

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

Philipp Gönzheimer

**Automatisierte Bereitstellung
von Maschinensteuerungsdaten
in Brownfield-Produktionssystemen**

Ein Beitrag zur Digitalisierung von Bestandsanlagen
am Beispiel von Werkzeugmaschinen

Band 279



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

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

Philipp Gönninger

**Automatisierte Bereitstellung
von Maschinensteuerungsdaten
in Brownfield-Produktionssystemen**
Ein Beitrag zur Digitalisierung von Bestandsanlagen
am Beispiel von Werkzeugmaschinen

Band 279

**Automatisierte Bereitstellung von Maschinensteuerungsdaten
in Brownfield-Produktionssystemen**
Ein Beitrag zur Digitalisierung von Bestandsanlagen
am Beispiel von Werkzeugmaschinen

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

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

angenommene

Dissertation

von

Philipp Gönzheimer, M.Sc.

Tag der mündlichen Prüfung: 25.03.2024

Hauptreferent: Prof. Dr.-Ing. Jürgen Fleischer

Korreferenten: Prof. Dr.-Ing. Jörg Krüger

Assoc. Prof. Dr.-Ing. Thorsten Wüst

Bibliografische Information der Deutschen Nationalbibliothek

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

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

Copyright Shaker Verlag 2024

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

Printed in Germany.

ISBN 978-3-8440-9488-6

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 der Herausgeber

Die schnelle und effiziente Umsetzung innovativer, nachhaltiger und wirtschaftlicher Technologien stellt den entscheidenden Wirtschaftsfaktor für produzierende Unternehmen dar. Universitäten können als "Wertschöpfungspartner" einen wesentlichen Beitrag zur Wettbewerbsfähigkeit der Industrie leisten, indem sie wissenschaftliche Grundlagen sowie neue Methoden und Technologien erarbeiten und aktiv den Umsetzungsprozess in die praktische Anwendung unterstützen.

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

Prof. Dr.-Ing. Jürgen Fleischer

Prof. Dr.-Ing. Gisela Lanza

Prof. Dr.-Ing. habil. Volker Schulze

Prof. Dr.-Ing. Frederik Zanger

Vorwort des Verfassers

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

Mein besonderer Dank gilt meinem Doktorvater Herrn Prof. Dr.-Ing. Jürgen Fleischer für die Betreuung meiner wissenschaftlichen Arbeit als Hauptreferent, die persönliche Unterstützung, die Förderung und das mir entgegengebrachte Vertrauen während meiner Tätigkeit als akademischer Mitarbeiter und später auch als Gruppenleiter für Werkzeugmaschinen und Mechatronik sowie Oberingenieur. Weiterhin bedanke ich mich bei Herrn Prof. Dr.-Ing. Jörg Krüger und Herrn Assoc. Prof. Dr.-Ing. Thorsten Wüst für ihr Interesse an meiner Arbeit und die Übernahme der Korreferate sowie bei Herrn Prof. Dr. rer. nat. Frank Gauterin für den Prüfungsvorsitz.

Bei allen Kolleginnen und Kollegen sowie Ehemaligen des wbk, insbesondere aus meinem Forschungsbereich Maschinen, Anlagen und Prozessautomatisierung, möchte ich mich für die hervorragende Zusammenarbeit bedanken. Die kollegiale Atmosphäre, die vielen gemeinsamen Stunden und Erlebnisse am wbk und darüber hinaus sowie die entstandenen Freundschaften werden mich immer auf eine einmalige Zeit zurückblicken lassen. Hervorheben möchte ich auch die zahlreichen Studierenden, die im Rahmen von Abschlussarbeiten oder als wissenschaftliche Hilfskräfte zum Erfolg meiner Arbeit am wbk und auch dieser Dissertation beigetragen haben.

Abschließend möchte ich mich ganz besonders bei meiner ganzen Familie bedanken, bei meinem Bruder Christoph für den konstruktiven Austausch und seine Ratschläge, aber vor allem bei meinen Eltern Gabriele und Hans Peter für ihre stetige Unterstützung und ihren Rückhalt, die mir mein Studium und die daran anschließende Promotion erst ermöglicht haben.

Karlsruhe, im März 2024

Philipp Gönzheimer

Abstract

Industry 4.0 has been a success story for many companies over the last ten years, not least because of the ever-growing number of profitable applications. However, the implementation of Industry 4.0 often poses a major challenge for companies, particularly in brownfield production with legacy machines, due to heterogeneous equipment and data structures. The communication connection of existing machines as well as the identification and assignment of signals to Industry 4.0 applications is often a manual and time-consuming process for users.

This dissertation develops approaches for the automated provision of machine control data in brownfield production systems. The aim of the developed system is the automated extraction of data from interfaces of existing machines as well as the identification and assignment of targeted signals for Industry 4.0 applications from the extracted data sets. To achieve this, connectors for data exchange with existing control systems and communication protocols in the brownfield are created on the basis of open source components. In the next step, concepts for automated signal identification based on analytical and machine learning approaches are developed. The hybrid solution system derived from both approaches is then integrated into an assistance system together with the established connectors. Part of the assistance system is a guided mode that directs the user through the provisioning process from the selection of the data source to the output of the signal assignment. Finally, the approach is validated on selected demonstrators with regard to its functionality and transferability.

Kurzfassung

Industrie 4.0 war in den letzten zehn Jahren für viele Unternehmen eine Erfolgsgeschichte, nicht zuletzt aufgrund der nach wie vor wachsenden Anzahl an gewinnbringenden Anwendungen. Vor allem in der Brownfield-Produktion mit Bestandsmaschinen stellt die Umsetzung von Industrie 4.0 aufgrund heterogener Anlagen- und Datenstrukturen jedoch häufig eine große Herausforderung für Unternehmen dar. Die kommunikationstechnische Anbindung von Bestandsmaschinen sowie die Identifikation und Zuordnung von Signalen zu Industrie 4.0-Anwendungen ist für Anwender häufig ein manueller und zeitaufwändiger Prozess.

Im Rahmen dieser Dissertation werden Ansätze für die automatisierte Bereitstellung von Maschinensteuerungsdaten in Brownfield-Produktionssystemen entwickelt. Ziel des entwickelten Systems sind die automatisierte Extraktion von Daten aus Schnittstellen von Bestandsmaschinen sowie die Identifikation und Zuordnung angestrebter Signale für Industrie 4.0-Anwendungen aus den extrahierten Datensätzen. Dafür werden zunächst auf Basis von Open Source-Bausteinen Konnektoren für den Datenaustausch mit im Brownfield existierenden Steuerungssystemen und Kommunikationsprotokollen erarbeitet. Im darauffolgenden Schritt werden Konzepte zur automatisierten Signalidentifikation auf Basis von analytischen sowie Machine Learning-Ansätzen entwickelt. Das von beiden Ansätzen abgeleitete hybride Lösungssystem wird darauf aufbauend zusammen mit den erarbeiteten Konnektoren in ein Assistenzsystem integriert. Teil des Assistenzsystems ist ein geführter Modus, der den Anwender von der Auswahl der Datenquelle bis zur Ausgabe der Signalzuordnung durch den Bereitstellungsprozess leitet. Der Ansatz wird abschließend an ausgewählten Demonstratoren hinsichtlich seiner Funktionalität und Übertragbarkeit validiert.

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Formelzeichen und Abkürzungen	V
Begriffserklärungen und Erläuterungen	6
1 Einleitung	7
1.1 Motivation	7
1.2 Zielsetzung	9
1.3 Aufbau der Arbeit	9
2 Stand der Forschung und Technik	12
2.1 Effektivitätssteigerungen durch Industrie 4.0	12
2.1.1 Gesamtanlageneffektivität	12
2.1.2 Anwendungen im Bereich Industrie 4.0	12
2.2 Produktionsmaschinen	13
2.2.1 Werkzeugmaschinenarten und -komponenten	13
2.2.2 Antriebssysteme	17
2.2.3 Steuerungs- und Regelungstechnik	19
2.3 Bereitstellung von Maschinensteuerungsdaten	25
2.3.1 Kommunikation in der Automatisierungstechnik	25
2.3.2 Datenschnittstellen im Brownfield	28
2.3.3 Maschinenanbindung und Zugriffsmöglichkeiten	29
2.3.4 Identifikation von Signalen	30
2.4 Analyse von Zeitreihendaten	31
2.4.1 Verarbeitung von Zeitreihendaten	32
2.4.2 Maschinelles Lernen zur Klassifikation von Zeitreihendaten	35
2.4.3 Industrielle Anwendungen	40
2.5 Bewertung des Stands der Forschung und Technik	42
2.5.1 Fazit zum Stand der Forschung und Technik	42
2.5.2 Aktuelle Defizite in Forschung und Technik	43

3	Zielsetzung und Vorgehensweise	45
3.1	Konkretisierung der Zielsetzung	45
3.2	Vorgehensweise zur Zielerreichung	47
4	Kommunikationstechnische Maschinenanbindung und Extraktion von Maschinendaten	48
4.1	Eingrenzung des Modellierungsraums	48
4.2	Datenextraktion in Brownfield-Maschinen	49
4.2.1	Betrachtung der Zugriffsmöglichkeiten von Datenquellen	49
4.2.2	Umsetzung der Datenextraktion	50
5	Identifikation von Maschinensteuerungssignalen	58
5.1	Analytische Signalidentifikation	60
5.1.1	Konzept	60
5.1.2	Datensätze	64
5.1.3	Stufe 1 – Filterung trivialer Klassen	67
5.1.4	Stufe 2 – Extraktion der Positionssignale	70
5.1.5	Stufe 3 – Bestimmung weiterer Signale durch regelbasierte Klassifikation	72
5.1.6	Stufe 4 – Identifikation von Spindelsignalen	75
5.1.7	Stufe 5 – Kinematische Zusammenhänge	77
5.1.8	Stufe 6 – Signalgruppierung der Achsen	80
5.1.9	Ergebnisse und Bewertung	82
5.2	ML-basierte Signalidentifikation	85
5.2.1	Konzept	85
5.2.2	Datensätze	87
5.2.3	Verwendete ML-Modelle	88
5.2.4	Vorverarbeitung	90
5.2.5	Signalidentifikation mit neuronalen Netzen	97
5.2.6	Signalidentifikation mit Random Forests	105
5.2.7	Ergebnisse und Bewertung	110
5.3	ML-basierte Signalidentifikation mit Korrelationsregeln	115
5.3.1	Konzept	116

5.3.2	Datensätze	118
5.3.3	Stufe 1 – Machine Learning-basierte Klassifikation	119
5.3.4	Stufe 2 – Gruppierung von Zeitreihen	125
5.3.5	Stufe 3 – Achszuweisung	126
5.3.6	Ergebnisse und Bewertung	129
5.4	Hybrider Ansatz zur Signalidentifikation	140
5.4.1	Konzept	141
5.4.2	Datensätze	144
5.4.3	Stufe 1 – Datenvorverarbeitung	145
5.4.4	Stufe 2 – Machine Learning-basierte Extraktion von Positionssignalen	147
5.4.5	Stufe 3 – Analytische Identifikation aller Signale	148
5.4.6	Ergebnisse und Bewertung	155
6	Systemintegration	160
6.1	Aufbau der Benutzeroberfläche des Assistenzsystems	160
6.2	Geführter Ablauf	161
7	Validierung des Lösungskonzepts	168
7.1	Validierung	168
7.1.1	Allgemeiner Aufbau	168
7.1.2	Validierung 1 – Horizontal-Fräsmaschine	169
7.1.3	Validierung 2 – Vertikal-Fräsmaschine	171
7.1.4	Validierung 3 – Honmaschine	173
7.1.5	Validierung 4 – Industrieroboter	175
7.2	Zusammenfassende Bewertung der Validierung	179
7.2.1	Bewertung innerhalb des Typs Fräszentren	179
7.2.2	Bewertung des Gesamtmodells auf Maschinen anderen Typs	180
7.2.3	Zusammenfassende Bewertung und Grenzen des Ansatzes	181
8	Zusammenfassung und Ausblick	183
8.1	Zusammenfassung	183
8.2	Ausblick	185

9	Publikationsliste des Autors	187
10	Literaturverzeichnis	191
11	Abbildungsverzeichnis	I
12	Tabellenverzeichnis	VII

Formelzeichen und Abkürzungen

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

Begriffserklärungen und Erläuterungen

Die Bedeutung der im Haupttext verwendeten und nicht verbreiteten Fachbegriffe wird bei ihrer ersten Nennung erklärt. Über diese hinaus werden im Folgenden die zentralen in dieser Arbeit genutzten Begriffe für eine klare Definition erläutert.

Begriff	Erklärung
Brownfield	Produktionssysteme oder einzelne Maschinen, die bereits, potentiell seit längerer Zeit, in Betrieb sind
Maschinensteuerungsdaten	Daten der Maschine oder von Maschinenkomponenten, die im Steuerungssystem der Maschine verarbeitet werden
Datenextraktion	Verfügbarmachung von Maschinendaten aus potentiell schwer zugänglichen Datenquellen
Signalidentifikation	Identifikation angestrebter Signale aus Datensätzen in unbekannter Semantik
Datenbereitstellung	Anwendungsorientierter Prozess, der Datenextraktion und Signalidentifikation umfasst und damit Maschinendaten extrahiert sowie angestrebten Signalen zuordnet

1 Einleitung

1.1 Motivation

Der globale Wettbewerb und weitere Herausforderungen wie volatile Märkte und unsichere Lieferketten stellen produzierende Unternehmen vor zunehmende Anforderungen hinsichtlich Kosten, Lieferzeiten und Flexibilität. Einen zentralen Lösungsansatz für Unternehmen bei der Bewältigung dieser Herausforderungen stellen die Digitalisierung und Vernetzung der Produktion dar. Diese bieten vielfältige Potentiale, unter anderem in Form von Steigerungen der Produktqualität oder der Senkung von Produktionskosten (Bauernhansl & Krüger et al. 2016). Zusätzlich spielt auch die Verfügbarkeit von Maschinen und Anlagen für Unternehmen und deren Wettbewerbsfähigkeit eine entscheidende Rolle. Um eine hohe Verfügbarkeit gewährleisten zu können, bieten sich zahlreiche Anwendungen im Bereich Industrie 4.0 an. Diese umfassen beispielsweise Anomalieerfassungs- und Zustandsüberwachungssysteme für Maschinen und Anlagen (Benker & Zaeh 2022; Klein & Thiele et al. 2020; Netzer & Palenga et al. 2021).

Eine notwendige Grundlage für alle Industrie 4.0-Anwendungen bilden Daten aus Maschinen und Prozessen, die die Anwendungen speisen und von diesen verarbeitet werden können. Diese Daten können in existierenden Brownfield-Produktionsumgebungen durch verschiedene Arten erzeugt oder ausgelesen werden. Einerseits besteht die Möglichkeit der Ausrüstung beziehungsweise Nachrüstung der Produktionsanlagen mit externer Sensorik zur Generierung von Datensätzen. Andererseits bietet sich auch die Verwendung bereits vorhandener Signale aus dem Steuerungssystem der Maschine an. Externe Sensorik hat dabei den Nachteil, dass ihre Nachrüstung sowie die der zugehörigen Hard- und Software häufig kostenintensiv ist und die Ansätze als individuelle Umsetzungen nur bedingt skalierbar sind. Dagegen versprechen Anwendungen, die auf vorhandenen Steuerungsdaten aufbauen, geringere Umsetzungskosten sowie eine bessere Skalierbarkeit. Die für viele Unternehmen größte Herausforderung bei der Nutzung interner Steuerungsdaten aus existierenden Maschinen und Anlagen ist die kommunikationstechnische Anbindung dieser. Vor allem im Hinblick auf die große Heterogenität mit unterschiedlichen Kommunikationsschnittstellen und dem breiten Spektrum an Herstellern und beim Maschinenalter kann sich die Anbindung aufwändig und zeitintensiv gestalten. Die überwiegenden Hemmnisse hierbei liegen für Unternehmen vor allem in fehlenden personellen Ressourcen, aber auch

in fehlender technischer Expertise des Personals. (Gönzheimer & Netzer et al. 2022; Netzer & Begemann et al. 2021)

Standardisierte Informationsmodelle können bei der Bereitstellung von Daten unterstützen. Beispiele wie die Spezifikation Universal Machine Technology Interface „umati“ für das Kommunikationsprotokoll OPC UA bieten Lösungen, um Maschinendaten in Struktur und Semantik herstellerübergreifend verfügbar zu machen und so einheitliche Schnittstellen zu schaffen. Sie schaffen in Anwendungen aber nur dort Abhilfe, wo Anlagen den Standard nutzen und nach ihm beschrieben sind. Vor allem ältere Maschinen im Brownfield, beispielsweise spanende Werkzeugmaschinen mit einem Durchschnittsalter von mehr als 10 Jahren, nutzen diesen häufig noch nicht (Barton & Stamm et al. 2020; Krüger & Vick et al. 2017). Eine weitere Einschränkung stellen begrenzte Signalmräume standardisierter Informationsmodelle dar, die nicht alle angestrebten Signale abdecken. Dies gilt vor allem für zentrale Maschinensteuerungsdaten auf Komponentenebene wie Motorströme oder Positionsdaten aus Antriebsachsen, die für zahlreiche Industrie 4.0-Anwendungen wie die zuvor beschriebenen benötigt werden.

Die Extraktion, Identifikation und Zuweisung von Signalen aus Steuerungssystemen unbekannter Maschinen zu bekannten Informationsmodellen oder als Eingang für Industrie 4.0-Anwendungen wird dadurch für den Anwender zu einem häufig manuellen und zeitaufwändigen Prozess. Dieser wird zusätzlich zum beschriebenen Mangel an personellen Ressourcen sowie der notwendigen Expertise dadurch erschwert, dass es je nach Kommunikationsschnittstelle der Maschine mehrere Hunderttausend Knotenpunkte mit Signalen geben kann, aus denen die gesuchten identifiziert werden müssen.

Um Anwender bei dieser Bereitstellung von Maschinensteuerungssignalen zu unterstützen, benötigen diese ein System, das ihnen bei der Exploration von Daten auf Produktionsmaschinen im Brownfield assistiert, dabei zu mehr Zeiteffizienz führt beziehungsweise möglichst wenige zeitliche Ressourcen in Anspruch nimmt und vom Anwender möglichst wenig technische Expertise erfordert. Zum Zeitpunkt des Verfassens dieser Dissertation bestehen keine Ansätze, die eine automatisierte Bereitstellung der genannten Maschinensteuerungsdaten in Brownfield-Produktionssystemen erlauben. Auf dieser Basis wird nachfolgend die Zielstellung der vorliegenden Dissertation erläutert.

1.2 Zielsetzung

Das Ziel dieser Dissertation ist die Erarbeitung eines Systems zur automatisierten Bereitstellung von Maschinensteuerungsdaten in Brownfield-Produktionssystemen. Dieses soll Anwendern als Assistenzsystem dienen, um Daten aus Bestandsmaschinen zu extrahieren und Signale, die für aufbauende Industrie 4.0-Anwendungen genutzt werden können, aus den extrahierten Daten zu identifizieren.

Dieses Hauptziel gliedert sich in vier Unterziele, die die Grundlage für die Komponenten des angestrebten Gesamtsystems darstellen: Das erste Unterziel besteht in der Strukturierung von Zugriffsmöglichkeiten auf einen definierten Signalraum mit entsprechenden Lösungen für Kommunikationsschnittstellen von Produktionsanlagen. Der Signalraum soll dabei möglichst viele aufbauende Industrie 4.0-Anwendungen ermöglichen und skalierbar beziehungsweise auf andere Maschinen und Anlagen übertragbar sein.

Zweites Unterziel ist die Entwicklung von Ansätzen und eines systematischen Ablaufs für die Identifikation der extrahierten Daten. Die Ansätze umfassen dabei sowohl die Evaluation isolierter Verfahren aus dem Domänenwissen und des Maschinellen Lernens (ML) als auch eine Kombination dieser.

Die Integration der Teilkomponenten für die Extraktion und die Identifikation der Maschinensteuerungsdaten in ein Assistenzsystem mit anwenderorientierter Oberfläche und geführtem Ablauf für den Anwender stellen das dritte Unterziel dar. Das vierte und abschließende Unterziel umfasst die Bewertung der Funktionalität und der Generalisierbarkeit des entwickelten Systems.

1.3 Aufbau der Arbeit

Auf Basis der definierten Ziele ist die vorliegende Arbeit in acht Kapitel gegliedert. Der Aufbau wird in Abbildung 1-1 dargestellt.

Für einen möglichst umfassenden Überblick zu den behandelten Bereichen sowie zur Identifikation existierender Defizite im Stand der Forschung und Technik wird in Kapitel 2 zunächst der derzeitige Kenntnisstand zusammengefasst. Hierbei wird eine Übersicht zu grundlegenden Maschinen, Kennzahlen und Industrie 4.0-Anwendungen in der Produktion sowie zur Bereitstellung und Analyse der behandelten Maschinensteuerungsdaten gegeben. Das Kapitel schließt mit einem Fazit sowie zentralen Defiziten im Stand der Forschung und Technik.

Ausgehend von diesen Defiziten werden in Kapitel 3 die Zielstellung der Dissertation konkretisiert und die abgeleitete Vorgehensweise zur Zielerfüllung beschrieben. Darüber hinaus werden die entsprechenden Beiträge zum Stand der Forschung und Technik dargestellt.

In Kapitel 4 wird eine Lösung für die kommunikationstechnische Anbindung von Bestandsmaschinen erarbeitet, die eine initiale Verbindung zu zentralen Schnittstellen von Maschinen im Brownfield und die Extraktion von Maschinensteuerungsdaten aus diesen erlaubt. Hierbei wird auf die einzelnen Teilschritte vom Verbindungsaufbau bis zum Auslesen der Signalquellen eingegangen.

Kapitel 5 beschreibt die Konzeption zur Identifikation von Maschinensteuerungssignalen. Diese erstreckt sich von der Untersuchung verschiedener Ansätze bis zur methodischen Ableitung des Zielsystems. Die Darstellung der Ansätze beginnt mit zur Identifikation genutzten ML-Verfahren, erweitert diese in einem folgenden Schritt um Korrelationsregeln zur Präzisierung der Identifikation und schließt mit einer analytischen Signalidentifikation auf Basis von Domänenwissen. Im letzten Teil des Kapitels wird dann ein von den vorherigen Ergebnissen ausgehender abgeleiteter hybrider Ansatz zur Signalidentifikation vorgestellt.

Fokus von Kapitel 6 ist die Erarbeitung eines Gesamtsystems, in das die entwickelten Lösungen eingebettet werden und das einem Anwender mit einem geführten Modus bei der Anbindung der Brownfield-Produktionsanlagen und der Bereitstellung der Signale assistiert. In diesem wird zuerst auf den Aufbau und die Funktionsweise des Systems eingegangen und im zweiten Teil die Konzeption des anwenderorientierten Durchlaufs bei der Nutzung erarbeitet.

In Kapitel 7 wird das erarbeitete Lösungskonzept in verschiedenen Anwendungsfällen validiert. Die ausgewählten Validierungsfälle beginnen dabei mit ähnlichen Anwendungen und erstrecken sich von bauartverwandten Maschinen bis hin zu einem Industrieroboter. Auf dieser Basis werden sowohl die Ergebnisse hinsichtlich der grundsätzlichen Funktion des Lösungskonzepts in den Anwendungen als auch hinsichtlich der Übertrag- und Skalierbarkeit gezeigt.

Kapitel 8, das die Dissertation abschließt, beginnt zunächst mit einer Zusammenfassung der gewonnenen Erkenntnisse sowie ihrer Einordnung und Bewertung. Darüber hinaus wird in einem Ausblick aufgezeigt, welche zukünftigen Forschungsfragen und -bedarfe abgeleitet werden können.

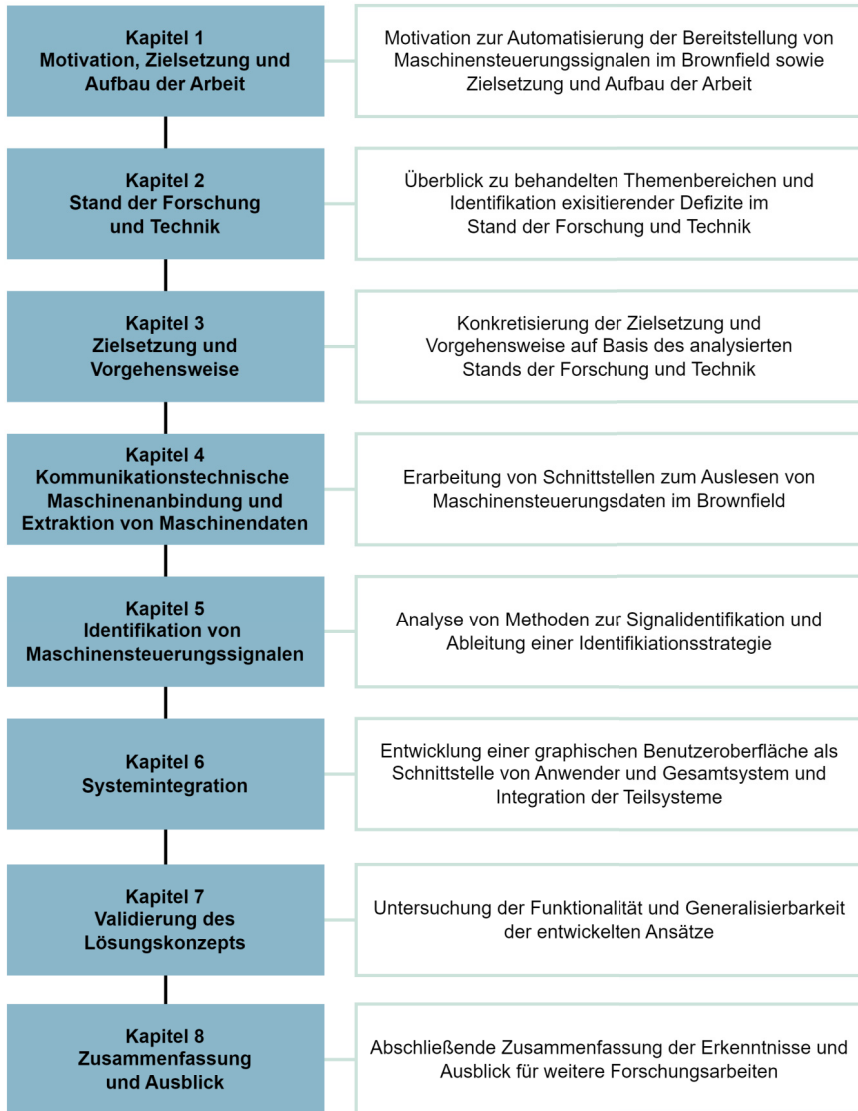


Abbildung 1-1: Aufbau der Arbeit

2 Stand der Forschung und Technik

In diesem Kapitel wird eine möglichst umfassende Übersicht zu den behandelten Themenbereichen der Dissertation sowie ihrem Stand der Forschung und Technik gegeben. Zunächst werden übergeordnete Ziele der industriellen Produktion in Form von Produktionskennzahlen sowie für diese Arbeit relevante Maschinen und die zugehörige Steuerungstechnik vorgestellt. Auf Basis der hier vorkommenden und für aufbauende Anwendungen angestrebten Signale werden folgend Bereitstellungsarten und Zugriffsmöglichkeiten sowie Analyseansätze vorgestellt. Abschließend erfolgen eine Zusammenfassung sowie eine Ableitung des Handlungsbedarfs.

2.1 Effektivitätssteigerungen durch Industrie 4.0

Als Basis zur Beschreibung der Effektivität einer Produktion werden Produktionskennzahlen verwendet, die einen zentralen Überblick über den gegenwärtigen Status der Produktion geben und diesen quantifizieren. In diesem Kapitel werden das zentrale Kennzahlensystem in der Produktion mit seinen Faktoren sowie ausgewählte Anwendungen vorgestellt, mit denen Optimierungen erzielt werden können.

2.1.1 Gesamtanlageneffektivität

Zentrale Kennzahl in der Produktion ist die Gesamtanlageneffektivität (engl.: Overall Equipment Effectiveness, kurz: OEE). Diese wird durch drei Faktoren bestimmt:

$$OEE = \text{Verfügbarkeitsgrad} * \text{Leistungsgrad} * \text{Qualitätsgrad} \quad 2-1$$

Die OEE beschreibt damit den Ist-Stand von Verfügbarkeit, Leistung und Qualität beziehungsweise der gesamten Produktion in Relation zum möglichen Idealzustand ohne Verluste. Auf diese Weise können Optimierungspotentiale in den Teilbereichen aufgezeigt und entsprechende Maßnahmen eingeleitet werden. (Focke & Steinbeck 2018)

2.1.2 Anwendungen im Bereich Industrie 4.0

Bereits zur Ermittlung der OEE und weiterer Kennzahlen sind ein Datenaustausch und Industrie 4.0-Anwendungen eine wichtige Basis, da genaue Ermittlungsverfahren auf Prozess- beziehungsweise Maschinendaten aufbauen. Auch zur Umsetzung von Maßnahmen zur Erhöhung der OEE eignen sich Anwendungen aus dem Bereich Industrie 4.0, die je nach Bedarf an der Verbesserung des Verfügbarkeits-, Leistungs- und Qualitätsgrads von Maschinen und Anlagen ansetzen. Bei häufigen Stillstandzeiten einer

Maschine aufgrund des Ausfalls einer Maschinenkomponente wie eines Kugelgewindetriebs bieten sich beispielsweise Condition Monitoring- beziehungsweise Predictive Maintenance-Systeme an (Armbruster & Gönzheimer et al. 2021). Diese können datenbasiert Verschleißmerkmale erfassen und damit vor drohenden Ausfällen warnen und so die Verfügbarkeit der jeweiligen Maschine verbessern. Auf die jeweilige Industrie 4.0-Anwendung zugeschnittene ML-Algorithmen erhöhen die Fähigkeiten der Anwendungen zusätzlich (Fahle & Prinz et al. 2020; Fono & Thiele et al. 2021).

Studien zeigen, dass aufgrund des durch häufige Maschinenstillstände entstehenden hohen Zeit- und Kostenaufwands industriell vor allem Systeme zur Zustandsüberwachung im Hinblick auf Störungen und Verschleiß gewünscht werden (Gönzheimer & Netzer et al. 2022; Netzer & Begemann et al. 2021). Diese können beispielsweise durch die Ergänzung bildbasierter Systeme zur Erfassung eines Komponentenverschleißes entweder auf nachgerüstete externe Sensorik aufbauen oder auf Basis vorhandener Maschinensteuerungsdaten arbeiten. Letztere umfassen beispielsweise Anwendungen zur Verschleißerfassung oder zur Detektion von Anomalien und bauen auf Motorströmen und ergänzenden Signalen auf (Benker & Zaeh 2022; Emec & Krüger et al. 2016; Netzer & Palenga et al. 2021). Zentrale Signale des Steuerungssystems sind im Kontext der beschriebenen Anwendungen vor allem Motorströme und Lagewerte aus den Antriebsachsen der Maschinen.

2.2 Produktionsmaschinen

Produktionsmaschinen sind eine entscheidende Basis industrieller Wertschöpfung und vor allem an Hochlohnstandorten wie Deutschland ein wichtiger Faktor der Wettbewerbsfähigkeit. Aufgrund der Vielfalt an Arten und Ausprägungen von Produktionsmaschinen wird im Folgenden ein Fokus auf Werkzeugmaschinen als repräsentative Vertreter von Produktionsmaschinen gesetzt. Im nachfolgenden Kapitel werden sie im Hinblick auf die wesentlichen Arten und Komponenten, ihre Steuerungssysteme sowie die vorkommenden Signale und Signalverarbeitung für ein grundlegendes Verständnis näher erläutert.

2.2.1 Werkzeugmaschinenarten und -komponenten

Grundsätzlich lassen sich Fertigungsverfahren der Metallverarbeitung nach der DIN 8580 strukturieren und umfassen „Urformen“, „Umformen“, „Trennen“, „Fügen“, „Beschichten“ und „Stoffeigenschaften ändern“ (Brecher & Weck 2019).

Werkzeugmaschinen decken, wie in Abbildung 2-1 dargestellt, einen großen Teil dieser Fertigungsverfahren ab und können in weitere Untergruppen unterteilt werden. Bei trennenden Werkzeugmaschinen beispielsweise lässt sich zwischen Verfahren mit geometrisch bestimmter und unbestimmter Schneide unterscheiden.

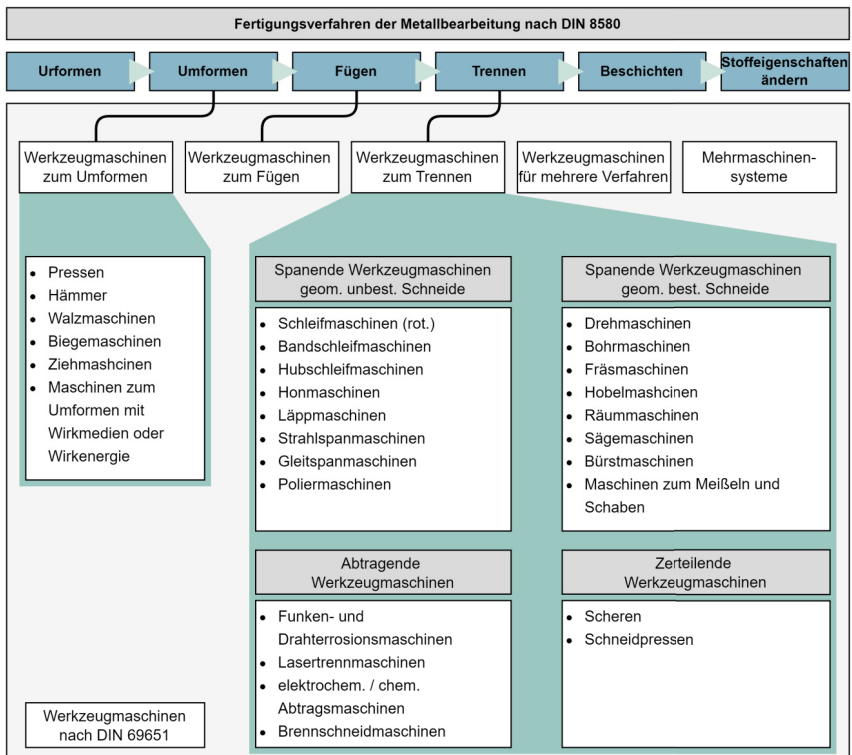


Abbildung 2-1: Fertigungsverfahren der Metallbearbeitung nach DIN 8580 nach Brecher & Weck (2019)

Spanende und abtragende Werkzeugmaschinen machten in 2022 und auch den Vorjahren jeweils etwa 75% des Produktionswerts der deutschen Werkzeugmaschinenindustrie aus (VDW 2022)¹. Der Großteil davon wiederum geht auf Bearbeitungs-

¹ VDW (2022), *Marktbericht 2022*. <https://vdw.de/wp-content/uploads/2023/07/VDW-Marktbericht-2022.pdf> [15.01.2024].

zentren, flexible Systeme, Transfer- und Mehrwegemaschinen sowie Dreh- und Fräsmaschinen zurück, weshalb diese im Folgenden fokussiert betrachtet werden.

2.2.1.1 Fräsmaschinen

Bei Fräsmaschinen wird durch die Rotation eines Werkzeugs, angetrieben durch die Hauptspindel, eine Schnittbewegung erzeugt. Ihre Vorschubrichtung ist meist senkrecht zur Drehachse ausgerichtet, wobei die Möglichkeit der Überlagerung mehrerer gekoppelter Vorschubbewegungen besteht (Brecher & Weck 2019). Werkstücke können dabei auf einem Maschinentisch für die Bearbeitung befestigt werden, der sich entlang der Bewegungsachsen fortbewegen kann (Bender & Göhlich 2020). Ein beispielhafter Aufbau einer Computerized Numerical Control (CNC)-Fräsmaschine wird in Abbildung 2-2 dargestellt und im Folgenden näher erläutert.




Abbildung 2-2: Beispielhafter Grundaufbau einer Fräsmaschine in Duoblock-Bauweise ohne Verkleidung nach Perovic (2009)

Bei der dargestellten Maschine handelt es sich um eine Fräsmaschine in Duoblock-Bauform des Herstellers DMG MORI, die drei translatorische Achsen X, Y, Z, einen numerisch gesteuerten (NC) Rundtisch sowie eine Hauptspindel umfasst. Grundlegend für die Stabilität der Maschine ist das Maschinenbett (1), auf dem der Ständer (2) montiert ist. Über den ebenfalls darauf aufbauenden Längstisch (3) erfolgt die Bewegung der X-Achse. (4) und (5) zeigen das Kreuzschlittenunter- sowie -oberteil, über die der Fräskopf (6) mit dem Gestell verbunden ist (Perovic 2009). Im Fall komplexerer Bearbeitungsprozesse werden auch vier- oder fünfachsiges Maschinen verwendet, die neben den genannten linearen Achsen noch zusätzliche rotatorische Achsen besitzen

(Brecher & Weck 2019). Weitere Varianten unterscheiden sich beispielsweise in der Anzahl der Achsen im Werkzeugträger sowie der Ausrichtung der Hauptspindel (Brecher & Weck 2019).

2.2.1.2 Drehmaschinen

Bei Drehmaschinen wird durch die Rotation des eingespannten Bauteils eine Schnittbewegung ausgeführt, weshalb diese hauptsächlich bei der Herstellung rotations-symmetrischer Teile zum Einsatz kommen (Brecher & Weck 2019). Ein beispielhafter Aufbau einer Drehmaschine wird in Abbildung 2-3 dargestellt.




Abbildung 2-3: Beispielhafter Grundaufbau einer CNC-Hochleistungs-Drehmaschine von Monforts nach Perovic (2009)

Zur Bearbeitung wird das Bauteil in der Hauptspindel (1) eingespannt und durch diese rotiert. Durch die erzeugte Relativbewegung zwischen dem eingespannten Bauteil und dem im Revolver (2) befindlichen Werkzeug kommt es zum Materialabtrag am Bauteil. Der Revolver ist auf einem Planschlitten (3) befestigt, der sich wiederum auf dem Längsschlitten (4) befindet. Im Fall des dargestellten Beispiels ist außerdem der Längsschlitten mit einer hydrostatischen Rundführung (5) ausgestattet. Auch bei Drehmaschinen stellt das Maschinenbett (6), das hier auf einem Betonfundament (7) angebracht ist, die Basis für die Stabilität der Maschine dar. (Perovic 2009)

Übergeordnet lassen sich Drehmaschinen in Universaldrehmaschinen, Einspindelautomaten, Mehrspindelautomaten, Karusselldrehmaschinen sowie Drehzentren gruppieren (Perovic 2009). Darunter können Unterscheidungen nach verschiedenen Merkmalen

vorgenommen werden, beispielsweise hinsichtlich des Bearbeitungsvorgangs (Längsdrehen bei axialem Vorschub, Plandrehen bei radialem Vorschub, Konturdrehen bei einer Kombination beider Vorschübe), der Anzahl an Hauptspindeln (Ein-, Zwei- und Mehrspindler) und deren Lage (Parallel- und gegenüberliegende Hauptspindeln) (Brecher & Weck 2019; Hirsch 2012).

2.2.1.3 Bearbeitungszentren

Bearbeitungszentren besitzen durch die Ausrüstung mit einem Werkzeugwechselsystem in Verbindung mit einem Werkzeugmagazin die Fähigkeit, mehrere Fertigungsverfahren abdecken zu können, beispielsweise zu fräsen, zu drehen und zu bohren. Mit diesen Erweiterungen können in Bearbeitungszentren mehrere Bearbeitungsschritte durchgeführt werden, ohne dass zwischen diesen das Werkstück umgespannt werden muss. Auch lassen sich dadurch in mehr Anwendungsfällen Komplettbearbeitungen realisieren. Dies führt gegenüber den vorher aufgeführten Maschinentypen zu großen Vorteilen hinsichtlich der Flexibilität bei damit einhergehenden Nachteilen in Bezug auf die Produktivität. (Perovic 2009)

2.2.2 Antriebssysteme

Die zentralen Antriebe von Werkzeugmaschinen umfassen den Hauptantrieb, auch Hauptspindel genannt, die Nebenantriebe, die auch Vorschubantriebe genannt werden, sowie Hilfsantriebe. Während die Hauptantriebe in spanenden Werkzeugmaschinen die Schnittbewegungen und damit die Spanabnahme erzeugen, sind die Nebenantriebe für die Vorschub- und Positionierbewegungen der Achsen verantwortlich, mit denen die Spanabnahme und weitere Bewegungen realisiert und aufrechterhalten werden. Hilfsantriebe kreieren Bewegungen für den eigentlichen Prozess ergänzende Peripherie wie den Kühlmittelfluss, Schmierung oder Hydraulik. (Böge & Böge 2021)

Hauptantriebe lassen sich in die in Abbildung 2-4 beschriebenen Arten unterteilen. Im Fall einer räumlichen Trennung zwischen Hauptspindel und antreibendem Motor wird die Spindelbaugruppe als elektromechanischer Antrieb ausgeführt und setzt sich aus Hauptspindel, getrennt montiertem Motor und einem für die Leistungsübertragung genutzten Getriebe zusammen. Bei direkt angetriebenen Hauptantrieben sind direkte Verbindungen ohne zusätzliches Getriebe möglich. (Böge & Böge 2021)

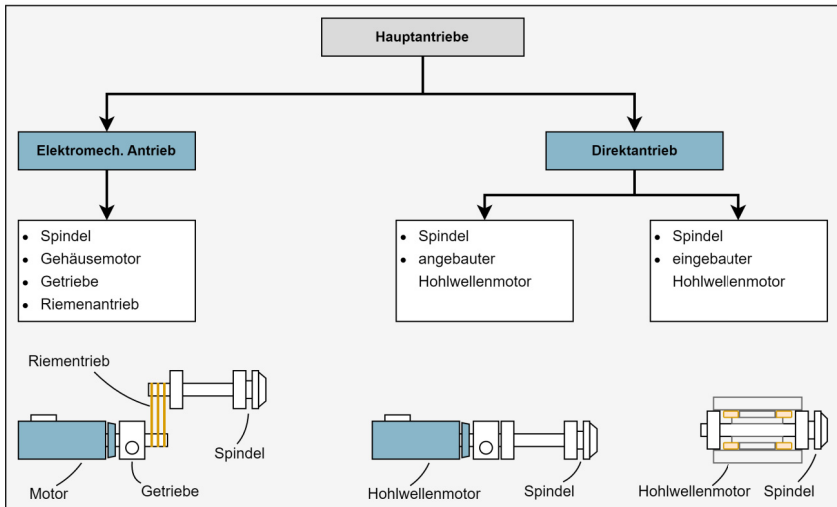


Abbildung 2-4: Bauarten von Hauptantrieben nach Kief & Roschiwal et al. (2020)

Die Neben- beziehungsweise Vorschubantriebe der Werkzeugmaschine können je nach Ausführung des zwischengelagerten Getriebes als rotatorische und translatorische Achsen umgesetzt sein. Typische Komponenten von Nebenantrieben sind ein Servomotor, ein Antriebsregler, die Leistungselektronik, Achsmechanik sowie das Wegmesssystem (Kief & Roschiwal et al. 2020).

In Abbildung 2-5 ist eine translatorische Vorschubachse schematisch dargestellt. Bei dieser wird über eine Kupplung und einen Zahnriemen der Antrieb für die Gewindespindel eines Kugelgewindetriebs realisiert. Von der zugehörigen Kugelrollmutter erfolgt die Umwandlung der rotatorischen Bewegung der Kugelrollspindel in eine translatorische Bewegung des installierten Maschinenschlittens. Die zugehörige Wegmessung kann dabei sowohl direkt als auch indirekt umgesetzt werden. Letzteres ist auf Basis der erfassten Winkellage des Motors und der Getriebeübersetzung möglich. Die direkte und aufgrund der Einflussreduktion genauere Wegmessung kann mit dem abgebildeten Linearmaßstab durchgeführt werden. Die abgebildete Regelungselektronik, an die der Wert zurückgeführt wird, wird in Kapitel 2.2.3.2 näher erläutert. (Brecher & Weck 2021)

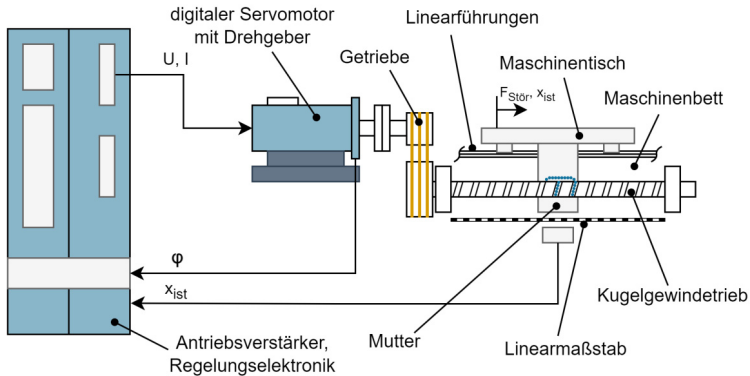


Abbildung 2-5: Translatorische Vorschubachse mit Kugelgewindetrieb nach Brecher & Weck (2021)

2.2.3 Steuerungs- und Regelungstechnik

Steuerungssysteme in Werkzeugmaschinen werden zum einen für umfangreiche und schnelle Steuerungsaufgaben im Kontext der Bearbeitung eingesetzt, zum anderen aber auch für Kommunikationsaufgaben, die Betriebsdatenerfassung, die Diagnose und weitere Umfänge. Sie sind daher entscheidend, um sowohl die Funktion und Wechselwirkungen innerhalb der Maschine zu verstehen als auch für die Benutzer- und Datenschnittstellen der Maschine nach außen. Im folgenden Kapitel wird daher ein Überblick über Steuerungssysteme im Kontext von Werkzeugmaschinen gegeben sowie der Zusammenhang der Steuer- und Regelungsaufgaben mit den in Kapitel 2.1.2 genannten und im folgenden Kapitel 2.2.3.2 ausführlicher beschriebenen Signalen erläutert.

2.2.3.1 Steuerungssysteme

Moderne, automatisierte Werkzeugmaschinen nutzen CNC-Steuerungen, die in Form von Mikrorechnern gemeinsam mit weiteren Steuerungsbaugruppen wie der Speicherprogrammierbaren Steuerung (SPS) integraler Bestandteil der Steuerungshardware der Maschine sind. Die Interaktion mit dem Maschinenbediener erfolgt über eine zugehörige Bedientafel mit Display (HMI). (Bahmann 2013)

Die wesentliche Kernaufgabe der NC liegt in der Steuerung der Relativbewegung zwischen dem verwendeten Bearbeitungswerkzeug und dem zu bearbeitenden Werkstück. Die hierfür notwendigen Steuerungsinformationen wie Weg- und Geschwindigkeitsanweisungen sind dabei in alphanumerischen Zeichen im NC-beziehungsweise Teileprogramm enthalten und durch dieses vorgegeben (Weck 2006). Die Ansteuerung von Aktorik wie Magnetventilen, Kupplungen und Motoren ist über eine SPS möglich (Bahmann 2013). Die schematische Struktur und das Zusammenspiel werden in Abbildung 2-6 veranschaulicht.

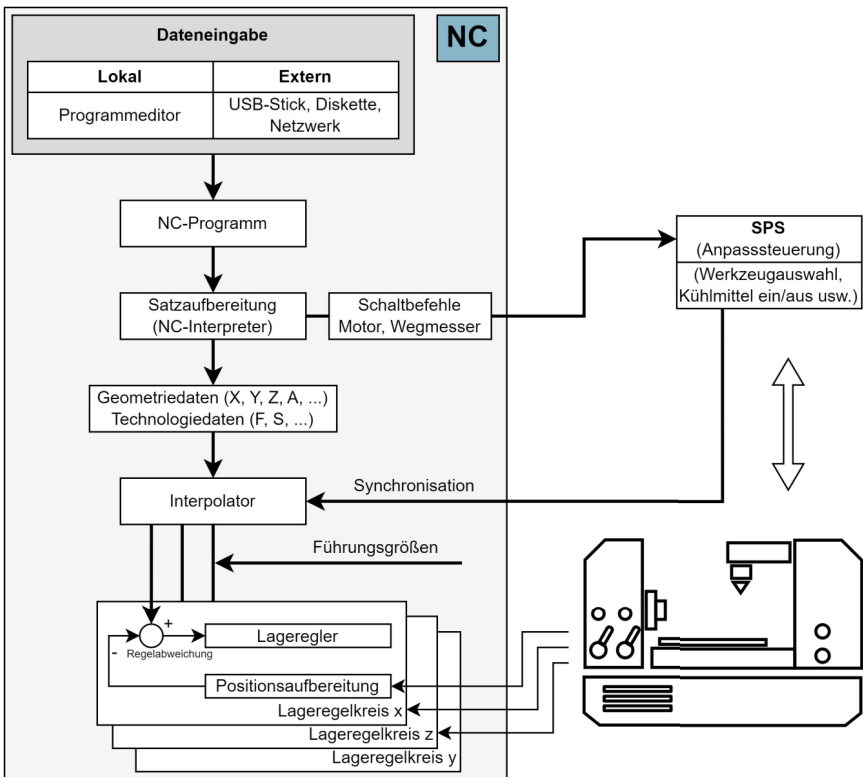


Abbildung 2-6: Aufbau einer numerischen Steuerung nach Weck (2006)

Die Dateneingabe erfolgt entweder lokal über einen Programmierer oder extern über einen USB-Stick oder vergleichbare Medien. Darauf aufbauend werden die im NC-Programm beinhalteten Steuerungsinformationen von einem NC-Interpreter in der Satzaufbereitung decodiert und je nach Anweisungsart als geometrische oder technologische Daten an den Interpolator sowie als Schaltbefehle an die SPS weitergegeben. Die Schaltbefehle werden in der auch Anpassteuerung genannten SPS, die über Rückmeldungen mit der CNC-Steuerung synchronisiert ist, an benötigte Aggregate weitergegeben, beispielsweise für den Werkzeug- oder Werkstückwechsel. (Weck 2006)

Der Interpolator gibt nach Erhalt der geometrischen und technologischen Daten den Antriebsachsen die Führungsgrößen vor. Die Antriebsachsen erzeugen daraufhin in der Überlagerung aller einzelnen Achsbewegungen die angestrebte Werkzeugbewegung zur Bearbeitung des Werkstücks. Dessen Kontur wird mit Konturendpunktkoordinaten sowie der Verknüpfungsart als Wegbedingungen, beispielsweise in Form von Geraden oder Kreisbögen, angegeben. (Weck 2006)

2.2.3.2 Regelungstechnische Grundlagen und Signale

Als Überblick zur Struktur des Regelungssystems und seinem Zusammenspiel mit den in Kapitel 2.1.2 genannten Maschinensteuerungssignalen werden im Folgenden die regelungstechnischen Grundlagen näher beschrieben.

Zentrale Aufgabe der NC von Werkzeugmaschinen ist die Übersetzung der erhaltenen Informationen über zu verfahrenende Wege und Geschwindigkeiten in Anweisungen in Form von Führungsgrößen für die Vorschubachsen (Brecher & Weck 2021). Diese Führungsgrößen umfassen Vorgaben für Lage- und Geschwindigkeitswerte. Fehlerfreie Bewegungen werden durch vielseitige und sichere Lageregelkreise umgesetzt, da in ihrem geschlossenen Wirkungskreis eine ständige Überprüfung von Istwerten stattfindet (Kief & Roschiwal et al. 2020).

Das Prinzip des Wirkungskreises ist in Abbildung 2-7 mit der Regelung der Position des Maschinenschlittens veranschaulicht. Hierbei wird die Position kontinuierlich erfasst und mit dem zugehörigen Sollwert abgeglichen sowie im Bedarfsfall angepasst. (Kief & Roschiwal et al. 2020)




Abbildung 2-7: Prinzip der Eingabe und Verarbeitung geometrischer Informationen im geschlossenen Regelkreis nach Kief & Roschival et al. (2020)

Der gesamte kaskadierte Lageregelkreis ist in Abbildung 2-8 dargestellt. Für eine möglichst hohe Regengenauigkeit werden zusätzlich zur Position noch Geschwindigkeit und Strom rückgeführt. Zunächst wird ausgehend von der Steuerung der Lagesollwert vorgegeben und mit dem Istwert der Lagerückführung verglichen. Auf Basis der sich als Differenz ergebenden Regeldifferenz bestimmt der Lageregler den Drehzahlsollwert. Dieser wiederum wird ebenfalls verglichen mit dem Drehzahlstwert der Geschwindigkeitsrückführung und die Differenz in Form der Regeldifferenz an den Drehzahlregler weitergegeben. Der daraus erzeugte Stromsollwert wird einem weiteren Vergleich mit dem Stromistwert zugeführt und die erneut berechnete Differenz dem Stromregler als Eingangswert übergeben. Der Stromregler als letzte Regeleinrichtung führt daraufhin dem Antriebssystem die definierte Energie zu. Der zugeführte Strom sowie die Drehzahl werden durch ein Strommesssystem und den am Motor

angebrachten Motorgeber, beispielsweise Resolver, gemessen. Die mechanische Energie wird in das mechanische Übertragungssystem geleitet, das Einflüssen verschiedener Störkräfte und Rückwirkungen ausgesetzt ist. Infolge der Aktionen verfährt die Antriebsachse, deren Position erneut indirekt durch Berechnung sowie direkt über den Linearmaßstab gemessen werden. Mit der Rückführung wird der Lageregelkreis geschlossen. (Brecher & Weck 2021; Kief & Roschiwal et al. 2020)

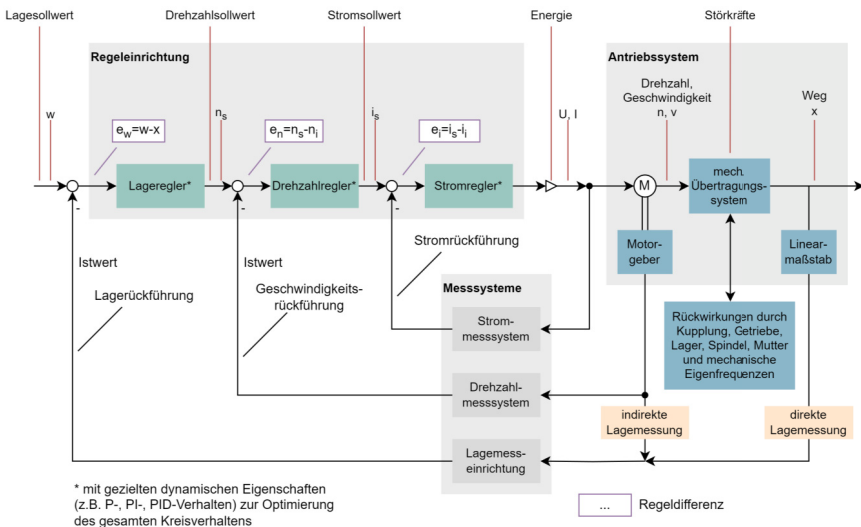


Abbildung 2-8: Schematische Darstellung des kaskadierten Lageregelkreises nach Kief & Roschiwal et al. (2020)

Darüber hinaus ist die Annäherung an das Folgeverhalten des kaskadierten Lageregelkreises durch einen vereinfachten Lageregelkreis mit unterlagerter Geschwindigkeitsrückführung möglich. Abbildung 2-9 veranschaulicht dazu den zeitlichen Verlauf des Lagewertes und der Geschwindigkeit des Schlittens in Abhängigkeit der Geschwindigkeitsverstärkung K_v , die als zentrale Kennzahl das Verhältnis der Geschwindigkeit \dot{x} zur Lageabweichung, auch Schleppabstand genannt, x_w beschreibt (Brecher & Weck 2021):

$$K_v = \frac{\dot{x}}{x_w}$$

Wie dargestellt, nimmt die Regelabweichung mit steigender Geschwindigkeitsverstärkung ab und die Sollgeschwindigkeit wird schneller erreicht. Gleichzeitig führen höhere Verstärkungen wegen geringerer Dämpfungen zu Schwingungen in Anfahr- und Anhaltphasen. Sprungförmige Geschwindigkeitsänderung eignen sich damit zum Testen und Bewerten des dynamischen Verhaltens von Vorschubantrieben. (Brecher & Weck 2021)

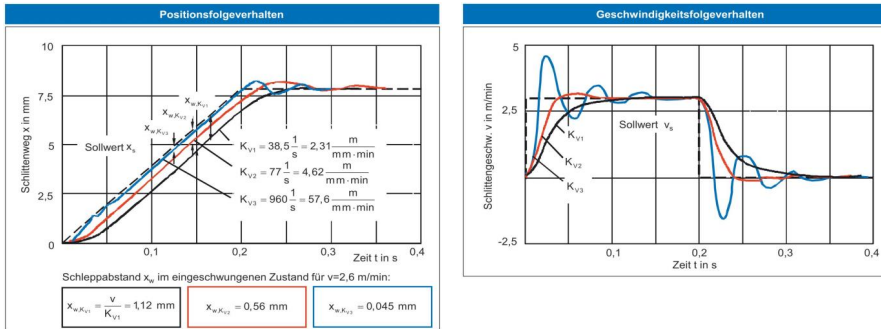


Abbildung 2-9: Folgeverhalten eines Lageregelkreises mit Geschwindigkeitsrückführung nach Brecher & Weck (2021)

Hinsichtlich der vorkommenden Signale in Werkzeugmaschinensteuerungssystemen existieren damit im Bereich der Vorschubachsen und der Spindel neben diversen binären Signalen mindestens die in Abbildung 2-8 behandelten. Diese umfassen zum einen die Soll-Vorgabewerte der Steuerung und zum anderen die erhobenen Istwerte, bei denen in Teilen zwischen Messverfahren unterschieden werden muss. Wie in Kapitel 2.2.2 beschrieben, existieren beispielsweise vom Lageistwert sowohl direkte als auch indirekte Messungen und damit unterschiedliche Signale, ausgelöst durch Störkräfte und Rückwirkungseffekte im mechanischen Übertragungssystem.

Die beschriebenen Signale lassen sich durch Zeitreihen beschreiben, welche eine chronologische Auflistung von Datenpunkten sind. Die zeitliche Distanz von Datenpunkten wird dabei durch die Abtastfrequenz vorgegeben. Werden mehrere Signale zur gleichen Zeit aufgezeichnet, kann dies in einer zweidimensionalen Matrix dargestellt werden. Betrachtet man zusätzlich unterschiedliche Aufnahmen, was beispielsweise bei Versuchsreihen der Fall ist, existieren für jedes Signal mehrere Zeitreihen. Dies lässt sich wiederum durch eine dreidimensionale Matrix darstellen. In Abbildung 2-10

ist beispielhaft aufgezeigt, wie gleichzeitig aufgezeichnete Datenpunkte und Versuchsreihen zwei- beziehungsweise dreidimensional dargestellt werden können.

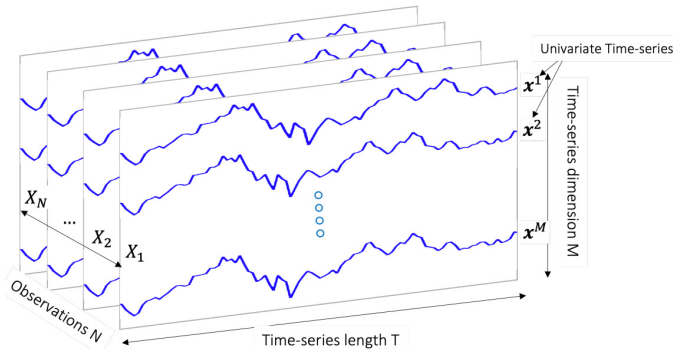


Abbildung 2-10: Definition von Signalen und Zeitreihen nach Farahani & McCormick et al. (2023a)

2.3 Bereitstellung von Maschinensteuerungsdaten

Wie in Kapitel 2.2 beschrieben, gibt es vielversprechende Industrie 4.0-Anwendungen zur Optimierung der Produktion, beispielsweise die Steigerung der Verfügbarkeit von Maschinen und -komponenten. Die Datenbasis für diese Anwendungen umfasst in vielen Fällen Signale aus dem Steuerungssystem der Maschine wie Motorströme oder Lagewerte aus den Vorschubachsen und der Spindel. Über die Möglichkeiten für den Zugriff auf Daten für Anwendungen im Bereich Industrie 4.0 im Brownfield wird in diesem Kapitel ein Überblick gegeben.

2.3.1 Kommunikation in der Automatisierungstechnik

Entlang der in Abbildung 2-11 dargestellten Ebenen der Automatisierungspyramide stellen sich spezifische Anforderungen an die verwendete Kommunikationstechnik. Zu Anforderungskriterien zählen unter anderem die maximale Anzahl der anzuschließenden Teilnehmer, die Antwortzeit, zu übertragende Datenmengen sowie die Übertragungsstrecke. Während auf höheren Datenebenen Datenmengen größer sind, wird auf den unteren Ebenen ein höherer Stellenwert auf Echtzeitfähigkeit und eine zuverlässigere Übertragung gelegt. Eine Auswahl der relevantesten Systeme, die dabei

zum Einsatz kommen, wird folgend näher erläutert. (Brecher & Weck 2021; Kief & Roschiwal et al. 2020)

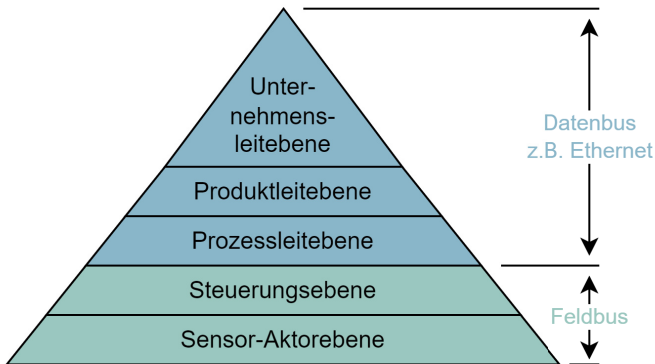


Abbildung 2-11: Kommunikationssysteme für unterschiedliche Ebenen der Automatisierung nach Kief & Roschiwal et al. (2020)

Für die Kommunikation in der Sensor-Aktor- beziehungsweise Feldebene werden vor allem Feldbusse genutzt, wie auch in Abbildung 2-11 dargestellt. Verbreitete Varianten umfassen beispielsweise Profinet, Profibus, InterBus und CANbus. Den am meisten verbreiteten Datenbus stellt Ethernet dar, das zu einem Industriestandard geworden ist. Ethernet und TCP/IP sind zusätzlich vorteilhaft, wenn Maschinen mit anderen Unternehmensteilen verknüpft werden müssen, da sie auch die Basis des Internets und der Bürokommunikation darstellen und damit durchgängig genutzt werden können. (Brecher & Weck 2021; Kief & Roschiwal et al. 2020)

Für die Produktion relevant sind darüber hinaus sogenannte Middleware-Protokolle wie OPC UA, die die vertikale Vernetzung über die Automatisierungspyramide unterstützen (Krüger & Vick et al. 2017). OPC UA kombiniert in einem definierten integrierten Adressraum und Informationsmodell zahlreiche Daten aus der Maschine (OPC Foundation 2015)². Zentrale Vorteile liegen dabei in der Plattform- und Herstellerunabhängigkeit, einer hoher integrierten IT-Sicherheit sowie der Modularität und Flexibilität des Objektmodells, das anwendungsspezifisch angepasst werden kann. Der Aufbau eines

² OPC Foundation (2015), *OPC Unified Architecture. Interoperabilität für Industrie 4.0 und das Internet der Dinge*. <https://opcfoundation.org/wp-content/uploads/2015/04/OPC-UA-Interoperability-For-Industrie4-and-IoT-DE-1.pdf> [15.01.2024].

beispielhaften OPC UA Servers ist in Abbildung 2-12 dargestellt. Abgebildet ist ein Auszug aus mehreren zehntausend Datenknoten, die in einer nicht standardisierten Struktur und nicht standardisierter Semantik vorliegen. Sowohl der Umfang als auch die Struktur und Semantik erschweren dem Anwender die Identifikation und Zuordnung gesuchter Signale.

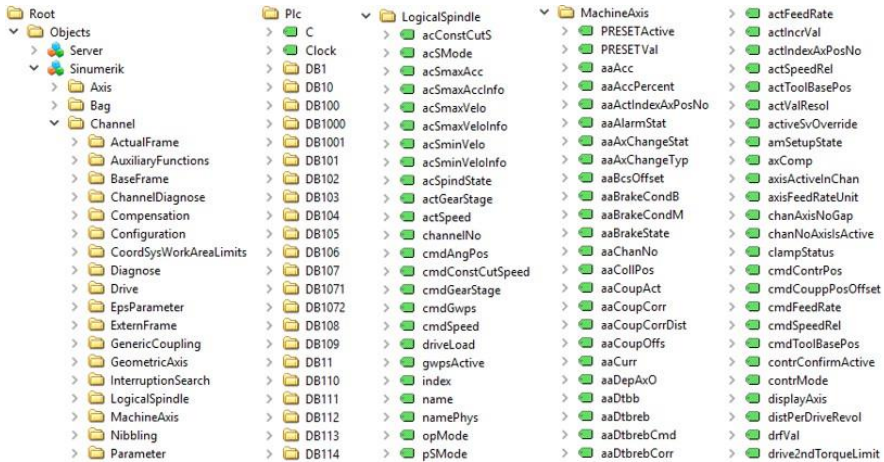


Abbildung 2-12: Auszug der Struktur aus einem OPC UA Server einer DMG MORI DMU 65 monoBLOCK

Standards, die die Struktur und Semantik für einen bestimmten Signalraum definieren, werden in verschiedenen Anwendungsgebieten durch sogenannte Companion Specifications beschrieben. Ein Beispiel hierfür ist die OPC UA Companion Specification Universal Machine Technology Interface (umat), die einen herstellerübergreifenden Standard für Informationsmodelle von Werkzeugmaschinen und darüber hinausgehenden Anlagen darstellt (VDW 2020)³. Der Fokus des abgebildeten Signalraums liegt hierbei auf Statusinformationen auf Maschinenlevel, beispielsweise zum Betriebszustand, der Signallampe, Fehlermeldungen oder aktuell verwendeten Werkzeugen. (Brecher & Weck 2021; Kief & Roschiwal et al. 2020)

³ VDW (2020), *The Global Production Language. OPC 40501-1 UA for Machine Tools*. https://umat.org/wp-content/uploads/20201110_OPC40501-1_Introduction_Information_Model_UA4MT.pdf [15.01.2024].

2.3.2 Datenschnittstellen im Brownfield

Bei der Maschinenanbindung im Brownfield stellt die große Heterogenität in Kommunikationsschnittstellen und informationstechnischer Semantik in Maschinenparks das größte Hemmnis für Unternehmen zur Nutzung vorhandener Steuerungsdaten dar (Netzer & Begemann et al. 2021). Begrenzte personelle Ressourcen und Expertise in den Unternehmen erschweren darüber hinaus sowohl die Umsetzung von Nachrüstungen als auch die kommunikationstechnische Anbindung der bestehenden Maschinen (Gönnheimer & Netzer et al. 2022).

Für einen Datenaustausch zwischen einem PC und der Maschine ist eine Kommunikationsverbindung notwendig. Die mögliche Gestaltung dieser ist abhängig von den vorhandenen Komponenten und Systemen. Die vorhandene Struktur kann unter anderem lediglich aus einer NC und SPS bestehen, einen an die NC angebotenen Industrie-PC beziehungsweise eine Edge nutzen, mit einer Datenbank gekoppelt sein, auf der Daten abgelegt werden oder die Daten via Middleware durch moderne Kommunikationsprotokolle wie MQTT oder OPC UA bereitstellen. Eine beispielhafte Struktur mit möglichen vorhandenen Komponenten ist in Abbildung 2-13 dargestellt.

Im Fall der Beschränkung auf eine NC und SPS muss auf Basis von Hard- oder Software-Lösungen eine Verbindung zu diesen hergestellt werden. Bei Verwendung eines Industrie-PCs oder einer gekoppelten Datenbank können Zeitreihendaten ausgegeben werden. Von OPC UA Servern oder MQTT Brokern können Daten unmittelbar durch entsprechende Client-Anwendungen abgerufen werden.

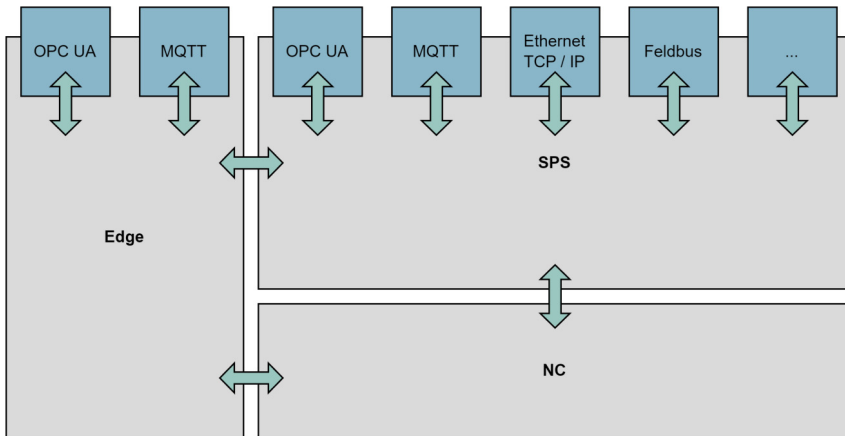


Abbildung 2-13: Beispielhafte Kommunikationsarchitektur mit möglichen Komponenten und Datenschnittstellen in Brownfield-Maschinen

2.3.3 Maschinenanbindung und Zugriffsmöglichkeiten

Für Bestandsanlagen ohne moderne Kommunikationsschnittstellen wie MQTT gibt es im Wesentlichen drei Herangehensweisen, um den Zugriff auf Maschinensteuerungsdaten umzusetzen. Die erste und umfassendste der Optionen beschreibt den Austausch des Steuerungssystems gegen eine moderne Variante und wird auch als „Rip-and-Replace“-Ansatz bezeichnet. Diese Option kann neben einer besseren Zugänglichkeit auch Vorteile für den weiteren technischen Support und die IT-Sicherheit bieten, stellt aber einen massiven Eingriff in die Anlage dar und ist mit erheblichem Aufwand und Kosten verbunden. (ptc 2023)⁴

Die zweite Option ist die Ergänzung meist kommerzieller Hard- und Softwarelösungen, die die bestehende Hardware um IoT-fähige Konnektivitätsbausteine erweitern und auf deren Basis moderne Schnittstellen anbieten. Die bestehenden Steuerungen werden dafür über Treiber angebunden, die das jeweilige proprietäre Protokoll übersetzen können. Der Ansatz ist kostengünstiger und aufwandsärmer als die „Rip-and-Replace“-Lösung, führt aber dennoch zu zusätzlichem Aufwand und Kosten für Anschaffungen

⁴ ptc (2023), *Built to Last: Merging Legacy Equipment With IoT*. <https://www.ptc.com/en/blogs/iiot/built-to-last-merging-legacy-equipment-with-iiot> [15.01.2024].

sowie Betriebslizenzen. Die Funktionalitäten werden in den meisten Fällen lediglich in Verbindung mit eigenen proprietären Systems angeboten, die in Teilen aufwändige Anpassungen oder Zusatzinstallationen bei der Kommunikationsarchitektur erfordern (Hillenbrand & Gönninger et al. 2021). Kommerzielle Beispiele hierfür sind unter anderem zentrale Messdatenmanagementsysteme (Delphin 2023)⁵. Auch Hersteller von Werkzeugmaschinen bieten entsprechende Retrofit-Lösungen an, beispielsweise DMG MORI mit einer nachrüstbaren IoT-Konnektorbox, die die Netzwerkkommunikation der Maschine und das Auslesen von Maschinendaten erlaubt (DMG MORI 2018)⁶. Weitere kommerziell angebotene Gateway-Lösungen bieten beispielsweise die Integration von Bus- und Netzwerkprotokollen sowie drahtloser Kommunikation (SICK 2018)⁷. Auch die Verlagerung der Steuerungslogik in ein Cloud-basiertes System und eine Weiternutzung der bestehenden und im weiteren Betrieb zu Konnektoren degradierten Hardware stellt einen möglichen Ansatz zur Ergänzung dar (Horn & Krüger 2016; Krüger & Verl 2019).

Dritte Option ist die Entwicklung eigener Lösungen auf Basis verfügbarer Open Source-IoT-Bausteine (Apache 2023)⁸. Diese bestehen aus einer Reihe von Bibliotheken, sogenannten Open Source Libraries, für die Kommunikation, die unter anderem SPS-Lösungen mit verschiedenen Protokollen abbilden. Sie erfordern den Aufwand der eigenen Erarbeitung und Programmierung, sind jedoch individuell anpassbar, in Anwendungen integrierbar und in der Nutzung kostenfrei. (Hillenbrand & Gönninger et al. 2021)

2.3.4 Identifikation von Signalen

Die in Kapitel 2.3.3 beschriebenen Ansätze können eine Lösung für die Herausforderung der grundlegenden Anbindung der Maschine und die Realisierung der Datenbereitstellung von der Bestandsanlage auf den Ziel-PC darstellen. Eine darüber

⁵ Delphin (2023), *Zentrales Messdatenmanagement. Softwarelösung für perfektes Prozessdaten-Management*. <https://www.delphin.de/produkte/messtechnik-software/delphin-data-center/> [15.01.2024].

⁶ DMG MORI (2018), *End-to-End-Lösungen in der Digitalisierung*. <https://de.dmgmori.com/news-und-media/news/amb-2018-integrated-digitization> [15.01.2024]

⁷ SICK (2018), *Gateway-System TDC-E: Multi-Sensor-Vernetzung mit Mobilfunk-Kommunikation. Daten sammeln, auswerten, speichern und übertragen in mobilen und stationären Anwendungen*. <https://www.sick.com/de/de/gateway-system-tdc-e-multi-sensor-vernetzung-mit-mobilfunk-kommunikation-daten-sammeln-auswerten-speichern-und-uebertragen-in-mobilen-und-stationaeren-anwendungen/w/press-2018-SMM-TDC-E/> [15.01.2024].

⁸ Apache (2023), *PLC4X: The universal protocol adapter for Industrial IoT*, The Apache Software Foundation. <https://plc4x.apache.org/> [15.01.2024].

hinausgehende Herausforderung nach erfolgreicher Extraktion der Daten bleibt für den Anwender die Identifikation der für aufbauende Industrie 4.0-Anwendungen angestrebten Signale. Diese müssen sowohl im Fall eines bereits existierenden Datenaustauschs als auch im Fall nachträglicher Zugriffslösungen durch den Anwender aus dem Pool der auslesbaren Knoten identifiziert und zugeordnet werden. Je nach Kommunikationsart können mehrere Hunderttausend Knoten mit Signalen verfügbar sein.

Standardisierte Informationsmodelle wie umati sind aufgrund des hohen Durchschnittsalters von Brownfield-Maschinen nur selten umgesetzt und bilden Komponentensignale wie Motorströme und Lagewerte nicht ab (VDW 2020)³. Nachrüstungen von umati auf ausgewählten Bestandsmaschinen wurden im Rahmen von Hackathons erprobt (VDW 2023)⁹. Auch weitere Forschungsansätze fokussieren sich mit ihrer semantischen Modellierung auf Signale zu generischeren Maschinenstatus sowie statischen Informationen zur Maschine und ermöglichen keine automatisierte Identifikation und Zuordnung (Mourtzis & Milas et al. 2018). Dabei werden Informationsmodelle für OPC UA-basierte Kommunikation zwischen den physischen Anlagen und digitalen Abbildern vorgeschlagen, die jedoch manuell umgesetzt werden müssen.

Auf dieser Basis kann die Identifikation der angestrebten Signale für den Anwender einen zeitaufwändigen und in manchen Fällen nicht lösbaren manuellen Prozess darstellen. Dieser wird zusätzlich dadurch erschwert, dass Unternehmen gewünschte, aber bisher nicht erfolgte Digitalisierung im Brownfield mit Defiziten bei personellen Ressourcen und Expertise begründen (Gönnheimer & Netzer et al. 2022).

2.4 Analyse von Zeitreihendaten

In diesem Kapitel werden Möglichkeiten zur Informationsgewinnung aus Zeitreihen durch unterschiedliche Methoden beschrieben. Bei Zeitreihen handelt es sich um Datenwerte, die aus den zuvor beschriebenen Werkzeugmaschinen stammen können. Ziel dieses Kapitels ist es, einen Überblick zu geben, welche Ansätze zur Informationsgewinnung aus Zeitreihendaten genutzt werden können, um Signale in diesen Zeitreihendaten automatisiert zu identifizieren und zuzuordnen. Dabei werden zunächst Möglichkeiten zur Verarbeitung von Zeitreihen durch analytische Berechnungsmethoden beschrieben. Hier wird auf gängige Methoden eingegangen, die als Werkzeug für

⁹ VDW (2023), *Umati verknüpft alte Maschinen mit neuen Anlagen*. <https://www.maschinenmarkt.vogel.de/schweizer-hackathon-umati-verknuepft-alte-maschinen-mit-neuen-anlagen-a-64ee4578ca6aaa4a90effda2d7b601ab/> [15.01.2024].

die Informationsgewinnung aus Zeitreihen in dieser Arbeit verwendet werden. Anschließend wird der Einsatz von ML-Verfahren erläutert, welche mittlerweile besonders häufig eingesetzt werden. In Kapitel 2.4.3 werden dann industrielle Anwendungsfälle aus dem Stand der Technik vorgestellt, bei denen eine automatisierte Identifikation auf Basis von ML-Verfahren umgesetzt wurde.

2.4.1 Verarbeitung von Zeitreihendaten

Um Informationen aus Zeitreihen zu gewinnen, existieren unterschiedliche Methoden der Verarbeitung, die hinsichtlich des vorliegenden Falls individuell ausgewählt werden müssen. Diese können als Werkzeuge betrachtet werden, mit denen Zeitreihen so modifiziert werden, dass daraus Erkenntnisse gewonnen werden können. Die Anzahl der zur Verfügung stehenden Methoden ist äußerst groß, weshalb in den nachfolgenden Kapiteln auf für diese Dissertation wichtige Verfahren eingegangen wird.

2.4.1.1 Daten-Skalierung

Zeitreihen können beispielsweise aufgrund ihres physikalischen Typs oder verwendeter Messsysteme hohe Diversität aufweisen, wodurch eine potenzielle Korrelation zunächst nicht einsehbar ist. Um die Zeitreihen besser vergleichen zu können, kann eine Skalierung der Datenpunkte sinnvoll sein. Eine Methode alle Zeitreihen auf das Intervall von 0 bis 1 einzugrenzen, ist die Min-Max-Normierung. Dabei werden die Werte der Ordinate neu berechnet während sich die Datenpunkte auf der zeitlichen Achse nicht ändern. Zu beachten ist, dass bei dieser Methode besonders Ausreißer großen Einfluss haben. Die Min-Max-Normierung lässt sich mit der Formel 2-3 berechnen.

$$X = \frac{x - x_{min}}{x_{max} - x_{min}} \quad 2-3$$

mit

$$\begin{aligned} x &= \text{Datenpunkt} \\ x_{min} &= \text{kleinster vorkommender Wert} \\ x_{max} &= \text{größter vorkommender Wert} \end{aligned}$$

Eine weitere Methode ist die z-Transformation. Bei dieser Methode wird für jeden Datenpunkt der Mittelwert der Zeitreihe abgezogen und anschließend durch die Standardabweichung dividiert. Daraus resultieren Zeitreihen mit dem Mittelwert 0 und der Standardabweichung 1, wodurch sich besonders Zeitreihen unterschiedlicher

Skalierung und Typs besser vergleichen lassen. Die z-Transformation wird mit der Formel 2-4 berechnet:

$$X = \frac{x - \mu}{\sigma} \quad 2-4$$

mit

$$\begin{aligned} x &= \text{Datenpunkt} \\ \mu &= \text{Mittelwert} \\ \sigma &= \text{Standardabweichung} \end{aligned}$$

2.4.1.2 Korrelationskoeffizienten

Um einen linearen Zusammenhang von Zeitreihen zu untersuchen, eignen sich Korrelationskoeffizienten. Zwei häufig verwendete Berechnungsmethoden sind die Korrelationskoeffizienten nach Bravais-Pearson und nach Spearman. Metrisch skalierte Zeitreihen werden mit dem Bravais-Pearson Korrelationskoeffizienten berechnet. Spearman eignet sich für ordinal skalierte Zeitreihen. Der Zusammenhang wird dann in einem Intervall angegeben, bei dem -1 bedeutet, dass kein linearer Zusammenhang, 0 generell kein Zusammenhang und 1 ein starker Zusammenhang besteht. (Krämer & Schoffer et al. 2018)

Die Berechnungsmethode nach Bravais Pearson ist mit Formel 2-5 dargestellt.

$$r_{XY} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sqrt{(\sum_{i=1}^n x_i^2 - n \bar{x}^2)(\sum_{i=1}^n y_i^2 - n \bar{y}^2)}} \quad 2-5$$

mit

$$\begin{aligned} X, Y &= \text{Zeitreihen} \\ x_i, y_i &= \text{Datenpunkte} \\ \bar{x}, \bar{y} &= \text{Mittelwert der jeweiligen Zeitreihen} \\ n &= \text{Anzahl an Untersuchungseinheiten} \end{aligned}$$

Bei dem Korrelationskoeffizienten nach Spearman wird der Rangkorrelationskoeffizient berechnet. Zunächst werden alle Datenpunkte aufsteigend sortiert und anschließend durchnummeriert. Mit Formel 2-6 lässt sich dann der Spearmansche Korrelationskoeffizient berechnen. (Krämer & Schoffer et al. 2018)

$$r_{XY} = \frac{\sum_{i=1}^n R(x_i)R(y_i) - \overline{nR(x)} \overline{R(y)}}{\sqrt{(\sum_{i=1}^n R(x_i)^2 - n\overline{R(x)}^2) (\sum_{i=1}^n R(y_i)^2 - n\overline{R(y)}^2)}} \quad 2-6$$

mit

- X, Y = Zeitreihen
- x_i, y_i = Datenpunkte
- \bar{x}, \bar{y} = Mittelwert der jeweiligen Zeitreihen
- R = Rang
- $\overline{R(x, y)}$ = Mittelwert des Ranges einer Zeitreihe
- n = Anzahl an Untersuchungseinheiten

2.4.1.3 Dynamic Time Warping

Eine weit verbreitete Technik zur Angleichung zweier zeitabhängiger Sequenzen ist das Dynamic Time Warping (DTW). Dabei werden die beiden Sequenzen nicht-linear verzerrt, wodurch sie einander angepasst werden (Müller 2007). DTW hat dadurch das Potential, zusätzliche Zusammenhänge von Signaltypen zu detektieren und wird beispielsweise in der Spracherkennung eingesetzt. In Abbildung 2-14 ist die Grundidee graphisch dargestellt.




Abbildung 2-14: Angleichung zweier Zeitreihen durch DTW nach Müller (2007)

2.4.1.4 Distanzmaße

Eine Methode, die Ähnlichkeit von Zeitreihen durch eine Kennzahl auszudrücken, ist die Berechnung von Distanzmaßen. Dabei werden die Datenpunkte unterschiedlicher Zeitreihen zur gleichen Zeit betrachtet und abhängig von der Methode verrechnet.

Die Methode aus Formel 2-7 stellt eine anpassbare Methode, die Minkowski-Distanz, dar, bei der die Beträge aller Abstände mit c potenziert werden und anschließend die Summe davon mit $\frac{1}{c}$ potenziert wird. Ein besonders häufig verwendetes Maß ist die euklidische Distanz, welche mit $c = 2$ ermittelt werden kann.

$$d(X_i, X_j) = \left(\sum_{d=1}^n |(X_{id} - X_{jd})|^c \right)^{\frac{1}{c}} \quad 2-7$$

mit

X_i = Datenpunkt von Vektor i

X_j = Datenpunkt von Vektor j

c = Exponent

n = Länge der Zeitreihen

Eine weitere Methode zur Untersuchung von Ähnlichkeiten ist die triviale Distanz. Bei dieser werden nicht die Abstände gewertet, sondern nur überprüft, ob die Werte zweier Zeitreihen zum gleichen Zeitpunkt identisch sind. In diesem Fall wird der Wert auf 0 gesetzt. Sind sie ungleich, wird der Abstand auf 1 gesetzt. Mit Formel 2-8 wird die triviale Distanz berechnet.

$$d(X_i, X_j) = \begin{cases} 0, & \text{für } X_i = X_j \\ 1, & \text{für } X_i \neq X_j \end{cases} \quad 2-8$$

mit

X_i = Datenpunkt von Vektor i

X_j = Datenpunkt von Vektor j

2.4.2 Maschinelles Lernen zur Klassifikation von Zeitreihendaten

ML-Verfahren werden heute für eine Vielzahl an Aufgaben als Hilfsmittel eingesetzt, weil sie besondere Stärken in der Erkennung komplexer Zusammenhänge besitzen. Auch im Bereich der Verarbeitung von Zeitreihen existieren bereits einige Modelle, die bestimmte Muster erkennen beziehungsweise darauf trainiert werden können, neue Muster zu erkennen. In diesem Kapitel wird ein Überblick über ML-Modelle zur Verarbeitung von Zeitreihendaten gegeben.

ML-Verfahren lassen sich unter anderem in überwachtes, unüberwachtes und bestärkendes Lernen einteilen, welche sich grundsätzlich dadurch unterscheiden, ob die

Label der Eingangsdaten bekannt ist oder nicht. In dieser Arbeit werden hauptsächlich Datensätze verwendet, bei denen die Label der Eingangsdaten bekannt sind. Aufgrund der Vielzahl an unterschiedlichen ML-Verfahren werden zunächst unterschiedliche Typen analysiert, um eine Vorauswahl treffen zu können.

In (Farahani & McCormick et al. 2023a) wird die Verwendung von ML-Modellen in der Anwendung im Bereich von Smart Manufacturing analysiert. Hierbei ist zentral, dass es sich nicht um die Eignung von Modellen handelt, sondern darum, welche Modelltypen wie häufig angewendet werden. Dabei wird übergeordnet in künstliche neuronale Netze, welche auch Deep Learning beinhalten, und konventionelle Verfahren unterschieden. Diese werden weiter unterteilt in untergeordnete Modelltypen. Außerdem wird zwischen multivariaten und binären Ausgangsklassen unterschieden. Für diese Arbeit werden hauptsächlich die Ergebnisse des überwachten Lernens mit multivariaten und binären Zeitreihen betrachtet.

Bei neuronalen Netzen wird eine Struktur aus mehreren Schichten mit einer endlichen Anzahl an Knoten aufgebaut, bei denen die Knoten abhängig vom gewählten Modell miteinander verbunden sind. Diese Verbindungen werden durch mathematische Funktionen beschrieben. Häufig werden vorwärts gerichtete Modelle verwendet, bei denen Verbindungen eines Knotens immer nur mit nachfolgenden Knoten hergestellt werden. Ein Beispiel für ein konventionelles Verfahren ist der Entscheidungsbaum, welcher auf einer Verzweigung von Knoten beruht, bei denen jeweils ein Merkmal untersucht und dann eine binäre Entscheidung getroffen wird. (Choo & Greplova et al. 2020)

In den Untersuchungen von Farahani & McCormick et al. (2023a) wurde festgestellt, dass für Zeitreihenanalysen in Smart Manufacturing häufiger neuronale Netze als konventionelle Verfahren verwendet werden. Die häufigsten neuronalen Netze sind Feed Forward Neural Networks, Convolutional Neural Networks (CNN) und Recurrent Neural Networks (RNN). An vierter Stelle steht jedoch der Entscheidungsbaum, welcher zu den konventionellen Verfahren gehört. Alle vier Typen können sowohl für binäre als auch für multivariate Ausgangsklassen verwendet werden. In einer weiteren Untersuchung werden Algorithmen der übergeordneten Modelltypen analysiert. Hier sind die häufigsten Modelle CNN, Multi Layer Perceptron, Random Forest (RanFor) und ein Long-Short-Term Memory Network (LSTM). Die ersten drei Modelle werden im Vergleich zum LSTM häufiger für multivariate Ausgangsklassen verwendet.

Auf Basis der Untersuchungsergebnisse lässt sich feststellen, dass sich mehrere Modelltypen für die Klassifikation von Zeitreihen eignen, wofür bereits verschiedene Algorithmen existieren. Besonders CNN-Modelle werden sehr häufig genutzt, weshalb in diesem Kapitel die gängigen Modelle Fully Convolutional Network (FCN) und das Residual Network (ResNet) erläutert werden. Da die höchste Popularität jedoch nicht allein als Entscheidungskriterium gelten sollte, werden zusätzlich noch die Modelle LSTM und RanFor erläutert, die ebenfalls häufig verwendet wurden. Dadurch werden sowohl künstliche neuronale Netze sowie auch ein konventionelles Verfahren näher betrachtet.

2.4.2.1 Fully Convolutional Network

Ein FCN kann aus mehreren Blöcken bestehen, in denen sich abwechselnd Convolutional Layer und ein Batch-Normalization Layer mit einer Rectified Linear Unit Aktivierungsfunktion (ReLU) befinden. In jedem Convolutional Layer werden lokale Muster in den Eingangsdaten untersucht, die durch die Anpassung der Gewichte zwischen Neuronen variiert werden. Ein Batch ist eine Menge an Trainingsdaten, die durch das Modell verarbeitet wird, bevor die Parameter des Modells angepasst werden. Bei der Batch-Normalisierung werden die Trainingsdaten normalisiert, um schneller Konvergenz und eine höhere Generalisierbarkeit zu erzielen. Bei der ReLU-Funktion werden die Eingangsdaten so verrechnet, dass alle negativen Werte auf 0 gesetzt werden, aber die positiven Werte unverändert bleiben. Nach der letzten Schicht werden die Ausgangsdaten in die Global Pooling Schicht weitergegeben und anschließend mit der Softmax-Funktion verrechnet. Bei einem Global Pooling werden über einen Filter die Informationen eines bestimmten Bereichs zu einem Wert zusammengefasst. Die Softmax-Funktion ist eine Aktivierungsfunktion, die die Zuordnungswahrscheinlichkeit der Eingangsdaten einer Klasse berechnet. (Choo & Greplova et al. 2020)

In Abbildung 2-15 ist beispielhaft der Aufbau eines FCN dargestellt. Die Eingangsdaten werden von Block zu Block übertragen, wobei jeder Block aus einem Convolutional Layer mit der angegebenen Anzahl an Filtern besteht sowie einer darauffolgenden Batch-Normalization (BN) mit ReLU-Aktivierungsfunktion. Im letzten Block werden die Daten einem Global Pooling unterzogen, um die Dimensionalität zu reduzieren. Anschließend wird über die Softmax-Funktion die Wahrscheinlichkeit der Zugehörigkeit der Eingangsdaten zu einer Klasse angegeben.




Abbildung 2-15: Aufbau eines FCN in Anlehnung an Wang & Yan et al. (2017)

2.4.2.2 Residual Network

Ein ResNet kann einem FCN sehr ähnlich sein und besteht oft aus einer Vielzahl an Schichten, wodurch insgesamt mehr Parameter optimiert werden müssen. Damit das Training schneller durchgeführt werden kann, wird das Modell in mehrere Blöcke aufgeteilt, die als Residual Units bezeichnet werden. Zusätzlich wird die Information vor jedem Block dem Output des Blocks über sogenannte Skip Connections wieder hinzugefügt. Das hat den Vorteil, dass zu Beginn des Trainings die Zielfunktion direkt an die erste Eingabe angepasst wird, die häufig auch der End-Zielfunktion stärker ähnelt als eine zufällig generierte. Dadurch kann sich die Trainingszeit sehr stark reduzieren. (Géron 2019)

In Abbildung 2-16 ist ein Grundmodell eines ResNet von Wang & Yan et al. (2017) dargestellt. Die Eingangsdaten der Eingabe-Schicht werden der ersten Residual Unit und gleichzeitig der Output-Schicht übergeben. Die Residual Units bestehen wiederum abwechselnd aus einem Convolutional Layer und einer Schicht mit einer Batch-Normalisierung und der ReLU-Aktivierungsfunktion.




Abbildung 2-16: Aufbau eines ResNet in Anlehnung an Wang & Yan et al. (2017)

2.4.2.3 Long Short-Term Memory

Ein LSTM ist eine Reihe an Zellen, die die Eingangsdaten eigenständig verarbeiten und entscheiden, welche Information davon an die nächste Zelle weitergegeben werden

soll. Die Verwendung eines LSTM hat den besonderen Vorteil, dass Abhängigkeiten durch das Erinnern von Informationen über einen längeren Zeitraum festgestellt werden können. Der Aufbau eines LSTM besteht aus vier sogenannten Gates und drei weiteren Komponenten. Bei den Gates handelt es sich um das Forget Gate, Candidate Gate, Input Gate und Output Gate. Die weiteren Komponenten sind der Hidden State und die Memory Cell. Bei den Gates handelt es sich um einschichtige neuronale Netzwerke, die mit Ausnahme des Candidate Gate die Sigmoid-Aktivierungsfunktion nutzen. Bei dem Candidate Gate wird die hyperbolische Tangensfunktion als Aktivierungsfunktion verwendet. (Vishwas & Patel 2020)

In Abbildung 2-17 ist eine LSTM-Zelle zum Zeitpunkt T abgebildet. Die Eingangszelle enthält den Eingangsvektor x , den vorherigen Hidden State h_{t-1} und den vorherigen Speicherzustand C .

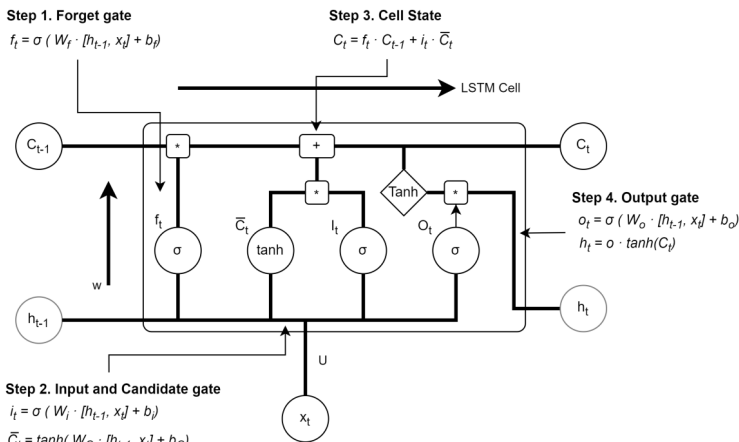


Abbildung 2-17: Architektur einer LSTM Zelle nach Vishwas & Patel (2020)

In einem ersten Schritt werden die Eingangsdaten im Zellstatus geschrieben beziehungsweise, wenn der Zellstatus schon Daten enthält, entscheidet das Forget Gate, welche Daten entfernt werden sollen. Im zweiten Schritt werden Entscheidungen darüber getroffen, welche Informationen wichtig sind und deshalb gespeichert werden müssen. Dafür trifft zunächst das Input Gate die Entscheidung darüber, welche Werte aktualisiert werden sollen. Anschließend erzeugt das Candidate Gate einen Vektor mit Werten als Kandidaten für die Aktualisierung des Zellzustands. Durch die Verknüpfung

der Gates wird in einem dritten Schritt der Zellzustand aktualisiert. Im vierten Schritt wird die eigentliche Ausgabe der Zelle durch das Output Gate erzeugt, was entscheidet, welche Daten als Ausgabe der Zelle dienen sollen. (Vishwas & Patel 2020)

2.4.2.4 Random Forest

Die Klassifizierung durch einen RanFor basiert auf Entscheidungen vieler einzelner Entscheidungsbäume. Diese beinhalten eine endliche Anzahl an Entscheidungsknoten, die während dem Training angepasst wird. An einem Entscheidungsknoten wird immer ein Merkmal abgefragt, worauf der nächste Knoten anhand des Ergebnisses festgelegt wird. Die Merkmale sind oft vor dem Training bestimmt und analysiert, sodass nur Merkmale existieren, die gut für die Problemlösung geeignet sind. Am letzten Knoten wird eine finale Entscheidung für die Zuordnung der Eingangsdaten getroffen. Verwendet man mehrere unterschiedlich generierte Entscheidungsbäume, erhält man mit hoher Wahrscheinlichkeit auch unterschiedliche Zuordnungen der Eingangsdaten. Ein RanFor entsteht dann beispielsweise durch das gemeinsame Abstimmen der Zielklasse, wobei auch Gewichtungen der Entscheidungen einzelner Entscheidungsbäume berücksichtigt werden können. (Hänsch & Hellwich 2017)

In Abbildung 2-18 wird das Schema eines beispielhaften RanFor veranschaulicht.




Abbildung 2-18: RanFor bestehend aus mehreren Entscheidungsbäumen nach Hänsch & Hellwich (2017)

2.4.3 Industrielle Anwendungen

Von Čulić Gambiroža & Mastelić et al. (2023) wird ein Ansatz im IoT-Bereich zum Verlust von Daten erläutert und wie man durch ML-Verfahren auf ursprüngliche Signaltypen rückschließen kann. Der Ansatz baut auf der Herausforderung des Verlusts von Metadaten auf, wodurch der Typ von Sensoren nicht mehr identifizierbar ist. Zur automatisierten und möglichst aufwandsarmen Bestimmung von Sensortypen werden

ML-Klassifikatoren verwendet. Untersucht wurden dafür mehrere Modelle mit jeweils der Architektur eines Ein-Klassen-Klassifikators, binären Klassifikators und eines Multiklassen-Klassifikators. Die Datengrundlage besteht aus Zeitreihenwerten verschiedener Sensoren, beispielsweise der Windgeschwindigkeit, der UV-Strahlung und der Temperatur sowie Datenwerten aus Computerhardware wie der CPU-Auslastung. Die höchste Genauigkeit zur Klassifikation der Rohdaten erzielte der RanFor mit der Architektur eines Multiklassen-Klassifikators. Zusätzlich wurde untersucht, inwieweit das Sample-Zeitintervall Einfluss auf die Genauigkeit der ML-Modelle hat. Dabei wurde festgestellt, dass diese besonders beim verwendeten RanFor als Multiklassen-Klassifikator einen Einfluss auf die Genauigkeit haben kann.

Eine weitere Anwendung der Extraktion und anschließenden Identifikation von Zeitreihen auf Basis von ML-Verfahren wurde von Hozhabr Pour & Wegmeth et al. (2019) durchgeführt. Ziel der Arbeit von Hozhabr Pour & Wegmeth et al. (2019) ist die automatisierte Klassifikation von Sensorsignalen, die auf einem CAN-Bus in Automobilen verarbeitet werden. Dabei werden die Klassen auf die Grundsignale Geschwindigkeit, Bremse, Lenkwinkel und Gaspedal begrenzt, die mit entwickelten Methoden anhand ihres Verlaufs erkannt werden sollten. Eine Untersuchung umfasst die Auswirkung von Merkmalen, die durch Expertenwissen oder durch Algorithmen aufgestellt wurden, um die beiden Methoden bewerten und vergleichen zu können. Außerdem wird die Leistungsfähigkeit eines binären Klassifikators und eines Multiklassen-Klassifikators analysiert. Als Ergebnis zeigt sich, dass der Einsatz von Algorithmen zur Suche von Merkmalen zusammen mit dem Multiklassen-Klassifikator die höchste Genauigkeit erzielt.

Auch die Arbeit von Lestyan & Acs et al. (2019) beschäftigt sich mit der Klassifikation von Zeitreihen in Automobilen, die auf einem CAN-Bus übertragen werden. Das Hauptziel ist jedoch die Rückführung auf den Fahrer anhand des Fahrverhaltens, wobei dafür zunächst der Signaltyp der extrahierten Signale identifiziert werden muss. Davor wird ein Signalpool bestimmt, der ausreichend ist, um anschließend Informationen über das Fahrverhalten zu sammeln. Als Ansatz werden mehrere Klassifikatoren ausgewählt, die jeweils nach einem spezifischen Signal suchen. Als Training werden Zeitreihen aus nur einem Versuchsfahrzeug verwendet, um später zusätzlich die Übertragbarkeit des Systems auf andere Fahrzeugmodelle überprüfen zu können. Als Klassifikatoren werden RanFor mit binärer Ausgabe verwendet, weil weitere Versuche für einen Multiklassen-Klassifikator nicht zielführend waren. Durch die Anwendung von RanFor konnten die

drei Signale Drehzahl, Geschwindigkeit und Gaspedalposition bei allen Fahrzeugtypen erfolgreich identifiziert werden.

2.5 Bewertung des Stands der Forschung und Technik

In diesem Kapitel wird der Stand der Forschung und Technik zusammengefasst und bewertet. Hierfür wird ein Gesamtfazit zur gegenwärtigen Ausgangssituation gezogen, um dann im zweiten Teil die zentralen Defizite im Stand der Forschung und Technik aufzuzeigen.

2.5.1 Fazit zum Stand der Forschung und Technik

In Kapitel 2.1 wurden zunächst die Rahmenbedingungen heutiger Produktionen beschrieben. Unternehmen müssen im globalen Wettbewerb in ihrer Produktion eine hohe Effektivität und Kosteneffizienz erzielen. Der Einsatz von Industrie 4.0-Anwendungen unterstützt bei der Erreichung dieser Ziele, beispielsweise in Form vielfältiger Anwendungen zur Zustandsüberwachung, die Anlagenstillstände reduzieren.

Aufgrund des hohen Durchschnittsalters von Produktionsanlagen ist neben der Entwicklung von Industrie 4.0-Anwendungen für neue Maschinen auch die Digitalisierung des Brownfields von entscheidender Bedeutung. Neben der Ergänzung externer Sensorik, die von vielen Unternehmen aufgrund von Kosten und geringer Skalierbarkeit abgelehnt wird, ist vor allem die Verwendung interner Daten aus Bestandsanlagen interessant, um Anwendungen auf bestehenden Maschinensteuerungssignalen aufbauen zu können. Beispiele hierfür sind Anomalie- und Verschleißdetektionssysteme auf Basis von Motorströmen und Lagewerten aus Antriebsachsen. Die zugrundeliegenden Maschinen, -komponenten sowie die zugehörige Steuerungs- und Regelungstechnik hierfür wurde in Kapitel 2.2 erläutert.

Die kommunikationstechnische Einbindung von Brownfield-Anlagen, um Maschinensteuerungssignale für aufbauende Anwendungen zu nutzen, stellt für viele Unternehmen eine große Herausforderung dar. Diese Herausforderung begründen die Unternehmen vor allem mit Hemmnissen durch fehlende personelle Ressourcen und Expertise, die sowohl für die Extraktion als auch die Identifikation der angestrebten Signale notwendig sind. Kapitel 2.3 erläutert in diesem Kontext die Bereitstellung von Maschinensteuerungsdaten im Brownfield, stellt dar, welche Datenschnittstellen bestehen und welche Aufwände Unternehmen zur Anbindung dieser gegenwärtig entstehen. Zentrale Aufwände sind dabei zum einen der grundsätzliche Datenaustausch, für den

es verschiedene existierende Lösungsansätze gibt, und zum anderen die Identifikation der angestrebten Signale aus den extrahierten Zeitreihendaten.

In Kapitel 2.4 wurde bei der Verarbeitung und Identifikation von Zeitreihendaten angesetzt und die bestehenden Ansätze aus Forschung und Technik aufgezeigt. Dabei wurde ersichtlich, dass verschiedene Arbeiten existieren, die sich mit der Klassifikation von Zeitreihendaten und auch der Identifikation von Signalen in diesen auseinandersetzen. Die Arbeiten bewegen sich in anderen Anwendungsfeldern mit abweichenden Rahmenbedingungen, zeigen aber das grundsätzliche Potential der Ansätze. Darüber hinaus wurden im zweiten Teil des Kapitels Methoden und Werkzeuge vorgestellt, die im Umgang und zur Verarbeitung der Zeitreihendaten nützlich sind.

2.5.2 Aktuelle Defizite in Forschung und Technik

Wie im vorherigen Kapitel bereits geschildert, nimmt die Bereitstellung von Maschinensteuerungsdaten aus Brownfield-Produktionssystemen bei der Digitalisierung der Produktion einen entscheidenden Stellenwert ein. Die kommunikationstechnische Anbindung stellt für viele Unternehmen dabei eine große Herausforderung dar und wird vor allem durch fehlendes Personal und Expertise gehemmt.

Der Stand der Forschung und Technik zeigt, dass es gegenwärtig keine hinreichenden Lösungen gibt, mit denen Anwender bei dieser Herausforderung umfassend unterstützt werden können. Sowohl der Austausch von Steuerungssystemen als auch die Nachrüstung kommerzieller Hard- und Softwarelösungen als IoT-Verbindung sind mit hohen Kosten und Aufwänden für Anwender verbunden. Die Entwicklung eigener Datenextraktionssysteme auf Basis von Open Source-Bausteinen stellt eine in der Verwendung günstigere und mögliche Alternative dar, unterstützt den Anwender jedoch lediglich bei der initialen Extraktion der Daten, nicht bei der ebenfalls aufwändigen Identifikation und Zuordnung der angestrebten Signale. Letzteres gilt ebenfalls für die zuvor genannten Austausch- und Nachrüstsysteme sowie für Brownfield-Maschinen mit einfacherer Zugänglichkeit der Daten, aber ohne bekannte Struktur und Semantik. Standardisierte Informationsmodelle wie umati für OPC UA stellen für herstellerübergreifende Lösungen zwar sinnvolle Ansätze dar, sind jedoch aufgrund ihrer Neuheit nur auf einem Bruchteil von Brownfield-Produktionssystemen umgesetzt beziehungsweise umsetzbar und in ihren Signalkräumen begrenzt.

Im Bereich der automatisierten Identifikation und Zuordnung von Zeitreihendaten sind vielversprechende Arbeiten erkennbar. Die beschriebenen Ansätze befassen sich mit

der ML-basierten Klassifikation von Signalen. Alle bekannten Anwendungen aus dem Stand der Technik liegen jedoch in abweichenden Einsatzbereichen. Diese umfassen beispielsweise Computertechnik mit Signalen wie der CPU-Auslastung und der Speichernutzung, den Automobilbereich mit Signalen wie den über CAN-Bus kommunizierten Lenkwinkel des Fahrzeugs sowie meteorologische Sensordaten wie die Luftfeuchtigkeit, UV-Strahlung, Windgeschwindigkeit und Temperatur. Die Anwendungen unterscheiden sich damit sowohl hinsichtlich der Infrastruktur und Datenschnittstellen als auch bezüglich der verwendeten Signale. Gegenwärtig sind keine Arbeiten bekannt, die sich mit einem vergleichbaren automatisierten Identifikationsprozess in Produktionssystemen auseinandersetzen. Die Identifikation und Zuordnung der angestrebten Signale aus Bestandsmaschinen stellen damit im Hinblick auf den Stand der Forschung und Technik das größte Defizit dar.

3 Zielsetzung und Vorgehensweise

In diesem Kapitel wird die Zielsetzung der vorliegenden Dissertation basierend auf dem Defizit im Stand der Technik und Forschung konkretisiert. Im Anschluss an diese Konkretisierung wird eine aufbauende Übersicht zum entwickelten Lösungsansatz gegeben, die das detailliertere Vorgehen zur Zielerreichung ganzheitlich darstellt.

3.1 Konkretisierung der Zielsetzung

Ziel dieser Dissertation ist es, Maschinensteuerungsdaten in Brownfield-Produktionssystemen automatisiert bereitzustellen. Diese Bereitstellung umfasst die automatisierte Extraktion der Daten sowie die aufbauende Identifikation der Signale. Dabei sollen in einem ersten Schritt Daten aus verschiedenen Kommunikationsschnittstellen von Bestandsmaschinen ausgelesen und dem Identifikationssystem übergeben werden. Anschließend erfolgt die Identifikation ausgewählter Signale aus den extrahierten Daten und ihre Zuordnung zu einem definierten Informationsmodell. Der angestrebte Ansatz wird darüber hinaus in ein Assistenzsystem überführt, das den Anwender durch den Bereitstellungsprozess leitet. Das System soll damit den gegenwärtig häufig zeit- und aufwändigen manuellen Identifikationsprozess ersetzen und von diesem als intuitives Softwareprogramm aufwandsarm und mit möglichst geringen Anpassungen auf einem im Netzwerk der Maschine befindlichen PC genutzt werden können.

Das angestrebte System hat das Ziel, mit möglichst geringem Aufwand in Brownfield-Produktionssystemen eine technische Basis für den Anwender zu schaffen, auf der Maschinendaten visualisiert, dokumentiert und für weiterführende Industrie 4.0-Anwendungen genutzt werden können. Zahlreiche der von Unternehmen gewünschten Anwendungen bauen auf Maschinenkomponentendaten auf, beispielsweise Signale wie Motorströme und Positionen aus Antriebsachsen (Gönzheimer & Netzer et al. 2022). Heutige Informationsmodellstandards bilden diese aufgrund ihrer Fokussierung auf Signale auf der Ebene der Gesamtmaschine nur unzureichend ab. Daher werden Daten aus Antriebsachsen als zentrale Signale für das Zielsystem genutzt. Dies verfolgt darüber hinaus das Ziel, den Ansatz möglichst übertrag- und skalierbar zu gestalten, da Antriebsachsen und die damit einhergehenden Signale und Zusammenhänge in vielfältigen Maschinen und Anwendungen genutzt werden (Gönzheimer & Netzer et al. 2020). Aufgrund dieser Vielfalt und der herausgehobenen Stellung von Werkzeugmaschinen im Kontext der Produktion sollen sie als Basis für die Betrachtung und Entwicklung des Systems dienen.

Abbildung 3-1 visualisiert das angestrebte Zielsystem und die Interaktion der Teilkomponenten. Die Datenerfassung erfolgt entweder über das direkte Auslesen des Steuerungssystems via Ethernet TCP/IP, von Kommunikationsprotokollen wie OPC UA und MQTT oder von existierenden Datenbanken wie InfluxDB. Die entsprechende Auswahl der Signalquelle kann vom Anwender über eine Benutzeroberfläche (engl.: Graphical User Interface, kurz: GUI) vorgenommen werden. Über die Benutzeroberfläche wird der Anwender durch den weiteren Prozess zur Identifikation der Signale geleitet und kann sich diese am Ende des Prozesses entweder als Zuordnungsinformation ausgeben lassen oder einen Datenserver in Struktur des bekannten Informationsmodells erzeugen.

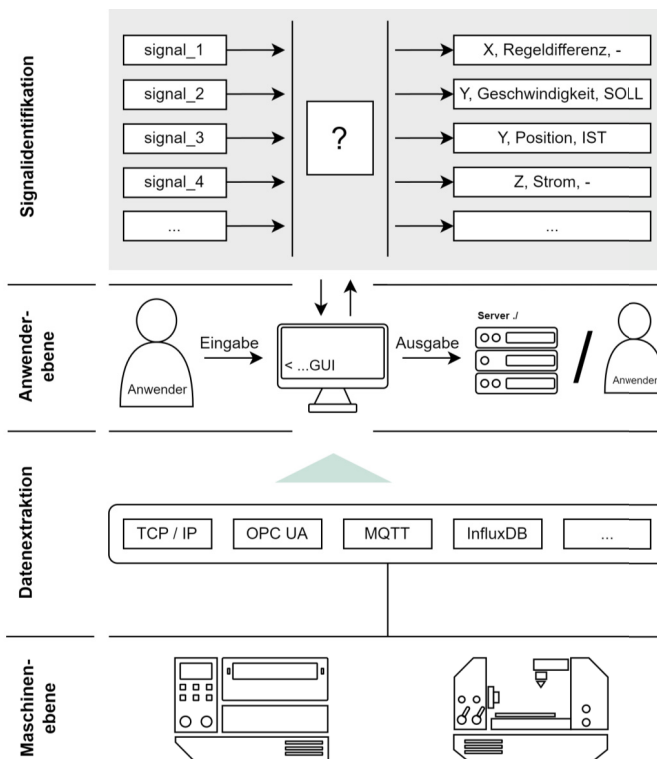


Abbildung 3-1: Konkretisiertes Zielsystem in Anlehnung an Gönzheimer & Ströbel et al. (2023b)

3.2 Vorgehensweise zur Zielerreichung

Die in Kapitel 3.1 konkretisierten Ziele sollen im Rahmen eines dreistufigen Lösungsansatzes untersucht und erarbeitet werden, der in Abbildung 3-2 dargestellt ist. Diese Stufen umfassen die Themenbereiche der Datenextraktion, der Identifikationsmethoden sowie des Assistenzsystems, auf die folgend näher eingegangen wird.

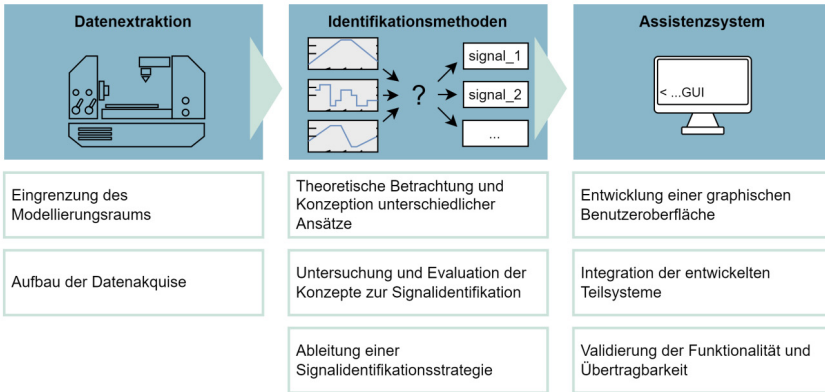


Abbildung 3-2: Vorgehensweise zur Entwicklung des Gesamtsystems

Im Rahmen der Datenextraktion werden Lösungen für die kommunikationstechnische Anbindung von Bestandsmaschinen erarbeitet. Hierfür wird in einem ersten Schritt der Modellierungsraum hinsichtlich der einbezogenen Maschinen und -schnittstellen sowie Signale eingegrenzt. Mittels der Datenextraktion werden Zeitreihendaten als Grundlage für die nachfolgenden Identifikationsmethoden ausgelesen (Kapitel 4).

Im darauffolgenden Bereich der Identifikationsmethoden findet zunächst eine theoretische Betrachtung von Klassifikations- und Identifikationsansätzen statt, auf deren Basis die zu untersuchenden Konzepte definiert werden. Die entwickelten Konzepte werden dann parallel ausgearbeitet und hinsichtlich ihrer Performanz, Stärken und Schwächen untersucht. Aufbauend auf allen Untersuchungsergebnissen wird eine umfassende Signalidentifikationsstrategie abgeleitet (Kapitel 5).

Die entwickelten Teilsysteme werden im letzten Bereich des Assistenzsystems in ein Gesamtsystem integriert, für das außerdem eine Benutzeroberfläche entwickelt wird. Das erarbeitete System wird abschließend in verschiedenen Anwendungsfällen hinsichtlich seiner Funktionalität und Übertragbarkeit validiert (Kapitel 6 und 7).

4 Kommunikationstechnische Maschinenanbindung und Extraktion von Maschinendaten

Um Sensorsignale aus Werkzeugmaschinen verarbeiten zu können, muss zunächst ein System erarbeitet werden, das eine Verbindung zwischen der Maschine und dem Ziel-PC herstellt und anschließend die Adressen existierender Datenquellen erkennt. In diesem Kapitel wird dieses System erläutert. Dafür wird zunächst der Modellierungsraum anhand der zu lösenden Aufgabe eingegrenzt, bevor die einzelnen Teilschritte vom Verbindungsaufbau bis hin zum Abonnieren von Signalquellen beschrieben werden. Der Inhalt dieses Kapitels wurde im Rahmen der angeleiteten Abschlussarbeit (A_Heider 2021) erarbeitet. Die Ergebnisse sind zusammenfassend dargestellt.

4.1 Eingrenzung des Modellierungsraums

Für die Eingrenzung des Modellierungsraums muss zunächst bekannt sein, für welche Anwendungsfälle das Gesamtsystem Signale identifizieren soll. Wie in Kapitel 3.1 angeführt, werden Werkzeugmaschinen als Basis der Betrachtung und Entwicklung des Systems genutzt. Da allerdings auch in anderen Maschinen, wie beispielsweise einem Vertikalknickarmroboter, ähnliche Komponenten verbaut sind, ist neben der Skalierbarkeit auch die Übertragbarkeit von großer Bedeutung. Für die Befähigung der aufgeführten Industrie 4.0-Anwendungen wie Anomaliedetektionen oder Zustandsüberwachungen werden entsprechende Maschinenkomponentendaten benötigt. Dafür muss zunächst der Zugriff auf die Werkzeugmaschinen ermöglicht werden, bevor Signale extrahiert werden können. Eine Herausforderung stellen die unterschiedlichen Kommunikationsprotokolle dar, die in den Werkzeugmaschinen verwendet werden. Nach Netzer & Begemann et al. (2021) sind in Unternehmen häufig mehrere Typen von Maschinen von unterschiedlichen Herstellern und unterschiedlichen Alters vorhanden. Neben einem möglichen Direktzugriff auf die SPS umfassen implementierte Kommunikationsprotokolle unter anderem OPC UA, OPC DA und MQTT, welche in den nachfolgenden Kapiteln näher betrachtet werden. Aus diesem Grund wird der Fokus des Zielsystems auf den Datenaustausch mit den aufgeführten Kommunikationsprotokollen, mit möglichen Datenbanken und direkt mit vorhandenen SPS gesetzt. Diese stellen gemeinsam eine repräsentative Auswahl vorhandener Zugangsmöglichkeiten in Brownfield-Produktionssystemen dar.

Damit einher geht auch die Auswahl des abzubildenden Signalraums. Bei Maschinen höheren Alters beschränkt sich der Signalraum oft auf nur wenige Signale. Dabei handelt es sich beispielsweise um Drehmomente, Motorströme und Prozesskräfte (Netzer & Begemann et al. 2021, S. 527). Weitere mögliche Signale sind beispielsweise Positions- und Geschwindigkeitssignale sowie Signale zur Leistung, Last und Temperatur. Wie in Kapitel 3.1 beschrieben, bauen die industriell gewünschten Anwendungen vor allem auf Signalen wie Motorströmen und Lagewerten aus Antriebsachsen auf, weshalb diese auch den Fokus des Signalraums darstellen. Ein weiterer Vorteil einer Betrachtung dieser Signalgruppe ist die mögliche Skalierbarkeit auf andere Maschinen mit vergleichbaren Antriebsachsen.

Das angestrebte Zielsystem für die Datenextraktion umfasst damit Konnektorlösungen für OPC UA, OPC DA, MQTT, Datenbanksysteme sowie eine direkte Kommunikation mit SPS. Der angestrebte Signalraum umfasst Motorströme, verschiedene Soll- und Ist-Positionen, Geschwindigkeiten, Drehmomente, Leistung, Last sowie die Regeldifferenzen von Antriebsachsen. Diese können außerdem von den beschriebenen Schnittstellen und Konnektorlösungen abgebildet werden.

4.2 Datenextraktion in Brownfield-Maschinen

In diesem Kapitel wird beschrieben, wie eine Verbindung mit den dargestellten Schnittstellen von Werkzeugmaschinen im Brownfield hergestellt und anschließend Daten aufgezeichnet werden können. Dazu werden im ersten Teil des Kapitels die Zugriffsmöglichkeiten von Datenquellen betrachtet und das entsprechende Konzept zum Datenaustausch skizziert. Im zweiten Teil wird darauf aufbauend die konkrete Umsetzung der Datenextraktion beschrieben.

4.2.1 Betrachtung der Zugriffsmöglichkeiten von Datenquellen

In Abbildung 4-1 ist ein schematischer Aufbau der Kommunikationsverbindung dargestellt. Dabei wird in drei Ebenen unterschieden. Auf der Maschinenebene befinden sich NC und SPS, über die Signale verarbeitet und gesendet beziehungsweise empfangen werden. Die Ebene zur Datenextraktion beinhaltet eine Middleware, welche einen Datenaustausch mit der Maschinenebene auf der Basis der jeweiligen Kommunikationsprotokolle ermöglicht. Dabei kann es sich unter anderem um einen Direktzugriff auf die SPS oder beispielsweise einen OPC UA Server handeln. Auf Anwenderebene befindet sich eine GUI, über die der Anwender durch ein Representational State Transfer

Application Programming Interface (REST-API) das Programm zur Datenerfassung bedienen kann. Wird eine Datenerfassung durch den Anwender gestartet, werden die Datenpunkte auf der Middleware gespeichert und nach Ende der Aufzeichnung an die Anwenderebene zurückgegeben. Die konkrete Umsetzung wird im folgenden Kapitel erläutert.

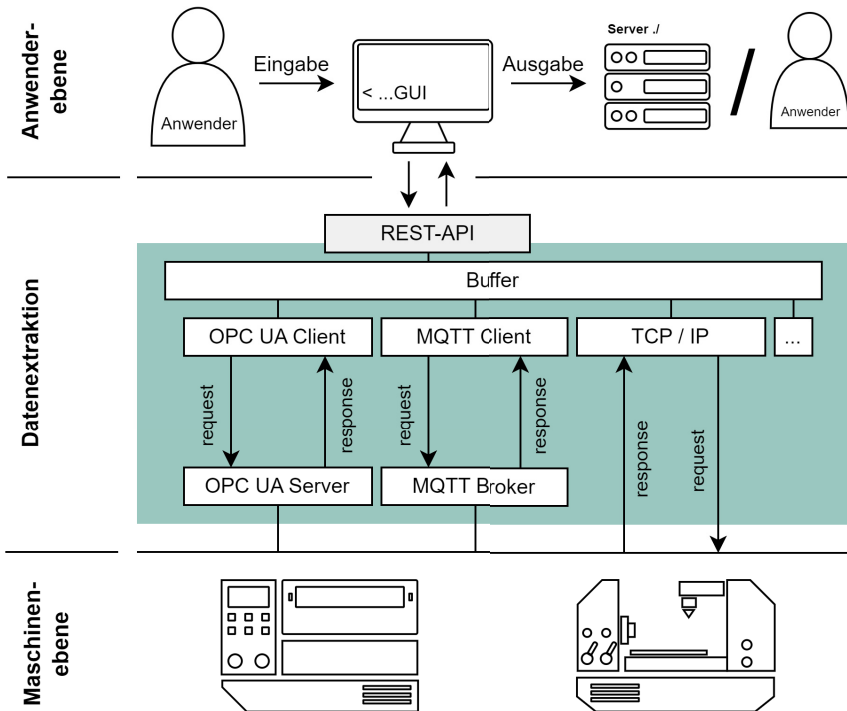


Abbildung 4-1: Schematische Darstellung des Systems zur Kommunikation mit Werkzeugmaschinen in Anlehnung an Gönzheimer & Ströbel et al. (2023b)

4.2.2 Umsetzung der Datenextraktion

Für die kommunikationstechnische Anbindung an Werkzeugmaschinen werden hauptsächlich Open Source Java Bibliotheken verwendet. Dies ermöglicht einerseits die

Anpassung unterschiedlicher Programmabschnitte ohne die Einschränkungen von Herstellern, aber auch die Erweiterung von zusätzlichen Modulen wie die Einbindung weiterer Kommunikationsprotokolle. Im Allgemeinen besteht die Anbindung aus drei übergeordneten Modulen. Bei diesen handelt es sich um DataChannel, DataBrowser und den DataAdapter. Durch den DataChannel werden die Datenstruktur vorgegeben und Adressangaben gemacht, die einen Signalknoten beschreiben, beispielsweise SPS-Variablen. Der DataBrowser sucht nach Variablen in einem bestimmten Pfad. Mit dem DataAdapter können unter anderem Variablen abonniert werden, um die Werte der jeweiligen Zeitreihen auszulesen. Der zeitliche Aufwand für einen Anwender ist dabei gering. Zu den wenigen aktiven Aufgaben gehört zu Beginn die Angabe notwendiger Daten zum Verbindungsaufbau wie der URL eines Servers sowie der dazugehörigen Zugangsdaten. Über die Benutzeroberfläche wird eine REST-API aufgerufen, die wiederum die aufgezeichneten Daten an den Anwender übergibt. In Abbildung 4-2 ist der schematische Aufbau dargestellt.

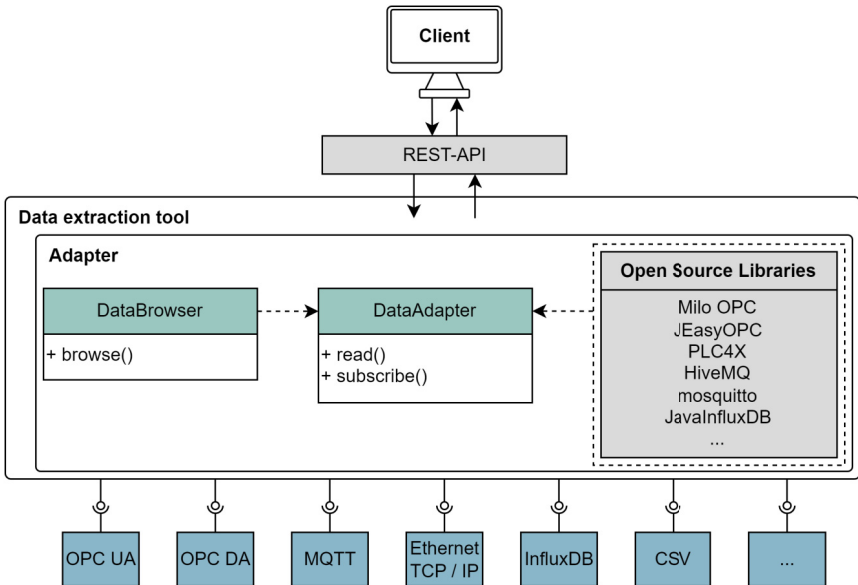


Abbildung 4-2: Schematischer Aufbau der Teilmodule zur automatisierten Extraktion von Signalen

4.2.2.1 DataChannel

Der DataChannel beschreibt die Datenstruktur und wird als Objekt erzeugt. In Abbildung 4-3 sind die darin enthaltenen Variablen am Beispiel eines OPC UA Servers dargestellt.

```
{
  "name": "Tag14",
  "source": "withSourcetime=true;
    password=null;
    endpointName=opc.tcp://laptop-8fia6k64:62640/
      IntegrationObjects/ServerSimulator;
    userName=null;
    adapterType=net.sytes.botg.opcua.OPCUAClientAdapter",
  "address": "ns=2;s=Tag14",
  "dataType": "INT",
  "unit": "",
  "description": "",
  "value": "36625",
  "sourceTime": 1624481122514
}
```

Abbildung 4-3: Datenstruktur am Beispiel eines OPC UA Servers nach A_Heider (2021)

4.2.2.2 DataBrowser

Der DataBrowser ist im Allgemeinen ein Teilmodul, das automatisiert nach Variablen sucht. Da die Kommunikationsprotokolle unterschiedliche Datenstrukturen aufweisen, wird für jedes Modell der passende DataBrowser erstellt. Der DataBrowser sucht in der Zielstruktur nach bestimmten Merkmalen und speichert diese mit der Struktur des vorher definierten DataChannels, sodass eine Liste mit allen verfügbaren Variablen entsteht.

4.2.2.3 DataAdapter

Um die gefundenen Variablen für weitere Schritte verfügbar zu machen, kann der DataAdapter diese Variablen lesen und abonnieren. Der Aufbau des DataAdapter besteht aus den notwendigen Parametern für einen Verbindungsaufbau, beispielsweise URL, Benutzername und Passwort, sowie Methoden aus der passenden Java Bibliothek für das vorliegende Kommunikationsprotokoll. Bei einem OPC UA Server können beispielsweise Variablen abonniert sowie auch die Dauer der Aufnahme und die Abtastfrequenz festgelegt werden.

4.2.2.4 REST-Interface

Das System mit den Methoden befindet sich auf einem HTTP-Server. Der Zugriff durch einen Client erfolgt über ein REST-Interface. Der Client übergibt die Startparameter durch die ConfigMap, welche als String an einen http-Request angehängt wird.

Anschließend kann der DataBrowser durch den Befehl `openBrowser()` geöffnet und durch `start()` gestartet werden, wodurch der DataBrowser nach Signalen sucht. Über die Funktion `getBrowsedChannels()` werden die gefundenen Signale als JSON Objekt mit der Struktur des DataChannels an den Anwender übergeben. JSON ist ein weitverbreitetes Datenformat, weshalb es auch in dieser Anwendung verwendet wird. Durch die Übergabe der Signale an den Anwender kann dieser diejenigen abwählen, die er nicht abonnieren möchte. Die angepasste Liste wird anschließend über das REST-Interface zurückgegeben und der DataAdapter durch `openSource()` gestartet. Die angegebenen Signale werden dann mit der Vorgabe der Abtastrate und Aufnahmedauer durch `getChannelData()` entsprechend aufgezeichnet. Nach Ablauf der Aufnahmedauer werden die Signale als JSON Objekt an den Anwender gegeben, wodurch die Zeitreihen durch weitere Programme verarbeitet werden können. Eine chronologische Darstellung des gesamten Ablaufs ist in Abbildung 4-4 dargestellt.

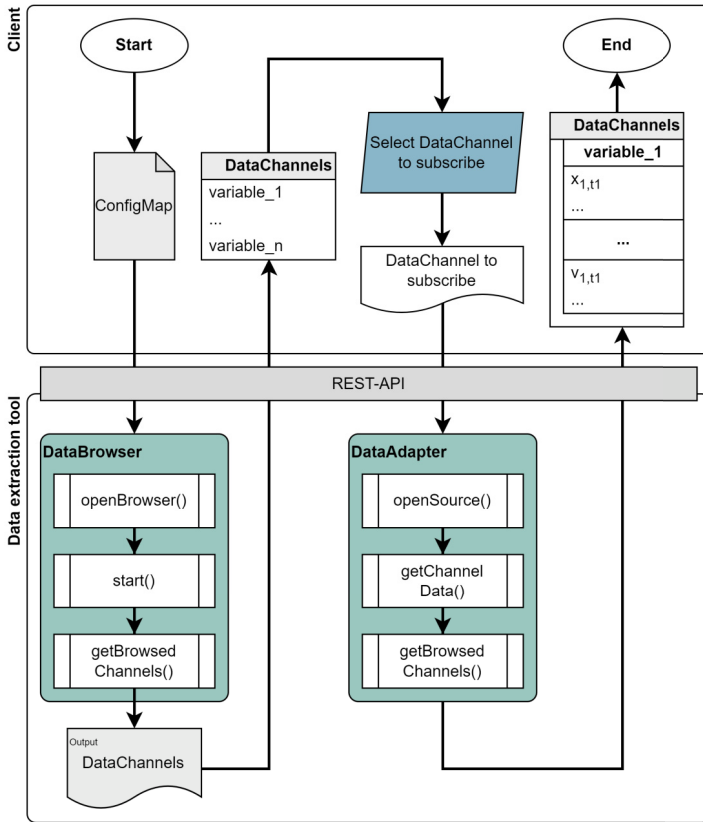


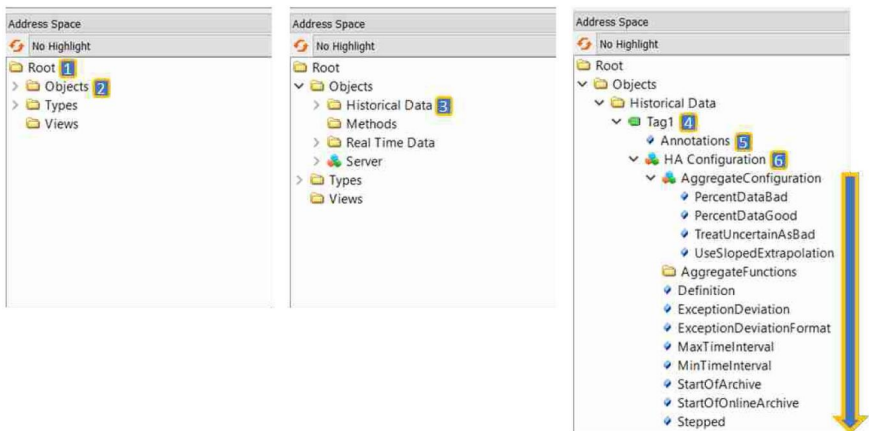
Abbildung 4-4: Chronologischer Ablauf der Methodenaufrufe zur Suche von Signalen und Aufzeichnung der Zeitreihen

4.2.2.5 Datenaufzeichnung

Aufgrund verbauter Werkzeugmaschinenkomponenten unterschiedlicher Hersteller müssen für eine weitreichende Kompatibilität gängige Kommunikationsprotokolle zur Aufzeichnung von Signalen berücksichtigt werden. Dazu gehören OPC UA, OPC DA, MQTT und die direkte Verbindung mit einer SPS. Alternativ gibt es für die Identifikation der Signale, die in Kapitel 5 beschrieben wird, zusätzlich die Option, manuell einen Dateipfad einer CSV-Datei mit den Zeitreihen anzugeben. Nachfolgend wird das

Browsing und das Abonnieren von Variablen am Beispiel eines OPC UA Servers beschrieben.

Nach der start()-Methode sucht der DataBrowser nach Variablen in der Reihenfolge, die in Abbildung 4-5 dargestellt ist. Die Suche dabei erfolgt rekursiv. Dabei werden die Kinder des ersten Objekts bis auf die tiefste Ebene durchsucht. Anschließend werden der nächste Eintrag und dessen Kinder gelesen bis keine weiteren mehr vorhanden sind. Alle gefundenen Attribute, die dem DataChannel entsprechen, werden anschließend übertragen. Attribute, die nicht der Struktur des DataChannel entsprechen, sind für den weiteren Verlauf nicht relevant. Hierdurch kann eine Vorselektion der möglichen Datenknoten vorgenommen werden, da beispielsweise die interessanten Antriebsdaten immer numerische Datentypen aufweisen. String-, Date- oder Boolean-Knoten können also ignoriert werden.



*Abbildung 4-5: OPC UA Hierarchie und Reihenfolge des DataBrowser nach
A_Heider (2021)*

Sind anschließend die zu abonnierenden Signale durch den Anwender ausgewählt, wird die Liste mit den Signalen zurückgegeben und der DataAdapter gestartet. Dieser stellt mit den Parametern URL, Benutzername und Passwort eine Verbindung mit dem OPC UA Server her. Dafür werden die Methoden install() und connect() verwendet, die wiederum auf Java Bibliotheken für die Verbindung zur Datenquelle zugreifen. Die subscribe()-Methode wird mit den Parametern, dem zu abonnierenden Signal und der

Abtastfrequenz aufgerufen und liest in Abhängigkeit davon die Werte aus. Eine nachfolgende sleep()-Methode bestimmt die Aufzeichnungsdauer. Nach dieser wird die unsubscribe()-Methode aufgerufen und die Aufzeichnung wird gestoppt. Eine Übersicht der Methoden des DataAdapter ist in Abbildung 4-6 dargestellt.

```
24 OPCUAClientAdapter DataAdapter = new OPCUAClientAdapter.Builder()
25     .endpointName("opc.tcp://192.168.0.3")
26     .userName("admin")
27     .password("admin")
28     .build();
29
30 DataAdapter.install();
31 DataAdapter.connect();
32
33 DataAdapter.subscribe(DataChannel_1, 100);
34 TimeUtility.sleep(10000);
35 DataAdapter.unsubscribe();
36
37 DataAdapter.read(DataChannel_2);
```

Abbildung 4-6: Aufbau des DataAdapter für OPC UA nach A_Heider (2021)

Die aufgezeichneten Signale werden anschließend als JSON Objekt an den Anwender zurückgegeben und können für weitere Berechnungsschritte verwendet werden.

Damit steht für die weitere Arbeit und die im folgenden Kapitel beschriebene Entwicklung der Identifikationsansätze ein modulares Datenextraktionswerkzeug zur Verfügung, das einfach erweitert werden kann und alle gängigen Kommunikationsschnittstellen in Brownfield-Produktionsumgebungen abdeckt.

5 Identifikation von Maschinensteuerungssignalen

In diesem Kapitel wird das Konzept zur Identifikation von Maschinensteuerungssignalen aus dem Brownfield erläutert. Um möglichst fundierte Entscheidungen treffen zu können, werden zunächst zwei unterschiedliche Ansätze untersucht. Dabei handelt es sich einerseits um einen rein analytischen Ansatz, der ausschließlich auf Datenanalyse, Domänenwissen und Korrelationen zwischen Signalen basiert (White-Box). Aufgrund von kinematischen und physikalischen Zusammenhängen sollen damit Signale differenziert und in Verbindung gebracht werden können. Andererseits wird ein zweiter Ansatz entwickelt, dessen Schwerpunkt auf ML-Verfahren gerichtet ist (Black-Box). In Kapitel 2.4.2 wurde bereits erläutert, dass ML-Modelle aus dem Stand der Forschung und Technik bei der automatisierten Analyse von Zeitreihen sehr gute Ergebnisse erzielen können. Der analytische und der ML-basierte Ansatz werden parallel entwickelt. Aus deren Erkenntnissen wird anschließend in Kapitel 5.4 ein hybrides Modell erarbeitet (Grey-Box). Der chronologische Ablauf ist in Abbildung 5-1 dargestellt.

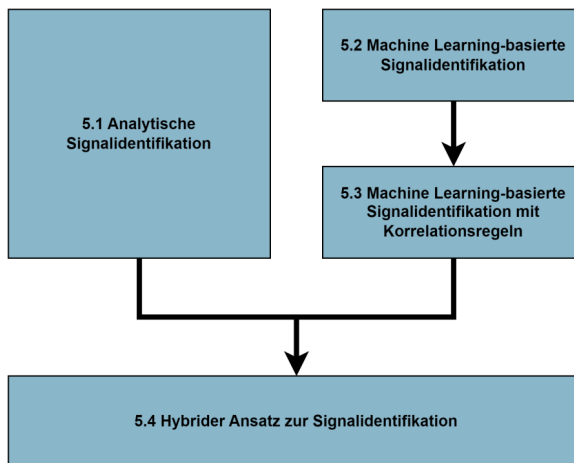


Abbildung 5-1: Chronologischer Ablauf zur Entwicklung des Identifikationssystems

Die Signalidentifikation kann in Abbildung 5-2 in den Kontext des Gesamtprozesses eingeordnet werden. Über die Benutzeroberfläche kann ein Anwender die aufgenommenen Zeitreihen an die Signalidentifikation übergeben und erhält im Anschluss die Ergebnisse als Zuweisungen zu vordefinierten Signalen und Signalgruppen.

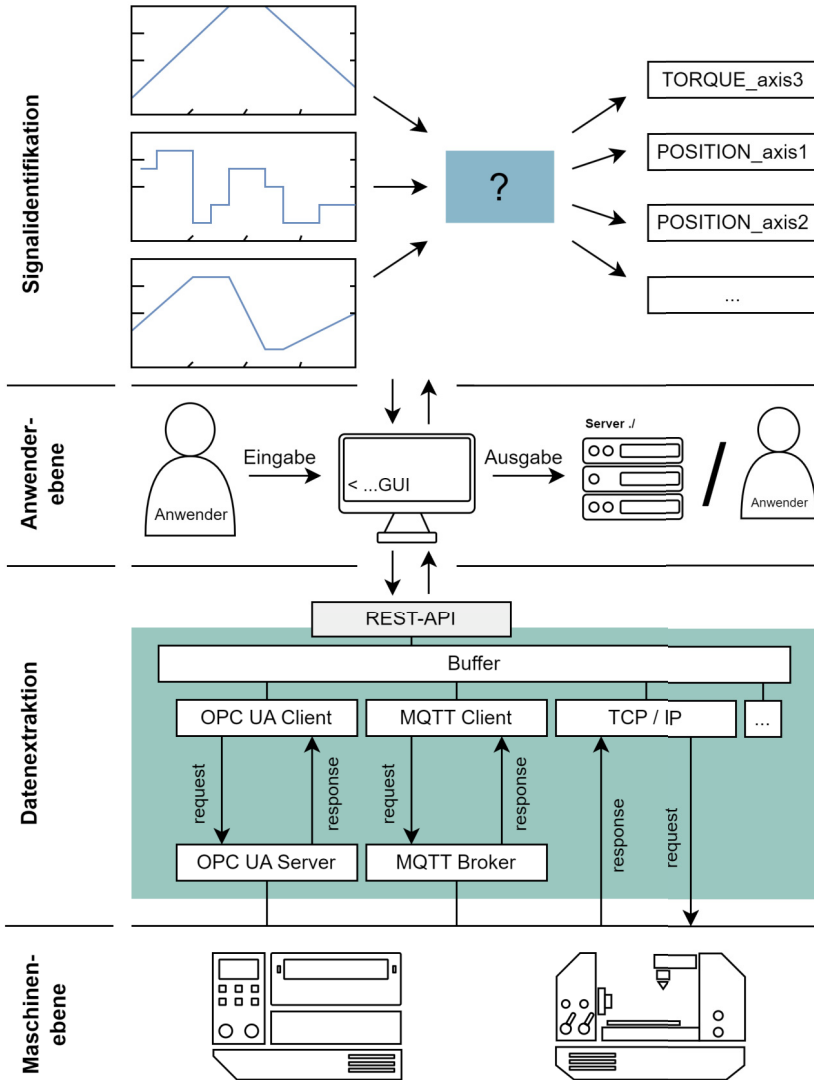


Abbildung 5-2: Einordnung des Ansatzes zur Identifikation von Maschinensteuerungsdaten in Anlehnung an Gönheimer & Ströbel et al. (2023b)

5.1 Analytische Signalidentifikation

In diesem Kapitel werden ein analytischer Ansatz zur Identifikation von Maschinensteuerungssignalen sowie als Grundlage hierfür spezifische Versuchsfahrten entwickelt, die nachfolgend als Referenzfahrten bezeichnet werden. Diese Referenzfahrten basieren auf automatisch erstellten Mustern der Bewegungsabläufe, was bei der Identifikation als Vorteil genutzt werden soll. Die aufgezeichneten Referenzfahrten werden anschließend durch ein sechsstufiges Modell hinsichtlich der enthaltenen Signale analysiert. Dabei werden in jeder Stufe bestimmte Signale identifiziert oder mit weiteren gruppiert. Die eigentliche Analyse basiert auf analytischen Regeln, die durch Domänenwissen entwickelt werden. Zuletzt entsteht ein Informationsmodell, welches aus den jeweiligen Maschinen und deren Achsen besteht, zu denen jeweils identifizierte Signale zugeordnet werden. Der Inhalt dieses Kapitels wurde im Rahmen der angeleiteten Abschlussarbeit (A_Ströbel 2022) erarbeitet. Die Ergebnisse sind zusammenfassend dargestellt.

Im Rahmen dieses Kapitels werden mehrere Regeln zur Identifikation spezifischer Signale und Signaltypen entwickelt. Eine detaillierte Beschreibung erfolgt jedoch nur bei den Regeln, die für den weiteren Verlauf von Kapitel 5 und das in Kapitel 5.4 entwickelte Zielsystem von Bedeutung sind.

5.1.1 Konzept

Zur Einordnung des Gesamtsystems ist in Abbildung 5-3 eine Übersicht dargestellt, die den analytischen Ansatz einordnet. Wichtig ist hierbei die Einordnung der Referenzfahrten in den Gesamtprozess. Diese stellen eine wichtige Grundlage dar und sind damit ein essentieller Teil des Gesamtkonzepts.

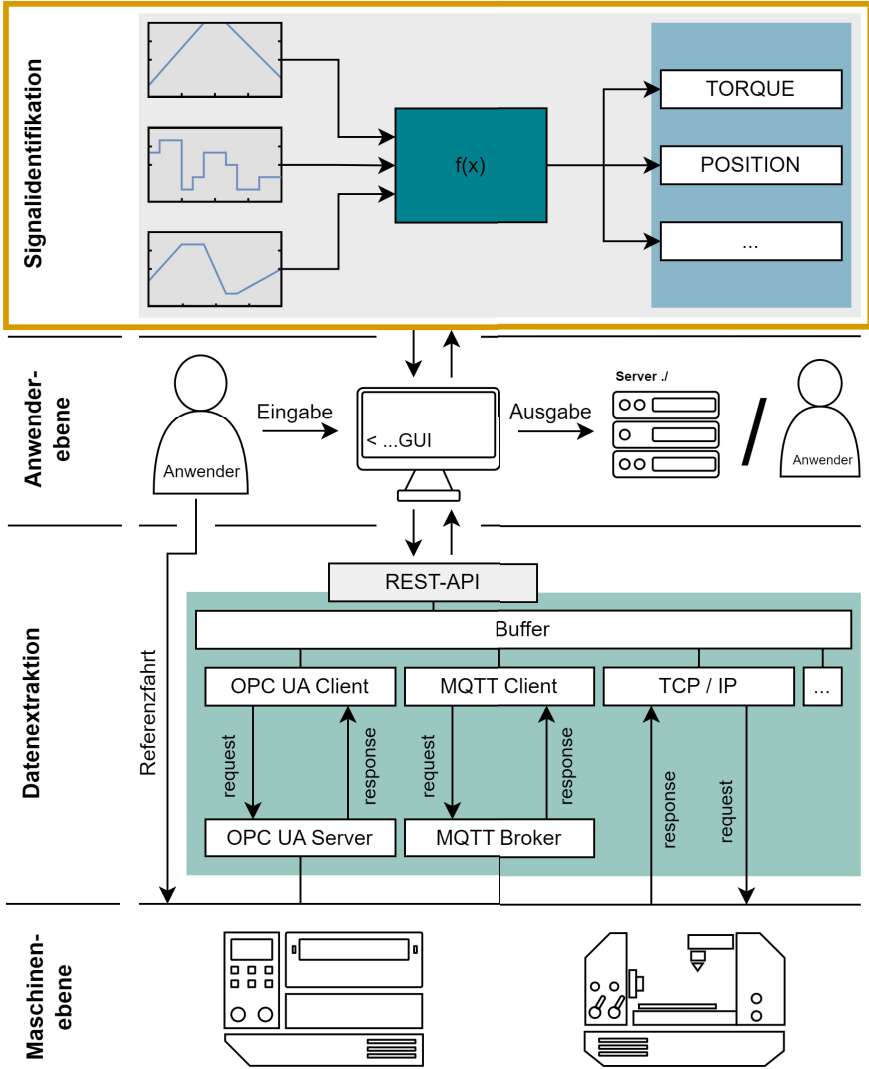


Abbildung 5-3: Einordnung des Ansatzes zur Signalidentifikation durch analytische Regelbasen in Anlehnung an Gönninger & Ströbel et al. (2023b)

Die Basis der Signalidentifikation ist ein in Abbildung 5-4 dargestelltes Informationsmodell, das aus den zwei Ebenen Maschine und Achsen besteht. In diesen Ebenen sind alle Abläufe eingegliedert, die mit der Eingabe von Daten durch einen Anwender beginnen und mit der Ausgabe von gewonnenen Informationen an den Anwender enden.

Die Grundlage wird aus eingearbeiteten Informationen über die Maschine gebildet, welche beispielsweise über Anwendereingaben eingepflegt werden können. Anschließend wird das Informationsmodell generiert, indem ein ID-Generator allen vorhandenen Vorschubachsen und der Spindel jeweils eine individuelle ID zuweist. Eine ID besteht aus einer Kette von Nullen und Einsen, welche letztendlich den Verlauf, beziehungsweise die positive oder negative Steigung einer Bahnkurve bestimmen. Dafür werden aus den Zahlenketten zunächst Stützpunkte generiert und daraus Bahnkurven erstellt. Durch einen G-Code-Generator werden die Bahntrajektorien in ausführbare Programme für die Werkzeugmaschine übersetzt. Die dadurch erzeugten Referenzfahrten werden aufgezeichnet und für die Signalidentifikation verwendet. Auf Basis der erzeugten IDs wird ermöglicht, dass spezifische und bekannte Bahnkurven von den Achsen durchgeführt werden, deren allgemeiner Verlauf anhand der zuvor definierten IDs erkannt werden kann. Somit kann nach den Mustern der eindeutigen IDs in den aufgezeichneten Achsbewegungen gesucht werden. Aufbauend auf den damit generierten Informationen sollen weitere Signale durch Zusammenhänge der Zeitreihen identifiziert und den jeweiligen Achsen zugeordnet werden. Zuletzt werden alle gewonnenen Informationen fusioniert und dem Informationsmodell übergeben, über das der Anwender die Ergebnisse der Signalidentifikation einsehen kann. (Gönnheimer & Hillenbrand et al. 2019; Gönnheimer & Ströbel et al. 2023d; Gönnheimer & Ströbel et al. 2022)

In Abbildung 5-4 sind die Abläufe und die Abhängigkeiten des Informationsmodells dargestellt.

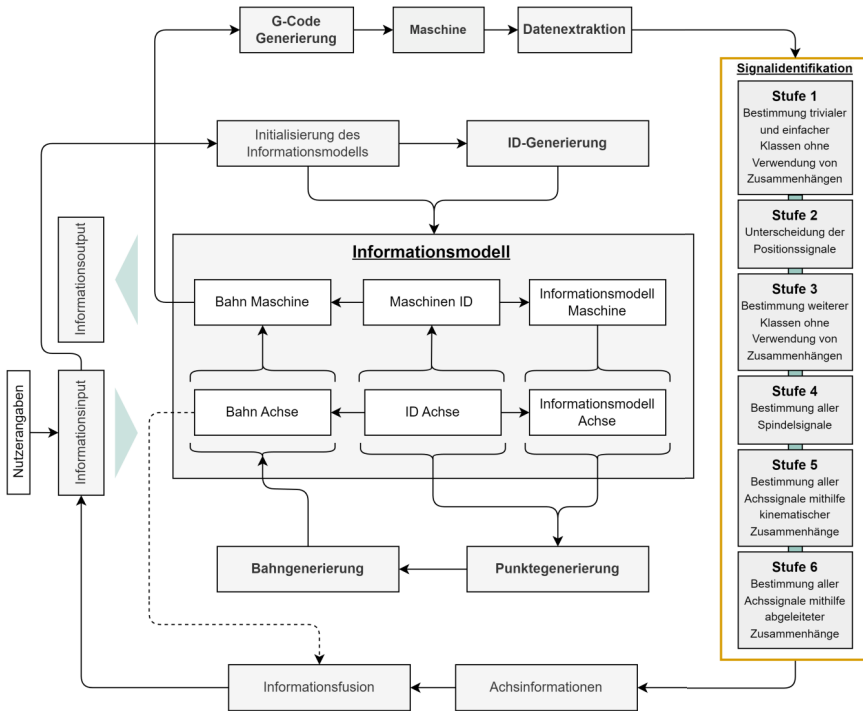


Abbildung 5-4: Darstellung des gesamten Ablaufs zur Identifikation von Maschinensteuerungssignalen nach A_Ströbel (2022)

Da der Schwerpunkt der analytischen Signalidentifikation besonders auf entwickelten Regeln in den Stufen der Signalidentifikation basiert, werden diese in den nachfolgenden Kapiteln erläutert. Dabei werden Signale unter anderem durch kinematische und physikalische Zusammenhänge miteinander in Verbindung gesetzt und kategorisiert. Dazu gehören beispielsweise der Zusammenhang eines Geschwindigkeitssignals und die Ableitung des dazugehörigen Positionssignals. Ein weiteres Beispiel stellt die Berechnung der Regeldifferenz eines Achssignals durch die Subtraktion des Soll- und Istwertes dar. Alternativ umfassen die Regeln in Teilen Bereiche und Grenzwerte, die aus Untersuchungen und Datenanalysen vorgegangen sind. Nachdem die Signale in Form von Zeitreihen vorliegen, werden diese in der ersten Stufe auf einfach zu identifizierende Signale untersucht. Dabei handelt es sich beispielsweise um konstante Zeitreihen, die problemlos identifiziert werden und den Suchraum für die nachfolgenden

Stufen stark verkleinern können. Zusätzlich werden ähnliche Signale mit bestimmten Merkmalen gruppiert. In der zweiten Stufe liegt der Schwerpunkt auf der Unterscheidung von Positionssignalen. In der dritten Stufe werden weitere Signale durch Regelbasen identifiziert und gruppiert, um in den nachfolgenden Stufen Zusammenhänge finden zu können. In der vierten Stufe werden die Spindelsignale analysiert. Durch kinematische Zusammenhänge werden in der fünften Stufe unterschiedliche Signale miteinander verknüpft, um diese zu den jeweiligen Achsen zuordnen zu können, was in Stufe sechs durch weitere analytische Regeln und Zusammenhänge vervollständigt wird.

5.1.2 Datensätze

Die Datensätze für den analytischen Ansatz bilden die Grundlage für die nachfolgenden Stufen zur Identifikation von Maschinensteuerungssignalen. Dafür müssen zunächst notwendige Informationen als Input in das Informationsmodell eingespeist werden. Dazu gehören beispielsweise die Kenntnis über die Art der Maschine, um dafür Steuerprogramme schreiben zu können sowie die Anzahl und Art der Achsen. Für den hier entwickelten Ansatz wird erneut die zuvor beschriebene Deckel Maho DMC 60H-HDM mit einer Siemens Sinumerik 840D-Steuerung verwendet. Die dabei von der Maschine zur Verfügung stehenden und aufgezeichneten Signale sind in Tabelle 1 aufgelistet.

Tabelle 1: Signale und Signaltypen der aufgezeichneten Referenzfahrten auf der Deckel Maho DMC 60H - HDM nach A_Ströbel (2022)

Nr.	Adresse	Beschreibung	Nr.	Adresse	Beschreibung
1	CYCLE		51	LOAD 4	Antriebslast
2	A_DBD 2000		52	LOAD 5	Antriebslast
3	A_DBD 2004		53	LOAD 6	Antriebslast
4	A_DBD 2008		54	ENC2_POS 1	Ist-Position direkt
5	A_DBD 2012		55	ENC2_POS 2	Ist-Position direkt
6	A_DBD 2016		56	ENC2_POS 3	Ist-Position direkt
7	A_DBD 2020		57	ENC2_POS 4	Ist-Position direkt
8	A_DBR 2048		58	ENC2_POS 5	Ist-Position direkt
9	A_DBR 2052		59	ENC1_POS 1	Ist-Position indirekt
10	A_DBR 2056		60	ENC1_POS 2	Ist-Position indirekt
11	A_DLD 20		61	ENC1_POS 3	Ist-Position indirekt
12	A_DLD 24		62	ENC1_POS 4	Ist-Position indirekt
13	A_DLD 28		63	ENC1_POS 5	Ist-Position indirekt
14	A_DLR 16		64	ENC1_POS 6	Ist-Position indirekt
15	A_DLR 20		65	CURRENT 1	Motorstrom
16	A_DLR 24		66	CURRENT 2	Motorstrom
17	TORQUE_FFW 1	Soll-Drehmoment Vorschub	67	CURRENT 3	Motorstrom
18	TORQUE_FFW 2	Soll-Drehmoment Vorschub	68	CURRENT 4	Motorstrom
19	TORQUE_FFW 3	Soll-Drehmoment Vorschub	69	CURRENT 5	Motorstrom
20	TORQUE_FFW 4	Soll-Drehmoment Vorschub	70	CURRENT 6	Motorstrom
21	TORQUE_FFW 5	Soll-Drehmoment Vorschub	71	CTRL_DIFF 2 1	Regeldiff. Mit f(Temp.)
22	TORQUE_FFW 6	Soll-Drehmoment Vorschub	72	CTRL_DIFF 2 2	Regeldiff. Mit f(Temp.)
23	VEL_FFW 1	Geschwindigkeitsvorschub an Regler	73	CTRL_DIFF 2 3	Regeldiff. Mit f(Temp.)
24	VEL_FFW 2	Geschwindigkeitsvorschub an Regler	74	CTRL_DIFF 2 4	Regeldiff. Mit f(Temp.)
25	VEL_FFW 3	Geschwindigkeitsvorschub an Regler	75	CTRL_DIFF 2 5	Regeldiff. Mit f(Temp.)
26	VEL_FFW 4	Geschwindigkeitsvorschub an Regler	76	CTRL_DIFF 2 6	Regeldiff. Mit f(Temp.)
27	VEL_FFW 5	Geschwindigkeitsvorschub an Regler	77	CTRL_DIFF 1	Regeldifferenz
28	VEL_FFW 6	Geschwindigkeitsvorschub an Regler	78	CTRL_DIFF 2	Regeldifferenz
29	CONT_DEV 1	Regeldifferenz	79	CTRL_DIFF 3	Regeldifferenz
30	CONT_DEV 2	Regeldifferenz	80	CTRL_DIFF 4	Regeldifferenz
31	CONT_DEV 3	Regeldifferenz	81	CTRL_DIFF 5	Regeldifferenz
32	CONT_DEV 4	Regeldifferenz	82	CTRL_DIFF 6	Regeldifferenz
33	CTRL_POS 1	Soll-Position Eingang Lageregler	83	CMD_SPEED 1	Soll-Geschwindigkeit
34	CTRL_POS 2	Soll-Position Eingang Lageregler	84	CMD_SPEED 2	Soll-Geschwindigkeit
35	CTRL_POS 3	Soll-Position Eingang Lageregler	85	CMD_SPEED 3	Soll-Geschwindigkeit
36	CTRL_POS 4	Soll-Position Eingang Lageregler	86	CMD_SPEED 4	Soll-Geschwindigkeit
37	TORQUE 1	Soll-Drehmoment	87	CMD_SPEED 5	Soll-Geschwindigkeit
38	TORQUE 2	Soll-Drehmoment	88	CMD_SPEED 6	Soll-Geschwindigkeit
39	TORQUE 3	Soll-Drehmoment	89	DES_POS 1	Soll-Position nach Feininterpolator
40	TORQUE 4	Soll-Drehmoment	90	DES_POS 2	Soll-Position nach Feininterpolator
41	TORQUE 5	Soll-Drehmoment	91	DES_POS 3	Soll-Position nach Feininterpolator
42	TORQUE 6	Soll-Drehmoment	92	DES_POS 4	Soll-Position nach Feininterpolator
43	POWER 1	Antriebsleistung	93	DES_POS 5	Soll-Position nach Feininterpolator
44	POWER 2	Antriebsleistung	94	DES_POS 6	Soll-Position nach Feininterpolator
45	POWER 3	Antriebsleistung	95	ENC_POS 1	Ist-Position
46	POWER 4	Antriebsleistung	96	ENC_POS 2	Ist-Position
47	POWER 5	Antriebsleistung	97	ENC_POS 3	Ist-Position
48	LOAD 1	Antriebslast	98	ENC_POS 4	Ist-Position
49	LOAD 2	Antriebslast	99	ENC_POS 5	Ist-Position
50	LOAD 3	Antriebslast	100	ENC_POS 6	Ist-Position

In einem ersten Schritt werden über einen ID-Generator für alle Achsen IDs erstellt, die sich alle voneinander unterscheiden. Die IDs bestehen aus einer binären Zahlenabfolge und beschreiben den Verlauf einer Kurve. Von einem Referenzpunkt aus werden die jeweiligen Ziffern äquidistant verteilt, wobei eine „1“ bedeutet, dass der zu setzende Stützpunkt höher als der vorherige ist. Umgekehrt bedeutet eine „0“, dass der zu setzende Stützpunkt tiefer ist als der vorherige. Die relative Distanz der Stützpunkte wird durch unterschiedliche Wahrscheinlichkeitsfunktionen bestimmt. Dabei werden die Exponentialverteilung, die Lognormalverteilung und die Gammaverteilung verwendet. Nach der Stützpunktgenerierung werden für jede ID die Bahnkurven bestimmt. Für diese können verschiedene Interpolationsarten verwendet werden, unter anderem Polynominterpolation, lineare B-Splines, quadratische B-Splines, kubische B-Splines, Akima-Splines und PCHIP. Bei der Spindel werden aufgrund einer erhöhten Rechenzeit die Stützpunkte als abschnittsweise konstante Drehzahlen festgelegt. Abbildung 5-5 zeigt eine Bahnkurve mit der ID 101101000111. Nach der Generierung der IDs als Bahnkurven werden diese durch einen G-Code-Generator in ausführbare Programme übersetzt, welche anschließend mit der Deckel Maho DMC 60H-HDM durchgeführt und aufgezeichnet werden. Die aufgezeichneten Datensätze mit dem Wissen über die darin enthaltenen Bahnkurvenverläufe sind die Grundlage für den analytischen Ansatz.




Abbildung 5-5: Beispiel der Achsbewegung mit der ID = 101101000111 nach A_Ströbel (2022)

Bei der Generierung der Referenzfahrten konnte festgestellt werden, dass der geforderte Bewegungsablauf und der tatsächliche Ablauf nicht identisch, sondern in der Zeitdomäne leicht verzerrt waren. Dies hängt damit zusammen, dass die erstellten Bahnkurven in Abhängigkeit der Zeit sind, wohingegen Werkzeugmaschinen bezüglich des Ortes interpolieren, um Konturabweichungen gering zu halten. Für den nachfolgenden Ansatz ist es jedoch maßgebend, dass der geforderte Bewegungsablauf

eingehalten wird. Deshalb wurden unterschiedliche Versuche durchgeführt, um die zeitliche Verzerrung zu minimieren. Dabei wurde unter anderem die Anzahl der G-Code-Sätze, die Spindeldrehzahl, die Interpolation der generierten Stützpunkte der Achsen sowie der Einfluss der Bremsrampe (BRK) untersucht. Es konnte festgestellt werden, dass der Zeitpunkt des Beginns der Bremsrampe einen besonderen Einfluss auf die Bewegungskurve hat. Abhängig davon kann ein Schwingungszustand eingestellt werden, welcher sich in den Positions-, Strom-, Drehmoment- und Regeldifferenzsignalen auffinden lässt. Dadurch lässt sich ein besonders hoher Informationsgehalt in den Bewegungsabläufen aufzeichnen, was später die Identifikation der einzelnen Signale begünstigen soll. Die Ursache für den Schwingungszustand liegt darin, dass der Achsantrieb durch einen Satzwechsel zu bremsen beginnt, dieser jedoch erst von der NCU berechnet werden muss. Daraufhin bremst die Achse ab, bis eine Beschleunigung durch den nächsten Satz gefordert wird. Dies führt dazu, dass das Achssystem schwingt. Allerdings kann dies nur durch BRK0 zuverlässig erzwungen werden und tritt mit einer späteren Bremsrampe weniger häufig auf, bis es bei BRK100 nicht mehr zuverlässig funktioniert. Für die zeitliche Verzerrung wurde nach Untersuchungen eine Anzahl an Sätzen von 250 festgelegt. Zusätzlich wird die Spindeldrehzahl abschnittsweise konstant gehalten (SC) und die Interpolation erfolgt durch den Achsinterpolator AIP.

5.1.3 Stufe 1 – Filterung trivialer Klassen

In der ersten Stufe werden zunächst einfach zu identifizierende Signale der vorliegenden Zeitreihen extrahiert, um den Datensatz für die nächsten Schritte zu reduzieren. Dies hat insbesondere große Vorteile für eine Verkürzung der Rechenzeiten. Die Signale der Klassen **NULL**, **BIN**, **NAN**, **CONST** und **CYCLE** werden in den ersten Teilschritten extrahiert und sind damit bereits in ihrer finalen Klasse zugeordnet. Anschließend werden weitere Zeitreihen für die übergeordneten Klassen von translatorischen Positionssignalen, rotatorischen Positionssignalen, Geschwindigkeitssignalen der Spindel sowie Positionssignale der Spindel gruppiert. Der Vorteil der Vorsortierung in Gruppen liegt darin, dass in den nachfolgenden Schritten nicht erneut alle existierenden Zeitreihen mehrfach überprüft werden müssen, sondern abhängig von der Analyse auf bestehende Signalgruppen zugegriffen werden kann. Auch dadurch kann die Rechenzeit nochmals verringert werden. In Abbildung 5-6 ist der

chronologische Ablauf der jeweiligen Teilschritte dargestellt. Anschließend wird auf die entwickelten Regelbasen eingegangen.

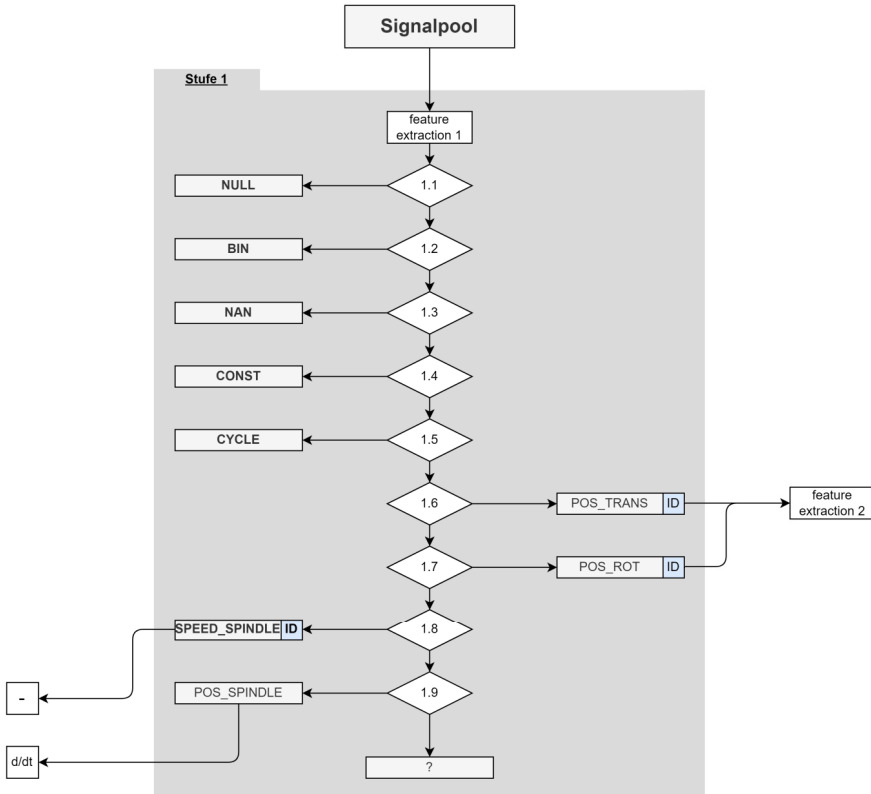


Abbildung 5-6: Identifikation von Maschinensteuerungssignalen in Stufe 1 mit den Regeln 1.1 bis 1.9 nach A_ Ströbel (2022)

Regel 1.1 – Identifikation von Null-Signalen

Besitzen alle Werte den Wert „0“, wird das Signal der Klasse **NULL** zugeordnet.

Regel 1.2 – Identifikation von binären Signalen

Existieren nur die Werte „0“ und „1“, liegt die Klasse **BIN** vor.

Regel 1.3 – Identifikation von NAN-Einträgen

Falls alle Werte der Zeitreihe nur den Wert „None“ aufweisen, wird das Signal der Klasse **NAN** zugewiesen.

Regel 1.4 – Identifikation von konstanten Zeitreihen

Signale mit konstanten Werten, die gegebenenfalls mit leichtem Rauschen überlagert sind, gehören der Klasse **CONST** an. Dazu gehören unter anderem auch Signale, die durch einen Sensor aufgezeichnet werden, der keine Änderung detektiert. Hierfür wird auf die dritte Nachkommastelle gerundet und überprüft, ob alle Abtastzeitpunkte den gleichen Wert besitzen.

Regel 1.5 – Identifikation von zyklischen Zeitreihen

Bei der verwendeten SINUMERIK Steuerung erhöht sich das CYCLE-Signal bei jedem Abtastschritt um „1“. Die Prüfung, ob ein Signal deshalb der Klasse **CYCLE** zugeordnet wird, erfolgt durch die Ableitung des Signals und den Vergleich der Werte mit „1“. Haben 99,9 % der Werte eine „1“, wird das Signal als zyklisch gewertet. Durch die Toleranz von 0,1 % soll die Robustheit auf störbehafteten Signalaufzeichnungen erhöht werden.

Regel 1.6 – Identifikation der translatorischen Achssignale

Aufgrund des vorgegebenen Verfahrbereichs der Achsen auf 10 mm können alle Signale mit einem Wertebereich kleiner als 9,9 mm oder größer als 10,1 mm entfernt werden. Durch die Toleranz werden Messunsicherheiten berücksichtigt. Zusätzlich wird der Mittelwert berechnet, welcher größer als $0,52 * 10$ sein muss. Signale, die diese Kriterien erfüllen, werden der Klasse **POS_TRANS|ID** zugeordnet.

Regel 1.7 – Identifikation rotatorischer Achssignale

Wie auch bei Regel 1.6 sind für die rotatorischen Achsen die Verfahrbereiche vorgegeben, wodurch diese zwischen 1,9 und 2,1 liegen müssen. Zusätzlich muss der Mittelwert größer als $0,52 * 2$ sein. In diesem Fall werden die Signale der Klasse **POS_ROT|ID** zugeordnet.

Regel 1.8 – Identifikation der Geschwindigkeitssignale der Spindel

Durch die Vorgabe von temporär konstanten Geschwindigkeiten der Spindel können diese Signale durch die dadurch entstehende Charakteristik erkannt werden. Durch den Wertebereich der Spindel von 200 liegt dessen Mittelwert bereits deutlich über dem der anderen Signale. Zusätzlich ist die Anzahl an Nulleinträgen der ersten Ableitung durch

die konstanten Phasen deutlich erhöht, weshalb durch diese beiden Merkmale die Spindelsignale der Klasse **SPEED_SPINDLE|ID** zugeordnet werden können.

Regel 1.9 – Identifikation von Positionssignalen der Spindel

Durch die Vorgabe einer stets positiven Drehzahl ohne Pausen muss der Wertebereich der Positionssignale der Spindel zwangsweise steigen. Dadurch ergibt sich ein wesentlich höherer Wertebereich dieser Signale, welcher sich stark von den anderen Signalen unterscheidet. Zusätzlich muss bei einer konstanten Geschwindigkeit die Ableitung von Positionssignalen immer größer als Null sein, weshalb dies als zweites Merkmal verwendet wird. Signale, die diese Kriterien erfüllen, werden der Klasse **POS_SPINDLE** zugeordnet.

Die translatorischen und rotatorischen Positionssignale der Achsen sowie die Geschwindigkeitssignale der Spindel werden mit den Regeln 1.6, 1.7, 1.8 und 1.9 identifiziert. Dafür werden unter anderem Mittelwerte, Wertebereiche und die Anzahl an Nullstellen genutzt, um die Zielklasse zu bestimmen. Dies wird durch die zuvor festgelegten Informationen im Modell ermöglicht. Das Positionssignal der Spindel kann durch die Werte der Ableitung und den Wertebereich bestimmt werden, da dieser aufgrund der sich immer in eine Richtung bewegenden Spindel sehr hohe Werte annimmt. Bei den Regeln 1.6, 1.7 und 1.8 wird zusätzlich noch die ID über deren Signalverlauf bestimmt, worauf die Signale in die Klassen **POS_TRANS|ID**, **POS_ROT|ID** und **SPEED_SPINDLE|ID** zugeordnet werden.

Alle verbleibenden Signale werden in die Klasse **REST** zugeordnet und in nachfolgenden Stufen analysiert.

5.1.4 Stufe 2 – Extraktion der Positionssignale

Die Aufteilung der in Stufe 1 identifizierten translatorischen und rotatorischen Positionssignale aller Achsen erfolgt in Stufe 2 in die Klassen **DES_POS|ID**, **CTRL_POS|ID**, **ENC1_POS|ID** und **ENC2_POS|ID**. Alle verbleibenden Signale werden der Klasse **UNKNOWN** zugewiesen. In Abbildung 5-7 ist der Ablauf der Stufe 2 im Detail dargestellt.

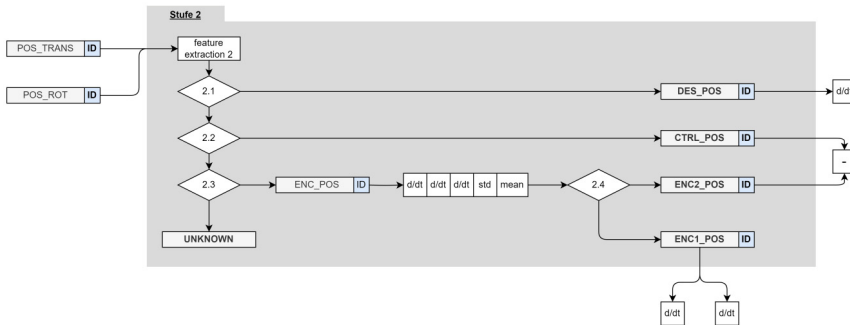


Abbildung 5-7: Identifikation von Maschinensteuerungssignalen in Stufe 2 nach A_Ströbel (2022)

Durch die spezifisch erstellten Referenzfahrten entstehen charakteristische Merkmale zur Unterscheidung der Positionssignale zu Beginn und am Ende der Aufzeichnung. Zusätzlich können durch Domänenwissen weitere grundlegende Zusammenhänge der Signale erkannt werden. Das DES_POS|ID-Signal wird mit Regel 2.1 identifiziert. Dieses wird im Feininterpolator zunächst durch Filter und Operationen modifiziert, bevor es dem Lageregler als CTRL_POS|ID-Signal zugeführt wird. Aufgrund der Berechnungen entsteht zu Beginn und Ende der Aufzeichnung ein kleiner zeitlicher Verzug des CTRL_POS|ID-Signals. Dadurch kann bei der Betrachtung der beiden Zeitbereiche das vorauseilende DES_POS|ID-Signal von dem CTRL_POS|ID-Signal unterschieden werden, was in Regel 2.2 untersucht wird. Die Signale in der Klasse ENC_POS|ID werden mit Regel 2.3 untersucht. Die Aufteilung der Klasse wird durch kinematische Zusammenhänge der Signaltypen durchgeführt. Da es sich bei ENC2_POS um eine indirekte und bei ENC1_POS um eine direkte Positionsmessung handelt und beide dem CTRL_POS-Signal folgen, kann durch die Betrachtung der dritten Eigenschwingungsform eine Unterscheidung der Signale folgen. Nach der dritten Ableitung, der Normierung und einer gleitenden Standardabweichung der Signale kann festgestellt werden, dass der Mittelwert der ENC2_POS-Signale immer höher ist als der der ENC1_POS-Signale. Für den Fall, dass weitere ENC_POS-Signale existieren, wird die Mitte des maximalen und minimalen Mittelwertes der Signale berechnet. Alle über diesem Wert liegenden Signale werden der Klasse ENC2_POS|ID zugeordnet, alle darunterliegenden der Klasse ENC1_POS|ID.

Befinden sich nach der Anwendung der Regelbasen noch Signale in den Klassen **POS_TRANS|ID** und **POS_ROT|ID**, werden diese in die Klasse **UNKNOWN** verschoben.

5.1.5 Stufe 3 – Bestimmung weiterer Signale durch regelbasierte Klassifikation

In der dritten Stufe werden Signale auf die Zugehörigkeit für die Klassen **POWER**, **VEL_FFWD**, **CTRL_DIFF** und **SPINDLE_REST** untersucht. Dafür werden die Signale der Klasse **REST** aus Stufe 1 betrachtet, welche bisher keiner Klasse zugeordnet werden konnten. In Abbildung 5-8 ist der Ablauf der Stufe 3 im Detail beschrieben.

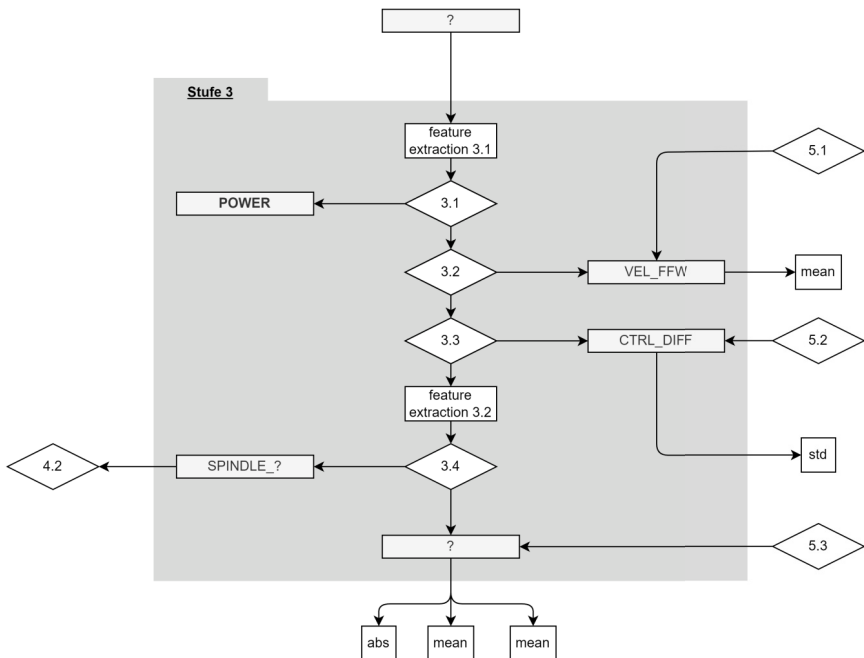


Abbildung 5-8: Identifikation von Maschinensteuerungssignalen in Stufe 3 nach A_Ströbel (2022)

In Abbildung 5-9 sind die Verläufe eines **POWER**- und eines **VEL_FFWD**-Signals dargestellt. Dabei fällt besonders der große Anteil ein Nullwerten auf. Um die beiden Signale

zu identifizieren, werden dieses Merkmal und der Wertebereich der zweiten Ableitung genutzt. Dadurch können diese eindeutig von den restlichen Signalen unterschieden werden.




Abbildung 5-9: Verlauf eines POWER- und VEL_FF1 Signals der DMC 60H-HDM nach A_Ströbel (2022)

Regel 3.1 - Identifikation der POWER Signale

In Abbildung 5-10 sind die Merkmale für die Signale einer Aufzeichnung berechnet und graphisch dargestellt, wodurch sich die unterschiedlichen Signaltypen differenzieren lassen. Für die Identifikation der POWER-Signale müssen 10 % der Einträge 0 sein, der Wertebereich der zweiten Ableitung ist kleiner als 30. Zusätzlich muss dieser entweder größer 1 sein oder es müssen mehr als 50 % der Einträge 0 sein.




Abbildung 5-10: Extraktion der VEL_FFW- und POWER-Signale aus den verbleibenden Zeitreihen nach A_ Ströbel (2022)

Regel 3.2 – Identifikation von Geschwindigkeitssignalen

Nach einer Signalanalyse konnte festgestellt werden, dass nur die Geschwindigkeitssignale einen prozentualen Anteil an Nullstellen von 3 % bis 45 % haben und gleichzeitig der Wertebereich der zweiten Ableitung zwischen 0,1 und 0,5 liegt

Regel 3.3 – Identifikation von Regeldifferenzsignalen

Bei Regeldifferenzen sind vor allem kleine Wertebereiche charakteristisch. Deshalb lassen sich diese durch den Wertebereich von 0,5 und den Betrag des Mittelwerts, welcher kleiner als 0,001 sein muss, identifizieren.

Regel 3.4 – Identifikation von Spindelsignalen

Zur Identifikation von Spindelsignalen wird das typische Merkmal der häufig konstanten Drehzahl einer Spindel genutzt. Das erste Merkmal beschreibt den prozentualen Anteil der Werte der ersten Ableitung, die um den Mittelwert verschoben sind und unterhalb von -0,1 und oberhalb von 0,1 liegen. Dies basiert auf der Tatsache, dass durch die Vorgabe der häufig konstanten Spindelbewegung immer nur sprunghafte Anstiege möglich sind, weshalb auch Änderungen von Strom und Drehmoment nur bei diesen spezifischen Ereignissen auftreten. Ein weiteres Merkmal wird durch das Verhältnis vom Wertebereich der zweiten Ableitung und der Standardabweichung beschrieben.

Die zweite Ableitung verstärkt die sprunghaften Anstiege nochmals, wobei gleichzeitig die Standardabweichung sinkt. Deshalb muss dieses Merkmal bei den Spindelsignalen besonders hohe Werte annehmen. Nach einer Untersuchung der Zeitreihen konnte ein Grenzbereich zwischen 20 und 60 festgelegt werden.

5.1.6 Stufe 4 – Identifikation von Spindelsignalen

In der vierten Stufe werden die Spindelsignale untersucht. Dafür werden zunächst die Soll- und Ist-Positionen identifiziert. Anschließend werden die Signale der Klasse **SPINDLE_REST** in Strom, Drehmoment und Last aufgeteilt. In Abbildung 5-11 ist der detaillierte Ablauf der Signalidentifikation in Stufe 4 dargestellt.

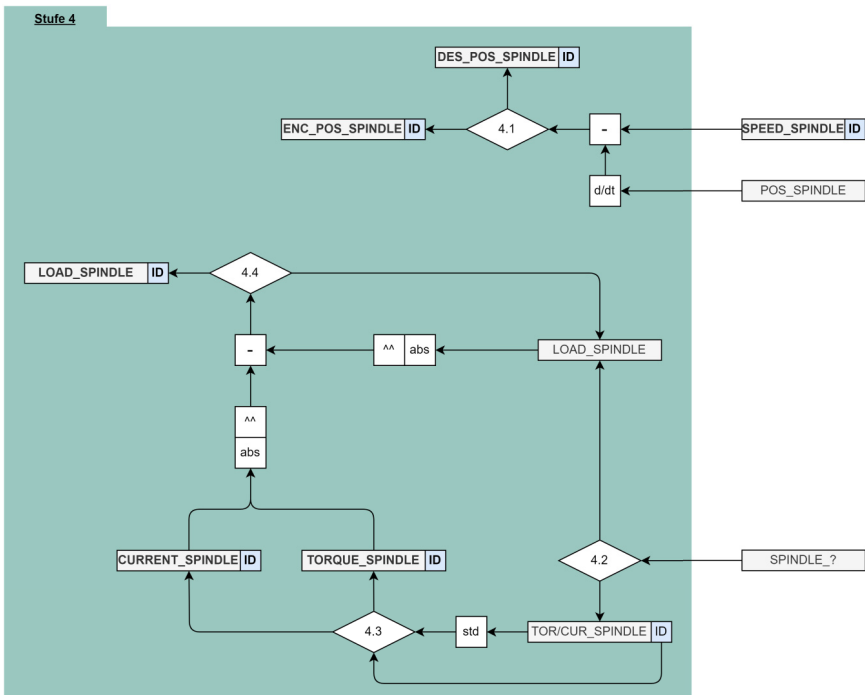


Abbildung 5-11: Identifikation von Maschinensteuerungssignalen in Stufe 4 nach A_Ströbel (2022)

Regel 4.1 – Unterscheidung der Spindelsignale in DES_POS_SPINDLE und ENC_POS_SPINDLE

Durch die Ableitung und Normierung der Signale aus **POS_SPINDLE** kann jeweils die Distanz zu den normierten Geschwindigkeitssignalen berechnet werden. Ist die Distanz kleiner als 10^{-10} , wird das Signal als DES_POS_SPINDLE|ID identifiziert. Ist sie kleiner als 0,05, wird es als ENC_POS_SPINDLE|ID-Signal deklariert.

Regel 4.2 – Identifikation der Last-Signale

Zur Klassifizierung der Last-Signale wird die Besonderheit genutzt, dass die Werte nicht kleiner als 0 werden können, da die Last prozentual ausgegeben wird. Liegt der prozentuale Anteil an Werten, welche größer als 0 sind, bei 99 %, werden die Zeitreihen der Klasse **LOAD_SPINDLE** zugeordnet. Der Verlauf eines Lastsignals ist in Abbildung 5-12 dargestellt. Alle noch verbleibenden Signale werden zunächst auf deren ID überprüft, um sie anschließend in die Klasse **CUR/TOR_SPINDLE|ID** zuordnen zu können. Dabei wird untersucht, in welcher Reihenfolge Maxima und Minima in den Zeitreihen vorkommen. Ein Maximum ergibt eine 1, ein Minimum eine 0, wodurch sich die ID des Signals bestimmen lässt.




Abbildung 5-12: Verlauf des Lastsignals der Spindel nach A_Ströbel (2022)

Regel 4.3 – Identifikation von Strom und Drehmoment

Zur Bestimmung der Strom- und Drehmomentsignale werden die Zeitreihen normiert und anschließend die gleitende Standardabweichung und der gleitende Mittelwert berechnet. In Abbildung 5-13 sind die Mittelwerte der Signale graphisch dargestellt. Es zeigt sich, dass der Mittelwert der Drehmomentsignale immer größer ist als der der

Stromsignale. Aus allen Signalen wird nun jeweils der Mittelwert berechnet und anschließend daraus der Mittelwert des größten und kleinsten vorkommenden Mittelwerts. Dieser wird als Grenzwert verwendet, über den die Strom- und Drehmomentsignale differenziert werden. Alle Signale, deren Mittelwert größer als der Grenzwert ist, werden der Klasse **TORQUE_SPINDLEID** zugeordnet, alle darunterliegenden der Klasse **CURRENT_SPINDLEID**.




Abbildung 5-13: Modifikation der Zeitreihen. Gleitende Standardabweichung, Normierung und Berechnung des Mittelwerts von Strom- und Drehmomentsignalen von Signalpaaren nach A_Ströbel (2022)

Um die Last-Signale aus der Klasse **LOAD_SPINDLE** der passenden ID zuordnen zu können, wird mit Regel 4.4 ein Distanzmaß berechnet, welches auf den relativen Positionen der Peaks basiert. Wird ein bestimmter Schwellenwert nicht überschritten, ist ein Paar aus Strom, Drehmoment und Last gefunden.

5.1.7 Stufe 5 – Kinematische Zusammenhänge

In der fünften Stufe werden Abhängigkeiten der Signale untersucht, um sie miteinander zu verknüpfen und einer Achse zuordnen zu können. Durch kinematische Zusammenhänge werden die Signale aus den Klassen **VEL_FFWD**, **CTRL_DIFF** und **CMD_SPEED** mit den Positionssignalen analysiert. In Abbildung 5-14 ist der detaillierte Ablauf der fünften Stufe dargestellt.

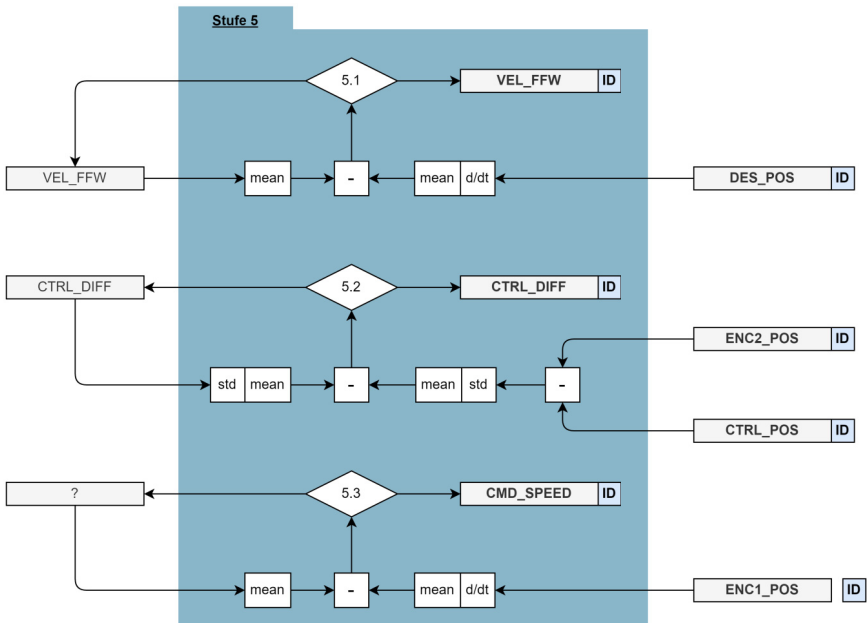


Abbildung 5-14: Identifikation von Maschinensteuerungssignalen in Stufe 5 nach A_Ströbel (2022)

Regel 5.1 – Identifikation der Geschwindigkeitssignale VEL_FFW

Über den kinematischen Zusammenhang $\frac{d}{dt} (DES_POS) \sim VEL_FFW$ lassen sich die Geschwindigkeitssignale der jeweiligen Achse zuordnen. Dabei wird zunächst der gleitende Mittelwert berechnet und die Zeitreihe anschließend normiert. Für die abschließende Zuweisung der Geschwindigkeitssignale wird die euklidische Distanz zu den DES_POS-Signalen berechnet, welche unter 0,01 liegen muss, um einer Achse zugewiesen werden zu können.

Regel 5.2 – Identifikation der Regeldifferenzsignale CTRL_DIFF

Für die Achszuweisung der CTRL_DIFF-Signale werden das Eingangssignal CTRL_POS des Lagereglers sowie die direkte Position des ENC2_POS-Signals benötigt. Da sich aus der Differenz beider Signale die Regelabweichung feststellen lässt,

stellt dies einen vielversprechenden Ansatz dar. Daraus folgt der Zusammenhang $CTRL_DIFF \sim CTRL_POS - ENC2_POS$. Bei jedem Signal werden zunächst die gleitende Standardabweichung und der gleitende Mittelwert berechnet. Anschließend werden die Zeitreihen normiert und die Positionssignale voneinander subtrahiert. Aus der daraus resultierenden Zeitreihe wird die euklidische Distanz mit dem normierten Regeldifferenzsignal berechnet, welche im Falle einer Zuordnung kleiner als 0,025 sein muss. In Abbildung 5-15 sind die Signale nach der Anwendung der gleitenden Standardabweichung und nach einem zusätzlichen gleitenden Mittelwert dargestellt.




Abbildung 5-15: Detailansicht der Analyse von Regeldifferenzsignalen durch eine gleitende Standardabweichung (oben) und einem zusätzlichen gleitenden Mittelwert (unten) nach A_Ströbel (2022)

Regel 5.3 – Identifikation der Geschwindigkeitssignale CMD_SPEED

Für die Identifikation der CMD_SPEED-Signale, welche bisher in Klasse **REST** vorzufinden sind, wird der Zusammenhang $CMD_SPEED \sim \frac{d}{dt} (ENC1_POS)$ verwendet. Dafür werden die Zeitreihen zunächst mit dem gleitenden Mittelwert geglättet und anschließend normiert, bevor die euklidischen Distanzen zu ENC1_POS-Signalen berechnet werden. Im Falle einer Zuordnung muss diese kleiner als 0,15 sein.

5.1.8 Stufe 6 – Signalgruppierung der Achsen

In der sechsten Stufe werden abgeleitete Zusammenhänge zwischen den Signalen genutzt, um Strom, Drehmoment und Last der jeweiligen Achsen identifizieren zu können. Falls Signale nicht eindeutig identifiziert werden können, werden diese anhand spezifischer Merkmale der Klasse **NOISE** zugewiesen und falls nichtzutreffend, der Klasse **UNKNOWN**. In Abbildung 5-16 ist der Ablauf der sechsten Stufe dargestellt.

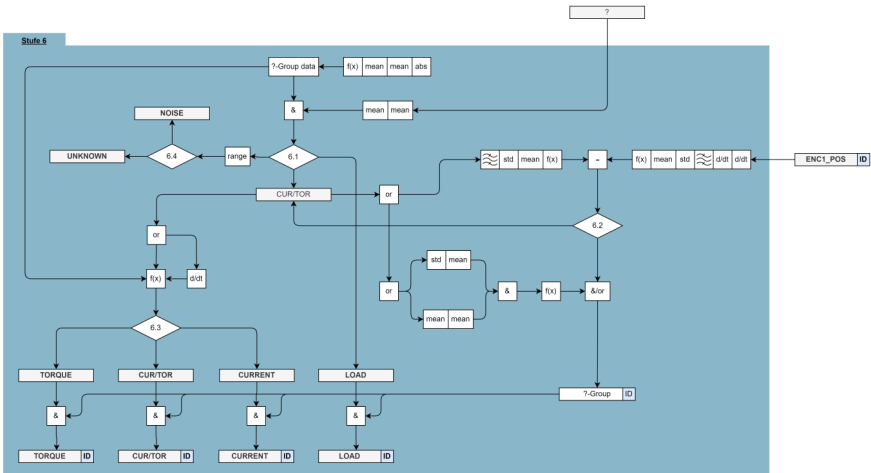


Abbildung 5-16: Identifikation von Maschinensteuerungssignalen in Stufe 6 nach A_Ströbel (2022)

Um die Klassifikationsgenauigkeit zu erhöhen, werden zunächst Unterschiede zwischen den Signalen herausgearbeitet, damit die Signale in die Klassen **CURRENT**, **TORQUE** und **LOAD** zugeordnet werden können. Dafür wird die Betragsfunktion auf jede Zeitreihe der Klasse **REST** angewendet, anschließend zweimalig der gleitende Mittelwert gebildet und zuletzt mit der vierten Potenz verrechnet. Alle Signale, deren euklidische Distanz untereinander kleiner als 0,3 ist, werden der gleichen Gruppe zugeordnet.

Regel 6.1 – Extraktion der LOAD-Signale

Über den Zusammenhang $-\frac{d^2}{dt^2} (ENC1_POS) \sim CURRENT \sim TORQUE$ wird in Regel 6.1 das LOAD-Signal extrahiert, da beim LOAD-Signal der Zusammenhang nicht gilt. Dafür

wird bei den Signalen zunächst der gleitende Mittelwert berechnet und anschließend werden die Zeitreihen normiert. Über die euklidische Distanz kann das LOAD-Signal extrahiert werden. Liegt die Distanz zum LOAD-Signal über 1 und die der anderen beiden Signale unter 0,1 gilt das LOAD-Signal als identifiziert. Sollte keine Zuordnung möglich sein, erfolgt die Zuordnung der LOAD-Signale über den Wertebereich, der nur Werte gleich oder größer 0 besitzt.

Regel 6.2 – Paarbildung von Position- mit Strom- und Drehmomentsignalen

Zur Verknüpfung der Positions- mit den Strom- und Drehmomentsignalen werden die Zeitreihen zunächst modifiziert. Das ENC1_POS-Signal wird zweifach abgeleitet, mit einem adaptiven Bandpassfilter gefiltert, die gleitende Standardabweichung und der gleitende Mittelwert berechnet und zuletzt quadriert. Die Strom- und Drehmomentsignale werden außer der zweifachen Ableitung gleich modifiziert wie das ENC1_POS-Signal. Liegt die euklidische Distanz zu diesem unter 1, wird die dazugehörige ID den Strom- und Drehmomentsignalen zugewiesen.

Regel 6.3 – Unterscheidung von Strom und Drehmoment

Abschließend müssen die Strom- und Drehmomentsignale voneinander unterschieden und identifiziert werden. Nach einer Untersuchung konnte festgestellt werden, dass das Drehmomentsignal immer leicht vorausseilt, weshalb dieser Effekt für die Identifikation der beiden Signale genutzt werden soll. In Abbildung 5-17 ist das Schema zur Unterscheidung dieser Signale dargestellt.




Abbildung 5-17: Unterscheidung zwischen dem vorausseilenden Drehmomentsignal und dem Stromsignal

Zunächst werden die beiden Signale normiert, voneinander subtrahiert und anschließend mit der Ableitung des ersten Signals multipliziert, wodurch die Bewegungsrichtung ausgeglichen wird. Wird nun der Mittelwert berechnet, können die Signale identifiziert werden. Falls der Mittelwert größer als 0,01 ist, ist das erste Signal,

von dem das zweite abgezogen wird, das Drehmomentsignal. Falls dieser kleiner als - 0,01 ist, war das erste Signal ein Stromsignal. Dadurch kann die ID des ENC1_POS-Signals auch den Strom- und Drehmomentsignalen zugewiesen werden.

In der Klasse **REST** verbleibende Signale werden durch Regel 6.4 bei einem Wertebereich von unter 0,05 der Klasse **NOISE** zugewiesen. Alle weiteren Signale können nicht identifiziert werden und werden deshalb in die Klasse **UNKOWN** verschoben.

5.1.9 Ergebnisse und Bewertung

In diesem Kapitel werden die Ergebnisse für das mehrstufige Vorgehen des analytischen Ansatzes aufbereitet und untersucht. Hierfür wird zunächst ein Überblick zur Auswertung der erzielten Genauigkeiten gegeben, um in einem zweiten Schritt in einem Fazit verbleibende Defizite des Ansatzes aufzuzeigen und einen möglichen Optimierungsbedarf abzuleiten.

5.1.9.1 Auswertung der Genauigkeiten

In diesem Kapitel werden die Ergebnisse des entwickelten analytischen Ansatzes zur Identifikation von Maschinensteuerungssignalen aufgezeigt. Aufgrund unterschiedlicher Betrachtungsweisen beinhaltet das Bewertungsverfahren drei Kennzahlen, die Auskunft über die Genauigkeit geben. Mit G1 werden alle Signale daraufhin überprüft, ob sie korrekt klassifiziert wurden. Signale, die in der Klasse **UNKNOWN** sind, werden als nicht korrekt klassifiziert betrachtet. Dies unterscheidet sich zur zweiten Kennzahl G2, welche die Signale in der Klasse **UNKNOWN** nicht weiter betrachtet. Dies wird damit begründet, dass diese Signale nicht falsch, sondern nicht zugeordnet werden konnten. Aufgrund dessen muss die Genauigkeit von G2 zwangsweise immer höher liegen als die von G1. Mit der dritten Kennzahl Z wird überprüft, wie groß der Anteil an Signalen ist, deren ID korrekt bestimmt wurde.

In der Tabelle 2 sind die Ergebnisse des Lerndatensatzes mit der Bremsrampe BRK100 aufgelistet, bei denen kein Schwingungszustand erzeugt werden konnte. Aufgrund der Vielzahl von Kombinationen der Versuchsparameter sind nur die Kombinationen 66 und 12 dargestellt, welche die höchste, beziehungsweise niedrigste Genauigkeiten aufweisen.

Tabelle 2: Genauigkeiten der Bewertungskennzahlen bei unterschiedlichen Kombinationen der Versuchsparameter nach Gönzheimer & Ströbel et al. (2023d)

Nr	Verteilung (trans)	Interpolator (trans)	Verteilung (rot)	Interpolator (rot)	G1	G2	Z
12	gamma	sbspline	gamma	sbspline	91,13%	94,20%	74,61%
66	exponential	sbspline	exponential	lbspline	97,50%	98,33%	85,61%

Es kann festgestellt werden, dass die Genauigkeiten von G1 und G2 mindestens 91 % betragen und damit bereits hoch sind. Auch kann durch den Vergleich der beiden Kennzahlen geschlussfolgert werden, dass generell nur sehr wenige Signale nicht identifiziert und damit der Klasse **UNKNOWN** zugeordnet werden. Bei Betrachtung der Kennzahl Z sinken die Genauigkeiten jedoch deutlich. Bei den vorliegenden Kombinationen werden nur 74,6 %, beziehungsweise 85,6 % erreicht, was bedeutet, dass einige IDs nicht in den Zeitreihen identifiziert werden können. Fehlerhafte Zuordnungen sind hauptsächlich bei CTRL_POS- und VEL_FFW-Signalen vorzufinden.

Aufgrund der fehlenden Schwingungszustände war bereits abzusehen, dass die Ergebnisse des Lerndatensatzes mit BRK100 weniger gute Genauigkeiten erzielen. Deshalb wurde ein Validierungsdatensatz mit drei Aufnahmen aufgezeichnet, welche mit der Bremsrampe BRK0 durchgeführt wurden. In Tabelle 3 sind die Ergebnisse aufgelistet. Es ist deutlich festzustellen, dass alle Bewertungskennzahlen eine sehr hohe Genauigkeit erreichen.

Tabelle 3: Genauigkeiten der Bewertungskennzahlen der drei Aufnahmen aus dem Validierungsdatensatz nach Gönzheimer & Ströbel et al. (2023d)

Aufzeichnung	G1	G2	Z
1	99,30%	99,57%	96,83%
2	98,80%	99,20%	96,28%
3	99,80%	99,80%	99,78%

Bei G1 liegt die minimale Genauigkeit bei 98,8 %, bei G2 99,2 % und bei Z werden mindestens 96,23 % erreicht. Dies bedeutet, dass fast alle Signale identifizierbar sind und damit kaum welche der Klasse UNKNOWN zugeordnet werden und auch nahezu alle IDs in den Zeitreihen korrekt identifiziert werden konnten.

5.1.9.2 Fazit und Optimierungsbedarf

Mit dem analytischen Ansatz wurde ein Modell entwickelt, welches bereits mit sehr hohen Genauigkeiten Signale aus einer Werkzeugmaschine identifizieren kann. Dennoch existieren einige Problemstellen, die näher betrachtet werden müssen. Zunächst basieren die Genauigkeiten besonders stark auf den erzeugten Schwingungszuständen der Referenzfahrt. Können diese nicht erzwungen werden, sind auch die Ergebnisse der Identifikation deutlich schlechter. Ohne diese Schwingungen konnte bereits festgestellt werden, dass die Signale CTRL_POS und VEL_FFW an der Versuchsmaschine nicht mehr zuverlässig identifiziert werden können. Deshalb ist zur zuverlässigen Ertüchtigung des Ansatzes für diese Fälle eine Optimierung der entwickelten Regelbasen, die zur Identifikation der Signale führen, notwendig.

Weiterhin kann der generelle Ablauf ein Hindernis darstellen, da bei den für den Ansatz essentiellen Referenzfahrten die aufzuklärende Werkzeugmaschine, neben der Zeit der Implementierung, zur Zeit der Referenzfahrt nicht produktiv zur Verfügung steht. Insbesondere bei hoch getakteten Maschinenparks kann dies ein großes Problem darstellen, auch wenn die Referenzfahrt nur einmal initial durchgeführt werden muss. Dass der angestrebte Ansatz für den Anwender darüber hinaus möglichst aufwandsminimal gestaltet und ohne Anwenderexpertise auskommen soll, stellt für den Ansatz im Hinblick auf die umzusetzenden Referenzfahrten einen weiteren Nachteil dar.

Zuletzt bestehen eine Herausforderung und ein Optimierungspotential bei der Synchronisation von Referenzfahrt und Datenaufzeichnung, die noch nicht generalisiert ist. Um die eigentliche Referenzfahrt zu erkennen, wäre es vorteilhaft, wenn Beginn und Ende durch eindeutige Merkmale gekennzeichnet werden. Beispielsweise könnten an diesen Zeitpunkten Extremwerte außerhalb des Wertebereichs angefahren werden, um die Ereignisse sicher zu kennzeichnen. Zusätzlich sollte danach eine Pause von einer Sekunde erfolgen, damit alle Abschwingvorgänge vollendet sind. Dies würde den Umsetzungsaufwand über die eigentliche Referenzfahrt hinaus erhöhen und die Verfügbarkeit der Maschine weiter einschränken.

5.2 ML-basierte Signalidentifikation

In diesem Kapitel werden Identifikationsansätze auf Basis von ML-Modellen entwickelt, welche Maschinensteuerungsdaten klar als bestimmte Signaltypen identifizieren können. In Kapitel 2.4 wurden mehrere vielversprechende Ansätze zur Klassifizierung von Zeitreihen mit ML aufgezeigt. Da diese Ansätze nicht direkt übertragen werden können, werden sie für das ML-Konzept als grundlegende Basis verwendet. Ziel des in diesem Kapitel beschriebenen Ansatzes ist es, mit ML-Modellen möglichst viele unterschiedliche Signale identifizieren zu können. Der Inhalt dieses Kapitels wurde im Rahmen der angeleiteten Abschlussarbeiten (A_Puchta 2020) und (A_Karle 2020) erarbeitet. Die Ergebnisse sind zusammenfassend dargestellt.

5.2.1 Konzept

Als Grundlage für die Identifikation von Maschinensteuerungsdaten werden die ML-Modelle ResNet, FCN, LSTM und RanFor verwendet. Aufgrund der Vielzahl an möglichen Signalen in Werkzeugmaschinen werden die Eingangsdaten zunächst auf spezifische Merkmale wie den Informationsgehalt analysiert, um die Struktur der Modelle sinnvoll anzupassen. Beispielsweise können Zeitreihen mit häufig konstanten Abschnitten, was einem niedrigeren Informationsgehalt entsprechen würde, das Training stark negativ beeinflussen. Diese Untersuchungen dienen dazu, in einer Vorverarbeitung die Eingangsdaten in eine passende Form zu bringen, um von den ML-Modellen verarbeitet werden zu können. Für den RanFor müssen zusätzlich noch Merkmale aufgelistet werden, nach denen dieser eine Entscheidungen treffen soll. Anschließend werden in Kapitel 5.2.5 und 5.2.6 die Architekturen aufgebaut und die Auswirkungen beispielsweise der Batchgröße von Deep-Learning-Modellen oder der maximalen Tiefe und Anzahl der Lerner des RanFor analysiert. In Abbildung 5-18 ist die Einordnung des ML-basierten Ansatzes in den Gesamtprozess dargestellt. Über eine Schnittstelle werden die Eingangsdaten an ein ML-Modell weitergeleitet, welches die Zuweisungen dem Anwender als Ausgabe zurückgibt.

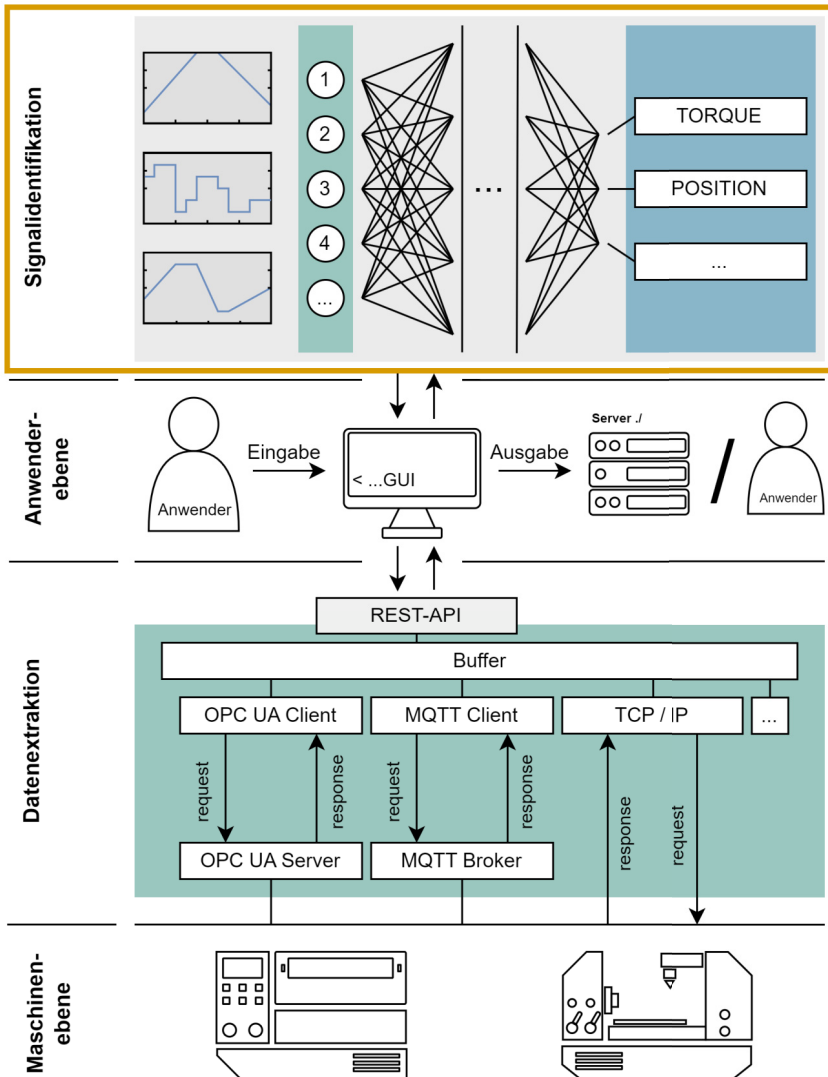


Abbildung 5-18: Einordnung und Konzept der ML-Modelle in den Gesamtprozess in Anlehnung an Gönninger & Ströbel et al. (2023b)

5.2.2 Datensätze

Die Datensätze sind ein wichtiger Bestandteil bei der Anwendung von ML, da die Informationen über die zu bestimmenden Signale nur anhand dieser gewonnen werden können. Deshalb werden unterschiedliche Aufzeichnungen genutzt, um eine größere Bandbreite an Signalverhalten abzubilden. Die hier verwendeten Datensätze wurden mit einer Deckel Maho DMC 60H – HDM-Werkzeugmaschine aufgezeichnet. Dabei stehen verschiedene Aufnahmen zur Verfügung, die unterschiedliche Arbeitsprozesse enthalten. Ein Teil der Aufzeichnungen umfasst lediglich freie Achsbewegungen ohne Bearbeitung eines Werkstücks. Bei den Signalen handelt es sich unter anderem um unterschiedliche Positionsdaten, Regeldifferenzen, Ströme, Drehmomente und einige Statussignale der Werkzeugmaschine. In Tabelle 4 ist beispielhaft der Signalpool einer Aufzeichnung mit einer Siemens SINUMERIK 840D Steuerung dargestellt. Anhand dieser Abbildung können bereits unterschiedliche Typen an Signalen erkannt werden, beispielsweise eine übergeordnete Gruppe für Positionssignale, in der jedes Positionssignal jedoch wieder spezifisch ist.

*Tabelle 4: Aufgezeichnete Daten der Deckel Maho DMC 60H – HDM nach
A_Karle (2020)*

Signalklasse	Bezeichner	Achstyp	Ausrichtung
Binär	A_DBD\2000	-	-
Zyklus	CYCLE	-	-
Ist-Position	ENC_POS 1	Linear	Horizontal
	ENC_POS 2	Linear	Vertikal
	ENC_POS 3	Linear	Horizontal
	ENC_POS 4	Rotation	-
	ENC_POS 6	Spindel	-
Soll-Position	DES_POS 1	Linear	Horizontal
	DES_POS 2	Linear	Vertikal
	DES_POS 3	Linear	Horizontal
	DES_POS 4	Rotation	-
Strom	CURRENT 1	Linear	Horizontal
	CURRENT 2	Linear	Vertikal
	CURRENT 3	Linear	Horizontal
	CURRENT 4	Rotation	-
	CURRENT 6	Spindel	-
Drehmoment	TORQUE 1	Linear	Horizontal
	TORQUE 2	Linear	Vertikal
	TORQUE 3	Linear	Horizontal
	TORQUE 6	Spindel	-
Regeldifferenz	CTRL_DIFF 1	Linear	Horizontal
	CTRL_DIFF 2	Linear	Vertikal
	CTRL_DIFF 3	Linear	Horizontal
	CTRL_DIFF 4	Rotation	-
	CTRL_DIFF2 1	Linear	Horizontal
	CTRL_DIFF2 2	Linear	Vertikal
	CTRL_DIFF2 3	Linear	Horizontal
	CTRL_DIFF2 4	Rotation	-

5.2.3 Verwendete ML-Modelle

In Kapitel 2.4.1 wurde die Verwendung unterschiedlicher Typen von ML-Modellen nach Farahani & McCormick et al. (2023a) erläutert. Auf dieser Basis konnte eine Auswahl sinnvoller ML-Modelle vorgenommen werden, zu denen in diesem Kapitel dazugehörige Algorithmen als Basis ausgewählt werden.

In (Farahani & McCormick et al. 2023b) wird eine Vielzahl an ML-Algorithmen anhand ihrer Leistungsfähigkeit miteinander verglichen, um den aktuellen Stand der Technik zu repräsentieren. Unterschieden wurde in konventionelle Verfahren und künstliche neuronale Netze, die auch Deep Learning beinhalten. Die Typen der Zeitreihen der verwendeten Datensätze sind alle bekannt, weshalb es sich hierbei um überwachtes Lernen handelt. Um die Zeitreihen zu vereinheitlichen, wurden diese durch eine Vorverarbeitung modifiziert. Dabei handelt es sich unter anderem um die z-Normalisierung zur besseren Vergleichbarkeit der Ergebnisse. Um die Datenbasis zu erweitern, wurden die Zeitreihen teilweise aufgeteilt und weiter modifiziert, was zu einer umfassenderen Charakteristik führen kann. Anschließend wurden von Farahani & McCormick et al. (2023b) alle Modelle mit den vorhandenen Datensätzen analysiert. Dafür wurde zunächst ein Benchmarking von sieben Standard Klassifikatoren durchgeführt. Als Bewertungsmaße wurden die durchschnittliche Genauigkeit (AVG ACC), Number of wins, Average Rank und der Mean per class error verwendet. Number of wins bezeichnet dabei die Häufigkeit, mit der ein Modell besser als alle anderen abgeschnitten hat. Der Average Rank stellt den durchschnittlichen Rang dar, den ein Modell über alle Tests erreicht hat. Der Mean per class error kann als Maß für die Fehlerquote eines Modells betrachtet werden, das angibt, wie groß der Fehler im Durchschnitt aller Klassen ist.

Das Multi-Layer Perceptron (MLP) aus der Referenzgruppe erzielte beim initialen Benchmarking das beste Ergebnis, gefolgt vom RanFor. Bei der Untersuchung rein konventioneller Verfahren wurden 19 Algorithmen getestet. Die höchste Genauigkeit wurde mit einem Diverse Representation Canonical Interval Forest (DrCIF) erzielt. Bei den neuronalen Netzen ist das ResNet deutlich an erster Stelle. Anschließend wurde der Einfluss von Data Augmentation untersucht. Dafür wurden die künstlich erzeugten, beziehungsweise veränderten Zeitreihen ausgeschlossen. Als ML-Modelle wurden von Farahani & McCormick et al. (2023b) die insgesamt zehn besten aus den konventionellen Verfahren und der künstlichen neuronalen Netze ausgewählt. Hierbei wurde festgestellt, dass sich durch Data Augmentation tendenziell leicht bessere Ergebnisse erzielen lassen können. Zusammenfassend kann aus dem Beitrag entnommen werden, dass bei komplexeren Problemen konventionelle Verfahren durchaus auch sehr gute Ergebnisse erzielen. Die insgesamt besten Modelle sind das ResNet, DrCIF, Inception-Time und ARSENAL. LSTM, BiLSTM und TS-LSTM haben ebenfalls sehr gute Ergebnisse in der Merkmalerkennung erzielen können.

Aufgrund der Ergebnisse aus (Farahani & McCormick et al. 2023a) und (Farahani & McCormick et al. 2023b) kann festgehalten werden, dass eine breitere Auswahl an ML-Modellen sinnvoll ist. Deshalb werden die verwendeten Modelle FCN und ResNet in (Farahani & McCormick et al. 2023b), welche in (Wang & Yan et al. 2017) entwickelt wurden, für diese Dissertation als Grundlage genommen. Zusätzlich wird auf der Basis von (Aggarwal 2018) ein LSTM Netzwerk entwickelt. Aufgrund der weiten Verbreitung von RanFor-Modellen und der hohen Leistungsfähigkeit in den genannten Arbeiten wird dieses Modell aus den konventionellen Verfahren ausgewählt. Der Aufbau wurde bereits in Kapitel 2.4.1 beschrieben. Die vorgenommenen Änderungen der neuronalen Netze und auch die Struktur des RanFor werden jeweils in den Unterkapiteln 5.2.5 und 5.2.6 erläutert.

5.2.4 Vorverarbeitung

Die Güte von ML-Modellen kann maßgeblich durch die verwendeten Trainingsdaten beeinflusst werden. Deshalb ist es besonders wichtig auf deren Informationsgehalt zu achten und gegebenenfalls Anpassungen durchzuführen. Dafür wird in diesem Kapitel der Einfluss inaktiver Samples, die Länge der Samples sowie die Überlappung der Samples analysiert, um eine zielführende Formatierung der Eingangsvektoren zu erstellen. Generell wird wie in (Farahani & McCormick et al. 2023b) auf alle Samples eine z-Normalisierung angewendet. Diese hat mit dem Mittelwert auf null und der Standardabweichung auf eins den entscheidenden Vorteil, dass Zeitreihen unterschiedlicher Typen besser miteinander verglichen werden können.

Zusätzlich müssen im Fall des RanFor im Voraus Merkmale bestimmt werden, anhand derer die Eingangsvektoren den Zielklassen zugeordnet werden. Zusätzlich wird überprüft, wie sehr die Merkmale das Gesamtergebnis beeinflussen. Dadurch kann gegebenenfalls der Merkmalsraum reduziert werden, um die Berechnung nicht notwendiger Merkmale und die entsprechende Rechenzeit zu vermeiden.

Für eine erste Untersuchung werden in diesem Kapitel Zielklassen auf Basis der in Tabelle 4 aufgeführten Signalklassen definiert. Dabei werden die Signalklassen der Ist- und Soll-Position sowie die von Strom und Drehmoment aufgrund ihrer starken Ähnlichkeit und des engen Zusammenhangs zusammengefasst. Es ergeben sich die Zielklassen **BIN** (binär), **CTRL_DIFF** (Regeldifferenzen), **CUR/TOR** (Strom und

Drehmoment), **POS** (Positionen) und **CYC** (Zyklus). Zielklassen werden im Folgenden für eine bessere Erkennbarkeit fett gedruckt.

5.2.4.1 Einfluss inaktiver Samples

Inaktive Samples sind Bereiche von Zeitreihen mit konstanten oder annähernd konstanten Werten. Die Erkennung inaktiver Samples kann über die Standardabweichung erfolgen, die als Indikator für ein Sample darstellt, wie sehr sich ein Signal in dem Zeitreihenabschnitt ändert, was wiederum als Informationsgehalt verstanden werden kann. Anhand eines Teildatensatzes werden die Zeitreihen in gleich große Samples aufgeteilt, deren Standardabweichung anschließend berechnet wird. Zur Bestimmung der Standardabweichung wird das Sample-Zeitintervall zunächst auf 100 ms festgelegt. In Abbildung 5-19 ist eine Analyse der Standardabweichungen von Positionssignalen dargestellt. Daraus wird festgestellt, dass die Standardabweichung selten exakt Null ist, weshalb der Schwellenwert zur Extraktion der inaktiven Signale größer Null sein muss.




Abbildung 5-19: Positionssignale (oben) und deren Standardabweichung (Mitte) und eine vergrößerte Ansicht der der Standardabweichung (unten) nach A_Karle (2020)

In Abbildung 5-20 sind Histogramme der Klassen in Bezug auf deren Standardabweichungen dargestellt. Auffällig ist, dass es keine Zeitreihen mit Standardabweichungen zwischen 10^{-12} und 10^{-6} gibt. Bei den Regeldifferenzen kann festgehalten werden, dass diese generell nur sehr kleine Werte aufweisen. Nach weiteren Untersuchungen konnte festgestellt werden, dass Positionssignale mit einer Standardabweichung kleiner als 10^{-2} als nicht aktiv betrachtet werden können. Dadurch lassen sich jedoch nur noch wenige Regeldifferenzsignale identifizieren, da diese unter dem benötigten Schwellenwert liegen.




Abbildung 5-20: Standardabweichungen aller Samples nach vordefinierten Klassen nach A_Karle (2020)

Da beim Training der ML-Modelle Informationen aus den Samples verwendet werden, um die Parametrierung der Zielfunktion zu bestimmen, ist die Qualität der Trainingsdaten von besonderer Bedeutung. Aufgrund inaktiver Signale lässt sich die Vermutung herleiten, dass diese deshalb den Trainingsprozess erschweren und damit die Modellgenauigkeit verringern. Um den Einfluss der inaktiven Samples zu überprüfen, werden RanFor mit unterschiedlichen Standardabweichungen trainiert und mit für das Modell unbekanntem Daten validiert. Das Training der RanFor wurde mit einer fünffachen Kreuzvalidierung durchgeführt und das beste Ensemble wurde für die Validierung verwendet. Die Samplelänge entspricht 200 und die Samples wurden mit 50 Datenpunkten überlappt. Es wurden 20 Lerner mit einer maximalen Tiefe von 5 Bäumen und einer minimalen Unreinheitsreduktion von 0,05 verwendet.

Untersucht wurden die Schwellenwerte 0 , 10^{-6} , 10^{-3} und 10^{-2} . Samples mit einer Standardabweichung von Null entsprechen Zeitreihen mit konstantem Wert, weshalb diese nicht weiterverwendet werden. Zusätzlich können während des Prozesses einige numerische Berechnungen nicht durchgeführt werden, da bei diesen durch die Standardabweichung dividiert wird.

In Tabelle 5 sind die Konfusionsmatrizen des RanFor mit den zuvor gefilterten Datensätzen unterschiedlicher Schwellenwerte für die Standardabweichung dargestellt. Mit einer Standardabweichung von 0 werden besonders viele Samples der

Positionssignale falsch zugeordnet. Erst durch eine Erhöhung des Schwellenwertes lassen sich diese besser klassifizieren. Allgemein werden besonders häufig Signale fälschlicherweise der Klasse Strom/Drehmoment zugeordnet. Erst bei einem Schwellenwert von 10^{-2} werden Positions- und Regeldifferenzsignale deutlich seltener der Klasse Strom/Drehmoment zugewiesen. Dadurch werden die Regeldifferenzen nur mit einem niedrigen Schwellenwert nicht von Beginn an aussortiert, im Anschluss jedoch bei der Klassifikation besonders häufig falsch zugewiesen werden. Da, wie in Abbildung 5-20 erkenntlich, mit Standardabweichung größer 10^{-2} auch gleichzeitig wesentlich mehr Samples gefiltert werden und damit weniger Informationen zur Verfügung stehen, stellt die Festlegung des Schwellenwertes auf 10^{-2} einen ausgeglichenen Kompromiss dar.

Tabelle 5: Konfusionsmatrizen der RanFor nach der Filterung der Samples unterschiedlicher Standardabweichungen nach A_Karle (2020)

		vorhergesagte Klasse				
		BIN	CTRL_DIFF	CUR/TOR	CYC	POS
wahre Klasse	BIN	616	4	0	0	0
	CTRL_DIFF	3	973	328	0	6
	CUR/TOR	10	107	3912	0	1
	CYC	0	0	0	603	0
	POS	1	1052	1211	5	1168

		vorhergesagte Klasse				
		BIN	CTRL_DIFF	CUR/TOR	CYC	POS
wahre Klasse	BIN	755	3	0	0	0
	CTRL_DIFF	3	808	320	0	21
	CUR/TOR	7	187	4254	0	1
	CYC	0	0	0	702	0
	POS	2	302	1198	4	1433

		vorhergesagte Klasse				
		BIN	CTRL_DIFF	CUR/TOR	CYC	POS
wahre Klasse	BIN	883	1	0	0	0
	CTRL_DIFF	0	363	352	0	31
	CUR/TOR	12	241	5063	0	16
	CYC	0	0	0	895	0
	POS	0	67	363	9	1704

		vorhergesagte Klasse				
		BIN	CTRL_DIFF	CUR/TOR	CYC	POS
wahre Klasse	BIN	1074	0	0	0	0
	CTRL_DIFF	0	267	28	0	3
	CUR/TOR	0	125	5282	0	5
	CYC	0	0	0	1058	0
	POS	0	156	50	2	1950

5.2.4.2 Länge der Samples am Beispiel eines RanFor

Die Länge der Samples spielt beim Training der Modelle eine besonders große Rolle, da über diese bestimmt wird, wie viel Information beim Training in einem Durchgang zur Verfügung steht. Um diesen Parameter zu optimieren, wurden RanFor mit unterschiedlichen Sample-Zeitintervallen trainiert. In einer ersten Untersuchung soll der Einfluss des Filters für inaktive Signale gering sein, weshalb der Schwellenwert auf 10^{-6} festgelegt wird. Zusätzlich wurde eine Klassengewichtung verwendet, um die

Unterschiede der Anzahl an Samples pro Klasse auszugleichen. Damit ein optimales Sample-Zeitintervall gefunden werden kann, wurden zunächst Samples aus Datensätzen mit den Sample-Zeitintervallen 10, 20, 50, 100, 200, 500, 1000, 2.000, 5.000, 10.000, 20.000 und 50.000 erstellt. Mit der verwendeten Abtastrate von 500 Hz liegen die

Sample-Zeitintervalle dementsprechend zwischen 0,02 und 100 Sekunden. In Tabelle 6 sind die Ergebnisse der durchschnittlichen Genauigkeiten der jeweiligen Zielklassen bei unterschiedlichen Samplelängen dargestellt.

Tabelle 6: Genauigkeit der Klassen mit unterschiedlichen Sample-Zeitintervallen nach A_Karle (2020)

Datenpunkte	10	20	50	100	200	500	1.000	2.000	5.000	10.000	20.000	50.000
BIN	100	100	100	100	99	99	100	99	100	100	100	100
CTRL_DIFF	22	28	67	67	73	78	79	80	85	88	92	92
CUR/TOR	92	94	90	95	94	94	94	95	90	88	91	93
CYC	100	100	100	100	100	99	97	100	100	100	100	100
POS	51	49	49	48	47	51	54	61	68	73	72	83
AVG ACC	74,3	75,1	77,1	78,7	78,5	79,9	80,7	82,4	83,3	84,7	86,1	90,1

Zunächst kann festgestellt werden, dass die Klassen für binäre und zyklische Signale nur sehr schwach von der Samplelänge beeinflusst werden. Die Regeldifferenzen können mit zunehmender Samplelänge kontinuierlich besser identifiziert werden. Ganz besonders steigt von 20 auf 50 Datenpunkte die Genauigkeit um 39 %. Die Positionssignale stagnieren bis zu einer Samplelänge von 1.000 bei etwa 50 % und steigen erst bei größeren Samplelängen auf bis zu 83 %. Die Gesamtgenauigkeit steigt von Beginn an monoton mit höherem Sample-Zeitintervall an und erreicht zuletzt 90,1 %. Die zunächst niedrige Genauigkeit zur Identifikation von Regeldifferenz- und besonders von Positionssignalen lässt sich mit den Erkenntnissen aus Kapitel 5.2.4.1 begründen. Mit einem niedrigeren Schwellenwert zur Filterung inaktiver Signale werden zunehmend die Samples von Regeldifferenz und Position falsch klassifiziert. Bei größeren Samplelängen wird die Anzahl an inaktiven Signalen wieder geringer, weshalb auch die Genauigkeit ansteigt. Im nachfolgenden Schritt wird deshalb die Untersuchung der Samplelänge mit den Schwellenwerten 10^{-4} , 10^{-3} , 10^{-2} durchgeführt. Wie in Tabelle 6 ersichtlich ist, sind die Ergebnisse bei kleineren Samplelängen deutlich schlechter, weshalb nur noch Samplelängen von mindestens 200 betrachtet werden. Zusätzlich wird auch nach oben hin eine Beschränkung von 5.000 festgelegt, da dies eine vertretbare Beobachtungsdauer darstellt.

In Tabelle 7 sind die Ergebnisse unterschiedlicher Kombinationen von Schwellenwerten für inaktiver Samples und der Samplelänge dargestellt. Daraus lässt sich erkennen, dass die Wahl der Standardabweichung einen deutlich größeren Einfluss als die Samplelänge besitzt. Zusätzlich steigt die Klassifikationsgenauigkeit mit steigender Standardabweichung stark an. Ein Schwellenwert von 10^{-2} erzielt die besten Ergebnisse von 96,1 % bei einer Samplelänge von 5.000 bis hin zu 97,4 % und einer Samplelänge 1.000. Dadurch bleibt weiterhin bestätigt, dass die Wahl des Schwellenwertes auf 10^{-2} zielführend ist. Zusätzlich kann nach dieser Untersuchung auch die Samplelänge auf 1000 festgelegt werden.

Tabelle 7: Klassifikationsgenauigkeit der RanFor mit unterschiedlichen Kombinationen von Standardabweichungsfilter und Samplelänge nach A_Karle (2020)

AVG ACC		Samplelänge [Datenpunkte]				
		200	500	1000	2000	5000
STD	10^{-4}	81,9	83,9	84,0	86,7	89,0
	10^{-3}	89,1	89,2	89,8	89,8	91,5
	10^{-2}	96,3	97,1	97,4	96,9	96,1

5.2.4.3 Einfluss überlappender Samples am Beispiel RanFor

Ein weiterer Parameter, der beim Training der Modelle hilfreich sein kann, ist die Überlappung der Samples. Da die ausreichende Datengrundlage oft eine Hürde darstellt, besteht die Möglichkeit aus den vorhandenen Daten mehr Samples zu generieren, indem man die Samples mit einer Überlappung berechnet. Dadurch resultiert eine höhere Anzahl an Samples, die während des Trainings verwendet werden können. Der konkrete Einfluss auf die Klassifikationsgenauigkeit muss jedoch zunächst geprüft werden. Dafür werden identische RanFor mit unterschiedlichem prozentualen Anteil an Überlappung der Samples trainiert. Ausgewählt werden 10 Variationen von 0 % Überlappung bis 90 % in jeweils 10 %-Schritten. In Tabelle 8 sind die Ergebnisse der verschiedenen Überlappungsgrößen aufgelistet. Die Klassifikationsgenauigkeit steigt bis zu einer Überlappung von 40 % nur sehr leicht an und fällt anschließend wieder um 0,5 %. Auf Basis dieser Ergebnisse lässt sich schlussfolgern, dass die Überlappung der Samples keinen entscheidenden Einfluss auf die Klassifikationsgenauigkeit besitzt.

Tabelle 8: Einfluss der Überlappung von Samples auf die Genauigkeit bei einem RanFor nach A_Karle (2020)

Überlappung der Samplelänge in %	0	10	20	30	40	50	60	70	80	90
Anzahl Sample	1.536	1.696	1.904	2.160	2.528	3.040	3.760	5.008	7.488	14.928
Faktor Zunahme	1,0	1,1	1,2	1,4	1,6	2,0	2,4	3,3	4,9	9,7
Anzahl Sample nach STD-Filterung	1.125	1.238	1.388	1.584	1.845	2.229	2.752	3.661	5.483	10.931
Faktor Zunahme	1,0	1,1	1,2	1,4	1,6	2,0	2,4	3,3	4,9	9,7
AVG ACC	94,9	94,9	94,8	94,9	95,1	95,0	94,9	94,8	94,7	94,6

5.2.4.4 Merkmalsauswahl für den RanFor

Für die Klassifikation von Zeitreihen mit einem RanFor werden Merkmale anstelle von Datenpunkten benötigt, weshalb in diesem Kapitel 40 typische Merkmale beschrieben werden, die zunächst für den RanFor verwendet werden sollen.

Tabelle 9: Auflistung der verwendeten 40 typischen Merkmale für den RanFor nach A_Karle (2020)

Nr.	Merkmalsbezeichnung	Beschreibung
1.-4.	max, max-pos, min, min-pos	Maximum und Minimum, sowie deren Position
5.	median	Median
6.	range	Wertebereich
7.	sign-changes	Anzahl an Vorzeichenwechsel
8.-10.	n-max, n-min, n-extrema	Anzahl an lokalen Maxima und Minima im Umkreis von mindestens einem Datenpunkt und die Summe beider Werte
11.-14.	max-grad, min-grad, max-grad2, min-grad2	Maximum und Minimum der ersten und zweiten Ableitung
15.-17.	n-max-grad, n-min-grad, turning-points	Anzahl der lokalen Maxima und Minima im Umkreis von mindestens einem Datenpunkt der ersten Ableitung und die Summe beider Werte als Anzahl der Wendepunkte
18.	sum-abs	Summe aller Beträge
19.-20.	n-pos, n-neg	Anzahl aller positiven und negativen Werte
21.	sum-abs-diff	Summe der Beträge aller Differenzen zweier benachbarten Datenpunkte

22.	most-common	Häufigster Wert
23.-24.	max-diff, min-diff	Maximale und minimale Differenz zweier benachbarter Datenpunkte
25.-28.	max-freq, 2-freq, 3-freq, min-freq	Frequenzen mit den drei größten sowie der kleinsten Amplitude im Frequenzspektrum
29.-30.	mean-freq, median-freq	Die Frequenzen des Medians und Mittelwert des Leistungsspektrums im Periodogramm
31.	sum-diff	Summe der Differenzen zweier benachbarter Werte
32.	zero-freq	Anzahl an Nullen
33.	mean-without-zero	Mittelwert ohne Werte gleich Null
34.-35.	n-overshoots, n-undershots	Anzahl der Über- und Unterschinger bei Annahme eines Bilevel-Signals
36.-37.	lower-state-lvl, upper-state-lvl	Unteres und Oberes Level unter Annahme eines Bilevel-Signals
38.	obw(99%)	Bandbreite unter Beachtung von 99 % des Leistungsspektrums
39.	skewness	Schiefe, Maß zur Stärke der Asymmetrie einer Wahrscheinlichkeitsverteilung
40.	kurtosis	Wölbung, Maß zur Steilheit einer Wahrscheinlichkeitsverteilung

5.2.5 Signalidentifikation mit neuronalen Netzen

In diesem Kapitel werden die verschiedenen neuronalen Netze ResNet, FCN und LSTM hinsichtlich der Hyperparameter untersucht. Dafür wird auf Basis einer Analyse zunächst die maximale Anzahl potenzieller Zielklassen festgelegt, um darauf aufbauend die Hyperparameter zu optimieren.

5.2.5.1 Definition der Zielklassen

Zur Festlegung zielführender Zielklassen müssen die Genauigkeiten unterschiedlicher Anzahlen an Zielklassen analysiert werden. Dadurch wird gewährleistet, dass die maximal sinnvolle Anzahl an Zielklassen bei ausreichend hoher Genauigkeit in die Modelle implementiert wird. Für die Datenaufbereitung wurde für die Filterung inaktiver Samples ein Schwellenwert von 10^{-2} und eine Samplelänge von 1.000 Datenpunkten verwendet. Die Klassenanteile wurden ausgeglichen und als Batchgröße wurde 16 festgelegt. Die Modelle wurden 500 Epochen trainiert.

Aus den vorhandenen Datensätzen sind insgesamt elf Signale als Zeitreihen vorhanden, die den geringsten Abstraktionsgrad darstellen. Durch Domänenwissen können einige Signale gruppiert werden, die in einem höheren Abstraktionsgrad als eine einzelne Zielklasse gelten können. In der Auswertung werden dafür vier unterschiedliche Abstraktionsgrade definiert. Der erste stellt die einzelnen Signale gleichzeitig als Zielklasse dar. In Abgrenzung zu den in Kapitel 5.2.4 definierten Zielklassen werden im Folgenden mit **DES** und **ENC** zwei getrennte Klassen für Soll- und Ist-Position definiert. Im nächsten Abstraktionsgrad werden die konkreten Achszuweisungen nicht mehr berücksichtigt. Ein noch höherer Abstraktionsgrad fasst alle Strom- und Drehmomentsignale als Gruppe sowie die Positionssignale als weitere Gruppe zusammen und unterteilt diese jeweils in Signale der Linearachsen und der Spindel. Die höchste Stufe baut auf der vorherigen auf, aber teilt die Strom- und Drehmomentsignale sowie die Positionssignale nicht weiter in Linearachsen und Spindel auf.

In Tabelle 10 sind die Ergebnisse der unterschiedlichen Abstraktionsgrade bei einem FCN aufgelistet. Da die Ergebnisse des ResNet nahezu identisch sind, werden diese nicht separat ausgewiesen.

Tabelle 10: Konfusionsmatrix (oben) und Genauigkeiten (unten) unterschiedlicher Zielklassengruppierungen des FCN nach A_Karle (2020)

		vorhergesagte Klasse											
		BIN	CYC	CTRL_DIFF		CURRENT		TORQUE		ENC		DES	
				lin.	lin.	Spin.	lin.	Spin.	lin.	Spin.	lin.	Spin.	
wahre Klasse	BIN	426											
	CYC		412										
	CTRL_DIFF	linear			259	10	3	2	1				
		Spindel			11	743	36	273	17	4			2
	CURRENT	linear		1	4	24	247	3	80	5			1
		Spindel			2	136	5	327	4				
	TORQUE	linear			6	31	150	3	186				1
		Spindel											
	ENC	linear		104	10	5	2				369		78
		Spindel		183						10	0		5
DES	linear		71	3	1	2		1	214			31	
	Spindel											0	

AVG ACC		BIN	CYC	CTRL_DIFF	CURRENT		TORQUE		ENC		DES	
Alle		100	100	94	68	68	69	49	65	0	10	-
nach Signal		100	100	94	72		61		49		10	
Gruppen	Signal	100	100	94	98				65			
	lin./Spin.	100	100	94	linear:	95	Spindel:	89	linear:	78	Spindel:	0

Zunächst ist erkennbar, dass die binären und zyklischen Signale in allen Fällen fehlerlos identifiziert werden konnten. Die Regeldifferenzen werden größtenteils identifiziert, wobei die fehlerhaften Zuweisungen hauptsächlich bei Strom und Drehmoment vorzufinden sind. Die Trennung von Strom und Drehmoment ist besonders fehlerhaft, was jedoch durch die Gruppierung mit den Teilklassen Linearachse und Spindel gelöst werden kann, wie in Tabelle 10 ersichtlich. Bei den Positionssignalen treten die meisten Fehlklassifikationen auf. Diese werden besonders häufig den zyklischen Signalen zugeordnet. Insbesondere die Spindelachse wird zu 90 % der Zielklasse **CYC** zugeordnet.

Bei der Betrachtung der Ergebnisse ist zu erkennen, dass es nicht zielführend ist, jedes Signal als Zielklasse zu definieren. Ausreichend hohe Genauigkeiten werden erst durch die Einteilung in die fünf Zielklassen **BIN**, **CTRL_DIFF**, **CUR/TOR**-linear, **CUR/TOR**-spindel und **POS/CYC** erreicht. Dadurch würde sich eine Gesamtgenauigkeit von 95,6 % ergeben.

Bei der Untersuchung des LSTM war das Training mit einer Samplelänge von 1.000 instabil, weshalb diese nach einem Stichprobentest zunächst auf 100 reduziert wurde. In Kapitel 5.2.5.3 wird die Samplelänge für das LSTM nochmals separat analysiert.

Die Hyperparameter wurden von den Modellen ResNet und FCN übernommen, wobei die Anzahl der versteckten Schichten auf 100 festgelegt wurde. In Tabelle 11 sind die Ergebnisse der unterschiedlichen Zielklassen des LSTM aufgelistet.

Tabelle 11: Konfusionsmatrix (oben) und Genauigkeiten (unten) unterschiedlicher Zielklassengruppierungen des LSTM nach A_Karle (2020)

		vorhergesagte Klasse											
		BIN	CYC	CTRL_DIFF		CURRENT		TORQUE		ENC		DES	
				lin.	lin.	Spin.	lin.	Spin.	lin.	Spin.	lin.	Spin.	
wahre Klasse	BIN	613			1		1						
	CYC		581										
	CTRL_DIFF	lin.			275	17	9	2	3			2	
	CURRENT	lin.	1	1	56	270	69	160	46	4		3	
		Spin.	1	5	32	21	330	11	225	6	1	2	
	TORQUE	lin.	2		16	138	38	112	19	1			
		Spin.		2	21	15	228	19	325	5		2	
	ENC	lin.		234	61		3		2	295	2	16	
		Spin.		414	7	1	2			5	1		
	DES	lin.		98	25	3	1			129	2	8	
Spin.													

AVG ACC		BIN	CYC	CTRL_DIFF	CURRENT		TORQUE		ENC		DES	
Alle		100	100	89	44	52	34	53	48	0	3	-
nach Signal		100	100	89	55		50		29		3	
Gruppen	Signal	100	100	89	93				35			
	lin./Spin.	100	100	89	linear:	73	Spindel:	89	linear:	51	Spindel:	0

Wie auch beim FCN werden beim LSTM die binären und zyklischen Signale fehlerfrei identifiziert. Auch die Regeldifferenzsignale werden mit 89 % noch gut erkannt. Jedoch sind auch Defizite bei der Unterscheidung von Strom- und Drehmoment sowie der unterschiedlichen Positionssignale zu erkennen, was auf ihren linearen Zusammenhang zurückgeführt werden kann. Auch hier werden die Positionssignale der Spindel besonders häufig der Zielklasse **CYC** zugeordnet. Zusätzlich treten auch vermehrt fehlerhafte Zuordnungen von Strom, Drehmoment und Position in die Zielklasse der Regeldifferenzen auf.

Wie auch beim FCN ist die Einteilung der Zielklassen nur durch bestimmte Gruppierungen zielführend. Auch hier ergibt sich eine ausreichend hohe Genauigkeit von 89,2 % erst bei der Aufteilung in die Zielklassen **BIN**, **CTRL_DIFF**, **CUR/TOR-linear**, **CUR/TOR-spindel** und **POS/CYC**.

5.2.5.2 Batchgröße

Ein wichtiger Aspekt beim Trainieren der Modelle ist die Batchgröße, welche bestimmt, wie viele Trainingsdaten gleichzeitig verarbeitet werden können bis die Gewichte der Modelle angepasst werden. Dies besitzt direkten Einfluss auf die Trainingsdauer. Außerdem kann durch eine geeignete Wahl der Batchgröße die Generalisierung der Modelle verbessert werden. Für die Auswahl der Batchgröße für die ML-Modelle wurden Auswertungen durchgeführt mit 8, 16, 64, 256, 1024 und zusätzlich 4096 für das FCN. Da der Speicherbedarf mit größerer Batchgröße steigt, wurde die Auswertung mit 4096 nur beim FCN durchgeführt.

Auswahl der Batchgröße für das FCN

In Abbildung 5-21 ist der Einfluss unterschiedlicher Batchgrößen auf den Fehler in Bezug auf die Anzahl an Epochen dargestellt. Zunächst ist ersichtlich, dass der Verlauf unterschiedlicher Batchgrößen sehr ähnlich ist. Mit zunehmender Batchgröße steigt jedoch der Fehler in der jeweiligen Epoche. Bei der Batchgröße von 4096, welche nur beim FCN überprüft wurde, gibt es nach ca. 570 Epochen einen starken Ausreißer. Dies ist ein Indiz dafür, dass die Batchgröße zu hoch gewählt ist, was zur Folge hat, dass auch die Gewichte im ML-Modell zu selten angepasst werden. Der nächste Batch kann deshalb zu einem instabilen Ergebnis führen, wenn dessen Charakteristik sich zu stark vom vorherigen Batch unterscheidet. Generell werden bei einer Batchgröße von 8 und 16 Genauigkeiten größer 98 % erreicht. Bei 256 und 1024 liegt diese unterhalb von 97 %. Da der Unterschied zwischen 8 und 16 nur gering ist und die Genauigkeit erst mit der nächstgrößeren Batchgröße reduziert wird, wird eine Batchgröße von 16 definiert.




Abbildung 5-21: Einfluss der Batchgröße auf die Fehlerberechnung beim FCN nach A_Karle (2020)

Auswahl der Batchgröße für das ResNet

In Abbildung 5-22 sind die Ergebnisse des ResNet dargestellt. Es ist erkennbar, dass alle Batchgrößen konvergieren, ohne dass es größere Ausreißer gibt. Außerdem gibt es keine Tendenz des größeren Fehlers mit steigender Batchgröße. Mit einer Batchgröße von 256 wurde die höchste Genauigkeit erreicht, jedoch sind die Unterschiede generell sehr gering. Kleinere Ausreißer sind nur bei größeren Batchgrößen zu erkennen. Aufgrund des stabilen Verlaufs mit einer Batchgröße von 64 wird diese als Zielgröße definiert.




Abbildung 5-22: Einfluss der Batchgröße auf die Fehlerberechnung beim ResNet nach A_Karle (2020)

Auswahl der Batchgröße für das LSTM

In Abbildung 5-23 sind die Ergebnisse des LSTM dargestellt. Zunächst ist erkennbar, dass die Batchgröße großen Einfluss auf die Ergebnisse besitzt. Die Trainingsergebnisse werden mit steigender Batchgröße instabiler. Mit 256 und 1024 lassen sich bereits

keine brauchbaren Ergebnisse mehr erzielen. Nur mit 8 und 16 konvergiert der Fehler. Während bei 8 häufig noch Ausreißer auftreten, sind bei 16 nur zu Beginn größere Abweichungen erkennbar. Bei einer Batchgröße von 64 sind über eine Vielzahl an Epochen große Schwankungen erkennbar, jedoch mit einer linearen Tendenz zu geringerem Fehler. Aufgrund der Ergebnisse, dass mit einer Batchgröße von 16 die höchste Genauigkeit erreicht wird und gleichzeitig ein stabilerer Verlauf vorliegt, wird die Batchgröße mit 16 definiert.




Abbildung 5-23: Einfluss der Batchgröße auf die Fehlerberechnung beim LSTM nach A_Karle (2020)

5.2.5.3 Anpassungen LSTM

Bei einem LSTM wird der Zellzustand durch die Berechnung einzelner Zeitschritte angepasst, weshalb ein großer Einfluss der Samplelänge naheliegt. Aufgrund dieses Zusammenhangs werden für das LSTM weitere Untersuchungen zur Bestimmung der optimalen Samplelänge durchgeführt. Als Zielklassen werden die bereits fünf bestimmten Klassen aus Kapitel 5.2.5.1 verwendet sowie eine Batchgröße von 16 und Dauer von 500 Epochen. Untersucht werden Samplelängen mit einer Länge von 10, 20, 50, 100, 200, 500 und 1.000. In Abbildung 5-24 sind die Ergebnisse für die Samplelängen 200 und größer dargestellt. Daraus lässt sich erkennen, dass keine Konvergenz erzielt werden kann und häufig Sprünge über die Epochen verteilt aufzufinden sind. Lediglich mit einer Samplelänge von 200 wird der Fehler reduziert. Daraus lässt sich ableiten, dass größere Samplelängen nicht für das LSTM geeignet sind.




Abbildung 5-24: Einfluss größerer Samplelängen auf den Fehler bei einem LSTM nach A_Karle (2020)

In Abbildung 5-25 sind die Ergebnisse für Samplelängen von 10 und kleiner dargestellt. Hier ist grundsätzlich bei allen Größen eine Konvergenz festzustellen, wobei es große Unterschiede hinsichtlich dem Kurvenverlauf gibt. Bei 10 und 20 treten vermehrt Ausreißer auf, die bei 50 auch noch, aber weniger häufig vorkommen. Mit einer Samplelänge von 100 wird über den ganzen Verlauf betrachtet ein stabiles Verhalten erzielt. Die Genauigkeiten mit einer Samplelänge von 100 liegen durchschnittlich 7 % höher als die mit 50 und erreichen insgesamt bis zu 94 %. Auf Basis dieser Untersuchung kann geschlussfolgert werden, dass der Einfluss der Samplelänge beim LSTM äußerst groß, weshalb diese weiterhin auf den Wert 100 festgelegt bleibt.




Abbildung 5-25: Einfluss kleinerer Samplelängen auf den Fehler bei einem LSTM nach A_Karle (2020)

Weiterhin wird die Dimensionalität des Hidden States des LSTM untersucht, um eine geeignete Anzahl an Merkmalen zu identifizieren. Dafür wurden mehrere LSTM mit unterschiedlicher Anzahl an Hidden States trainiert, um anschließend einen Vergleich

über die Fehlerfunktion durchzuführen. Die Architektur wurde aus der vorherigen Untersuchung übernommen. Untersucht wurde die Dimensionalität des Hidden States mit den Werten 5, 10, 20, 50, 100, 200, 500 und 1.000. In der Abbildung 5-26 sind die Ergebnisse dargestellt.




Abbildung 5-26: Einfluss der Dimension des Hidden States auf den Fehler über die Anzahl an Epochen bei eine LSTM nach A_Karle (2020)

Es ist erkennbar, dass die Wahl einer niedrigeren Dimension von 5 oder 10 zu nicht konvergierenden Verläufen führt. Bei 500 gibt es ein vermehrtes Aufkommen von Ausreißern, wohingegen mit einem Wert von 200 das beste Ergebnis erzielt wird. Deshalb wird die Dimensionalität des Hidden State auf 200 definiert.

5.2.6 Signalidentifikation mit RanFor

In diesem Kapitel wird zunächst die sinnvolle Anzahl an potenziellen Zielklassen untersucht. Anschließend werden Parameter des RanFor untersucht und optimiert. Zu diesen gehören die Merkmalsreduktion sowie die Bestimmung der maximalen Tiefe und Anzahl an Lernern.

5.2.6.1 Definition der Zielklassen

In einem ersten Schritt wird der Einfluss der Anzahl an Zielklassen bestimmt. Die Einteilung in vier Abstraktionsgrade entspricht dabei dem Vorgehen aus Kapitel 5.2.5.1. Für den RanFor werden 50 Bäume in einem Ensemble zusammengefasst. Zusätzlich werden Klassengewichte verwendet, um alle Zielklassen gleichwertig zu behandeln. Die Filterung inaktiver Samples wird mit einem Schwellenwert von 10^{-2} durchgeführt und die Samplelänge beträgt 1.000. Für das Training wird eine 10-fache

Kreuzvalidierung verwendet. In Tabelle 12 sind die Ergebnisse der unterschiedlichen Zielklassen des RanFor aufgelistet.

Tabelle 12: Konfusionsmatrix (oben) und Genauigkeiten (unten) unterschiedlicher Zielklassengruppierungen des RanFor nach A_Karle (2020)

		vorhergesagte Klasse													
		BIN	CYC	CTRL_DIFF		CURRENT			TORQUE		ENC			DES	
				lin.	rot.	lin.	rota.	Spin.	lin.	Spin.	lin.	rota.	Spin.	lin.	rota.
wahre Klasse	BIN	379													
	CYC		447												
	CTRL_DIFF	lin.			266	20					3				1
		rot.													
	CURRENT	lin.			1	888	37	145	19	1					
		rot.				5	2	4							
		Spin.			3	51	247	2	80						
	TORQUE	lin.				288	10	155	7						
		rot.				54	104	7	227						
	ENC	lin.			4	4					456		1	72	
		rot.									1	0			
		Spin.				4					12		191		
	DES	lin.		1							105				228
		rot.													

AVG ACC		BIN	CYC	CTRL_DIFF	CURRENT			TORQUE		ENC			DES		
Alle		100	100	92	-	81	18	64	34	58	85	0	92	68	-
nach Signal		100	100	92		83			46		89			68	
Gruppiert	Signal	100	100	92		100					99				
	lin./Spin.	100	100	92	linear:	95	Spindel:	85	linear:	99	Spindel:	92			

Bei der Betrachtung des ersten Abstraktionsgrades ist erkennbar, dass die binären und zyklischen Signale fehlerfrei erkannt werden. Auch die Regeldifferenzen werden mit 92 % Genauigkeit sehr gut erkannt. Bei den Zielklassen von Strom und Drehmoment werden Signale häufig fehlklassifiziert. Auch bei dem nächstgrößeren Abstraktionsgrad mit der Einteilung Strom und Drehmoment als jeweils einzelne Zielklassen steigt die Genauigkeit nur auf 83 % beziehungsweise 46 %. Bei der Einteilung beider Zielklassen in linear und Spindel werden sehr gute 95 % und 85 % erzielt. Bei den Positionssignalen werden besonders gut die Signale der Linearachse und der Spindel der Ist-Positionen erkannt, jedoch nicht die der Soll-Positionen, welche lediglich 68 %

erreichen. Erst beim dritten Abstraktionsgrad in die Einteilung der gesamten Positionssignale in linear und Spindel werden 99 % und 92 % erzielt.

Zusammenfassend kann gesagt werden, dass die Unterscheidung von Strom und Drehmoment sowie die Trennung der Soll- und Ist-Positionen nicht zuverlässig durchgeführt werden können. Deshalb empfiehlt es sich, diese jeweils in eine Zielklasse zusammenzufassen. Als Zielklassen ergeben sich damit die sieben Klassen binär, zyklisch, Regeldifferenz, Strom/Drehmoment linear, Strom/Drehmoment Spindel, Position linear und Position Spindel.

5.2.6.2 Merkmalsreduktion

Da die Anzahl an Merkmalen großen Einfluss auf die Trainingsdauer besitzen kann, werden in diesem Kapitel die 40 vorliegenden Merkmale genauer betrachtet. Dabei soll herausgefunden werden, welche Wichtigkeit die jeweiligen Merkmale darstellen, um anschließend eine Modellreduktion durchführen zu können. Als Hilfsmittel dienen die Feature Importance und Permutation Feature Importance.

In Abbildung 5-27 sind die Merkmale nach ihrer Feature Importance aufgelistet und sortiert. Der blaue Balken entspricht dem Bewertungsmaß und der schwarze stellt die Standardabweichung dar. Es ist erkennbar, dass es keine klar abtrennbaren Stufen der Merkmale gibt. Eine Merkmalsreduktion auf Basis dieser Ergebnisse ist daher nicht sinnvoll.




Abbildung 5-27: Gemittelte Feature Importance der Merkmale für den RanFor nach A_Karle (2020)

In Abbildung 5-28 wird die Permutation Feature Importance dargestellt, um auch dort die Abgrenzbarkeit zu prüfen. Die Merkmale mit der höchsten Relevanz setzen sich

deutlicher von den restlichen ab und die Standardabweichungen sind im Vergleich zu der Feature Importance wesentlich größer. Ein direkter Vergleich beider Verfahren kann nicht ohne weiteres durchgeführt werden, aber einige Merkmale, beispielsweise minimale Differenz der Datenpunkte (Min_diff), sind bei beiden gleich hoch eingestuft.




Abbildung 5-28: Gemittelte Permutation Feature Importance der Merkmale für den RanFor nach A_Karle (2020)

In einem weiteren Schritt werden die Merkmale in Rangordnung in Bezug auf die Modellgenauigkeit untersucht. Dabei wird zunächst nur mit dem jeweils am besten bewerteten Merkmal die Klassifikation durchgeführt und anschließend in der angegebenen Rangfolge weitere dazu gegeben. In Abbildung 5-29 sind die Ergebnisse graphisch dargestellt.




Abbildung 5-29: Einfluss der Merkmale hinsichtlich Auswahl und Anzahl auf die Modellgenauigkeit nach A_Karle (2020)

Es ist ersichtlich, dass zwischen den beiden Bewertungsmaßen nur geringe Unterschiede auftreten. Außerdem besitzt die Anzahl der Merkmale im Training nur einen

geringen Einfluss auf die Klassifikationsgenauigkeit, da bereits mit dem ersten Merkmal 97 % erreicht werden. Dies spricht allerdings stark für ein Overfitting des Modells. Bei der Betrachtung der unbekanntenen Testdaten sind bis zu den ersten zehn Merkmalen Änderungen einfach feststellbar. Danach ist der Einfluss auf die Klassifikationsgenauigkeit durch die Verwendung weiterer Merkmale kaum mehr erkennbar.

Zusammenfassend kann festgestellt werden, dass die Merkmale der Permutation Feature Importance minimal höhere Genauigkeiten erzielen, weshalb davon die ersten zehn Merkmale für den RanFor ausgewählt werden. Dabei handelt es sich um die Parameter `min_diff`, `obw(99%)`, `sum_diff_abs`, `range`, `min_grad2`, `n_max_grad`, `mean_frequence`, `skewness`, `max`, und `max_grad2`.

5.2.6.3 Maximale Tiefe

Um den Speicherbedarf der Modelle zu reduzieren, wird in diesem Kapitel das Wachstum der Bäume durch die maximale Tiefe untersucht. Als Grundlage dienen die bisherigen Bäume des Ensembles, welche eine maximale Tiefe von 30 aufweisen und damit als Maximalwert gelten. Ausgehend davon wird die Genauigkeit für Bäume mit geringerer Tiefe berechnet, um anschließend eine geeignete Auswahl treffen zu können. In Abbildung 5-30 sind die Ergebnisse dargestellt.




Abbildung 5-30: Einfluss der Baumtiefe auf die Genauigkeit des RanFor nach A_Karle (2020)

Es ist erkennbar, dass bis zu einer Reduktion auf eine Tiefe von 15 keine Änderungen der Genauigkeit auftreten. Die Genauigkeiten der Trainings- und Testdaten verhalten sich nahezu identisch. Erst bei einer weiteren Kürzung sinken beide Genauigkeiten ab. Jedoch ist anzumerken, dass der Speicherbedarf bei unbegrenzter Tiefe nur 1,4 MB

beträgt und erst bei kleineren Tiefen geringer ist. Damit ist der Speicherbedarf sehr gering, weshalb keine Beschränkung der Tiefe vorgenommen wird.

5.2.6.4 Anzahl der Entscheidungsbäume in einem Ensemble

Durch die Anzahl an Entscheidungsbäumen kann die Genauigkeit des RanFor beeinflusst werden. Deshalb wird untersucht, wie viele Entscheidungsbäume in einem Ensemble nötig sind, um ausreichend hohe Genauigkeiten erreichen zu können. Dafür wird der Einfluss unterschiedlicher Anzahlen an Entscheidungsbäumen auf die Genauigkeit eines RanFor überprüft. In Abbildung 5-31 sind die Ergebnisse dargestellt.




Abbildung 5-31: Einfluss der Anzahl an Lernern auf die Genauigkeit bei einem RanFor nach A_Karle (2020)

Es ist festzustellen, dass ab einer Anzahl von 30 Entscheidungsbäumen eine nahezu konstante Genauigkeit mit dem Testdatensatz erreicht wird. Auch mit weiteren Entscheidungsbäumen steigt diese nicht an, sondern konvergiert gegen 96 %.

Eine genauere Untersuchung des Speicherbedarfs zeigt, dass dieser pro Entscheidungsbaum um 40 kB größer wird, was eine äußerst geringe Speichermenge darstellt. Um auch bei größeren Datenmengen gute Ergebnisse erzielen zu können, wird die Anzahl an Entscheidungsbäumen in einem Ensemble mit 50 definiert.

5.2.7 Ergebnisse und Bewertung

In diesem Kapitel werden die Ergebnisse der unterschiedlichen ML-Modelle in Bezug auf die Klassifikationsgenauigkeit dargestellt und miteinander verglichen. Auf Basis dieser soll das beste Modell ausgewählt werden, welches die besten Eigenschaften zur Identifikation von Maschinensteuerungssignalen aufweist. Zusätzlich wird das Ergebnis der Trainingsdauer der neuronalen Netze betrachtet. Abschließend werden wichtige

Aspekte zur Optimierung des Gesamtsystems diskutiert, die eine Grundlage für Kapitel 5.3 darstellen.

5.2.7.1 Trainingsdauer

Die Datengrundlage für Kapitel 5.2 basiert auf einigen Aufzeichnungen der genutzten Deckel Maho DMC 60H-HDM, mit denen zunächst das Potential von ML-Modellen zur Identifikation von Maschinensteuerungssignalen bewertet wurde. Weiterhin zeigt die Größe der Trainingsdaten einen direkten Einfluss auf die Dauer des Trainings von ML-Modellen. Um auch größere Datenmengen und entsprechende Trainingsdatensätze zu ermöglichen, ist auch die Trainingsdauer ein Aspekt, der in die Betrachtung mit aufgenommen wird. Schließlich ist auch die Rechenleistung für das Training von ML-Modellen begrenzt, weshalb der Trainingsdatensatz nicht beliebig groß und die Modelle nicht beliebig komplex sein dürfen. Außerdem kann durch die Kenntnis der optimalen Trainingsdauer ein Abbruchkriterium erstellt werden, bei dem keine weiteren Epochen mehr durchlaufen werden, um Rechenkapazität zu sparen. Deshalb werden in diesem Kapitel die Ergebnisse dargestellt, die den Verlauf der Genauigkeit über die Epochen beim Training des FCN, ResNet und LSTM darstellen.

In Abbildung 5-32 ist der Verlauf der Genauigkeit des FCN dargestellt. Erkennbar ist, dass die Genauigkeit bis ca. Epoche 80 zunächst sehr stark zunimmt, gefolgt von einer etwas abgeflachten Phase. Ab Epoche 300 fällt die Zunahme der Genauigkeit pro Epoche nochmals deutlich ab. Bei den Testdaten wird das Maximum von 98,1 % nach 1037 Epochen erreicht. Bei den nachfolgenden Epochen stagniert das Modell. Aufgrund dessen kann festgehalten werden, dass ein Training von 1250 Epochen als ausreichend betrachtet wird.




Abbildung 5-32: Verlauf der Genauigkeit in Abhängigkeit der Anzahl an Epochen beim FCN nach A_Karle (2020)

In Abbildung 5-33 sind die Ergebnisse des ResNet dargestellt. Hier ist eine deutlich schnellere Stagnation der Genauigkeit festzustellen. Bereits nach ca. 170 Epochen werden bei den Trainingsdaten 97,5 % erreicht. Nach 200 Epochen bildet sich ein flaches Plateau, bei dem der Zuwachs nur noch gering ausfällt. Nach 843 Epochen wird eine maximale Testgenauigkeit von 98,6 % erreicht. Die Differenz der Trainings- und Testgenauigkeit ist nach 700 Epochen vernachlässigbar klein. Deshalb kann gefolgert werden, dass 850 Epochen für das Training des ResNet ausreichend sind.




Abbildung 5-33: Verlauf der Genauigkeit in Abhängigkeit der Anzahl an Epochen beim ResNet nach A_Karle (2020)

In Abbildung 5-34 sind die Ergebnisse des LSTM dargestellt. Hier ist zunächst festzustellen, dass der Verlauf von einigen Ausreißern geprägt ist. Hierbei fällt die Genauigkeit der Trainings- und Testdaten teilweise um mehr als 10 %, bevor sie wieder sprunghaft steigt. Erst nach 700 Epochen wird ein stabiler Verlauf erreicht. Die maximale Testgenauigkeit wird nach 1054 Epochen mit 92,5 % erreicht. Nach 1100

Epochen tritt erneut ein unruhigerer Verlauf auf, weshalb ein Training des LSTM mit 1000 Epochen definiert wird.




Abbildung 5-34: Verlauf der Genauigkeit in Abhängigkeit der Anzahl an Epochen beim LSTM nach A_Karle (2020)

5.2.7.2 Vergleich der ML-Modelle

In den vorherigen Kapiteln wurden die ML-Modelle ausgewählt und deren Hyperparameter zur Erhöhung der Genauigkeit optimiert. Als Datengrundlage wurde bisher systematisch ein Teil der Datenpunkte je Aufzeichnung entnommen, wobei berücksichtigt wurde, dass charakteristische Merkmale verschiedener Rahmenbedingungen und Zustände enthalten sind. Abschließend werden die nun optimierten Modelle genutzt und nochmals mit allen vorliegenden Daten trainiert, um sie dann vergleichen zu können. Zum Vergleich werden ausschließlich die Genauigkeiten des Testdatensatzes verwendet.

Zunächst werden in Tabelle 13 die neuronalen Netze miteinander verglichen. Hierbei ist festzustellen, dass das FCN und das ResNet mit 97,4 % und 97,8 % eine sehr hohe Gesamtgenauigkeit aufweisen. Das LSTM schneidet mit 89,8 % deutlich schlechter ab. Bei einer genaueren Betrachtung der Zielklassen sind die Unterschiede bei **CUR/TOR**-linear und **CUR/TOR**-Spindel besonders groß. Hier werden nur 84,6 % und 87,0 % erreicht. Binäre Zeitreihen werden hingegen von allen ML-Modellen fehlerfrei als solche identifiziert. Bei den Zielklassen **CTRL_DIFF** und **POS/CYC** ist das LSTM wieder ca. 4-6 % schlechter als das ResNet und das FCN. Die Unterschiede von FCN und ResNet sind äußerst gering und hauptsächlich in linear und Spindel von **CUR/TOR** aufzufinden. Insgesamt ist das ResNet mit 97,8 % 0,4 % genauer als das FCN und 8,0 % genauer als das LSTM.

Tabelle 13: Vergleich der Genauigkeiten der drei neuronalen Netze FCN, ResNet und LSTM in Anlehnung an Gönzheimer & Karle et al. (2021)

	AVG ACC	BIN	CTRL_DIFF	CUR/TOR		POS/CYC
				linear	Spindel	
FCN	97,4	100,0	97,1	96,0	94,6	99,4
ResNet	97,8	100,0	97,1	97,5	94,0	99,3
LSTM	89,8	100,0	93,3	84,6	87,0	93,3

Da das ResNet die höchsten Genauigkeiten aufweist, wird dieses ML-Modell in Tabelle 14 mit dem RanFor verglichen. Aufgrund der unterschiedlichen Anzahl an Zielklassen kann nicht bei jeder ein direkter Vergleich durchgeführt werden.

Tabelle 14: Vergleich der Genauigkeiten von ResNet und RanFor in Anlehnung an Gönzheimer & Karle et al. (2021)

	AVG ACC	BIN	CTRL_DIFF	CUR/TOR		POS		CYC
				linear	Spindel	linear	Spindel	
RanFor	94,3	100,0	93,0	95,5	80,1	99,0	92,3	100,0
	94,3	100,0	93,0	95,5	80,1	99,8		100,0
ResNet	97,8	100,0	97,1	97,5	94,0	99,3		

Insgesamt erzielt das ResNet mit 97,8 % eine höhere Genauigkeit als der RanFor mit 94,27 %. Bei einer näheren Betrachtung der jeweiligen Zielklassen liegt der größte Unterschied bei den Spindelsignalen von **CUR/TOR**. Während der RanFor nur 80,1 % erzielt, konnten mit dem ResNet 94,0 % der Spindelsignale von **CUR/TOR** korrekt klassifiziert werden. Bei den Zielklassen **CTRL_DIFF** und **CUR/TOR** linear konnten mit dem RanFor noch sehr gute Genauigkeiten von mindestens 93,0 % erreicht werden, wobei das ResNet nochmals höhere Werte erzielte. Bei den Positionssignalen werden vom RanFor die der Linearachse mit 99,0 % deutlich besser erkannt als die der Spindel mit 92,3 %.

Zusammengefasst kann festgehalten werden, dass beide Modelle sehr hohe Genauigkeiten erzielen, wobei beim RanFor die Identifikation von Spindelsignalen der Klasse **CUR/TOR** problematisch ist. Da in dieser Zielklasse das ResNet deutlich besser abschneidet und auch die Gesamtgenauigkeit höher ist, wird das ResNet als das finale Modell ausgewählt.

5.2.7.3 Fazit und Optimierungsbedarf

In Kapitel 5.2 konnte nachgewiesen werden, dass die Identifikation von Maschinensteuerungssignalen durch ML-Modelle generell gut funktioniert. Es zeigen sich jedoch einige Defizite, für die im Laufe der Entwicklung Anpassungen getroffen werden mussten. Dies führte beispielsweise zu einer Zusammenfassung mehrerer Signale und damit zu einer starken Beschränkung der Zielklassen, weil einzelne Signale einer Gruppe nicht zuverlässig identifiziert werden konnten. Deshalb stellen die ML-Modelle im Allgemeinen eine fundierte Basis dar, die jedoch noch erweitert werden muss. Durch die Zusammenfassung von Signalen existieren nun mehrere Signaltypen in einer einzigen Zielklasse, die mithilfe der ML-Modelle nicht voneinander unterschieden werden können. Um nun einzelne Signale isolieren zu können, müsste eine weitere Analyse zur Identifikation der jeweiligen Signale in den Gruppen durchgeführt werden. Weiterhin bestand die Datengrundlage bisher nur aus wenigen Signalen, die alle auch für einen Anwender interessant sein könnten. Es ist jedoch nicht auszuschließen, dass in späteren industriellen Anwendungen auch Signale vorhanden sind, die nicht beim Training berücksichtigt wurden und damit unbekannt sind. Da die ML-Modelle jedoch ein Sample immer einer der Klassen zuweisen, würden unbekannte Samples in allen Fällen falsch klassifiziert werden. Weiterhin muss berücksichtigt werden, dass durch eine größere Datenbasis das Training neu durchgeführt werden muss. Da Rechenleistung in der Regel nur begrenzt zur Verfügung steht und die Modelle teilweise mehrere Tage berechnet werden, wäre es vorteilhaft, wenn die Trainingsdauer reduziert werden kann.

Damit kann insgesamt das Zwischenfazit gezogen werden, dass der ML-Ansatz eine sehr gute Eignung bei der Erkennung bestimmter Signalklassen wie der der Positionssignale aufweist. Die Bestimmung von Signalen wie der Regeldifferenzen sowie einzelner weiterer Signale weist allerdings große Defizite auf. Eine Verwendung eines rein ML-basierten Identifikationsansatzes erscheint damit nicht sinnvoll.

5.3 ML-basierte Signalidentifikation mit Korrelationsregeln

Nachdem in Kapitel 5.2 die Eignung von ML-Modellen zur Identifikation von Maschinensteuerungssignalen bestätigt wurde, werden diese in Kapitel 5.3 als Grundlage für eine Weiterentwicklung genutzt. Da die Identifikation von einzelnen Signalen zu teils größeren Unsicherheiten geführt hat, wurden Signalgruppen als Zielklasse definiert, um bestimmte Signaltypen zu gruppieren. Damit aus diesen Gruppen die ursprünglich geforderten einzelnen Signale identifiziert werden können, wird ein Lösungsweg

erarbeitet, der dies ermöglicht. Außerdem wird die Datengrundlage durch zusätzlich verfügbare Aufzeichnungen erweitert. Dabei sind auch Aufzeichnungen mit Signalen enthalten, die nicht von Werkzeugmaschinen stammen. Diese sollen als Grundlage für die Modellerweiterung um unbekannte Signale dienen, wodurch ein ML-Modell zwischen bereits bekannten und fremden Signaltypen unterscheiden soll. Dies stellt einen Schwerpunkt von Kapitel 5.3 dar, weshalb am Ende die Erweiterung zur Identifikation von unbekanntem Signalen mit dem Modell ohne diese Eigenschaft verglichen werden soll. Der Inhalt dieses Kapitels wurde im Rahmen der angeleiteten Abschlussarbeiten (A_Karle 2020), (A_Kupfernagel 2021) und (A_Baucks 2021) erarbeitet. Die Ergebnisse sind zusammenfassend dargestellt.

5.3.1 Konzept

Aufgrund der Erkenntnis aus Kapitel 5.1, dass die vollständige Identifizierung von Maschinensteuerungssignalen allein durch ML-Modelle nur begrenzt möglich ist, wird ein mehrstufiges Modell entwickelt (Gönnheimer & Puchta et al. 2020). Dafür werden ML-Modelle aus Kapitel 5.2 zunächst anhand weiterer Datenaufzeichnungen validiert, um daraus das beste ML-Modell bestimmen zu können. Die Aufteilung der Gruppen in einzelne Signale soll anschließend durch analytische Regeln durchgeführt werden. Durch diese Maßnahme ist die Genauigkeit der analytischen Regeln sehr stark von der Klassifizierung des ML-Modells abhängig. Deshalb muss dieses Modell eine sehr hohe Klassifikationsgenauigkeit nachweisen. Um dies zu ermöglichen, werden bei der Validierung der bestehenden Modelle aus Kapitel 5.2 die Zielklassen auf **BIN**, **CTRL_DIFF**, **CUR/TOR**, **POS** und **CYC** festgelegt. Da häufig Signale der Klasse **CYC** in **POS** und **CUR/TOR** aufzufinden sind, werden diese in einem weiteren Schritt durch analytische Regeln extrahiert und der Klasse **CYC** zugeordnet. Dadurch existieren fünf Zielklassen, welche für alle vier ML-Modelle gelten.

Nach der Bestimmung des besten ML-Modells beginnt die eigentliche Entwicklung des mehrstufigen Modells. In Abbildung 5-35 ist der mehrstufige Ansatz dargestellt.

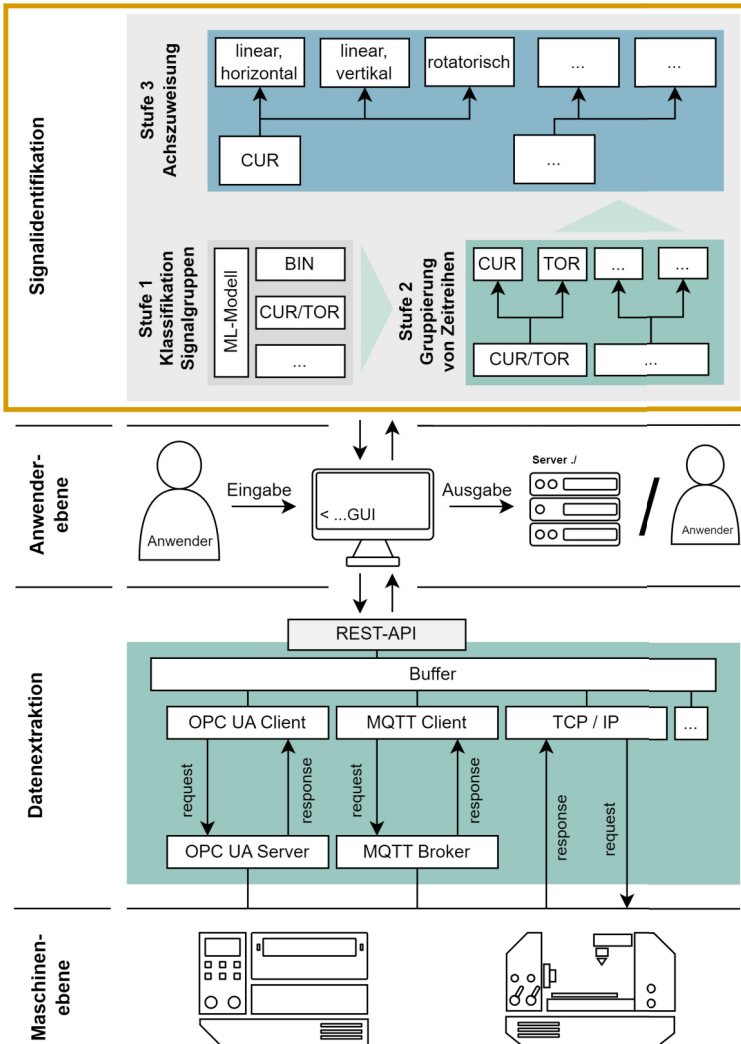


Abbildung 5-35: Einordnung des Ansatzes zur Signalidentifikation durch ML-Modelle und analytische Regeln in den Gesamtprozess in Anlehnung an Gönheimer & Ströbel et al. (2023b)

In der ersten Stufe werden die Zeitreihen zunächst durch ein ML-Modell klassifiziert. Dabei unterscheidet das ML-Modell zunächst zwischen bekannten und unbekanntem Daten. Zeitreihen, die als bekannt klassifiziert werden, werden anschließend den Zielklassen **BIN**, **CTRL_DIFF**, **CYC** und **POS/CYC** in Abhängigkeit ihrer berechneten Zugehörigkeit zugewiesen. Anschließend werden durch eine analytische Regel die zyklischen Zeitreihen von den Positionssignalen getrennt. Dadurch ergeben sich ohne die unbekanntem Klassen fünf Zielklassen, die in der nächsten Stufe weiterverarbeitet werden.

In Stufe 2 liegt der Schwerpunkt auf der Unterscheidung der Soll- und Ist-Positionen sowie der Paarbildung von Zeitreihen innerhalb der **CUR/TOR** Zielklasse. Durch die Paarbildung sollen zusammengehörige Strom- und Drehmomentsignale gruppiert werden, welche als Grundlage für die Achszuweisung in der nächsten Stufe dienen.

In Stufe 3 werden die bereits identifizierten Soll-Positionen durch eine erneute Paarbildung mit den **CUR/TOR**-Signalen verknüpft. Zusätzlich werden auch die Regeldifferenzsignale durch Korrelationen diesen zugeordnet. Anschließend werden die Strom- und Drehmomentsignale zunächst in Signale der Linearachse und der Spindel aufgeteilt und anschließend die Linearachse weiter in horizontal und vertikal. Zuletzt werden die darin enthaltenen Strom- und Drehmomentsignale voneinander unterschieden, um letztendlich einzelne identifizierte Zeitreihen für jede Achse vorliegen zu haben.

5.3.2 Datensätze

Die Aufzeichnungen aus Kapitel 5.2.2 wurden auch für die Weiterentwicklung in Kapitel 5.3 verwendet. Zusätzlich wurden jedoch auch weitere Datensätze mit der Deckel Maho DMC 60H-HDM aufgenommen, wodurch die Datenbasis deutlich erweitert wurde. Hierbei handelt es sich um Signale der Soll- und Ist-Positionen, Ströme, Drehmomente, Regeldifferenzen sowie zyklische und binäre Zeitreihen.

Um die Datengrundlage nochmals zu vergrößern und diversifizieren, wurden im Rahmen von Data Augmentation vorhandene Aufzeichnungen als Grundlage für die Generierung weiterer Datensätze verwendet. Da Data Augmentation mittlerweile ein gängiges Verfahren ist und auch in (Farahani & McCormick et al. 2023b) zu tendenziell besseren Ergebnissen geführt hat, soll untersucht werden, wie sich die generierten Datensätze auf die Ergebnisse auswirken. Bei der Durchführung wurden binäre und zyklische Signale ausgeschlossen. Die Generierung wurde durch eine

Wertebereichstransformation und durch eine Zeitbereichstransformation mit Window Warping durchgeführt. Beim Window Warping werden die zu bearbeitenden Zeitbereiche zufällig ausgewählt anstelle der kompletten Zeitreihe.

Als Datengrundlage für die Zielklasse der unbekanntem Signale wurden sechs unterschiedliche Datensätze verwendet, die nicht von Werkzeugmaschinen stammen. Dabei handelt es sich um Bewegungsdaten von Versuchspersonen, chemische Daten einer Messung zur Luftverschmutzung, Zustandsdaten eines Raumes mit Temperatur, Hellichtigkeit und Luftfeuchtigkeit sowie weitere chemische Messungen von unterschiedlichen Gasgemischen. Die Auswahl der Datensätze beruht auf dem breiten Spektrum der Signaltypen, wodurch das entwickelte Modell gut auf unbekannte Signale getestet werden kann, die im Training nicht berücksichtigt wurden.

- Wearable Stress and Affect Detection Data Set (Schmidt & Reiss et al. 2018)
- Air Quality Data Set (Vito & Massera et al. 2008)
- Occupancy Detection Data Set (Candanedo & Feldheim 2016)
- Gas Sensor Array under Dynamic Gas Mixtures Data Set (Fonollosa & Sheik et al. 2015)
- Satellite image data and radar data for classification of croplands (Khosravi & Alavi-panah 2019)
- Bitcoin transactions (Akcora & Li et al. 2021)

5.3.3 Stufe 1 – Machine Learning-basierte Klassifikation

In diesem Kapitel wird die erste Stufe des mehrstufigen Ansatzes entwickelt. Dieser besteht fast ausschließlich aus einer ML-basierten Klassifikation durch ein ML-Modell. Dafür werden zunächst die bestehenden Modelle aus Kapitel 5.2 als Basis verwendet. Über einen Vergleich der Genauigkeiten mit den erweiterten Datensätzen wird das beste ML-Modell ausgewählt und für alle weiteren Schritte als Grundlage verwendet. Nach der Klassifikation werden durch analytische Regeln die zyklischen Signale von den Positionssignalen extrahiert. In Abbildung 5-36 ist der Ablauf der Stufe 1 dargestellt.

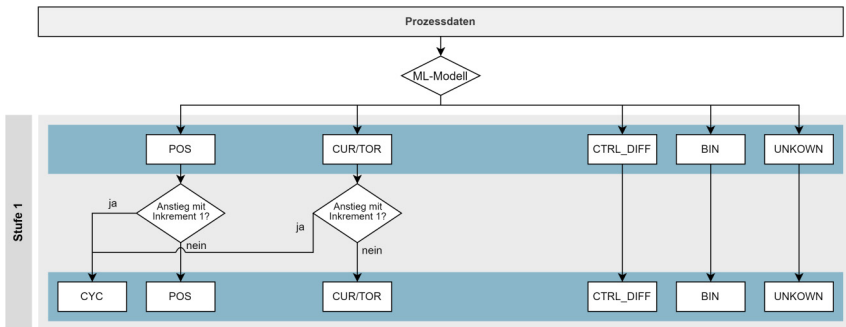


Abbildung 5-36: Ablaufplan der Stufe 1 nach A_Baucks (2021)

5.3.3.1 ML-Modell Auswahl

Bevor die zusätzliche Eigenschaft zur Erkennung unbekannter Daten implementiert wird, werden die ML-Modelle aus Kapitel 5.2 miteinander verglichen. Dabei handelt es sich um die ML-Modelle FCN, ResNet, LSTM und RanFor. Die grundsätzliche Architektur wird übernommen. Die Zielklassen werden für alle Modelle auf **BIN**, **CTRL_DIFF**, **CUR/TOR** und **POS/CYC** festgelegt. Diese werden mit den bereits bekannten Daten erneut trainiert, jedoch mit dem Unterschied, dass die Zielklassen für alle Modelle identisch sind. Dadurch wird der Abstraktionsgrad mit dem Ziel der Steigerung der Genauigkeit verringert. Außerdem wird so die Vergleichbarkeit der Modelle besser gewährleistet. Anschließend werden die zyklischen Signale aus der Zielklasse **POS/CYC** extrahiert. Daraus werden die Genauigkeiten aller ML-Modelle berechnet und miteinander verglichen. In Abbildung 5-37 sind die Ergebnisse der Analyse dargestellt.




Abbildung 5-37: Vergleich der Genauigkeit unterschiedlicher ML-Modelle mit erweitertem Datensatz zur Validierung nach A_Baucks (2021)

Bei der Betrachtung der Ergebnisse aus Abbildung 5-37 sind die Ergebnisse für die Klassen **BIN** und **CYC** für alle ML-Modelle sehr ähnlich. Alle Modelle klassifizieren fast fehlerlos alle vorhandenen Samples dieser Klassen. Bei der Klasse **pos** wurden alle Samples vom ResNet und LSTM korrekt klassifiziert. Das FCN und der RanFor schneiden mit 10 und 37 Fehlklassifizierungen schlechter ab. Die Klasse **CUR/TOR** wird besonders von ResNet und FCN sehr gut erkannt, während das LSTM und der RanFor einige Signale falsch zuordnen. Die Regeldifferenzen werden nur vom LSTM

größtenteils korrekt klassifiziert. Bei der Auswahl des geeignetsten ML-Modells muss zusätzlich berücksichtigt werden, dass Fehlklassifizierungen abhängig von der Klasse zu weiterer Modellungenauigkeit führen, da schließlich die Zuordnungen die Basis für zwei weitere Berechnungsstufen sind. Eine korrekte Klassifikation bestimmter Klassen wie **POS** und **CUR/TOR** ist damit essentiell. Ohne diese Rahmenbedingung wäre das LSTM mit den wenigsten Fehlklassifizierungen das beste Modell, welches sich besonders bei den Regeldifferenzen absetzt, gefolgt vom ResNet. Für die Auswahl des besten Modells muss neben der Anzahl korrekt zugeordneter Samples zusätzlich berücksichtigt werden, dass die Ergebnisse aus Stufe 1 in den nachfolgenden Stufen die Grundlage für weitere Berechnungen bilden. Dabei werden die **CUR/TOR**-Signale häufiger für Berechnungen verwendet als die Regeldifferenzsignale. Da das LSTM bei **CUR/TOR** einige Samples falsch zuweist und diese Klasse besonders wichtig für den weiteren Verlauf ist, wird das ResNet dem LSTM vorgezogen.

5.3.3.2 Einführung einer Klasse für unbekannte Daten

Nachdem in Kapitel 5.3.3.1 das ResNet für die weitere Entwicklung als bestes ML-Modell ausgewählt wurde, soll dieses nun um die Funktion zur Erkennung unbekannter Signale mittels eines Schwellenwertes ergänzt werden. Das Ziel dabei ist, anhand der aufgezeichneten Zeitreihen zu erkennen, ob diese generell einer der vorhandenen Zielklassen entsprechen. Falls nicht, müssen diese Zeitreihen vor der Klassifizierung entfernt werden. Signale, die als unbekannt gelten, wären beispielsweise die Temperatur oder Luftfeuchtigkeit, die durch Sensoren erfasst werden und nicht Teil von Werkzeugmaschinen sind. Als Datengrundlage werden die in Kapitel 5.3.2 aufgelisteten Datensätze verwendet, welche Zeitreihen aus Bewegungsaufzeichnungen, chemischen Messungen sowie Zustandsdaten eines Raumes beinhalten.

Für die Klassifikation der Samples müssen zunächst die Vektoren mit den Labels umgeschrieben werden, da die Zuordnungswahrscheinlichkeit in weiteren Schritten verwendet wird. Ursprünglich werden die Klassen der Samples in einem $n \times 1$ -Vektor dargestellt, wobei jeder Eintrag der Klasse des Samples entspricht. Dieser Vektor wird nun durch eine $n \times 5$ -Matrix ersetzt. Jede Spalte repräsentiert eine Klasse und deren Einträge entsprechen den idealen Zuteilungswahrscheinlichkeiten der Samples. Wenn das Sample aus Zeile i der Klasse j angehört, wird der j -te Eintrag aus Zeile i auf 1 gesetzt und die restlichen auf 0. Samples, die der Klasse **UNKNOWN** angehören, erhalten zu jeder Klasse den Eintrag 0,2, da die Wahrscheinlichkeit für jede Klasse

gleich sein muss. Zusätzlich müssen die Samples binär gekennzeichnet werden, um deren Zugehörigkeit zu den bekannten oder unbekanntem Zeitreihen zu bestimmen. Dafür wird ein weiteres Label mit zwei Spalten eingeführt, wobei in der ersten Spalte durch eine 1 gekennzeichnet wird, dass es sich um bekannte Daten handelt, oder durch eine 0 bei unbekanntem. Die zweite Spalte hingegen kennzeichnet unbekanntem Signale mit einer 1 und die bekannten mit einer 0.

Um bekannte und unbekanntem Daten voneinander zu unterscheiden, werden die Arbeiten von Dhamija & Günther et al. (2018) als Grundlage verwendet. Dabei werden zwei Fehlerfunktionen benötigt. Die Softmax-Entropie der unbekanntem Daten muss vergrößert werden, wodurch die explizite Klassenzuweisung schwerer wird. Gleichzeitig muss die euklidische Distanz zwischen den unbekanntem Daten verringert und die Distanz der bekannten Daten vergrößert werden, um unbekanntem und bekannte Daten besser differenzieren zu können. Dafür wird die Entropic Open-Set Loss-Funktion und die Objectosphere Loss-Funktion aus (Dhamija & Günther et al. 2018) eingesetzt. Die Entropic Open-Set Loss-Funktion kann nicht direkt übernommen werden. Diese ist der Categorical Cross Entropy Loss-Funktion sehr ähnlich und benötigt als Eingangsvektoren mit den Labels die Form $n \times 1$. Die unbekanntem Daten können jedoch keiner der fünf existierenden Klassen zugeordnet werden, weshalb eine Methode entwickelt werden muss, um die Labels in Matrixform übergeben zu können. Zur Bestimmung des Categorical Cross Entropy Loss wird die Formel 5-1 aus (Nathaniel 2021)¹⁰ implementiert.

$$CCE = -\frac{1}{N} * \sum_{i=0}^N \sum_{j=0}^J y_j * \log(\hat{y}_j) + (1 - y_j) * \log(1 - \hat{y}_j) \quad 5-1$$

N : Anzahl der Samples

J : Anzahl der Klassen

y_j : wahre Zuordnungswahrscheinlichkeit der Klasse j

\hat{y}_j : berechnete Zuordnungswahrscheinlichkeit der Klasse j

¹⁰ Nathaniel, J. (2021), *Understanding PyTorch Loss Functions: The Maths and Algorithms (Part 1)*. A step-by-step guide to the mathematical definitions, algorithms, and implementations of loss functions in PyTorch. <https://towardsdatascience.com/understanding-pytorch-loss-functions-the-maths-and-algorithms-part-1-6e439b27117e> [15.01.2024].

Da jedoch bei einer errechneten Zuordnungswahrscheinlichkeit von $\hat{y}_j = 0$ oder $\hat{y}_j = 1$ einer der beiden logarithmischen Terme negativ unendlich wird, werden die Eingabewerte auf $\hat{y}_j = 1 * 10^{-7}$ beziehungsweise auf $\hat{y}_j = 1 - 1 * 10^{-7}$ gesetzt, falls sie außerhalb der beiden Werte liegen sollten.

Um die beiden Fehlerfunktionen in das bestehende ResNet zu implementieren, muss die Architektur des ML-Modells so verändert werden, dass zwei Outputs erzeugt werden. In (Dhamija & Günther et al. 2018) werden dazu zwei aufeinanderfolgende Fully Connected Layer verwendet, bei denen die erste Schicht den Input für die Objectosphere Loss-Funktion erzeugt. Diese vergrößert die euklidische Distanz zwischen den bekannten und unbekanntem Daten. In der zweiten Schicht werden die Klassenzugehörigkeiten durch eine Softmax-Aktivierungsfunktion bestimmt, welche der Entropic Open-Set Loss-Funktion als Input gegeben werden. Die zweite Schicht existiert bereits mit einem Eingangsvektor von $n \times 321$ und einem Ausgangsvektor von $n \times 5$. Um nun die erste Schicht zu implementieren, muss diese den Eingangsvektor von $n \times 321$ übernehmen und einen Ausgangsvektor von $n \times 2$ generieren. Damit muss auch die letzte Schicht von $n \times 321$ auf $n \times 2$ geändert werden. Der ursprüngliche Ausgangsvektor der letzten Schicht wird durch diese Maßnahmen nicht verändert. Damit wird nun durch die zusätzliche Schicht ein Fehler berechnet, der Auskunft über die Zugehörigkeit von bekannten und unbekanntem Daten gibt, während die letzte Schicht die Klasse der bekannten Daten bestimmt. Über einen Grenzwert des Objectosphere Loss können unbekannte Daten erkannt werden, wodurch die Zuweisung der Softmax-Aktivierungsfunktion der jeweiligen Samples nicht weiter betrachtet wird.

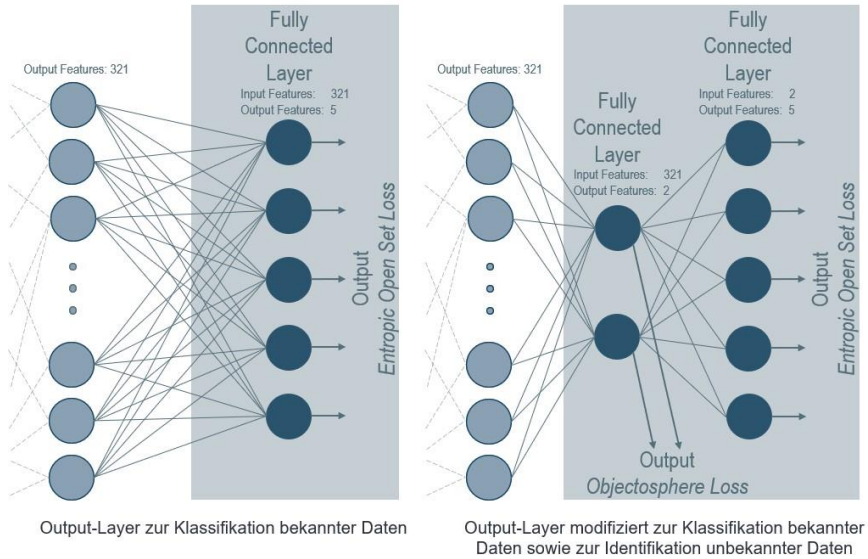


Abbildung 5-38: Modifikation des ResNet zur Unterscheidung von bekannter und unbekannter Daten nach A_Baucks (2021)

Die Trainingsdatensätze werden zu 60 % aus den fünf bekannten Klassen und zu 40 % aus den Zeitreihen der unbekannt Daten erstellt. Anschließend erfolgt ein Train-Test-Split von 50:50. Um unterrepräsentierte Klassen nicht zu vernachlässigen, wird die Klassengewichtung berücksichtigt. Der Schwellenwert für die Klassifizierung von unbekannt Daten wird zunächst auf 0,6 festgelegt.

5.3.4 Stufe 2 – Gruppierung von Zeitreihen

Nachdem in der ersten Stufe alle Zeitreihen klassifiziert wurden, werden in der Stufe 2 Regeln aufgestellt, die die Zeitreihen aus den Klassen weiter differenzieren können. Dafür werden Korrelationspaare jeweils in der Klasse **POS** und in der Klasse **CUR/TOR** gebildet. Diese müssen einen Korrelationskoeffizienten nach Spearman von 0,99 aufweisen. Bei den Positionssignalen werden die Paare gespeichert, deren Medianwerte nur um 10 % voneinander abweichen, aber auch nicht exakt gleich sind. Dadurch werden Paare aus identischen Signalen verhindert. Übrig bleiben Paare aus Soll- und Ist-Positionssignalen. Es wird dabei vorausgesetzt, dass die Ist-Positionen nicht von mehreren Sensoren erfasst werden und damit nur einmal vorkommen.

Zur weiteren Differenzierung der Korrelationspaare wird anschließend bestimmt, welches Signal vorausleitet. Da das Ist-Positionssignal regelungstechnisch immer dem Soll-Positionssignal angenähert werden muss, ist das dem Ist-Positionssignal vorausleisende Soll-Positionssignal ein typisches Merkmal zur Differenzierung beider. Die Berechnung erfolgt mittels DTW, wie in Kapitel 2.4.1.3 erläutert, wobei aufgrund des hohen Rechenaufwands nur charakteristische Stellen analysiert werden. Die Identifikation dieser Stellen wird durch die gleitende Standardabweichung mit fünf Abtastwerten durchgeführt. Die höchsten Werte entsprechen den gesuchten charakteristischen Stellen. Anschließend wird ein Zeitbereich um diese Stellen extrahiert, sodass beide Signale an der gleichen Stelle verglichen werden können. Durch DTW wird dabei ein Pfad erstellt, der die Segmente mit dem kleinsten euklidischen Abstand zueinander ausrichtet, beziehungsweise minimiert. Über die Ausrichtung kann dann festgestellt werden, welches Signal vorausleitet. In Abbildung 5-39 ist der Ablauf der Stufe 2 dargestellt.

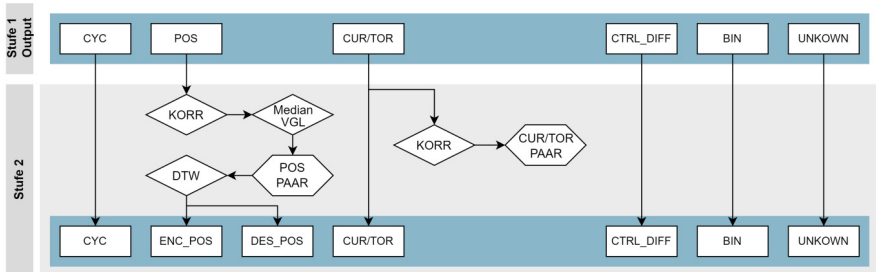


Abbildung 5-39: Ablaufplan der Stufe 2 nach A_Baucks (2021)

5.3.5 Stufe 3 – Achszuweisung

Das Ziel der dritten Stufe ist die Gruppierung von Signalen, die jeweils der gleichen Achse zugehören. Als Endergebnis sollen Achscluster entstehen, bei denen die Signale bekannt sind und gleichzeitig auch die Einteilung der Achscluster in linear-horizontal, linear-vertikal sowie rotatorisch. In Abbildung 5-40 ist der Ablauf der Stufe 3 dargestellt.

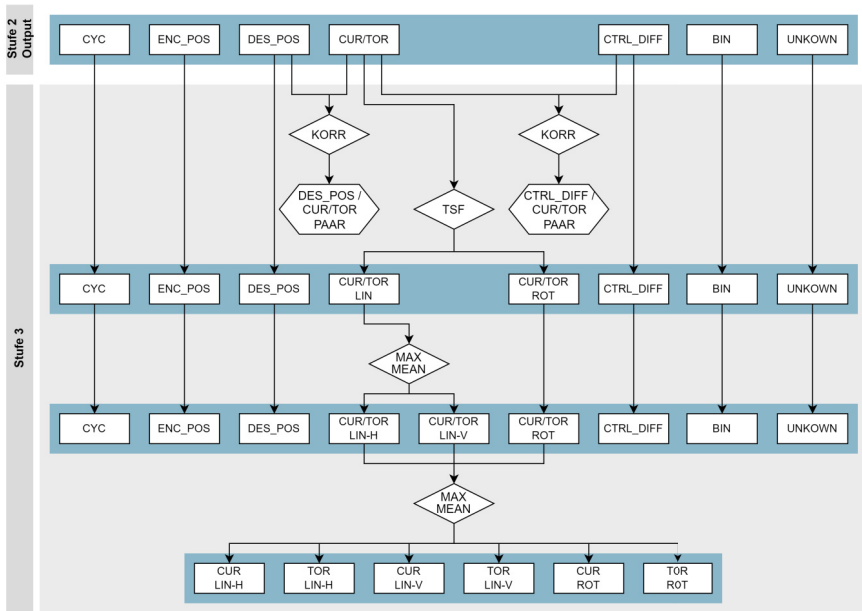


Abbildung 5-40: Ablauf der Stufe 3 nach A_Baucks (2021)

Für eine erste Aufteilung in Achscluster werden jeweils die Soll-Positionssignale und die Regeldifferenzsignale mit den Strom- und Drehmomentsignalen untersucht. Die Zugehörigkeit der Regeldifferenzsignale zu den Strom- und Drehmomentsignalen wird über eine einfache Plausibilitätsprüfung durchgeführt. Dafür wird der Korrelationskoeffizient nach Pearson berechnet. Falls ein Signalpaar einen Korrelationskoeffizienten größer gleich 0,8 besitzt, werden diese Signale als eine Achse gruppiert. Die Gruppierung von Positionssignalen mit den Strom- und Drehmomentsignalen erfolgt durch den Korrelationskoeffizienten nach Pearson, nachdem die Positionssignale zweifach abgeleitet werden. Wird der Grenzwert von 0,8 erreicht, werden die Signale als eine Achse gruppiert.

Nachdem die **CUR/TOR** Signale mit Signalen der gleichen Achse in Verbindung gesetzt sind, werden diese über einen Time Series Forest Classifier (TSF) in Signale der linearen und rotatorischen Achse aufgeteilt. Der TSF ist dem RanFor ähnlich, hat jedoch den Vorteil, dass zeitliche Zusammenhänge erhalten bleiben, die wiederum Einfluss auf die Klassifikation haben (Löning & Bagnall et al. 2019). Da nur die Strom- und

Drehmomentsignale in linear und rotatorisch unterschieden werden sollen, wird der Datensatz auch auf nur Strom- und Drehmomentsignale reduziert. Die Trainingsdaten mit ihrer Länge m werden in \sqrt{m} Intervalle aufgeteilt, woraus vier Merkmale berechnet werden. Bei den Merkmalen handelt es sich um die Standardabweichung, den Gradient des Intervalls sowie drei Merkmale aus Tabelle 9, welche die minimale und maximale Wertedifferenz zweier Zeitpunkte (min_diff , max_diff) und die Summe der Differenzen von allen aufeinanderfolgenden Zeitpunkten (sum_diff) beinhalten. Auf der Grundlage der Erkenntnisse von Kapitel 5.2.6 wird der TSF mit einem Ensemble von 50 Entscheidungsbäumen und einer maximalen Tiefe von 15 Verzweigungen erstellt. Für das Training wird ein Klassenausgleich verwendet, da mehr Signale der linearen Achse existieren als von der rotatorischen. Durch den Klassenausgleich werden weniger vorkommende Signale beim Training stärker gewichtet. Außerdem wird das Modell mit einem 75:25 Train-Test-Split trainiert. Die Zuweisung eines Signals erfolgt durch die überwiegende Mehrheit der zugeteilten Samples. Im Fall einer Gleichverteilung entscheidet die Summe aller berechneten Wahrscheinlichkeiten der einzelnen Samples über die Zuordnung des Signals.

Um die Strom- und Drehmomentsignale der Linearachsen in horizontal und vertikal unterscheiden zu können, wird der Einfluss der Schwerkraft auf die Komponenten genutzt. Da die Motoren der vertikalen Achse gegen die Schwerkraft arbeiten müssen, ist der benötigte Strom dieser Achse größer als die Ströme der horizontalen Achsen. Dafür werden die Mittelwerte der **CUR/TOR** linear berechnet. Das Paar mit dem höchsten Mittelwert wird der Vertikalachse zugeordnet. Die anderen Signalpaare gehören den horizontalen Achsen an. Dieser Aspekt ist hinsichtlich seiner Übertragbarkeit unter anderem im Hinblick auf den Gewichtsausgleich einiger Werkzeugmaschinen für eine spätere Evaluierung der Generalisierbarkeit zu prüfen.

Da bisher die Strom- und Drehmomentsignale nur als Paar vorliegen und nur deren Ausführung in horizontal, vertikal und rotatorisch bekannt ist, werden diese nun in einzelne Strom- und Drehmomentsignale aufgeteilt. Dafür wird der DTW-Ansatz zur Differenzierung von Soll-Positions- und Ist-Positionssignalen aus Kapitel 5.3.4 übernommen, da nach einer Untersuchung festgestellt wurde, dass auch das Drehmomentsignal immer dem Stromsignal vorausgeht.

5.3.6 Ergebnisse und Bewertung

In diesem Kapitel werden die Ergebnisse unterschiedlicher Untersuchungen dargestellt und bewertet, um abschließend zu jeder Stufe die optimalen Berechnungsschritte zu verwenden. Dafür werden zunächst die Erweiterungen der Trainingsdaten analysiert. Anschließend werden die Ergebnisse der Eigenschaft zur Erkennung unbekannter Signale untersucht sowie die Ergebnisse der Stufe 2 und 3. Abschließend wird das Gesamtsystem einheitlich betrachtet.

5.3.6.1 Einfluss der Erweiterung von Trainingsdaten auf das ML-Modell

In diesem Kapitel wird der Einfluss der Diversifikation der Daten analysiert. Dabei werden mehrere ResNet mit jeweils zwei unterschiedlichen Zusammensetzungen aus Trainingsdaten trainiert. Unbekannte Signale werden hierfür nicht betrachtet. Als Grundlage dient das ResNet aus der Abbildung 5-33, welches mit Daten einer Prozessaufzeichnung trainiert wurde. Diese Aufzeichnungen werden durch augmentierte Daten, welche in Kapitel 5.3.2 beschrieben sind, ergänzt. Ein weiteres ResNet wird neben den augmentierten Daten zusätzlich noch um weitere Datenaufzeichnungen eines realen Prozesses trainiert.

In Abbildung 5-41 ist der Trainingsverlauf mit den zusätzlichen augmentierten Daten dargestellt. Es ist erkennbar, dass sich die Trainings- und Testgenauigkeit sehr ähnlich verhalten, wobei ab Epoche 600 die Testgenauigkeit nahezu konstant bleibt, während die Trainingsgenauigkeit erst ab der Epoche 800 abflacht. Die maximale Trainingsgenauigkeit liegt bei 99,9 % und die maximale Testgenauigkeit bei 99,2 %.




Abbildung 5-41: Trainingsverlauf des ResNet durch die Ergänzung von augmentierten Daten nach A_Baucks (2021)

In Abbildung 5-42 ist der Trainingsverlauf mit den zusätzlichen augmentierten Daten sowie weiteren Prozessdaten abgebildet. Hier unterscheiden sich die Trainings- und Testgenauigkeit deutlich weniger als beim Training mit den originalen und augmentierten Daten. Die maximale Trainingsgenauigkeit liegt bei 99,5 % und die maximal Testgenauigkeit bei 99,2 %.

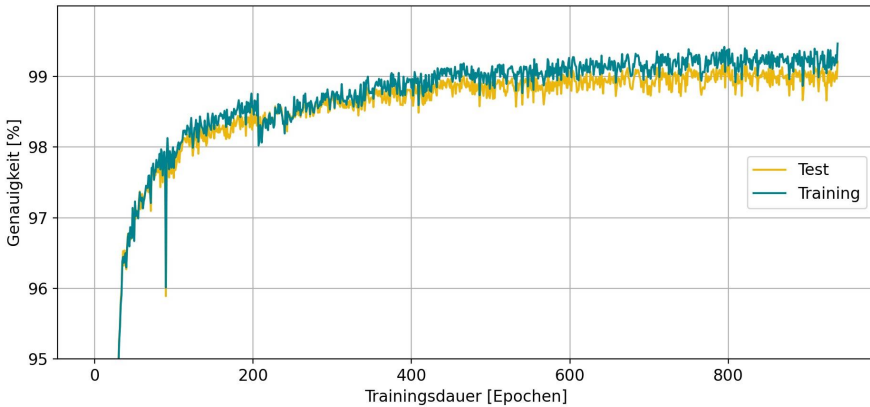


Abbildung 5-42: Trainingsverlauf des ResNet durch die Ergänzung von augmentierten und weiteren Prozessdaten nach A_Baucks (2021)

Im Vergleich zu diesen beiden Modellen steht das ResNet aus Abbildung 5-33, welches nur mit den ursprünglich vorhandenen Daten aus Kapitel 5.2.2 trainiert wurde. Dieses erreicht eine maximale Testgenauigkeit von 98,6 %. Durch die Ergänzung der Trainingsdaten konnte demnach eine Verbesserung der Testgenauigkeit um 0,6 % erreicht werden.

Durch weitere Prozessdaten, welche nicht im Training verwendet wurden, soll validiert werden, wie gut diese klassifiziert werden können. Dadurch soll eine abschließende Aussage gegeben werden, inwiefern die Ergänzung der Daten sinnvoll ist. Die Ergebnisse aller drei ML-Modelle sind in Abbildung 5-43 dargestellt. Bei den binären und zyklischen Signalen können keine Unterschiede zwischen den Modellen festgestellt werden. Diese werden zu 100 % korrekt klassifiziert. Die Regeldifferenzsignale sind für alle Modelle weiterhin nicht zu identifizieren. Die Strom- und Drehmomentsignale werden vom ursprünglichen ResNet und vom ResNet, welches mit zusätzlichen augmentierten Daten trainiert wurde, zu 100 % erkannt. Das um die real erweiterten Daten ResNet konnte 171 von 180 Samples korrekt klassifizieren. Bei den Positionssignalen konnten durch die Erweiterung von Trainingsdaten deutlich mehr Samples korrekt klassifiziert werden. Während das ursprüngliche Netz 152 Samples korrekt klassifizieren konnte, erreichten die anderen beiden ML-Modelle 179 beziehungsweise 180

mit den zusätzlichen Prozessdaten. Dadurch kann geschlussfolgert werden, dass die Erweiterung der Daten grundsätzlich einen positiven Einfluss auf die Klassifizierungsfähigkeit der ResNet-Modelle besitzt.




Abbildung 5-43: Validierung der ResNet-Modelle mit einem Datensatz, der nicht im Training verwendet wurde, nach A_Baucks (2021)

5.3.6.2 Erkennung unbekannter Signale

Für die Erkennung der unbekanntem Signale wurde das ResNet 450 Epochen trainiert. Damit eine fundierte Aussage über die Eignung des Modells getroffen werden kann, werden die Bewertungsmaße aus (Dhamija & Günther et al. 2018) herangezogen. Dabei handelt es sich um die Correct Classification Rate (CCR), welche als Maß für die bekannte Klassen verwendet wird und um die False Positive Rate (FPR) als Maß für die falsch zugeordneten unbekanntem Signale in den bekannten Klassen. Ein gutes Modell zeichnet sich deshalb durch eine hohe CCR und niedrige FPR aus.

In Abbildung 5-44 ist der Trainingsverlauf der CCR und FPR über die Dauer von 450 Epochen dargestellt. Bei den Trainingsdaten wurde eine CCR von 99,9 % sowie eine FPR von 0,1 % erreicht. Die Testdaten liegen bei 99,1 % beziehungsweise 0,7 %. Nach 300 Epochen wird keine Verbesserung mehr erzielt.




Abbildung 5-44: Verlauf der CCR und FPR beim Training des ResNet nach A_Baucks (2021)

Die Validierung erfolgt mit den letzten beiden Datensätzen der unbekannt Daten aus Kapitel 5.3.2, welche Satellitenbilddaten, Radardaten und Bitcoin Transaktionen beinhalten. Davor werden jedoch die Schwellenwerte zur Klassifizierung von bekannten und unbekannt Daten analysiert. Dadurch soll festgestellt werden, ab wann ein Sample als unbekannt oder bekannt gelten darf. Für die Entscheidung der Zuweisungen von Samples werden der Entropie- und der Klassifikationsschwellenwert als Hilfsmittel verwendet. Der Klassifikationsschwellenwert gibt die minimale Wahrscheinlichkeit an, mit der ein Sample einer Klasse zugeordnet wird. Der Entropie-Schwellenwert gibt an, bis zu welcher Wahrscheinlichkeit ein Sample als unbekannt gewertet wird. Da die Zuordnung eines vollständigen Signals von den Zuordnungen der einzelnen Samples abhängt, soll durch die beiden Schwellenwerte eine sichere Aussage getroffen werden. Dadurch werden bei der Zuordnung des ganzen Signals nur Samples berücksichtigt, die definitiv einer Klasse angehören oder definitiv unbekannt sind. Alle Samples, die nicht sicher zugeordnet werden können, gelten als „unsicher“ und werden nicht bei der finalen Zuordnung des Signals berücksichtigt.

Zur Bestimmung von geeigneten Schwellenwerten sind in Abbildung 5-45 jeweils die Optima von FPR (a) und CCR (b) in Abhängigkeit des Entropie- und Klassifikations-Schwellenwerts dargestellt. Das Optimum der FPR wird bei 0,02 mit einem Klassifikations-Schwellenwert von 0,95 und einem Entropie-Schwellenwert von 0,75 erreicht. Die CCR erreicht das Optimum bei 0,3 bei einem Klassifikations-Schwellenwert von 0,5 und einem Entropieschwellenwert von 0,3.

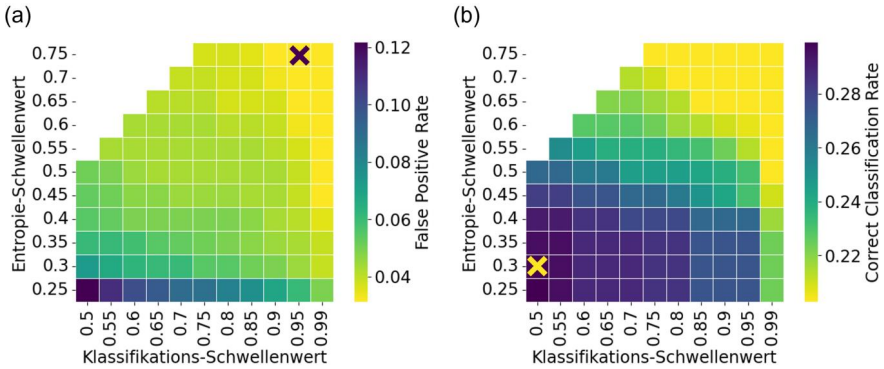


Abbildung 5-45: Abhängigkeit von FPR (a) und CCR (b) mit Entropie- und Klassifikations-Schwellenwert (x: Optimum FPR (a) und CCR (b)) nach A_Baucks (2021)

Aufgrund der stark abweichenden Schwellenwerte in Abbildung 5-45 muss ein Kompromiss gefunden werden, der eine zuverlässige Bewertung beider Methoden ermöglicht. In einer weiteren Analyse wird die Summe der FPR und der Incorrect Classification Rate ($1 - CCR$) berechnet und wieder in Abhängigkeit der Entropie- und Klassifikations-Schwellenwerte dargestellt. In Abbildung 5-46 ist das Ergebnis dargestellt. Das Optimum befindet sich bei einem Klassifikation-Schwellenwert von 0,55 und einem Entropie-Schwellenwert von 0,4.




Abbildung 5-46: Abhängigkeit der kombinierten FPR und CCR von dem Entropie- und Klassifikations-Schwellenwert (x: Optimum von FPR und CCR) nach A_Baucks (2021)

Um die zusätzliche Eigenschaft zur Identifizierung von unbekanntem Daten zu validieren, wird das mit unbekanntem Daten trainierte Modell mit dem ResNet aus dem Kapitel 5.3.6.1 verglichen. Das mit den unbekanntem Daten trainierte Modell wird nachfolgend als ResNet+ bezeichnet. Für beide Modelle werden die soeben ermittelten Entropie- und Klassifikations-Schwellenwerte verwendet. Alle Signale werden auf jeweils 50 Samples reduziert, von denen mindestens 10 als bekannt oder unbekannt klassifiziert werden müssen, um schließlich das Signal zu identifizieren.

In Abbildung 5-47 sind die Ergebnisse der Klassifikationsergebnisse des ResNet+ und ResNet dargestellt. Die unbekanntem Signale werden vom ResNet+ fast vollständig korrekt klassifiziert, während das ResNet nahezu alle falsch zuordnet. Die binären Signale können von beiden ML-Modellen vollständig korrekt klassifiziert werden. Die Regeldifferenzsignale werden wiederum von beiden ML-Modellen nicht identifiziert. Die Strom- und Drehmomentsignale werden vom ResNet+ zu 76,6 % korrekt klassifiziert von vom ResNet zu 99,1 %. Bei den Positionssignalen ist ein erheblicher Unterschied zu erkennen. Während das ResNet eine Genauigkeit von 76,6 % erreicht, kann das ResNet+ nur 18,6 % der Signale korrekt identifizieren. Auch die zyklischen Signale werden vom ResNet zu 100 % identifiziert, während das ResNet+ alle Samples als unbekannt

einstuft. Generell ist festzustellen, dass das ResNet+ 59,1 % der Signale der bekannten Klasse als unbekannt klassifiziert, wohingegen es beim ResNet nur 7,8 % sind.




Abbildung 5-47: Validierung des ResNet+ und ResNet mit den ermittelten Entropie- und Klassifikations-Schwellenwerten nach A_Baucks (2021)

5.3.6.3 Stufe 2 und 3

Für die Auswertung der Stufe 2 und 3 werden die Signale jeweils vorsortiert, um die Ergebnisse unabhängig von der Zuordnung aus Stufe 1 beurteilen zu können. Die Klassifikationsgenauigkeit der Datensätze ist in Abbildung 5-48 dargestellt.




Abbildung 5-48: Klassifikationsgenauigkeit unterschiedlicher Datensätze in Stufe 2 und 3 nach A_Baucks (2021)

Die Positionsdaten werden zu 80 % korrekt in Soll- und Ist-Positionen klassifiziert. Bei der Zuordnung der Strom- und Drehmomentsignale in Linear- und Rotationsachsen wurde ein TSF entwickelt, der die Signale unterscheiden soll. Beim Training des ML-Modells wurde auf dem Test-Split eine Genauigkeit von 99,53 % erzielt. Durch eine Kreuzvalidierung mit 10 Durchläufen konnte ebenfalls eine Genauigkeit von 99,55 % mit einer Standardabweichung von 0,09 % erreicht werden. Auf den ideal vorsortierten Validierungsdaten wird eine Genauigkeit von 75 % erzielt. Die weitere Differenzierung mittels DTW führt zu einer Genauigkeit von nur 38 %.

5.3.6.4 Bewertung Gesamtmodell

Mit den Ergebnissen aus Kapitel 5.3.6 kann festgestellt werden, dass das ResNet+ mit der Eigenschaft, unbekannte Daten zu erkennen, eine deutlich niedrigere Genauigkeit erzielt als das ursprüngliche ResNet. Auch wird ein Großteil der bekannten Signale fälschlicherweise als unbekannt klassifiziert. Deshalb wird für die Bewertung des gesamten Identifikationsprozesses das ursprüngliche ResNet verwendet. Die Stufen 2 und 3 bleiben jedoch unverändert.

Das ResNet erzielt bei den binären, zyklischen, Positions- und Strom- und Drehmomentsignalen eine Genauigkeit von 97,5 %. Dadurch ergibt sich eine nahezu ideale Klassifizierung, weshalb diese den Ergebnissen aus 5.3.6.3 entsprechen.

5.3.6.5 Fazit und Optimierungsbedarf

Nachdem die einzelnen Stufen und das Gesamtmodell auf deren Genauigkeiten getestet wurden, werden in diesem Kapitel die Defizite des Modells ermittelt. Zunächst besteht weiterhin das Problem, dass Regeldifferenzsignale in Stufe 1 nicht identifiziert werden können und größtenteils den Strom- und Drehmomentsignalen zugeordnet werden. Die Erkennung unbekannter Signale funktioniert insofern gut, als dass auch tatsächlich unbekannte Signale als solche größtenteils identifiziert werden. Allerdings werden auch besonders viele bekannte Signale als unbekannt klassifiziert, wodurch die Genauigkeit des ML-Modells drastisch verringert wird. Hier besteht die Herausforderung, die Schwellenwerte der Entropie und Klassifikation so zu ermitteln, dass unbekannte Signale weiterhin erkannt, aber bekannte Signale den fünf Klassen zugewiesen werden können. Die Regel zur Aufteilung der Positionssignale in Soll- und Ist-Positionen funktioniert, sofern keine Ist-Positionssignale mehrfach vorkommen. Die Regel berücksichtigt an diesem Punkt keine Duplikate.

Durch die fehlerhaften Klassifikationsergebnisse der Regeldifferenzen aus Stufe 1 in die Strom- und Drehmomentklasse entsteht in Stufe 3 ein Problem der Korrelationsbeziehungen zwischen diesen und den Positionssignalen. Die Korrelation zwischen Positionssignalen und Regeldifferenzen ist häufig größer als die zwischen Positionssignalen und Strom- und Drehmoment. Dadurch entstehen falsche Zuordnungen, was wiederum zu weiteren Fehlklassifikationen in nachfolgenden Schritten führt. Auch bei der Zuteilung der Strom- und Drehmomentsignale besteht das Problem, dass exakt drei Signale oder Signalpaare der Linearachse vorliegen müssen und es keine weiteren Signale oder Duplikate geben darf, da die Regel dies nicht berücksichtigen kann. Eine Verwendung von DTW zur Bestimmung und Einteilung in Achsen der Strom- und Drehmomentsignale konnte keine zufriedenstellenden Ergebnisse liefern, da lediglich 38 % der Signale korrekt klassifiziert wurden.

Damit kann das Zwischenfazit gezogen werden, dass die Ergänzung der Korrelationsregeln zum ML-basierten Ansatz ermöglicht, Signalklassen zuverlässiger als der reine ML-Ansatz weiter in individuelle Signale aufzuteilen. Jedoch behält auch der um Korrelationsregeln ergänzte ML-Ansatz starke Defizite bei der Identifikation einiger Signale

und erlaubt keine zuverlässige Zuordnung der Signale in der Breite. Außerdem wird damit keine Signalgruppierung zur Zuordnung einzelner Vorschubachsen oder der Spindel möglich. Eine genauere Betrachtung analytischer Zusammenhänge zur Verbesserung der Identifikation über die Anwendung von Korrelationsregeln hinaus ist in Folge dieser Ergebnisse sinnvoll.

5.4 Hybrider Ansatz zur Signalidentifikation

In den Kapiteln 5.1, 5.2 und 5.3 wurden zwei grundsätzliche unterschiedliche Ansätze zur Identifikation von Maschinensteuerungssignalen entwickelt, die jeweils ihre Stärken und Schwächen besitzen. Zunächst wurde der Ansatz in Kapitel 5.1 entwickelt, der hauptsächlich auf analytischen Regeln und Domänenwissen beruht. Bei diesem liegt die Stärke vor allem darin, dass die Bewegungsabläufe der Achsen vorgegeben werden und damit die Datengrundlage in das Gesamtkonzept integriert ist. Durch die spezifische Erstellung der Referenzfahrten wurde Information in die Bewegungsabläufe gegeben, nach der anschließend in einem mehrstufigen Prozess in den Zeitreihen gesucht wird. Zusätzlich wurden kinematische Beziehungen aufgestellt, mit denen sich unterschiedliche Signale verknüpfen lassen. Zuletzt konnte gezeigt werden, dass die Signale mit sehr hoher Genauigkeit klassifiziert werden können. Während die vorgegebenen Bewegungsabläufe die Identifikation vereinfachen können, besteht darin allerdings auch der Nachteil, dass die Datenaufzeichnungen nicht unabhängig sein dürfen. Dies kann insbesondere bei einer erforderlichen hohen Verfügbarkeit der Maschinen zu Stillstandzeiten führen.

Parallel wurde ein Ansatz entwickelt, der auf ML-Verfahren beruht. Mit diesem konnten teilweise sehr gute Ergebnisse hinsichtlich der Identifikation von Maschinensteuerungssignalen erzielt werden. Allerdings gab es große Defizite hinsichtlich der Anzahl an Zielklassen und der Generalisierungsfähigkeit. Die Zielklassen wurden deshalb auf wenige limitiert, um die Signale zunächst als Signaltypen identifizieren zu können, was die Basis für eine Weiterentwicklung des Ansatzes in Kapitel 5.3 bildete. Dort wurden die Signale anhand von Merkmalen und Korrelationen weiter aufgeteilt. Dadurch konnten die unterschiedlichen Signale aus den jeweiligen Klassen so weit differenziert werden, dass individuelle Signale identifiziert werden konnten. Allerdings wurden Probleme festgestellt, die starken Einfluss auf die Genauigkeit besitzen. Beispielsweise führten falsche Zuweisungen zu Beginn der Identifikation dazu, dass durch nachfolgende Rechenschritte weitere Signale falsch klassifiziert werden, wodurch Folgefehler entstehen.

Außerdem waren vereinzelte Rechenschritte wie die Aufteilung der Strom- und Drehmomentsignale durch DTW nicht zuverlässig. Deshalb ist der isolierte Ansatz mit ML-Verfahren nicht ausreichend performant und zielführend.

In diesem Kapitel wird ein hybrider Ansatz vorgestellt, welcher eine Kombination aus der Klassifizierung durch ML-Modelle und der Identifikation durch analytische Zusammenhänge darstellt und die Stärken beider Ansätze vereint. Damit soll ein insgesamt flexibles Konzept entwickelt werden, was gleichzeitig Signale mit sehr hoher Genauigkeit identifizieren kann. Der Inhalt dieses Kapitels wurde im Rahmen der angeleiteten Abschlussarbeit (A_Dörflinger 2022) erarbeitet. Die Ergebnisse sind zusammenfassend dargestellt.

5.4.1 Konzept

In den vorherigen Kapiteln hat sich eine Identifikation von Signalen in mehreren Schritten als bewährt gezeigt. Deshalb wird auch das hybride Modell in drei klar abgrenzbare Stufen eingeteilt. In Abbildung 5-49 ist die Einordnung des hybriden Modells in den Gesamtprozess dargestellt.

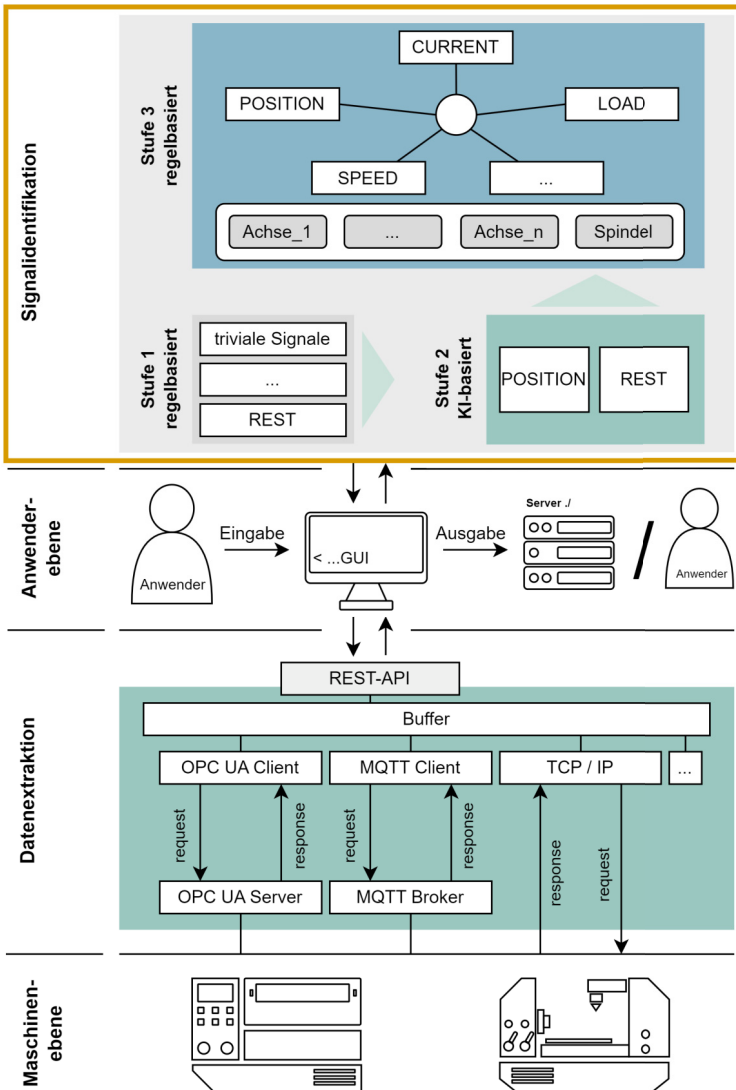


Abbildung 5-49: Einordnung des hybriden Ansatzes in Anlehnung an Gönzheimer & Ströbel et al. (2023b)

Die erste Stufe dient hauptsächlich dazu, über einfache Regelbasen bestimmte Typen von Zeitreihen zu extrahieren, um den Datensatz für nachfolgende komplexere Analysen zu verkleinern. Dafür werden einige Regeln aus Kapitel 5.1.3 als Basis verwendet. Alle verbleibenden Signale werden der Stufe 2 übergeben. Diese baut auf den Stärken der ML-Modelle aus Kapitel 5.2 und 5.3 auf. Dabei werden die Zielklassen jedoch deutlich reduziert, da mit dem analytischen Ansatz nachgewiesen werden konnte, dass allein durch die Kenntnis der Positionssignale auf weitere Signale geschlossen werden kann. Dies stellt ein essentielles Merkmal des hybriden Ansatzes dar, da die ML-Modelle nur zwischen Position und nicht-Position unterscheiden sollen. Stufe 3 basiert wiederum hauptsächlich auf den analytischen Regelbasen aus Kapitel 5.1, durch die von den Positionssignalen aus auf weitere Signale geschlossen werden kann.

Als Ergebnis werden für jede Achse die identifizierten Signale nach ihrem Typ aufgelistet. In Abbildung 5-50 ist die Struktur dargestellt, nach denen Signale identifiziert und eingeteilt werden. Die linke Seite entspricht der Vorklassifizierung. Bei dieser werden Signale eingeordnet, deren übergeordneter Typ zunächst bekannt ist, aber noch nicht das konkrete Signal. In weiteren Schritten werden diese Signale, mit der Ausnahme der POWER-Signale, analysiert und im Falle einer Identifikation den jeweiligen Achsen zugeordnet. Die POWER-Signale werden keiner Achse zugeordnet, da deren Auflösung in den vorhandenen Aufzeichnungen teilweise nicht hoch genug ist. Auf der rechten Seite der Abbildung ist das Achscluster dargestellt, in dem für jede existierende Achse eine Spalte mit vordefinierten Signaltypen erstellt wird. Die Anzahl der Achsen wird dabei im Voraus vom Anwender abgefragt. Können manche Signale der Vorklassifizierung nicht den Achsen zugeordnet werden, verbleiben sie in ihrer Klasse. Dadurch ist trotzdem noch deren übergeordneter Signaltyp bekannt, was unter Umständen für einen Anwender auch hilfreich sein kann.

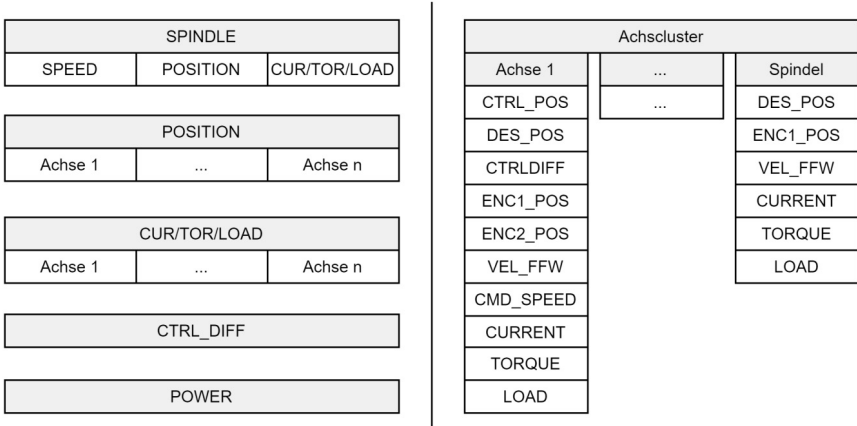


Abbildung 5-50: Ergebnisstruktur der Klassifikationen. Links: Vorklassifizierung der Signale nach (Gönzheimer & Ströbel et al. 2023b). Rechts: Struktur eines Achsklusters, welches für jede Achse angelegt wird in Anlehnung an Gönzheimer & Ströbel et al. (2023b)

In Kapitel 5.4 werden häufig Distanzen und Korrelationen gebildet. Dabei handelt es sich, wenn nicht anders formuliert, um die Minkowski-Distanz dritter Ordnung und um den Bravais-Pearson Korrelationskoeffizienten. Bei Normierungen wird grundsätzlich die Min-Max-Normierung verwendet.

5.4.2 Datensätze

Die Datensätze für den hybriden Ansatz werden aus den vorherigen Kapiteln übernommen. Dabei handelt es sich um Aufzeichnungen aus Kapitel 5.1, welche aus einem tatsächlichen Bearbeitungsprozess entstammen. Zusätzlich werden die Referenzfahrten aus Kapitel 5.1 verwendet, welche den deutlich größeren Teil der Datengrundlage bilden. In bestimmten Untersuchungen wird in den nachfolgenden Kapiteln unter anderem untersucht, ob Unterschiede der Genauigkeiten zwischen tatsächlichen Bearbeitungsprozessen und Referenzfahrten als Datengrundlage bestehen. Deshalb werden die Datensätze nach der Tabelle 15 eingeteilt. Bei den Aufzeichnungen handelt es sich um jeweils durchgeführte Versuche, weshalb in jeder Aufzeichnung eine Vielzahl an Signalen enthalten ist. Der Datensatz D2 wird hauptsächlich als Lerndatensatz

für das Gesamtsystem verwendet. Die Zeitreihen aus D3 werden dabei als Validierung verwendet.

Tabelle 15: Auflistung der verwendeten Datensätze in Anlehnung an Gönzheimer & Ströbel et al. (2023b)

Versuchsreihe	Maschine	Prozess	Aufzeichnungen	Aufnahmedauer	Signale
D1	DMC 60H	Fräsen	189	0,6 – 730 s	16 - 26
D2	DMC 60H	Referenzfahrt	3000	13 s	100
D3	DMC 60H	Referenzfahrt	840	13 s	100

5.4.3 Stufe 1 – Datenvorverarbeitung

Mit der Verwendung von ML-Verfahren in Kapitel 5.2 und 5.3 konnte festgestellt werden, dass eine hohe Anzahl an Zielklassen zu komplexen Zielfunktionen führt. Dadurch erhöht sich die Fehleranfälligkeit bei der Klassifikation, wodurch die Genauigkeiten stark verringert werden können (Gönzheimer & Ströbel et al. 2023a). In Kapitel 5.1 wurde mit dem analytischen Ansatz gezeigt, dass es bestimmte Signaltypen gibt, die sich sehr leicht mit analytischen Regelbasen bestimmen lassen. Durch eine sinnvolle Reduktion des Datensatzes in Stufe 1 kann die Komplexität drastisch reduziert werden, was zur Folge hat, dass auch die ML-Modelle genauer sein können. Deshalb wird in Stufe 1 eine Datenvorverarbeitung durchgeführt, um die trivialen Signale zu bestimmen und somit die Größe des Datensatzes stark zu reduzieren.

Als Anhaltspunkt werden die Klassen aus Kapitel 5.1.3 übernommen und um weitere ergänzt. Die bereits bestehenden Klassen sind **NAN**, **NULL**, **BIN**, **CONST**, **CYCLE**. Weiterhin werden Duplikate (**DUPL**), Regeldifferenzen (**CTRL_DIFF**) und rauschende Signale (**NOISE**) in Stufe 1 identifiziert. Nachfolgend wird kurz auf die jeweiligen Maßnahmen zur Bestimmung der Signale eingegangen.

DUPL – Identifikation von identischen Zeitreihen

Da in Datensätzen Zeitreihen mit identischen Werten existieren können und diese keinen Mehrwert bieten, wird die Klasse für Duplikate eingeführt. Zur Bestimmung der Signale wird überprüft, ob die Werte von unterschiedlichen Signalen identisch sind. In einer Gruppe von identischen Zeitreihen werden alle bis auf eine als Duplikate der Klasse DUPL zugeordnet.

CTRL_DIFF – Identifikation von potenziellen Regeldifferenzsignalen

Mit Regel 5.2 aus Kapitel 5.1.7 wurden die Regeldifferenzsignale anhand der bereits bestimmten Positionssignale identifiziert. Da beim hybriden Ansatz zunächst keine Positionssignale bekannt sind, wird die Grundidee übernommen und so angepasst, dass die Regeldifferenzsignale bereits in Stufe 1 vorklassifiziert werden können. Dabei spielt die Zuordnung zu einer Achse noch keine Rolle, sondern nur, ob es sich allgemein um ein Regeldifferenzsignal handelt. Um die Rechenzeit zu verkürzen, wird zunächst von jeder Zeitreihe der Wertebereich überprüft. Liegt dieser zwischen -3 und 3, wird die Zeitreihe vorerst als potenzielles Regeldifferenzsignal betrachtet. Mit den verbleibenden Signalen werden alle möglichen Subtraktionspaare gebildet und dann mit jeweils allen potenziellen Regeldifferenzsignalen verglichen. Durch die Beziehung $CTRL_DIFF \sim CTRL_POS - ENC2_POS$ lassen sich die tatsächlichen Regeldifferenzsignale identifizieren, wenn deren Minkowski-Distanz kleiner als 0,1 ist. Da es jedoch auch unterschiedliche Regeldifferenzsignale einer einzelnen Achse aufgrund von weiteren Verrechnungsfaktoren im Regelungsmodell geben kann und diese nicht mit dem soeben beschriebenen Verfahren gefunden werden, wird anhand der gefundenen Regeldifferenzsignale eine weitere Analyse durchgeführt. Dafür werden die Regeldifferenzsignale zunächst mit einer gleitenden Standardabweichung und anschließend mit einem gleitenden Mittelwert modifiziert. Damit nun zusammengehörige Signale gefunden werden können, muss die Minkowski-Distanz unter 1 und der Korrelationskoeffizient größer als 0,6 sein.

NOISE – Identifikation von rein rauschenden Signalen

Die Identifizierung von ausschließlich rauschenden Signalen, die grundsätzlich keinen Informationsgehalt liefern, wird durch den Wertebereich bestimmt und dem Verhältnis minimaler und maximaler Standardabweichung nach einer gleitenden Standardabweichung. In Abbildung 5-51 ist die klare Abgrenzung der Signale dargestellt.

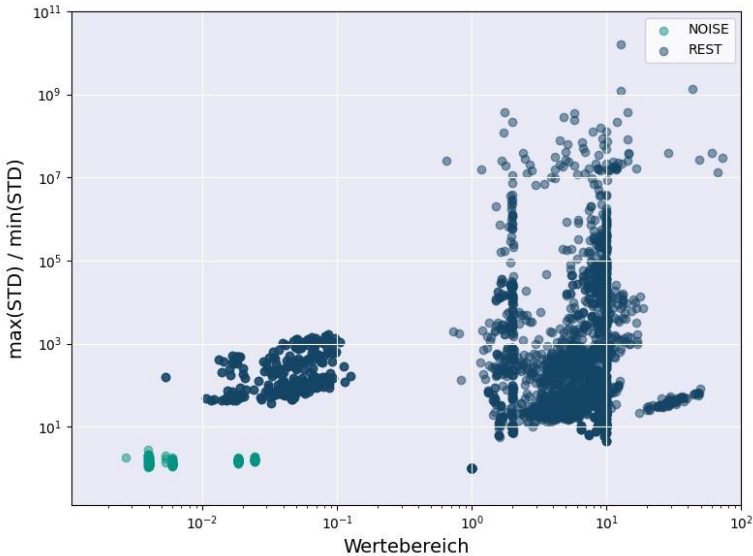


Abbildung 5-51: Differenzierung von Signalen mit Rauschen nach Gönninger & Ströbel et al. (2023b)

5.4.4 Stufe 2 – Machine Learning-basierte Extraktion von Positionssignalen

In den Kapiteln 5.2 und 5.3 wurde das Potential von ML-Modellen zur Klassifikation von Signalen ausführlich erläutert. Durch die zuvor bestimmte Architektur der Modelle beziehungsweise durch die Festlegung der Klassen sind diese relativ starr. Wird ein neuer Datensatz mit weiteren Signaltypen verwendet, welche nicht in den Lerndatensätzen vorgekommen sind, kann dies zu drastischem Genauigkeitsverlust führen. Da die Identifikation aus mehreren Schritten besteht, werden auch Folgefehler entstehen. Gleichzeitig konnte mit dem rein analytischen Ansatz aus Kapitel 5.1 nachgewiesen werden, dass durch die spezifische Auswahl der Positionssignale sich diese mit Domänenwissen und kinematischen Zusammenhängen mit vielen anderen Signaltypen verknüpfen lassen. Dies führt zum Ergebnis, dass sich die Anzahl an Zielklassen der ML-Modelle intelligent reduzieren lässt, wodurch deren Komplexität sinkt und die Genauigkeit steigen dürfte. Aufgrund dieser Tatsache werden die ML-Modelle auf zwei Zielklassen beschränkt. Dabei handelt es sich um die Klasse **POS**, welche alle Positionssignale enthält, und um die Klasse **REST**, welche alle anderen Signale beinhaltet.

Als ML-Modelle werden die zuvor verwendeten Modelle aus 5.2 verwendet. Die Hyperparameter werden übernommen, wodurch ein Sample-Zeitintervall für den RanFor, das FCN und das ResNet auf 1000 und für das LSTM auf 100 festgelegt wird. In Kapitel 5.1.2 wurden Referenzfahrten aufgezeichnet, bei denen kein Werkstück bearbeitet wurde. Um den Einfluss eines tatsächlichen Arbeitsvorgangs und der reinen Durchführung der Achsbewegungen zu analysieren, werden die ML-Modelle mit unterschiedlichen Kombinationen an Datensätzen trainiert. Alle ML-Modelle werden jeweils mit D1 und D2 sowie auch mit der Kombination aus beiden (Mixed) trainiert.

Nach der Zuweisung aller Samples durch die ML-Modelle auf die Klassen, wird die Verteilung für jedes Signal überprüft und schließlich final einer einzigen Klasse zugeordnet. Diese Zuordnung basiert auf dem Prinzip der einfachen Mehrheit. Das bedeutet, dass ein Signal der Klasse zugewiesen wird, in der sich mehr Samples befinden. Sollte es ausgeglichen sein, wird das Signal der Klasse **REST** zugeordnet.

Zusammengefasst werden in der Stufe 2 alle verbleibenden Signale aus Stufe 1 den ML-Modellen zugeführt, welche diese den Klassen **POS** und **REST** zuordnen.

5.4.5 Stufe 3 – Analytische Identifikation aller Signale

Nachdem in der Stufe 2 alle Signale in Position und nicht-Position aufgeteilt wurden, werden die Erkenntnisse des analytischen Ansatzes aus Kapitel 5.1 verwendet, um von Positionsdaten auf die restlichen Signaltypen schließen zu können. Dabei handelt es sich um kinematische und physikalische Zusammenhänge zwischen den Signalen. Für die jeweiligen Analysen von Zusammenhängen werden die Signale größtenteils modifiziert. Dafür werden gleitende Standardabweichungen, gleitende Mittelwerte, Korrelationskoeffizient nach Bravais-Pearson und als Distanzmaß die Minkowski-Distanz verwendet. Normalisierungen werden mit der Min-Max-Normalisierung durchgeführt. Die grundlegenden kinematischen Zusammenhänge der unterschiedlichen Signale werden aus Kapitel 5.1.7 und 5.1.8 übernommen. Eine Übersicht der verwendeten Beziehungen ist in der nachfolgenden Tabelle 16 dargestellt.

Tabelle 16: Verwendete Zusammenhänge von Signaltypen nach Gönzheimer & Ströbel et al. (2023b)

Beziehung	Korrelationsregeln
1.	$CTRL_DIFF \sim CTRL_POS - ENC2_POS$
2.	$VEL_FFW \sim \frac{d}{dt}(DES_POS)$
3.	$CMD_SPEED \sim VEL_FFW$
4.	$\left \frac{d^2}{dt^2}(ENC1_POS) \right \sim CURRENT \sim TORQUE \sim LOAD $

5.4.5.1 Achsstufe

Mit den nun bekannten Positionssignalen werden in einem ersten Schritt Achscluster erstellt, welche die vordefinierte Struktur aus Abbildung 5-50 aufweisen. Durch einen sequenziellen Ablauf werden spezifische Signale und Signaltypen gesucht und den Achsclustern zugeordnet. In Abbildung 5-52 sind die Zusammenhänge der Signale dargestellt, welche durch analytische Regeln beschrieben werden.

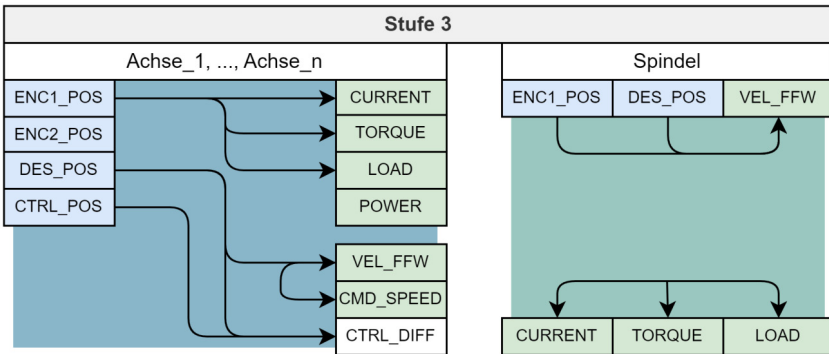


Abbildung 5-52: Korrelationen unterschiedlicher Signale nach Gönzheimer & Ströbel et al. (2023b)

Gruppierung der Positionszeitreihen

Da der gesamte Ansatz auf dem Wissen der Positionssignale basiert, müssen diese zunächst innerhalb der Klasse **POS** unterschieden werden. Dafür werden die Korrelationen zwischen den Positionssignalen analysiert, die bei der Zugehörigkeit gleicher Achsen deutlich höher sein müssen als zwischen den Achsen. Die Anzahl zu suchende Gruppen wird zuvor vom Anwender abgefragt, da dieser die Anzahl an Achsen in der Werkzeugmaschine leicht bestimmen kann. Dadurch besteht jede gebildete Gruppe aus den Signalen ENC1_POS, ENC2_POS, DES_POS und CTRL_POS.

Ermittlung der Regeldifferenzen

Die potenziellen Regeldifferenzen wurden bereits in Stufe 1 vorklassifiziert und werden nun erneut mit den gefundenen Positionssignalen analysiert. Mit Beziehung 1 aus Tabelle 16 lassen sich in diesem Schritt somit für jede Gruppe die Soll- und Ist-Position CTRL_POS und ENC2_POS sowie das dazugehörige Regeldifferenzsignal identifizieren. Diese werden dann dem jeweiligen Achscluster zugeordnet.

Unterscheidung DES_POS und ENC1_POS

Um die beiden Positionssignale unterscheiden zu können, wird das bereits identifizierte CTRL_POS-Signal verwendet. Da dieses ein durch Operationen modifiziertes DES_POS-Signal ist, ist deren Korrelation deutlich höher als das ENC1_POS-Signal, welches direkt am bewegten Maschinentisch gemessen wird. Mit diesem Zusammenhang können auch die Signale DES_POS und ENC1_POS dem Achscluster zugeordnet werden.

Ermittlung der Geschwindigkeiten

Zur Identifikation der Geschwindigkeitssignale wird zunächst das DES_POS-Signal als Ausgangslage genutzt. Mit der Beziehung 2 aus Tabelle 16 kann der direkte Vergleich mit allen Signalen aus der Klasse **REST** durchgeführt werden, um das Geschwindigkeitssignal VEL_FFW zu identifizieren. Das CMD_SPEED-Signal, das auch ein Geschwindigkeitssignal ist, korreliert ebenfalls mit dem DES_POS-Signal, wobei beide Distanzen klar voneinander differenzierbar sind, wie in Abbildung 5-53 erkennbar ist. Da sich die Distanzen zu den CMD_SPEED-Signalen mit den restlichen Signalen aus der Klasse **REST** überschneiden, werden diese erst im nächsten Schritt bestimmt.

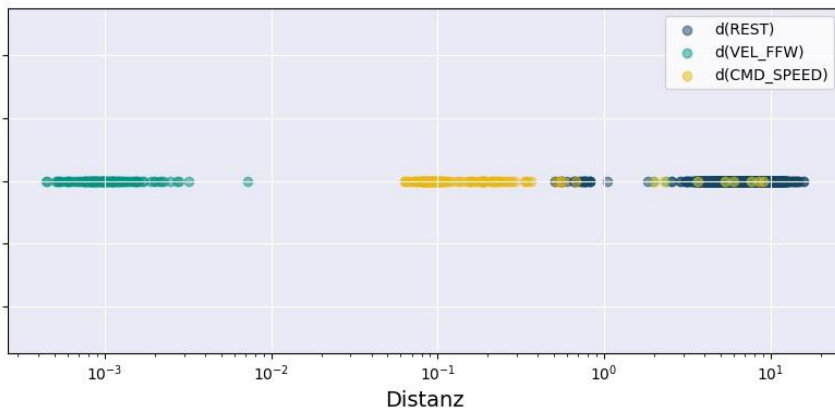


Abbildung 5-53: Bestimmung der Geschwindigkeitssignale anhand der Distanz zu Positionssignalen in eindimensionaler Abbildung nach A_Dörfinger (2022)

Die Ermittlung der CMD-SPEED-Signale erfolgt mit den nun bekannten VEL_FFW-Signalen durch die Beziehung 3 aus Tabelle 16. Durch die modifizierten Zeitreihen können diese wieder klar von der Klasse **REST** abgegrenzt werden. Dadurch sind nun auch die beiden Geschwindigkeitssignale den Achsclustern zugeordnet. In Abbildung 5-54 ist die Abgrenzung der Geschwindigkeitssignale von den restlichen Signalen durch die Distanzberechnung klar erkennbar.




Abbildung 5-54: Bestimmung der verbleibenden Geschwindigkeitssignale durch die Berechnung von Distanzen in eindimensionaler Abbildung nach A_Dörflinger (2022)

Ermittlung der POWER-Signale

Für die Identifizierung der POWER-Signale wird die Regel 3.1 aus Kapitel 5.1.5 übernommen. Diese können durch ihren Wertebereich und den prozentualen Anteil an Nulleinträgen klar von den verbleibenden Signalen separiert werden. Die Signale werden der allgemeinen Klasse POWER zugeordnet.

Ermittlung von Strom, Drehmoment und Last

Als Grundlage zur Identifikation der Leistungssignale werden die Regeln 6.2 und 6.3 aus Kapitel 5.1.8 verwendet, die wiederum auf Beziehung 4 aus Tabelle 16 aufbauen. Mit dem ENC1_POS-Signal lassen sich direkte Zusammenhänge zu den Leistungssignalen herleiten, wobei jedoch Effekte berücksichtigt werden müssen. Da die Ähnlichkeiten der Signale durch Korrelationskoeffizienten bestimmt werden, sind Ausreißer eine potenzielle Fehlerquelle nach der Normierung der Signale. Dies tritt besonders bei den Stromsignalen auf, da durch eine starke Beschleunigung der Strom kurzzeitig überproportional steigt. Dieser Effekt kann jedoch nicht in den Positionssignalen festgestellt werden. Deshalb wird bei den Signalen aus der Klasse **REST** eine weitere Rechenoperation vor der Normierung durchgeführt. Dabei werden alle sprunghaften Änderungen in den Zeitreihen identifiziert und entfernt. Die gleichen Abtastzeitpunkte werden dann auch in den Positionssignalen entfernt. Dadurch sind die

Signale deutlich vergleichbarer, wodurch die Korrelationskoeffizienten nach einer Normierung höher ausfallen. In der nachfolgenden Abbildung 5-55 ist die Modifikation dargestellt. Nach diesem Schritt korrelieren die Positionssignale hauptsächlich mit den Strom-, Drehmoment- und Lastsignalen der Achsen.




Abbildung 5-55: Modifikation der Signale für stärkere Korrelationen von Positions- und Drehmomentsignalen. Oben: modifizierte Positions- und Stromsignale nach bisherigem Schema. Unten: Erweiterte Modifikation durch die Entfernung von Peaks in den Stromsignalen durch die Identifikation von lokalen Minima in den Positionssignalen. Darstellung nach Gönzheimer & Ströbel et al. (2023b)

Korreliert mit einem Positionssignal nur ein weiteres Signal, können keine weiteren Rückschlüsse daraus gewonnen werden und das gefundene Signal wird der Klasse **CUR/TOR/LOAD** zugeordnet. Falls mehr als drei Signale mit dem Positionssignal korrelieren, werden für die nachfolgenden Schritte nur die drei mit der geringsten Distanz zum Positionssignal verwendet. Die restlichen Signale werden der Klasse **CUR/TOR/LOAD** zugeordnet. Als nächstes wird aus den korrelierenden Signalen das LOAD-Signal identifiziert. Sind nur zwei Signale vorhanden, wird die Distanz berechnet, welche einen Grenzwert nicht überschreiten darf. Bei drei Signalen werden alle möglichen Distanzen berechnet und das Paar mit der kleinsten Distanz als Strom und Drehmoment betrachtet. Liegen die anderen Distanzen unterhalb eines Schwellenwertes, wird das dritte Signal als LOAD in das Achscluster klassifiziert. Für die Unterscheidung von Strom und Drehmoment wird die Regel 6.3 aus Kapitel 5.1.8 verwendet.

Alle Signale, welche sich nach diesem Schritt noch in der Klasse **REST** oder **POS** befinden, konnten keiner Achse zugeordnet werden. Diese sind entweder Signale der Spindel oder mit den bestehenden Regeln nicht identifizierbar.

5.4.5.2 Spindelstufe

In dieser Stufe werden die verbleibenden Signale in den Klassen **POS** und **REST** auf die Zugehörigkeit zur Spindel untersucht.

Positions- und Geschwindigkeitssignale

Für die Identifikation der Positionssignale wird das Merkmal der Drehrichtung und des Wertebereichs einer Spindel genutzt. Sind 99,9 % der Werte größer Null und ist der Wertebereich größer als 2000, werden die Signale zunächst als potenzielle Positionssignale der Spindel vorklassifiziert. Als nächstes wird die Beziehung 2 aus Tabelle 16 verwendet, um den Zusammenhang zwischen Position und Geschwindigkeit herzustellen. Ist der Korrelationskoeffizient über 0,85, werden die gefundenen Signale als Geschwindigkeiten der Spindel klassifiziert. Die damit korrelierenden Positionssignale werden dann über die Distanz differenziert. Nach einer Untersuchung konnte festgestellt werden, dass das DES_POS-Signal eine geringere Distanz zum VEL_FFW-Signal aufweist als das ENC1_POS-Signal.

Strom, Drehmoment, Last

Zur Identifikation der Signale wird die Regel 3.4 aus Kapitel 5.1.5 verwendet. Dafür werden der prozentuale Anteil der um den Mittelwert verschobenen Zeitreihe sowie das Verhältnis von maximaler und minimaler Standardabweichung berechnet. Zusätzlich wird die Berechnung um ein drittes Merkmal ergänzt, welche die Standardabweichung beschreibt, sodass die Fehlklassifikation von Signalen stark reduziert werden kann. Nach der Gruppierung der potenziellen Leistungssignale wird das Lastsignal durch den ausschließlich positiven Wertebereich identifiziert. Das Drehmomentsignal kann nach einer Normierung und einer gleitenden Standardabweichung vom Stromsignal unterschieden werden, da dessen Mittelwert immer höher ist als das vom Stromsignal.

Alle Signale, welche sich nach diesem Schritt noch in der Klasse **REST** oder **POS** befinden, konnten nicht identifiziert werden.

5.4.6 Ergebnisse und Bewertung

In diesem Kapitel werden zunächst die Ergebnisse der drei Stufen untersucht, um deren Eignung zu prüfen und das beste ML-Modell auszuwählen. Anschließend wird das finale Gesamtmodell getestet. Zur Bewertung werden zwei unterschiedliche Methoden beschrieben, die eine Aussage über die Genauigkeit geben. Diese Methoden stellen unterschiedliche Detaillierungsgrade der Genauigkeitsberechnung dar, um zwei mögliche Szenarien aufzuzeigen.

5.4.6.1 Stufe 1 – Extraktion von trivialen Signalen

In der ersten Stufe werden die trivialen Signale mit einer sehr hohen Genauigkeit identifiziert. In Tabelle 17 sind die Ergebnisse aufgelistet. Bei dem Trainingsdatensatz D2 werden 99,61 % und bei dem Validierungsdatensatz D3 99,59 % an Genauigkeit erreicht. Durch die Klassifikation konnten teilweise bis zu 54 von 100 Signalen bereits identifiziert werden. Durch diese Maßnahme konnten die Datensätze bedeutend reduziert werden, was auch zur Verringerung der Berechnungszeiten nachfolgender Analysen führt. Wie stark sich diese verringern lassen, hängt jedoch immer von der jeweiligen Berechnungsmethode und der Anzahl an Zeitreihen ab.

Tabelle 17: Genauigkeiten der Identifikation trivialer Signale in Stufe 1 von D2 und D3 nach Gönzheimer & Ströbel et al. (2023b)

	D2	D3
AVG ACC	99,61%	99,59%

5.4.6.2 Stufe 2 – Identifikation von Positionssignalen durch ML-Modelle

Für die Untersuchung der ML-Modelle wurden zwei Datensätze verwendet, bei denen es sich bei D1 um einen tatsächlichen Bearbeitungsprozess handelt und bei D2 um eine Referenzfahrt. Zur Überprüfung wurden die ML-Modelle mit den drei möglichen Kombinationen der Datensatzzusammenstellung trainiert. Die Ergebnisse sind in Tabelle 18 aufgelistet.

Tabelle 18: Analyse der Genauigkeiten der ML-Modelle bei unterschiedlichen Kombinationen der Datensätze als Datengrundlage nach Gönninger & Ströbel et al. (2023b)

	D1 Train	Test	D2Train	Test	Mixed Train	Test
ResNet	99,96%	99,94%	99,99%	99,99%	99,98%	99,98%
FCN	99,82%	99,78%	99,99%	99,99%	99,96%	99,94%
LSTM	99,30%	99,28%	99,97%	99,97%	99,60%	99,61%
RanFor	99,94%	99,89%	99,99%	99,99%	99,97%	99,97%

Die Genauigkeiten sind bei allen Auswertungen über 99 %, wobei festgestellt werden kann, dass mit Datensatz D2 tendenziell mehr Samples korrekt klassifiziert werden können als mit D1. Dies liegt darin begründet, dass die Bewegungen der Referenzfahrten einfacher und eindeutiger sind als der Bearbeitungsprozess, welcher in D1 durchgeführt wurde. Die Ergebnisse mit dem Datensatz Mixed liegen zwischen D1 und D2. Um weitere Unterschiede feststellen zu können, werden die trainierten Modelle mit dem Datensatz D3 validiert. Die Ergebnisse sind in Tabelle 19 aufgelistet.

Tabelle 19: Genauigkeiten der ML-Modelle mit unterschiedlicher Trainingsdaten auf den Validierungsdatensatz D3 nach Gönninger & Ströbel et al. (2023b)

	Trainingsdatensatz	AVG ACC D3
ResNet	D1	97,75%
	D2	99,98%
	Mixed	99,97%
FCN	D1	97,75%
	D2	99,99%
	Mixed	99,97%
LSTM	D1	96,75%
	D2	99,95%
	Mixed	99,87%
RanFor	D1	99,02%
	D2	100,00%
	Mixed	99,99%

Auch hier zeigen sich keine bedeutsamen Unterschiede zwischen den ML-Modellen. Alle erreichen sehr hohe Genauigkeiten von mindestens 96,75 %. Bei der Datengrundlage von D1 ist zu erkennen, dass die Genauigkeiten niedriger sind. Bei D2 und Mixed sind keine nennenswerten Unterschiede festzustellen. Damit kann keine Abgrenzung

der ML-Modelle durch die Datengrundlage auf dieser Basis festgestellt werden. In diesem Fall wird das LSTM präferiert, da es grundlegende Vorteile wie die Eigenschaften, komplexere Zusammenhänge zu erkennen und auch vergangene Ereignisse zu berücksichtigen, besitzt.

5.4.6.3 Stufe 3 – Identifikation von Zeitreihen und Zuweisung zu Achsen

In der dritten Stufe können durch die analytischen Regeln und Zusammenhänge der Signale ebenfalls sehr hohe Genauigkeiten erzielt werden. In Tabelle 20 sind die Ergebnisse aufgelistet. Mit D2 werden 97,78 % der Signale korrekt klassifiziert und mit D3 werden 98,06 % erreicht.

Tabelle 20: Genauigkeiten der Identifikation von Signalen in Stufe 3 nach Gönzheimer & Ströbel et al. (2023b)

	D2	D3
AVG ACC	97,78%	98,06%

5.4.6.4 Gesamtergebnis

Zur Berechnung der Genauigkeiten der verschiedenen Stufen müssen verschiedene Betrachtungsweisen berücksichtigt werden, da der benötigte Detaillierungsgrad unterschiedlich tief sein kann. Beispielsweise kann es unter Umständen ausreichend sein, wenn die Positionssignale allgemein einer Achse zugeordnet sind, ohne, dass die Positionssignale selbst unterschieden werden.

Die Bewertungsmethode nach G1 ist ein Indikator für die Richtigkeit der getroffenen Entscheidungen in den Stufen 1 und 3. Dabei wird überprüft, ob das zugewiesene Signal exakt der zugeordneten Klasse entspricht. Falsch zugeordnete Signale, die dem übergeordneten Signaltyp angehören, werden als falsch bewertet. Beispielsweise ist ein ENC1_POS-Signal, welches der Klasse **ENC2_POS** zugewiesen wurde, zwar immer noch in der Gruppe der Positionssignale, die konkrete Zuordnung ist jedoch falsch. Zusätzlich werden die Signale, die keiner Klasse zugeordnet wurden, ebenfalls als falsch gewertet.

Die Bewertungsmethode G2 berücksichtigt bei den Zuweisungen der Signale aus Stufe 1 und 3 auch den übergeordneten Signaltyp. Ein Positionssignal, welches falsch klassifiziert wurde, sich aber in der übergeordneten Klasse **POS** befindet, wird als korrekt klassifiziert gewertet. Zusätzlich besitzen die nicht klassifizierbaren Signale keinen

weiteren negativen Einfluss mit Folgefehlern auf die Auswertung, weshalb diese nicht in die Bewertung miteinfließen. In Abbildung 5-56 sind die Bewertungsmaße dargestellt.

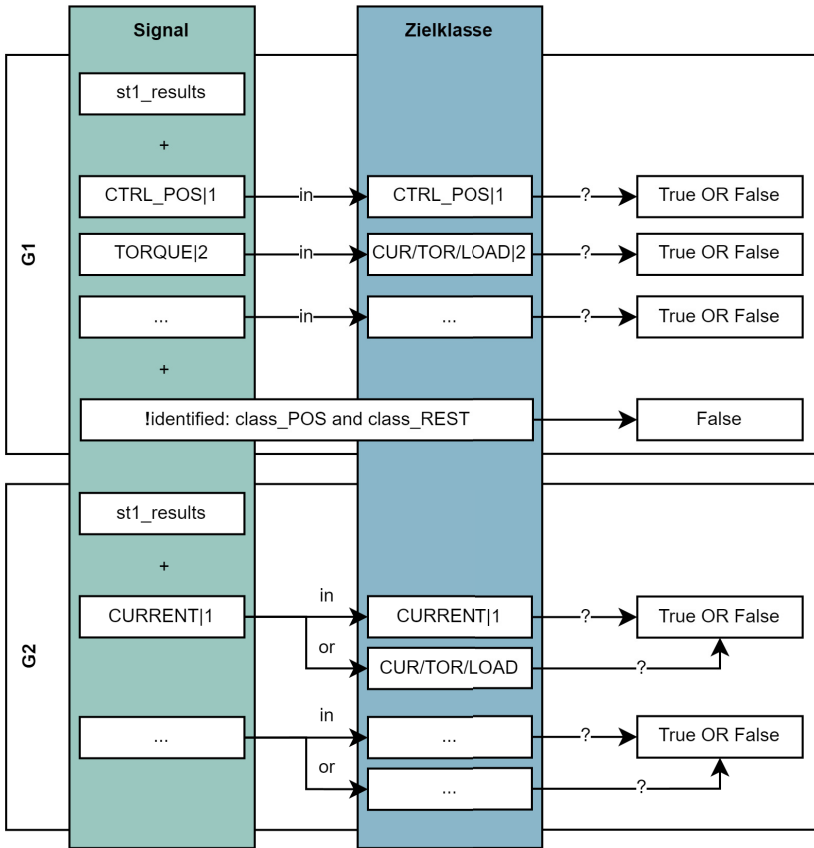


Abbildung 5-56: Schema der Bewertungsmethoden G1 und G2 nach A_Dörflinger (2022)

Durch die Definition der Bewertungsmaße kann G1 maximal so hoch wie G2 sein. Die Differenz von G1 und G2 ist ein Indikator für die Anzahl an nicht klassifizierbaren und nicht eindeutig klassifizierbaren Signalen. In Tabelle 21 sind die Ergebnisse detaillierter dargestellt. Mit dem Lerndatensatz D2 werden mit G1 96,44 % und mit G2 98,93 %

erreicht. Die Genauigkeit liegt damit sehr hoch und auch die Differenz der beiden Bewertungsmaße zeigt, dass nahezu alle Signale eindeutig identifizierbar waren. Bei dem Validierungsdatensatz D3 unterscheiden sich die Ergebnisse zu D2 hauptsächlich bei G1. Dort werden nur 95,57 % erreicht. Dennoch wurden auch hier sehr hohe Genauigkeiten erzielt, wodurch die Eignung des hybriden Ansatzes bestätigt werden kann.

Tabelle 21: Gesamtergebnis des Gesamtmodells mit den Datensätzen D2 und D3 nach A_Dörflinger (2022)

Bewertungsmaß	D2	D3
G1	96,44%	96,57%
G2	98,93%	99,01%

6 Systemintegration

Nachdem die Teilsysteme zur Datenextraktion aus Werkzeugmaschinen in Kapitel 4 und die Signalidentifikation durch das hybride Modell aus Kapitel 5.4 entwickelt wurden, müssen diese nun zusammengeführt werden. Dafür wird ein „wbk-Crawler“ genanntes Assistenzsystem mit Benutzeroberfläche erarbeitet, über die ein Anwender in einem geführten Modus den Prozess durchlaufen kann (Gönnheimer & Hillenbrand et al. 2023). Das Ziel der Benutzeroberfläche ist, dem Anwender ausschließlich die notwendigen Informationen darzustellen, um die Benutzeroberfläche als Assistenzsystem möglichst intuitiv zu gestalten und das benötigte Vorwissen gering zu halten. Dadurch soll die Problematik der genannten Hemmnisse aus Kapitel 1.1 durch fehlende persönliche Ressourcen sowie Expertise gelöst werden. In den nachfolgenden Kapiteln wird zunächst der Aufbau der Benutzeroberfläche beschrieben und anschließend der geführte Durchlauf als Anwendung detailliert erläutert.

6.1 Aufbau der Benutzeroberfläche des Assistenzsystems

Die Benutzeroberfläche (GUI) wird als ausführbares Programm auf Windows-PCs entwickelt. Dadurch wird eine generelle Unterstützung aller Unternehmen ermöglicht, sodass keine zusätzlichen Systemprogramme notwendig sind. Abhängig von der gewünschten Methode zum Einlesen von Signalen müssen netzwerkseitig die Schnittstellen zur Verbindungsherstellung gegeben sein, falls die Daten nicht manuell über eine CSV-Datei importiert werden. Für den Verbindungsaufbau mit einem Server muss der Anwender die benötigten Benutzerdaten eingeben. Generell ist die Struktur der GUI so aufgebaut, dass nur zu Beginn notwendige Informationen vorliegen müssen, um den Prozess zu starten. Die Datenextraktion und Signalidentifikation laufen auf dieser Basis automatisiert ab und geben die Ergebnisse als übersichtliche Tabellen an den Anwender zurück. Dieser hat daraufhin die Möglichkeit, die Signale graphisch darstellen zu lassen oder manuell vor der Datenausgabe Änderungen vorzunehmen. Abschließend können die identifizierten Signale mit einer entsprechenden Zuordnungsinformation als CSV-Datei oder über einen erzeugten Server exportiert werden. In den nachfolgenden Kapiteln werden die einzelnen Schritte zum Ablauf anhand eines Datensatzes aus Kapitel 5.4.2 von Beginn an im Detail erläutert.

6.2 Geführter Ablauf

Bei der Ausführung des Systems wird das Fenster aus Abbildung 6-1 angezeigt. Hier hat der Anwender die Möglichkeit zwischen den Datenquellen auszuwählen. Auf der linken Seite der Abbildung kann eine lokale Datei im CSV-Format zu importieren. Andernfalls kann eine Verbindung mit einem Server durch die entwickelten Zugriffsmöglichkeiten aus Kapitel 4.2.2 hergestellt werden. Hierfür müssen dem Anwender die dafür benötigten Zugangsdaten, bestehend aus Serveradresse, dem Benutzernamen und dem dazugehörigen Passwort vorliegen.

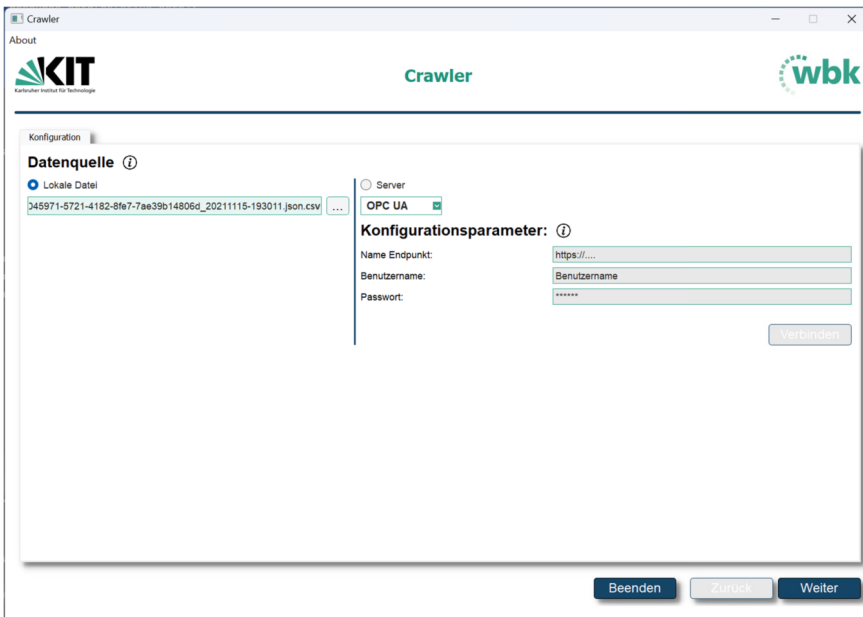


Abbildung 6-1: Startseite der GUI

Nach der Auswahl der Eingabequelle wird der nächste Schritt angezeigt, welcher in Abbildung 6-2 dargestellt ist. Hier werden weitere Eingaben vom Anwender abgefragt. Um die Qualität der Signalidentifikation zu steigern, kann die Anzahl der Achsen der Werkzeugmaschine angegeben werden, da dieser Parameter für weitere Berechnungen eine wichtige Rolle spielt. Zusätzlich ist es hilfreich, die Abtastrate der Datenquelle in der Werkzeugmaschine zu kennen, da auch diese in Berechnungen eine Rolle spielt.

Als Default-Wert werden 500 Hz angezeigt, falls die Abtastrate nicht bekannt ist. Die Aufnahmezeit hat einen Default-Wert von 100 Sekunden, kann aber vom Anwender individuell angepasst werden.

Nach der Eingabe der Daten kann der eigentliche Prozess gestartet werden. Die Zeitreihendaten werden eingelesen und anschließend der Signalidentifikation übergeben. Die Signalidentifikation ist im Anzeigefenster in ihre drei Stufen aufgeteilt, wodurch der aktuelle Status des Prozesses eingesehen werden kann. Ist diese abgeschlossen, kann mit dem nächsten Anzeigefenster fortgefahren werden.

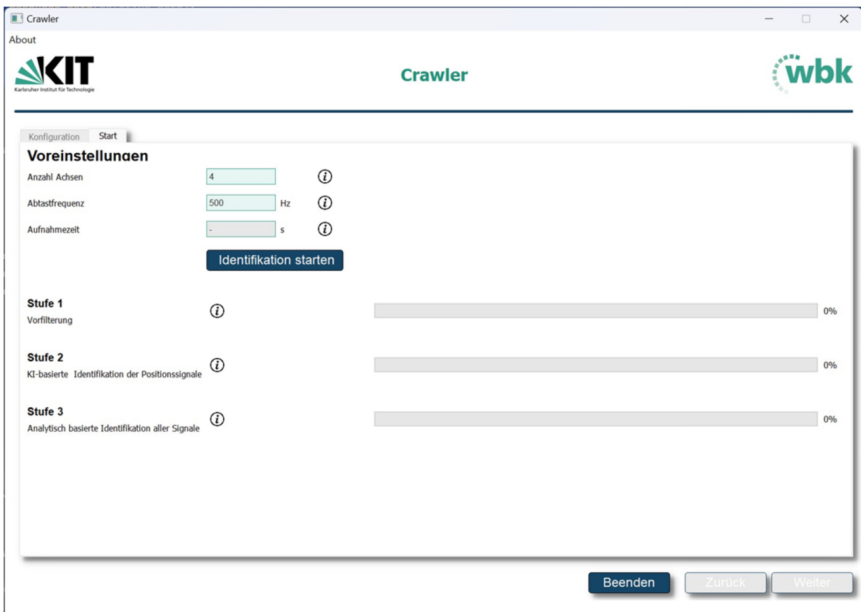


Abbildung 6-2. Konfiguration

Nach der Signalidentifikation werden die Ergebnisse so dargestellt, dass sie für jede Stufe einzeln einsehbar sind. Dafür werden zunächst die gefilterten trivialen Signale aus Stufe 1 angezeigt, welche in Kapitel 5.4.3 erläutert wurden. Dabei sind alle Filterklassen tabellarisch dargestellt. Die zugewiesenen Signale sind jeweils in den Tabellen einsehbar. Außerdem besteht die Möglichkeit, Signale auszuwählen und diese in einem

separaten Fenster graphisch darzustellen. Die Seite mit den Ergebnissen aus Stufe 1 ist in Abbildung 6-3 dargestellt.

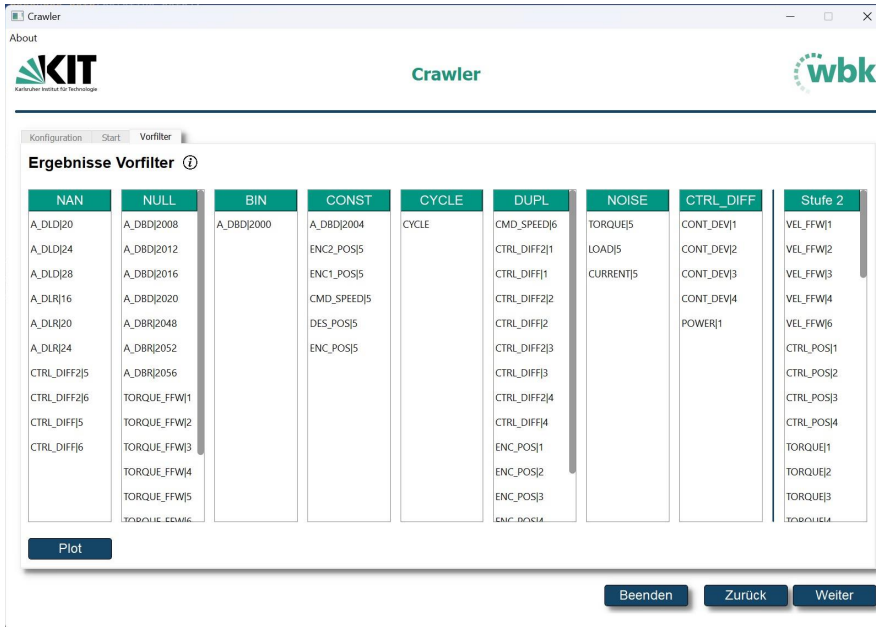


Abbildung 6-3. Ergebnisse Vorfilter

Gemäß der Struktur werden im nächsten Schritt die Ergebnisse der Stufe 2 dargestellt. In Kapitel 5.4.4 wurde das Verfahren zur Identifikation von Positions- und nicht-Positionssignalen erläutert. In Abbildung 6-4 sind die beiden Zielklassen tabellarisch mit den jeweils zugeordneten Signalen dargestellt. Auch hier können Signale wieder graphisch angezeigt werden.

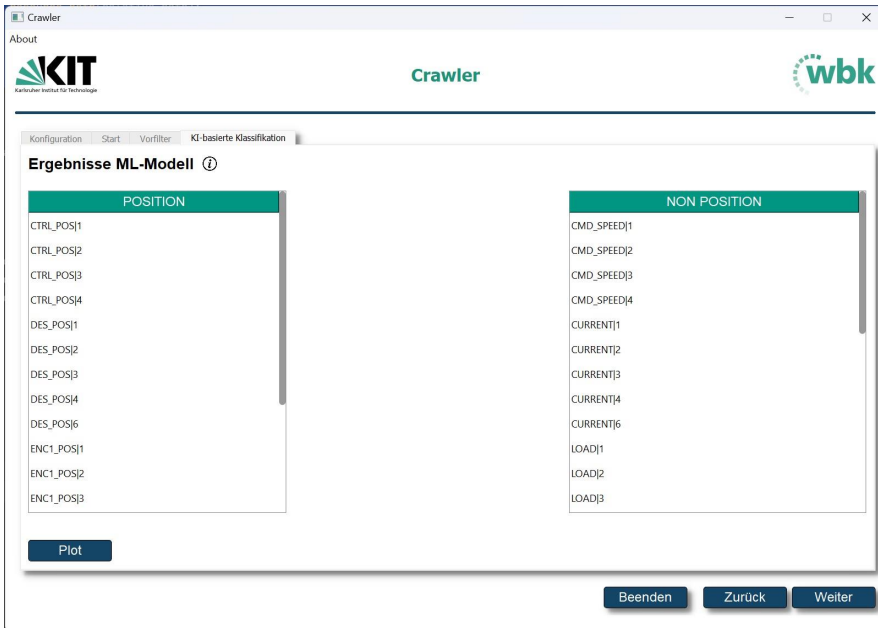


Abbildung 6-4. Ergebnisse ML

In Abbildung 6-5 ist die erste Ergebnisseite von Stufe 3 dargestellt. Das Teilsystem dazu wurde in Kapitel 5.4.5 beschrieben. Die dritte Stufe ist aufgrund der vielen möglichen Zielklassen und der Anzahl der Signalzuordnungen deutlich umfangreicher als die ersten beiden Stufen, weshalb die Ergebnisse auf zwei Seiten aufgeteilt werden. Zunächst werden die vorsortierten Signale angezeigt, die nicht eindeutig identifiziert werden konnten. Die Zielklassen werden links von der Tabelle angezeigt und können aus- und abgewählt werden, um die dazugehörigen Signale in der Tabelle ein- und auszublenden. Eine Zielklasse mit roter Umrandung bedeutet, dass kein Signal dieser Klasse zugewiesen wurde. In der Tabelle selbst wird in der ersten Spalte die Signalbezeichnung aus der Aufzeichnung angegeben. In der zweiten Spalte kann der Anwender eine eigene Bezeichnung eingeben und die dritte Spalte zeigt erneut die Klassenzuweisung an. Über die Spalte „Verschieben“ kann der Anwender das Signal bei Bedarf manuell in eine andere Klasse verschieben. Anschließend wird, falls bekannt, noch die zum Signal zugehörige Achse angezeigt. In der letzten Spalte kann zusätzlich manuell ausgewählt werden, ob das jeweilige Signal später beim Export berücksichtigt werden

soll. Alternativ kann dafür auch „Alles auswählen“ verwendet werden. Außerdem lassen sich auch hier wieder alle Signale graphisch in einem separaten Fenster öffnen.

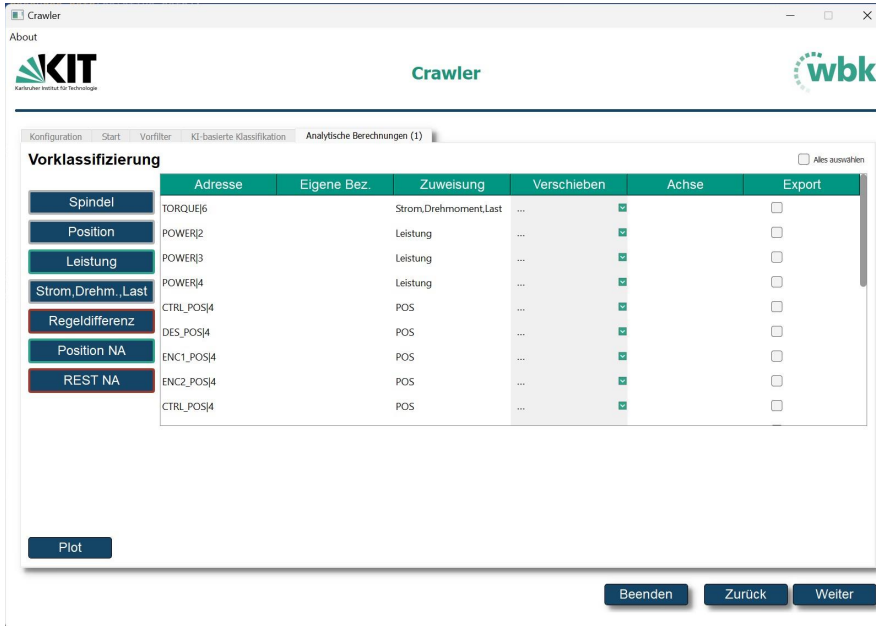


Abbildung 6-5. Ergebnisse der Vorklassifizierung in Stufe 3

Die zweite Ergebnisseite der Stufe 3 ist in Abbildung 6-6 dargestellt. Diese unterscheidet sich zur ersten Seite hauptsächlich durch die angezeigten Klassen neben der Tabelle. Hier werden statt Klassen die Achsen angezeigt, durch die ganze Achsgruppen in der Tabelle ein- und ausgeblendet werden können. Außerdem ist noch dargestellt, wie ein Signal durch eine manuelle Auswahl in eine andere Zielklasse verschoben werden kann.

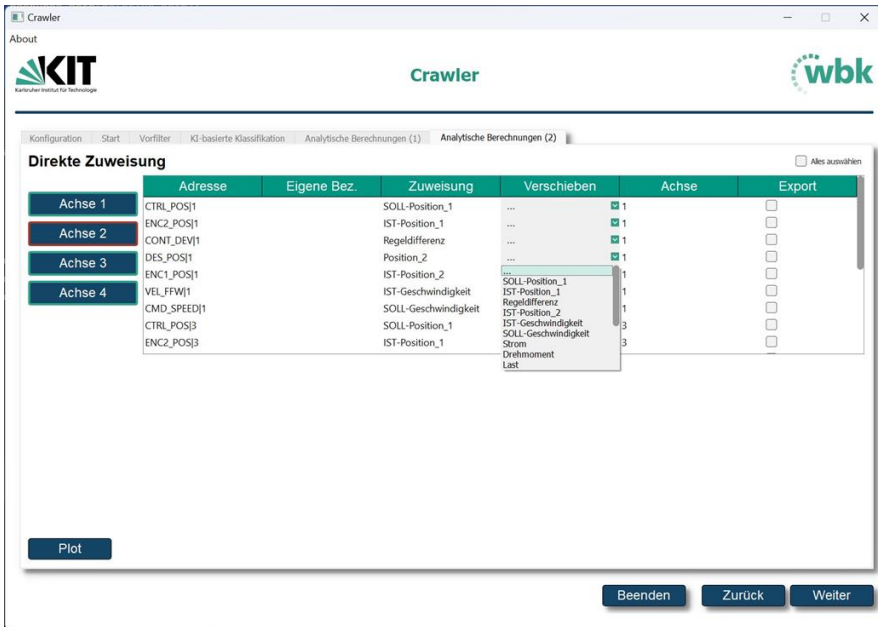


Abbildung 6-6: Ergebnisse der direkten Zuweisung in Stufe 3

Nach Auswahl der zu exportierenden Signale durch den Anwender können nun im Export-Fenster, dargestellt in Abbildung 6-7, die sortierten Zeitreihen ausgegeben werden. Dafür kann zwischen einer lokalen Datei und der Datenübertragung über einen OPC UA Server ausgewählt werden. Optional können die Ergebnisse aus Stufe 1 über ein Kästchen komplett ausgeschlossen werden. Der Export erfolgt im CSV-Format. Falls die Daten über OPC UA exportiert werden sollen, wird ein OPC UA Server gestartet, auf den ein Client zugreifen kann.

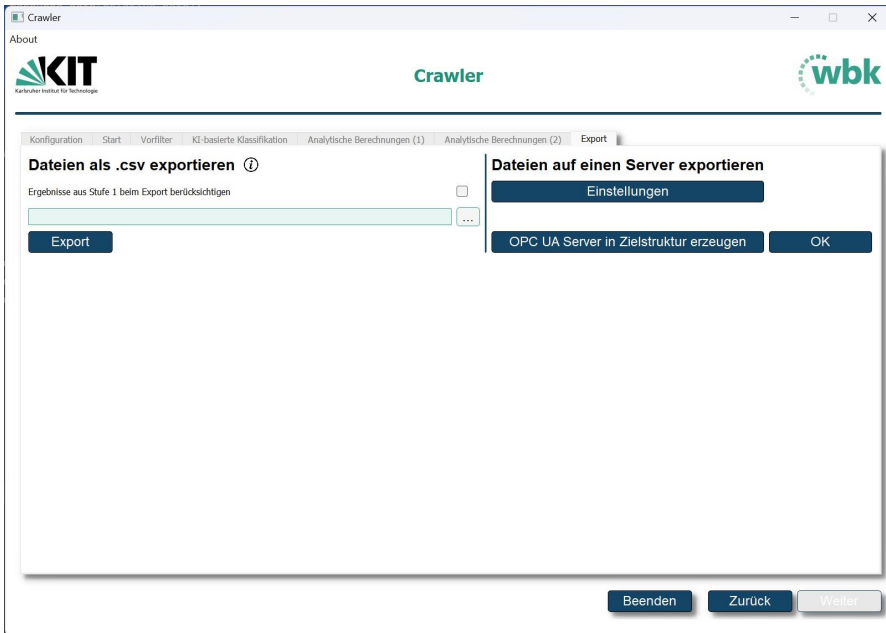


Abbildung 6-7: Export der Ergebnisse als lokale Datei oder über einen OPC UA Server

Zusammengefasst stellt die entwickelte Benutzeroberfläche für den Anwender ein intuitives Assistenzsystem dar, das diesen durch den gesamten Bereitstellungsprozess der Maschinendaten begleitet und die entwickelten Module der Datenextraktion und Signalidentifikation nahtlos integriert. Im Hinblick auf die in Kapitel 2.3.3 beschriebenen Digitalisierungshemmnisse für Unternehmen, die vor allem einen Mangel der notwendigen personellen Ressourcen und Expertise angeben, ist das Assistenzsystem auf minimalen Zeiteinsatz und Input des Anwenders ausgerichtet.

7 Validierung des Lösungskonzepts

In diesem Kapitel wird der entwickelte Lösungsansatz an verschiedenen Anwendungsfällen demonstriert und validiert. Die Anwendungsfälle beginnen dabei mit einer Validierung auf der Ausgangsmaschine und einer ähnlichen Fräsmaschine und gehen dann zu schrittweise weniger ähnlichen Anlagen wie einer Honmaschine und abschließend einem Industrieroboter über. Zum Abschluss des Kapitels werden die Ergebnisse zusammengefasst und bewertet.

7.1 Validierung

Ziel dieses Kapitels ist die Validierung der Teilschritte des mehrstufigen Modells zur Identifikation von Maschinensteuerungssignalen mit weiteren Datensätzen. Zunächst werden diese erläutert und auf ihre besonderen Merkmale eingegangen. Außerdem werden die Schwerpunkte der Analyse der jeweiligen Datensätze festgelegt, um aussagekräftige Ergebnisse auf das Gesamtmodell zurückführen zu können.

7.1.1 Allgemeiner Aufbau

Um das Modell des hybriden Ansatzes zu testen, stehen unterschiedliche Datensätze zur Verfügung, mit denen eine Validierung durchgeführt wird. Die Datensätze sind Aufzeichnungen aus sowohl bereits bekannten Fräsmaschinen als auch von Maschinentypen, die sich unterschiedlich stark von diesen unterscheiden. Bei den Fräsmaschinen handelt es sich um Datensätze der Deckel Maho DMC 60-H HDM, bei der Referenzfahrten aufgezeichnet wurden, und einer DMG MORI CMX 600V, bei der Verschleißversuche durchgeführt wurden. Eine weitere Aufzeichnung stammt aus einer Nagel VARIOHONE 9684 Honmaschine, deren Signalpool nur teilweise mit der Ergebnisstruktur des hybriden Modells übereinstimmt. Deshalb muss die Validierung hier teilweise spezifiziert durchgeführt werden. Der vierte Datensatz entstammt aus einem KUKA KR6 R900-2 Industrieroboter, bei dem sowohl Fahrten mit Last als auch ohne Last durchgeführt wurden. Auch bei diesem Datensatz ist der Signalpool stark abweichend, weshalb spezifische Schwerpunkte der Analyse gesetzt werden.

Aufgrund der Vielfalt an verwendeten leistungsgebenden Komponenten im Brownfield können die möglichen Abstraten bei einer Aufzeichnung ebenfalls sehr unterschiedlich sein. Während bei der Entwicklung hauptsächlich Datensätze mit einer Abstrategie von 500 Hz verwendet wurden, ist bisher unbekannt, wie robust sich das Modell gegenüber niedrigeren Frequenzen verhält. Deshalb ist es notwendig, dass auch Datensätze

mit geringeren Abtastraten und damit niedrigerem Informationsgehalt überprüft werden, um ein möglichst breites Spektrum abbilden zu können. Als Grundlage werden die dafür bereits vorhandenen Datensätze genutzt. Aus diesen werden zusätzliche synthetische Datensätze mit niedrigerer Abtastfrequenz erstellt. Hierfür werden mit Downsampling Zeitreiheneinträge aus der ursprünglichen Zeitreihe entfernt, wodurch niedrigere Abtastfrequenzen simuliert werden. Durch die Abtastratenvariation kann dann eine Aussage zur Robustheit gegenüber verringerter Abtastraten getroffen werden. Die Ergebnisse aus jeder Stufe des Modells werden separat ausgewertet, um konkret über die jeweiligen Teilschritte urteilen zu können. Dabei können Stufe 1 und 2 ohne weitere Anpassungen mit den vorliegenden Datensätzen validiert werden. Stufe 3 kann für manche Datensätze nicht vollständig genutzt werden, da die vorhandenen Signale teilweise zu stark von der Grundstruktur abweichen. Deshalb werden hierfür spezifische Regeln extrahiert und genutzt, um mithilfe dieser eine Aussage treffen zu können.

Mit der nachfolgend beschriebenen Reihenfolge der Validierungen wird der erwartete Schwierigkeitsgrad stetig erhöht. Während zunächst Datensätze der Maschinen analysiert werden, die auch bei der Entwicklung des Gesamtmodells verwendet wurden, ändert sich der Maschinen- beziehungsweise Anlagentyp über eine Honmaschine zu einem KUKA-Roboter.

7.1.2 Validierung 1 – Horizontal-Fräsmaschine

Im ersten Validierungsfall wurde der Datensatz (TD1) aus Kapitel 5.4.2 verwendet, welche mit 500 Hz aufgezeichnet wurde. Überprüft wird hierbei die Robustheit auf synthetisch reduzierte Abtastraten von 250 Hz und 125 Hz.

7.1.2.1 Ergebnisse

Stufe 1

In Tabelle 22 sind die Genauigkeiten der Stufe 1 mit dem Datensatz TD1 aufgelistet. Bei 500 Hz wird eine Genauigkeit von 99,59 % erreicht. Bei der Reduktion der Abtastrate fällt diese bei 125 Hz um 0,75 %.

Tabelle 22: Genauigkeiten der Stufe 1 mit TD1 und unterschiedlichen Abtastraten nach Gönheimer & Ströbel et al. (2023c)

	500 Hz	250 Hz	125 Hz
AVG ACC	99,59 %	99,16 %	98,84 %

Stufe 2

In der nachfolgenden Tabelle 23 sind die Genauigkeiten der Stufe 2 mit Datensatz TD1 aufgelistet. Man kann erkennen, dass bei 500 Hz mindestens eine Genauigkeit von 99,72 % besteht und die Abtastratenreduktion nur einen geringen Einfluss besitzt. Bei 125 Hz verliert der RanFor die meisten Prozentpunkte, ist aber mit 98,26 % weiter auf einem sehr hohen Niveau.

Tabelle 23: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD1 nach Gönzheimer & Ströbel et al. (2023c)

ML-Modell	500 Hz	250 Hz	125 Hz
ResNet	99,97 %	99,95 %	99,98 %
FCN	99,72 %	99,51 %	99,94 %
LSTM	99,87 %	99,59 %	99,05 %
RanFor	99,99 %	99,82 %	98,26 %

Gesamtmodell

In Tabelle 24 sind die Ergebnisse der Genauigkeiten der Stufe 3 mit TD1 aufgelistet. Bei 500 Hz wird eine Genauigkeit von 99,01 % erreicht, welche bei der Reduktion der Abtastrate auf 250 Hz auf 98,76 % fällt. Eine größere Differenz von -5,91 % liegt bei der Reduktion von 250 Hz auf 125 Hz vor.

Tabelle 24: Ergebnisse des gesamten mehrstufigen Modells mit dem Datensatz TD1 nach Gönzheimer & Ströbel et al. (2023c)

	500 Hz	250 Hz	125 Hz
AVG ACC	99,01 %	98,76 %	93,85 %

7.1.2.2 Bewertung

Für die Stufe 1 kann grundsätzlich festgestellt werden, dass die aufgestellten Regeln auch bei kleineren Abtastfrequenzen mit sehr hoher Genauigkeit die trivialen Signale identifizieren können. Bei 125 Hz ist die Genauigkeit mit 98,84 % minimal. Dadurch ergibt sich eine Differenz von nur -0,75 % im Vergleich zu 500 Hz.

Auch in der Stufe 2 ist der Einfluss der Abtastrate vernachlässigbar klein. Beim ResNet und dem FCN sind die Genauigkeiten nahezu konstant. Die Genauigkeit des LSTM verringert sich von 99,87 % auf 99,05 % und beim RanFor von 99,99 % auf 98,26 %.

Bei der Betrachtung des gesamten hybriden Modells lässt sich eine auffallende Abweichung erst bei 125 Hz feststellen. Während die Genauigkeit bei 250 Hz um nur 0,25 %

abfällt, sind es auf 125 Hz bereits 5,16 %. Allerdings ist diese mit 93,85 % immer noch hoch, weshalb das Modell auch in seiner Gesamtheit als robust gegenüber unterschiedlichen Abtastraten bei Zeitreihen aus der Deckel Maho DMC 60H-HDM bezeichnet werden kann.

7.1.3 Validierung 2 – Vertikal-Fräsmaschine

Im zweiten Validierungsfall wird ein Datensatz (TD2) der DMG MORI CMX 600V untersucht. Dieser wurde mit einer Abtastrate von 500 Hz aufgezeichnet. In diesem Kapitel wird die Variation der Abtastrate auf 250 Hz und 125 Hz analysiert. Bei der Aufzeichnung wurde ein Werkstück bearbeitet, wodurch sich ein realistischer Anwendungsfall abbilden lässt.

7.1.3.1 Ergebnisse

Stufe 1

In der Tabelle 25 sind die Genauigkeiten der Stufe 1 mit dem Datensatz TD2 aufgelistet. Bei allen Abtastraten können die vorhandenen Signale korrekt klassifiziert werden, wodurch sich eine konstante Genauigkeit von 100 % ergibt.

Tabelle 25: Genauigkeiten der Stufe 1 mit TD2 und unterschiedlichen Abtastraten nach Gönzheimer & Ströbel et al. (2023c)

	500 Hz	250 Hz	125 Hz
AVG ACC	100,00 %	100,00 %	100,00 %

Stufe 2

In Tabelle 26 sind die Genauigkeiten von Datensatz TD2 aufgelistet. Das LSTM hat die höchste Genauigkeit bei 500 Hz mit 95,71 %. Das FCN und der RanFor erreichen knapp über 90 % Genauigkeit und das ResNet erreicht 98,52 %. Für alle Modelle ist zu erkennen, dass mit der Reduktion die Abtastrate auch die Genauigkeit sinkt. Eine Ausnahme ist beim ResNet erkennbar, welches von 250 Hz auf 125 Hz wieder 0,95 % gewinnt. Das LSTM verliert insgesamt -1,06 %, das ResNet -7,23 %, der RanFor -7,49 % und das FCN -15,90 %.

Tabelle 26: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD2 nach Gönzheimer & Ströbel et al. (2023c)

ML-Modell	500 Hz	250 Hz	125 Hz
ResNet	89,52 %	82,29 %	83,34 %
FCN	90,33 %	89,73 %	74,43 %
LSTM	95,71 %	95,66 %	94,65 %
RanFor	90,37 %	89,91 %	82,88 %

Gesamtmodell

In Tabelle 27 sind die Ergebnisse des gesamten mehrstufigen Modells mit dem Datensatz TD2 aufgelistet. Die niedrigste Genauigkeit liegt mit 87,84 % bei 500 Hz. Das Maximum wird bei 250 Hz mit 88,75 % erreicht.

Tabelle 27: Ergebnisse Gesamtmodell TD2 nach Gönzheimer & Ströbel et al. (2023c)

	500 Hz	250 Hz	125 Hz
AVG ACC	87,84 %	88,75 %	88,43 %

7.1.3.2 Bewertung

Die Abtastratenvariation hat in der Stufe 1 keine Auswirkungen auf die Genauigkeit. Bei allen Abtastraten werden die trivialen Zeitreihen zu 100 % korrekt klassifiziert.

In der Stufe 2 können größere Unterschiede zwischen den Modellen und den unterschiedlichen Abtastraten festgestellt werden. Das LSTM ist das einzige Modell, welches bei allen Abtastraten nahezu konstant bleibt. Mit 94,65 % verringert sich die Abtastrate um nur 1,06 % im Vergleich zu 500 Hz und stellt damit ein robustes ML-Modell dar. Das FCN und der RanFor verzeichnen bei der Reduktion auf 250 Hz kaum einen Verlust an Genauigkeit. Jedoch fällt diese auf 125 Hz deutlich ab. Das FCN fällt von 90,33 % auf 74,43 % ab und stellt damit das ML-Modell dar, welches den größten Einfluss der Abtastrate erfährt. Das ResNet verliert auf 250 Hz 7,23 %, gewinnt dann jedoch 1,05 % auf 125 Hz und ist damit relativ konstant zwischen den beiden Frequenzen.

Beim Gesamtmodell lässt sich insgesamt kaum ein Einfluss der Abtastrate feststellen. Diese ist mit 87,84 % nahezu konstant. Auffällig ist jedoch die leicht höheren Genauigkeiten bei niedrigeren Abtastraten. Dies kann unterschiedliche Ursachen haben, beispielsweise ein durch eine niedrigere Abtastrate verringertes Rauschen, wodurch bestimmte Merkmale in Zeitreihen besser identifiziert werden können.

7.1.4 Validierung 3 – Honmaschine

Der Datensatz (TD3) für die dritte Validierung entstammt aus einer Honmaschine und wurde während eines laufenden Prozesses mit einer Abtastrate von 500 Hz aufgezeichnet. Die Variation der Abtastrate wurde auf 250 Hz und 125 Hz festgelegt. Die Anzahl an Signalen ist sehr beschränkt, weshalb bei diesem Datensatz in der dritten Stufe des Gesamtmodells nur ausgewählte Teilschritte betrachtet werden können. Dazu gehören die Teilschritte zur Identifikation der Geschwindigkeit und des Drehmoments. Die Regel zur Identifikation der Geschwindigkeit wurde leicht modifiziert, da diese in einem bisher nicht verwendeten Format vorlag.

7.1.4.1 Ergebnisse

Stufe 1

In der Tabelle 28 sind die Genauigkeiten der Stufe 1 mit dem Datensatz TD3 aufgelistet. Bei allen Abtastraten konnten die vorhandenen Signale korrekt klassifiziert werden, wodurch sich eine konstante Genauigkeit von 100 % ergibt.

Tabelle 28: Genauigkeiten der Stufe 1 mit TD3 und unterschiedlichen Abtastraten nach Gönzheimer & Ströbel et al. (2023c)

	500 Hz	250 Hz	125 Hz
AVG ACC	100,00 %	100,00 %	100,00 %

Stufe 2

In Tabelle 29 sind die Ergebnisse der Genauigkeiten mit Datensatz TD3 aufgelistet. Das ResNet und das FCN verhalten sich ähnlich mit einer maximalen Genauigkeit bei 500 Hz zwischen 87 % und 88 %. Bei der Abtastratenreduktion verringern sich diese auf 82,84 % beziehungsweise 82,69 %. Das LSTM weist eine leicht steigende Genauigkeit mit der Reduktion der Abtastrate auf. Das Maximum liegt bei 83,38 %. Auch hier wäre es möglich, dass eine Reduktion der Abtastrate zu weniger Rauschen führt, wodurch das LSTM die gelernten Merkmale besser erkennen kann. Es ist jedoch zu beachten, dass der Zuwachs an Genauigkeit nur sehr gering ist. Der RanFor liegt zwischen 84,25 % und 86,69 %.

Tabelle 29: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD3 nach Gönzheimer & Ströbel et al. (2023c)

ML-Modell	500 Hz	250 Hz	125 Hz
ResNet	87,20 %	86,76 %	82,69 %
FCN	87,94 %	86,99 %	82,84 %
LSTM	80,96 %	83,38 %	83,17 %
RanFor	86,69 %	84,25 %	85,77 %

Stufe 3

In Tabelle 30 sind die Ergebnisse der Stufe 3 unter der Verwendung der Beziehungen aus Tabelle 16 mit dem Datensatz TD3 aufgelistet. Dabei wird zwischen der ursprünglichen Regel und einer einfachen Modifikation unterschieden, wodurch sich alle Signale mit einer Genauigkeit von 100 % identifizieren lassen. Das vorhandene Drehmoment-signal konnte mit der vorhandenen Regel nicht identifiziert werden. Während der Berechnung muss nach einer Modifikation der Zeitreihe ein Bravais-Pearson-Korrelationskoeffizient von 0,8 überschritten werden. Dieser liegt bei den vorhandenen Zeitreihen nur zwischen ca. 0,51 und 0,75.

Tabelle 30: Untersuchung der Geschwindigkeitssignale von TD3 mit zusätzlicher modifizierter Regel der Stufe 3 bei unterschiedlichen Abtastfrequenzen nach Gönzheimer & Ströbel et al. (2023c)

Beziehung	Signal	500 Hz	250 Hz	125 Hz
2	VEL	0,00 %	0,00 %	0,00 %
2 (mod)	VEL	100,00 %	100,00 %	100,00 %
4	TORQUE	0,00 %	0,00 %	0,00 %

7.1.4.2 Bewertung

Die Abtastratenvariation hat in der Stufe 1 keine Auswirkungen auf die Genauigkeit. Bei allen Abtastraten werden die trivialen Zeitreihen zu 100 % korrekt klassifiziert. Damit kann erstmal gezeigt werden, dass die existierenden Regeln der Stufe 1 auch bei anderen Maschinentypen anwendbar sind.

Die ML-Modelle der Stufe 2 haben allgemein betrachtet keine sehr hohe Genauigkeit mehr. Das Maximum wird bei 500 Hz mit 87,94 % mit dem FCN erreicht. Die größte Robustheit lässt sich beim LSTM und RanFor erkennen. Während das LSTM leicht höhere Genauigkeiten bei sinkender Abtastrate verzeichnet, verhält sich der RanFor sehr konstant. Das LSTM hat mit 80,96 % bei 500 Hz die niedrigste Genauigkeit von allen

Modellen und Abtastraten. Das ResNet und das FCN verzeichnen erst bei 125 Hz eine Verringerung der Genauigkeit um ca. 4 %. Bei diesem Datensatz ist damit der RanFor das geeignetste Modell, da es hohe Genauigkeiten erzielt und gleichzeitig kaum auf die Variation der Abtastrate reagiert.

Für die Analyse der Stufe 3 wurde aufgrund der vorliegenden Signale nur die Regel zur Identifikation der Geschwindigkeiten untersucht. Dabei konnten zunächst keine Zeitreihen identifiziert werden. Die Ursache dafür liegt in Konvention der Geschwindigkeitssignale, welche alle positiv sind, obwohl die dazugehörigen Positionssignale annehmen lassen, dass es auch Signale mit negativem Vorzeichen geben müsste. Deshalb wurde eine einfache Modifikation der Regel für diese Untersuchung vorgenommen, die auch zukünftig allgemein eingesetzt werden kann. Hierfür wurde der Betrag des abgeleiteten Positionssignal verrechnet, um rein positive Werte zu erhalten. Damit können dann wiederum alle Geschwindigkeitssignale zu 100 % identifiziert werden. Für die Identifizierung der Drehmomentsignale müssen weitere Modifikationen der bestehenden Regel vorgenommen werden. Da der berechnete Wertebereich zur Zuordnung der modifizierten Zeitreihen zwischen ca. 0,51 und 0,75 liegt, sind gegebenenfalls einfachere Anpassungen ausreichend, da der Grenzwert von 0,8 bereits von vielen Signalen fast erreicht wird.

7.1.5 Validierung 4 – Industrieroboter

Die vierte Validierung wurde mit einem Datensatz (TD4) von einem KUKA-Roboter mit einer Abtastrate von 83,3 Hz aufgezeichnet. Es ist dabei zu beachten, dass der Datensatz Signale von zwei Achsen enthält, die nachfolgend mit „1“ und „2“ gekennzeichnet werden. Zur Analyse der Abtastratenvariation wurden die Frequenzen auf 41,65 Hz und 20,83 Hz festgelegt. Der Datensatz beinhaltet nur wenige Signale, weshalb in der dritten Stufe des Gesamtmodells lediglich die spezifischen Teilschritte der Identifikation von Geschwindigkeit, Strom und Drehmoment betrachtet werden. Bei der Identifikation der Geschwindigkeit liegen Signale in unterschiedliche Richtungen vor, die mit der ursprünglichen Regel zur Identifikation nicht gleichermaßen klassifiziert werden können. Deshalb wurde auch hier eine leichte Modifikation durchgeführt, die zu höheren Genauigkeiten aller Geschwindigkeitssignale führen soll.

Bei diesem Datensatz wurden zwei unterschiedliche Versuche mit einem Vertikal-Knickarmroboter durchgeführt. Bei der ersten Versuchsreihe wird ein Gewicht am Endeffektor befestigt, welches an unterschiedlichen Positionen abstoßbar ist und somit

einen Bauteilverlust darstellt. Die zweite Versuchsreihe untersucht kurzzeitige Momentüberhöhungen, welche eine Crash-Fahrt darstellen sollen. Die Prozessgeschwindigkeit wurde im Vergleich zu realen Anwendungen reduziert, um den Informationsgehalt der Daten zu erhöhen.

7.1.5.1 Ergebnisse

Stufe 1

In der Tabelle 31 sind die Genauigkeiten der Stufe 1 mit dem Datensatz TD4 aufgelistet. Bei allen Abtastraten konnten die vorhandenen Signale korrekt klassifiziert werden, wodurch sich eine konstante Genauigkeit von 100 % ergibt.

Tabelle 31: Genauigkeiten der Stufe1 mit TD4 und unterschiedlichen Abtastraten nach Gönzheimer & Ströbel et al. (2023c)

	83,3 Hz	41,65 Hz	20,83 Hz
AVG ACC	100,00 %	100,00 %	100,00 %

Stufe 2

In Tabelle 32 sind die Genauigkeiten der ML-Modelle mit dem Datensatz TD4 aufgelistet. Bei 83,3 Hz hat das LSTM mit 97,88 % die höchste Genauigkeit. Das ResNet, das FCN und der RanFor variieren zwischen ca. 91 % und 92 %. Mit der Reduktion der Abtastrate steigen bei allen Modellen die Genauigkeiten. Während das LSTM maximal 99,42 % erreicht, sind Genauigkeiten der anderen Modelle bei 100 %.

Tabelle 32: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD4 nach Gönninger & Ströbel et al. (2023c)

ML-Modell	83,3 Hz	41,65 Hz	20,83 Hz
ResNet	91,56 %	100,00 %	100,00 %
FCN	91,51 %	100,00 %	100,00 %
LSTM	97,88 %	99,01 %	99,42 %
RanFor	91,67 %	100,00 %	100,00 %

Stufe 3

In Tabelle 33 sind die Ergebnisse der Stufe 3 unter der Verwendung der Beziehungen aus Tabelle 16 mit ausgewählten Signalen aus TD4 mit deren Genauigkeiten aufgelistet. Dabei handelt es sich um Signale von Geschwindigkeit, Drehmoment und Strom. Stromsignale werden mit einer Genauigkeit von 100 % bei allen Abtastraten identifiziert. Das Drehmoment der Achse 1 wird mit 78,79 % identifiziert, wobei bei 20,83 Hz die Genauigkeit auf 75,75 % fällt. Bei Achse 2 ist die Genauigkeit konstant mit 57,78 %. Die Genauigkeiten der Geschwindigkeiten beider Achsen verhalten sich gegensätzlich. Mit der ursprünglichen Regel werden bei der Achse 1 keine Signale identifiziert, wohingegen bei Achse 2 mit Ausnahme bei 20,83 Hz 100 % erreicht werden. Mit der modifizierten Regel werden keine Geschwindigkeitssignale der Achse 2 erkannt, aber dafür bei der Achse 1 zu 100 %, mit Ausnahme von 20,83 Hz. Mit 20,83 Hz werden 75,76 % korrekt identifiziert.

Tabelle 33: Untersuchung ausgewählter Signale von TD4 mit modifizierten Regeln der Stufe 3 bei unterschiedlichen Abtastfrequenzen nach Gönzheimer & Ströbel et al. (2023c)

Beziehung	Signal	83,3 Hz	41,65 Hz	20,83 Hz
2	VEL_1	0,00 %	0,00 %	0,00 %
2 (mod)	VEL_1	100,00 %	96,97 %	75,76 %
4	CUR_1	100,00 %	100,00 %	100,00 %
4	TOR_1	78,79 %	78,79 %	75,76 %
2	VEL_2	100,00 %	100,00 %	71,11 %
2 (mod)	VEL_2	0,00 %	0,00 %	0,00 %
4	CUR_2	100,00 %	100,00 %	100,00 %
4	TOR_2	57,78 %	57,78 %	57,78 %

7.1.5.2 Bewertung

Die Abtastratenvariation hat in der Stufe 1 keine Auswirkungen auf die Genauigkeit. Bei allen Abtastraten werden die trivialen Zeitreihen zu 100 % korrekt klassifiziert. Damit kann erneut gezeigt werden, dass die existierenden Regeln der Stufe 1 auch bei Maschinentypen mit ausschließlich Rotationsachsen verwendet werden können.

Bei der Untersuchung der ML-Modelle ist besonders auffällig, dass sich die Genauigkeiten bei niedrigeren Abtastfrequenzen erhöhen. Bei dem ResNet, FCN und beim RanFor wird bereits bei 250 Hz eine Genauigkeit von 100 % erreicht, was in Anbetracht des Informationsverlusts bemerkenswert ist. Auch hier kann die leicht gestiegene Genauigkeit verschiedene Ursachen haben. Naheliegend wäre eine Rauschreduktion durch niedrigere Abtastraten. Außerdem besitzen diese drei ML-Modelle bei 500 Hz mit 91,5 % in etwa die gleiche Genauigkeit, wodurch sie sich nahezu identisch verhalten. Das LSTM weist bei 500 Hz bereits eine Genauigkeit von 97,88 % auf und erhöht sich mit sinkender Frequenz auf 99,42 %. Dieses Verhalten ist im Vergleich zu den Datensätzen TD1, TD2 und TD3 untypisch und muss näher analysiert werden. Die vorhandenen Zeitreihen aus TD4 besitzen allerdings nur wenige Datenpunkte, sodass beispielsweise die Reduktion der Abtastrate nicht weiter verringert werden kann, da eine Mindestlänge benötigt wird, die andernfalls nicht eingehalten werden kann. Bei noch niedrigeren Abtastraten wären niedrigere Genauigkeiten zu erwarten, da der Informationsgehalt ab einem bestimmten Zeitpunkt nicht mehr ausreichend sein dürfte. In weiteren Untersuchungen müssten Signale mit deutlich längerer Dauer aufgezeichnet werden, um weitere Erkenntnisse über den Einfluss der Abtastrate zu erhalten.

Für die Analyse der Stufe 3 fehlen wie auch bei TD3 ausreichend viele Zeitreihen, weshalb auch hier einzelne Regeln auf ihre Eignung untersucht werden. Dabei handelt es sich um die Regeln zur Identifikation von Geschwindigkeit, Strom und Drehmoment. Zunächst kann festgestellt werden, dass alle Stromsignale mit einer Genauigkeit von 100 % bei allen Abstraten identifiziert werden können. Beim Drehmoment liegt die Genauigkeit der Achse 1 nahezu konstant bei 78 % und bei Achse 2 bei 57,78 %. Damit sind die Regeln nicht mehr vollkommen zuverlässig anwendbar und müssten gegebenenfalls angepasst werden. Bei der Identifikation der Geschwindigkeitssignalen lässt sich wie bei TD3 erneut eine spezifische Konvention der Signale erkennen. Während mit der bestehenden Regel bei der Achse 1 keine Geschwindigkeitssignale identifiziert werden können, werden diese bei Achse 2 mit 83,3 Hz und 41,65 Hz zu 100 % und bei 20,83 Hz mit 71,11 % erkannt. Bei näherer Betrachtung ist erkennbar, dass sich das Geschwindigkeitssignal der Achse 1 in Bezug auf das Vorzeichen invertiert gegenüber dem dazugehörigen Positionssignal verhält. Mit der Modifikation der Regel, dass alle Werte mit „minus“ multipliziert werden, können nun die Signale der Achse 1 bei 83,3 Hz identifiziert werden, jedoch die Signale der Achse 2 wie erwartet nicht mehr. Die Ursache könnte darin liegen, dass die Koordinatensysteme zueinander verdreht sind, wodurch die invertierten Geschwindigkeitssignale entstehen. Bei 41,65 Hz verringert sich die Genauigkeit auf 96,67 % und bei 20,83 Hz werden noch 75,76 % Genauigkeit erzielt. Dadurch ist die Kenntnis der Ursache bewiesen und könnte allgemein in allen Fällen durch eine einzige Modifikation gelöst werden. Dafür müsste der Betrag von dem abgeleiteten Positionssignal und dem Geschwindigkeitssignal genommen werden, wodurch alle Datenpunkte im positiven Bereich angeordnet wären.

7.2 Zusammenfassende Bewertung der Validierung

Im Rahmen dieses Kapitels werden die Ergebnisse der Validierung bewertend zusammengefasst und ein Fazit gezogen.

7.2.1 Bewertung innerhalb des Typs Fräszentren

Die Ergebnisse der Datensätze TD1 und TD2 sind beide sehr vielversprechend, da besonders viele Signale identifiziert werden können. In der ersten Stufe werden unabhängig von der Abstrakte nahezu alle trivialen Signale identifiziert. Bei den ML-Modellen gibt es deutliche Unterschiede zwischen den Datensätzen. Während alle Modelle bei TD1 sehr gute Ergebnisse erzielen, sind bei TD2 starke Differenzen zu erkennen. Mit dem LSTM können aber trotzdem noch sehr gute Ergebnisse erzielt

werden. Auffällig dabei ist, dass die Ergebnisse kaum auf die Variation der Abtastrate reagieren, sondern nahezu konstant bleiben. Bei der Analyse der Gesamtmodells sind wieder erkennbare Unterschiede vorhanden. Bei TD1 sinkt die Genauigkeit bei der Abtastratenvariation von 500 Hz mit 99,01 % auf 93,85 % bei 125 Hz. Bei 250 Hz ist die Differenz vernachlässigbar klein. Der Einfluss der Abtastrate bei TD2 ist bei allen Frequenzen vernachlässigbar. Dadurch kann geschlussfolgert werden, dass die Abtastrate erst ab 125 Hz eine nicht mehr zu vernachlässigende Reduktion der Genauigkeit aufweist, welche jedoch für einige Anwendungsfälle trotzdem noch ausreichend gut sein kann.

7.2.2 Bewertung des Gesamtmodells auf Maschinen anderen Typs

Mit den Datensätzen TD3 und TD4 wurde überprüft, wie gut die jeweiligen Stufen des Gesamtmodells Zeitreihen von Maschinen anderen Typs identifizieren können und wie groß der Einfluss der Abtastrate auf die Ergebnisse ist. Die erste Stufe konnte bei beiden Datensätzen alle trivialen Signale identifizieren. Allerdings sind hier im Vergleich zu TD1 und TD2 auch deutlich weniger Signale vorhanden. Für eine stärkere Aussagekraft müssten größere Datensätze aufgezeichnet werden. In der zweiten Stufe sind die Ergebnisse der beiden Datensätze sehr unterschiedlich. Mit TD3 werden mit keinem Modell Ergebnisse über 87,94 % erzielt. Trotzdem lassen sich dadurch jedoch fast alle Signale korrekt identifizieren, da die Zuweisung zu einer Klasse über das Verhältnis der jeweiligen zugeordneten Samples eines Signals bestimmt wird. Auffällig ist jedoch, dass die Variation der Abtastrate im Durchschnitt kaum große Auswirkungen auf die Genauigkeit besitzt. Bei TD4 erhöht sich hingegen die Genauigkeit mit sinkender Abtastrate, was mit zusätzlichen länger andauernden Aufzeichnungen weiter untersucht werden sollte. Dennoch kann aus beiden Datensätzen geschlussfolgert werden, dass die Teilstufen auch bei Aufzeichnungen anderer Maschinentypen Signale gut identifizieren können. Bei der dritten Stufe wurden aufgrund inkompatibler Formate der Zeitreihen leichte Modifikationen durchgeführt, die jedoch die Ergebnisse und ihre Aussagekraft nicht beeinflussen. Bei TD3 konnten durch die Modifikation alle Signale identifiziert werden, die Reduktionen der Abtastrate haben keinen Einfluss auf die Genauigkeit gezeigt. Bei TD4 sind unterschiedliche Signaltypen vorhanden, von denen besonders Stromsignale gut identifiziert werden konnten. Bei Drehmomentsignalen ist die Genauigkeit bei maximal 78,79 %. Durch die Modifikation konnten auch alle Geschwindigkeitssignale identifiziert werden. Die Reduktion der Abtastrate ist erst bei

20,83 Hz deutlich erkennbar, wobei besonders die Identifikation der Geschwindigkeits-signale an Genauigkeit verliert. Insgesamt lässt sich jedoch feststellen, dass die vorhandenen Regeln der Stufe 3 auch auf Zeitreihen von Maschinen anderen Typs grundsätzlich anwendbar sind.

7.2.3 Zusammenfassende Bewertung und Grenzen des Ansatzes

Bei der Betrachtung der Reduktion der Abtastrate kann festgestellt werden, dass ein nichtlinearer Einfluss erkennbar ist. Dies bedeutet, dass bei einer Erhöhung der Abtast-ratenreduktion die Genauigkeit überproportional abnimmt. Dieser Einfluss ist allerdings häufig erst bei einer starken Reduktion um den Faktor vier nicht mehr zu vernachlässi-gen. Bei der Halbierung der Abtastrate ist der Verlust der Genauigkeit größtenteils sehr gering. Dadurch kann geschlussfolgert werden, dass das Gesamtmodell insgesamt eine begrenzte Robustheit gegenüber niedrigen Abtastraten besitzt.

Bei der Analyse des Gesamtmodells auf die unterschiedlichen Maschinentypen kann festgestellt werden, dass die Teilstufen in allen Fällen Signale identifizieren können. Bei der ersten Stufe sind keine Unterschiede zu erkennen. Bei den ML-Modellen differenzieren sich die Genauigkeiten teilweise sehr stark. Das LSTM-Modell ist dabei bei allen Maschinentypen und Abtastfrequenzen am robustesten und liefert sehr gute Ergeb-nisse. Auch die analytischen Regeln der Stufe 3 können auf Datensätze anderer Maschinentypen verwendet werden. Lediglich kleinere Modifikationen mussten bei die-ser Validierung durchgeführt werden. Das Gesamtmodell zeigt durch die durchgeführten Validierungen ein großes Potential der Generalisierungsfähigkeit und stellt damit eine geeignete Basis für die Anbindung sowie Exploration auch eines grö-ßeren Spektrums an Maschinen und Anlagen dar. Gleichzeitig muss berücksichtigt werden, dass bei anderen Typen von Produktionsanlagen einzelne Berechnungs-schritte der analytischen Regelbasen gegebenenfalls modifiziert werden müssen. Beispiele hierfür sind unter Umständen Grenzwerte und statistische Merkmale.

Für eine Generalisierung ist auch die Erweiterung des Signalraums von großer Bedeu-tung, da der aktuelle Ansatz auf Antriebsachsen fokussiert ist. Die Ergänzung weiterer Signale erfordert je nach Signalart und -umfang möglicherweise auch die Ergänzung weiterer auf Domänenwissen basierender Regelbasen und möglicherweise ein Neu-training des ML-Modells.

Damit steht mit der entwickelten Lösung ein Ansatz zur Verfügung, der neben den Werkzeugen zur Datenextraktion vielfältige Untersuchungs- und Evaluationsmethoden

für die Identifikation von Zeitreihendaten umfasst. Diese sind in dieser Arbeit in ein Assistenzsystem eingebettet, das den Anwender durch den Explorationsprozess leitet, die Extraktion von Maschinendaten für verschiedene Schnittstellen im Brownfield erlaubt, den Identifikationsprozess für Signale automatisiert und eine effiziente Basis für aufbauende Industrie 4.0-Anwendungen erzeugt.

8 Zusammenfassung und Ausblick

Dieses Kapitel gibt einen abschließenden Überblick zur Dissertation in Form einer Zusammenfassung sowie einen Ausblick auf mögliche aufbauende Forschungsthemen.

8.1 Zusammenfassung

Die industrielle Produktion muss durch zunehmende Kundenanforderungen hinsichtlich der Kosten, Lieferzeiten und Flexibilität sowie einen starken globalen Wettbewerb eine hohe Kosteneffizienz bei gleichzeitig hoher Qualität erreichen. Die Digitalisierung und Vernetzung der Produktion nimmt hierbei einen hohen Stellenwert ein. Industrie 4.0-Anwendungen, beispielsweise Anomalie- oder Verschleißdetektionssysteme, können für die Erreichung einer hohen Gesamtanlageneffektivität wichtige Beiträge leisten. Eine entscheidende Rolle kommt hierbei der Digitalisierung von Brownfield-Produktionssystemen zu, deren Datenbereitstellung Unternehmen als zentrale Herausforderung sehen und die für diese einen gegenwärtig großen Aufwand darstellt. Notwendig ist auf dieser Basis ein für Anwender aufwandsminimales System, das diese mit der automatisierten Extraktion und Identifikation von Maschinensteuerungsdaten in Brownfield-Produktionssystemen unterstützt.

Die Analyse des Stands der Forschung und Technik zeigt, dass zur Zeit der Entstehung dieser Dissertation keine hinreichenden Lösungen existieren, die eine umfassende Unterstützung von Anwendern bei dieser Aufgabe darstellen. Bisherige Ansätze im Bereich der Datenextraktion und Kommunikation fokussieren vor allem den Austausch von Steuerungssystemen und die Nachrüstung aufwändiger Hard- und Softwarelösungen. Existierende Open Source-Entwicklungen können hier Lösungsansätze darstellen, beschränken sich jedoch ebenfalls auf die Übertragung noch zu identifizierender Datensätze. Die automatisierte Identifikation von Signalen ist Gegenstand einzelner Entwicklungsarbeiten, beinhaltet jedoch ausschließlich Anwendungen in Automobilen mit spezifischen Signalen. Ein kombiniertes System, das für die Datenextraktion sowie die aufbauende Identifikation und Zuordnung von Maschinensteuerungssignalen genutzt werden kann, ist gegenwärtig nicht bekannt.

Ziel dieser Dissertation ist es auf dieser Basis, Maschinensteuerungsdaten in Brownfield-Produktionssystemen automatisiert bereitzustellen. Die Bereitstellung umfasst dabei die Erarbeitung geeigneter Lösungen für die initiale Extraktion von Daten und die Entwicklung einer Methodik für die aufbauende Identifikation der angestrebten Signale.

Das Lösungssystem wird realisiert, indem zunächst ein Kommunikationssystem für verschiedene im Brownfield existierende Datenquellen erarbeitet wird. Im Fokus davon stehen Signale aus Antriebsachsen wie Motorströme und Lagewerte, mit denen die beschriebenen Industrie 4.0-Anwendungen gespeist werden können. Für den Verbindungsaufbau werden auf Basis von Open Source Java Bibliotheken Konnektoren zu Kommunikationsprotokollen wie OPC UA, OPC DA und MQTT sowie Datenbanken und SPS implementiert.

In einem zweiten Schritt werden Konzepte zur automatisierten Identifikation der angestrebten Signale aus den extrahierten Datensätzen entwickelt. Hierfür werden verschiedene analytische sowie ML-basierte Ansätze umgesetzt und hinsichtlich ihrer Stärken und Schwächen evaluiert. Auf Basis der Untersuchungen wird darauf aufbauend ein dreistufiges hybrides Identifikationssystem konzeptioniert. Dieses kombiniert ML-Verfahren sowie analytische Zusammenhänge und die Stärken beider Ansätze. Die Eignung des hybriden Systems zeigt sich dabei in sehr hohen Genauigkeiten bei der Signalidentifikation.

Beide Teilsysteme zur Datenextraktion und -identifikation werden darauf aufbauend in ein umfassendes Assistenzsystem mit Benutzeroberfläche integriert, das den Anwender durch den mehrstufigen Ablauf des Bereitstellungsprozesses führt. Der assistierte Prozess beginnt mit der Auswahl der Datenquelle und endet mit der Ausgabe der zugeordneten Signale für den Anwender. Der Anwender kann dabei zwischen der simplen Zuordnungsinformation von Datenquellen zu Zielsignalen sowie der Erzeugung eines Datenservers in Zielstruktur wählen. Die Zuordnungsinformation gleicht dabei einer Legende mit Übersetzungen beziehungsweise Erläuterung der Maschinensignale. Im Fall des erzeugten Datenservers werden die Maschinensignale in einer definierten Struktur und in definierten Benennungen ausgegeben.

Abschließend findet eine Validierung hinsichtlich der Funktionsfähigkeit und Übertragbarkeit statt, in der das entwickelte System in verschiedenen Anwendungsfällen getestet wird. Die Validierung wird dabei schrittweise von einer bauartverwandten Maschine über eine stärker abweichende Anlage bis hin zu einem Industrieroboter durchgeführt. Die Ergebnisse zeigen die grundsätzliche Robustheit des entwickelten Systems sowie sein Generalisierungspotential hinsichtlich eines weiteren Spektrums an Produktionsanlagen.

8.2 Ausblick

Das im Rahmen dieser Dissertation entwickelte System fokussiert zum einen die Anwendung an Werkzeugmaschinen und zum anderen die Bereitstellung von Signalen aus Antriebsachsen wie Motorströme und Lagewerte. Eine Erweiterung dieser beiden Eingrenzungen in Richtung einer Generalisierung für weitere Produktionsmaschinen würde eine sinnvolle Weiterführung darstellen. Neben Werkzeugmaschinen gibt es in Brownfield-Produktionen viele weitere, in Teilen auch sehr spezifische Anlagen, die von SPS gesteuert werden und in der Anbindung vergleichbare Herausforderungen besitzen. Die Validierung des entwickelten Ansatzes zeigt, dass am Beispiel des Industrieroboters eine grundsätzliche Übertragbarkeit gegeben ist. Systematische Planungen und Tests zur weiteren Generalisierung sowie entsprechende Anpassungen des Systems wären darüber hinaus jedoch folgerichtige weitere Schritte. In diesem Zug wäre auch die Erweiterung des Signalraums sinnvoll, beispielsweise auf weitere Komponentensignale wie Temperaturdaten oder Statussignale der Maschine. Notwendig wäre in diesem Fall auch die Erweiterung der Identifikationsmethodik, beispielsweise um die Analyse der Knotenbezeichnungen der Datenquellen.

Erweitert werden könnten der Ansatz und das entwickelte Assistenzsystem außerdem hinsichtlich nachfolgender Programmschritte, die sich an die Identifikation der Signale anschließen. Mögliche Umfänge wären beispielsweise die Bestimmung des Aufbaus der Maschine oder der Systemparameter der analysierten Antriebsachsen. Konzepte, wie ein ergänzender Funktionsumfang mit zusätzlichen Analysen aussehen könnte, werden unter anderem von Chen & Zhu et al. (2015), Oexle & Fleischer (2023) sowie Puchta & Frisch et al. (2024) vorgestellt. Mit der Integration der Komponentenidentifikation aus Vorschubachsen von Puchta & Frisch et al. (2024) wäre neben der in dieser Dissertation entwickelten Bestimmung der Signale der Vorschubachsen auch die Bestimmung von deren Aufbau hinsichtlich verwendeter Motoren, Getriebe und Führungen möglich. Hierfür verwendet werden könnten außerdem die in Kapitel 5.1 entwickelten Referenzfahrten, die im Ansatz von Puchta & Frisch et al. (2024) als Fahrt einer Strecke zwischen zwei Punkten mit unterschiedlichen Geschwindigkeiten benötigt werden.

Vorstellbar ist darüber hinaus eine Erweiterung der Assistenzfunktion hinsichtlich der Umsetzung aufbauender Industrie 4.0-Anwendungen wie Condition Monitoring-Systemen oder der von Oexle & Fleischer (2023) entwickelten automatischen

Parametrierung von Maschinenmodellen aus einer Art App Store. Neben der Identifikation von Datenquellen könnte das System dem Anwender aufzeigen, welche notwendigen Input-Daten für aufbauende Anwendungen nicht gefunden wurden und wie diese gewonnen werden könnten. Im Fall des exemplarischen Ansatzes von Oexle & Fleischer (2023) sind Positionsdaten aus den Vorschubachsen, Prozesskräfte und Beschleunigungsdaten der Spindel notwendig. Bei identifizierten Positionsdaten aus Vorschubachsen und Beschleunigungsdaten der Spindel wäre es beispielsweise denkbar, dass keine Prozesskräfte vorliegen, zu deren Erfassung dem Anwender die Verwendung einer Kraftmessplatte vorgeschlagen wird.

Aus den genannten Ansätzen ergeben sich drei zentrale Forschungsfelder für mögliche aufbauende Arbeiten: 1. die Erweiterungen des Fokus des entwickelten Assistenzsystems über Werkzeugmaschinen und den umgesetzten Signalraum hinaus, 2. die Integration weiterer Identifikationsschritte, beispielsweise hinsichtlich des Maschinenaufbaus und der Systemparameter und 3. eine aufbauende Assistenzfunktion bei der Umsetzung von Industrie 4.0-Anwendungen.

9 Publikationsliste des Autors

Armbruster & Gönzheimer et al. 2021

Armbruster, J.; Gönzheimer, P. & Netzer, M. (2021), „Predictive Maintenance in der Antriebstechnik“, *computer & automation*, 2021(09-21), S. 66–69.

Gönzheimer & Hillenbrand et al. 2019

Gönzheimer, P.; Hillenbrand, J.; Betz-Mors, T.; Bischof, P.; Mohr, L. & Fleischer, J. (2019), „Auto-configuration of a digital twin for machine tools by intelligent crawling“. *Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP), September 30th - October 2nd, Hamburg 2019*, Hrsg. J. P. Wulfsberg, W. Hintze & B.-A. Behrens. WGP Annual Congress 2019. 30.09.-02.10.2019. Hamburg, Springer Vieweg, Berlin, Heidelberg, S. 543–552. https://doi.org/10.1007/978-3-662-60417-5_54.

Gönzheimer & Hillenbrand et al. 2023

Gönzheimer, P.; Hillenbrand, J.; Heider, I.; Baucks, M. & Fleischer, J. (2023), „Enabling data-based applications in manufacturing: Approaches for broadly applicable machine data acquisition and intelligent parameter identification“. *Production at the Leading Edge of Technology. Proceedings of the 12th Congress of the German Academic Association for Production Technology (WGP), University of Stuttgart, October 2022*, Hrsg. M. Liewald, A. Verl, T. Bauernhansl & H.-C. Möhring. WGP Annual Congress 2022. 11.-14.10.2022. Stuttgart, Springer, Cham, S. 555–563. https://doi.org/10.1007/978-3-031-18318-8_56.

Gönzheimer & Karle et al. 2021

Gönzheimer, P.; Karle, A.; Mohr, L. & Fleischer, J. (2021), „Comprehensive machine data acquisition through intelligent parameter identification and assignment“. *Procedia CIRP. 54th CIRP CMS 2021 - Towards Digitalized Manufacturing 4.0*, Hrsg. D. Mourtzis. CIRP CMS 2021 - 54th CIRP Conference on Manufacturing Systems. 22.-24.09.2021. Athen, Elsevier, Amsterdam, S. 720–725. <https://doi.org/10.1016/j.procir.2021.11.121>.

Gönzheimer & Netzer et al. 2022

Gönzheimer, P.; Netzer, M.; Lange, C.; Dörflinger, R.; Armbruster, J. & Fleischer, J. (2022), „Datenaufnahme und -verarbeitung in der Brownfield-Produktion“,

Zeitschrift für wirtschaftlichen Fabrikbetrieb, 117(5), S. 317–320.

<https://doi.org/10.1515/zwf-2022-1062>.

Gönnheimer & Netzer et al. 2020

Gönnheimer, P.; Netzer, M.; Mohr, L.; Hörsten, G. von & Fleischer, J. (2020), „Erhöhung der Skalierbarkeit von KI-Anwendungen in Produktionsanlagen“,

Zeitschrift für wirtschaftlichen Fabrikbetrieb, 115(7-8), S. 517–519.

<https://doi.org/10.3139/104.112318>.

Gönnheimer & Puchta et al. 2020

Gönnheimer, P.; Puchta, A. & Fleischer, J. (2020), „Automated Identification of Parameters in Control Systems of Machine Tools“. *Production at the leading edge of technology. Proceedings of the 10th Congress of the German Academic Association for Production Technology (WGP), Dresden, 23-24 September 2020*, Hrsg. B.-A. Behrens, A. Brosius, W. Hintze, S. Ihlenfeldt & J. P. Wulfsberg. WGP Annual Congress 2020. 23.-24.09.2020. Dresden, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 568–577. https://doi.org/10.1007/978-3-662-62138-7_57.

Gönnheimer & Ströbel et al. 2023a

Gönnheimer, P.; Ströbel, R.; Dörflinger, R.; Mattes, M. & Fleischer, J. (2023), „Interoperable system for automated extraction and identification of machine control data in brownfield production“. *Manufacturing Letters. 51st SME North American Manufacturing Research Conference (NAMRC 51)*, Hrsg. R. Gao, X. Xu & I. Ragai. 51st SME North American Manufacturing Research Conference. 12.-16.06.2023. New Brunswick, NJ, Elsevier, Amsterdam, S. 915–925.

<https://doi.org/10.1016/j.mfglet.2023.08.010>.

Gönnheimer & Ströbel et al. 2023b

Gönnheimer, P.; Ströbel, R.; Roßkopf, A.; Dörflinger, R.; Walter, I.; Becker, J. & Fleischer, J. (2023), „Potential of systematically generated training datasets on the accuracy and generalization of AI-based approaches for the automated identification of machine control signals“.

Procedia CIRP. 16th CIRP Conference on Intelligent Computation in Manufacturing Engineering, Hrsg. R. Teti & D. D'Addona. 16th CIRP Conference on Intelligent Computation in Manufacturing Engineering. 13.-15.07.2022. Neapel, Elsevier, Amsterdam, S. 145–150.

<https://doi.org/10.1016/j.procir.2023.06.026>.

Gönnheimer & Ströbel et al. 2023c

Gönnheimer, P.; Ströbel, R.; Dörflinger, R.; Mattes, M.; Alexander, P.; Wuest, T. & Fleischer, J. (2023), „Generalizability of an Identification Approach for Machine Control Signals in Brownfield Production Environments“. *Procedia CIRP. Procedia CIRP - Proceedings of the 56th CIRP Conference on Manufacturing Systems 2023*, Hrsg. K. Mporfu, N. Sacks & O. Damm. 56th CIRP Conference on Manufacturing Systems 2023. 24.-26.10.2023. Kapstadt, Elsevier, Amsterdam, S. 649–654. <https://doi.org/10.1016/j.procir.2023.09.053>.

Gönnheimer & Ströbel et al. 2023d

Gönnheimer, P.; Ströbel, R. & Fleischer, J. (2023), „Analytical Approach for Parameter Identification in Machine Tools Based on Identifiable CNC Reference Runs“. *Production at the Leading Edge of Technology. Proceedings of the 12th Congress of the German Academic Association for Production Technology (WGP), University of Stuttgart, October 2022*, Hrsg. M. Liewald, A. Verl, T. Bauernhansl & H.-C. Möhring. WGP Annual Congress 2022. 11.-14.10.2022. Stuttgart, Springer, Cham, S. 494–503. https://doi.org/10.1007/978-3-031-18318-8_50.

Gönnheimer & Ströbel et al. 2022

Gönnheimer, P.; Ströbel, R.; Netzer, M. & Fleischer, J. (2022), „Generation of identifiable CNC reference runs with high information content for machine learning and analytic approaches to parameter identification“. *Procedia CIRP - Leading manufacturing systems transformation - Proceedings of the 55th CIRP Conference on Manufacturing Systems 2022*, Hrsg. E. Carpanzano, C. Boër & A. Valente. CIRP CMS 2022 - 55th CIRP Conference on Manufacturing Systems. 29.06.-01.07.2022. Lugano, Elsevier, Amsterdam, S. 734–739. <https://doi.org/10.1016/j.procir.2022.05.054>.

Hillenbrand & Gönnheimer et al. 2021

Hillenbrand, J.; Gönnheimer, P.; Gerlitz, E. & Fleischer, J. (2021), „Design and implementation of a holistic framework for data integration in industrial machine and sensor networks“. *Procedia CIRP. 54th CIRP CMS 2021 - Towards Digitalized Manufacturing 4.0*, Hrsg. D. Mourtzis. CIRP CMS 2021 - 54th CIRP Conference on Manufacturing Systems. 22.-24.09.2021. Athen, Elsevier, Amsterdam, S. 1771–1776. <https://doi.org/10.1016/j.procir.2021.11.298>.

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*(1/2021 vol. 21), S. 98–108. <https://doi.org/10.36897/jme/132248>.

Netzer & Begemann et al. 2021

Netzer, M.; Begemann, E.; Gönzheimer, P. & Fleischer, J. (2021), „Digitalisierung im deutschen Maschinen- und Anlagenbau/Study on Digitalization in the German Mechanical Engineering Sector“. Aktuelle Studie zur Digitalisierung im deutschen Maschinen- und Anlagenbau und Bedarfsanalyse, *wt Werkstattstechnik online*, 111(07-08), S. 526–530. <https://doi.org/10.37544/1436-4980-2021-07-08-58>.

10 Literaturverzeichnis

Verweise gemäß dem Schema (A_Name Jahr) beziehen sich auf studentische Arbeiten, die vom Verfasser der Dissertation angeleitet wurden.

A_Baucks 2021

Baucks, M. (2021), *Integration und Weiterentwicklung eines KI-basierten Systems zur automatisierten Extraktion und Identifikation von Maschinenparametern*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönzheimer.

A_Dörflinger 2022

Dörflinger, R. (2022), *Entwicklung und Integration eines interoperablen Systems zur automatisierten Extraktion und Identifikation von Maschinensteuerungsdaten im Brownfield*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönzheimer.

A_Heider 2021

Heider, I. (2021), *Entwicklung eines Konzepts zur kommunikationstechnischen Anbindung von Werkzeugmaschinen als Basis für ein System zur automatisierten Identifikation und Bereitstellung von Steuerungsparametern*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönzheimer.

A_Karle 2020

Karle, A. N. (2020), *Entwicklung eines KI-basierten Ansatzes zur automatisierten Identifikation und Zuordnung von Maschinenparametern*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönzheimer.

A_Kupfernagel 2021

Kupfernagel, T. (2021), *Entwicklung eines KI-basierten Ansatzes zum automatisierten Clustern von Zeitreihendaten und der aufbauenden Identifikation klassifizierter Parameter*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönzheimer.

A_Puchta 2020

Puchta, A. (2020), *Entwicklung eines Ansatzes zur automatisierten Identifikation von Zeitreihendaten durch Maschinelles Lernen*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönninger.

A_Ströbel 2022

Ströbel, R. (2022), *Automatisierte Generierung von identifizierbaren Referenzfahrten für einen KI-basierten Ansatz und Entwicklung eines analytischen Ansatzes für die Parameteridentifikation in Produktionssystemen*. Masterarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, wbk Institut für Produktionstechnik. Angeleitet durch Philipp Gönninger.

Aggarwal 2018

Aggarwal, C. C. (2018), *Machine Learning for Text*, Springer International Publishing, Cham.

Akcora & Li et al. 2021

Akcora, C. G.; Li, Y.; Gel, Y. R. & Kantarcioglu, M. (2021), „BitcoinHeist: Topological Data Analysis for Ransomware Detection on the Bitcoin Blockchain“. *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence*, Hrsg. C. Bessiere. Twenty-Ninth International Joint Conference on Artificial Intelligence. 07.-15.01.2021. Yokohama, Japan, Association for Computing Machinery, New York, NY, S. 4439–4445.

Armbruster & Gönninger et al. 2021

Armbruster, J.; Gönninger, P. & Netzer, M. (2021), „Predictive Maintenance in der Antriebstechnik“, *computer & automation*, 2021(09-21), S. 66–69.

Bahmann 2013

Bahmann, W. (2013), *Werkzeugmaschinen kompakt. Baugruppen, Einsatz und Trends*, Springer Vieweg, Wiesbaden.

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(07-08), S. 491–495. <https://doi.org/10.37544/1436-4980-2020-07-08-35>.

Bauernhansl & Krüger et al. 2016

Bauernhansl, T.; Krüger, J.; Reinhart, G. & Schuh, G. (2016), *WGP-Standpunkt Industrie 4.0*.

Bender & Göhlich 2020

Bender, B. & Göhlich, D. (2020), *Dubbel Taschenbuch für den Maschinenbau 2: Anwendungen*, Springer Berlin Heidelberg, Berlin, Heidelberg. ISBN: 978-3-662-59712-5.

Benker & Zaeh 2022

Benker, M. & Zaeh, M. F. (2022), „Condition monitoring of ball screw feed drives using convolutional neural networks“, *CIRP Annals*, 71(1), S. 313–316. <https://doi.org/10.1016/j.cirp.2022.03.017>.

Böge & Böge 2021

Böge, A. & Böge, W. (2021), *Handbuch Maschinenbau*, Springer Fachmedien Wiesbaden, Wiesbaden.

Brecher & Weck 2021

Brecher, C. & Weck, M. (2021), *Werkzeugmaschinen Fertigungssysteme 3*, Springer Berlin Heidelberg, Berlin, Heidelberg.

Brecher & Weck 2019

Brecher, C. & Weck, M. (2019), *Werkzeugmaschinen Fertigungssysteme 1*, Springer Berlin Heidelberg, Berlin, Heidelberg.

Candanedo & Feldheim 2016

Candanedo, L. M. & Feldheim, V. (2016), „Accurate occupancy detection of an office room from light, temperature, humidity and CO₂ measurements using statistical learning models“, *Energy and Buildings*, 112, S. 28–39. <https://doi.org/10.1016/j.enbuild.2015.11.071>. <https://www.sciencedirect.com/science/article/pii/S0378778815304357>.

Chen & Zhu et al. 2015

Chen, G.; Zhu, S. & Zheng, Q. (2015), „Dynamic parameters' identification for the feeding system of computer numerical control machine tools stimulated by G-

code“, *Advances in Mechanical Engineering*, 7(8), 168781401559783.

<https://doi.org/10.1177/1687814015597830>.

Choo & Greplova et al. 2020

Choo, K.; Greplova, E.; Fischer, M. H. & Neupert, T. (2020), *Machine Learning kompakt. Ein Einstieg für Studierende der Naturwissenschaften*, Springer Fachmedien Wiesbaden, Wiesbaden. ISBN: 978-3-658-32267-0.

Čulić Gambiroža & Mastelić et al. 2023

Čulić Gambiroža, J.; Mastelić, T.; Nižetić Kosović, I. & Čagalj, M. (2023), „Lost in data: recognizing type of time series sensor data using signal pattern classification“, *International Journal of Data Science and Analytics*.

<https://doi.org/10.1007/s41060-023-00413-9>.

Dhamija & Günther et al. 2018

Dhamija, A. R.; Günther, M. & Boulton, T. E. (2018), „Reducing Network Agnostophobia“. *NIPS'18: Proceedings of the 32nd International Conference on Neural Information Processing Systems*, Hrsg. S. Bengio, H. M. Wallach, H. Larochelle, K. Grauman & N. Cesa-Bianchi. 32nd International Conference on Neural Information Processing Systems. 03.-08.12.2018. Montréal, Association for Computing Machinery, New York, NY, S. 9175–9186.

Emec & Krüger et al. 2016

Emec, S.; Krüger, J. & Seliger, G. (2016), „Online Fault-monitoring in Machine Tools Based on Energy Consumption Analysis and Non-invasive Data Acquisition for Improved Resource-efficiency“. *Procedia CIRP. 13th Global Conference on Sustainable Manufacturing – Decoupling Growth from Resource Use*, Hrsg. G. Seliger, H. Kohl & J. Mallon. 13th Global Conference on Sustainable Manufacturing – Decoupling Growth from Resource Use. 16.-18.09.2015. Ho Chi Minh City / Binh Duong, Vietnam, Elsevier, Amsterdam, S. 236–243. <https://doi.org/10.1016/j.procir.2016.01.111>.

Fahle & Prinz et al. 2020

Fahle, S.; Prinz, C. & Kuhlentötter, B. (2020), „Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application“. *Procedia CIRP. 53rd CIRP Conference on Manufacturing Systems 2020*, Hrsg. R. Gao & K. Ehmann. 53rd CIRP Conference on

Manufacturing Systems. 01.-03.07.2020. Chicago, IL, Elsevier, Amsterdam, S. 413–418. <https://doi.org/10.1016/j.procir.2020.04.109>.

Farahani & McCormick et al. 2023a

Farahani, M. A.; McCormick, M. R.; Gianinny, R.; Hudacheck, F.; Harik, R.; Liu, Z. & Wuest, T. (2023), „Time-series pattern recognition in Smart Manufacturing Systems: A literature review and ontology“, *Journal of Manufacturing Systems*, 69, S. 208–241. <https://doi.org/10.1016/j.jmsy.2023.05.025>.

Farahani & McCormick et al. 2023b

Farahani, M. A.; McCormick, M. R.; Harik, R. & Wuest, T. (2023), *Time-Series Classification in Smart Manufacturing Systems: An Experimental Evaluation of State-of-the-Art Machine Learning Algorithms*. <https://arxiv.org/pdf/2310.02812.pdf>.

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 Fachmedien Wiesbaden, Wiesbaden. ISBN: 978-3-658-21455-5.

Fono & Thiele et al. 2021

Fono, A.; Thiele, G.; Klein, M. & Krüger, J. (2021), „Assistance Method for the Application-Driven Design of Machine Learning Algorithms“. *Modern Materials and Manufacturing (MMM 2021)*. *IOP Conference Series: Materials Science and Engineering Volume 1140*, Hrsg. Karjust, Kristo, J. Kurbarsepp, T. Otto & I. Hussainova. *Modern Materials and Manufacturing (MMM 2021)*. 27.-29.04.2021. Talinn, Institute of Physics Publishing (IOP), Bristol, S. 1-6 (Beitragsnummer 012018). <https://doi.org/10.1088/1757-899X/1140/1/012018>.

Fonollosa & Sheik et al. 2015

Fonollosa, J.; Sheik, S.; Huerta, R. & Marco, S. (2015), „Reservoir computing compensates slow response of chemosensor arrays exposed to fast varying gas concentrations in continuous monitoring“, *Sensors and Actuators B: Chemical*, 215, S. 618–629. <https://doi.org/10.1016/j.snb.2015.03.028>.

Géron 2019

Géron, A. (2019), *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. Concepts, tools, and techniques to build intelligent systems*, O'Reilly, Sebastopol, CA. ISBN: 9781492032618.

Gönnheimer & Hillenbrand et al. 2023

Gönnheimer, P.; Hillenbrand, J.; Heider, I.; Baucks, M. & Fleischer, J. (2023), „Enabling data-based applications in manufacturing: Approaches for broadly applicable machine data acquisition and intelligent parameter identification“. *Production at the Leading Edge of Technology. Proceedings of the 12th Congress of the German Academic Association for Production Technology (WGP), University of Stuttgart, October 2022*, Hrsg. M. Liewald, A. Verl, T. Bauernhansl & H.-C. Möhring. WGP Annual Congress 2022. 11.-14.10.2022. Stuttgart, Springer, Cham, S. 555–563. https://doi.org/10.1007/978-3-031-18318-8_56.

Gönnheimer & Hillenbrand et al. 2019

Gönnheimer, P.; Hillenbrand, J.; Betz-Mors, T.; Bischof, P.; Mohr, L. & Fleischer, J. (2019), „Auto-configuration of a digital twin for machine tools by intelligent crawling“. *Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP), September 30th - October 2nd, Hamburg 2019*, Hrsg. J. P. Wulfsberg, W. Hintze & B.-A. Behrens. WGP Annual Congress 2019. 30.09.-02.10.2019. Hamburg, Springer Vieweg, Berlin, Heidelberg, S. 543–552. https://doi.org/10.1007/978-3-662-60417-5_54.

Gönnheimer & Karle et al. 2021

Gönnheimer, P.; Karle, A.; Mohr, L. & Fleischer, J. (2021), „Comprehensive machine data acquisition through intelligent parameter identification and assignment“. *Procedia CIRP. 54th CIRP CMS 2021 - Towards Digitalized Manufacturing 4.0*, Hrsg. D. Mourtzis. CIRP CMS 2021 - 54th CIRP Conference on Manufacturing Systems. 22.-24.09.2021. Athen, Elsevier, Amsterdam, S. 720–725. <https://doi.org/10.1016/j.procir.2021.11.121>.

Gönnheimer & Netzer et al. 2022

Gönnheimer, P.; Netzer, M.; Lange, C.; Dörflinger, R.; Armbruster, J. & Fleischer, J. (2022), „Datenaufnahme und -verarbeitung in der Brownfield-Produktion“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 117(5), S. 317–320. <https://doi.org/10.1515/zwf-2022-1062>.

Gönnheimer & Netzer et al. 2020

Gönnheimer, P.; Netzer, M.; Mohr, L.; Hörsten, G. von & Fleischer, J. (2020), „Erhöhung der Skalierbarkeit von KI-Anwendungen in Produktionsanlagen“,

Zeitschrift für wirtschaftlichen Fabrikbetrieb, 115(7-8), S. 517–519.

<https://doi.org/10.3139/104.112318>.

Gönnheimer & Puchta et al. 2020

Gönnheimer, P.; Puchta, A. & Fleischer, J. (2020), „Automated Identification of Parameters in Control Systems of Machine Tools“. *Production at the leading edge of technology. Proceedings of the 10th Congress of the German Academic Association for Production Technology (WGP), Dresden, 23-24 September 2020*, Hrsg. B.-A. Behrens, A. Brosius, W. Hintze, S. Ihlenfeldt & J. P. Wulfsberg. WGP Annual Congress 2020. 23.-24.09.2020. Dresden, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 568–577. https://doi.org/10.1007/978-3-662-62138-7_57.

Gönnheimer & Ströbel et al. 2023a

Gönnheimer, P.; Ströbel, R.; Roßkopf, A.; Dörflinger, R.; Walter, I.; Becker, J. & Fleischer, J. (2023), „Potential of systematically generated training datasets on the accuracy and generalization of AI-based approaches for the automated identification of machine control signals“. *Procedia CIRP. 16th CIRP Conference on Intelligent Computation in Manufacturing Engineering*, Hrsg. R. Teti & D. D'Addona. 16th CIRP Conference on Intelligent Computation in Manufacturing Engineering. 13.-15.07.2022. Neapel, Elsevier, Amsterdam, S. 145–150. <https://doi.org/10.1016/j.procir.2023.06.026>.

Gönnheimer & Ströbel et al. 2023b

Gönnheimer, P.; Ströbel, R.; Dörflinger, R.; Mattes, M. & Fleischer, J. (2023), „Interoperable system for automated extraction and identification of machine control data in brownfield production“. *Manufacturing Letters. 51st SME North American Manufacturing Research Conference (NAMRC 51)*, Hrsg. R. Gao, X. Xu & I. Ragai. 51st SME North American Manufacturing Research Conference. 12.-16.06.2023. New Brunswick, NJ, Elsevier, Amsterdam, S. 915–925. <https://doi.org/10.1016/j.mfglet.2023.08.010>.

Gönnheimer & Ströbel et al. 2023c

Gönnheimer, P.; Ströbel, R.; Dörflinger, R.; Mattes, M.; Alexander, P.; Wuest, T. & Fleischer, J. (2023), „Generalizability of an Identification Approach for Machine Control Signals in Brownfield Production Environments“. *Procedia CIRP. Procedia CIRP - Proceedings of the 56th CIRP Conference on Manufacturing Systems 2023*, Hrsg. K. Mpofu, N. Sacks & O. Damm. 56th CIRP Conference on

Manufacturing Systems 2023. 24.-26.10.2023. Kapstadt, Elsevier, Amsterdam, S. 649–654. <https://doi.org/10.1016/j.procir.2023.09.053>.

Gönnheimer & Ströbel et al. 2023d

Gönnheimer, P.; Ströbel, R. & Fleischer, J. (2023), „Analytical Approach for Parameter Identification in Machine Tools Based on Identifiable CNC Reference Runs“. *Production at the Leading Edge of Technology. Proceedings of the 12th Congress of the German Academic Association for Production Technology (WGP), University of Stuttgart, October 2022*, Hrsg. M. Liewald, A. Verl, T. Bauernhansl & H.-C. Möhring. WGP Annual Congress 2022. 11.-14.10.2022. Stuttgart, Springer, Cham, S. 494–503. https://doi.org/10.1007/978-3-031-18318-8_50.

Gönnheimer & Ströbel et al. 2022

Gönnheimer, P.; Ströbel, R.; Netzer, M. & Fleischer, J. (2022), „Generation of identifiable CNC reference runs with high information content for machine learning and analytic approaches to parameter identification“. *Procedia CIRP - Leading manufacturing systems transformation - Proceedings of the 55th CIRP Conference on Manufacturing Systems 2022*, Hrsg. E. Carpanzano, C. Boër & A. Valente. CIRP CMS 2022 - 55th CIRP Conference on Manufacturing Systems. 29.06.-01.07.2022. Lugano, Elsevier, Amsterdam, S. 734–739. <https://doi.org/10.1016/j.procir.2022.05.054>.

Hänsch & Hellwich 2017

Hänsch, R. & Hellwich, O. (2017), „Random Forests“ in *Photogrammetrie und Fernerkundung. Handbuch der Geodäsie, herausgegeben von Willi Freuden und Reiner Rummel*, Hrsg. C. Heipke, Springer Spektrum Berlin, Heidelberg, Berlin, Heidelberg, S. 603–643.

Hillenbrand & Gönnheimer et al. 2021

Hillenbrand, J.; Gönnheimer, P.; Gerlitz, E. & Fleischer, J. (2021), „Design and implementation of a holistic framework for data integration in industrial machine and sensor networks“. *Procedia CIRP. 54th CIRP CMS 2021 - Towards Digitalized Manufacturing 4.0*, Hrsg. D. Mourtzis. CIRP CMS 2021 - 54th CIRP Conference on Manufacturing Systems. 22.-24.09.2021. Athen, Elsevier, Amsterdam, S. 1771–1776. <https://doi.org/10.1016/j.procir.2021.11.298>.

Hirsch 2012

Hirsch, A. (2012), *Werkzeugmaschinen*, Vieweg+Teubner Verlag, Wiesbaden.

Horn & Krüger 2016

Horn, C. & Krüger, J. (2016), „A retrofitting concept for integration of machinery with legacy interfaces into cloud manufacturing architectures“. *2016 16th International Conference on Control, Automation and Systems (ICCAS)*, Hrsg. K. C. Shin & S.-G. Lee. 2016 16th International Conference on Control, Automation and Systems (ICCAS). 16.-19.10.2016. Gyeongju, Institute of Electrical and Electronics Engineers (IEEE), Piscataway, NJ, S. 350–352. <https://doi.org/10.1109/ICCAS.2016.7832342>.

Hozhabr Pour & Wegmeth et al. 2019

Hozhabr Pour, H.; Wegmeth, L.; Kordes, A.; Grzegorzec, M. & Wismüller, R. (2019), „Feature Extraction and Classification of Sensor Signals in Cars Based on a Modified Codebook Approach“. *Progress in Computer Recognition Systems*, Hrsg. R. Burduk, M. Kurzynski & M. Wozniak. 20.-22.05.2019. Polanica Zdroj, Springer International Publishing AG, Cham, S. 184–194. ISBN: 978-3-030-19737-7. https://doi.org/10.1007/978-3-030-19738-4_19.

Khosravi & Alavipanah 2019

Khosravi, I. & Alavipanah, S. K. (2019), „A random forest-based framework for crop mapping using temporal, spectral, textural and polarimetric observations“, *International Journal of Remote Sensing*, 40(18), S. 7221–7251. <https://doi.org/10.1080/01431161.2019.1601285>.

Kief & Roschiwal et al. 2020

Kief, H. B.; Roschiwal, H. A. & Schwarz, K. (2020), *CNC-Handbuch. CNC, DNC, CAD, CAM, FFS, SPS, RPD, LAN, CNC-Maschinen, CNC-Roboter, Antriebe, Energieeffizienz, Werkzeuge, Industrie 4.0, Fertigungstechnik, Richtlinien, Normen, Simulation, Fachwortverzeichnis*, Carl Hanser Verlag GmbH & Co. KG, München.

Klein & Thiele et al. 2020

Klein, M.; Thiele, G.; Fono, A.; Khorsandi, N.; Schade, D. & Krüger, J. (2020), „Process data based Anomaly detection in distributed energy generation using Neural Networks“. *2020 International Conference on Control, Automation and Diagnosis (ICCAD). Proceedings : 7-9 October 2020, Paris, France*, Hrsg. M. Djemai. 2020 International Conference on Control, Automation and Diagnosis

(ICCAD). 07.-09.10.2020. Paris, IEEE, Piscataway, NJ, S. 1–5. ISBN: 978-1-7281-6999-6. <https://doi.org/10.1109/ICCAD49821.2020.9260563>.

Krämer & Schoffer et al. 2018

Krämer, W.; Schoffer, O.; Tschiersch, L. & Gerß, J. (2018), *Datenanalyse mit SAS. Statistische Verfahren und ihre grafischen Aspekte*, Springer Gabler, Berlin, Heidelberg. ISBN: 978-3-662-57799-8.

Krüger & Verl 2019

Krüger, J. & Verl, A. (2019), *RetroNet – Retrofitting von Maschinen und Anlagen für die Vernetzung mit Industrie 4.0 Technologie*, VDI Verlag, Düsseldorf. <https://elibrary.vdi-verlag.de/10.51202/9783186700025>. ISBN: 9783186700025.

Krüger & Vick et al. 2017

Krüger, J.; Vick, A.; Chemnitz, M.; Rosenstrauch, M.; Hügler, J.; Fichteler, M. & Blankenburg, M. (2017), „Daten, Information und Wissen in Industrie 4.0“ in *Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik*, Hrsg. G. Reinhart, Carl Hanser Verlag, München, S. 89–110.

Lestyan & Acs et al. 2019

Lestyan, S.; Acs, G.; Biczok, G. & Szalay, Z. (2019), „Extracting vehicle sensor signals from CAN logs for driver re-identification“. *ICISSP 2019. Proceedings of the 5th International Conference on Information Systems Security and Privacy : Prague, Czech Republic, February 23-25, 2019*, Hrsg. P. Mori, S. Furnell & O. Camp. 23.-25.02.2019. Prag, SCITEPRESS - Science and Technology Publications Lda, Setúbal, S. 136–145. ISBN: 9789897583599.

Löning & Bagnall et al. 2019

Löning, M.; Bagnall, A.; Ganesh, S.; Kazakov, V.; Lines, J. & Király, F. J. (2019), *sktime: A Unified Interface for Machine Learning with Time Series*. <https://arxiv.org/pdf/1909.07872.pdf>.

Mourtzis & Milas et al. 2018

Mourtzis, D.; Milas, N. & Athinaios, N. (2018), „Towards Machine Shop 4.0: A General Machine Model for CNC machine-tools through OPC-UA“. *Procedia CIRP. 6th CIRP Global Web Conference – Envisaging the future manufacturing, design, technologies and systems in innovation era (CIRPe 2018)*, Hrsg. A. Simeone & P. C. Priarone. 6th CIRP Global Web Conference (CIRPe 2018). 23.-25.10.2018.

Online, Elsevier, Amsterdam, S. 301–306. <https://doi.org/10.1016/j.procir.2018.09.045>.

Müller 2007

Müller, M. (2007), „Dynamic Time Warping“ in *Information Retrieval for Music and Motion. With 26 tables*, Hrsg. M. Müller, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 69–84.

Netzer & Begemann et al. 2021

Netzer, M.; Begemann, E.; Gönzheimer, P. & Fleischer, J. (2021), „Digitalisierung im deutschen Maschinen- und Anlagenbau/Study on Digitalization in the German Mechanical Engineering Sector“. Aktuelle Studie zur Digitalisierung im deutschen Maschinen- und Anlagenbau und Bedarfsanalyse, *wt Werkstattstechnik online*, 111(07-08), S. 526–530. <https://doi.org/10.37544/1436-4980-2021-07-08-58>.

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*(1/2021 vol. 21), S. 98–108. <https://doi.org/10.36897/jme/132248>.

Oexle & Fleischer 2023

Oexle, F. & Fleischer, J. (2023), „Auf dem Weg zur autonomen Maschine“, *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, 118(1-2), S. 69–73. <https://doi.org/10.1515/zwf-2023-1016>.

Perovic 2009

Perovic, B. (2009), *Spanende Werkzeugmaschinen*, Springer Berlin Heidelberg, Berlin, Heidelberg.

Puchta & Frisch et al. 2024

Puchta, A.; Frisch, M. & Fleischer, J. (2024), „Automated Identification of Components of Feed Axes“. *Production at the leading edge of technology. Proceedings of the 13th Congress of the German Academic Association for Production Technology (WGP), Freudenstadt, November 2023*, Hrsg. T. Bauernhansl, A. Verl, M. Liewald & H.-C. Möhring. 20.-23.11.2023. Freudenstadt, Springer Nature Switzerland; Imprint Springer, Cham, S. 143–151. ISBN: 978-3-031-47393-7. https://doi.org/10.1007/978-3-031-47394-4_15.

Schmidt & Reiss et al. 2018

Schmidt, P.; Reiss, A.; Duerichen, R.; Marberger, C. & van Laerhoven, K. (2018), „Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection“. *Proceedings of the 20th ACM International Conference on Multimodal Interaction*, Hrsg. S. K. D'Mello. 20th ACM International Conference on Multimodal Interaction. 16.-20.10.2018. Boulder, CO, Association for Computing Machinery, New York, NY, S. 400–408. ISBN: 9781450356923.
<https://doi.org/10.1145/3242969.3242985>.

Vishwas & Patel 2020

Vishwas, B. V. & Patel, A. (2020), *Hands-on Time Series Analysis with Python. From Basics to Bleeding Edge Techniques*, Apress, Berkeley, CA. ISBN: 978-1-4842-5991-7.

Vito & Massera et al. 2008

Vito, S. de; Massera, E.; Piga, M.; Martinotto, L. & Di Francia, G. (2008), „On field calibration of an electronic nose for benzene estimation in an urban pollution monitoring scenario“, *Sensors and Actuators B: Chemical*, 129(2), S. 750–757.
<https://doi.org/10.1016/j.snb.2007.09.060>. <https://www.sciencedirect.com/science/article/pii/S0925400507007691>.

Wang & Yan et al. 2017

Wang, Z.; Yan, W. & Oates, T. (2017), „Time series classification from scratch with deep neural networks: A strong baseline“. *2017 International Joint Conference on Neural Networks (IJCNN)*, Hrsg. Y. Choe. International Joint Conference on Neural Networks (IJCNN). 14.-19.05.2017. Anchorage, AK, IEEE, Piscataway, NJ, S. 1578–1585. <https://doi.org/10.1109/IJCNN.2017.7966039>.

Weck 2006

Weck, M. (2006), *Werkzeugmaschinen 4*, Springer Berlin Heidelberg, Berlin, Heidelberg.

11 Abbildungsverzeichnis

Abbildung 1-1: Aufbau der Arbeit	11
Abbildung 2-1: Fertigungsverfahren der Metallbearbeitung nach DIN 8580 nach Brecher & Weck (2019)	14
Abbildung 2-2: Beispielhafter Grundaufbau einer Fräsmaschine in Duoblock-Bauweise ohne Verkleidung nach Perovic (2009)	15
Abbildung 2-3: Beispielhafter Grundaufbau einer CNC-Hochleistungs-Drehmaschine von Monforts nach Perovic (2009)	16
Abbildung 2-4: Bauarten von Hauptantrieben nach Kief & Roschiwal et al. (2020)	18
Abbildung 2-5: Translatorische Vorschubachse mit Kugelgewindetrieb nach Brecher & Weck (2021)	19
Abbildung 2-6: Aufbau einer numerischen Steuerung nach Weck (2006)	20
Abbildung 2-7: Prinzip der Eingabe und Verarbeitung geometrischer Informationen im geschlossenen Regelkreis nach Kief & Roschiwal et al. (2020)	22
Abbildung 2-8: Schematische Darstellung des kaskadierten Lageregelkreises nach Kief & Roschiwal et al. (2020)	23
Abbildung 2-9: Folgeverhalten eines Lageregelkreises mit Geschwindigkeitsrückführung nach Brecher & Weck (2021)	24
Abbildung 2-10: Definition von Signalen und Zeitreihen (Farahani & McCormick et al. 2023a)	25
Abbildung 2-11: Kommunikationssysteme für unterschiedliche Ebenen der Automatisierung nach Kief & Roschiwal et al. (2020)	26
Abbildung 2-12: Auszug der Struktur aus einem OPC UA Server einer DMG MORI DMU 65 monoBLOCK	27
Abbildung 2-13: Beispielhafte Kommunikationsarchitektur mit möglichen Komponenten und Datenschnittstellen in Brownfield-Maschinen	29
Abbildung 2-14: Angleichung zweier Zeitreihen durch DTW nach Müller (2007)	34
Abbildung 2-15: Aufbau eines Fully Convolutional Network in Anlehnung an Wang & Yan et al. (2017)	38

Abbildung 2-16: Aufbau eines ResNet in Anlehnung an Wang & Yan et al. (2017)	38
Abbildung 2-17: Architektur einer LSTM Zelle nach Vishwas & Patel (2020)	39
Abbildung 2-18: Random Forest bestehend aus mehreren Entscheidungsbäumen nach Hänsch & Hellwich (2020)	40
Abbildung 3-1: Konkretisiertes Zielsystem in Anlehnung an Gönzheimer & Ströbel et al. (2023a)	46
Abbildung 3-2: Vorgehensweise zur Entwicklung des Gesamtsystems	47
Abbildung 4-1: Schematische Darstellung des Systems zur Kommunikation mit Werkzeugmaschinen in Anlehnung an Gönzheimer & Ströbel et al. (2023a)	50
Abbildung 4-2: Schematischer Aufbau der Teilmodule zur automatisierten Extraktion von Signalen	52
Abbildung 4-3: Datenstruktur am Beispiel eines OPC UA Servers nach A_Heider (2021)	53
Abbildung 4-4: Chronologischer Ablauf der Methodenaufrufe zur Suche von Signalen und Aufzeichnung der Zeitreihen	55
Abbildung 4-5: OPC UA Hierarchie und Reihenfolge des DataBrowser nach A_Heider (2021)	56
Abbildung 4-6: Aufbau des DataAdapter für OPC UA nach A_Heider (2021)	57
Abbildung 5-1: Chronologischer Ablauf zur Entwicklung des Identifikationssystems	58
Abbildung 5-2: Einordnung des Ansatzes zur Identifikation von Maschinensteuerungsdaten in Anlehnung an Gönzheimer & Ströbel et al. (2023a)	59
Abbildung 5-3: Einordnung des Ansatzes zur Signalidentifikation durch analytische Regelbasen in Anlehnung an Gönzheimer & Ströbel et al. (2023a)	61
Abbildung 5-4: Darstellung des gesamten Ablaufs zur Identifikation von Maschinensteuerungssignalen nach A_Ströbel (2022)	63
Abbildung 5-5: Beispiel der Achsbewegung mit der ID = 101101000111 nach A_Ströbel (2022)	66
Abbildung 5-6: Identifikation von Maschinensteuerungssignalen in Stufe 1 mit den Regeln 1.1 bis 1.9 nach A_Ströbel (2022)	68

Abbildung 5-7: Identifikation von Maschinensteuerungssignalen in Stufe 2 nach A_Ströbel (2022)	71
Abbildung 5-8: Identifikation von Maschinensteuerungssignalen in Stufe 3 nach A_Ströbel (2022)	72
Abbildung 5-9: Verlauf eines POWER- und VEL_FFW Signals der DMC 60H-HDM nach A_Ströbel (2022)	73
Abbildung 5-10: Extraktion der VEL_FFW- und POWER-Signale aus den verbleibenden Zeitreihen nach A_Ströbel (2022)	74
Abbildung 5-11: Identifikation von Maschinensteuerungssignalen in Stufe 4 nach A_Ströbel (2022)	75
Abbildung 5-12: Verlauf des Lastsignals der Spindel nach A_Ströbel (2022)	76
Abbildung 5-13: Modifikation der Zeitreihen. Gleitende Standardabweichung, Normierung und Berechnung des Mittelwerts von Strom- und Drehmomentsignalen von Signalpaaren nach A_Ströbel (2022)	77
Abbildung 5-14: Identifikation von Maschinensteuerungssignalen in Stufe 5 nach A_Ströbel (2022)	78
Abbildung 5-15: Detailansicht der Analyse von Regeldifferenzsignalen durch eine gleitende Standardabweichung (oben) und einem zusätzlichen gleitenden Mittelwert (unten) nach A_Ströbel (2022)	79
Abbildung 5-16: Identifikation von Maschinensteuerungssignalen in Stufe 6 nach A_Ströbel (2022)	80
Abbildung 5-17: Unterscheidung zwischen dem vorausseilenden Drehmomentsignal und dem Stromsignal	81
Abbildung 5-18: Einordnung und Konzept der ML-Modelle in den Gesamtprozess in Anlehnung an Gönninger & Ströbel et al. (2023a)	86
Abbildung 5-19: Positionssignale (oben) und deren Standardabweichung (Mitte) und eine vergrößerte Ansicht der Standardabweichung (unten) nach A_Karle (2020)	91
Abbildung 5-20: Standardabweichungen aller Samples nach vordefinierten Klassen nach A_Karle (2020)	92

Abbildung 5-21: Einfluss der Batchgröße auf die Fehlerberechnung beim FCN nach A_Karle (2020)	102
Abbildung 5-22: Einfluss der Batchgröße auf die Fehlerberechnung beim ResNet nach A_Karle (2020)	102
Abbildung 5-23: Einfluss der Batchgröße auf die Fehlerberechnung beim LSTM nach A_Karle (2020)	103
Abbildung 5-24: Einfluss größerer Samplelängen auf den Fehler bei einem LSTM nach A_Karle (2020)	104
Abbildung 5-25: Einfluss kleinerer Samplelängen auf den Fehler bei einem LSTM nach A_Karle (2020)	104
Abbildung 5-26: Einfluss der Dimension des Hidden States auf den Fehler über die Anzahl an Epochen bei eine LSTM nach A_Karle (2020)	105
Abbildung 5-27: Gemittelte Feature Importance der Merkmale für den RanFor nach A_Karle (2020)	107
Abbildung 5-28: Gemittelte Permutation Feature Importance der Merkmale für den RanFor nach A_Karle (2020)	108
Abbildung 5-29: Einfluss der Merkmale hinsichtlich Auswahl und Anzahl auf die Modellgenauigkeit nach A_Karle (2020)	108
Abbildung 5-30: Einfluss der Baumtiefe auf die Genauigkeit des RanFor nach A_Karle (2020)	109
Abbildung 5-31: Einfluss der Anzahl an Lernern auf die Genauigkeit bei einem RanFor nach A_Karle (2020)	110
Abbildung 5-32: Verlauf der Genauigkeit in Abhängigkeit der Anzahl an Epochen beim FCN nach A_Karle (2020)	112
Abbildung 5-33: Verlauf der Genauigkeit in Abhängigkeit der Anzahl an Epochen beim ResNet nach A_Karle (2020)	112
Abbildung 5-34: Verlauf der Genauigkeit in Abhängigkeit der Anzahl an Epochen beim LSTM nach A_Karle (2020)	113

Abbildung 5-35: Einordnung des Ansatzes zur Signalidentifikation durch ML-Modelle und analytische Regeln in den Gesamtprozess in Anlehnung an Gönninger & Ströbel et al. (2023a)	117
Abbildung 5-36: Ablaufplan der Stufe 1 nach A_Baucks (2021)	120
Abbildung 5-37: Vergleich der Genauigkeit unterschiedlicher ML-Modelle mit erweitertem Datensatz zur Validierung nach A_Baucks (2021)	121
Abbildung 5-38: Modifikation des ResNet zur Unterscheidung von bekannter und unbekannter Daten nach A_Baucks (2021)	125
Abbildung 5-39: Ablaufplan der Stufe 2 nach A_Baucks (2021)	126
Abbildung 5-40: Ablauf der Stufe 3 nach A_Baucks (2021)	127
Abbildung 5-41: Trainingsverlauf des ResNet durch die Ergänzung von augmentierten Daten nach A_Baucks (2021)	130
Abbildung 5-42: Trainingsverlauf des ResNet durch die Ergänzung von augmentierten und weiteren Prozessdaten nach A_Baucks (2021)	131
Abbildung 5-43: Validierung der ResNet-Modelle mit einem Datensatz, der nicht im Training verwendet wurde, nach A_Baucks (2021)	132
Abbildung 5-44: Verlauf der CCR und FPR beim Training des ResNet nach A_Baucks (2021)	133
Abbildung 5-45: Abhängigkeit von FPR (a) und CCR (b) mit Entropie- und Klassifikations-Schwellenwert (x: Optimum FPR (a) und CCR (b)) nach A_Baucks (2021)	135
Abbildung 5-46: Abhängigkeit der kombinierten FPR und CCR von dem Entropie- und Klassifikations-Schwellenwert (x: Optimum von FPR und CCR) nach A_Baucks (2021)	136
Abbildung 5-47: Validierung des ResNet+ und ResNet mit den ermittelten Entropie- und Klassifikations-Schwellenwerten nach A_Baucks (2021)	137
Abbildung 5-48: Klassifikationsgenauigkeit unterschiedlicher Datensätze in Stufe 2 und 3 nach A_Baucks (2021)	138
Abbildung 5-49: Einordnung des hybriden Ansatzes in Anlehnung an Gönninger & Ströbel et al. (2023a)	142

Abbildung 5-50: Ergebnisstruktur der Klassifikationen. Links: Vorklassifizierung der Signale nach (Gönnheimer & Ströbel et al. 2023a). Rechts: Struktur eines Achscluster, welches für jede Achse angelegt wird in Anlehnung an Gönnheimer & Ströbel et al. (2023a)	144
Abbildung 5-51: Differenzierung von Signalen mit Rauschen nach Gönnheimer & Ströbel et al. (2023a)	147
Abbildung 5-52: Korrelationen unterschiedlicher Signale nach Gönnheimer & Ströbel et al. (2023a)	149
Abbildung 5-53: Bestimmung der Geschwindigkeitssignale anhand der Distanz zu Positionssignalen in eindimensionaler Abbildung nach A_Dörflinger (2022)	151
Abbildung 5-54: Bestimmung der verbleibenden Geschwindigkeitssignale durch die Berechnung von Distanzen in eindimensionaler Abbildung nach A_Dörflinger (2022)	152
Abbildung 5-55: Modifikation der Signale für stärkere Korrelationen von Positions- und Drehmomentsignalen. Oben: modifizierte Positions- und Stromsignale nach bisherigem Schema. Unten: Erweiterte Modifikation durch die Entfernung von Peaks in den Stromsignalen durch die Identifikation von lokalen Minima in den Positionssignalen. Darstellung nach Gönnheimer & Ströbel et al. (2023a)	153
Abbildung 5-56: Schema der Bewertungsmethoden G1 und G2 nach A_Dörflinger (2022)	158
Abbildung 6-1: Startseite der GUI	161
Abbildung 6-2. Konfiguration	162
Abbildung 6-3. Ergebnisse Vorfilter	163
Abbildung 6-4. Ergebnisse ML	164
Abbildung 6-5. Ergebnisse der Vorklassifizierung in Stufe 3	165
Abbildung 6-6: Ergebnisse der direkten Zuweisung in Stufe 3	166
Abbildung 6-7: Export der Ergebnisse als lokale Datei oder über einen OPC UA Server	167

12 Tabellenverzeichnis

Tabelle 1: Signale und Signaltypen der aufgezeichneten Referenzfahrten auf der Deckel Maho DMC 60H - HDM nach A_Ströbel (2022)	65
Tabelle 2: Genauigkeiten der Bewertungskennzahlen bei unterschiedlichen Kombinationen der Versuchsparameter nach Gönzheimer & Ströbel et al. (2022a)	83
Tabelle 3: Genauigkeiten der Bewertungskennzahlen der drei Aufnahmen aus dem Validierungsdatensatz nach Gönzheimer & Ströbel et al. (2022a)	83
Tabelle 4: Aufgezeichnete Daten der Deckel Maho DMC 60H – HDM nach A_Karle (2020)	88
Tabelle 5: Konfusionsmatrizen der RanFor nach der Filterung der Samples unterschiedlicher Standardabweichungen nach A_Karle (2020)	93
Tabelle 6: Genauigkeit der Klassen mit unterschiedlichen Sample-Zeitintervalle nach A_Karle (2020)	94
Tabelle 7: Klassifikationsgenauigkeit der RanFor mit unterschiedlichen Kombinationen von Standardabweichungsfiler und Samplelänge nach A_Karle (2020)	95
Tabelle 8: Einfluss der Überlappung von Samples auf die Genauigkeit bei einem RanFor nach A_Karle (2020)	96
Tabelle 9: Auflistung der verwendeten 40 typischen Merkmale für den RanFor nach A_Karle (2020)	96
Tabelle 10: Konfusionsmatrix (oben) und Genauigkeiten (unten) unterschiedlicher Zielklassengruppierungen des FCN nach A_Karle (2020)	99
Tabelle 11: Konfusionsmatrix (oben) und Genauigkeiten (unten) unterschiedlicher Zielklassengruppierungen des LSTM nach A_Karle (2020)	100
Tabelle 12: Konfusionsmatrix (oben) und Genauigkeiten (unten) unterschiedlicher Zielklassengruppierungen des RanFor nach A_Karle (2020)	106
Tabelle 13: Vergleich der Genauigkeiten der drei neuronalen Netze FCN, ResNet und LSTM in Anlehnung an Gönzheimer & Karle et al. (2021)	114
Tabelle 14: Vergleich der Genauigkeiten von ResNet und RanFor in Anlehnung an Gönzheimer & Karle et al. (2021)	114

Tabelle 15: Auflistung der verwendeten Datensätze in Anlehnung an Gönzheimer & Ströbel et al. (2023a)	145
Tabelle 16: Verwendete Zusammenhänge von Signaltypen nach Gönzheimer & Ströbel et al. (2023a)	149
Tabelle 17: Genauigkeiten der Identifikation trivialer Signale in Stufe 1 von D2 und D3 nach Gönzheimer & Ströbel et al. (2023a)	155
Tabelle 18: Analyse der Genauigkeiten der ML-Modelle bei unterschiedlichen Kombinationen der Datensätze als Datengrundlage nach Gönzheimer & Ströbel et al. (2023a)	156
Tabelle 19: Genauigkeiten der ML-Modelle mit unterschiedlicher Trainingsdaten auf den Validierungsdatensatz D3 nach Gönzheimer & Ströbel et al. (2023a)	156
Tabelle 20: Genauigkeiten der Identifikation von Signalen in Stufe 3 nach Gönzheimer & Ströbel et al. (2023a)	157
Tabelle 21: Gesamtergebnis des Gesamtmodells mit den Datensätzen D2 und D3 nach A_Dörflinger (2022)	159
Tabelle 22: Genauigkeiten der Stufe1 mit TD1 und unterschiedlichen Abtastraten nach Gönzheimer & Ströbel et al. (2023c)	169
Tabelle 23: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD1 nach Gönzheimer & Ströbel et al. (2023c)	170
Tabelle 24: Ergebnisse des gesamten mehrstufigen Modells mit dem Datensatz TD1 nach Gönzheimer & Ströbel et al. (2023c)	170
Tabelle 25: Genauigkeiten der Stufe 1 mit TD2 und unterschiedlichen Abtastraten nach Gönzheimer & Ströbel et al. (2023c)	171
Tabelle 26: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD2 nach Gönzheimer & Ströbel et al. (2023c)	172
Tabelle 27: Ergebnisse Gesamtmodell TD2 nach Gönzheimer & Ströbel et al. (2023c)	172
Tabelle 28: Genauigkeiten der Stufe 1 mit TD3 und unterschiedlichen Abtastraten nach Gönzheimer & Ströbel et al. (2023c)	173

Tabelle 29: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD3 nach Gönheimer & Ströbel et al. (2023c)	174
Tabelle 30: Untersuchung der Geschwindigkeitssignale von TD3 mit zusätzlicher modifizierter Regel der Stufe 3 bei unterschiedlichen Abtastfrequenzen nach Gönheimer & Ströbel et al. (2023c)	174
Tabelle 31: Genauigkeiten der Stufe1 mit TD4 und unterschiedlichen Abtastraten nach Gönheimer & Ströbel et al. (2023c)	176
Tabelle 32: Ergebnisse der Untersuchung auf Genauigkeiten unterschiedlicher ML-Modelle mit dem Datensatz TD4 nach Gönheimer & Ströbel et al. (2023c)	177
Tabelle 33: Untersuchung ausgewählter Signale von TD4 mit modifizierten Regeln der Stufe 3 bei unterschiedlichen Abtastfrequenzen nach Gönheimer & Ströbel et al. (2023c)	178

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 druck geregelter 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 fünffachsignen Fräsen von Freiformflächen

Band 49

Dr.-Ing. Wolfgang Bernhart

Beitrag zur Bewertung von Montagevarianten: Rechnergestützte Hilfsmittel zur kostenorientierten, parallelen Entwicklung von Produkt und Montage system

Band 50

Dr.-Ing. Peter Ganghoff

**Wissensbasierte Unterstützung der Planung technischer Systeme:
Konzeption eines Planungswerkzeuges und exemplarische Anwendung
im Bereich der Montagesystemplanung**

Band 51

Dr.-Ing. Frank Maier

**Rechnergestützte Prozessregelung beim flexiblen Gesenkbiegen durch
Rückführung von Qualitätsinformationen**

Band 52

Dr.-Ing. Frank Debus

**Ansatz eines rechnerunterstützten Planungsmanagements für die Planung
in verteilten Strukturen**

Band 53

Dr.-Ing. Joachim Weinbrecht

**Ein Verfahren zur zielorientierten Reaktion auf Planabweichungen in der
Werkstattregelung**

Band 54

Dr.-Ing. Gerd Herrmann

**Reduzierung des Entwicklungsaufwandes für anwendungsspezifische
Zellenrechnersoftware durch Rechnerunterstützung**

Band 55

Dr.-Ing. Robert Wassmer

**Verschleissentwicklung im tribologischen System Fräsen: Beiträge
zur Methodik der Prozessmodellierung auf der Basis tribologischer
Untersuchungen beim Fräsen**

Band 56

Dr.-Ing. Peter Uebelhoer

Inprocess-Geometriemessung beim Honen

Band 57

Dr.-Ing. Hans-Joachim Schelberg

Objektorientierte Projektierung von SPS-Software

Band 58

Dr.-Ing. Klaus Boes

Integration der Qualitätsentwicklung in featurebasierte CAD/CAM-Prozessketten

Band 59

Dr.-Ing. Martin Schreiber

Wirtschaftliche Investitionsbewertung komplexer Produktionssysteme unter Berücksichtigung von Unsicherheit

Band 60

Dr.-Ing. Ralf Steuernagel

Offenes adaptives Engineering-Werkzeug zur automatisierten Erstellung von entscheidungsunterstützenden Informationssystemen

Band 62

Dr.-Ing. Uwe Schauer

Qualitätsorientierte Feinbearbeitung mit Industrierobotern: Regelungsansatz für die Freiformflächenfertigung des Werkzeug- und Formenbaus

Band 63

Dr.-Ing. Simone Loeper

Kennzahlengestütztes Beratungssystem zur Verbesserung der Logistikleistung in der Werkstattfertigung

Band 64

Dr.-Ing. Achim Raab

Räumen mit hartstoffbeschichteten HSS-Werkzeugen

Band 65,

Dr.-Ing. Jan Erik Burghardt

Unterstützung der NC-Verfahrenskette durch ein bearbeitungselementorientiertes, lernfähiges Technologieplanungssystem

Band 66

Dr.-Ing. Christian Tritsch

Flexible Demontage technischer Gebrauchsgüter: Ansatz zur Planung und (teil-)automatisierten Durchführung industrieller Demontageprozesse

Band 67

Dr.-Ing. Oliver Eitrich

Prozessorientiertes Kostenmodell für die entwicklungsbegleitende Vorkalkulation

Band 68

Dr.-Ing. Oliver Wilke

Optimierte Antriebskonzepte für Räummaschinen - Potentiale zur Leistungssteigerung

Band 69

Dr.-Ing. Thilo Sieth

Rechnergestützte Modellierungsmethodik zerspantechnologischer Prozesse

Band 70

Dr.-Ing. Jan Linnenbueger

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 Mauerwerkabbaus und der Elektroinstallation auf Baustellen

Band 82

Dr.-Ing. Dipl. Wirtschaftsingenieur Simone Riedmiller

Der Prozesskalender - Eine Methodik zur marktorientierten Entwicklung von Prozessen

Band 83

Dr.-Ing. Dietmar Tilch

Analyse der Geometrieparameter von Präzisionsgewinden auf der Basis einer Least-Squares-Estimation

Band 84

Dr.-Ing. Dipl.-Kfm. Oliver Stiefbold

Konzeption eines reaktionsschnellen Planungssystems für Logistikketten auf Basis von Software-Agenten

Band 85

Dr.-Ing. Ulrich Walter

Einfluss von Kühlschmierstoff auf den Zerspanprozess beim Fräsen: Beitrag zum Prozessverständnis auf Basis von zerspantechnischen Untersuchungen

Band 86

Dr.-Ing. Bernd Werner

Konzeption von teilautonomer Gruppenarbeit unter Berücksichtigung kultureller Einflüsse

Band 87

Dr.-Ing. Ulf Osmer

Projektieren Speicherprogrammierbarer Steuerungen mit Virtual Reality

Band 88

Dr.-Ing. Oliver Doerfel

Optimierung der Zerspantechnik beim Fertigungsverfahren Wälzstossen: Analyse des Potentials zur Trockenbearbeitung

Band 89

Dr.-Ing. Peter Baumgartner

Stufenmethode zur Schnittstellengestaltung in der internationalen Produktion

Band 90

Dr.-Ing. Dirk Vossmann

Wissensmanagement in der Produktentwicklung durch Qualitätsmethodenverbund und Qualitätsmethodenintegration

Band 91

Dr.-Ing. Martin Plass

Beitrag zur Optimierung des Honprozesses durch den Aufbau einer Honprozessregelung

Band 92

Dr.-Ing. Titus Konold

Optimierung der Fünfachsfräsbearbeitung 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

Entwicklungsintegrierte 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 Schmäzle

Bewertungssystem für die Generalüberholung von Montageanlagen –Ein Beitrag zur wirtschaftlichen Gestaltung geschlossener Facility- Management-Systeme im Anlagenbau

Band 105

Dr.-Ing. Thorsten Frank

Vergleichende Untersuchungen schneller elektromechanischer Vorschubachsen mit Kugelgewindetrieb

Band 106

Dr.-Ing. Achim Agostini

Reihenfolgeplanung unter Berücksichtigung von Interaktionen: Beitrag zur ganzheitlichen Strukturierung und Verarbeitung von Interaktionen von Bearbeitungsobjekten

Band 107

Dr.-Ing. Thomas Barrho

Flexible, zeitfenstergesteuerte Auftragseinplanung in segmentierten Fertigungsstrukturen

Band 108

Dr.-Ing. Michael Scharer

Quality Gate-Ansatz mit integriertem Risikomanagement

Band 109

Dr.-Ing. Ulrich Suchy

**Entwicklung und Untersuchung eines neuartigen Mischkopfes für das Wasser
Abrasive Strahlenschneiden**

Band 110

Dr.-Ing. Sellal Mussa

Aktive Korrektur von Verlagerungsfehlern in Werkzeugmaschinen

Band 111

Dr.-Ing. Andreas Hühsam

Modellbildung und experimentelle Untersuchung des Wälzschälprozesses

Band 112

Dr.-Ing. Axel Plutowsky

**Charakterisierung eines optischen Messsystems und den Bedingungen des
Arbeitsraums einer Werkzeugmaschine**

Band 113

Dr.-Ing. Robert Landwehr

**Konsequent dezentralisierte Steuerung mit Industrial Ethernet und offenen
Applikationsprotokollen**

Band 114

Dr.-Ing. Christoph Dill

Turbulenzreaktionsprozesse

Band 115

Dr.-Ing. Michael Baumeister

Fabrikplanung im turbulenten Umfeld

Band 116

Dr.-Ing. Christoph Gönninger

**Konzept zur Verbesserung der Elektromagnetischen Verträglichkeit (EMV) in
Produktionssystemen durch intelligente Sensor/Aktor-Anbindung**

Band 117

Dr.-Ing. Lutz Demuß

**Ein Reifemodell für die Bewertung und Entwicklung von Dienstleistungs-
organisationen: Das Service Management Maturity Modell (SMMM)**

Band 118

Dr.-Ing. Jörg Söhner

Beitrag zur Simulation zerspanungstechnologischer Vorgänge mit Hilfe der Finite-Element-Methode

Band 119

Dr.-Ing. Judith Elsner

Informationsmanagement für mehrstufige Mikro-Fertigungsprozesse

Band 120

Dr.-Ing. Lijing Xie

Estimation Of Two-dimension Tool Wear Based On Finite Element Method

Band 121

Dr.-Ing. Ansgar Blessing

Geometrischer Entwurf mikromechatronischer Systeme

Band 122

Dr.-Ing. Rainer Ebner

Steigerung der Effizienz mehrachsiger Fräsprozesse durch neue Planungsmethoden mit hoher Benutzerunterstützung

Band 123

Dr.-Ing. Silja Klinkel

Multikriterielle Feinplanung in teilautonomen Produktionsbereichen – Ein Beitrag zur produkt- und prozessorientierten Planung und Steuerung

Band 124

Dr.-Ing. Wolfgang Neithardt

Methodik zur Simulation und Optimierung von Werkzeugmaschinen in der Konzept- und Entwurfsphase auf Basis der Mehrkörpersimulation

Band 125

Dr.-Ing. Andreas Mehr

Hartfeinbearbeitung von Verzahnungen mit kristallinen diamantbeschichteten Werkzeugen beim Fertigungsverfahren Wälzstoßen

Band 126

Dr.-Ing. Martin Gutmann

Entwicklung einer methodischen Vorgehensweise zur Diagnose von hydraulischen Produktionsmaschinen

Band 127

Dr.-Ing. Gisela Lanza

Simulative Anlaufunterstützung auf Basis der Qualitätsfähigkeiten von Produktionsprozessen

Band 128

Dr.-Ing. Ulf Dambacher

Kugelgewindetrieb mit hohem Druckwinkel

Band 129

Dr.-Ing. Carsten Buchholz

Systematische Konzeption und Aufbau einer automatisierten Produktionszelle für pulverspritzgegossene Mikrobauteile

Band 130

Dr.-Ing. Heiner Lang

Trocken-Räumen mit hohen Schnittgeschwindigkeiten

Band 131

Dr.-Ing. Daniel Nesges

Prognose operationeller Verfügbarkeiten von Werkzeugmaschinen unter Berücksichtigung von Serviceleistungen

Im Shaker Verlag erschienene Bände:

Band 132

Dr.-Ing. Andreas Bechle

Beitrag zur prozesssicheren Bearbeitung beim Hochleistungsfertigungsverfahren Wälzschälen

Band 133

Dr.-Ing. Markus Herm

Konfiguration globaler Wertschöpfungsnetzwerke auf Basis von Business Capabilities

Band 134

Dr.-Ing. Hanno Tritschler

Werkzeug- und Zerspanprozessoptimierung beim Hartfräsen von Mikrostrukturen in Stahl

Band 135

Dr.-Ing. Christian Munzinger

**Adaptronische Strebe zur Steifigkeitssteigerung
von Werkzeugmaschinen**

Band 136

Dr.-Ing. Andreas Stepping

**Fabrikplanung im Umfeld von Wertschöpfungsnetzwerken und
ganzheitlichen Produktionssystemen**

Band 137

Dr.-Ing. Martin Dyck

**Beitrag zur Analyse thermische bedingter Werkstückdeformationen
in Trockenbearbeitungsprozessen**

Band 138

Dr.-Ing. Siegfried Schmalzried

**Dreidimensionales optisches Messsystem für eine effizientere
geometrische Maschinenbeurteilung**

Band 139

Dr.-Ing. Marc Wawerla

Risikomanagement von Garantieleistungen

Band 140

Dr.-Ing. Ivesa Buchholz

**Strategien zur Qualitätssicherung mikromechanischer Bauteile
mittels multisensorieller Koordinatenmesstechnik**

Band 141

Dr.-Ing. Jan Kotschenreuther

**Empirische Erweiterung von Modellen der Makrozerspanung
auf den Bereich der Mikrobearbeitung**

Band 142

Dr.-Ing. Andreas Knödel

Adaptronische hydrostatische Drucktascheneinheit

Band 143

Dr.-Ing. Gregor Stengel

**Fliegendes Abtrennen räumlich gekrümmter Strangpressprofile mittels
Industrierobotern**

Band 144

Dr.-Ing. Udo Weismann

Lebenszyklusorientiertes interorganisationelles Anlagencontrolling

Band 145

Dr.-Ing. Rüdiger Pabst

Mathematische Modellierung der Wärmestromdichte zur Simulation des thermischen Bauteilverhaltens bei der Trockenbearbeitung

Band 146

Dr.-Ing. Jan Wieser

Intelligente Instandhaltung zur Verfügbarkeitssteigerung von Werkzeugmaschinen

Band 147

Dr.-Ing. Sebastian Haupt

Effiziente und kostenoptimale Herstellung von Mikrostrukturen durch eine Verfahrenskombination von Bahnerosion und Laserablation

Band 148

Dr.-Ing. Matthias Schlipf

Statistische Prozessregelung von Fertigungs- und Messprozess zur Erreichung einer variabilitätsarmen Produktion mikromechanischer Bauteile

Band 149

Dr.-Ing. Jan Philipp Schmidt-Ewig

Methodische Erarbeitung und Umsetzung eines neuartigen Maschinenkonzeptes zur produktflexiblen Bearbeitung räumlich gekrümmter Strangpressprofile

Band 150

Dr.-Ing. Thomas Ender

Prognose von Personalbedarfen im Produktionsanlauf unter Berücksichtigung dynamischer Planungsgrößen

Band 151

Dr.-Ing. Kathrin Peter

Bewertung und Optimierung der Effektivität von Lean Methoden in der Kleinserienproduktion

Band 152

Dr.-Ing. Matthias Schopp

Sensorbasierte Zustandsdiagnose und -prognose von Kugelgewindetrieben

Band 153

Dr.-Ing. Martin Kipfmüller

Aufwandsoptimierte Simulation von Werkzeugmaschinen

Band 154

Dr.-Ing. Carsten Schmidt

Development of a database to consider multi wear mechanisms within chip forming simulation

Band 155

Dr.-Ing. Stephan Niggeschmidt

Ausfallgerechte Ersatzteilbereitstellung im Maschinen- und Anlagenbau mittels lastabhängiger Lebensdauerprognose

Band 156

Dr.-Ing. Jochen Conrad Peters

Bewertung des Einflusses von Formabweichungen in der Mikro-Koordinatenmesstechnik

Band 157

Dr.-Ing. Jörg Ude

Entscheidungsunterstützung für die Konfiguration globaler Wertschöpfungsnetzwerke

Band 158

Dr.-Ing. Stefan Weiler

Strategien zur wirtschaftlichen Gestaltung der globalen Beschaffung

Band 159

Dr.-Ing. Jan Rühl

Monetäre Flexibilitäts- und Risikobewertung

Band 160

Dr.-Ing. Daniel Ruch

Positions- und Konturerfassung räumlich gekrümmter Profile auf Basis bauteilimmanenter Markierungen

Band 161

Dr.-Ing. Manuel Tröndle

Flexible Zuführung von Mikrobauteilen mit piezoelektrischen Schwingförderern

Band 162

Dr.-Ing. Benjamin Viering

Mikroverzahnungsnormal

Band 163

Dr.-Ing. Chris Becke

Prozesskraftrichtungsangepasste Frässtrategien zur schadigungsarmen 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

Segmentspannbildung, Werkzeugverschleiß, Randschichtzustand und Bauteileigenschaften: Numerische Analysen zur Optimierung des Zerspanungsprozesses am Beispiel von Ti-6Al-4V

Band 170

Dr.-Ing. Benjamin Behmann

Servicefähigkeit

Band 171

Dr.-Ing. Annabel Gabriele Jondral

Simulationsgestützte Optimierung und Wirtschaftlichkeitsbewertung des Lean-Methodeneinsatzes

Band 172

Dr.-Ing. Christoph Ruhs

Automatisierte Prozessabfolge zur qualitätssicheren Herstellung von Kavitäten mittels Mikrobahnerosion

Band 173

Dr.-Ing. Steven Peters

Markoffsche Entscheidungsprozesse zur Kapazitäts- und Investitionsplanung von Produktionssystemen

Band 174

Dr.-Ing. Christoph Kühlewein

Untersuchung und Optimierung des Wälzschälverfahrens mit Hilfe von 3D-FEM-Simulation – 3D-FEM Kinematik- und Spanbildungssimulation

Band 175

Dr.-Ing. Adam-Mwanga Dieckmann

Auslegung und Fertigungsprozessgestaltung sintergefügter Verbindungen für μ MIM-Bauteile

Band 176

Dr.-Ing. Heiko Hennrich

Aufbau eines kombinierten belastungs- und zustandsorientierten Diagnose- und Prognosesystems für Kugelgewindetriebe

Band 177

Dr.-Ing. Stefan Herder

Piezoelektrischer Self-Sensing-Aktor zur Vorspannungsregelung in adaptronischen Kugelgewindetriebe

Band 178

Dr.-Ing. Alexander Ochs

Ultraschall-Strömungsgreifer für die Handhabung textiler Halbzeuge bei der automatisierten Fertigung von RTM-Bauteilen

Band 179

Dr.-Ing. Jürgen Michna

Numerische und experimentelle Untersuchung zerspanungsbedingter Gefügeumwandlungen und Modellierung des thermo-mechanischen Lastkollektivs beim Bohren von 42CrMo4

Band 180

Dr.-Ing. Jörg Elser

Vorrichtungsfreie räumliche Anordnung von Fügepartnern auf Basis von Bauteilmarkierungen

Band 181

Dr.-Ing. Katharina Klimscha

Einfluss des Fügespalts auf die erreichbare Verbindungsqualität beim Sinterfügen

Band 182

Dr.-Ing. Patricia Weber

Steigerung der Prozesswiederholbarkeit mittels Analyse akustischer Emissionen bei der Mikrolaserablation mit UV-Pikosekundenlasern

Band 183

Dr.-Ing. Jochen Schädel

Automatisiertes Fügen von Tragprofilen mittels Faserwickeln

Band 184

Dr.-Ing. Martin Krauß

Aufwandsoptimierte Simulation von Produktionsanlagen durch Vergrößerung der Geltungsbereiche von Teilmodellen

Band 185

Dr.-Ing. Raphael Moser

Strategische Planung globaler Produktionsnetzwerke

Bestimmung von Wandlungsbedarf und Wandlungszeitpunkt mittels multikriterieller Optimierung

Band 186

Dr.-Ing. Martin Otter

Methode zur Kompensation fertigungsbedingter Gestaltabweichungen für die Montage von Aluminium Space-Frame-Strukturen

Band 187

Dr.-Ing. Urs Leberle

Produktive und flexible Gleitförderung kleiner Bauteile auf phasenflexiblen Schwingförderern mit piezoelektrischen 2D-Antriebs-elementen

Band 188

Dr.-Ing. Johannes Book

Modellierung und Bewertung von Qualitätsmanagementstrategien in globalen Wertschöpfungsnetzwerken

Band 189

Dr.-Ing. Florian Ambrosy

Optimierung von Zerspanungsprozessen zur prozesssicheren Fertigung nanokristalliner Randschichten am Beispiel von 42CrMo4

Band 190

Dr.-Ing. Adrian Kölmel

Integrierte Messtechnik für Prozessketten unreifer Technologien am Beispiel der Batterieproduktion für Elektrofahrzeuge

Band 191

Dr.-Ing. Henning Wagner

Featurebasierte Technologieplanung zum Preforming von textilen Halbzeugen

Band 192

Dr.-Ing. Johannes Gebhardt

Strukturoptimierung von in FVK eingebetteten metallischen Lasteinleitungselementen

Band 193

Dr.-Ing. Jörg Bauer

Hochintegriertes hydraulisches Vorschubsystem für die Bearbeitung kleiner Werkstücke mit hohen Fertigungsanforderungen

Band 194

Dr.-Ing. Nicole Stricker

Robustheit verketteter Produktionssysteme

Robustheitsevaluation und Selektion des Kennzahlensystems der Robustheit

Band 195

Dr.-Ing. Anna Sauer

Konfiguration von Montagelinien unreifer Produkttechnologien am Beispiel der Batteriemontage für Elektrofahrzeuge

Band 196

Dr.-Ing. Florian Sell-Le Blanc

Prozessmodell für das Linearwickeln unrunder Zahnspulen

Ein Beitrag zur orthozyklischen Spulenwickeltechnik

Band 197

Dr.-Ing. Frederic Förster

Geregeltes Handhabungssystem zum zuverlässigen und energieeffizienten Handling textiler Kohlenstofffaserzuschnitte

Band 198

Dr.-Ing. Nikolay Boev

Numerische Beschreibung von Wechselwirkungen zwischen Zerspanprozess und Maschine am Beispiel Räumen

Band 199

Dr.-Ing. Sebastian Greinacher

Simulationsgestützte Mehrzieloptimierung schlanker und ressourcen-effizienter 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 Mikrotextrurierung

Band 249

Dr.-Ing. Shun Yang

Regionalized implementation strategy of smart automation within assembly systems in China

Band 250

Dr.-Ing. Constantin Carl Hofmann

Vorausschauende und reaktive Mehrzieloptimierung für die Produktionssteuerung einer Matrixproduktion

Band 251

Dr.-Ing. Paul Ruhland

Prozesskette zur Herstellung von hybriden Faser-Metall-Preforms

Modellbildung und Optimierung des Binderauftrags und der Drapierung für stabförmige Bauteile

Band 252

Dr.-Ing. Leonard Schild

Erzeugung und Verwendung von Anwendungswissen in der industriellen Computertomographie

Band 253

Dr.-Ing. Benedikt Klee

Analyse von Phaseninformationen in Videodaten zur Identifikation von Schwingungen in Werkzeugmaschinen

Band 254

Dr.-Ing. Bruno Vargas

Wälzschälern mit kleinen Achskreuzwinkeln

Prozessgrenzen und Umsetzbarkeit

Band 255

Dr.-Ing. Lucas Bretz

Function-oriented in-line quality assurance of hybrid sheet molding compound

Band 256

Dr.-Ing. Bastian Rothaupt

Dämpfung von Bauteilschwingungen durch einstellbare Werkstückdirektspannung mit Hydrodehnspanntechnik

Band 257

Dr.-Ing. Daniel Kupzik

Robotic Swing Folding of three-dimensional UD-tape-based Reinforcement Structures

Band 258

Dr.-Ing. Bastian Verhaelen

(De-)Zentralisierung von Entscheidungen in globalen Produktionsnetzwerken

Strategie- und komplexitätsorientierte Gestaltung der Entscheidungsautonomie

Band 259

Dr.-Ing. Hannes Wilhelm Weinmann

Integration des Vereinzelungs- und Stapelbildungsprozesses in ein flexibel und kontinuierlich arbeitendes Anlagenmodul für die Li-Ionen Batteriezellfertigung

Band 260

Dr.-Ing. Florian Stamer

Dynamische Lieferzeit-Preisgestaltung in variantenreicher Produktion

Ein adaptiver Ansatz mithilfe von Reinforcement Learning

Band 261

Dr.-Ing. Patrick Neuenfeldt

Modellbildung des Tauchgleitschleifens zur Abtrag- und

Topografievorhersage an komplexen Geometrien

Band 262

Dr.-Ing. Boris Matuschka

Energieeffizienz in Prozessketten: Analyse und Optimierung von

Energieflüssen bei der Herstellung eines PKW-Getriebebauteils aus 16MnCr5

Band 263

Dr.-Ing. Tobias Schlagenhaut

Bildbasierte Quantifizierung und Prognose des Verschleißes an

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

Band 267

Dr.-Ing. Simon Raphael Merz

Analyse der Kinematik und Kinetik von Planetenwalgwindetrieben

Band 268

Dr.-Ing. Rainer Maria Silbernagel

Funktionsorientierte Qualitatsregelung in Produktionsnetzwerken

Qualitatsmanagement in der Produktion hochpraziser Produkte durch netzwerkweite Datenintegration

Band 269

Dr.-Ing. Jonas Nieschlag

Gestaltung und Prozessanalyse fur im Schleuderverfahren hergestellte FKV-Metall-Hohlstrukturen

Band 270

Dr.-Ing. Lukas Matthias Weiser

In-Process Porositatserkennung fur den PBF-LB/M-Prozess

Band 271

Dr.-Ing. Leonard Vincent Overbeck

Digital Twins of production systems

Automated validation and update of material flow simulation models with real data

Band 272

Dr.-Ing. Felix Klenk

Transparenzsteigerung in der Ruckfuhrungslogistik zur Verbesserung der Materialbedarfsplanung fur das Remanufacturing

Band 273

Dr.-Ing. Benjamin Bold

Kompensation der Wrinkle-Bildung beim Kalandrieren von Lithium-Ionen-Kathoden

Vom Prozessverstandnis des Kalandrierens bis zur Prozessoptimierung mittels Anti-Wrinkle-Modul

Band 274

Dr.-Ing. Daniel Gauder

Adaptive in-line Qualitatsregelung in der Mikro-Verzahnungsfertigung

Band 275

Dr.-Ing. Fabian Sasse

Ontologie-basierte Entscheidungsunterstützung für die Auswahl von Messsystemen in unreifen Produktionsprozessen

Band 276

Dr.-Ing. Jonas Hillenbrand

Unsupervised Condition-Monitoring für Kugelgewindetriebe mittels Acoustic Emission

Band 277

Dr.-Ing. Manuela Neuenfeldt

Untersuchung des Einflusses der PBF-LB-Stellgrößen auf die zerspanende Bearbeitung additiv gefertigter Stahlbauteile

Band 278

Dr.-Ing. Marvin Carl May

Intelligent production control for time-constrained complex job shops

Band 279

Dr.-Ing. Philipp Gönzheimer

Automatisierte Bereitstellung von Maschinensteuerungsdaten in Brownfield-Produktionssystemen

Ein Beitrag zur Digitalisierung von Bestandsanlagen am Beispiel von Werkzeugmaschinen

