Koordinatenachsen definiert. Es ergeben sich aus der Position der zeitlichen Minima beispielsweise sechs Muster in der X-Achse. In der Y- und Z-Achse sind fünf beziehungsweise zwei Muster zu erkennen. Insgesamt wurden durch die Datensegmentierung mit den gewählten Parametern 25 verschiedene granulare Repräsentanten erkannt. Abbildung 9-8 zeigt einen Ausschnitt der Y-Achse und in grün dargestellt die gefundenen Segmente. In Rot dargestellt ist der angewählte Repräsentant (rechts im Diagramm vergrößert in schwarz dargestellt) sowie das Vorkommen in der gesamten Zeitreihe. Als Distanzmetrik für das Clustering wurde die erweiterte euklidische Distanz genutzt. Alle Zeitreihen wurden in einem Vorverarbeitungsschritt zweifach geglättet.

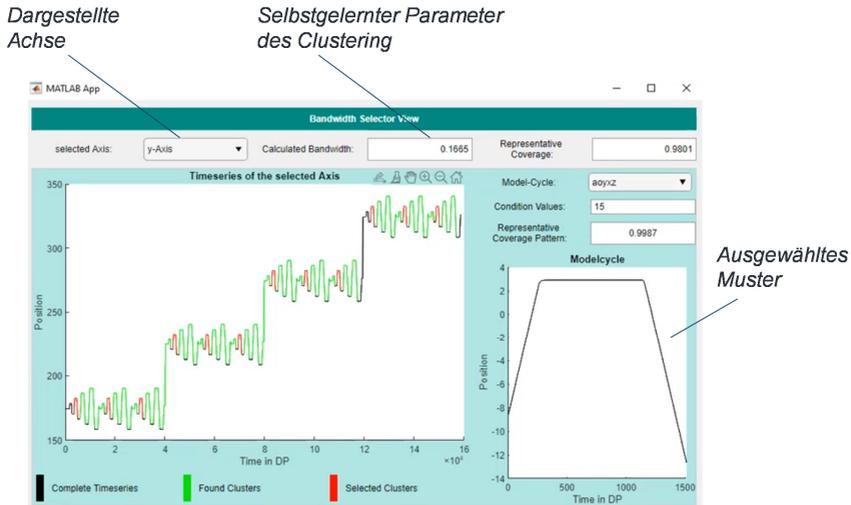


Abbildung 9-8: Beispielhafte Darstellung des gefundenen Repräsentanten in der App.

Auf Basis der Offline-Datensegmentierung startet der Prozess der Anomalieerkennung mit integrierter Online-Mustererkennung. Für die Online-Mustererkennung wurden eine *DetectionThreshold* von 0,05 und eine *PredictionDifference* von 0,35 festgelegt. In der Anomalieerkennung sind pro Repräsentant 20 Datenpunkte außerhalb des Toleranzbandes zulässig, bevor eine Anomalie ausgegeben wird. Im ersten Schritt der Validierung werden zunächst die Daten von Versuch 1 als Trainingsdatensatz zusammen mit den initialen Daten der Offline-Datensegmentierung importiert. Die Daten aus Versuch 2 wurden anschließend importiert und analysiert. In Versuch 2 war noch kein nennenswerter Verschleiß zu erwarten. Das Verfahren bzw. die programmiertechnische Umsetzung zeigte echtzeitnah an, welches Prozesssegment detektiert wird. Das detektierte Segment wurde mit einer Wahrscheinlichkeit von 98 % (Score von 0,02) bei 22% der Datenpunkte im Online Signal aufgefunden. Die Anomalieerkennung wird parallel zur Online-Mustererkennung durchgeführt. Abbildung 9-9 zeigt die detektierte Anomalie eines Lunkers resp. deren Zeitreihe (in schwarz dargestellt) sowie die Vergrößerung des anomalen Bereichs. Des Weiteren sind die selbstgelernten Toleranzgrenzen zu erkennen (violette Linienkontur). Diese sind durch ein intelligentes Clusterverfahren bestimmt und beschreiben die Eingriffsgrenzen des Ansatzes. In Rot hervorgehoben sind die Signalspitzen außerhalb der Toleranzgrenzen.

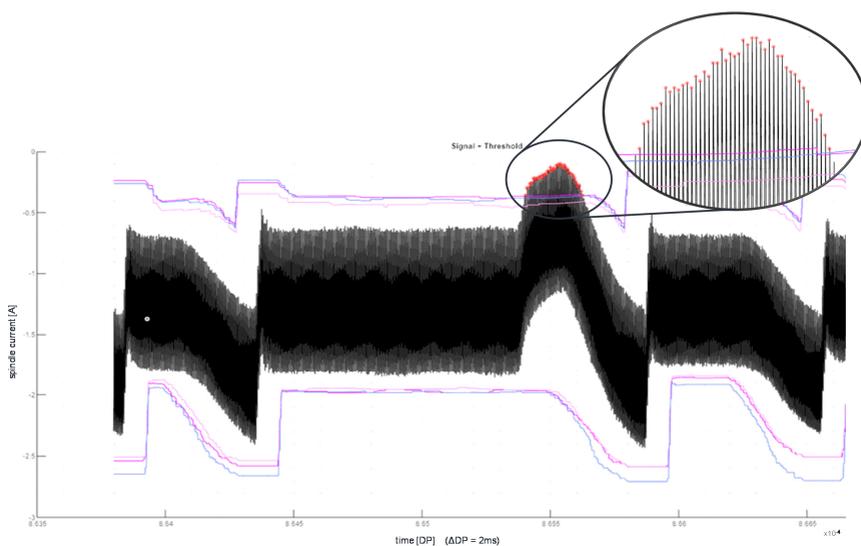


Abbildung 9-9: Datenreihe zum Spindelmotorstrom mit farbig markiertem Toleranzband. (Lunker). Darstellung in Anlehnung an (Netzer, Palenga & Fleischer 2022).

Durch diese Diagramme ist anschaulich gezeigt, dass die Verfahren in der Lage sind, Lunker im Allgemeinen erfolgreich zu detektieren. Der Einfluss der Lunkerbohrungen nimmt jedoch in den Versuchsdaten bei jeder Fräsebene ab. Das Verfahren konnte auch in den anderen Datensätzen V2-V7 erfolgreich Lunker detektieren. Die beschriebenen Verfahren konnten demnach als Funktionsnachweis in einem industriell relevanten Anwendungsfall validiert werden. Im Anschluss an die erfolgreiche Lunkererkennung wurden Versuchsdaten für den Verschleiß ausgewertet. Hierzu wurden die Daten der ersten drei Fräsversuche als Trainingsdaten verwendet. Im Anschluss sind damit die Fräsdaten von Versuch 7, bei dem merklicher Verschleiß erkennbar war, ausgewertet.

Analog zu den zuvor erläuterten Abbildungen werden auch hier die vom Verfahren erzeugten Anomalieerkennungswerte und Diagramme analysiert. Im Gegensatz zum Anwendungsfall Lunker/Poren sind deutlich mehr als 100 Datenpunkte außerhalb des Toleranzgrenzwertes erkennbar. Aus diesem Grund wird diese Anomalie folgerichtig als sogenannte kontinuierliche Anomalie detektiert. Auch in diesem Fall lassen sich wieder

weitere Informationen zum Repräsentanten, dem Score und den zugehörige Datenpunkten analysieren. Der Score beträgt 0,024012 (~98% Vorkommenswahrscheinlichkeit des Prozesssegments) und ist damit hinreichend klein. Abbildung 9-10 stellt den Verlauf der Datenpunkte innerhalb des erkannten Musters dar.

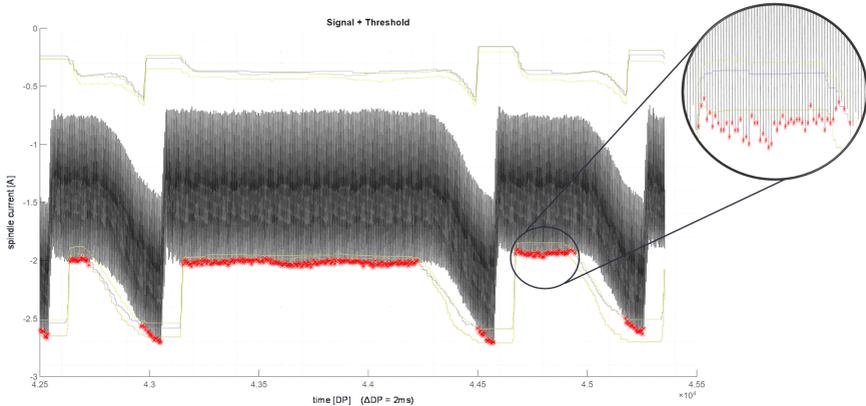


Abbildung 9-10: Datenreihe zum Spindelmotorstrom mit farbig markiertem Toleranzband. (Verschleiß).

Dieses Diagramm kann analog zu Abbildung 9-9 interpretiert werden. Auffällig ist in diesem Fall, dass die schwarzen Datenpunktverläufe im Toleranzfeld nach unten verschoben sind, sodass 340 Datenpunkte unterhalb des selbstgelernten Toleranzfeldes (gelbe Linienkontur) liegen. Im Vergleich zu Abbildung 9-9 lässt sich darüber hinaus feststellen, dass im Verschleißfall zwar eine deutlich größere Menge an Punkten außerhalb des Toleranzfeldes sind, diese aber, je nach Verschleißgrad, mitunter eine vergleichsweise geringe Distanz zum Toleranzgrenzwert haben. Die vorangegangene Abbildung 9-10 zeigt lediglich die Verschleißerscheinungen bei Fräsversuch 7. Die Ergebnisse wurden darüber hinaus mit den anderen Versuchsdaten verglichen. Es konnte gezeigt werden, dass der ansteigende Verschleiß mit Hilfe der intelligenten Anomalieerkennung erkannt wird. Die Versuchsreihen in der Validierung gewährleisteten die Funktionsfähigkeit der Verfahren.

9.3.2 Bewertung und Grenzen

In den vorherigen Kapiteln konnte gezeigt werden, dass der eingeführte Ansatz erfolgreich anwendbar ist, Anomalien unterschiedlicher Länge am Beispiel von künstlich erzeugten Lunkern und Werkzeugverschleiß im Zeitbereich zu detektieren. Es ist jedoch zu beachten, dass die Wahl der zulässigen Datenpunkte im anormalen Bereich maßgeblich über den Erfolg der Detektion entscheidet. Die Einstellung bedarf einiger Erfahrung, ist aber nach einer Inbetriebnahmefahrt in der Regel korrekt eingestellt. Ein zu klein gewählter Toleranzbereich zur Erkennung von Anomalien führt zu einer Ausgabe von sogenannten Falsch-Positiven. Es werden dann fälschlicherweise Anomalien ausgegeben, obwohl keine reale Anomalie vorliegt. Dem gegenübergestellt führt ein zu breit gewählter Toleranzbereich dazu, dass beispielsweise Verschleiß zu spät erkannt wird. Dieser Zielkonflikt ist ein prinzipbedingter Nachteil des Konzeptes. Wie bereits aufgeführt ist eine Annäherung der Parameterfelder und der Sensitivität in einer Inbetriebnahmefahrt möglich. Erfahrungswerte aus anderen erfolgreichen Versuchen sind als Standard-Werte hinterlegt. Die untersuchten Prozesse sind quasi statisch und es werden keine externen Umgebungseinflüsse betrachtet. Das Verfahren ist nicht geschwindigkeitsinvariant. Unterschiedliche Geschwindigkeiten wie Drehzahl führen demnach zu unterschiedlichen Segmenten, was unter Umständen ein weiterer Nachteil des Systems ist.

Zur Bestimmung der Prozesssegmente werden aktuell drei Raumrichtungen mit kartesischen Koordinaten verwendet. Diese drei Dimensionen sind bei komplexeren Fräsanwendungen für eine eindeutige Bestimmung des Prozesssegmentes nicht ausreichend. Diesem Problem kann aktuell durch die Verwendung von Statusvariablen, analog zu den im Stand der Technik beschriebenen Ansätzen zum sogenannten Indexing (Putz & Frieß et al. 2016), entgegnet werden. Eine zusätzliche Dimension für Referenzsignale mit der Möglichkeit zur Angabe der Winkel und -geschwindigkeit sollte für weitere komplexere Fräsbearbeitungen realisiert werden.

Mit Blick auf den Versuchsablauf ist generell festzuhalten, dass sich die verwendeten Bohrungen zur Nachbildung von Lunkern an der Größe der Literaturangaben richten, in der Realität aber keine zylindrische Form aufweisen. Dennoch kann die Versuchsreihe als repräsentativ gewertet werden, da die Anomalien weit im anormalen Bereich liegen. Da verschiedene Anomalien auch einen unterschiedlichen Einfluss auf die erwartete Lebensdauer haben können, ist es unter Umständen notwendig, Anomalien

nicht nur anhand der Anzahl der Punkte außerhalb des Toleranzbandes zu bewerten, sondern zusätzlich auch die Entfernung des Datenpunktes von der Toleranzgrenze mit-einzubeziehen. So könnten Anomalien wie beispielsweise Lunker ab einer gewissen Moment- beziehungsweise Stromüberhöhung zusätzlich automatisch zum Anomaliefall führen, wohingegen Lunker mit niedrigen Erhöhungen beispielsweise nur eine Warnmeldung generieren.

9.4 Anwendung 2: Bauteilverlustüberwachung einer Transportkinematik

Im nachfolgenden Kapitel erfolgt die Validierung der aufgeführten Verfahren anhand eines weiteren industriell relevanten Anwendungsbeispiels. Des Weiteren wird aufgrund der Diversität der Anwendungsfälle eine implizite Übertragbarkeit der Ansätze sichergestellt. Es wird aufgezeigt, dass kein großer Applikationsaufwand bei der Übertragung der Verfahren auf neuartige Anwendungsfälle notwendig ist. Der in diesem Kapitel vorgestellte Anwendungsfall beschreibt die Prozessüberwachung einer Transportkinematik. Serielle Knickarmroboter sind fester Bestandteil einer automatisierten Produktionsanlage. Meist werden sie für nicht-wertschöpfende Tätigkeiten wie Handhabung eingesetzt. Flexiblere Produktionsanlagen nutzen spezielle Endeffektoren an den Knickarmrobotern um Fertigungsprozesse auszuführen. Der Einsatz von Knickarmrobotern weist in der Regel eine hohe Prozessvielfalt und Flexibilität der Produktion auf. Industrielle Robotersysteme haben i. d. R. integrierte Sensoren zur beispielsweise Überlasterkennung verbaut. Diese Systeme sind durch einen Anwender zu konfigurieren und sind ebenso durch feste Eingriffsgrenzen charakterisiert. In hochflexiblen Produktionsabläufen stoßen die anwenderbasierten Konfigurationen aufgrund der großen Regelkette oder der geringen Datenmenge bei lernenden Verfahren an ihre Grenzen. Die vorgestellten Verfahren dieser Dissertation eignen sich daher für die Anwendung im aufgeführten Anwendungsfall. Ziel dieser Validierung ist das Detektieren und spätere Vermeiden von Stillständen. Stillstände können beispielsweise durch Bauteilverlust beim Transportieren oder eine unerwartete Krafterhöhung beispielsweise durch Crash entstehen.

Eine weitere Herausforderung ist die Vielzahl an Freiheitsgraden im System. Wird ein 6-Achsen Industrieroboter betrachtet, dann fällt auf, dass die Position des Roboters im verfügbaren Arbeitsraum durch sechs Gelenkwinkel definiert ist und nicht nur durch zwei oder drei kartesische Koordinaten wie es bei einfachen Dreh- oder Fräsmaschinen

der Fall ist. Hinzu kommen oft weitere externe Freiheitsgrade beispielsweise durch einen angeschlossenen pneumatischen Greifer. Das Definieren und Wiedererkennen von sich wiederholenden Bewegungsmustern ist um ein vielfaches komplexer.

9.4.1 Versuchsdurchführung und Ergebnisse

Die Validierungsversuche wurden mit Hilfe eines KUKA KR6 R900-2 Industrieroboters durchgeführt. Um verschiedenartige Anomalietypen nachzubilden werden nachfolgend zwei separate Versuchsreihen beschrieben. Die Prozessgeschwindigkeit des Roboters ist in nachfolgenden Versuchsreihen geringer als in realen Anwendungen. Dies ermöglicht eine echtzeitnahe Datenaufnahme der Antriebssignale im Roboter selbst. Für eine Echtzeitaufnahme in realen Produktionsgeschwindigkeiten ist ein Edge-Computing notwendig. Abbildung 9-11 zeigt den Versuchsaufbau des Roboters in der ersten Versuchsreihe. Am Endeffektor ist ein Gewicht befestigt, welches reproduzierbar an unterschiedlichen Positionen im Arbeitsraum abstoßbar ist. Im rechten Bild ist eine vergrößerte Darstellung des Endeffektors abgebildet. Der Bauteilverlust wird nachfolgend als Part-Drop bezeichnet.

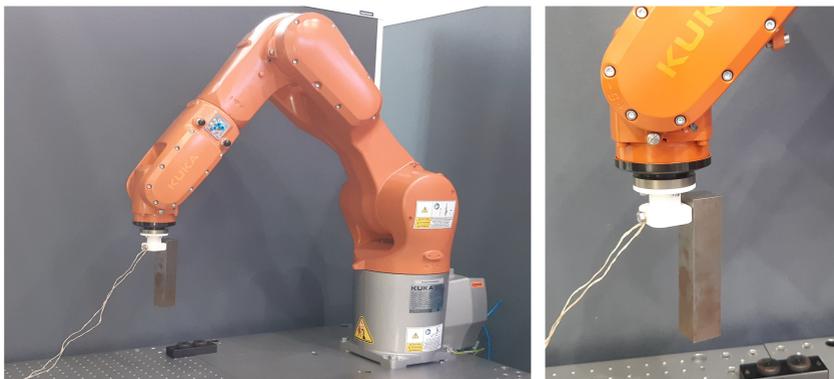


Abbildung 9-11: Versuchsaufbau mit künstlich erzeugter Anomalie als Bauteilverlust.

Die Masse des Gewichts beträgt 25% der vom Hersteller genannten Nennlast. Auf eine manuelle Entnahme des Gewichtes wurde verzichtet, um reproduzierbare Versuchsabläufe gewährleisten zu können.

Ergänzend zum Bauteilverlust wird ein weiterer Anwendungsfall realisiert. Dabei wird eine Crash-Fahrt resp. kurzzeitige Momentüberhöhung der Antriebsmotoren abgebildet. Ziel der Untersuchung ist das Auffinden kurzzeitiger Momentüberhöhungen in beliebigen Prozessabläufen. Zur Nachbildung dieses Anomaliefalls wurden elastische Gummibänder mit definierter Zugkraft verwendet. Abbildung 9-12 zeigt den Versuchsaufbau erneut, allerdings mit Verwendung eines Zugbandes (blau). Das Vorgehen ist analog zur vorangegangenen Versuchsreihe. Zunächst wurden Roboterbewegungen mit entsprechenden Antriebssignalen der Achsen als Trainingsdaten aufgezeichnet. Auch hier werden verschiedene Bewegungen als variierende Prozessabläufe realisiert, um eine Vielzahl an Prozessen abzudecken. Die Abläufe werden nur wenige Male wiederholt, um hinreichend viele Daten aufzuzeichnen.

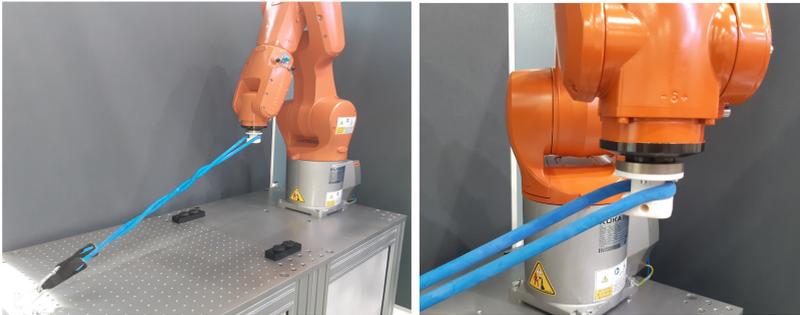


Abbildung 9-12: Versuchsaufbau mit künstlich erzeugter Anomalie als Momentüberhöhung.

Die verfügbaren Daten beinhalten neben den Momenten und Strömen aller sechs Achsen auch Informationen zur kartesischen Position des Endeffektors, den Motortemperaturen oder den Abweichungen zwischen Soll- und Ist-Positionen. Für die Durchführung der Versuche wurde die in Tabelle 5 dargestellte Auswahl an Parametern verwendet. Da hardwarebedingt nicht alle Parameter in derselben Frequenz zur Verfügung stehen, wurde ein Downsampling auf 12ms bzw. 83,33Hz durchgeführt. Die so angepassten Datensätze werden dann in die Anomalieerkennungs-App eingelesen. Dieser Prozess ist bei beiden Versuchsreihen identisch.

Tabelle 5: Übersicht der verfügbaren Daten aus der Steuerung

Nummer	Benennung	Signalart	Verwendungszweck
1	Number of Data Point	Informationssignal	Muster-/Anomalieerkennung
2	Position X-Axis	Referenzsignal	Mustererkennung
3	Position Y-Axis	Referenzsignal	Mustererkennung
4	Position Z-Axis	Referenzsignal	Mustererkennung
5	Torque Axis-1	Informationssignal	Anomalieerkennung
6	Current Axis-1	Informationssignal	Anomalieerkennung
7	Torque Axis-2	Informationssignal	Anomalieerkennung
8	Current Axis-2	Informationssignal	Anomalieerkennung
9	Torque Axis-3	Informationssignal	Anomalieerkennung
10	Current Axis-3	Informationssignal	Anomalieerkennung
11	Torque Axis-4	Informationssignal	Anomalieerkennung
12	Current Axis-4	Informationssignal	Anomalieerkennung
13	Torque Axis-5	Informationssignal	Anomalieerkennung
14	Current Axis-5	Informationssignal	Anomalieerkennung
15	Torque Axis-6	Informationssignal	Anomalieerkennung
16	Current Axis-6	Informationssignal	Anomalieerkennung

Nachfolgend werden die Ergebnisse aus den beiden Anomalie-Versuchsreihen dargestellt. Deutlich zu erkennen sind Signalabweichungen der Achse 3 des Knickarmroboters im Anomaliefall. Strom- und Momentenverlauf weisen durch den physikalischen Zusammenhang sehr ähnliche Datenverläufe auf.

Ein vergleichbarer Effekt tritt in den anderen Achsen auf. Die Abweichung lässt sich durch die sinkende Belastung im Motor durch den Part-Drop und die damit verbundene Gewichtsabnahme interpretieren. Abbildung 9-13 zeigt die erkannte Part-Drop Anomalie. Der Zeitbereich des Bauteilverlustes ist in hellrot dargestellt. Es ist zu erkennen, dass das Toleranzfeld direkt nach dem Bauteilverlust verlassen wird und dann eine starke Überhöhung des Drehmoments mit sich zieht. Die Regler des Motors greifen dann schnell ein und die Drehmomentkurve kommt in das Toleranzfeld zurück. Es lässt sich festhalten, dass der Bauteilverlust trotz der schnellen Regelung durch die Verfahren zuverlässig detektiert wird

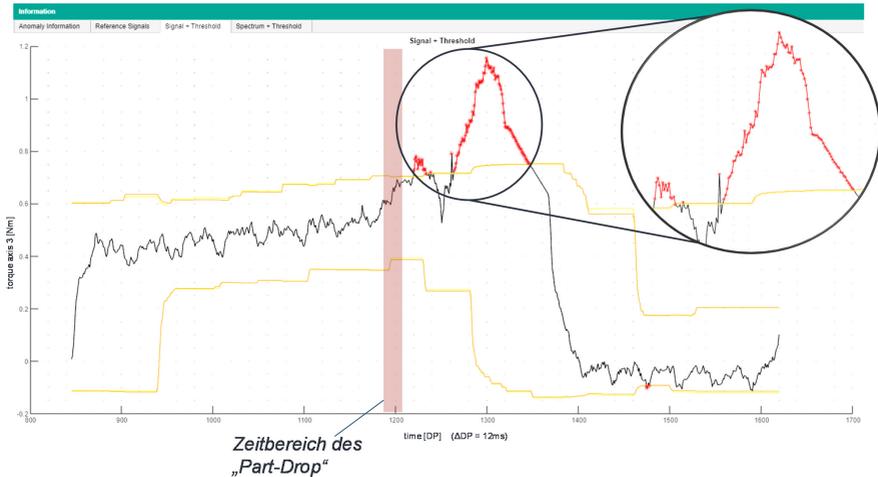


Abbildung 9-13: Datenreihe zum Momentenverlauf in Achse 3 mit gelb markiertem Toleranzband, sowie den rot markierten Toleranzbandbrüchen (Part-Drop).

Es ist deutlich zu sehen, dass sich der schwarz dargestellte Verlauf der Datenreihe nach eingetretenem Part Drop (roter Bereich) der oberen selbstgelernten Toleranzgrenze nähert und diese im Folgenden durchdringt. Die Anzahl der Toleranzausreißer hängt hierbei mit dem gewählten Toleranzband zusammen und sollte in der Praxis je nach Anwendungszweck und Belastung des Roboters angepasst sein. Im vorliegenden Fall ist aufgrund des geringen Gewichtes des zu transportierenden Bauteils eine sehr hohe Sensitivität gewählt.

Anschließend wird die Versuchsreihe mit simuliertem Verschleiß in Form einer Momentenüberhöhung betrachtet. Die Versuchsreihe wird analog der bereits beschriebenen Versuchsreihe durchgeführt. Es erfolgt eine erste Segmentierung sowie anschließend die Anomalieerkennung. Die Einstellungen sind zum vorherigen Versuchsablauf identisch.

Abbildung 9-14 zeigt das Ergebnis der Anomalieerkennungs-App und zeigt den Verlauf der Anomalie deutlich. Im Vergleich zum Part-Drop Versuch ist eindeutig zu erkennen, dass wesentlich mehr Werte (rot markiert) außerhalb des Toleranzbandes detektiert werden. Insgesamt werden drei anomale Muster entdeckt. Alle Muster weisen dabei Anomalien in verschiedenen Informationssignalen auf. Das aufgefundene Verhalten

Konventionen oder die Klassifizierung von Gelenkwinkeln als zusätzliche Informationssignale gewinnbringend herausstellen. Auch die Möglichkeit des Auftretens von Singularitäten im Bewegungsraum muss in weiteren Analysen, hinsichtlich der Implementierung in ein industrielles System, berücksichtigt werden.

Im Hinblick auf eine mögliche Anwendung in der Industrie sind weitere Elemente zu berücksichtigen. Im Gegensatz zu Dreh- oder Fräsmaschinen, bei denen die Bearbeitungsrichtung im Allgemeinen häufig ähnlich ist, treten bei Robotikanwendungen vermehrt komplexere Bewegungen auf. Aus diesem Grund ist es denkbar, die Segmentierung in der Mustererkennung auf Sattelpunkte zu erweitern. Bei der aktuellen Umsetzung können Sattelpunkte in Referenzsignalen beziehungsweise in deren differenzierten Form zu falscher Klassifikation führen. Bewegungsmuster mit Sattelpunkten sind in vorliegender Validierungsreihe bewusst nicht untersucht.

9.5 Anwendung 3: Prozessüberwachung bei der Elektromotoren-Produktion

Die in dieser Dissertation beschriebenen Verfahren sind an industriellen Anwendungsfällen validiert. Das dritte Anwendungsbeispiel der Verfahren, mit Hilfe dessen die breite Anwendbarkeit an verschiedenen Produktionsmaschinen sichergestellt wird, beschreibt eine verkettete Produktionsanlage zur Elektromotoren-Produktion. Nachfolgende Ergebnisse sind zusammengefasst dargestellt. Weitere Erklärungen sind in (Armbruster, Gönzheimer & Netzer 2021) (Netzer & Gönzheimer et al. 2021) (Netzer & Bach et al. 2022) gegeben.

Im vorliegenden Anwendungsfall wird eine vollautomatische Montage von BLDC-Motoren in einer teils-flexiblen Anlage ausgeführt. In der verketteten Anlage der Firma Braun Sondermaschinen GmbH⁵ sind diverse Fügeprozesse implementiert. Die Überwachung des Fügeprozesses erfolgt bislang über eine Kraft-Weg-Überwachung mit a priori definierten Eingriffsgrenzen. Die gemessenen Werte werden zusätzlich für Traceability-Zwecke genutzt. Nachteil der aktuellen Überwachung ist einerseits das aufwendige Applizieren von Eingriffsgrenzen in der Inbetriebnahme. Andererseits ist zum Auslesen von Daten eine separate Steuerung erforderlich. Ziel der Implementierung der Ansätze der vorliegenden Dissertation ist es, selbstlernende Eingriffsgrenzen bei teil-flexiblen

⁵ Braun Sondermaschinen GmbH (2022). *Fügeprozesse*. Abgerufen am 20.01.2022, von <https://www.braun-sondermaschinen.de/sondermaschinenbau-maschinenbau/fuegeprozesse/>

Prozessen umzusetzen. Der Applikationsaufwand bei der Inbetriebnahme soll reduziert werden. Abbildung 9-15 zeigt einen Ausschnitt der Anlage. Im Speziellen ist links die Fügeinheit dargestellt. In dieser Station werden Magnete in entsprechende Blechpakete gefügt.

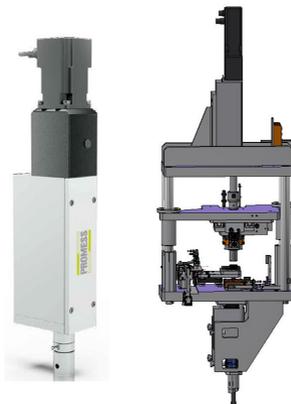


Abbildung 9-15: Fügeinheit mit Kraft-Weg Datenaufnahme (Fa. Promess⁶ Typ UFMm PR5, 3 kN). Darstellung in Anlehnung an (Netzer & Gönninger et al. 2021) (Netzer & Bach et al. 2022).

9.5.1 Versuchsdurchführung und Ergebnisse

Nachfolgend werden die Versuchsreihe und die Ergebnisse aus der Anomalieerkennungs-App beschrieben. Im Rahmen der Versuchsreihe wurde ein realer Montageprozess beobachtet. Es wurden an verschiedenen Stationen unterschiedliche Kraft-Weg-Verläufe mit 32Hz gemessen. In Abbildung 9-16, links, sind Sequenzen des Positionsverlaufs des Pressvorgangs der Magnete in Statoren sichtbar. Rechts auf Abbildung 9-16 ist der berechnete Repräsentant nach der Datensegmentierung abgebildet.

⁶ PROMESS Montage- und Prüfsysteme GmbH (2022). Typ UFMm PR5, 3kN. Abgerufen am 20.01.2022, von https://www.promessmontage.de/fileadmin/download/UFM%20Precision/DE/ufrm_PR5ID030-020-025XXX-DE.pdf

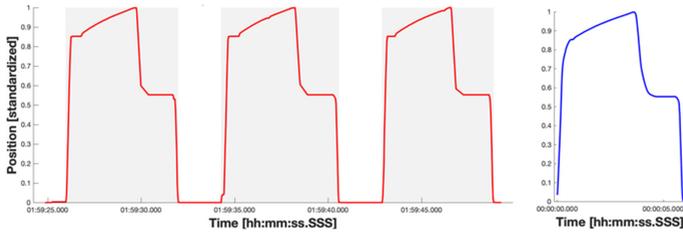


Abbildung 9-16: links: Ausschnitt einer Prozessfolge beim Einpressen der Magnete in den Stator, rechts: berechneter Repräsentant. Darstellung nach (Netzer & Bach et al. 2022).

Im Rahmen eines realen Produktionsablaufs wurde der Pressvorgang mit vorliegendem System überwacht. Ziel der Überwachung ist das Auffinden von Einpressstörungen, wie Verklemmen oder Verkippen der Magnete beim Einpressen. Dies kann zum Abbrechen von Kleinstteilen der Magnete führen, was die Leistungsfähigkeit der Elektromotoren maßgeblich beeinflusst. Abbildung 9-17 zeigt die Anomalie, welche durch ein Verkanten des Magnets im Pressvorgang auftritt. Die intelligente Anomalieerkennung ist in der Lage, dem Anwender während der Bearbeitungszeit die Information zu melden, sodass dieser im oder direkt nach dem Fügeprozess das Bauteil ausschleusen kann.

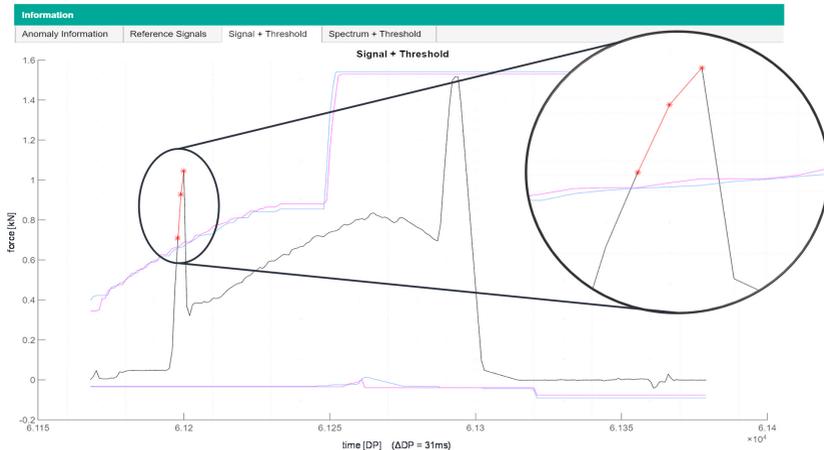


Abbildung 9-17: Darstellung der selbstgelernten Eingriffsgrenzen sowie die Anomalie durch Verkanten des Magnetes im Kraftsignal.

9.5.2 Bewertung und Grenzen

Der Validierungsfall der Elektromotorenproduktion konnte deutlich zeigen, dass die entwickelten Verfahren sowie die Umsetzung in der Anomalieerkennungs-App eine hohe Praxisfähigkeit aufweisen. Alle Ansätze sind hinlänglich erprobt und durch die Variation der Anwendungsbeispiele konnte eine breite Anwendbarkeit gezeigt werden. Aufgrund der Tatsache, dass bislang nur wenige Varianten der Elektromotoren auf dieser Anlage produziert werden, ist die Komplexität der beschriebenen Datensegmentierung nicht notwendig. In Zukunft sollen allerdings weitere Varianten und Kleinserien auf der Anlage produziert werden, was wiederum den Einsatz der intelligenten Anomalieerkennung erfordert. Für eine direkte Implementierung als Produktfeature in der Elektromotoren-Produktion ist in Bezug auf die Datenaufnahme weitere Entwicklungsarbeit notwendig. Die direkte verzögerungsfreie Messung von Zeitreihen ist im aktuellen Aufbau nicht möglich. Hierfür ist es denkbar, dass eine direkte Interaktion mit der Anlagensteuerung erarbeitet wird. Dadurch können detektierte Störungen als Qualitätsfehler der Bauteile direkt im Produktionsprozess ausgeschleust werden. Eine Verzögerung und weitere Wertschöpfung von n.i.O.-Bauteilen würde verhindert werden. Die untersuchten Prozesse sind quasi statisch und es werden keine externen Umgebungseinflüsse betrachtet. Das Verfahren ist nicht geschwindigkeitsinvariant.

9.6 Zusammenfassende Bewertung der Validierung

In den vergangenen Kapiteln wurden die eingeführten neuartigen Verfahren der Mustererkennung zur Prozesssegmentierung sowie der darauf aufbauenden Anomalieerkennung an unterschiedlichen industriell relevanten Anwendungsfällen validiert. Die Auswahl der Anwendungsfälle ist durch hohe Repräsentativität und Übertragbarkeit auf weitere Anwendungen gekennzeichnet. Die Validierung zeigte eine überaus einfache Implementierung des Systems an verschiedenen Anwendungen. Die selbstlernende Eigenschaft der Verfahren bei der Parametrierung ermöglicht die schnelle Inbetriebnahme und Übertragbarkeit. Die Performanz der Verfahren konnte ebenso validiert werden. Es wurde sichergestellt, dass die Anforderungen an Laufzeiten, welche < 1 Sekunde betragen, erreicht wurden. Die Umsetzung der Verfahren in der sogenannten Anomalieerkennungs-App konnte aufzeigen, dass komplexe Verfahren über eine Mensch-Maschinen Schnittstelle intuitiv Bedienern zur Verfügung gestellt werden können. Weitere Entwicklungen hinsichtlich der einfachen Bedienung der App sind notwendig, um die Verfahren direkt in die Maschinensteuerungen zu implementieren.

10 Zusammenfassung und Ausblick

Ziel der vorliegenden Dissertation ist die Entwicklung von Verfahren zur Erkennung von Störungen in hochflexiblen Produktionsmaschinen. Die vorgestellten Verfahren zielen auf die Anwendung in Brownfield Produktionen ab. Bei Brownfield Maschinen sind meist keine externen Sensoren verbaut, weswegen bei der Aufnahme von Steuerungsdaten meist eine geringe Datenmenge und wechselnde -qualität vorliegt. In diesem Fall können keine herkömmlichen Klassifikationsverfahren angewendet werden. Das bearbeitete Themengebiet zeichnet sich durch eine überaus hohe industrielle Relevanz aus, da sowohl Anwender von Produktionsmaschinen als auch Hersteller bestrebt sind Störungen in flexiblen Produktionsmaschinen frühzeitig in ihrem Beginn aufzufinden. Dies hat einen direkten Zusammenhang mit der Gesamtanlageneffektivität der Produktionen der Anwender. Das vorgestellte Gesamtsystem zielt weiterhin auf die Integration von Anwenderwissen ab. Dies wird durch eine Formalisierung des Wissens erreicht. Durch diese Integration können auch bei geringer Datenmenge Signalklassifikationen umgesetzt werden. In der industriellen Praxis ist dies von großem Vorteil, da bislang häufig Kleinserien-Prozesse ohne Störungsüberwachungen durchgeführt werden.

Die Analyse des Standes von Forschung und Technik zeigt, dass Verfahren zu Mustererkennung bislang in verschiedenen Branchen untersucht und angewendet werden. Aktuelle Forschungsarbeiten konzentrieren sich im Wesentlichen auf Klassifikationsansätze sowie die Generalisierbarkeit dieser überwachten Verfahren. Oft wird dabei eine große Datenmenge vorausgesetzt. Die Integration von datengetriebenen Verfahren mit Anwenderwissen ist bislang nicht publiziert. Expertensysteme sind ein bereits hinlänglich erarbeitetes Forschungsgebiet, lassen jedoch in aller Regel die Verknüpfung mit datenbasierten Systemen offen. Ein hybrides System, bestehend aus einem unüberwachten Clusterverfahren als Grundlage einer Prozesssegmentierung sowie der aufbauenden unüberwachten Anomalieerkennung mit Integration von formalisiertem Anwenderwissen, ist hingegen in keinen Publikationen beschrieben.

Vorliegende Dissertation ist in zehn Kapitel gegliedert. Zunächst erfolgt die Analyse des Standes von Forschung und Technik, aufgrund dessen Forschungsdefizite abgeleitet werden. Ein wesentliches Defizit ist die geringe Datenmenge bei hochflexiblen Produktionsmaschinen je Prozess. Herkömmliche Condition Monitoring Systeme sind zudem durch einen hohen Applikationsaufwand gekennzeichnet, da in der Regel maschinen-

und prozessindividuelle Parametrierungen vorgenommen werden müssen. Eine selbstlernende Architektur ist bislang kaum umgesetzt, wird aber in der vorliegenden Dissertation eingeführt. Nach Einführung der forschungsleitenden Fragestellungen sowie der Ableitung der präzisierten Zielstellung erfolgt die Verfahrensentwicklung im eigenen Ansatz. Hier werden zunächst Systemgrenzen abgeleitet und anschließend Clusterverfahren evaluiert. Ein neuartiges Konzept zur Segmentierung von Prozessen sowie zur Bestimmung von Prozess-Repräsentanten ist eingeführt. Anschließend erfolgt die Entwicklung von Verfahren zur Anomalieerkennung. Selbstlernende Eingriffsgrenzen werden entwickelt. Nachfolgend werden Verfahren zur Formalisierung von Anwenderwissen eingeführt sowie Ansätze vorgestellt, wie dieses Anwenderwissen zur Klassifikation von gefundenen Anomalien verwendet werden kann. Zur Sicherstellung der breiten Anwendbarkeit sind alle Ansätze programmiertechnisch in Form einer App umgesetzt. Dabei wurden die Einzelverfahren zusammengeführt und eine konsistente Funktion über alle Bausteine des Gesamtsystems sichergestellt. Der Nachweis über die Funktionsfähigkeit erfolgt an drei verschiedenen industriell relevanten Anwendungen. Abschließend erfolgt eine Bewertung der Verfahren.

Vorliegende Dissertation zeigt ein neuartiges Verfahren auf und stellt die breite Anwendung in der Praxis unter Berücksichtigung der aufgezeigten Grenzen sicher. Durch den Einsatz des Systems kann die Gesamtanlageneffektivität nachhaltig gesteigert werden.

Ausblick

Die in dieser Arbeit eingeführten Verfahren zur Prozesssegmentierung basieren auf der Tatsache, dass Prozesssegmente mindestens zwei Mal vorkommen. Dies führt konzeptbedingt dazu, dass erstmalig auftretende Prozesse nicht verarbeitet werden können, da Referenzen zu diesem Prozess fehlen. Des Weiteren ist konzeptbedingt keine echtzeitfähige Detektion von Anomalien möglich. Da die eigentliche Anomalieerkennung nach der Online-Mustererkennung erfolgt, ist mit einer Verzögerung zu rechnen.

In weiterführenden Arbeiten ist es daher denkbar, dass in NC gesteuerten Produktionsmaschinen der NC-Code bereits zur Vorhersage von Repräsentanten verwendet werden kann. Der NC Code kann dann offline zur Analyse von Prozesssegmenten genutzt werden. Im eigentlichen Produktionsprozess (online) erfolgt dann lediglich die Anomalieerkennung. Durch diesen Ansatz kann eine echtzeitnahe Anomalieerkennung ermöglicht werden. Herausforderungen hierbei bestehen in der Synchronisierung von diskon-

kontinuierlichen NC Ablaufprogrammen mit kontinuierlich gemessenen Zeitreihen der Antriebs-signale. Ein erster Ansatz einer Synchronisation ist in der angeleiteten Arbeit (A_Hesse-mann 2020) aufgezeigt. Bei nicht NC-gesteuerten Produktionsmaschinen kann keine vorgelagerte Prozesssegmentierung erfolgen. In diesem Fall muss aufgrund einer Übergangswahrscheinlichkeit zwischen historischen Prozesssegmenten eine probabilistische Vorhersage getroffen werden. In weiteren Arbeiten ist es daher denkbar, Ansätze wie bspw. Markov-Ketten zu verwenden, um auf Basis vergangener Prozessketten fortfolgende zu prognostizieren. Dadurch kann ebenso die Verzögerung bei der Anomaliedetektion reduziert werden. Einen Funktionsnachweis in vorliegendem System gibt die angeleitete Arbeit (A_Martin 2020). Bei weiteren Analysen zeigt sich, dass die Prozesssegmentierung an Minima-Werte der Zeitreihe einige Performanzvorteile bringt. Dennoch kann es in praxisrelevanten Anwendungen vorkommen, dass eine Verschiebung der realen Prozesssegmentierung mit der angenommenen, durch Minima aufgetrennten, Zeitreihe kommt. In diesem Fall sind in fortführenden Arbeiten weitere relevante Segmentierungspunkte wie Sattelpunkte oder Maxima zu untersuchen. Im Allgemeinen ist eine etwaige Asynchronität nicht funktionskritisch. Dennoch kann es ggfs. zu einer verzögerten Anomalieerkennung kommen. Weiterhin bedingen unterschiedliche Anwendungsfälle wie bspw. Werkzeugmaschinen eine Unterscheidung zwischen Haupt- und Nebenzeiten einer Maschine. Die Anomalieerkennung soll im Wesentlichen bei Hauptzeiten der Maschine Störungen wie Qualitätsfehler auffinden. Aus diesem Grund ist in weiteren Arbeiten die Untersuchung nach einem prozessbedingten Segmentierungspunkt notwendig. Ein möglicher Segmentierungspunkt kann ein initiales Eintreten eines Fräasers in das Werkstück sein, was durch eine erste initiale Erhöhung des Spindelstroms gekennzeichnet ist. Die angeleitete Arbeit (A_Heihoff 2019) zeigt einen Proof-of-Concept, um Prozesse durch initiale Motorstromerhöhungen zu segmentieren.

Zur Erweiterung der Systemgrenzen ist in nachfolgenden Arbeiten der Einfluss der Maschinengeschwindigkeit oder Drehzahl zu berücksichtigen, sodass auch weitere dynamische Prozesse in die Anomalieerkennung aufgenommen werden können. Die Erweiterung auf nicht-stationäre Prozesse ist für die Anwendung in der Praxis maßgeblich.

Publikationsliste des Autors

Armbruster, Gönzheimer & Netzer 2021

Armbruster, J.; Gönzheimer, P. & Netzer, M. (2021), „Predictive Maintenance in der Antriebstechnik“, *computer & automation*, S. 66–69.

Gönzheimer & Netzer et al. 2020

Gönzheimer, P.; Netzer, M.; Mohr, L.; Hörsten, G. v. & Fleischer, J. (2020), „Erhöhung der Skalierbarkeit von KI-Anwendungen in Produktionsanlagen“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 115 (7-8), S. 517–519.

Netzer & Bach et al. 2022

Netzer, M.; Bach, J.; Puchta, A.; Gönzheimer, P. & Fleischer, J. (2022), „Process Segmented based Intelligent Anomaly Detection in Highly Flexible Production Machines under Low Machine Data Availability“. *Procedia CIRP - 55th Conference on Manufacturing Systems*, Hrsg. E. Carpanzano, C. Boër & A. Valente. 55th CIRP Conference on Manufacturing Systems. 29.06.-01.07.2022. Lugano, Switzerland, Elsevier, Amsterdam, S. 647–652.

Netzer & Begemann et al. 2021

Netzer, M.; Begemann, E.; Gönzheimer, P. & Fleischer, J. (2021), „Digitalisierung im deutschen Maschinen- und Anlagenbau“, *wt Werkstattstechnik online*, 111 (07-08), S. 526–530.

Netzer & Gönzheimer et al. 2020

Netzer, M.; Gönzheimer, P.; Michelberger, J. & Fleischer, J. (2020), „Skalierbarkeit von KI-Anwendungen in der Produktion“, *Fabriksoftware* (1), S. 51–54.

Netzer & Gönzheimer et al. 2021

Netzer, M.; Gönzheimer, P.; Schäfer, W.; Grosser, K. & Fleischer, J. (2021), „Daten-Enabling für eine breite KI-Anwendung“, *wt Werkstattstechnik online*, 111 (07-08), S. 481–485.

Netzer, Michelberger & Fleischer 2019

Netzer, M.; Michelberger, J. & Fleischer, J. (2019), „Intelligente Störungserkennung einer Werkzeugmaschine“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 114 (10), S. 635–638.

Netzer, Michelberger & Fleischer 2020

Netzer, M.; Michelberger, J. & Fleischer, J. (2020), „Intelligent Anomaly Detection

of Machine Tools based on Mean Shift Clustering“. *Procedia CIRP - 53rd Conference on Manufacturing Systems*, Hrsg. Robert X. Gao, Kornel Ehmann. 53rd CIRP Conference on Manufacturing Systems. 01.-03.07.2020. Chicago, USA, Elsevier, Amsterdam, S. 1448–1453.

Netzer & Palenga et al. 2021

Netzer, M.; Palenga, Y.; Gönzheimer, P. & Fleischer, J. (2021), „Offline-Online pattern recognition for enabling time series anomaly detection on older NC machine tools“, *Journal of Machine Engineering*, 21, S. 98–108.

Netzer, Palenga & Fleischer 2022

Netzer, M.; Palenga, Y. & Fleischer, J. (2022), „Machine tool process monitoring by segmented timeseries anomaly detection using subprocess-specific thresholds“, *Production Engineering*, 16, S. 597–606.

Literaturverzeichnis

Verweise gemäß Schema (A_Nachname, Vorname (Jahr)) beziehen sich auf studentische Arbeiten des wbk, die durch den Verfasser der vorliegenden Dissertation angeleitet wurden.

A_Alexander, P. 2021

A_Alexander, P. (2021), *Entwicklung eines Ansatzes zur Generalisierung von spezifisch trainierten KI-Algorithmen in Werkzeugmaschinen*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Ammon, C. 2019

A_Ammon, C. (2019), *Weiterentwicklung einer Anomaliedetektion einer Werkzeugmaschine basierend auf Methoden des maschinellen Lernens*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Baier, C. 2021

A_Baier, C. (2021), *Weiterentwicklung einer KI-basierten Mustererkennung durch Hyperparameteroptimierung in Werkzeugmaschinen*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Begemann, E. 2021

A_Begemann, E. (2021), *Sensorintegration und konzeptionelle Weiterentwicklung einer KI-basierten Anomalieerkennung für den realen Einsatz am Anwendungsbeispiel Fräsmaschine*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Brunnenkant, F.-A. 2020

A_Brunnenkant, F.-A. (2020), *Entwicklung eines Zeitreihen-Clustering-Algorithmus zur Erkennung wiederkehrender Bewegungen auf Basis eines Zwei-Stufen-Ansatzes mit DBSCAN*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Chamoulias, F. 2019

A_Chamoulias, F. (2019), *Entwicklung eines Algorithmus zur Erkennung von Bewegungszyklen einer Produktionsmaschine*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik.

A_Heihoff, S. 2019

A_Heihoff, S. (2019), *Weiterentwicklung einer KI-basierten intelligenten Bewegungserkennung für Werkzeugmaschinen*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Hessemann, S. 2020

A_Hessemann, S. (2020), *Automatisierte Detektion von wiederkehrenden Bearbeitungen in Produktionsmaschinen auf Basis der NC-Sollwertvorgabe*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Köhler, L. 2020

A_Köhler, L. (2020), *Weiterentwicklung einer intelligenten KI-basierten Anomalieerkennung am Anwendungsbeispiel Fräsmaschine*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Kopp, R. 2019

A_Kopp, R. (2019), *Konzeptionelle Weiterentwicklung und Validierung eines KI-Algorithmus zur Erkennung von Anomalien basierend auf wiederkehrenden Bewegungen bei einer Werkzeugmaschine*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Martin, J. 2020

A_Martin, J. (2020), *Anomaly Detection in Motion Sequences of Production Machines using Machine Learning Algorithms*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Mehmedovic, M. 2020

A_Mehmedovic, M. (2020), *Weiterentwicklung eines KI-Algorithmus zur Mustererkennung an Werkzeugmaschinen*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Michelberger, J. 2019

A_Michelberger, J. (2019), *Entwicklung eines KI-Algorithmus zur Erkennung von Bewegungszyklen einer Produktionsmaschine basierend auf Methoden des maschinellen Lernens*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Winkler, L. 2020

A_Winkler, L. (2020), *Entwicklung einer KI-basierten Anomalieerkennung zur Identifikation von Verschleiß in Werkzeugmaschinen*. Masterarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

A_Wurche, P.-D. 2020

A_Wurche, P.-D. (2020), *Weiterentwicklung von intelligenten Clusteransätzen für eine Bewegungserkennung für Werkzeugmaschinen*. Bachelorarbeit, Karlsruher Institut für Technologie, wbk Institut für Produktionstechnik, Karlsruhe.

Aggarwal 2017

Aggarwal, C. C. (2017), *Outlier Analysis*, Springer International Publishing, Cham. ISBN: 978-3-319-47577-6.

Aghabozorgi, Seyed Shirkhorshidi & Ying Wah 2015

Aghabozorgi, S.; Seyed Shirkhorshidi, A. & Ying Wah, T. (2015), „Time-series clustering – A decade review“, *Information Systems*, 53, S. 16–38.

Agrawal, Faloutsos & Swami 1993

Agrawal, R.; Faloutsos, C. & Swami, A. (1993), „Efficient Similarity Search In Sequence Databases“ in *Foundations of Data Organization and Algorithms (FODO 1993)*. Lecture Notes in Computer Science, Hrsg. G. Goos, J. Hartmanis & D. B. Lomet, Springer, Berlin, Heidelberg, S. 69–84.

Ahmad & Lavin et al. 2017

Ahmad, S.; Lavin, A.; Purdy, S. & Agha, Z. (2017), „Unsupervised real-time anomaly detection for streaming data“, *Neurocomputing*, 262, S. 134–147.

Ahmadi & Padoy et al. 2009

Ahmadi, S.-A.; Padoy, N.; Rybachuk, K.; Feussner, H.; Heinin, S. M. & Navab, N. (2009), „Motif discovery in OR sensor data with application to surgical workflow analysis and activity detection“, *MICCAI Workshop on Modeling and Monitoring of Computer Assisted Interventions (M2CAI)*, S. 2-11.

Akerkar & Sajja 2010

Akerkar, R. A. & Sajja, P. S. (2010), *Knowledge-based systems*, Jones and Bartlett Learning, Sudbury, USA. ISBN: 978-0-763-77647-3.

Aleskerov, Freisleben & Rao 1997

Aleskerov, E.; Freisleben, B. & Rao, B. (1997), „CARDWATCH: a neural network

based database mining system for credit card fraud detection". *Proceedings of the IEEE/IAFE 1997 Computational Intelligence for Financial Engineering (CIFER)*, Hrsg. J. F. Marshall, R. J. Marks, A. Tucker & R. R. Yacker. IEEE/IAFE 1997 Computational Intelligence for Financial Engineering (CIFER). 24.-25.03.1997. New York City, USA, IEEE, New York, USA, S. 220–226. ISBN: 0-7803-4133-3.

Allianz Global Corporate & Specialty SE 2020

Allianz Global Corporate & Specialty SE (2020), *Allianz Risk Barometer. Identifying the Major Business Risks for 2020*. <https://www.agcs.allianz.com/content/dam/onemarketing/agcs/agcs/reports/Allianz-Risk-Barometer-2020.pdf> [20.08.2022].

Amruthnath & Gupta 2018

Amruthnath, N. & Gupta, T. (2018), „Fault Class Prediction in Unsupervised Learning using Model-Based Clustering Approach“, *2018 International Conference on Information and Computer Technologies (ICICT)*, S. 5–12.

Anderl, R., Picard, A., Wang, Y., Fleischer, J., Dosch, S., Klee, B., & Bauer, J. 2015

Anderl, R., Picard, A., Wang, Y., Fleischer, J., Dosch, S., Klee, B., & Bauer, J. (2015), *Leitfaden Industrie 4.0. Orientierungshilfe zur Einführung in den Mittelstand*, VDMA-Verlag, Frankfurt am Main. ISBN: 978-3-8163-0677-1.

Armbruster, Gönzheimer & Netzer 2021

Armbruster, J.; Gönzheimer, P. & Netzer, M. (2021), „Predictive Maintenance in der Antriebstechnik“, *computer & automation*, S. 66–69.

Aurich & Ilse et al. 2018

Aurich, J. C.; Ilse, R.; Mert, G. & Kirsch, B. (2018), „Nachhaltigkeit in der Produktion – Aufgabenstellungen und Lösungsansätze“ in *Fortschritte in der Nachhaltigkeitsforschung*, Hrsg. M. v. Hauff & T. Nguyen, Nomos, Baden-Baden, S. 231–252.

Balasubramanian & Prabhakaran 2013

Balasubramanian, A. & Prabhakaran, B. (2013), „Flexible Exploration and Visualization of Motifs in Biomedical Sensor Data“. *Proceedings of the 19th ACM SIG-KDD International Conference on Knowledge Discovery and Data Mining*, Hrsg. R. Ghani, T. E. Senior, P. Bradley, R. Parekh, J. He, R. L. Grossman, R. Uthurusamy, I. S. Dhillon & Y. Koren. Workshop on Data Mining for Healthcare

(DMH). 11.-13.08.2013. Chicago, USA, Association for Computing Machinery, New York, S. 1-10.

Barton & Stamm et al. 2020

Barton, D.; Stamm, R.; Mergler, S.; Bardenhagen, C. & Fleischer, J. (2020), „Industrie-4.0-Nachrüstkit für Werkzeugmaschinen: Modulare Lösung für zustandsorientierte Instandhaltung und Prozessüberwachung“, *wt Werkstattstechnik online*, 110 (7-8), S. 491–495.

Bauernhansl 2016

Bauernhansl, T. (2016), „Weckruf für Unternehmen“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 111 (7-8), S. 453–457.

Bauernhansl, Hompel & Vogel-Heuser 2014

Bauernhansl, T.; Hompel, M. ten & Vogel-Heuser, B. (2014), *Industrie 4.0 in Produktion, Automatisierung und Logistik*, Springer Vieweg, Wiesbaden. ISBN: 978-3-658-04681-1.

Bender, Kaul & Sextro 2017

Bender, A.; Kaul, T. & Sextro, W. (2017), „Entwicklung eines Condition Monitoring Systems für Gummi-Metall Elemente“, *Wissenschafts-und Industrieforum*, 369, S. 347–358.

Bink & Zschech 2018

Bink, R. & Zschech, P. (2018), „Predictive Maintenance in der industriellen Praxis“, *HMD Praxis der Wirtschaftsinformatik*, 55 (3), S. 552–565.

Bloching & Leutiger et al. 2015

Bloching, B.; Leutiger, P.; Oltmanns, T.; Rossbach, C.; Schlick, T.; Remane, G.; Quick, P. & Shafranyuk, O. (2015), *Die digitale Transformation der Industrie. Was sie bedeutet. Wer gewinnt. Was jetzt zu tun ist.* https://bdi.eu/media/presse/publikationen/information-und-telekommunikation/Digitale_Transformation.pdf [02.08.2022].

Brecher & Weck 2021

Brecher, C. & Weck, M. (2021), *Werkzeugmaschinen Fertigungssysteme 1. Mechatronische Systeme, Steuerungstechnik und Automatisierung*, Springer Vieweg, Berlin. ISBN: 978-3-662-46569-1.

- Bundesverband Materialwirtschaft, Einkauf und Logistik e. V. & riskmethods GmbH 2018
Bundesverband Materialwirtschaft, Einkauf und Logistik e. V. & riskmethods GmbH (2018), *Supply Chain Risk Management: Herausforderungen und Status Quo*. <https://www.riskmethods.net/media/Content/Resources/riskmethods-bme-scrum-umfrage-status-quo-herausforderungen-2018.pdf> [02.08.2022].
- Byrne & Dornfeld et al. 1995
Byrne, G.; Dornfeld, D.; Inasaki, I.; Ketteler, G.; König, W. & Teti, R. (1995), „Tool Condition Monitoring (TCM) — The Status of Research and Industrial Application“, *CIRP Annals*, 44 (2), S. 541–567.
- Cassisi & Aliotta et al. 2013
Cassisi, C.; Aliotta, M.; Cannata, A.; Montalto, P.; Patanè, D.; Pulvirenti, A. & Spampinato, L. (2013), „Motif Discovery on Seismic Amplitude Time Series: The Case Study of Mt Etna 2011 Eruptive Activity“, *Pure and Applied Geophysics*, 170 (4), S. 529–545.
- Chan & Fu 1999
Chan, K.-P. & Fu, A. W.-C. (1999), „Efficient time series matching by wavelets“. *Proceedings of the 15th International Conference on Data Engineering 1999*, Hrsg. M. Kitsuregawa, L. Maclaszek, M. Papazoglou & C. Pu. 15th International Conference on Data Engineering. 23.-26.03.1999. Sydney, Australia, IEEE, New York, USA, S. 126–133.
- Chandola, Banerjee & Kumar 2009
Chandola, V.; Banerjee, A. & Kumar, V. (2009), „Anomaly detection“, *ACM Computing Surveys*, 41 (3), S. 1–58.
- Chapman & Clinton et al. 2000
Chapman, P.; Clinton, J.; Kerber, T.; Khabaza, T.; Reinartz, C.; Shearer, C. & Wirth, R. (2000), „CRISP-DM 1.0 Step-by-step data mining guide“, *SPSS*, 9 (13), S. 1-73.
- Chatfield 2003
Chatfield, C. (2003), *The analysis of time series. An Introduction*, Chapman & Hall, CRC, Boca Raton, USA. ISBN: 978-1584883173.

Cheboli, D. 2010

Cheboli, D. (2010), *Anomaly detection of time series*. Masterarbeit, University of Minnesota, Department of Computer Science and Engineering, Minnesota, USA.

Cheboli, D.; Chandola, V. & Kumar, V. 2009

Cheboli, D.; Chandola, V. & Kumar, V. (2009), *Detecting anomalies in a time series database*, University of Minnesota, Department of Computer Science and Engineering, Minnesota, USA.

Chen & Liu et al. 2020

Chen, T.; Liu, X.; Xia, B.; Wang, W. & Lai, Y. (2020), „Unsupervised Anomaly Detection of Industrial Robots Using Sliding-Window Convolutional Variational Autoencoder“, *IEEE Access*, 8, S. 47072–47081.

Cheng 1995

Cheng, Y. (1995), „Mean shift, mode seeking, and clustering“, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17 (8), S. 790–799.

Chiang 2001

Chiang, L. H. (2001), *Fault Detection and Diagnosis in Industrial Systems*, Springer London, London. ISBN: 978-1-85233-327-0.

Chicco 2012

Chicco, G. (2012), „Overview and performance assessment of the clustering methods for electrical load pattern grouping“, *8th World Energy System Conference*, 42 (1), S. 68–80.

Chow 1960

Chow, Y. S. (1960), „A Martingale Inequality and the Law of Large Numbers“, *Proceedings of the American Mathematical Society*, 11 (1), S. 107–111.

Collatz & Wetterling 1971

Collatz, L. & Wetterling, W. (1971), „Tschebyscheff-Approximation und Optimierung“ in *Optimierungsaufgaben*, Hrsg. L. Collatz & W. Wetterling, Springer, Berlin, Heidelberg, S. 152–176.

Comaniciu & Meer 2002

Comaniciu, D. & Meer, P. (2002), „Mean shift: a robust approach toward feature space analysis“, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24 (5), S. 603–619.

Curry & Grace 2008

Curry, E. & Grace, P. (2008), „Flexible Self-Management Using the Model-View-Controller Pattern“, *IEEE Software*, 25 (3), S. 84–90.

Das & Lin et al. 1998

Das, G.; Lin, K.-I.; Mannila, H.; Renganathan, G. & Smyth, P. (1998), „Rule discovery from time series“. *Proceedings of the 4th International Conference on Knowledge Discovery and Data Mining (KDD'98)*, Hrsg. R. Agrawal & P. Stolorz. 4th International Conference on Knowledge Discovery and Data Mining. 27.-31.08.1998. New York, USA, AAAI Press, Palo Alto, USA, S. 16–22.

Davies 2012

Davies, A. (Hrsg.) (2012), *Handbook of condition monitoring: techniques and methodology*, Springer, Dordrecht, Niederlande. ISBN: 978-0-412-61320-3.

Debenham 1998

Debenham, J. (1998), *Knowledge Engineering. Unifying Knowledge Base and Database Design*, Springer, Berlin, Heidelberg. ISBN: 978-3-642-72034-5.

Degischer 2018

Degischer, H. P. (2018), „Legierungstechnologie“ in *Maschinenbau*, Hrsg. W. Skolaut, Springer, Berlin, Heidelberg, S. 527–559.

Deutsches Institut für Normung 2003

Deutsches Institut für Normung (2003), *Fertigungsverfahren – Begriffe, Einteilungen*. DIN 8580 (2003-09), Beuth-Verlag, Berlin.

Deutsches Institut für Normung 2011

Deutsches Institut für Normung (2011), *Sicherheit von Maschinen - Allgemeine Gestaltungsleitsätze - Risikobeurteilung und Risikominderung*. DIN EN ISO 12100 (2011-03), Beuth-Verlag, Berlin.

Deutsches Institut für Normung 2018

Deutsches Institut für Normung (2018), *Instandhaltung - Begriffe der Instandhaltung. Abschnitt 2.1*. DIN EN 13306 (2018-02), Beuth-Verlag, Berlin.

Du & Jin et al. 2009

Du, X.; Jin, R.; Ding, L.; Lee, V. E. & Thornton, J. H. (2009), „Migration motif: a spatial-temporal pattern mining approach for financial markets“. *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data*

mining - KDD '09, Hrsg. J. Elder, F. S. Fogelman, P. Flach & M. Zaki. 15th ACM SIGKDD international conference on Knowledge discovery and data mining. 28.06.-01.07.2009. Paris, France, ACM Press, New York, USA, S. 1135-1144.

Durkin 1994

Durkin, J. (1994), *Expert systems. Design and development*, Prentice-Hall, New Jersey, USA. ISBN: 0-02-330970-9.

Ester & Kriegel 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“. *Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining (KDD'96)*, Hrsg. E. Simoudis, J. Han & U. M. Fayyad. 2nd International Conference on Knowledge Discovery & Data Mining (KDD). 02.-04.08.1996. Portland, USA, AAAI Press, Palo Alto, USA, S. 226–231.

Focke & Steinbeck 2018

Focke, M. & Steinbeck, J. (2018), *Steigerung der Anlagenproduktivität durch OEE-Management. Definitionen, Vorgehen und Methoden – von manuell bis Industrie 4.0*, Springer Gabler, Wiesbaden. ISBN: 978-3-658-21456-2.

Förster & Förster 2018

Förster, R. & Förster, A. (2018), *Einführung in die Fertigungstechnik. Lehrbuch für Studenten ohne Vorpraktikum*, Springer, Berlin, Heidelberg. ISBN: 978-3-662-54702-1.

Frieß & Kolouch et al. 2018

Frieß, U.; Kolouch, M.; Friedrich, A. & Zander, A. (2018), „Fuzzy-clustering of machine states for condition monitoring“, *CIRP Journal of Manufacturing Science and Technology*, 23 (2), S. 64–77.

Fujimaki, Yairi & Machida 2005

Fujimaki, R.; Yairi, T. & Machida, K. (2005), „An Anomaly Detection Method for Spacecraft Using Relevance Vector Learning“ in *Advances in Knowledge Discovery and Data Mining*, 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, T. B. Ho, D. Cheung & H. Liu, Springer, Berlin, Heidelberg, S. 785–790.

Fukunaga & Hostetler 1975

Fukunaga, K. & Hostetler, L. (1975), „The estimation of the gradient of a density function, with applications in pattern recognition“, *IEEE Transactions on Information Theory*, 21 (1), S. 32–40.

Gama & Zliobaite et al. 2014

Gama, J.; Zliobaite, I.; Bifet, A.; Pechenizkiy, M. & Bouchachia, A. (2014), „A survey on concept drift adaptation“, *ACM Computing Surveys*, 46 (4), S. 1–37.

Gomes & Batista 2015

Gomes, E. F. & Batista, F. (2015), „Classifying Urban Sounds using Time Series Motifs“, *Advanced Science and Technology Letters*, 97, S. 52–57.

Gönnheimer & Netzer et al. 2020

Gönnheimer, P.; Netzer, M.; Mohr, L.; Hörsten, G. v. & Fleischer, J. (2020), „Erhöhung der Skalierbarkeit von KI-Anwendungen in Produktionsanlagen“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 115 (7-8), S. 517–519.

Gönnheimer, Puchta & Fleischer 2021

Gönnheimer, P.; Puchta, A. & Fleischer, J. (2021), „Automated Identification of Parameters in Control Systems of Machine Tools“ in *Production at the leading edge of technology*, Hrsg. B.-A. Behrens, A. Brosius, W. Hintze, S. Ihlenfeldt & J. P. Wulfsberg, Springer, Berlin, Heidelberg, S. 568–577.

Gronau, Kern & Jonitz 2019

Gronau, N.; Kern, E.-M. & Jonitz, H. (2019), „Herausforderungen im Umgang mit Produktionsstörungen“, *Industrie 4.0 Management*, 4 (6), S. 33–36.

Hao & Shokoohi-Yekta et al. 2013

Hao, Y.; Shokoohi-Yekta, M.; Papageorgiou, G. & Keogh, E. (2013), „Parameter-Free Audio Motif Discovery in Large Data Archives“. *Proceedings of the 2013 IEEE 13th International Conference on Data Mining Workshops (ICDMW '13)*, Hrsg. W. Ding, T. Washio, H. Xiong, G. Karypis, B. Thuraisingham, D. Cook & X. Wu. 2013 IEEE International Conference on Data Mining (ICDM). 07.-10.12.2013. Dallas, USA, IEEE Computer Society, Washington DC, USA, S. 261–270.

Hauskrecht & Valko et al. 2007

Hauskrecht, M.; Valko, M.; Kveton, B.; Visweswaran, S. & Cooper, G. F. (2007),

„Evidence-based anomaly detection in clinical domains“. *American Medical Informatics Association Annual Symposium 2007. Biomedical and Health Informatics: From Foundations to Applications to Policy*, Hrsg. J. M. Teich. American Medical Informatics Association Annual Symposium 2007. 10.-14.11.2007. Chicago, USA, AMIA Symposium, Washington DC, USA, S. 319–323.

Hayes & Capretz 2015

Hayes, M. A. & Capretz, M. A.M. (2015), „Contextual anomaly detection framework for big sensor data“, *Journal of Big Data*, 2 (2), S. 1-22.

Heilmann 2020

Heilmann, R. (2020), *Rauschen in der Sensorik*, Springer Fachmedien, Wiesbaden. ISBN: 978-3-658-29213-3.

Herrmann & Schumny 1984

Herrmann, D. & Schumny, H. (1984), „Teile- und -Herrsche-Prinzip“ in *Programmierprinzipien in BASIC und Pascal*, Hrsg. D. Herrmann & H. Schumny, Vieweg+Teubner Verlag, Wiesbaden, S. 37–42.

Hirsch 2016

Hirsch, A. (2016), *Werkzeugmaschinen. Anforderungen, Auslegung, Ausführungsbeispiele*, Springer Fachmedien, Wiesbaden. ISBN: 978-3-658-14249-0.

Hochreiter & Schmidhuber 1997

Hochreiter, S. & Schmidhuber, J. (1997), „Long short-term memory“, *Neural computation*, 9 (8), S. 1735–1780.

Jain, Murty & Flynn 1999

Jain, A. K.; Murty, M. N. & Flynn, P. J. (1999), „Data clustering“, *ACM Computing Surveys*, 31 (3), S. 264–323.

Janusz & Venkatasubramanian 1991

Janusz, M. E. & Venkatasubramanian, V. (1991), „Automatic generation of qualitative descriptions of process trends for fault detection and diagnosis“, *Engineering Applications of Artificial Intelligence*, 4 (5), S. 329–339.

Javadpour & Knapp 2003

Javadpour, R. & Knapp, G. M. (2003), „A fuzzy neural network approach to machine condition monitoring“, *Computers & Industrial Engineering*, 45 (2), S. 323–330.

Kawachi, Koizumi & Harada 2018

Kawachi, Y.; Koizumi, Y. & Harada, N. (2018), „Complementary Set Variational Autoencoder for Supervised Anomaly Detection“. *Proceedings of the 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Hrsg. M. Hayes, H. Ko & D. Schonfeld. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 15.-20.4.2018. Calgary, Canada, IEEE, New York, USA, S. 2366–2370.

Keogh & Chakrabarti et al. 2001

Keogh, E.; Chakrabarti, K.; Pazzani, M. & Mehrotra, S. (2001), „Dimensionality Reduction for Fast Similarity Search in Large Time Series Databases“, *Knowledge and Information Systems*, 3 (3), S. 263–286.

Keogh & Chu et al. 2001

Keogh, E.; Chu, S.; Hart, D. & Pazzani, M. (2001), „An online algorithm for segmenting time series“, *IEEE International Conference on Data Mining*, S. 289–296.

Keogh & Kasetty 2003

Keogh, E. & Kasetty, S. (2003), „On the Need for Time Series Data Mining Benchmarks: A Survey and Empirical Demonstration“, *Data Mining and Knowledge Discovery*, 7 (4), S. 349–371.

Keogh & Lin 2005

Keogh, E. & Lin, J. (2005), „Clustering of time-series subsequences is meaningless: implications for previous and future research“, *Knowledge and Information Systems*, 8 (2), S. 154–177.

Keogh, Lin & Fu 2005

Keogh, E.; Lin, J. & Fu, A. (2005), „HOT SAX: Efficiently Finding the Most Unusual Time Series Subsequence“. *Proceedings of the 5th IEEE International Conference on Data Mining (ICDM'05)*, Hrsg. J. Han, B. W. Wah, V. Raghavan, X. Wu & R. Rastogi. 5th IEEE International Conference on Data Mining (ICDM'05). 27.-30.11.2005. Houston, USA, IEEE, New York, USA, S. 226–233.

Klingel, S. 2015

Klingel, S. (2015), *Automatisierte Zerlegung von Bildern und die geordnete Darstellung ihrer Konstituenten*. Diplomarbeit, Universität Stuttgart, Fakultät Informatik, Elektrotechnik und Informationstechnik, Stuttgart.

Knorn & Leith 2008

Knorn, F. & Leith, D. J. (2008), „Adaptive Kalman Filtering for anomaly detection in software appliances“. *Proceedings of the IEEE Conference on Computer Communications Workshops*, Hrsg. D. Merrill, J. Hou, S. Kalyanaraman & K. Sivalingam. IEEE Conference on Computer Communications Workshops (INFOCOM 2008). 13.-18.04.2008. Phoenix, USA, IEEE, New York, USA, S. 1–6.

Lasi & Fettke et al. 2014

Lasi, H.; Fettke, P.; Kemper, H.-G.; Feld, T. & Hoffmann, M. (2014), „Industrie 4.0“, *WIRTSCHAFTSINFORMATIK*, 56 (4), S. 261–264.

Lee, Padmanabhan & Whang 1997

Lee, H. L.; Padmanabhan, V. & Whang, S. (1997), „The Bullwhip Effect in Supply Chains“, *sloan management review*, 38, S. 93–102.

Lei & Jia et al. 2016

Lei, Y.; Jia, F.; Lin, J.; Xing, S. & Ding, S. X. (2016), „An Intelligent Fault Diagnosis Method Using Unsupervised Feature Learning Towards Mechanical Big Data“, *IEEE Transactions on Industrial Electronics*, 63 (5), S. 3137–3147.

Lin & Keogh et al. 2007

Lin, J.; Keogh, E.; Wei, L. & Lonardi, S. (2007), „Experiencing SAX: a novel symbolic representation of time series“, *Data Mining and Knowledge Discovery*, 15 (2), S. 107–144.

Lin & Li 2010

Lin, J. & Li, Y. (2010), „Finding approximate frequent patterns in streaming medical data“. *Proceedings of the 2010 IEEE 23rd International Symposium on Computer-Based Medical Systems (CBMS)*, Hrsg. T. Dillon, D. Rubin, W. Gallagher, A. Sidhu & A. Tsymbal. 2010 IEEE 23rd International Symposium on Computer-Based Medical Systems (CBMS). 12.-15.10.2010. Bentley, UK, IEEE, New York, USA, S. 13–18.

Liu & Li et al. 2015

Liu, B.; Li, J.; Chen, C.; Tan, W.; Chen, Q. & Zhou, M. (2015), „Efficient Motif Discovery for Large-Scale Time Series in Healthcare“, *IEEE Transactions on Industrial Informatics*, 11 (3), S. 583–590.

Ludwig & Waczowicz et al. 2017

Ludwig, N.; Waczowicz, S.; Mikut, R. & Hagenmeyer, V. (2017), „Mining Flexibility Patterns in Energy Time - Series from Industrial Processes“. *Proceedings of the 27th Workshop Computational Intelligence*, Hrsg. F. Hoffmann, E. Hüllermeier & R. Mikut. 27th Workshop Computational Intelligence. 23.-24.11.2017. Dortmund, Germany, KIT Scientific Publishing, Karlsruhe, S. 13-32.

Lunze 2020a

Lunze, J. (2020), *Regelungstechnik 1*, Springer, Berlin, Heidelberg. ISBN: 978-3-662-60745-9.

Lunze 2020b

Lunze, J. (2020), *Regelungstechnik 2*, Springer, Berlin, Heidelberg. ISBN: 978-3-662-60759-6.

Ma & Perkins 2003

Ma, J. & Perkins, S. (2003), „Time-series novelty detection using one-class support vector machines“. *Proceedings of the International Joint Conference on Neural Networks, 2003*, Hrsg. D. Wunsch & M. Hasselmo. 2003 International Joint Conference on Neural Networks. 20.-24.07.2003. Portland, USA, IEEE, New York, USA, S. 1741–1745.

Maier, Schriegel & Niggemann 2017

Maier, A.; Schriegel, S. & Niggemann, O. (2017), „Big Data and Machine Learning for the Smart Factory—Solutions for Condition Monitoring, Diagnosis and Optimization“ in *Industrial Internet of Things*, Hrsg. S. Jeschke, C. Brecher, H. Song & D. B. Rawat, Springer International Publishing, Cham, S. 473–485.

Matyas 2013

Matyas, K. (2013), *Instandhaltungslogistik. Qualität und Produktivität steigern*, Hanser, München. ISBN: 978-3-446-43589-6.

Maurya & Paritosh et al. 2010

Maurya, M. R.; Paritosh, P. K.; Rengaswamy, R. & Venkatasubramanian, V. (2010), „A framework for on-line trend extraction and fault diagnosis“, *Engineering Applications of Artificial Intelligence*, 23 (6), S. 950–960.

May & Koch 2008

May, C. & Koch, A. (2008), „Overall Equipment Effectiveness (OEE) - Werkzeug

zur Produktivitätssteigerung“, *Zeitschrift der Unternehmensberatung (ZUB)*, 6, S. 245–250.

Mehdiyev & Krumeich et al. 2016

Mehdiyev, N.; Krumeich, J.; Werth, D. & Loos, P. (2016), „Determination of Event Patterns for Complex Event Processing Using Fuzzy Unordered Rule Induction Algorithm with Multi-objective Evolutionary Feature Subset Selection“. *Proceedings of the 2016 49th Hawaii International Conference on System Sciences (HICSS)*, Hrsg. T. X. Bui & R. H. Sprague Jr. 2016 49th Hawaii International Conference on System Sciences (HICSS). 05.-08.01.2016. Koloa, USA, IEEE, New York, USA, S. 1719–1728.

Michau & Fink 2019

Michau, G. & Fink, O. (2019), „Unsupervised Fault Detection in Varying Operating Conditions“. *Proceedings of the 2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*, Hrsg. J. Liu & S. Li. 2019 IEEE International Conference on Prognostics and Health Management (ICPHM). 17.-20.06.2019. San Franzisco, USA, IEEE, New York, USA, S. 1–10.

Mierswa, D. 2016

Mierswa, D. (2016), *Industrie 4.0: Integration und Vernetzung existierender Werkzeugmaschinen*. Masterarbeit, Hochschule RheinMain, Fachbereich Design Informatik Medien, Wiesbaden.

Minnen & Isbell et al. 2007

Minnen, D.; Isbell, C.; Essa, I. & Starner, T. (2007), „Detecting Subdimensional Motifs: An Efficient Algorithm for Generalized Multivariate Pattern Discovery“. *Proceedings of the 7th IEEE International Conference on Data Mining (ICDM 2007)*, Hrsg. N. Ramakrishnan, O. R. Zaïane, Y. Shi, C. W. Clifton & X. Wu. 7th IEEE International Conference on Data Mining (ICDM 2007). 28.-31.10.2007. Omaha, USA, IEEE, New York, USA, S. 601–606.

Minnen & Starner et al. 2006

Minnen, D.; Starner, T.; Essa, I. & Isbell, C. (2006), „Discovering Characteristic Actions from On-Body Sensor Data“. *Proceedings of the 10th International Symposium on Wearable Computers (ISWC06)*, Hrsg. P. Lukowicz, J. Healey & T. Martin. 10th International Symposium on Wearable Computers (ISWC06). 11.-14.10.2006. Montreux, Switzerland, IEEE, New York, USA, S. 11–18.

Mohammad & Nishida 2014

Mohammad, Y. & Nishida, T. (2014), „Exact Discovery of Length-Range Motifs“ in *Intelligent Information and Database Systems*, 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, N. T. Nguyen, B. Attachoo, B. Trawiński & K. Somboonviwat, Springer International Publishing, Cham, S. 23–32.

Mohanraj & Shankar et al. 2020

Mohanraj, T.; Shankar, S.; Rajasekar, R.; Sakthivel, N. R. & Pramanik, A. (2020), „Tool condition monitoring techniques in milling process — a review“, *Journal of Materials Research and Technology*, 9 (1), S. 1032–1042.

Mueen 2013

Mueen, A. (2013), „Enumeration of Time Series Motifs of All Lengths“. *Proceedings of the 2013 IEEE 13th International Conference on Data Mining Workshops (ICDMW '13)*, Hrsg. W. Ding, T. Washio, H. Xiong, G. Karypis, B. Thuraisingham, D. Cook & X. Wu. 2013 IEEE International Conference on Data Mining (ICDM). 07.-10.12.2013. Dallas, USA, IEEE Computer Society, Washington DC, USA, S. 547–556.

Mueen 2014

Mueen, A. (2014), „Time series motif discovery: dimensions and applications“, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 4 (2), S. 152–159.

Mueen & Keogh et al. 2009

Mueen, A.; Keogh, E.; Zhu, Q.; Cash, S. & Westover, B. (2009), „Exact Discovery of Time Series Motifs“. *Proceedings of the SIAM International Conference on Data Mining*, Hrsg. C. Apte, H. Park, K. Wang & M. J. Zaki. SIAM International Conference on Data Mining 2009. 30.04.-02.05.2009. Nevada, USA, SIAM, Philadelphia, USA, S. 473–484.

Mulder, Bethard & Moens 2015

Mulder, W. d.; Bethard, S. & Moens, M.-F. (2015), „A survey on the application of recurrent neural networks to statistical language modeling“, *Computer Speech & Language*, 30 (1), S. 61–98.

Müller 2007

Müller, M. (2007), *Information retrieval for music and motion*, Springer, Berlin, Heidelberg. ISBN: 978-3-540-74047-6.

Murakami & Doki et al. 2005

Murakami, K.; Doki, S.; Okuma, S. & Yano, Y. (2005), „A Study of Extraction Method of Motion Patterns Observed Frequently from Time-Series Posture Data“. *Proceedings of the 2005 IEEE International Conference on Systems, Man and Cybernetics*, Hrsg. M. Jamshidi, E. Tunstel & G. Anderson. 2005 IEEE International Conference on Systems, Man and Cybernetics. 10.-12.10.2005. Waikoloa, USA, IEEE, New York, USA, S. 3610–3615.

Muscariello, Gravier & Bimbot 2011

Muscariello, A.; Gravier, G. & Bimbot, F. (2011), „An efficient method for the unsupervised discovery of signalling motifs in large audio streams“. *Proceedings of the 9th International Workshop on Content-Based Multimedia Indexing (CBMI)*, Hrsg. J. M. Martinez, J. Bescós, G. Gravier, J. Jose & P. Villegas. 9th International Workshop on Content-Based Multimedia Indexing (CBMI). 13.-15.06.2011. Madrid, Spain, IEEE, New York, USA, S. 145–150.

Musliner & Hendler et al. 1995

Musliner, D. J.; Hendler, J. A.; Agrawala, A. K.; Durfee, E. H.; Strosnider, J. K. & Paul, C. J. (1995), „The challenges of real-time AI“, *Computer*, 28 (1), S. 58–66.

Netzer & Bach et al. 2022

Netzer, M.; Bach, J.; Puchta, A.; Gönzheimer, P. & Fleischer, J. (2022), „Process Segmented based Intelligent Anomaly Detection in Highly Flexible Production Machines under Low Machine Data Availability“. *Procedia CIRP - 55th Conference on Manufacturing Systems*, Hrsg. E. Carpanzano, C. Boër & A. Valente. 55th CIRP Conference on Manufacturing Systems. 29.06.-01.07.2022. Lugano, Switzerland, Elsevier, Amsterdam, S. 647–652.

Netzer & Begemann et al. 2021

Netzer, M.; Begemann, E.; Gönzheimer, P. & Fleischer, J. (2021), „Digitalisierung im deutschen Maschinen- und Anlagenbau“, *wt Werkstattstechnik online*, 111 (07-08), S. 526–530.

Netzer & Gönzheimer et al. 2020

Netzer, M.; Gönzheimer, P.; Michelberger, J. & Fleischer, J. (2020), „Skalierbarkeit von KI-Anwendungen in der Produktion“, *Fabriksoftware* (1), S. 51–54.

Netzer & Gönzheimer et al. 2021

Netzer, M.; Gönzheimer, P.; Schäfer, W.; Grosser, K. & Fleischer, J. (2021), „Daten-Enabling für eine breite KI-Anwendung“, *wt Werkstattstechnik online*, 111 (07-08), S. 481–485.

Netzer, Michelberger & Fleischer 2019

Netzer, M.; Michelberger, J. & Fleischer, J. (2019), „Intelligente Störungserkennung einer Werkzeugmaschine“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 114 (10), S. 635–638.

Netzer, Michelberger & Fleischer 2020

Netzer, M.; Michelberger, J. & Fleischer, J. (2020), „Intelligent Anomaly Detection of Machine Tools based on Mean Shift Clustering“. *Procedia CIRP - 53rd Conference on Manufacturing Systems*, Hrsg. Robert X. Gao, Kornel Ehmann. 53rd CIRP Conference on Manufacturing Systems. 01.-03.07.2020. Chicago, USA, Elsevier, Amsterdam, S. 1448–1453.

Netzer & Palenga et al. 2021

Netzer, M.; Palenga, Y.; Gönzheimer, P. & Fleischer, J. (2021), „Offline-Online pattern recognition for enabling time series anomaly detection on older NC machine tools“, *Journal of Machine Engineering*, 21, S. 98–108.

Netzer, Palenga & Fleischer 2022

Netzer, M.; Palenga, Y. & Fleischer, J. (2022), „Machine tool process monitoring by segmented timeseries anomaly detection using subprocess-specific thresholds“, *Production Engineering*, 16, S. 597–606.

Niu & Shi et al. 2011

Niu, Z.; Shi, S.; Sun, J. & He, X. (2011), „A Survey of Outlier Detection Methodologies and Their Applications“. *Proceedings of the 3rd International Conference of Artificial Intelligence and Computational Intelligence*, Hrsg. H. Deng, D. Miao, J. Lei & F. L. Wang. 3rd International Conference of Artificial Intelligence and Computational Intelligence. 24.-25.09.2011. Taiyuan, China, Springer, Berlin, Heidelberg, S. 380–387.

Nunthanid, Niennattrakul & Ratanamahatana 2011

Nunthanid, P.; Niennattrakul, V. & Ratanamahatana, C. A. (2011), „Discovery of variable length time series motif“. *Proceedings of the 8th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, Hrsg. M. Krairiksh, P. Chongstitvatana & K. Sripanawat. 2011 8th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2011). 17.-19.5.2011. Khon Kaen, Thailand, IEEE, New York, USA, S. 472–475.

Oberlé & Schorr et al. 2020

Oberlé, R.; Schorr, S.; Yi, L.; Glatt, M.; Bähre, D. & Aurich, J. C. (2020), „A Use Case to Implement Machine Learning for Life Time Prediction of Manufacturing Tools“. *Procedia CIRP - 53rd Conference on Manufacturing Systems*, Hrsg. Robert X. Gao, Kornel Ehmann. 53rd CIRP Conference on Manufacturing Systems. 01.-03.07.2020. Chicago, USA, Elsevier, Amsterdam, S. 1484–1489.

Patel & Keogh et al. 2002

Patel, P.; Keogh, E.; Lin, J. & Lonardi, S. (2002), „Mining motifs in massive time series databases“. *Proceedings of the 2002 IEEE International Conference on Data Mining*, Hrsg. V. Kumar. International Conference on Data Mining (ICDM 2002). 09.-12.12.2002. Maebashi City, Japan, IEEE, New York, USA, S. 370–377.

Pethig, Niggemann & Walter 2017

Pethig, F.; Niggemann, O. & Walter, A. (2017), „Towards Industrie 4.0 compliant configuration of condition monitoring services“. *Proceedings of the 15th International Conference on Industrial Informatics (INDIN)*, Hrsg. A. Walter Colombo, L. Gomes, J. Barata, S. Karnouskos, R. Luo, O. Sauer & Y. Shi. 2017 IEEE 15th International Conference on Industrial Informatics (INDIN). 24.-26.6.2017. Emden, Germany, IEEE, New York, USA, S. 271–276.

Pevzner & Sze 2000

Pevzner, P. A. & Sze, S.-H. (2000), „Combinatorial approaches to finding subtle signals in DNA sequences“. *Proceedings of the 8th International Conference on Intelligent Systems for Molecular Biology*, Hrsg. Philip E. Bourne, Michael Gribskov, Russ B. Altman, Nancy Jensen, Debra A. Hope, Thomas Lengauer, Julie C.

Mitchell, Eric D. Scheeff, Chris Smith, Shawn Strande, Helge Weissig.: 8th International Conference on Intelligent Systems for Molecular Biology. 19.-23.08.2000. San Diego, USA, AAAI Press, Palo Alto, USA, S. 269–278.

Pietruszka & Glöckler 2021

Pietruszka, W. D. & Glöckler, M. (2021), *MATLAB® und Simulink® in der Ingenieurpraxis*, Springer Fachmedien, Wiesbaden. ISBN: 978-3-658-29739-8.

Pincombea 2005

Pincombea, B. (2005), „Anomaly detection in time series of graphs using ARMA processes“, *Intelligence, Surveillance and Reconnaissance Division, Defence Science and Technology Organisation*, 24 (4), S. 1–10.

Praveenkumar & Saimurugan et al. 2014

Praveenkumar, T.; Saimurugan, M.; Krishnakumar, P. & Ramachandran, K. I. (2014), „Fault Diagnosis of Automobile Gearbox Based on Machine Learning Techniques“. *Procedia Engineering - 12th Global Congress on Manufacturing and Management (GCMM 2014)*, Hrsg. M. A. Xavier & P. K. Yarlagadda. 12th Global Congress on Manufacturing and Management (GCMM). 08.-10.12.2014. Vel-lore, India, Elsevier, Amsterdam, S. 2092–2098.

Puente León & Kiencke 2013

Puente León, F. & Kiencke, U. (2013), *Ereignisdiskrete Systeme. Modellierung und Steuerung verteilter Systeme*, DE GRUYTER, Berlin. ISBN: 978-3-486-73574-1.

Putz & Frieß et al. 2016

Putz, M.; Frieß, U.; Wabner, M.; Friedrich, A.; Zander, A. & Schlegel, H. (2016), „State-based and Self-adapting Algorithm for Condition Monitoring“. *Procedia CIRP - 10th CIRP Conference on Intelligent Computation in Manufacturing Engineering - (CIRP ICME '16)*, Hrsg. R. Teti. 10th CIRP Conference on Intelligent Computation in Manufacturing Engineering. 20.-22.07.2016. Ischia, Italy, Elsevier, Amsterdam, S. 311–316.

Rafiee & Arvani et al. 2007

Rafiee, J.; Arvani, F.; Harifi, A. & Sadeghi, M. H. (2007), „Intelligent condition monitoring of a gearbox using artificial neural network“, *Mechanical Systems and Signal Processing*, 21 (4), S. 1746–1754.

Ramaswamy, Rastogi & Shim 2000

Ramaswamy, S.; Rastogi, R. & Shim, K. (2000), „Efficient algorithms for mining outliers from large data sets“. *Proceedings of the 2000 ACM SIGMOD international conference on Management of data*, Hrsg. M. Dunham. The 2000 ACM SIGMOD international conference. 15.-18.05.2000. Dallas, USA, ACM, New York, USA, S. 427–438.

Ramotsoela, Abu-Mahfouz & Hancke 2018

Ramotsoela, D.; Abu-Mahfouz, A. & Hancke, G. (2018), „A Survey of Anomaly Detection in Industrial Wireless Sensor Networks with Critical Water System Infrastructure as a Case Study“, *Sensors*, 18 (8), S. 2491.

Reichel, Müller & Haeffs 2018

Reichel, J.; Müller, G. & Haeffs, J. (Hrsg.) (2018), *Betriebliche Instandhaltung*, Springer Vieweg, Heidelberg. ISBN: 978-3-662-53134-1.

Rengaswamy, Hägglund & Venkatasubramanian 2001

Rengaswamy, R.; Hägglund, T. & Venkatasubramanian, V. (2001), „A qualitative shape analysis formalism for monitoring control loop performance“, *Engineering Applications of Artificial Intelligence*, 14 (1), S. 23–33.

Ropohl 2009

Ropohl, G. (2009), *Allgemeine Technologie: eine Systemtheorie der Technik*, KIT Scientific Publishing, Karlsruhe. ISBN: 978-3-86644-374-7.

Rowley 2007

Rowley, J. (2007), „The wisdom hierarchy: representations of the DIKW hierarchy“, *Journal of Information Science*, 33 (2), S. 163–180.

Ruediger-Flore, Glatt & Aurich 2021

Ruediger-Flore, P.; Glatt, M. & Aurich, J. C. (2021), „Maschinelles Lernen bei hohem Variantenreichtum und kleinen Serien“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 116 (7-8), S. 538–543.

Salem & Guerassimov et al. 2013

Salem, O.; Guerassimov, A.; Mehaoua, A.; Marcus, A. & Furht, B. (2013), „Sensor fault and patient anomaly detection and classification in medical wireless sensor networks“. *Proceedings of the 2013 IEEE International Conference on Communi-*

cations (ICC), Hrsg. C. Mattheisen & A. Molisch. 2013 IEEE International Conference on Communications (ICC 2013). 09.-13.6.2013. Budapest, Hungary, IEEE, New York, USA, S. 4373–4378.

Sase & Ramírez et al. 2016

Sase, T.; Ramírez, J. P.; Kitajo, K.; Aihara, K. & Hirata, Y. (2016), „Estimating the level of dynamical noise in time series by using fractal dimensions“, *Physics Letters A*, 380 (11-12), S. 1151–1163.

Sathya & Abraham 2013

Sathya, R. & Abraham, A. (2013), „Comparison of supervised and unsupervised learning algorithms for pattern classification“, *International Journal of Advanced Research in Artificial Intelligence*, 2 (2), S. 34–38.

Schenk 2010

Schenk, M. (2010), *Instandhaltung technischer Systeme. Methoden und Werkzeuge zur Gewährleistung eines sicheren und wirtschaftlichen Anlagenbetriebs*, Springer, Berlin, Heidelberg. ISBN: 978-3-642-03948-5.

Schlagenhauf, Brander & Fleischer 2021

Schlagenhauf, T.; Brander, T. & Fleischer, J. (2021), „A stitching algorithm for automated surface inspection of rotationally symmetric components“, *CIRP Journal of Manufacturing Science and Technology*, 35 (5), S. 169–177.

Serin & Sener et al. 2020

Serin, G.; Sener, B.; Ozbayoglu, A. M. & Unver, H. O. (2020), „Review of tool condition monitoring in machining and opportunities for deep learning“, *The International Journal of Advanced Manufacturing Technology*, 109 (3-4), S. 953–974.

Sivaraks & Ratanamahatana 2015

Sivaraks, H. & Ratanamahatana, C. A. (2015), „Robust and accurate anomaly detection in ECG artifacts using time series motif discovery“, *Computational and mathematical methods in medicine* (2015), S. 1–21.

Smith 1985

Smith, D. R. (1985), „The design of divide and conquer algorithms“, *Science of Computer Programming*, 5, S. 37–58.

Spence, Parra & Sajda 2001

Spence, C.; Parra, L. & Sajda, P. (2001), „Detection, synthesis and compression in

mammographic image analysis with a hierarchical image probability model". *Proceedings of the IEEE Workshop on Mathematical Methods in Biomedical Image Analysis (MMBIA 2001)*, Hrsg. L. Staib. Workshop on Mathematical Methods in Biomedical Image Analysis. 09.-10.12.2001. Kauai, Hawaii, IEEE, New York, USA, S. 3–10.

Stiller 2006

Stiller, C. (2006), *Grundlagen der Mess- und Regelungstechnik*, Shaker, Aachen. ISBN: 978-3-83225582-4.

Sugiyama & Borgwardt 2013

Sugiyama, M. & Borgwardt, K. M. (2013), „Rapid Distance-Based Outlier Detection via Sampling“, *Advances in Neural Information Processing Systems (NIPS)*, 26, S. 467–475.

Tan, Steinbach & Kumar 2005

Tan, P.-N.; Steinbach, M. & Kumar, V. (2005), *Introduction to Data Mining*, Pearson Education India, New Delhi. ISBN: 978-8-13171472-0.

Thatte, Mitra & Heidemann 2011

Thatte, G.; Mitra, U. & Heidemann, J. (2011), „Parametric Methods for Anomaly Detection in Aggregate Traffic“, *IEEE/ACM Transactions on Networking*, 19 (2), S. 512–525.

Thommen & Achleitner et al. 2017

Thommen, J.-P.; Achleitner, A.-K.; Gilbert, D. U.; Hachmeister, D. & Kaiser, G. (2017), „Wissensmanagement“ in *Allgemeine Betriebswirtschaftslehre*, Hrsg. J.-P. Thommen, A.-K. Achleitner, D. U. Gilbert, D. Hachmeister & G. Kaiser, Springer Fachmedien, Wiesbaden, S. 551–560.

Torkamani & Lohweg 2017

Torkamani, S. & Lohweg, V. (2017), „Survey on time series motif discovery“, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 7 (2), S. 1199.

Venkatasubramanian & Rengaswamy et al. 2003

Venkatasubramanian, V.; Rengaswamy, R.; Kavuri, S. N. & Yin, K. (2003), „A review of process fault detection and diagnosis“, *Computers & Chemical Engineering*, 27 (3), S. 327–346.

Vercruyssen, Meert & Davis 2017

Vercruyssen, V.; Meert, W. & Davis, J. (2017), „Transfer Learning for Time Series Anomaly Detection“. *Proceedings of the European Conference of Machine Learning and Knowledge Discovery in Databases (ECML PKDD 2017)*, Hrsg. M. Ceci, J. Hollmén, L. Todorovski, C. Vens & S. Džeroski. European Conference of Machine Learning and Knowledge Discovery in Databases. 18.-22.09.2017. Skopje, North Macedonia, Springer International Publishing, Cham, S. 27-37.

Vogel 2015

Vogel, J. (2015), *Prognose von Zeitreihen. Eine Einführung für Wirtschaftswissenschaftler*, Springer Gabler, Wiesbaden. ISBN: 978-3-658-06837-0.

Waczowicz & Reischl et al. 2015

Waczowicz, S.; Reischl, M.; Hagenmeyer, V.; Mikut, R.; Klaiber, S.; Bretschneider, P.; Konotop, I. & Westermann, D. (2015), „Demand response clustering - How do dynamic prices affect household electricity consumption?“. *Proceedings of the 2015 IEEE Eindhoven PowerTech*, Hrsg. C. Vournas. 2015 IEEE Eindhoven PowerTech. 29.06.-02.07.2015. Eindhoven, Netherlands, IEEE, New York, USA, S. 1–6.

Webb & Hyde et al. 2016

Webb, G. I.; Hyde, R.; Cao, H.; Nguyen, H. L. & Petitjean, F. (2016), „Characterizing concept drift“, *Data Mining and Knowledge Discovery*, 30 (4), S. 964–994.

Weck & Brecher 2013

Weck, M. & Brecher, C. (2013), *Werkzeugmaschinen 3. Mechatronische Systeme, Vorschubantriebe, Prozessdiagnose*, Springer Vieweg, Berlin. ISBN: 978-3-642-38746-3.

Yeh, Kavantzias & Keogh 2017

Yeh, C.-C. M.; Kavantzias, N. & Keogh, E. (2017), „Matrix Profile VI: Meaningful Multidimensional Motif Discovery“. *Proceedings of the 2017 IEEE International Conference on Data Mining (ICDM)*, Hrsg. R. Gottumukkala, X. Ning, G. Dong, V. Raghavan, S. Aluru, G. Karypis, L. Miele & X. Wu. 2017 IEEE International Conference on Data Mining (ICDM). 18.-21.11.2017. New Orleans, USA, IEEE, New York, USA, S. 565–574.

Yuan & Liu 2013

Yuan, J. & Liu, X. (2013), „Semi-supervised learning and condition fusion for fault diagnosis“, *Mechanical Systems and Signal Processing*, 38 (2), S. 615–627.

Zare Moayedı & Masnadi-Shirazi 2008

Zare Moayedı, H. & Masnadi-Shirazi, M. A. (2008), „Arıma model for network traffic prediction and anomaly detection“. *Proceedings of the 2008 2nd International Symposium on Intelligent Information Technology Application (IITA)*, Hrsg. H. B. Zaman, T. M. T. Sembok, K. V. Rijsbergen, L. Zadeh, P. Bruza, T. Shih & M. N. Taib. 2008 Second International Symposium on Intelligent Information Technology Application (IITA). 26.-28.08.2008. Kuala Lumpur, Malaysia, IEEE, New York, USA, S. 1–6.

Zöllner, M. 2020

Zöllner, M. (2020), *Machinelles Lernen 1*. Vorlesungsskript, Karlsruher Institut für Technologie, Institut für Angewandte Informatik und Formale Beschreibungsverfahren, Karlsruhe.

Zuber & Bajrić 2020

Zuber, N. & Bajrić, R. (2020), „Gearbox faults feature selection and severity classification using machine learning“, *Eksploatacja i Niezawodność - Maintenance and Reliability*, 22 (4), S. 748–756.

Zwick, Zwick & Nguyen 2015

Zwick, A.; Zwick, J. & Nguyen, X. P. (2015), *Signal- und Rauschanalyse mit Quellenverschiebung*, Springer, Berlin, Heidelberg. ISBN: 978-3-642-54036-3.

Abbildungsverzeichnis

Abbildung 1-1: Aufbau der Arbeit dargestellt als Ablaufdiagramm.	6
Abbildung 2-1: Ausschnitt der Fertigungsverfahren nach (Deutsches Institut für Normung 2003). Darstellung in Anlehnung an (Hirsch 2016).	7
Abbildung 2-2: Einflussgrößen auf die Funktion der Fertigungsmittel und die Qualität der Produkte. Darstellung in Anlehnung an (Brecher & Weck 2021).	10
Abbildung 2-3: Beispielhafter Zusammenhang von Störungen in einer Werkzeugmaschine mit Auswirkung der OEE.	11
Abbildung 2-4: schematischer Aufbau eines Condition Monitoring Systems. Darstellung in Anlehnung an (Schenk 2010).	19
Abbildung 2-5: Links: Kurze, aber starke Abweichung. Rechts: Lange, aber geringe Abweichung), Unterschiedliche Interpretation der Ähnlichkeit von Mustern.	22
Abbildung 2-6: schematische Darstellung der Funktionsweise einer gleitenden Fensterung.	23
Abbildung 2-7: Hierarchie verschiedener Zeitreihendarstellungen nach (Lin & Keogh et al. 2007).	25
Abbildung 2-8: SAX-Transformation der Ausgangsdatenreihe in einen diskretisierten String. In Anlehnung an (Keogh & Lin 2005).	26
Abbildung 2-9: Punktweise Distanzberechnung zwischen zwei Sequenzen.	27
Abbildung 2-10: Links: einfaches statisches Distanzmaß (bspw. Euklidische Distanz). Rechts: elastisches Distanzmaß (bspw. Dynamic Time Warping (DTW)). Darstellung in Anlehnung an (Keogh & Lin 2005).	28
Abbildung 2-11: Übersicht Clusterverfahren in Anlehnung an (Jain, Murty & Flynn 1999).	30
Abbildung 2-12: Automatisiertes Finden von Clusterzentren. Darstellung in Anlehnung an (Klingel 2015).	30
Abbildung 2-13: Vereinfachte Darstellung der Funktionsweise des DBSCAN Algorithmus. Darstellung in Anlehnung an (Zöllner 2020).	31

Abbildung 2-14: Ein einfaches Beispiel von Ausreißer und Anomalien in einem 2-dimensionalen Datenset. Darstellung in Anlehnung an (Chandola, Banerjee & Kumar 2009).	34
Abbildung 2-15: Darstellung unterschiedlicher Ausprägungsformen von Anomalien.	35
Abbildung 2-16: Einordnung der Verfahren zur Anomalieerkennung nach (Niu & Shi et al. 2011).	36
Abbildung 2-17: Vergleich von (a) Neuronales Netz mit Vorwärtskopplung und (b) Rekurrentes Neuronales Netz. Darstellung in Anlehnung an (Mulder, Bethard & Moens 2015).	40
Abbildung 2-18: Typische Struktur eines Encoder-Decoder-Netzwerkes. Darstellung in Anlehnung an (Chen & Liu et al. 2020).	40
Abbildung 2-19: Wissenshierarchie. Darstellung in Anlehnung an (Akerkar & Sajja 2010) (Rowley 2007).	45
Abbildung 2-20: Methoden und Ansätze zur Anomalieklassifikation. Darstellung in Anlehnung an (Chiang 2001).	46
Abbildung 2-21: Merkmalsextraktion mit Hilfe einer QTA nach (Maurya & Paritosh et al. 2010).	48
Abbildung 2-22: Aktuelle Defizite und Lösungsansätze.	53
Abbildung 3-1: Schaubild der intelligenten Anomalieerkennung und Darstellung der Schnittstellen.	55
Abbildung 3-2: präzisierete Vorgehensweise zur Zielerfüllung.	56
Abbildung 4-1: Systemtheoretische Betrachtung der Messstrecke mit der Messgröße x , der Anomalie z sowie der Messgröße y .	60
Abbildung 5-1: Modularer Aufbau des Anomalieerkennungssystems.	64
Abbildung 5-2: (a) Reale Messdaten einer Fräsmaschinenachse (Z-Achse) und Berechnung des globalen Minimums als Musteranfang, (b) Zoom in den Bereich des globalen Minimums.	67
Abbildung 5-3: Anforderungen an die Datenvorverarbeitung.	68
Abbildung 5-4: Qualitative Bewertung der Konzepte.	70

Abbildung 5-5: Originalzeitreihe sowie deren Ableitung mit gefundenen Extremwerten im Toleranzfeld. Darstellung in Anlehnung an (A_Wurche 2020).	73
Abbildung 5-6: links: Glättungsiteration = 1; rechts: Glättungsiteration = 10 einer Messreihe einer Fräsmaschine. Darstellung in Anlehnung an (A_Wurche 2020).	74
Abbildung 5-7: Beispielhafte Darstellung der Verzerrung einer Distanzberechnung bei der Verwendung der euklidischen Distanz. Links: kleines Muster. Rechts: großes Muster. Darstellung in Anlehnung an (A_Michelberger 2019).	76
Abbildung 5-8: Darstellung zweier Sequenzen und deren Kennwerte in Anlehnung an (A_Brunnenkant 2020).	78
Abbildung 5-9: relative Zeitmessung beider Ansätze der Ähnlichkeitsbestimmung.	79
Abbildung 5-10: Einfluss des Signalrauschens auf das Mean-Shift-Clustering und die Wahl der Bandwidth.	82
Abbildung 5-11: Ablaufdiagramm zur Bestimmung des „bandwidth“ Parameters des Clusterverfahrens.	83
Abbildung 5-12: Bestimmung des durchschnittlichen Musters mit Hilfe der Berechnung des arithmetischen Mittels. Gelb, Blau, Rot: Im Cluster beinhaltete Sequenzen. Grün gestrichelt: Verzerrung des Repräsentanten. Darstellung nach (A_Michelberger 2019) (A_Kopp 2019).	85
Abbildung 5-13: Links: Durch das globale Minimierungsproblem ausgerichtete Sequenzen. Rechts: Berechneter Repräsentant in Grün. Darstellung nach (A_Michelberger 2019)	87
Abbildung 5-14: Bearbeitungsprozess bestehend aus Referenz- und Informationssignalen.	89
Abbildung 5-15: Beispielhafter Inhalt eines Puffers.	91
Abbildung 5-16: Iteratives Hinzufügen von DataDelta Datenpunkten.	92
Abbildung 5-17: Veranschaulichung der Wahl von DataBufferSize. Darstellung in Anlehnung an (A_Martin 2020).	94
Abbildung 5-18: Ablauf der Kennzahlberechnung in sechs Schritten.	96
Abbildung 5-19: Veranschaulichung der Anzahl der Summanden in Abhängigkeit des Startzeitpunkts s , der Länge des Puffers k und der Länge des Repräsentanten l .	97

Abbildung 6-1: Veranschaulichung des Toleranzbandes mit einem Cluster-Schwellwert. Darstellung nach (Netzer, Palenga & Fleischer 2022).	102
Abbildung 6-2: Hüllkurvendarstellung eines Signals. Darstellung nach (Netzer, Palenga & Fleischer 2022).	103
Abbildung 7-1: (a) Exemplarische Darstellung eines Soll-Signals mit einem überlagerten Sinussignal sowie resultierendem Ist-Signal. (b) zeigt das Differenzspektrum von Soll- und Ist-Signal. Darstellung nach (A_Winkler 2020).	107
Abbildung 7-2: Architektur des SVM-DeepNet-Konzepts zur Anomalieklassifikation. Darstellung in Anlehnung an (A_Winkler 2020).	111
Abbildung 7-3: Qualitative Darstellung des Klassifikationsfehlers in Abhängigkeit der Datenmenge	112
Abbildung 8-1: Aufbau Gesamtsystem und Schnittstelle Domänenwissen-Integration (rot umrandet).	113
Abbildung 8-2: Schematischer Aufbau der Wissensformulierung und der anschließenden Klassifikation. Darstellung in Anlehnung an (A_Alexander 2021).	115
Abbildung 8-3: Trendstrukturen (lokal) in Anlehnung an (Janusz & Venkatasubramanian 1991) (A_Alexander 2021).	116
Abbildung 8-4: Beispielhafte Aufschlüsselung einer Anomaliebeschreibung.	118
Abbildung 8-5: (a) Lunker-Anomalien in Spindel-Motorstrom, (b) Datenausschnitt eines Lunkers. Darstellung in Anlehnung an (A_Alexander 2021).	119
Abbildung 8-6: Beispielhafte Zeitreihe in Referenzfenster mit möglichen Trendstrukturen. Darstellung in Anlehnung an (A_Alexander 2021).	122
Abbildung 8-7: Ähnlichkeitsberechnung zwischen Trendsequenzen und gespeicherten Trendsequenzen. Darstellung in Anlehnung an (A_Alexander 2021).	123
Abbildung 9-1: Veranschaulichung des MVC-Konzepts (a) und des Observer-Patterns (b). Darstellung nach (A_Martin 2020).	126
Abbildung 9-2: App zur Anomalieerkennung. Darstellung des Reiters zur Mustererkennung „OPR“.	128
Abbildung 9-3: Darstellung des Reiters „Anomaly Detection“.	129

Abbildung 9-4: Beispielhaftes Produktportfolio mit gleicher Passfedernut und somit Prozesssegment.	131
Abbildung 9-5: links: Darstellung einer Fräsoperation in Steuerungsoberfläche, rechts: Einblick in Fräsmaschine.	132
Abbildung 9-6: links: CAD Modell des fertigen Bauteils, rechts: CAD Modell des Halbzeuges.	132
Abbildung 9-7: Darstellung der Referenzsignale (Achsen X,Y,Z) für die Datensegmentierung.	134
Abbildung 9-8: Beispielhafte Darstellung des gefundenen Repräsentanten in der App.	135
Abbildung 9-9: Datenreihe zum Spindelmotorstrom mit farbig markiertem Toleranzband. (Lunker). Darstellung in Anlehnung an (Netzer, Palenga & Fleischer 2022).	136
Abbildung 9-10: Datenreihe zum Spindelmotorstrom mit farbig markiertem Toleranzband. (Verschleiß).	137
Abbildung 9-11: Versuchsaufbau mit künstlich erzeugter Anomalie als Bauteilverlust.	140
Abbildung 9-12: Versuchsaufbau mit künstlich erzeugter Anomalie als Momentüberhöhung.	141
Abbildung 9-13: Datenreihe zum Momentenverlauf in Achse 3 mit gelb markiertem Toleranzband, sowie den rot markierten Toleranzbandbrüchen (Part-Drop).	143
Abbildung 9-14: Datenreihe zum Stromverlauf in Achse 1 mit farbig markiertem Toleranzband (Momentenüberhöhung mit Gummiband).	144
Abbildung 9-15: Fügeeinheit mit Kraft-Weg Datenaufnahme (Fa. Promess Typ UFMm PR5, 3 kN). Darstellung in Anlehnung an (Netzer & Gönzheimer et al. 2021) (Netzer & Bach et al. 2022).	146
Abbildung 9-16: links: Ausschnitt einer Prozessfolge beim Einpressen der Magnete in den Stator, rechts: berechneter Repräsentant. Darstellung nach (Netzer & Bach et al. 2022).	147
Abbildung 9-17: Darstellung der selbstgelernten Eingriffsgrenzen sowie die Anomalie durch Verkanten des Magnetes im Kraftsignal.	147

Abbildung 0-1: Oberfläche nach aufgefundener Anomalie. Links: Eingabe Metadaten der Anomalie, rechts: Signalverlauf und Informationen. XXV

Abbildung 0-2: Einstellung der Mustererkennung für die Fräsversuch-Validierung. XXVI

Abbildung 0-3: Einstellungen der Anomalieerkennung für die Fräsversuch-Validierung. XXVI

Abbildung 0-4: Einstellung der Mustererkennung für die Roboter-Validierung. XXVI

Abbildung 0-5: Einstellungen der Anomalieerkennung für die Roboter-Validierung. XXVII

Abbildung 0-6: Einstellungen der Anomalieerkennung für die Fügeinheit-Validierung. XXVII

Tabellenverzeichnis

Tabelle 1: Nomenklatur nach (A_Alexander 2021).	117
Tabelle 2: Anomalieprofil der Luncker-Anomalie nach (A_Alexander 2021).	120
Tabelle 3: Trendstrukturen und deren Darstellung als Funktion	121
Tabelle 4: Übersicht der verfügbaren Daten aus der Steuerung	133
Tabelle 5: Übersicht der verfügbaren Daten aus der Steuerung	142

Anhang

Nachfolgend sind weitere Darstellungen der Anomalieerkennungs-App sowie die Einstellungen, welche für die Validierung getroffen wurden, sichtbar.

Anwender-Feedback

Anomalieinformationen/ -signale

Anomalie-klassifikation

Handlungsempfehlung

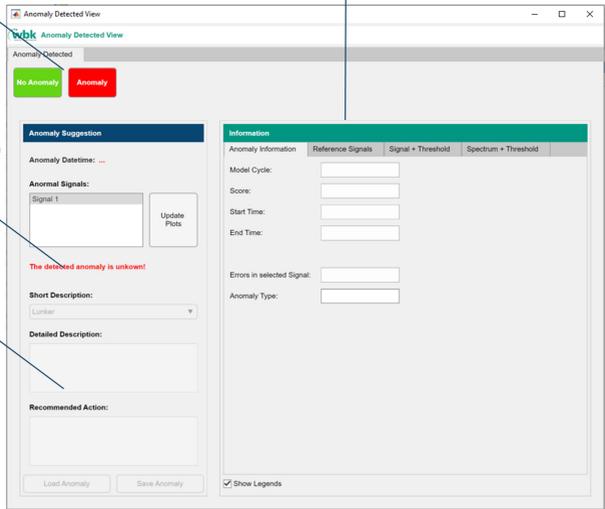


Abbildung 0-1: Oberfläche nach aufgefundener Anomalie. Links: Eingabe Metadaten der Anomalie, rechts: Signalverlauf und Informationen.

Machine settings				Algorithm settings			
Machine Name: <input type="text" value="Prufstand"/>		Sample Rate: <input type="text" value="500"/>		input data		segmentation	
first dimension: <input type="radio"/> x <input type="radio"/> y <input type="radio"/> z				Number of data measurands: <input type="text" value="16"/>		Iterative adjustment of noise cancelling: <input type="checkbox"/> On	
Line in Input Data: <input type="text" value="1"/>		Min time duration for one micro pattern in s: <input type="text" value="12"/>		Rows in which the conditions are: <input type="text" value="16"/>		Segmentation of invariances: <input type="checkbox"/> On	
Number of Pattern in Reference: <input type="text" value="6"/>		Possible minimum movement in mm/min: <input type="text" value="1000"/>		hyperparameterfeintuning		clustering	
second dimension: <input type="radio"/> x <input checked="" type="radio"/> y <input type="radio"/> z <input type="radio"/> no second dimension				Representative Coverage: <input type="checkbox"/> On		Distance Metric: <input type="text" value="Euklidische Dista..."/>	
Line in Input Data: <input type="text" value="2"/>		Min time duration for one micro pattern in s: <input type="text" value="12"/>		Tolerance field in mm: <input type="text" value="1"/>		Max. number of pattern: <input type="text" value="50"/>	
Number of Pattern in Reference: <input type="text" value="5"/>		Possible minimum movement in mm/min: <input type="text" value="1000"/>		Resolution hyperparameterfeintuning: <input type="text" value="20"/>		Max. relative prevalence: <input type="text" value="1"/>	
third dimension: <input type="radio"/> x <input type="radio"/> y <input checked="" type="radio"/> z <input type="radio"/> no third dimension				Prominence Peak: <input type="text" value="4"/>			
Line in Input Data: <input type="text" value="3"/>		Min time duration for one micro pattern in s: <input type="text" value="0.5"/>					
Number of Pattern in Reference: <input type="text" value="3"/>		Possible minimum movement in mm/min: <input type="text" value="700"/>					

Abbildung 0-2: Einstellung der Mustererkennung für die Fräsversuch-Validierung.

General Settings			Cycle Detection			Anomaly Detection		
DataBufferSize: <input type="text" value="1000"/>		[]	DesiredFrequency: <input type="text" value="83.33"/>		[Hz]	Use VarianceMatch: <input checked="" type="checkbox"/>		
DataDelta: <input type="text" value="100"/>		[]	InDataPercentage: <input type="text" value="1"/>		[0...1]	Use VarianceSpectrumMatch: <input type="checkbox"/>		
DimensionsToScore: <input type="text" value="3"/>		[]	InDataPoints: <input type="text" value="15"/>		[]	AllowedErrorsTan: <input type="text" value="8"/>		[]
InputFrequency: <input type="text" value="83.33"/>		[Hz]	DetectionThreshold: <input type="text" value="1"/>		[]	AllowedErrorsCos: <input type="text" value="40"/>		[]
MinCycleLength: <input type="text" value="80"/>		[]	PredictorDiff: <input type="text" value="0.35"/>		[0...1]			
MaxCycleLength: <input type="text" value="900"/>		[]	Cycle Detection: <input type="text" value="FastFullMatchCycleScoreCalculator"/>					
			Cycle Prediction: <input type="text" value="MarkovModel"/>					
			Status Variable 1: <input type="text" value="15"/>		[]			
			Status Variable 2: <input type="text" value="10"/>		[]			
			Status Variable 3: <input type="text" value="2"/>		[]			

Abbildung 0-3: Einstellung der Anomalieerkennung für die Fräsversuch-Validierung.

Machine settings				Algorithm settings			
Machine Name: <input type="text" value="Kuka"/>		Sample Rate: <input type="text" value="83.33"/>		input data		segmentation	
first dimension: <input checked="" type="radio"/> x <input type="radio"/> y <input type="radio"/> z				Number of data measurands: <input type="text" value="117"/>		Iterative adjustment of noise cancelling: <input type="checkbox"/> On	
Line in Input Data: <input type="text" value="2"/>		Min time duration for one micro pattern in s: <input type="text" value="40"/>		Rows in which the conditions are: <input type="text" value="117"/>		Segmentation of invariances: <input type="checkbox"/> On	
Number of Pattern in Reference: <input type="text" value="4"/>		Possible minimum movement in mm/min: <input type="text" value="120"/>		hyperparameterfeintuning		clustering	
second dimension: <input type="radio"/> x <input checked="" type="radio"/> y <input type="radio"/> z <input type="radio"/> no second dimension				Representative Coverage: <input type="checkbox"/> On		Distance Metric: <input type="text" value="Euklidische Dista..."/>	
Line in Input Data: <input type="text" value="3"/>		Min time duration for one micro pattern in s: <input type="text" value="40"/>		Tolerance field in mm: <input type="text" value="1"/>		Max. number of pattern: <input type="text" value="50"/>	
Number of Pattern in Reference: <input type="text" value="2"/>		Possible minimum movement in mm/min: <input type="text" value="120"/>		Resolution hyperparameterfeintuning: <input type="text" value="20"/>		Max. relative prevalence: <input type="text" value="1"/>	
third dimension: <input type="radio"/> x <input type="radio"/> y <input checked="" type="radio"/> z <input type="radio"/> no third dimension				Prominence Peak: <input type="text" value="4"/>			
Line in Input Data: <input type="text" value="4"/>		Min time duration for one micro pattern in s: <input type="text" value="40"/>					
Number of Pattern in Reference: <input type="text" value="4"/>		Possible minimum movement in mm/min: <input type="text" value="120"/>					

Abbildung 0-4: Einstellung der Mustererkennung für die Roboter-Validierung.

View Settings		
General Settings	Cycle Detection	Anomaly Detection
DataBufferSize: <input type="text" value="6000"/> [-] DataDelta: <input type="text" value="500"/> [-] DimensionsToScore: <input type="text" value="3"/> [-] InputFrequency: <input type="text" value="500"/> [Hz] MinCycleLength: <input type="text" value="50"/> [-] MaxCycleLength: <input type="text" value="16000"/> [-]	DesiredFrequency: <input type="text" value="500"/> [Hz] InDataPercentage: <input type="text" value="1"/> [0..1] InDataPoints: <input type="text" value="200"/> [-] DetectionThreshold: <input type="text" value="0.05"/> [-] PredictionDiff: <input type="text" value="0.35"/> [0..1] Cycle Detection: <input type="text" value="FastFullMatchCycleScoreCalculator"/> Cycle Prediction: <input type="text" value="MarkovModel"/> Status Variable 1: <input type="text" value="15"/> [-] Status Variable 2: <input type="text" value="10"/> [-] Status Variable 3: <input type="text" value="2"/> [-]	Use VarianceMatch <input checked="" type="checkbox"/> Use VarianceSpectrumMatch <input type="checkbox"/> AllowedErrorsTran: <input type="text" value="5"/> [-] AllowedErrorsCont: <input type="text" value="20"/> [-]

Abbildung 0-5: Einstellungen der Anomalieerkennung für die Roboter-Validierung.

View Settings		
General Settings	Cycle Detection	Anomaly Detection
DataBufferSize: <input type="text" value="300"/> [-] DataDelta: <input type="text" value="30"/> [-] DimensionsToScore: <input type="text" value="3"/> [-] InputFrequency: <input type="text" value="31"/> [Hz] MinCycleLength: <input type="text" value="80"/> [-] MaxCycleLength: <input type="text" value="300"/> [-]	DesiredFrequency: <input type="text" value="31"/> [Hz] InDataPercentage: <input type="text" value="0.9"/> [0..1] InDataPoints: <input type="text" value="20"/> [-] DetectionThreshold: <input type="text" value="3"/> [-] PredictionDiff: <input type="text" value="0.35"/> [0..1] Cycle Detection: <input type="text" value="FastFullMatchCycleScoreCalculator"/> Cycle Prediction: <input type="text" value="MarkovModel"/> Status Variable 1: <input type="text" value="15"/> [-] Status Variable 2: <input type="text" value="10"/> [-] Status Variable 3: <input type="text" value="2"/> [-]	Use VarianceMatch <input checked="" type="checkbox"/> Use VarianceSpectrumMatch <input type="checkbox"/> AllowedErrorsTran: <input type="text" value="1"/> [-] AllowedErrorsCont: <input type="text" value="40"/> [-]

Abbildung 0-6: Einstellungen der Anomalieerkennung für die Fügeinheit-Validierung

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

Bisher erschienene Bände:

Band 0

Dr.-Ing. Wu Hong-qi

Adaptive Volumenstromregelung mit Hilfe von drehzahlgeregelten Elektroantrieben

Band 1

Dr.-Ing. Heinrich Weiß

**Fräsen mit Schneidkeramik - Verhalten des System
Werkzeugmaschine-Werkzeug-Werkstück und Prozessanalyse**

Band 2

Dr.-Ing. Hans-Jürgen Stierle

**Entwicklung und Untersuchung hydrostatischer Lager für die
Axialkolbenmaschine**

Band 3

Dr.-Ing. Herbert Hörner

Untersuchung des Geräuschverhaltens druckgeregelter Axialkolbenpumpen

Band 4

Dr.-Ing. Rolf-Dieter Brückbauer

**Digitale Drehzahlregelung unter der besonderen Berücksichtigung
von Quantisierungseffekten**

Band 5

Dr.-Ing. Gerhard Staiger

Graphisch interaktive NC-Programmierung von Drehteilen im Werkstattbereich

Band 6

Dr.-Ing. Karl Peters

**Ein Beitrag zur Berechnung und Kompensation von Positionierfehlern an
Industrierobotern**

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 Fertigungsverfahren 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 fünfachsigem Fräsen von Freiformflächen

Band 49

Dr.-Ing. Wolfgang Bernhart

Beitrag zur Bewertung von Montagevarianten: Rechnergestützte Hilfsmittel zur kostenorientierten, parallelen Entwicklung von Produkt und Montagesystem

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 bearbeitungs-elementorientiertes, 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 Zerspansprozess 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 Vossman

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 Fünffachsfräsbearbeitung 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 Abrasivstrahlschneiden

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 Gönzheimer

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 Dienstleistungsorganisationen: 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 Mikroteile

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 Makrozerspannung 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 adaptiven 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 Krauße

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-Antriebsselementen

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 Zahnpulen

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 Unsicherheit
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 Montagesysteme – 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 Segebade

Erhöhung der Verschleißbeständigkeit von Bauteilen aus Ti-6Al-4V mittels simulationsgestützter Zerspanung und mechanischer Mikrotexturierung

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 Vereinzelnungs- 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 Schlagenhauf

Bildbasierte Quantifizierung und Prognose des Verschleißes an Kugelgewindetriebspindeln

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

