

Matthias Jürgen Dörr

## **Erfassung von Informationen zur Produktnutzung beim Schleifen mit Power-Tools auf Basis von Daten eines Sensormoduls**

Acquisition of product usage information for  
grinding with Power-Tools using data from a  
sensor module

Band 169

Systeme ■ Methoden ■ Prozesse

Univ.-Prof. Dr.-Ing. Dr. h.c. A. Albers  
Univ.-Prof. Dr.-Ing. S. Matthiesen  
(Hrsg.)

Copyright IPEK - Institut für Produktentwicklung, 2023  
Karlsruher Institut für Technologie (KIT)  
Die Forschungsuniversität in der Helmholtz-Gemeinschaft  
Alle Rechte vorbehalten

Druck WIRmachenDRUCK GmbH, Backnang  
0711-99598220

ISSN 1615-8113

# **Erfassung von Informationen zur Produktnutzung beim Schleifen mit Power-Tools auf Basis von Daten eines Sensormoduls**

Zur Erlangung des akademischen Grades eines  
**DOKTORS DER INGENIEURWISSENSCHAFTEN (Dr.-Ing.)**  
von der KIT-Fakultät für Maschinenbau des  
Karlsruher Instituts für Technologie (KIT)

angenommene

**DISSERTATION**

von

M.Sc. Matthias Jürgen Dörr

Tag der mündlichen Prüfung:	19.06.2023
Hauptreferent:	Univ.-Prof. Dr.-Ing. Sven Matthiesen
Korreferent:	Univ.-Prof. Dr.-Ing. Benjamin Schleich



## Vorwort der Herausgeber

Wissen ist einer der entscheidenden Faktoren in den Volkswirtschaften unserer Zeit. Der Unternehmenserfolg wird mehr denn je davon abhängen, wie schnell ein Unternehmen neues Wissen aufnehmen, zugänglich machen und verwerten kann. Die Aufgabe eines Universitätsinstitutes ist es, hier einen wesentlichen Beitrag zu leisten. In den Forschungsarbeiten wird ständig Wissen generiert. Dieses kann aber nur wirksam und für die Gemeinschaft nutzbar werden, wenn es in geeigneter Form kommuniziert wird. Diese Schriftenreihe dient seit mehr als 20 Jahren als eine Plattform zum Transfer und macht damit das Wissenspotenzial aus aktuellen Forschungsarbeiten am IPEK - Institut für Produktentwicklung Karlsruhe\* am Karlsruher Institut für Technologie (KIT) verfügbar. Die Forschung des IPEK ist dabei strukturiert in die Kategorien Systeme, Methoden und Prozesse, um so der Komplexität heutiger Produktentwicklung ganzheitlich gerecht zu werden. Erst die Verknüpfung dieser drei Kategorien ermöglicht die Synthese innovativer Systeme durch Nutzung neuester Methoden und Prozesse. Gleichzeitig werden durch die Systemsynthese die erforschten neuen Methoden und Prozesse validiert und deren Mehrwert für die Praxis abgesichert. Dieses Forschungskonzept prägt nicht nur das IPEK-Leitbild, sondern auch den Charakter dieser Schriftenreihe, da immer alle drei Kategorien und deren Wechselwirkungen berücksichtigt werden. Jeder Band setzt hier individuelle Schwerpunkte und adressiert dabei folgende Forschungsgebiete des IPEK:

- das Entwicklungs- und Innovationsmanagement,
- die Entwicklungs- und Konstruktionsmethodik,
- der Leichtbau von der Ebene des ganzen Systems bis hinunter zur Optimierung des Bauteils,
- die Validierung technischer Systeme auch unter Berücksichtigung der NVH Aspekte (Noise, Vibration, Harshness) mit dem Fokus auf Schwingungen und Akustik an Komponenten und in den Gesamtsystemen sowie deren subjektiver Beurteilung durch den Menschen,
- die Antriebssystemtechnik mit den Schwerpunkten komplette Antriebslösungen für Fahrzeuge und Maschinen,
- das Design, die Tribologie und Erprobung von Kupplungen und Bremsen sowie
- die Gerätetechnik mit dem Schwerpunkt auf Power-Tools.

Die Forschungsberichte stellen Ergebnisse unserer Forschung sowohl anderen Wissenschaftlern als auch den Unternehmen zu Verfügung, um damit die Produktentwicklung in allen ihren Facetten mit innovativen Impulsen zu optimieren.

Albert Albers und Sven Matthiesen

\* Eh.: Institut für Maschinenkonstruktionslehre und Kraftfahrzeugbau, Universität Karlsruhe (TH)



## Vorwort zu Band 169

Kenntnisse über die Produktnutzung sind für die Produktentwicklung essentiell. Auf Basis dieser Kenntnisse können Produkte passgenau entwickelt und ausgelegt werden. In der Kreislaufwirtschaft kann bei Bekanntheit der Produktnutzung bezüglich der Wiederverwendung oder der Aufbereitung von Teilsystemen fundiert und instanzindividuell entschieden werden. Der Weg zu einer skalierbaren und unbeobachteten Erfassung geht nur über automatisiert erhobene Daten und die automatische Ableitung von Aussagen zur Nutzung der technischen Systeme. Oft können diese notwendigen Daten zur Produktnutzung nicht direkt mit Sensoren gemessen werden. Dann können sogenannte „virtuelle Sensoren“ genutzt werden. Diese setzen sich aus einer Kombination von Messtechnik und Modellen zur Ableitung von Aussagen zusammen.

Die vorliegende Arbeit befasst sich mit der Erfassung von Informationen zur Produktnutzung beim Schleifen mit Power-Tools auf Basis von Daten eines Sensormodules. In der Arbeit wird die Bildung und Validierung von mathematischen Modellen für virtuelle Sensoren zur unbeobachteten und skalierbaren Erfassung von „Nutzungselementen“ untersucht. Nutzungselemente sind die durchgeführte Tätigkeit, die „Kräfte im Werkzeugkontakt“ und die „Kräfte am Antriebsstrang“. Eingangsgrößen der mathematischen Modelle sind die Sensordaten eines von Matthias Dörr entwickelten und hier vorgestellten Sensormodules. Das Sensormodul kann zwischen Akku und Gerät eingesteckt werden und in der realen Anwendung auf der Baustelle minimalinvasiv für die Produktnutzung eingesetzt werden. Die zentralen Ergebnisse der Forschungsarbeit sind die gebildeten Modelle zur Erfassung der durchgeführten Tätigkeit, der Kräfte im Werkzeugkontakt und der Kräfte am Antriebsstrang bei Winkelschleifern sowie die damit verbundenen erfolgreich angewandten Vorgehen zur Modellbildung und Modellvalidierung. Die Zusammenführung der entwickelten Modelle ermöglicht die unbeobachtete und skalierbare Erfassung von Nutzungselementen an Winkelschleifern über virtuelle Sensoren in Verbindung mit einem Sensormodul. Die Parametrisierung der Modelle erfolgt mit verschiedenen Machine-Learning Ansätzen.

In der vorgelegten Arbeit wird Wert darauf gelegt, die virtuellen Sensoren auf Basis von physischer Messtechnik zu entwickeln, die auch kostengünstig und im Umfeld der Baustelle eingesetzt werden kann. Damit wird es herausfordernder, die Aussagegenauigkeit zu steigern, aber der tatsächliche Einsatz dieser virtuellen Sensoren überhaupt erst unter wirtschaftlichen Randbedingungen und minimalinvasivem Einfluss auf den Nutzer möglich.

Juni, 2023

Sven Matthiesen





## Kurzfassung

Wissen über die Produktnutzung ist bedeutsam für die Konstruktion und Auslegung von Produkten. Die Produktnutzung kann datenbasiert über Nutzungselemente, beispielweise aus einer Nutzung resultierende Kräfte, beschrieben werden. Diese Nutzungselemente unbeobachtet in der Nutzungsphase zu erfassen, ist häufig nicht direkt möglich. Daher werden virtuelle Sensoren eingesetzt, um diese Nutzungselemente unbeobachtet in großem Umfang zu erfassen. Virtuelle Sensoren nutzen Sensordaten aus eingebetteten Informationsmodulen oder Sensormodulen und erfassen die Nutzungselemente mithilfe von mathematischen Modellen. Für die Umsetzung des Ansatzes des virtuellen Sensors fehlt es an Wissen zur Bildung und Validierung der mathematischen Modelle.

In dieser Forschungsarbeit werden die Bildung und Validierung von mathematischen Modellen für virtuelle Sensoren zur unbeobachteten und skalierbaren Erfassung von Nutzungselementen untersucht. Winkelschleifer sind für diese Untersuchung besonders geeignet, da sie für eine große Vielfalt von Arbeitsaufgaben eingesetzt werden. Daher erfolgt die Untersuchung anhand von drei Nutzungselementen für das Beispielsystem Winkelschleifer in Verbindung mit einem Sensormodul. Konkret werden die Nutzungselemente durchgeführte Tätigkeit, Kräfte im Werkzeugkontakt und Kräfte am Antriebsstrang betrachtet. Eingangsgrößen der mathematischen Modelle sind Sensordaten des Sensormoduls.

Für die Erfassung der durchgeführten Tätigkeiten wurden statistische Modelle mittels Machine-Learning parametrisiert. Es wurde gezeigt, dass sich das Verfahren Leave-One-Trial-Out Kreuzvalidierung zur Bewertung der Vorhersage unter starkem Einfluss von Störgrößen eignet. Für die Erfassung der Kräfte im Werkzeugkontakt wurde ein Gauß-Prozess-Regression (GPR)-Modell mittels Machine-Learning gebildet. Für die Tangential- und Normalkräfte ist die Vorhersage mit hoher Genauigkeit für verschiedene Abstraten möglich. Für die Erfassung der Kräfte am Antriebsstrang wurden Übertragungsfunktionen zur Berechnung der Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt experimentell ermittelt. Die Ergebnisse zeigen, dass die Übertragungsfunktionen verschiedener Arbeitspunkte zweckmäßig zu einer arbeitspunktunabhängigen Übertragungsfunktion zusammengeführt werden können.

Zentrale Ergebnisse dieser Forschungsarbeit sind die gebildeten Modelle zur Erfassung der durchgeführten Tätigkeit, der Kräfte im Werkzeugkontakt und der Kräfte am Antriebsstrang bei Winkelschleifern sowie die damit verbundenen, erfolgreich angewandten Vorgehensweisen zur Modellbildung und -validierung. Die Zusammenfassung dieser Modelle ermöglicht die unbeobachtete und skalierbare Erfassung von Nutzungselementen an Winkelschleifern über virtuelle Sensoren in Verbindung mit einem Sensormodul.



## Abstract

Knowledge about product usage is important for the design and dimensioning of products. Product usage can be described in a data-based manner by usage elements. It is often not possible to directly capture these usage elements unobserved in the usage phase. Therefore, virtual sensors are used to capture these usage elements unobserved on large scale. Virtual sensors use sensor data from embedded information modules or sensor modules and capture the usage elements using mathematical models. To implement the virtual sensor approach, knowledge of the modeling and validation of mathematical models is lacking.

In this thesis, the modeling and validation of mathematical models for virtual sensors for the unobserved and scalable acquisition of usage elements are investigated. Angle grinders are particularly suitable for this investigation because they are used for a wide variety of work tasks. Therefore, the investigation is conducted using three usage elements for the example system of angle grinders in conjunction with a sensor module. Specifically, the usage elements are activity performed, forces in tool contact, and forces on the drive train. Input variables of the mathematical models are sensor data of the sensor module.

Statistical models were parameterized using machine learning to capture the activities performed. It was shown that the validation strategy Leave-One-Trial-Out cross-validation is suitable for strong disturbance variables. A Gaussian Process Regression (GPR) model was built using machine learning for the detection of the forces in the tool contact. The validation of the model shows that a prediction of the tangential and normal forces with different sampling rates is possible with high accuracy. Transfer functions for calculating the forces on the drive train from the forces in the tool contact were determined experimentally. It was shown that the transfer functions of different working points can be well combined into a transfer function independent of working points.

The central results of this thesis are the models to capture the activity performed, the forces in tool contact, and the forces on the drive train for angle grinders, as well as the associated successfully applied approaches to modeling and validation. The summary of these models enables the unobserved and scalable acquisition of usage elements on angle grinders using virtual sensors in conjunction with a sensor module.



# Danksagung

Die vorliegende Forschungsarbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Gerätekonstruktion und Maschinenelemente am IPEK - Institut für Produktentwicklung des Karlsruher Instituts für Technologie (KIT).

An erster Stelle möchte ich mich bei meinem Doktorvater, Herrn Univ.-Prof. Dr.-Ing. Sven Matthiesen, für seine kompetente Betreuung, Offenheit und konstruktive Kritik bedanken. Seine wertvollen Hinweise und sein offenes Ohr haben wesentlich zum Gelingen dieser Forschungsarbeit beigetragen.

Herrn Univ.-Prof. Dr.-Ing. Benjamin Schleich danke ich für die Übernahme des Korreferats. Herrn Univ.-Prof. Dr.-Ing. habil. Volker Schulze danke ich für die Übernahme des Prüfungsvorsitzes.

Ein herzliches Dankeschön geht auch an das gesamte IPEK-Team, einschließlich der Verwaltung, des Sekretariats, der technischen Dienste und der IT-Abteilung, sowie an meine wissenschaftlichen Kolleginnen und Kollegen. Die gute Zusammenarbeit und Unterstützung haben meine Forschungsarbeit sehr bereichert.

Insbesondere möchte ich mich bei meinen Kollegen Sebastian Zimprich, Markus Döllken, Dr.-Ing. Matthias Eisenmann und Dr.-Ing. Thomas Gwosch für die wissenschaftliche Diskussion und die konstruktiven Kommentare zu dieser Forschungsarbeit bedanken.

Ein besonderer Dank gilt auch meinen Freunden, die mich während meiner Promotionszeit unterstützt und gefördert haben. Ihre Unterstützung und ihr Rückhalt waren von großem Wert.

Nicht zuletzt möchte ich mich bei meiner Familie bedanken. Ihr habt mich während meiner gesamten akademischen Laufbahn unterstützt und ermutigt. Mein besonderer Dank gilt meiner Frau Saskia. Ihre Liebe und Unterstützung haben mich durch die herausfordernden Phasen meiner Promotion getragen.

Herzlichen Dank!

Juli, 2023

Matthias Jürgen Dörr



"All models are wrong, but some models are useful"  
George Box, 1987





# Inhaltsverzeichnis

<b>Kurzfassung</b> .....	<b>i</b>
<b>Abstract</b> .....	<b>iii</b>
<b>Inhaltsverzeichnis</b> .....	<b>ix</b>
<b>Abbildungsverzeichnis</b> .....	<b>xiii</b>
<b>Tabellenverzeichnis</b> .....	<b>xvii</b>
<b>Abkürzungsverzeichnis</b> .....	<b>xix</b>
<b>Formelzeichen</b> .....	<b>xxi</b>
<b>1 Einleitung</b> .....	<b>1</b>
<b>2 Grundlagen und Stand der Forschung</b> .....	<b>3</b>
2.1 Grundlagen zum Schleifen mit Power-Tools und Machine-Learning .....	3
2.1.1 Grundlagen zum Schleifen mit Power-Tools .....	4
2.1.2 Grundlagen zum Machine-Learning mit überwachten Lernverfahren .....	9
2.2 Ansätze zur Erfassung von Informationen zur Produktnutzung von Power-Tools .....	12
2.2.1 Charakterisierung der Produktnutzung .....	13
2.2.2 Datenquellen zur Erfassung von Informationen zur Produktnutzung .....	17
2.2.3 Anforderungen an messtechnische Erfassung von Informationen zur Produktnutzung.....	20
2.3 Messtechnische Erfassung von Informationen zur Produktnutzung bei Power-Tools .....	23
2.3.1 Einsatz von Sensoren .....	24
2.3.2 Einsatz von virtuellen Sensoren.....	28
2.4 Nutzungselemente beim Schleifen mit Power-Tools.....	31
2.4.1 Nutzungselement: Durchgeführte Tätigkeit.....	32
2.4.2 Nutzungselement: Kräfte im Werkzeugkontakt .....	35
2.4.3 Nutzungselement: Kräfte am Antriebsstrang.....	38
2.5 Fazit zu Grundlagen und Stand der Forschung .....	41
<b>3 Motivation und Zielsetzung</b> .....	<b>43</b>
<b>4 Forschungsdesign</b> .....	<b>45</b>
<b>5 Erfassung der durchgeführten Tätigkeit</b> .....	<b>51</b>

5.1	Versuchsaufbau und Modellbildung .....	52
5.1.1	Manuelle Studie .....	52
5.1.2	Sensormodul .....	56
5.1.3	Datenverarbeitung .....	57
5.1.4	Modellbildung und Validierung zur Vorhersage der durchgeführten Tätigkeit .....	59
5.2	Ergebnis .....	64
5.3	Diskussion .....	65
5.3.1	Vergleich der Ergebnisse mit dem Stand der Forschung .....	65
5.3.2	Diskussion zur Teilforschungsfrage 1.1 .....	66
5.3.3	Diskussion zur Teilforschungsfrage 1.2 .....	68
5.3.4	Einschränkungen und Übertragbarkeit der Ergebnisse .....	69
5.4	Zwischenfazit .....	70
<b>6</b>	<b>Erfassung der Kräfte im Werkzeugkontakt .....</b>	<b>71</b>
6.1	Studiendesign und Modellentwicklung .....	72
6.1.1	Manuelle Studie .....	72
6.1.2	Datenverarbeitung .....	73
6.1.3	Modellbildung und Validierung zur Vorhersage der Kräfte im Werkzeugkontakt .....	76
6.2	Ergebnisse .....	79
6.3	Diskussion .....	82
6.3.1	Diskussion zur Teilforschungsfrage 2.1 .....	83
6.3.2	Vergleich der Ergebnisse mit dem Stand der Forschung .....	85
6.3.3	Diskussion zur Teilforschungsfrage 2.2 .....	87
6.3.4	Einschränkungen und Übertragbarkeit der Ergebnisse .....	88
6.4	Zwischenfazit .....	91
<b>7</b>	<b>Erfassung der Kräfte am Antriebsstrang durch Modellierung des Werkzeugs .....</b>	<b>93</b>
7.1	Zusammenführung von Übertragungsfunktionen verschiedener Arbeitspunkte .....	94
7.1.1	Versuchsaufbau und Bildung der Übertragungsfunktionen .....	95
7.1.2	Ergebnisse .....	101
7.1.3	Diskussion .....	106
7.2	Anwendung der zusammengeführten Übertragungsfunktionen .....	109
7.2.1	Vorgehen zur Anwendung der zusammengeführten Übertragungsfunktionen .....	109
7.2.2	Ergebnisse .....	111
7.2.3	Diskussion .....	115
7.3	Zwischenfazit .....	116

<b>8 Zusammenfassung und Ausblick</b> .....	<b>117</b>
8.1 Zusammenfassung .....	117
8.2 Ausblick.....	120
<b>Literaturverzeichnis</b> .....	<b>I</b>
<b>Glossar</b> .....	<b>XXI</b>
<b>Anhang</b> .....	<b>XXIII</b>



# Abbildungsverzeichnis

Abbildung 2.1:	Aufbau und Komponenten eines Winkelschleifers. Durch Gwosch (2019, S. 31) modifizierte Darstellung der C. & E. Fein GmbH (2019) .....	5
Abbildung 2.2:	Vier verschiedene Werkzeug eines Winkelschleifers: Trennscheiben (a), Schruppscheiben (b), Fiberscheiben mit Stützteller (c) und Fächerschleifscheiben (d). (Dörr, Zimprich et al., 2019, S. 2).....	6
Abbildung 2.3:	Zusammenhänge beim Schleifen zwischen den Kräften und der Energie mit anderen relevanten Größen. In Anlehnung an Tönshoff et al. (1992, S. 678).....	8
Abbildung 2.4:	Trainings- und Validierungsdatensätze beim Verfahren Kreuzvalidierung zur Validierung eines statistischen Modells am Beispiel von k = 5 Durchläufen. In Anlehnung an Bishop (2009, S. 33) .....	11
Abbildung 2.5:	Framework von Voet et al. (2019) zur Generierung von Wissen zur Produktverbesserung aus mit Sensoren und Algorithmen erfassten Nutzungselementen. In Anlehnung an Voet et al. (2019, S. 4) .....	14
Abbildung 2.6:	Charakterisierung der Produktnutzung mit Informationen zur Produktnutzung in vier Detailstufen nach Deng & Thoben (2022). In Anlehnung an Deng & Thoben (2022, S. 10).....	15
Abbildung 2.7:	Vorgehen von Schmidt (2019) zur Ableitung von Tätigkeiten aus der messtechnisch erfassten Produktnutzung anhand definierter Clusterkriterien. In Anlehnung an Schmidt (2019, S. 149) .....	16
Abbildung 2.8:	Datenquellen zur Bedarfsermittlung in der Konzeptphase der datengetriebenen Produktentwicklung. In Anlehnung an Bertoni (2020, S. 105) .....	19
Abbildung 2.9:	Vorwärts- und rückwärtsgerichteter Informationsfluss im Produktlebenszyklus. In Anlehnung an Wellsandt et al. (2015, S. 243) .....	21
Abbildung 2.10:	Prozess der technischen Vererbung nach Lachmayer et al. (2014) zur Verbesserung eines Systems nachfolgender Produktgenerationen durch Informationen zur Produktnutzung. In Anlehnung an Lachmayer et al. (2014, S. 184) .....	23

Abbildung 2.11:	Aufbau und Anwendung eines Labor-Messsystems am Beispiel der Vibrationsmessung am Getriebegehäuse eines Winkelschleifers. In Anlehnung an Sang (2020) .....	26
Abbildung 2.12:	Anwendung des Sensormoduls <i>Cross-Domain Development Kit XDK 110</i> (Robert Bosch GmbH, Gerlingen-Schillerhöhe, Deutschland) am Beispiel der Vibrationsmessung am Getriebegehäuse eines Winkelschleifers. ....	27
Abbildung 2.13:	IMU für das Sensormodul von Yang et al. (2019) <b>(a)</b> sowie Sensormodule von Wilwer et al. (2020) <b>(b)</b> , von Heinis et al. (2018) <b>(c)</b> und von Redžepagić et al. (2020) <b>(d)</b> , die am Beispiel Akkuschauber eingesetzt werden. In Anlehnung an Heinis et al. (2018, S. 37), Redžepagić et al. (2020, S. 131), Wilwer et al. (2020, S. 143) und Yang et al. (2019, S. 37).....	28
Abbildung 2.14:	Virtueller Sensor als Kombination von physisch vorhandenen Sensoren in einem Messsystem und einem Modell, dargestellt am Beispiel der Vorhersage von Kräften im Werkzeugkontakt. In Anlehnung an Chérury (1997, S. 194).....	29
Abbildung 2.15:	Bildung, Validierung und Anwendung von Black-Box-Modellen. In Anlehnung an Tönshoff et al. (1992, S. 678).....	30
Abbildung 2.16:	Ansatz zur Messung der Kräfte am Antriebsstrang eines Winkelschleifers durch berührungslose Wegsensoren. (Matthiesen et al., 2014, S. 58).....	39
Abbildung 2.17:	Ansatz zur Messung der Kräfte am Antriebsstrang eines Winkelschleifers durch Applikation eines Kraft-Momenten-Sensors am Gehäuse und Einbau einer Nachgiebigkeit in den Antriebsstrang: Skizze des Ansatzes <b>(a)</b> und an einem handelsüblichen Winkelschleifer angebrachter Prototyp <b>(b)</b> . In Anlehnung an Phan et al. (2017, S. 552) .....	40
Abbildung 4.1:	Forschungsdesign zur Erreichung der Zielsetzung .....	47
Abbildung 5.1:	In der Studie wurden vier Tätigkeiten mit unterschiedlichen Werkzeugen durchgeführt. In Anlehnung an Dörr, Ott et al. (2021, S. 4).....	53
Abbildung 5.2:	CCG18 mit Sensormodul und Versuchsaufbau T2 mit dem Werkstück zur Tätigkeit <i>Schleifen mit einer Fächerschleifscheibe</i> <b>(a)</b> und GWS18 mit Sensormodul und Versuchsaufbau T2 mit dem Werkstück zur Tätigkeit <i>Schruppen mit einer Schrappscheibe</i> <b>(b)</b> . (Dörr, Spoden et al., 2022, S. 3) .....	55

Abbildung 5.3:	Leiterplatte und Gehäuse des Sensormoduls. In Anlehnung an Dörr, Peters & Matthiesen (2021, S. 4) und Helmstetter et al. (2022, S. 11) .....	57
Abbildung 5.4:	Bildung der Gruppen bei der Kreuzvalidierung und der Leave-One-Trial-Out-Kreuzvalidierung. In Anlehnung an Dörr, Spoden et al. (2022, S. 4).....	60
Abbildung 5.5:	Auf das Schleifen mit Power-Tools adaptierte mehrstufige binäre Klassifikation. Übersetzt aus Dörr, Spoden et al. (2022, S. 5) .....	62
Abbildung 5.6:	Vorgehen für die Modellbildung mittels verschachtelter Kreuzvalidierung zur Vorhersage der durchgeführten Tätigkeit. In Anlehnung an Dörr, Spoden et al. (2022, S. 4).....	63
Abbildung 6.1:	Verwendete Winkelschleifer mit passendem Sensormodul und Versuchsaufbau zur Messung der Kräfte im Werkzeugkontakt: Winkelschleifer GWS18 (a), Winkelschleifer CCG18 (b) und Versuchsaufbau T1 mit der Stahlprobe für die Tätigkeiten <i>Schruppen mit einer Schrupscheibe</i> und <i>Schruppen mit einer Fiberscheibe</i> (c). (Dörr, Ott et al., 2021, S. 4).....	73
Abbildung 6.2:	Transformation der Koordinatensysteme der am Versuchsaufbau gemessenen Kräfte auf die Kräfte im Werkzeugkontakt für alle Tätigkeiten: Transformation für die Tätigkeit <i>Trennen mit einer Trennscheibe</i> (a), für die Tätigkeiten <i>Schruppen mit einer Schrupscheibe</i> und <i>Schruppen mit einer Fiberscheibe</i> (b) und für die Tätigkeit <i>Schleifen mit einer Fächerschleifscheibe</i> (c). Übersetzt aus Dörr, Ott et al. (2021, S. 5) .....	74
Abbildung 6.3:	Vorgehen für die Modellbildung zur Vorhersage der Kräfte im Werkzeugkontakt. In Anlehnung an Dörr, Ott et al. (2021, S. 9) .....	77
Abbildung 6.4:	Gemessene und vorhergesagte Kräfte im Werkzeugkontakt einschließlich Vorhersageintervall beim <i>Schruppen mit einer Schrupscheibe</i> . In Anlehnung an Dörr, Ott et al. (2021, S. 11) .....	80
Abbildung 7.1:	Untersuchte Werkzeuge, einschließlich Koordinatensysteme im Werkzeugkontakt und am Antriebsstrang. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 4-5) .....	95
Abbildung 7.2:	Skizze des Prüfstands zur Messung der Kräfte in allen drei Richtungen im Werkzeugkontakt und am Antriebsstrang für	

	verschiedene Arbeitspunkte. Übersetzt aus Dörr, Dürkopp et al. (2021, S. 2).....	96
Abbildung 7.3:	Vorgehen zur Bildung einer Übertragungsfunktion aus einem einzelnen Versuch am Beispiel für die untersuchte Schruppscheibe bei einer Normalkraft von 70 N und einer Drehzahl von $6500 \text{ min}^{-1}$ . In Anlehnung an Dörr, Dürkopp et al. (2021, S. 3).....	99
Abbildung 7.4:	Streuung von 40 Übertragungsfunktionen für 20 Arbeitspunkte für die untersuchte Fächerschleifscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 4).....	102
Abbildung 7.5:	Streuung von 40 Übertragungsfunktionen über 20 Arbeitspunkte für die untersuchte Schruppscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 5).....	103
Abbildung 7.6:	Streuung von 40 Übertragungsfunktionen über 20 Arbeitspunkte für die untersuchte Trennscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 5).....	104
Abbildung 7.7:	Vorgehen zur Ermittlung der Kräfte am Antriebsstrang eines Winkelschleifers anhand einer Übertragungsfunktion für die untersuchte Schruppscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 4).....	110
Abbildung 7.8:	Verteilung der Kraftwerte im Werkzeugkontakt und am Antriebsstrang in alle Richtungen für die untersuchte Fächerschleifscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 5).....	112
Abbildung 7.9:	Verteilung der Kraftwerte im Werkzeugkontakt und am Antriebsstrang in alle Richtungen für die untersuchte Schruppscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 6).....	113
Abbildung 7.10:	Verteilung der Kraftwerte im Werkzeugkontakt und am Antriebsstrang in alle Richtungen für die untersuchte Trennscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 6).....	114



# Tabellenverzeichnis

Tabelle 2.1:	Übersicht von Sensoren, die an oder in einem Winkelschleifer appliziert wurden .....25
Tabelle 5.1:	Versuchscluster in Bezug auf Merkmale der Versuche innerhalb des Studiendesigns zur Erfassung von Messdaten abweichender Versuche. In Anlehnung an Dörr, Spoden et al. (2022, S. 3) .....56
Tabelle 5.2:	Anzahl der Segmente aller Tätigkeiten nach Reduzierung der Segmente der Klasse <i>Kein Werkzeugkontakt</i> . In Anlehnung an Dörr, Spoden et al. (2022, S. 3).....58
Tabelle 5.3:	Genauigkeit der Klassifikation für verschiedene statistische Modelle für zwei Winkelschleifer bei 26-facher CV und bei der LOTO CV. Übersetzt aus Dörr, Spoden et al. (2022, S. 4) .....64
Tabelle 5.4:	Genauigkeit der Klassifikation der einzelnen Stufen der mehrstufigen binären Klassifikation (MBC) mittels LOTO CV. In Anlehnung an Dörr, Spoden et al. (2022, S. 5).....65
Tabelle 6.1:	Bewertung der Leistung des GPR-Modells zur Vorhersage von Kräften im Werkzeugkontakt bei einer vorherzusagenden Abtastrate von 10 Hz für beide Winkelschleifer. In Anlehnung an Dörr, Ott et al. (2021, S. 10) .....81
Tabelle 6.2:	Bewertung der Leistung des GPR-Modells zur Vorhersage von Kräften im Werkzeugkontakt für die Abtastraten 1 Hz, 10 Hz und 20 Hz für beide Winkelschleifer. In Anlehnung an Dörr, Ott et al. (2021, S. 11).....82
Tabelle 7.1:	Versuchsplan zur Messung der Kräfte im Werkzeugkontakt und am Antriebsstrang bei maschinenunabhängigen Arbeitspunkten. Übersetzt aus Dörr, Dürkopp et al. (2021, S. 3) .....97
Tabelle 7.2:	Durchschnittliche Abweichungen als mittlerer absoluter Fehler (MAE) zwischen verschiedenen Gruppen von Übertragungsfunktionen, die anhand der Faktoren des Versuchsdesigns eingeteilt wurden. ....105



# Abkürzungsverzeichnis

CV	Kreuzvalidierung (englisch: Cross Validation)
DIN	Deutsches Institut für Normung e. V.
EL	Ensemble Methode
FFT	Fast-Fourier-Transformation
GPR	Gauß-Prozess-Regression
HAR	Erkennung menschlicher Aktivitäten (englisch: Human Activity Recognition)
IFW	Institut für Werkzeugforschung und Werkstoffe e.V.
IMU	Inertiale Messeinheit (englisch: Inertial Measurement Unit)
ISO	Internationale Organisation für Normung
kNN	k-Nächster-Nachbar Algorithmus
LOTO	Leave-One-Trial-Out
MBC	Mehrstufige binäre Klassifikation (englisch: Multistage Binary Classification)
MEMS	Mikro-Elektro-Mechanisches System
MRMR	Minimum Redundancy Maximum Relevance
PUI	Informationen zur Produktnutzung (englisch: Product Usage Information)
PEID	In ein Produkt eingebettetes Informationsmodul (englisch: Product Embedded Information Device)
SD	Standardabweichung (englisch: Standard Deviation)
SVM	Support-Vektor-Maschine
VBG	Verwaltungs-Berufsgenossenschaft



# Formelzeichen

$f()$	Mathematische Beziehung
$F$	Gemessener beziehungsweise wahrer Kraftverlauf
$F^*$	Vorhergesagter Kraftverlauf
$F_{F,Fiber}$	Führungskraft bei der Tätigkeit <i>Schruppen mit einer Fiberscheibe</i>
$F_{F,Schleif}$	Führungskraft bei der Tätigkeit <i>Schleifen mit einer Fächerschleifscheibe</i>
$F_{F,Schrupp}$	Führungskraft bei der Tätigkeit <i>Schruppen mit einer Schrappscheibe</i>
$F_N$	Normalkraft
$F_{N,C}$	Kraftkomponente der Normalkraft zur Zerspanung mittels Schleifkorn
$F_{N,Fiber}$	Normalkraft bei der Tätigkeit <i>Schruppen mit einer Fiberscheibe</i>
$F_{N,Schleif}$	Normalkraft bei der Tätigkeit <i>Schleifen mit einer Fächerschleifscheibe</i>
$F_{N,Schrupp}$	Normalkraft bei der Tätigkeit <i>Schruppen mit einer Schrappscheibe</i>
$F_{N,Sl}$	Kraftkomponente der Normalkraft, die beim Gleiten über eine Oberfläche entsteht
$F_{Q,Trenn}$	Querkraft bei der Tätigkeit <i>Trennen mit einer Trennscheibe</i>
$F_{R,Trenn}$	Radialkraft bei der Tätigkeit <i>Trennen mit einer Trennscheibe</i>
$F_{N,C}$	Kraftkomponente der Normalkraft zur Zerspanung mittels Schleifkorn
$F_T$	Tangentialkraft
$F_{T,C}$	Kraftkomponente der Tangentialkraft zur Zerspanung mittels Schleifkorn
$F_{T,Fiber}$	Tangentialkraft bei der Tätigkeit <i>Schruppen mit einer Fiberscheibe</i>

$F_{T,Schleif}$	Tangentialkraft bei der Tätigkeit <i>Schleifen mit einer Fächerschleifscheibe</i>
$F_{T,Schrupp}$	Tangentialkraft bei der Tätigkeit <i>Schruppen mit einer Schruppscheibe</i>
$F_{T,Sl}$	Kraftkomponente der Tangentialkraft, die beim Gleiten über eine Oberfläche entsteht
$k$	Anzahl der Durchläufe bei der Kreuzvalidierung
$i$	Summationsindex
$MAE$	Mittlere absolute Fehler (englisch: Mean Absolute Error)
$N$	Anzahl an unabhängigen Variablen
$P$	Schleifleistung
$r$	Pearson-Korrelationskoeffizient
$R^2$	Bestimmtheitsmaß
$rMAE$	relativer $MAE$
$v_u$	Umfangsgeschwindigkeit eines Werkzeugs
$X$	Unabhängige Variable
$x$	Wert einer unabhängigen Variable
$Y$	Abhängige Variable
$y$	Wahrer Wert einer abhängigen Variablen
$\hat{y}$	Vorhergesagter Wert einer abhängigen Variable
$\bar{y}$	Durchschnittlicher Wert einer abhängigen Variable
$\beta$	Vektor zur Schätzung einer abhängigen Variable $Y$ anhand von unabhängigen Variablen $X$ .
$\mu$	Reibungskoeffizient

# 1 Einleitung

Die Konstruktion ist ein bedeutsamer Bestandteil der Produktentwicklung. Ihr grundsätzliches Ziel ist die Konstruktion von Produkten mit einem hohen Anbieter- und Kundennutzen. Dazu wird in der Konstruktion die Gestalt des Produkts aus Entwicklungszielen synthetisiert. Die Gestalt eines Produkts definiert das Verhalten. Unter dem Verhalten eines Produkts wird dessen Reaktion auf einwirkende Einflussgrößen verstanden (Zingel, 2013). Um die Gestalt zu synthetisieren, ist Wissen über das Verhalten des Produkts in Situationen erforderlich, die während der Nutzung auftreten. Das Paradoxon der Konstruktion besagt, dass in frühen Phasen der Produktentwicklung das Verhalten eines Produkts am stärksten beeinflusst werden kann, aber die Erkenntnismöglichkeit und das Wissen über das Verhalten am geringsten sind (Ehrlenspiel & Meerkamm, 2017). Der Konstruktionsprozess ist vor allem ein informationsverarbeitender Prozess (Hubka & Eder, 1992). Ein wesentlicher Zeitanteil, je nach Quelle 8 % bis 50 % der Konstruktionszeit, wird dabei für die Informationsgewinnung eingesetzt (Ehrlenspiel & Meerkamm, 2017). Dies zeigt die Bedeutung von Wissen über das Verhalten eines Produkts für die Konstruktion.

Wissen zum Verhalten eines Produkts kann durch die Beobachtung des Verhaltens generiert werden, beispielsweise beim Testing. Bei der datengetriebenen Produktentwicklung wird die Konstruktion durch die Analyse erfasster Daten unterstützt, indem die Ursache für ein Produktverhalten identifiziert und erklärt wird (Küstner, 2020). Die verfügbare „Datenmenge muss [...] ausreichend groß sein, um Muster erkennen und generalisierbare Aussagen treffen zu können“ (Mehlstäubl et al., 2021, S. 6). Dies erfordert Ansätze und Methoden zur Erfassung von Daten zum Produktverhalten.

Eine wertvolle Quelle für die Prognose des Produktverhaltens sind Informationen zur Produktnutzung (PUI) (Klein et al., 2019). PUI beschreiben alle dem Produkt zugeordneten Informationen, die aus der Nutzungsphase zurück in die Produktentwicklung fließen (Fathi & Holland, 2009), und ermöglichen damit die Identifikation und Erklärung eines Produktverhaltens. Damit leisten PUI einen bedeutsamen Beitrag zur Produktverbesserung, beispielsweise hinsichtlich der Zuverlässigkeit (Kiritsis et al., 2003), und sind damit ein zentraler Bestandteil der datengetriebenen Produktentwicklung (Hou & Jiao, 2020; Shin et al., 2015).

Aus dem Bedarf der Konstruktion für PUI wird in dieser Forschungsarbeit die Erfassung der PUI mit dem Ansatz des virtuellen Sensors untersucht. Ein virtueller

Sensor besteht aus mehreren physisch vorhandenen Sensoren und mathematischen Modellen, die die PUI aus den Sensordaten bestimmen. Für die Umsetzung dieses Ansatzes fehlt es an Wissen zur Bildung und Validierung der Modelle. Daher werden in dieser Forschungsarbeit Modelle für virtuelle Sensoren zur Erfassung von PUI gebildet und validiert.

Produkte, die in Interaktion mit der anwendenden Person stehen und auf vielfältige Weise genutzt werden können, sind Power-Tools. Aufgrund der vielfältigen Einsatzmöglichkeiten von Power-Tools ist die Erfassung von PUI für die Produktverbesserung besonders relevant. Für Power-Tools eröffnet die Erfassung der PUI neben der Produktverbesserung weitere Potenziale: Damit wird die Erfassung von manuellen Prozessen und Bearbeitungsschritten in der Fertigung ermöglicht, bei denen Power-Tools eingesetzt werden (Lee et al., 2021; Roblek et al., 2016). Für die Kreislaufwirtschaft ist die durchgängige Erfassung der Produktnutzung bedeutsam, um daraus Erkenntnisse zur Verbesserung der Produkte und zur Reparatur und Aufbereitung der Produkte abzuleiten (Alcayaga et al., 2019). PUI von Power-Tools können auch für Geschäftsmodelle (Pirola et al., 2020) wie Pay-per-Use (Heinis et al., 2018) verwendet werden.

Aus diesen Gründen befasst sich diese Forschungsarbeit mit Power-Tools. Dabei liegt der Fokus im Rahmen dieser Forschungsarbeit auf Power-Tools, die zum Schleifen eingesetzt werden. Für diese Power-Tools sind drei Aspekte der Produktnutzung, sogenannte Nutzungselemente, relevant: die durchgeführte Tätigkeit, die Kräfte im Werkzeugkontakt und die Kräfte am Antriebsstrang. Diese werden anhand des Beispielsystems Winkelschleifer untersucht.

Nach der Einleitung werden in Kapitel 2 die notwendigen Grundlagen und der aktuelle Stand der Forschung zur Erfassung von PUI bei Power-Tools dargelegt. Hierauf basierend wird in Kapitel 3 eine konkrete Zielsetzung abgeleitet. Die Forschungsfragen und das Forschungsdesign zur Erreichung der Zielsetzung sind in Kapitel 4 dargestellt. In Kapitel 5 werden die Modellbildung und Validierung zur Vorhersage der durchgeführten Tätigkeit mit einem Winkelschleifer vorgestellt. In Kapitel 6 werden die Modellbildung und Validierung zur Vorhersage der Kräfte im Werkzeugkontakt bei der Arbeit mit einem Winkelschleifer ausgeführt. In Kapitel 7 wird die Berechnung der Kräfte am Antriebsstrang eines Winkelschleifers aus den Kräften im Werkzeugkontakt vorgestellt. In Kapitel 8 wird die Forschungsarbeit zusammengefasst und es wird ein Ausblick auf anknüpfende Forschungsrichtungen vorgenommen.



## **2 Grundlagen und Stand der Forschung**

In diesem Kapitel werden die notwendigen Grundlagen und der Stand der Forschung vorgestellt.

In Kapitel 2.1 werden die zum Verständnis dieser Forschungsarbeit notwendigen Grundlagen zum Schleifen mit Power-Tools sowie zum Machine-Learning vorgestellt.

In Kapitel 2.2 wird die Charakterisierung der Produktnutzung durch PUI vorgestellt. Zudem wird diskutiert, aus welchen Datenquellen PUI erhoben werden können und welche Anforderungen sich daraus ergeben.

In Kapitel 2.3 wird der Stand der Forschung zur messtechnischen Erfassung von PUI bei Power-Tools auf Basis der Eingrenzung in Kapitel 2.2 aufgezeigt. Dazu werden Sensoren, Messsysteme und virtuelle Sensoren für Power-Tools vorgestellt und deren Eignung zur Erfassung von PUI während der Nutzungsphase wird beleuchtet.

In Kapitel 2.4 wird der Stand der Forschung zu drei relevanten Nutzungselementen beim Schleifen mit Power-Tools auf Basis der messtechnischen Erfassung in Kapitel 2.3 aufgezeigt. Die Nutzungselemente umfassen die durchgeführte Tätigkeit, die Kräfte im Werkzeugkontakt und die Kräfte am Antriebsstrang.

In Kapitel 2.5 wird ein Fazit zum Stand der Forschung gezogen und daraus eine Forschungslücke abgeleitet.

### **2.1 Grundlagen zum Schleifen mit Power-Tools und Machine-Learning**

In diesem Kapitel werden die Grundlagen zum Schleifen mit Power-Tools erläutert. Daraufhin werden das Beispielsystem Winkelschleifer und dazugehörige Werkzeuge vorgestellt. Darüber hinaus werden in diesem Kapitel die Grundlagen des Machine-Learning vorgestellt. Es wird erklärt, wie statistische Modelle zur Erfassung von PUI mittels Machine-Learning gebildet und validiert werden können.

### 2.1.1 Grundlagen zum Schleifen mit Power-Tools

Schleifen ist ein Fertigungsverfahren mit geometrisch unbestimmter Schneide zum Materialabtrag bei Werkstücken (Deutsches Institut für Normung e.V. [DIN], 2003). Beim manuellen Schleifen können Power-Tools eingesetzt werden. Solche Power-Tools, die zum Schleifen eingesetzt werden, sind handgeführte Maschinen. Damit werden tragbare Maschinen bezeichnet, deren Gewicht ganz oder teilweise auf einer Werkbank, auf dem bearbeiteten Werkstück oder auf dem Boden abgestützt wird und deren Bewegung von einer anwendenden Person während der Bedienung der Maschine mit der Hand geführt wird (Verwaltungs-Berufsgenossenschaft [VBG], 2022).

Power-Tools zum Schleifen lassen sich nach ihrem Funktionsprinzip in die folgenden vier Typen unterteilen: Rotationsschleifer, Exzentrerschleifer, Schwingschleifer und Bandschleifer. Zu den Rotationsschleifern gehören Geradschleifer und Winkelschleifer. Bei Rotationsschleifern wird das Schleifmittel mit einer hohen Drehzahl rotiert, was eine hohe Umfangsgeschwindigkeit zur Folge hat. Beim Exzentrerschleifer wird eine oszillierende Bewegung mit einer zusätzlichen Rotation überlagert. Schwingschleifer basieren dagegen ausschließlich auf einer oszillierenden Bewegung mit geringer Amplitude. Bandschleifmaschinen besitzen eine große Schleiffläche, auf der das Schleifband mit hoher Geschwindigkeit rotiert. (Schweizer, 2003)

Winkelschleifer sind Rotationsschleifer, bei denen die Drehachse des Werkzeugs in einem Winkel von  $90^\circ$  zur Antriebsachse angeordnet ist (Schweizer, 2005). Das System Winkelschleifer besteht aus der eigentlichen Maschine und einem wechselbaren Werkzeug. Im Rahmen dieser Forschungsarbeit wird die Bezeichnung Power-Tool für die Kombination der Systeme Werkzeug und Maschine verwendet. Ein beispielhafter Aufbau und Komponenten eines Winkelschleifers sind in Abbildung 2.1 dargestellt.




Abbildung 2.1: Aufbau und Komponenten eines Winkelschleifers. Durch Gwosch (2019, S. 31) modifizierte Darstellung der C. & E. Fein GmbH (2019)

Winkelschleifer werden zum Seiten- und Umfangsschleifen (Trennschleifen) eingesetzt (Schweizer, 2005). Beim Winkelschleifer werden je nach Tätigkeit verschiedene Werkzeuge eingesetzt. Im Folgenden werden mit der Trenn-, der Schrupp-, der Fiber- und der Fächerschleifscheibe die vier Werkzeuge erläutert, die im Rahmen dieser Forschungsarbeit untersucht werden:

- Trennscheibe: Eine Trennscheibe wird eingesetzt, um ein Werkstück zu schneiden, wobei das Schleifen am Umfang des Werkzeugs erfolgt.
- Schruppscheibe: Eine Schruppschleifscheibe ist ein harzgebundenes Werkzeug mit einer Dicke von mehreren Millimetern, das zum Schruppschleifen beziehungsweise zum Schleifen mit grobem Materialabtrag und zum Schleifen von Schweißnähten verwendet wird.
- Fiberscheibe: Eine Fiberscheibe besitzt eine planare, dünne Geometrie und erfordert einen zusätzlichen flexiblen Stützteller. Durch den Stützteller weisen Fiberscheiben eine größere Elastizität auf. Sie ermöglichen einen kostengünstigeren Betrieb, da nur die Fiberscheibe, aber nicht der Stützteller ausgetauscht werden muss.
- Fächerscheibe: Eine Fächerschleifscheibe ist ein Werkzeug, bei der das Schleifmittel fächerförmig auf überlappende Lamellen aufgebracht wird.

Die in dieser Forschungsarbeit verwendeten Werkzeuge haben einen Durchmesser von 125 mm. Dies bedeutet, dass sie bis zu einer Umfangsgeschwindigkeit  $v_u$  von

80 m/s (DIN, 2017; DIN, 2019) und einer Drehzahl von bis zu 11000 min<sup>-1</sup> (Gwosch, 2019) betrieben werden können. Die vier vorgestellten Werkzeuge sind in Abbildung 2.2 dargestellt.



Abbildung 2.2: Vier verschiedene Werkzeug eines Winkelschleifers: Trennscheiben (a), Schruppscheiben (b), Fiberscheiben mit Stützteller (c) und Fächerschleifscheiben (d). (Dörr, Zimprich et al., 2019, S. 2)

Das Werkzeug kann für unterschiedliche Anwendungen eines Winkelschleifers ausgetauscht werden. Nach Gwosch (2019) wird unter einer Anwendung im Kontext von Power-Tools die Aneinanderreihung von Tätigkeiten zur Erfüllung einer Arbeitsaufgabe verstanden. Tätigkeiten können beim Winkelschleifer beispielsweise das Anschalten der Maschine, Halten im Leerlaufbetrieb, Anfasen von Stahl oder Ausschalten der Maschine sein (Gwosch, 2019). Somit beschreiben die Tätigkeiten eine Anwendung auf einem höheren Detaillierungsgrad. Eine Tätigkeit beschreibt im Kontext von Power-Tools eine Handlung oder Aktion, die eine anwendende Person mit einem Power-Tool durchführt.

Die Leistung ist eine relevante Größe zur Charakterisierung des Schleifprozesses (Malkin, 2008). Nach Malkin (2008) korreliert die Schleifleistung  $P$  bei starren Werkstücken bei einer zweidimensionalen Betrachtung über folgende vereinfachte Formel mit der Schleiftangentialkraft  $F_T$  und der Umfangsgeschwindigkeit  $v_u$  des Werkzeugs. Dies zeigt die Bedeutung der Tangentialkraft  $F_T$  und der Umfangsgeschwindigkeit  $v_u$ .

$$P = F_T * v_u \quad 2.1$$

Die Tangentialkraft  $F_T$  beim Schleifen steht über den Reibungskoeffizienten  $\mu$  in direktem Zusammenhang mit der Normalkraft  $F_N$ . Da beim Schleifen in der Regel nur ein Teil der Kontaktfläche geschliffen wird, bestehen die Kräfte aus zwei Komponenten: Eine Komponente beschreibt die Kraftkomponente der Tangentialkraft beziehungsweise der Normalkraft zur Zerspanung mittels Schleifkorn  $F_{T,C} / F_{N,C}$ . Die andere Komponente beschreibt die Kraftkomponente der

Tangentialkraft beziehungsweise der Normalkraft, die beim Gleiten über eine Oberfläche entsteht  $F_{T,Sl} / F_{N,Sl}$ . Nach Malkin (2008) können beide Kräfte und die Beziehung zueinander mit den folgenden Gleichungen beschrieben werden. (Malkin, 2008)

$$F_T = F_{T,C} + F_{T,Sl} \quad 2.2$$

$$F_N = F_{N,C} + F_{N,Sl} \quad 2.3$$

$$F_N = \frac{1}{\mu} F_T + \frac{\mu * F_{N,C} - F_{T,C}}{\mu} \quad 2.4$$

Gleichung 2.4 zeigt, dass ein linearer Zusammenhang zwischen der Tangentialkraft  $F_T$  und der Normalkraft  $F_N$  nur bei einem konstanten Reibungskoeffizienten  $\mu$  sowie konstanten Kraftkomponenten beim Schneiden  $F_{T,C}$  und  $F_{N,C}$  vorliegt. Der Zusammenhang zwischen der Tangentialkraft  $F_T$  und der Normalkraft  $F_N$  hängt somit vom Arbeitspunkt ab. Ein Arbeitspunkt ist ein bestimmter Punkt innerhalb einer Kennlinie oder im Arbeitsbereich eines technischen Systems, beispielsweise ein Optimum auf der Motorkennlinie eines Elektromotors. Beim Schleifprozess wird der Arbeitspunkt beispielsweise durch unterschiedliche geometrische Kontaktflächen aufgrund von Bewegungen der anwendenden Person oder durch Verschleiß des Werkzeugs und damit in Form einer Abnahme der Kraftkomponente zur Zerspanung mittels Schleifkorn beeinflusst. Die Umformung von Gleichung 2.4 und das Einsetzen in Gleichung 2.1 führt zu folgender Gleichung:

$$P = v_u * (\mu * (F_N - F_{N,C}) + F_{T,C}) \quad 2.5$$

Dies zeigt, dass die Schleifleistung  $P$  von der Umfangsgeschwindigkeit  $v_u$ , dem Reibungskoeffizienten  $\mu$ , der Normalkraft  $F_N$ , der Kraftkomponente der Normalkraft zur Zerspanung mittels Schleifkorn  $F_{N,C}$  und der Kraftkomponente der Tangentialkraft zur Zerspanung mittels Schleifkorn  $F_{T,C}$  abhängig ist. Diese Größen haben daher einen Einfluss auf die Konstanz des Schleifprozesses. Bei größeren Abweichungen im Verhalten des Schleifprozesses ist es für eine Untersuchung zweckmäßig, den Schleifprozess in einzelne Arbeitspunkte zu unterteilen.

Es gibt für den Schleifprozess zahlreiche Modelle, die die Zusammenhänge zwischen den Kräften und der Energie mit anderen Größen beschreiben. (Tönshoff, Peters, Inasaki & Paul, 1992) fassen die Zusammenhänge aus bestehenden Modellen im Stand der Forschung in folgender Abbildung zusammen.

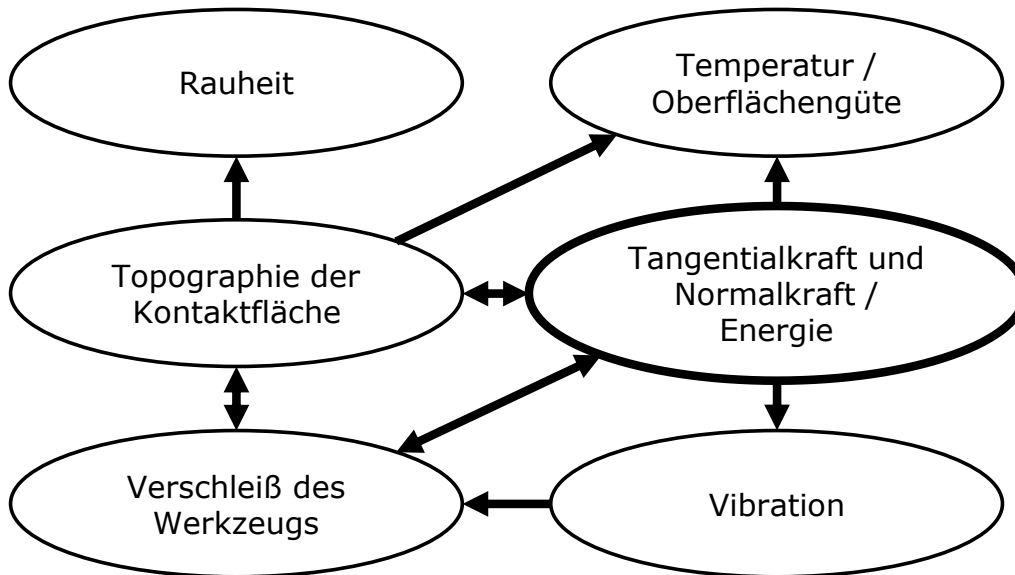


Abbildung 2.3: Zusammenhänge beim Schleifen zwischen den Kräften und der Energie mit anderen relevanten Größen. In Anlehnung an Tönshoff et al. (1992, S. 678)

Für Power-Tools besteht eine maschinenspezifische Abhängigkeit zwischen dem Lastmoment und der Umfangsgeschwindigkeit  $v_u$  über die Motorkennlinie des Elektromotors. Das Lastmoment lässt sich wiederum auf die Tangentialkraft  $F_T$  und über den Reibungskoeffizienten  $\mu$ , unter Vernachlässigung der Kraftkomponenten für die Zerspanung mittels Schleifkorn  $F_{N,C} / F_{T,C}$ , auf die Normalkraft  $F_N$  zurückführen. Das bedeutet, dass für die maschinenspezifische Analyse des Schleifprozesses die Betrachtung der Drehzahl oder der Normalkraft aufgrund der Zusammenhänge in der Regel ausreichend ist. Sollen jedoch übertragbare Erkenntnisse über eine Maschine hinaus gewonnen werden, so müssen Drehzahl und Normalkraft unabhängig voneinander betrachtet werden.

## 2.1.2 Grundlagen zum Machine-Learning mit überwachten Lernverfahren

Beim Machine-Learning wird ein statistisches Modell parametrisiert und gegebenenfalls parametrisiert, um mithilfe des Modells eine Vorhersage<sup>1</sup> für neue, dem Modell unbekannte Werte zu treffen. In Abhängigkeit des statistischen Modells wird dieses Modell beim Machine-Learning parametrisiert und parametrisiert oder nur parametrisiert (Murphy, 2013). Da in den meisten, in dieser Forschungsarbeit verwendeten Modellen nur eine Parametrisierung stattfindet, wird im Folgenden nur der Begriff Parametrisierung verwendet. Die Annotation in diesem Kapitel erfolgt durch Großbuchstaben wie  $X$  für eine Zufallsvariable, durch Kleinbuchstaben wie  $x$  für den Wert der Variablen und durch fettgedruckte Buchstaben für Vektoren.

In dieser Forschungsarbeit werden für das Machine-Learning nur überwachte Lernverfahren verwendet. Bei der Parametrisierung kann zwischen der eigentlichen Parametrisierung durch das überwachte Lernverfahren und der Parametrisierung vor dem Einsatz dieses Verfahrens unterschieden werden. Die vor dem Einsatz überwachter Lernverfahren definierten Parameter werden als Hyperparameter bezeichnet (Murphy, 2013). Diese werden manuell definiert oder automatisch durch eine sogenannte Hyperparameteroptimierung festgelegt.

Die Parametrisierung mittels Machine-Learning erfolgt anhand eines Trainingsdatensatzes, bei dem die abhängige Variable bekannt ist. Ein Trainingsdatensatz besteht aus  $N$  unabhängigen Variablen, bezeichnet als  $\mathbf{X} = [x_1, x_2, \dots, x_N]^T$ . Diese werden verwendet, um die Werte eines statistischen Modells so einzustellen, dass daraus die Vorhersage einer abhängigen Variable  $Y = [y_1, y_2, \dots, y_N]^T$  erfolgt. Das mathematische Ziel bei der Erstellung eines statistischen Modells bei der Parametrisierung ist die Schätzung der mathematischen Beziehung  $f()$  durch einen Vektor  $\boldsymbol{\beta}$ , um eine abhängige Variable  $Y$  anhand von unabhängigen Variablen  $\mathbf{X}$  vorherzusagen.

$$Y = f(\mathbf{X}, \boldsymbol{\beta}) \quad 2.6$$

Die Fähigkeit eines Modells, abhängige Variablen basierend auf bisher unbekanntem Wertkombinationen der unabhängigen Variablen korrekt

---

<sup>1</sup> Im Rahmen dieser Arbeit wird der Begriff *Vorhersage* verwendet, da dieser beim Einsatz des Machine Learning üblich ist. In der Statistik ist der Begriff *Prognose* üblich.

vorherzusagen, wird als Generalisierung bezeichnet (Bishop, 2009). In praktischen Anwendungen bildet ein Trainingsdatensatz aufgrund der Variabilität der unabhängigen Variablen meist nur einen kleinen Teil aller möglichen Daten ab. In der manuellen Fertigung zum Beispiel sind aufgrund der Einbeziehung von Menschen in die Datenerfassung kleine Datensätze mit großen Streuungen üblich, bei denen die abhängige Variable ungleichmäßig verteilt ist (Lee et al., 2021). Eine Herausforderung besteht in der Generalisierung auf einer begrenzten Datenmenge mit großen Streuung (Bishop, 2009). Damit ist eine gute Generalisierung des statistischen Modells das übergeordnete Ziel der Parametrierung mittels Machine-Learning (Bishop, 2009).

Weisen die Werte der abhängigen Variable eine ungleichmäßige Verteilung auf, muss für die Bewertung der Generalisierung die Verteilung der Werte der abhängigen Variable im Trainingsdatensatz berücksichtigt werden. Um diese Störgröße bei der Bewertung der Generalisierung zu eliminieren, ist es sinnvoll, dass die Werte der abhängigen Variable im Trainingsdatensatz gleichmäßig verteilt sind. (Murphy, 2013)

Um die Generalisierung eines statistischen Modells zu bewerten, wird ein Teil der verfügbaren Datensätze nicht für die Parametrierung verwendet, sondern als Validierungsdatensatz zurückbehalten. Dieser wird zur Bewertung der Generalisierung und damit zur Validierung des statistischen Modells verwendet. Um möglichst gut generalisierbare Modelle zu erstellen, ist es zielführend, möglichst viele der verfügbaren Daten als Trainingsdatensatz zu verwenden. Wenn der Validierungsdatensatz jedoch zu klein ist, ist die Bewertung der Generalisierung unsicherheitsbehaftet. Eine Lösung für dieses Dilemma ist die Verwendung der Kreuzvalidierung (CV). Bei der  $k$ -fachen Kreuzvalidierung, die in Abbildung 2.4 für den Fall von  $k = 5$  dargestellt ist, werden alle verfügbaren Daten in  $k$  Gruppen aufgeteilt. Weiter werden  $k-1$  der Gruppen verwendet, um das Modell zu parametrieren, das anschließend an der verbleibenden Gruppe validiert wird. Dieser Vorgang wird  $k$ -mal wiederholt. Die Ergebnisse der einzelnen Gruppen werden gemittelt. Die Zuordnung von Daten zu Gruppen erfolgt in der Regel nach dem Zufallsprinzip, ist aber auch durch Domänenwissen über das zu untersuchende System möglich. (Bishop, 2009)



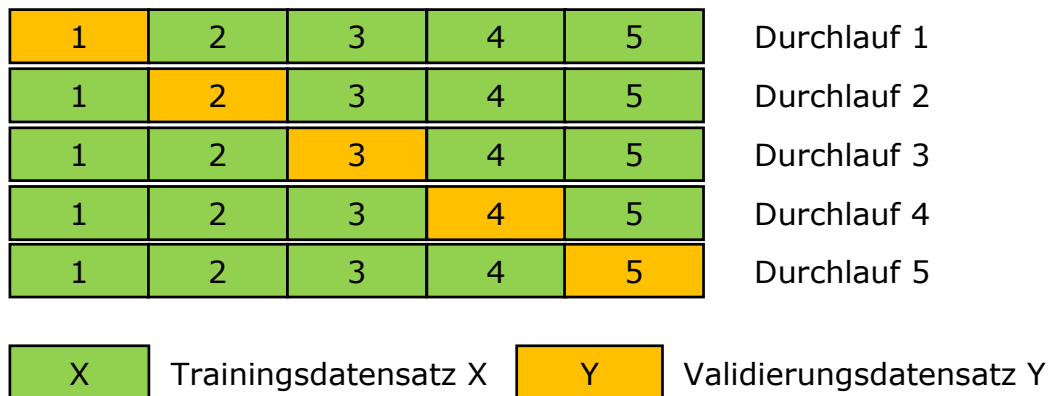


Abbildung 2.4: Trainings- und Validierungsdatensätze beim Verfahren Kreuzvalidierung zur Validierung eines statistischen Modells am Beispiel von  $k = 5$  Durchläufen. In Anlehnung an Bishop (2009, S. 33)

In den meisten praktischen Anwendungen werden die unabhängigen Variablen vorverarbeitet, indem sie in einen neuen Variablenraum transformiert werden, um das Ziel der Generalisierung des statistischen Modells leichter zu erreichen (Bishop, 2009). Diese Transformation wird als Merkmalsextraktion bezeichnet. Die unabhängigen Variablen im neuen transformierten Vektor werden als Merkmale bezeichnet. Ein Merkmal eines Winkelschleifers ist zum Beispiel der Durchschnittswert der Stromaufnahme, der ein Indikator für die aufgebrachte Leistung ist. Für die Merkmalsextraktion ist Domänenwissen über das zu untersuchende System von großer Bedeutung. Wenn zahlreiche Merkmale vorliegen oder die Menge an verfügbaren Daten beschränkt ist, kann der Ansatz der Merkmalsselektion verwendet werden. Dabei wird die Anzahl der Merkmale reduziert. Im Rahmen dieser Forschungsarbeit werden nur filterbasierte Ansätze zur Merkmalsselektion verwendet. Filterbasiert bedeutet für die Merkmalsselektion, dass die Merkmale unabhängig vom verwendeten statistischen Modell anhand eines statistischen Werts selektiert werden.

Beim überwachten Lernen wird zwischen Klassifikation und Regression unterschieden. Bei der Klassifikation besteht die abhängige Variable aus diskreten Kategorien. Eine relevante Bewertungsgröße bei der Klassifikation ist die Genauigkeit. Diese eignet sich vor allem bei gleich verteilten abhängigen Variablen. Die Genauigkeit beschreibt den Anteil der richtigen Vorhersagen des Modells aus der Anzahl der unabhängigen Variablen  $N$  und wird durch die folgende Formel dargestellt.

$$\text{Genauigkeit} = \frac{\text{Anzahl richtiger Vorhersagen}}{N} \quad 2.7$$

Bei der Regression ist die abhängige Variable ein kontinuierlicher Wert. Im Rahmen dieser Forschungsarbeit werden drei Bewertungsgrößen für die Bewertung der Leistung eines statistischen Modells zur Regression verwendet: Der mittlere absolute Fehler (*MAE*), der relative *MAE* (*rMAE*) und der Pearson-Korrelationskoeffizient (*r*). Der *MAE* beschreibt die durchschnittliche Abweichung des mit dem statistischen Modell vorhergesagten Werts vom tatsächlichen Wert der abhängigen Variablen. Der *rMAE* beschreibt im Vergleich zum *MAE* die dimensionslose relative Abweichung. Der Pearson-Korrelationskoeffizient (*r*) ist ein Maß für die lineare Korrelation zwischen dem mit dem statistischen Modell vorhergesagten Wert und dem tatsächlichen Wert der abhängigen Variablen. *r* kann Werte zwischen -1 und 1 annehmen. Die drei Bewertungsgrößen werden mit den folgenden Formeln ausgedrückt.

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad 2.8$$

$$rMAE = \frac{\frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i|}{\bar{y}} \quad 2.9$$

$$r = \sqrt{\frac{\sum_{i=1}^N (y_i - \bar{y})^2 - \sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad 2.10$$

## 2.2 Ansätze zur Erfassung von Informationen zur Produktnutzung von Power-Tools

Ziel dieses Kapitels ist die Eingrenzung der Forschungsarbeit auf die unbeobachtete und skalierbare Erfassung von PUI in der Nutzungsphase bestehender Produktgenerationen mittels Sensordaten. Daher wird in diesem Kapitel zunächst die Charakterisierung der Produktnutzung mittels PUI für die Produktentwicklung von Power-Tools beleuchtet. Es folgt eine Betrachtung der Detailstufen von PUI. Daraufhin werden Quellen vorgestellt, aus denen PUI erfasst werden können. Abschließend werden Anforderungen an die Erfassung von PUI aus den Randbedingungen des Produktlebenszyklus abgeleitet.

## 2.2.1 Charakterisierung der Produktnutzung

Nach Ram & Jung (1990) kann die Nutzung eines Produkts in die Nutzungsfrequenz und die Art der Nutzung eingeteilt werden. Während die Nutzungsfrequenz Auskunft darüber gibt, wie häufig ein Produkt verwendet wird, bezieht sich die Art der Nutzung auf die verschiedenen Anwendungen und Situationen, für die ein Produkt verwendet wird, unabhängig davon, wie häufig es genutzt wird (Ram & Jung, 1990). Beverungen et al. (2019) unterscheiden Daten für Produkte in Nutzungsdaten, Kontextdaten und Zustandsdaten.

- Nutzungsdaten beschreiben, wie ein Produkt verwendet wird, beispielsweise durch Beschreibung der durchgeführten Tätigkeiten (Beverungen et al., 2019).
- Kontextdaten beziehen sich auf den Kontext eines Produkts. Kontext kann als jede Information definiert werden, die zur Charakterisierung der Situation eines Produkts verwendet werden kann (Abowd et al., 1999).
- Zustandsdaten beziehen sich auf den Zustand und die Funktionsfähigkeit des Produkts, die Aufschluss über Instandhaltungsmaßnahmen geben können (Beverungen et al., 2019).

Diese Aspekte können als PUI zusammengeführt werden. PUI beschreiben alle einem Produkt zugeordneten Informationen, die aus der Nutzungsphase zurück in die Produktentwicklung fließen (Fathi & Holland, 2009). Somit umfassen PUI Nutzungs-, Kontext- und Zustandsdaten. PUI bilden einen bedeutsamen Bestandteil des Wissens, das zur Konstruktion in der Produktentwicklung benötigt wird (van Horn & Lewis, 2015). Daher werden in den folgenden Absätzen drei Ansätze zur Charakterisierung der PUI vorgestellt. Verwendete Detailstufen werden kursiv dargestellt.

Voet et al. (2019) stellen ein Framework zur Erfassung und Analyse von PUI vor. In diesem Framework werden die PUI mit einem *Nutzungsprofil* charakterisiert. Das *Nutzungsprofil* beschreibt die relevanten Aspekte auf der Grundlage zuvor definierter Ziele und von Wissen über das untersuchte System und seine Interaktion. Ein *Nutzungsprofil* kann verschiedene *Nutzungselemente* enthalten. Jedes *Nutzungselement* erweitert das im *Nutzungsprofil* enthaltene Wissen. In dem beschriebenen Framework sind Nutzungselemente einzelne Tätigkeiten oder Parameter, die von integrierten Sensoren eines Systems erfasst werden. Für den Inhalt der *Nutzungselemente* werden mögliche *Zustände* definiert. In Abbildung 2.5 ist das Framework dargestellt. Anhand der charakterisierten PUI werden Sensoren und Algorithmen definiert. Das Vorgehen ermöglicht den Aufbau von Wissen für die Produktentwicklung zur Verbesserung eines Produkts. (Voet et al., 2019)

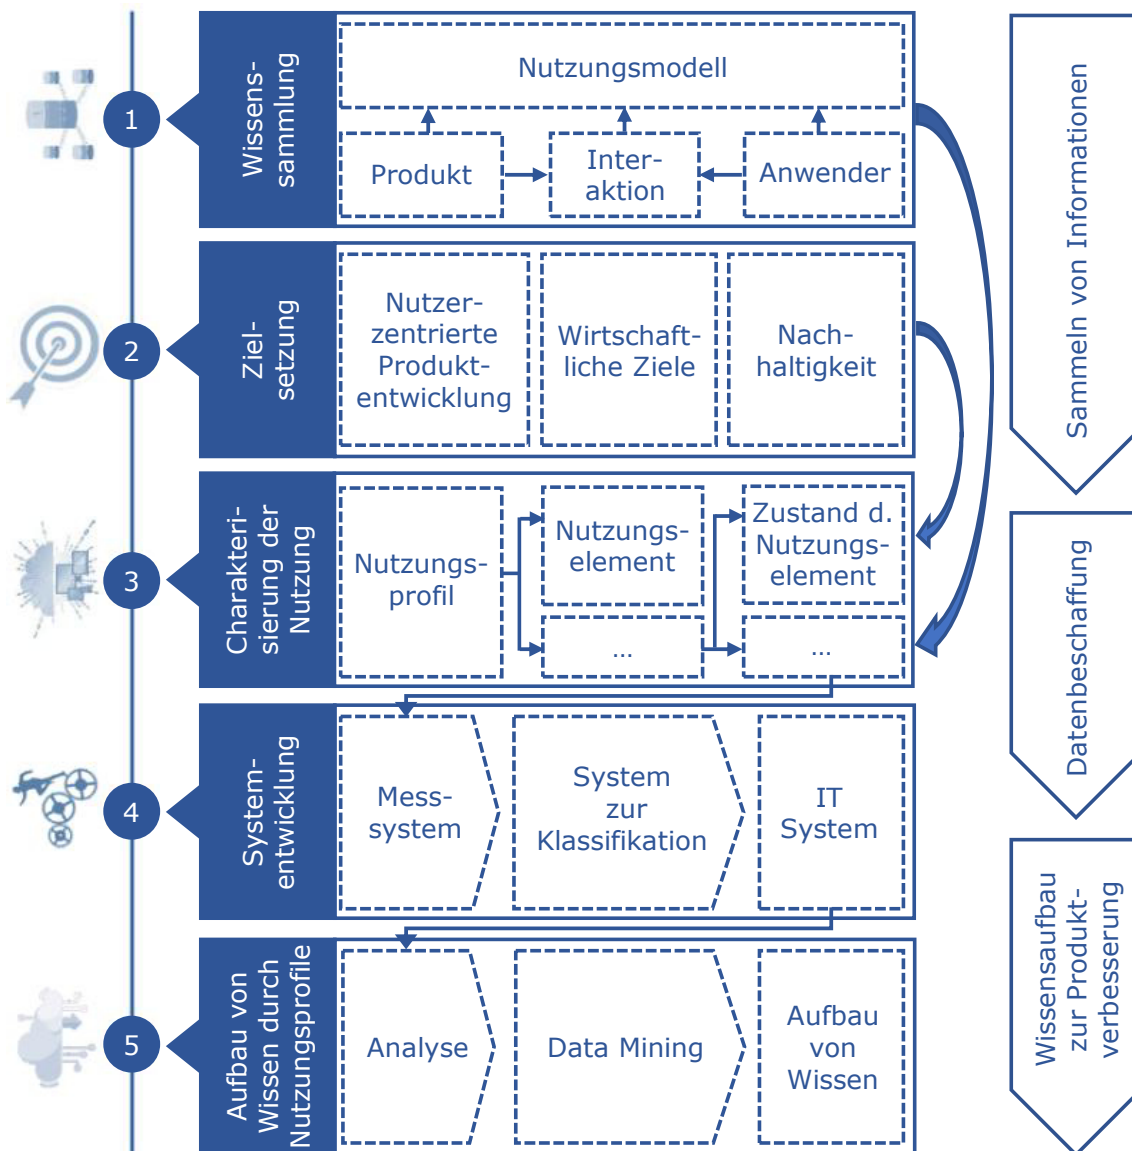


Abbildung 2.5: Framework von Voet et al. (2019) zur Generierung von Wissen zur Produktverbesserung aus mit Sensoren und Algorithmen erfassten Nutzungselementen. In Anlehnung an Voet et al. (2019, S. 4)

Voet et al. (2019) nutzen als Beispiel zur Charakterisierung der Produktnutzung einen Geradschleifer und erfassen dabei folgende vier *Nutzungselemente*:

- die Zeitpunkte, in denen sich das Werkzeug in Kontakt mit dem Werkstück befindet,
- die Drehzahl während des Schleifvorgangs,
- die Andruckkraft, die die anwendende Person beim Schleifen auf das Werkstück ausübt und

- das Material des bearbeiteten Werkstücks.

Deng & Thoben (2022) charakterisieren die Produktnutzung mit PUI in mehreren Detailstufen. Dabei nutzen sie auf der obersten Abstraktionsebene ebenfalls ein *Nutzungsprofil*. Innerhalb des *Nutzungsprofils* stellen *Nutzungsaspekte* jeweils einen einzelnen Aspekt der Produktnutzung dar, der für die Produktentwicklung relevant ist. Ein *Nutzungsaspekt* wird weiterhin unterteilt in *Nutzungsobjekte* als Informationseinheiten eines *Nutzungsaspekts*, die eine Menge von Parametern oder Tätigkeiten im Sinne der Informatik enthalten. Die unterste Detailstufe besteht aus *Nutzungsvariablen*, die einzelne Parameter und damit den Inhalt eines *Nutzungsobjekts* repräsentieren. Die Charakterisierung nach Deng & Thoben (2022) ist in Abbildung 2.6 visualisiert. (Deng & Thoben, 2022)

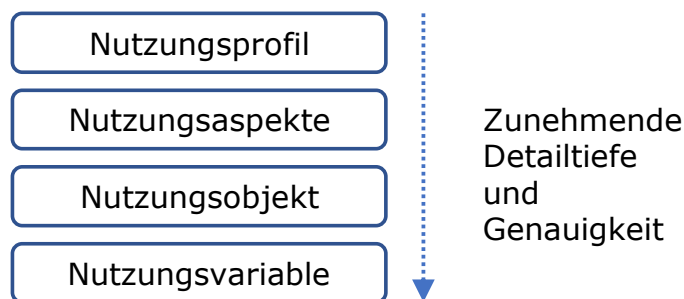


Abbildung 2.6: Charakterisierung der Produktnutzung mit Informationen zur Produktnutzung in vier Detailstufen nach Deng & Thoben (2022). In Anlehnung an Deng & Thoben (2022, S. 10)

Schmidt (2019) stellt eine Methodik vor, um PUI von Power-Tools aus der gemessenen oder beobachteten Anwendung zu erfassen. Innerhalb der Methodik stellt die Generalisierung der *messtechnisch erfassten Produktnutzung* eine Aktivität dar. Dazu werden Messdaten anhand von *Clusterkriterien* in zeitliche Abschnitte unterteilt, die zu *Tätigkeiten* zusammengefasst werden. Schmidt (2019) nennt folgende *Clusterkriterien* einschließlich möglicher Ausprägungen als Beispiele zur Charakterisierung der *messtechnisch erfassten Produktnutzung* für das Schleifen mit einem Winkelschleifer:

- die Körperhaltung (stehend, sitzend, liegend, Arbeiten in Brusthöhe, am Boden oder über Kopf sowie bestimmte Gelenkwinkel),
- das verwendete Werkzeug (Trennscheibe, Schleifscheibe, Schruppscheibe, Fächerscheibe oder Polierscheibe),
- die Arbeitsweise (Schleifen, Trennen, Schruppen oder Polieren) oder
- interne Gerätedaten (Leistungsaufnahme, Drehmoment oder Drehzahl).

Das Vorgehen von Schmidt (2019) zur Ableitung von *Tätigkeiten* aus der *messtechnisch erfassten Produktnutzung* innerhalb seiner Methodik ist in Abbildung 2.7 dargestellt.

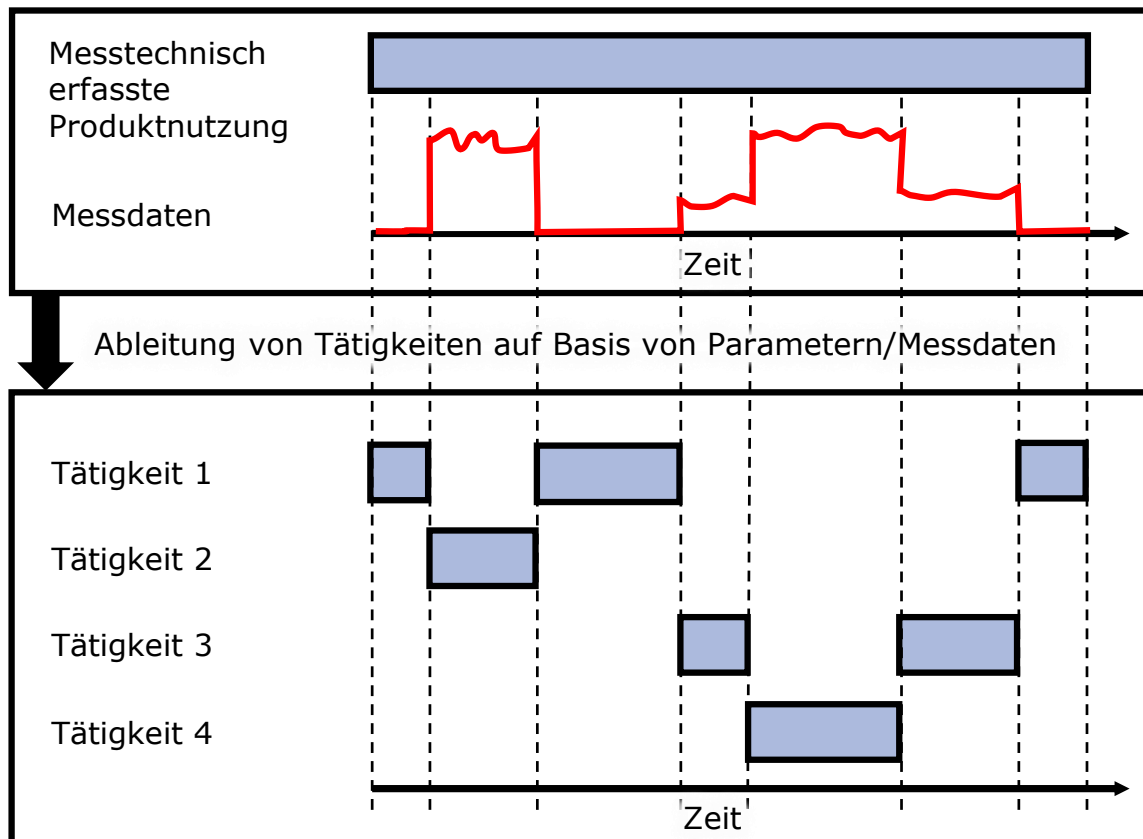


Abbildung 2.7: Vorgehen von Schmidt (2019) zur Ableitung von Tätigkeiten aus der messtechnisch erfassten Produktnutzung anhand definierter Clusterkriterien. In Anlehnung an Schmidt (2019, S. 149)

Die drei Ansätze zur Charakterisierung der Produktnutzung teilen die Eigenschaft, dass die PUI auf verschiedenen Detailstufen beschrieben werden. Zudem werden die PUI bis auf einzelne Parameter oder Zustände heruntergebrochen, die quantitativ oder qualitativ beschrieben werden. Deng & Thoben (2022) verwenden mit dem *Nutzungsaspekt* und *Nutzungsobjekt* zwei Detailstufen zwischen dem übergeordneten *Nutzungsprofil* und der spezifischen *Nutzungsvariable*. Voet et al. (2019) etablieren mit dem *Nutzungselement* eine Detailstufe zwischen dem übergeordneten *Nutzungsprofil* und dem spezifischen *Zustand des Nutzungselements*. Schmidt (2019) nutzt *Tätigkeiten*, die gemeinsam die Produktnutzung beschreiben, als Detailstufe zwischen der übergeordneten *messtechnisch erfassten Produktnutzung* und den spezifischen *Clusterkriterien*. Die *Tätigkeiten* werden aus Messdaten retrospektiv zusammengeführt.

Voet et al. (2019) und Schmidt (2019) nutzen für ihre Charakterisierung der Produktnutzung das Beispiel Schleifen mit Power-Tools. Dies zeigt, dass eine Detailstufe zur Charakterisierung für das Schleifen mit Power-Tools ausreichend ist. Daher wird für diese Forschungsarbeit eine äquivalente Detaillierung verwendet. Die Produktnutzung wird mit PUI durch *Nutzungselemente* mit qualitativen und quantitativen *Zuständen* nach Voet et al. (2019) charakterisiert. Der Umfang an möglichen *Nutzungselementen* macht eine Fokussierung auf relevante *Nutzungselemente* und *Zustände* notwendig.

Zusammenfassend wird die Produktnutzung mittels PUI beschrieben. PUI beinhalten alle einem Produkt zugeordneten Informationen, die aus der Nutzungsphase zurück in die Produktentwicklung fließen. Die PUI werden im Rahmen dieser Forschungsarbeit in *Nutzungselemente* detailliert. Für die *Nutzungselemente* werden spezifische *Zustände* definiert.

## **2.2.2 Datenquellen zur Erfassung von Informationen zur Produktnutzung**

PUI können aus unterschiedlichen Datenquellen erfasst werden. Ein Beispiel mit großem Potenzial für die Produktentwicklung ist die Erfassung von Kundenmeinungen durch beschreibungsbasierte Text-Mining-Methoden aus Online-Bewertungen (Jin et al., 2019). Ein weiteres Beispiel ist die Erfassung von PUI aus Sensordaten während der Produktnutzung (van Horn & Lewis, 2015). Erfasste Sensordaten können direkt Nutzungselementen zugeordnet werden, zum Beispiel bei der quantitativen Andruckkraft einer anwendenden Person (Voet et al., 2019). Alternativ können Nutzungselemente aus Sensordaten abgeleitet werden, wie beispielsweise zur Erfassung der durchgeführten Tätigkeit (Schmidt, 2019) oder zur Erfassung des bearbeiteten Werkstücks (Voet et al., 2019).

Die Erfassung von PUI mittels Sensoren wurde durch die Miniaturisierung von Sensoren und durch Fortschritte in der Informationstechnologie erleichtert (Abramovici et al., 2009). Nach Jun et al. (2009) können in ein Produkt eingebettete Informationsmodule (PEID) in vier Kategorien eingeteilt werden:

- PEID als 1-Bit-Transponder (Typ A),
- PEID des passiven oder semi-passiven Typs mit Speicher (Typ B),
- PEID des aktiven Typs mit Sensor, Speicher, Mikroprozessor und Modul zur Energieversorgung (Typ C) oder
- PEID als Modul für smarte Produkte mit Sensor, Speicher, Mikroprozessor, Modul zur Energieversorgung und Kommunikationsmodul (Typ D).

Im Rahmen dieser Forschungsarbeit werden Systeme des Typs C oder D als PEID bezeichnet, die mindestens einen Sensor, einen Mikroprozessor, eine Speichereinheit und ein Modul zur Energieversorgung, wie eine Batterie, enthalten. Somit ermöglichen PEID die Erfassung, Verarbeitung und Speicherung von Sensordaten (Jun et al., 2009). Eine Verwendung eines PEID ist sowohl auf Gesamtsystemebene (Kiritsis, 2011) als auch auf Teilsystem- und Komponentenebene, beispielsweise in Maschinenelementen (Vorwerk-Handing et al., 2020), möglich. Methodische Ansätze zur strukturierten Bereitstellung von PUI in der Produktentwicklung über eine Benutzerschnittstelle wurden beispielsweise durch Abramovici & Lindner (2011) untersucht.

Nach Bertoni (2020) ist eine vertretene Auffassung im Stand der Forschung, dass aus Sicht der datengetriebenen Produktentwicklung bereits viele Daten zur Ableitung von PUI vorhanden sind und nur noch die Frage offen ist, wie diese genutzt werden können. Um dies weiter zu untersuchen, führte Bertoni (2020) eine systematische Literaturrecherche durch, bei der 32 Publikationen zur Bedarfsermittlung während der Konzeptphase in der datengetriebenen Produktentwicklung aus insgesamt 591 Publikationen selektiert wurden. In den Publikationen wurde untersucht, welche Datenquellen in den verschiedenen Phasen der datengetriebenen Produktentwicklung genutzt wurden. Die Datenquellen zur Bedarfsermittlung wurden von Bertoni (2020) geclustert und sind in Abbildung 2.8 dargestellt. (Bertoni, 2020)





Abbildung 2.8: Datenquellen zur Bedarfsermittlung in der Konzeptphase der datengetriebenen Produktentwicklung. In Anlehnung an Bertoni (2020, S. 105)

Die Recherche von Bertoni (2020) ergab zudem eine überwiegende Verwendung von Text-Mining-Methoden (19 von insgesamt 32), die auf soziale Medien und Online-Rezensionen (17 von insgesamt 32) angewandt wurden. Insgesamt wurden kaum Sensordaten verwendet. Bertoni (2020) kommt auf der Grundlage seiner Untersuchungen zu dem Schluss, dass die Ansicht falsch sei, es würden aufgrund der zunehmenden Verbreitung von PEID bereits viele Sensordaten als PUI in der datengetriebenen Produktentwicklung genutzt. Dies führt für Bertoni (2020) zur Notwendigkeit, Methoden und Ansätze zur Erfassung und Analyse von PUI aus Sensordaten zu entwerfen, anstatt bereits verfügbare Sensordaten zu verwenden. (Bertoni, 2020)

Die seltene Verwendung von Sensordaten in wissenschaftlichen Publikationen im Bereich der datengetriebenen Produktentwicklung zeigt den Bedarf an Ansätzen zur Erfassung von PUI mittels Sensordaten. Auch die Bildung von Simulationsmodellen zur Generierung synthetischer Sensordaten, beispielweise durch van Horn & Lewis (2015), zeigt den Bedarf. Nach Deng et al. (2021) stellt die Erfassung und Aufbereitung von PUI eine Herausforderung dar, insbesondere wenn keine bestehenden Datenströme genutzt werden können.

Ob und mit welchem Erfolg bereits Sensordaten zur Ableitung von PUI gesammelt werden können, hängt vom Produkt und den Randbedingungen ab. So eignen sich Produkte mit einem oder mehreren PEID gut für die Erfassung von PUI, da bereits Sensordaten zur Bestimmung des Kontexts vorliegen und somit die Ableitung weiterer PUI vereinfacht wird. Zudem erfordert die Erfassung neuer Sensordaten bei vorhandener Infrastruktur durch einen PEID einen geringeren zusätzlichen Aufwand (Holler et al., 2016). Auch begünstigen homogene und standardisierte Gesamtsysteme einschließlich der Umgebung die erfolgreiche Erfassung von PUI, da der Daten- und Informationsaustausch vereinfacht wird (Holler et al., 2016). Beispielweise können im Automobilbereich (Heinrich, 2016) und bei Arbeitsmaschinen (Eckstein, 2017) unkomplizierter als bei Power-Tools neue Sensordaten erhoben werden, da die Infrastruktur durch vorhandene PEID in Form von Steuergeräten schon gegeben ist. Bei Power-Tools besteht aufgrund der Vielfalt an unterschiedlichen Umgebungen, einer im Vergleich zum Automobilbereich geringen Dichte an Sensoren und PEID noch Bedarf für Ansätze und Methoden zur Erfassung von PUI.

Zusammenfassend können Sensordaten als Datenquelle zur Ableitung von PUI für die Produktentwicklung dienen. Aufgrund des Bedarfs an Ansätzen zur Erfassung von PUI mittels Sensordaten bei Power-Tools wird die Erfassung von PUI für diese Forschungsarbeit auf Sensordaten eingegrenzt. Ob und mit welchem Erfolg bereits Sensordaten zur Ableitung von PUI gesammelt werden können, hängt von dem Produkt und den Randbedingungen ab. Daher werden in Kapitel 2.2.3 Anforderungen an messtechnische Erfassung abgeleitet und in Kapitel 2.3 die messtechnische Erfassung bei Power-Tools vorgestellt.

### **2.2.3 Anforderungen an messtechnische Erfassung von Informationen zur Produktnutzung**

Der Zeitpunkt, zu dem PUI erfasst werden, lässt sich anhand des Produktlebenszyklus einordnen. Eine grobe Einteilung des Produktlebenszyklus erfolgt in drei aufeinanderfolgende Phasen, wobei die Produktentwicklung in der ersten Phase stattfindet. Die Produktentwicklung liefert Informationen für die Nutzungs- und Endphase des Produkts und enthält Informationen aus der Nutzungs- und Endphase, wie in Abbildung 2.9 dargestellt. (Wellsandt et al., 2015)

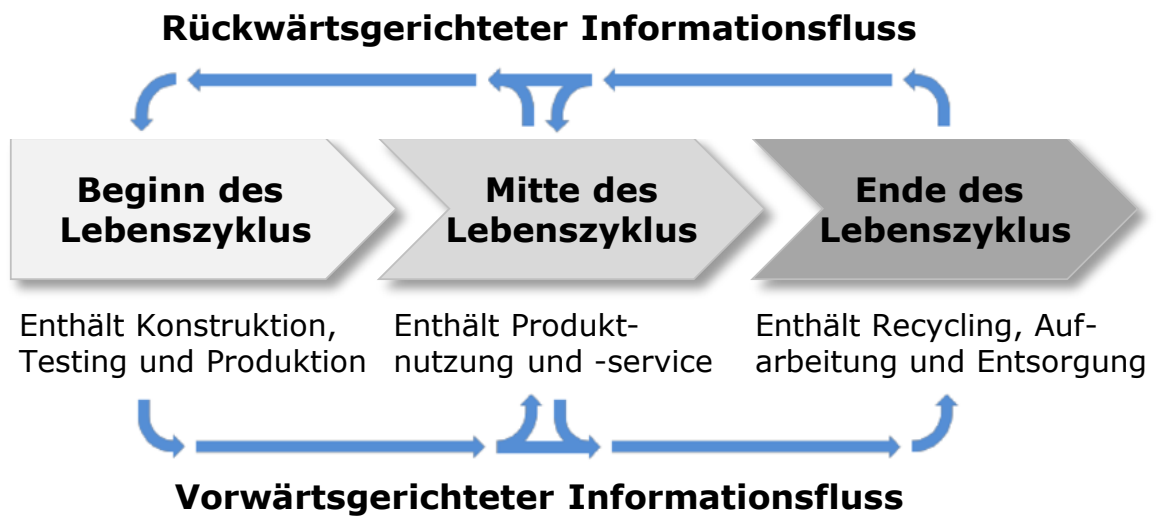


Abbildung 2.9: Vorwärts- und rückwärtsgerichteter Informationsfluss im Produktlebenszyklus. In Anlehnung an Wellsandt et al. (2015, S. 243)

Um die bei der Nutzung gewonnenen Informationen in die Synthese der Gestalt eines Produkts einfließen lassen zu können, ist ein Informationsrückfluss erforderlich (Ehrlenspiel & Meerkamm, 2017; Wynn & Maier, 2022). Dabei unterscheiden Ehrlenspiel & Meerkamm (2017) kurze Regelkreise, die meist innerhalb der Produktentwicklung stattfinden, und lange Regelkreise, wie die Rückkopplung aus der Nutzungsphase des Produkts.

Bei Betrachtung eines Entwicklungsprozesses eines einzelnen Produkts ist es zielführend, die Regelkreise möglichst kurz zu halten, um schnell und iterativ Erkenntnisse zu erzielen. Dazu werden verschiedene Aktivitäten innerhalb der Produktentwicklung unternommen. Bei Power-Tools kann die Produktnutzung beispielsweise in Anwendungsanalysen in der realen Anwendungsumgebung und in manuellen Tests in einer Laborumgebung erfasst werden (Gwosch, 2019). Beide Fälle werden im Rahmen dieser Forschungsarbeit als beobachtete Probandenstudien während der Produktentwicklung charakterisiert.

Schmidt (2019) entwickelte Methoden zur messtechnischen Erfassung von Informationen zur Produktnutzung bei Power-Tools in beobachteten Probandenstudien. Dazu werden Kameras in Verbindung mit verschiedenen Sensoren eingesetzt. Dabei finden eine durchgehende Beobachtung der anwendenden Person während der Messung und eine manuelle Analyse der Messdaten statt, was einen hohen Aufwand erzeugt (Schmidt, 2019). Der Aufwand zur Erfassung der Produktnutzung in einer Probandenstudie ist nur bei kleiner Probandenzahl vertretbar (Deng et al., 2019). Für Probandenstudien schlägt Schmidt (2019) vor, dass die Erfassung der Produktnutzung aus den Messdaten

softwarebasiert und teilautomatisiert erfolgen sollte, beispielsweise mit dem Ansatz des Machine-Learnings, um der Herausforderung der Aufwandsreduzierung zu begegnen.

Für die Unterstützung der Konstruktion in der datengetriebenen Produktentwicklung sind große Datenmengen vorteilhaft. Bei Probandenstudien ist der Aufwand nur vertretbar, wenn die Anzahl der Probanden gering ist (Deng et al., 2019). Stattdessen sollte die Erfassung von PUI aus Sensordaten aufgrund des Aufwands skalierbar und nicht manuell erfolgen (Ghosh et al., 2018). Für die Messung von menschlichem Verhalten im Bereich der Psychologie wird eine Skalierung sowohl hinsichtlich einer größeren Anzahl von zu untersuchenden Personen als auch hinsichtlich einer schnelleren Messung angestrebt (Germine et al., 2021). Ghosh et al. (2017) beziehen die Skalierbarkeit bei der Erfassung von PUI auf die Anzahl von zu untersuchenden Personen. Unter skalierbarer Erfassung im Kontext der messtechnischen Erfassung von PUI wird verstanden, dass diese bei zusätzlichen anwendenden Personen mit geringem Aufwand verbunden ist.

Die Erfassung von PUI aus Sensordaten in der Nutzungsphase ist in der Regel durch eine unbeobachtete Erfassung gekennzeichnet. Unbeobachtete Erfassung von PUI bedeutet im Rahmen dieser Forschungsarbeit, dass der Kontext nur durch Kontextdaten geschaffen wird. Im Gegensatz dazu stehen Probandenstudien, bei denen der Kontext beispielsweise durch Fragebögen erhoben oder durch das Versuchsdesign geschaffen wird.

Wird die Betrachtung eines einzelnen Produktlebenszyklus aus Abbildung 2.9 auf mehrere Produktgenerationen erweitert, ergibt sich eine weitere Möglichkeit der Informationsrückführung aus der Nutzungsphase. Anstatt PUI erst nach der Markteinführung in die Produktentwicklung zurückfließen zu lassen, können PUI aus bereits auf dem Markt befindlichen Produktgenerationen in die Produktentwicklung einer neuen Produktgeneration einfließen. Dies bietet den Vorteil, dass die Rückkopplung aus der Nutzungsphase keinen langen Regelkreis mehr bildet. Die Verkürzung des Regelkreises der Informationsrückführung wird durch den Prozess der technischen Vererbung nach Lachmayer et al. (2014) veranschaulicht, der in Abbildung 2.10 dargestellt ist. Dabei werden datengetriebene Ansätze zur Erfassung von PUI verwendet, um die Produktentwicklung neuer Generationen auf der Grundlage der PUI zu unterstützen (Lachmayer et al., 2014). Dieser Prozess ist Teil der Ergebnisse des Sonderforschungsbereichs 653 mit dem Titel „Gentelligente Bauteile im Lebenszyklus – Nutzung vererbbarer, bauteilinhärenter Informationen in der Produktionstechnik“, der sich mit kommunikationsfähigen sensorintegrierten Bauteilen sowie der Überführung gesammelter Informationen zur Verbesserung der nächsten Produktgeneration beschäftigt hat.

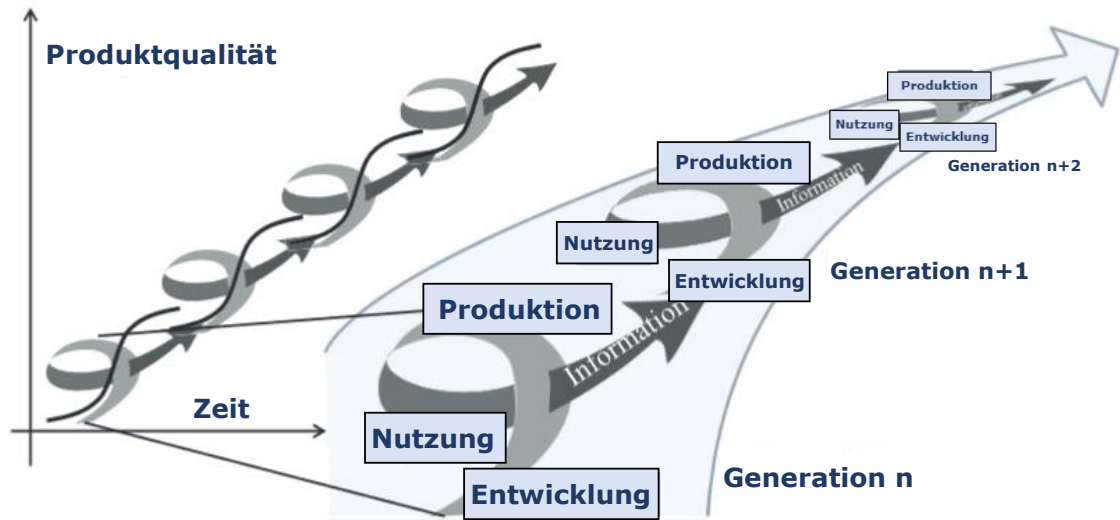


Abbildung 2.10: Prozess der technischen Vererbung nach Lachmayer et al. (2014) zur Verbesserung eines Systems nachfolgender Produktgenerationen durch Informationen zur Produktnutzung. In Anlehnung an Lachmayer et al. (2014, S. 184)

Zusammenfassend kann die Erfassung der Produktnutzung in einer Probandenstudie oder durch die messtechnische Erfassung von PUI in der Nutzungsphase erfolgen. Anforderungen an zu entwickelnde Ansätze zur messtechnischen Erfassung von PUI in der Nutzungsphase sind die unbeobachtete und skalierbare Erfassung sowie Analyse. Um dem hohen Aufwand bei der Analyse der PUI zu begegnen, eignet sich eine softwarebasierte teilautomatisierte Auswertung mittels Machine-Learning. Dies führt zu einer Skalierbarkeit des Aufwands. Für eine unbeobachtete Erfassung von PUI sind die Erfassung und Verarbeitung von Kontextdaten notwendig.

### 2.3 Messtechnische Erfassung von Informationen zur Produktnutzung bei Power-Tools

Dieses Kapitel umfasst die messtechnische Erfassung von PUI während der Produktentwicklung und der Nutzungsphase von Power-Tools. Es werden im oder am Power-Tool applizierte Sensoren und Sensormodule als Alternative zu PEID vorgestellt. Darauf wird der Ansatz des virtuellen Sensors mit den dabei verwendeten Modellen und Herausforderungen präsentiert.

### 2.3.1 Einsatz von Sensoren

Nach Schmidt (2019) kann die Messtechnik zur Erfassung von PUI von Power-Tools in die Kategorien externe Messtechnik, Messtechnik, die an der anwendenden Person appliziert ist, und Messtechnik, die am oder im Power-Tool appliziert ist, unterteilt werden. Ein Beispiel für externe Messtechnik ist eine aufgestellte Videokamera. Ein Beispiel für Messtechnik, die an einer anwendenden Person appliziert ist, ist eine Eyetracking-Brille. Beispiele für Messtechnik, die am oder im Power-Tool appliziert werden, sind Strom- oder Vibrationssensoren. Alle drei Kategorien der Messtechnik können zur Erfassung von PUI bei Power-Tools in Probandenstudien eingesetzt werden. (Schmidt, 2019)

Erfassung von PUI unter den Randbedingungen der Nutzungsumgebung ist eine große Herausforderung (Vichare et al., 2007). In Kapitel 2.2.3 wurde die Anforderung abgeleitet, dass die Erfassung von PUI während der Nutzungsphase unbeobachtet und skalierbar erfolgen soll. Für Messtechnik, die extern aufgestellt ist, bedeutet das, dass die unbeobachtete Messung nur am Aufstellungsort erfolgen kann. Somit ist die Verwendung nur bei einer ortsfesten Anwendung möglich. Dies gilt beispielsweise für einen spezifizierten Arbeitsplatz in einem manuellen Fertigungsprozess, nicht aber für eine freie Anwendung ohne festen Einsatzort. Auch der Einsatz von Sensoren, die an einer anwendenden Person appliziert werden, ist bei einer unbeobachteten Anwendung mit Herausforderungen verbunden. So muss sichergestellt werden, dass der Sensor an der anwendenden Person, beispielsweise über Handschuhe oder eine Smartwatch, korrekt appliziert ist, da eine fehlerhafte Applikation eine Störgröße darstellt. Für beide Kategorien stellt die unbeobachtete Erfassung eine Herausforderung dar, da die Messung nicht am Power-Tool erfolgt und damit erst der Kontext zum Power-Tool hergestellt werden muss. Es muss beispielsweise festgestellt werden, welche Art des Produkts verwendet wird und wann die Nutzung stattfindet. Dies setzt eine Kopplung zwischen Messtechnik und Power-Tool voraus, beispielsweise über eine kabellose Datenübertragung mittels Bluetooth. Aufgrund dieser Herausforderungen befasst sich diese Forschungsarbeit nur mit am oder im Power-Tool applizierter Messtechnik.

Tabelle 2.1 zeigt eine Übersicht über die an und in Winkelschleifern applizierte, eingesetzte Messtechnik in Form der Messgröße und der Sensoren. Ergänzend werden zugehörige wissenschaftliche Publikationen und Patente aufgeführt.

Tabelle 2.1: Übersicht von Sensoren, die an oder in einem Winkelschleifer appliziert wurden

Messgröße	Messmethode	Quelle
Position d. Welle relativ zum Gehäuse	Wirbelstromsensor	(Matthiesen et al., 2016)
Elektrischer Eingangsstrom	Stromsensor	(Matthiesen et al., 2016)
Drehzahl der Welle	Magnetischer oder optischer Winkelsensor	(Matthiesen et al., 2016; Matthiesen, Gwosch & Bruchmüller, 2017)
Temperatur in der Maschine	Thermoelement	(Matthiesen et al., 2016; Matthiesen, Gwosch & Bruchmüller, 2017)
Beschleunigung	Beschleunigungssensor	(Liljelind et al., 2010; Liljelind et al., 2013; A. Lim et al., 2013; Matthiesen, Gwosch & Bruchmüller, 2017; Yusuf et al., 2019; Zimprich et al., 2021)
Kraft zwischen Werkzeug und Antriebsstrang	Kraft-Momenten-Sensor	(Phan et al., 2017; Phan et al., 2020)
Drehmoment	Kraft-Momenten-Sensor	(Phan et al., 2017; Phan et al., 2020)
Rotationsgeschwindigkeit eines Systems	Gierratensensor	(Klee & Faisst, 2013)
Bewegungsdaten	Inertiale Messeinheit (IMU)	(Schmid et al., 2021)

Ein Großteil der in der Tabelle dargestellten Messtechnik weist die Gemeinsamkeit auf, dass nur der Messaufnehmer an oder im Power-Tool appliziert wird. Das Messsignal wird per Kabel an einen stationären Teil des Messsystems übertragen, der den Messumformer und die Auswerteeinheit enthält. Dieser Aufbau ermöglicht hohe Abtastraten und eine gute Signalqualität. Solche Messsysteme werden in dieser Forschungsarbeit als Labor-Messsysteme bezeichnet, da sie sich aufgrund des stationären Messsystems am besten für Probandenstudien in einer Laborumgebung eignen. Abbildung 2.11 zeigt ein Labor-Messsystem am Beispiel der Vibrationsmessung am Getriebegehäuse eines Winkelschleifers.

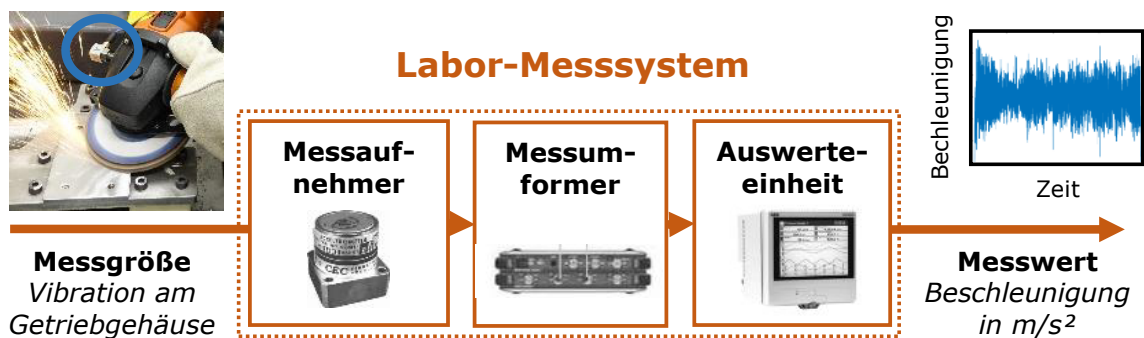


Abbildung 2.11: Aufbau und Anwendung eines Labor-Messsystems am Beispiel der Vibrationsmessung am Getriebegehäuse eines Winkelschleifers. In Anlehnung an Sang (2020)

Für den Einsatz in der Nutzungsphase ist es notwendig, dass die Messung ohne kabelgebundenes, stationäres Messsystem erfolgt. Zudem sollte die Datenerfassung skalierbar erfolgen. Ein geeigneter Ansatz ist die Integration eines PEID in die Maschine. Dazu werden Mikroprozessor, Speichereinheit und Modul zur Energieversorgung des PEID als Microcontroller zusammengefasst. In der Serienproduktion ist dies aufgrund der bereits im Produkt integrierten Infrastruktur wie für andere Zwecke verwendete Leiterplatten und Microcontroller oftmals mit skalierbarem Aufwand möglich. Aufgrund des geringen Bauraums werden hierfür in der Regel mikro-elektro-mechanische Systeme (MEMS) eingesetzt.

Bei der Erforschung der Erfassung von PUI in wissenschaftlichen Studien oder in den frühen Phasen der Produktentwicklung besteht das Problem, dass die Integration eines PEID nur mit großem Aufwand möglich ist. Dies liegt in der hohen Fertigungstiefe begründet, die notwendig ist, um die Integration eines PEID bei begrenztem Bauraum durchzuführen. Daher werden in wissenschaftlichen Studien oder in den frühen Phasen der Produktentwicklung in der Regel prototypische Systeme oder Ersatzsysteme verwendet, um die Integration eines PEID auf dem Niveau der Serienproduktion abzubilden.

Ghosh et al. (2017) beantworten ihre Forschungsfrage: „How can quantitative and scalable user-product interaction data be obtained?“ (S. 2), indem sie ein vom Produkt separierbares System mit integrierten Sensoren und Auswerteeinheit in Form eines Microcontrollers verwenden, um Messdaten zu erfassen. Auch Vichare et al. (2007) schlagen ein generisches Konzept für ein Hardware-Software-Modul mit Sensoren, einer Speichereinheit und einem Microcontroller zur Erfassung der PUI handgehaltener Geräte während der Nutzung vor. Messsysteme, bei denen der Messaufnehmer, der Messumformer und die Auswerteeinheit als kompaktes Modul mit integrierter Speichereinheit und Stromversorgung ausgeführt sind, werden in dieser Forschungsarbeit als Sensormodul bezeichnet.



Ein Sensormodul kann in wissenschaftlichen Studien oder in den frühen Phasen der Produktentwicklung die Integration eines PEID zur Erfassung von PUI während der Nutzungsphase abbilden. Abbildung 2.12 zeigt ein Sensormodul zur Messung der Vibration am Getriebegehäuse eines Winkelschleifers.



Abbildung 2.12: Anwendung des Sensormoduls *Cross-Domain Development Kit XDK 110* (Robert Bosch GmbH, Gerlingen-Schillerhöhe, Deutschland) am Beispiel der Vibrationsmessung am Getriebegehäuse eines Winkelschleifers.

Redžepagić et al. (2020) nutzen ein Sensormodul mit einer inertialen Messeinheit (IMU) und einem Mikrofon in einem Gehäuse, das leicht lösbar an einem Akkuschauber zur automatisierten Qualitätskontrolle befestigt wird. Yang et al. (2019) entwickeln kompakte nicht-invasive Sensormodule mit einer IMU für mehrere Arten von Power-Tools, um damit PUI zu erfassen. Das Sensormodul kann entweder am Griff befestigt oder in die Elektronik des Power-Tools integriert werden (Yang et al., 2019). Heinis et al. (2018) nutzen ein in einen Akkuschauber integriertes Sensormodul mit einem Beschleunigungssensor und einem Mikrofon zur Vorhersage der durchgeführten Tätigkeit mit einem Akkuschauber. Wilwer et al. (2020) zeigen die Applikation des auf dem Markt verfügbaren Sensormoduls *Cross-Domain Development Kit XDK 110* (Robert Bosch GmbH, Gerlingen-Schillerhöhe, Deutschland) mit einer IMU, einem Mikrofon und Umweltsensoren an einem Akkuschauber. In Abbildung 2.13 zeigt die IMU für das Sensormodul von Yang et al. (2019) sowie die Sensormodule von Wilwer et al. (2020), Heinis et al. (2018) und Redžepagić et al. (2020). Diese Beispiele zeigen den erfolgreichen Einsatz von Sensormodulen.

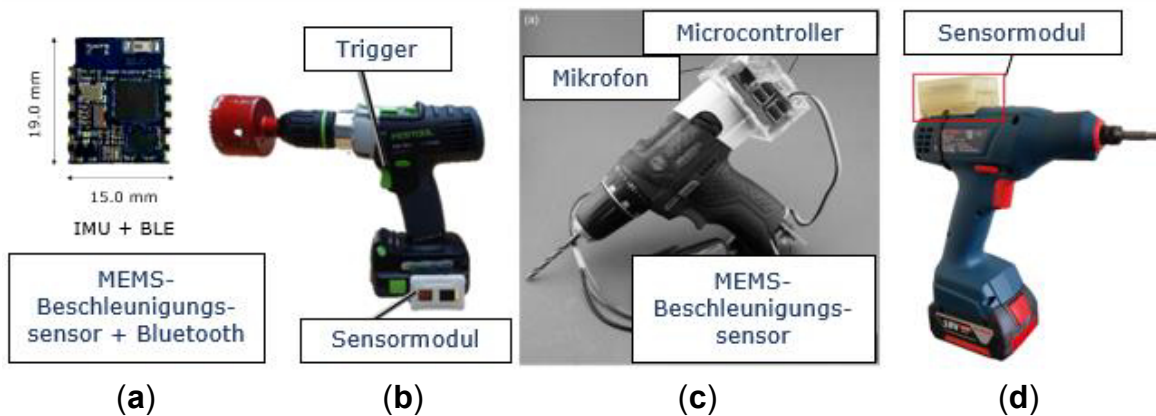


Abbildung 2.13: IMU für das Sensormodul von Yang et al. (2019) (a) sowie Sensormodule von Wilwer et al. (2020) (b), von Heinis et al. (2018) (c) und von Redžepagić et al. (2020) (d), die am Beispiel Akkuschauber eingesetzt werden. In Anlehnung an Heinis et al. (2018, S. 37), Redžepagić et al. (2020, S. 131), Wilwer et al. (2020, S. 143) und Yang et al. (2019, S. 37)

Zusammenfassend werden zur messtechnischen Erfassung von PUI bei Power-Tools verschiedene Sensoren am oder im Power-Tool appliziert. Sensormodule sind geeignet, um die Integration eines PEID in wissenschaftlichen Studien oder in den frühen Phasen der Produktentwicklung abzubilden.

### 2.3.2 Einsatz von virtuellen Sensoren

Virtuelle Sensoren bestehen aus einer Kombination von physikalisch vorhandenen Sensoren oder Messdaten und mathematischen Modellen zur Vorhersage einer schwer oder gar nicht zu messenden Ausgangsgröße aus Messwerten als Eingangsgröße (Becker & Krause, 2010). Ein Zweck virtueller Sensoren besteht darin, durch die Kombination von Messdaten, die mittels physikalisch vorhandener Sensoren gemessen werden, die Erfassung einer Zielgröße zu ermöglichen, die nicht direkt messbar ist (Kabadayi et al., 2006).

Im folgenden Absatz wird die Definition virtueller Sensoren diskutiert. Virtuelle Sensoren werden auch Softsensoren oder Softwaresensoren genannt. In der Literatur gibt es abweichende Definitionen für virtuelle Sensoren (Jiang et al., 2021). In manchen Fällen bezieht sich der virtuelle Sensor nur auf das mathematische Modell (Graziani & Xibilia, 2020). Teilweise werden nur Messdaten eines einzelnen Sensors verwendet, zum Beispiel wenn das Modell des virtuellen Sensors eine Übertragungsfunktion darstellt (Liu et al., 2009). Darüber hinaus werden virtuelle Sensoren verwendet, um eine qualitative Zielvariable anstelle einer quantitativen Zielvariable zu erfassen (Bustillo et al., 2011).

In dieser Forschungsarbeit werden virtuelle Sensoren folgendermaßen definiert: Virtuelle Sensoren bestehen aus mehreren physisch vorhandenen Sensoren und mathematischen Modellen, die eine quantitative oder qualitative Zielgröße aus den Sensordaten berechnen oder vorhersagen.

Die Darstellung eines virtuellen Sensors in Abbildung 2.14 erfolgt am Beispiel der Vorhersage der Zielgröße *Kräfte im Werkzeugkontakt* in Anlehnung an (Chéruy, 1997).

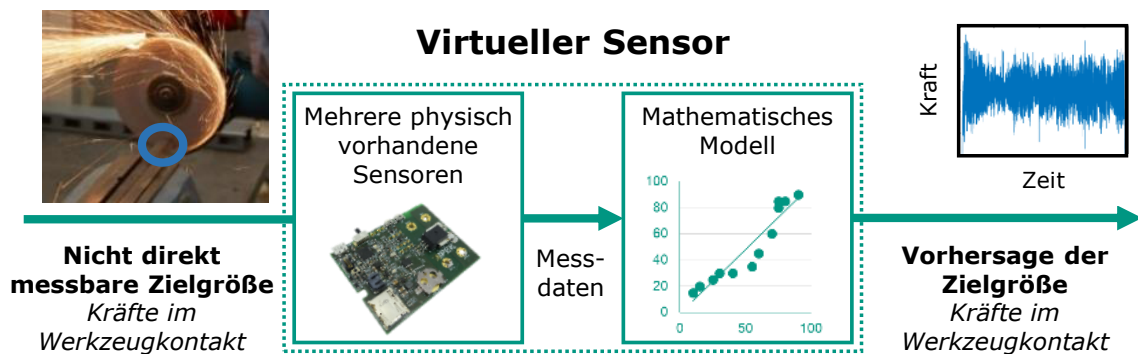


Abbildung 2.14: Virtueller Sensor als Kombination von physisch vorhandenen Sensoren in einem Messsystem und einem Modell, dargestellt am Beispiel der Vorhersage von Kräften im Werkzeugkontakt. In Anlehnung an Chéruy (1997, S. 194)

Für virtuelle Sensoren können je nach Wissen über das Produkt verschiedene Modelle verwendet werden (Becker & Krause, 2010). Nach Kadlec et al. (2009) können Modelle virtueller Sensoren modellgetriebenen und datengetriebenen Ansätzen zugeordnet werden. Modelle des modellgetriebenen Ansatzes beschreiben die physikalischen und chemischen Zusammenhänge (Kadlec et al., 2009). Modelle des datengetriebenen Ansatzes sind vor allem Black-Box-Modelle (Kadlec et al., 2009). Black-Box-Modelle umfassen statistische Modelle, die mittels Machine-Learning parametrisiert werden.

Ein Vorgehen zur Bildung, Validierung und Anwendung von statistischen Modellen für virtuelle Sensoren ist in Abbildung 2.15 skizziert. Das Vorgehen orientiert sich an der allgemeinen Beschreibung der Bildung und Anwendung von Modellen nach Tönshoff et al. (1992). Bei der Modellbildung wird das Modell anhand der Eingangs- und Ausgangsgrößen des zu modellierenden Prozesses parametrisiert. Bei der Modellvalidierung wird das Modell durch den Vergleich zwischen den Ausgangsgrößen des Prozesses und des Modells validiert. Bei der Anwendung werden die Ausgangsgrößen des Prozesses nicht gemessen, sondern über das Modell aus den Eingangsgrößen vorhergesagt oder berechnet. Der virtuelle Sensor

besteht aus Sensoren, die die Eingangsgrößen für das Modell messen, und dem validierten Modell, das die Ausgangsgröße des Prozesses vorhersagt oder berechnet.

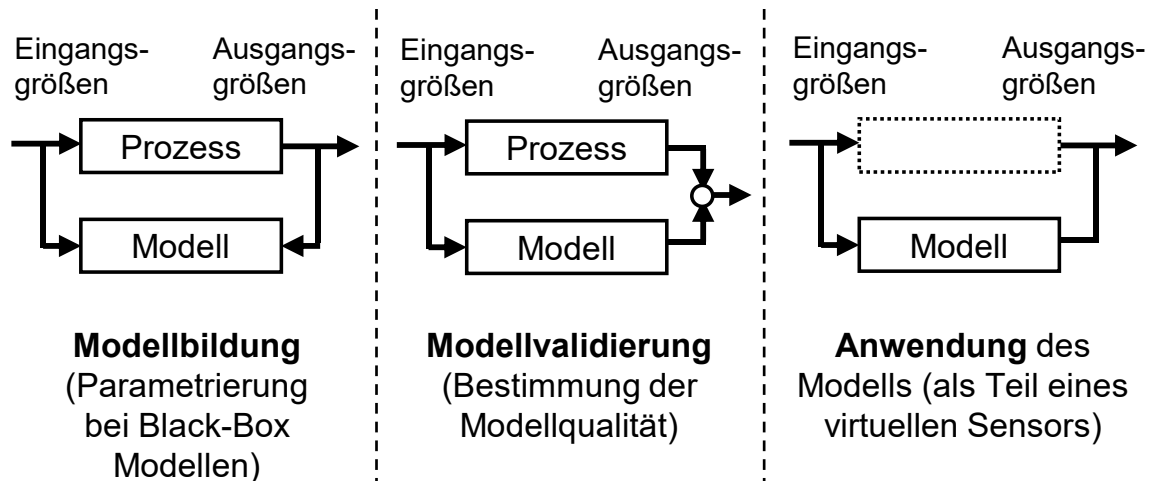


Abbildung 2.15: Bildung, Validierung und Anwendung von Black-Box-Modellen. In Anlehnung an Tönshoff et al. (1992, S. 678)

Bei fast allen Anwendungen virtueller Sensoren mittels datengetriebener Ansätze wird ein einziges Modell parametrieren, ohne zwischen Arbeitspunkten eines Prozesses des Produktes zu unterscheiden (Souza et al., 2016). Für unterschiedliche Betriebszustände hat es sich im Bereich der Prozessindustrie bewährt, für jeden Betriebszustand ein eigenes Modell zu parametrieren (Facco et al., 2009). Die Identifikation des Betriebszustands für die Zuordnung des passenden Modells stellt eine Herausforderung beim Einsatz von virtuellen Sensoren dar (Camacho & Picó, 2006; N. Lu & Gao, 2005).

Für Power-Tools entspricht der Betriebszustand den Tätigkeiten und Arbeitspunkten. Das Verhalten eines Power-Tools kann sich abhängig von den Tätigkeiten oder Arbeitspunkten unterscheiden, zum Beispiel bei der Verstimmung des Schlagwerks eines Bohrhammers (Schäfer, 2018). Daher ist die Identifikation der durchgeführten Tätigkeit und des Arbeitspunktes bedeutsam, bei denen ein unterschiedliches Verhalten des Power-Tools vorliegt. Dies ermöglicht den Austausch von Modellen innerhalb des virtuellen Sensors in Abhängigkeit von der Tätigkeit oder des Arbeitspunktes.

Zusammenfassend werden bei schwer oder gar nicht messbaren Zielgrößen virtuelle Sensoren eingesetzt, die mehrere physisch vorhandene Sensoren und mathematische Modelle zur Vorhersage der Zielgröße verwenden. Für die Realisierung eines virtuellen Sensors müssen Modelle gebildet und validiert werden. Dazu können statistische Modelle verwendet werden. Bei stark unterschiedlichen

Tätigkeiten oder Arbeitspunkten sollten bei virtuellen Sensoren spezifische Modelle für die jeweilige Tätigkeit und den jeweiligen Arbeitspunkt benutzt werden. Um das korrekte Modell zu verwenden, müssen die Tätigkeit und der Arbeitspunkt sicher erkannt werden.

## **2.4 Nutzungselemente beim Schleifen mit Power-Tools**

In dieser Forschungsarbeit wird die unbeobachtete und skalierbare Erfassung der PUI beim Schleifen mit Power-Tools untersucht. Die Erfassung wird anhand von drei relevanten Nutzungselementen untersucht, die in diesem Kapitel vorgestellt werden. Die Nutzungselemente sind die durchgeführte Tätigkeit, die Kräfte im Werkzeugkontakt und die Kräfte am Antriebsstrang. Zuerst wird der Nutzen dieser Elemente für die Produktentwicklung vorgestellt. In den Kapiteln 2.4.1 bis 2.4.3 wird der Stand der Forschung zum Nutzungselement für das Schleifen mit Power-Tools und angrenzende Bereiche vorgestellt.

Bei Power-Tools wird der Kontext der Nutzung qualitativ durch eine Anwendung und in höherem Detaillierungsgrad durch eine Tätigkeit beschrieben. Der Nutzungskontext in Form der Tätigkeit beeinflusst die Produktperformance und Kundenakzeptanz eines Produkts (He et al., 2012). Die Kenntnis der Tätigkeit ist notwendig, um eine sinnvolle Auswertung von Sensordaten aus der unbeobachteten Erfassung während der Nutzungsphase durchzuführen (Lehmhus et al., 2015). Bei der Anwendung eines virtuellen Sensors muss, wie in Kapitel 2.3.2 ausgeführt, die Tätigkeit sicher erkannt werden, um das korrekte Modell für den virtuellen Sensor zu verwenden. Daher ist die Kenntnis der Tätigkeit beim Schleifen mit Power-Tools von großer Bedeutung für die Produktentwicklung. (Dörr, Spoden et al., 2022)

Ein wesentlicher Nutzen der Kenntnis von Kräften im Werkzeugkontakt für die Produktentwicklung besteht im Zusammenhang mit mehreren relevanten Variablen des Schleifprozesses und des Verhaltens des Power-Tools. Die Relevanz der Tangentialkraft und Normalkraft in einem Schleifprozess wurde in Abbildung 2.3 von (Tönshoff et al., 1992) aufgezeigt. Für das Schleifen mit Power-Tools wurden die Zusammenhänge der Tangentialkraft und Normalkraft mit dem Materialabtrag (Bales et al., 2017) und der Rauheit nach dem Schleifvorgang (Das et al., 2018) bestätigt. In einer Studie konnten Dörr, Zimprich et al. (2019) einen signifikanten Effekt des dynamischen Anteils der Kraft auf die Vibration eines Winkelschleifers und den Verschleiß von Trennscheiben und Schruppscheiben beim Schleifen mit einem Winkelschleifer zeigen. Der Schleifprozess mit Power-Tools wird in hohem Maße durch die anwendende Person bestimmt (Odum et al., 2014). Die anwendende Person beeinflusst die Tangentialkraft und die Normalkraft und damit

die Konstanz des Schleifprozesses (Bales et al., 2017). Somit lassen sich die für den allgemeinen Schleifprozess aufgezeigten Zusammenhänge für das Schleifen mit Power-Tools um die Zusammenhänge mit der anwendenden Person erweitern. Dies zeigt die Bedeutung der Kenntnis der Kräfte im Werkzeugkontakt beim Schleifen von Power-Tools für die Produktentwicklung. (Dörr, Ott et al., 2021)

Genauere Kenntnisse über äußere, auf das Produkt wirkende Kräfte, beispielsweise durch die Belastung, sind in allen Schritten der Produktentwicklung unerlässlich (Bracke et al., 2016). Häufig ist die Belastung auf das Produkt in der Produktentwicklung jedoch nicht bekannt (Raheja, 2012). Mit den Kräften im Werkzeugkontakt kann die Belastung auf das Werkzeug bestimmt werden. Maßgeblich für die Belastung der Maschine ist jedoch die Belastung, die am Antriebsstrang an der Schnittstelle zwischen Werkzeug und Maschine vorliegt. Diese Belastung wird beispielsweise für die Auslegung oder für Lebensdauertests mit mehrdimensionaler Belastung an einem Prüfstand benötigt (Dörr, Mertens et al., 2021; Matthiesen, Gwosch, Mangold et al., 2017). Der Antriebsstrang umfasst, wie in Abbildung 2.1 dargestellt, die Arbeitswelle und Motorwelle. Die Belastung besteht aus Drehmomenten und Kräften. Das am Antriebsstrang wirkende Drehmoment als rotatorische Last kann durch die Messung des Stromsignals des Motors und dessen Umrechnung in ein Drehmoment bestimmt werden (Yan et al., 2005). Dies erfordert die Kenntnis der Drehmoment-Strom-Kennlinie des Elektromotors, die aus der Entwicklung bekannt ist oder experimentell ermittelt werden kann (Dörr, Mertens et al., 2021; Matthiesen, Gwosch, Mangold et al., 2017). Da die Vorhersage des Drehmoments im Stand der Technik und Wissenschaft bereits bekannt ist, fokussiert sich diese Forschungsarbeit auf die Vorhersage des Nutzungselements Kräfte am Antriebsstrang, die als Radial- und Axialkräfte in drei Raumrichtungen auf den Antriebsstrang wirken. (Dörr, Dürkopp et al., 2021)

### **2.4.1 Nutzungselement: Durchgeführte Tätigkeit**

*Der Stand der Forschung dieses Kapitels basiert zu Teilen auf der nachfolgenden Veröffentlichung:*

*- „Activity Recognition With Machine Learning in Manual Grinding“ (Dörr, Spoden et al., 2022)*

*Teile des folgenden Textes sind ohne Veränderung in übersetzter Form aus der Veröffentlichung übernommen. Sie werden aus Gründen der Übersichtlichkeit nicht gesondert gekennzeichnet.*

Die Ermittlung von Tätigkeiten, die von Menschen ausgeführt werden, auf Basis von Sensor- oder Videodaten wird im Forschungsfeld Human Activity Recognition (HAR) untersucht (Ranasinghe et al., 2016). Dabei werden die Tätigkeiten über Machine-Learning auf Basis von Messdaten vorhergesagt, wobei bei der Erfassung zwischen

Kameras und tragbaren Sensoren unterschieden wird (Lara & Labrador, 2013). Der folgende Stand der Forschung im Forschungsfeld HAR beschränkt sich auf Ansätze, bei denen tragbare Sensoren verwendet werden. Diese umfassen sowohl an einer anwendenden Person applizierte als auch an oder in der Maschine applizierte Sensoren.

Im Forschungsfeld HAR wird an der Vorhersage von Tätigkeiten im Rahmen von Arbeitsschritten bei Montageprozessen geforscht. Stiefmeier et al. (2008) und Ward et al. (2006) untersuchten die Vorhersage einzelner Arbeitsschritte beim Einbau einer Frontleuchte in eine Autokarosserie mithilfe von tragbaren und externen Sensoren. Die Vorhersage von Tätigkeiten in Bezug auf die verwendeten Werkzeuge wurde mit IMU an beiden Handgelenken eines Arbeiters in einem Montageprozess eines Möbelstücks untersucht (Huikari et al., 2010; Koskimäki et al., 2009). Eine Kombination aus Messung durch IMU und Messung elektrischer Aktivität in Muskeln wurde zur Vorhersage von Montageaufgaben und eingesetzten Werkzeugen verwendet (Tao et al., 2018). Die Vorhersage der benutzten Werkzeuge wurde auch mit Sensorhandschuhen (Ibarguren et al., 2006) oder einer Smartwatch (Bieber et al., 2016) durchgeführt.

Zudem wird im Forschungsfeld HAR an der Vorhersage von Tätigkeiten im Rahmen von Arbeitsschritten im Bauwesen geforscht. Im Bereich Bauwesen wurden Studien durchgeführt, um manuelle Tätigkeiten anhand der verwendeten Werkzeuge zu erkennen (Akhavian & Behzadan, 2016). Auch manuelle Tätigkeiten wie Maurerarbeiten (Joshua & Varghese, 2011; Ryu et al., 2019; Sanhudo et al., 2021), Bewehrungsarbeiten (Zhang et al., 2018), Eisen- und Zimmermannsarbeiten (Joshua & Varghese, 2014) wurden auf der Grundlage von Messdaten einer IMU erkannt.

Die Vorhersage von Tätigkeiten beim Schleifen mit Power-Tools wurde in der verarbeitenden Industrie durchgeführt. Dabei wurde die Anwendung verschiedener Power-Tools (Exzentrerschleifer, Winkelschleifer, Blechnibbler, Schwingschleifer, Poliermaschine, Steinschleifer und Kreissäge) identifiziert (Aiello et al., 2021).

Die vorgestellten Arbeiten zu HAR in der Fertigung und im Bauwesen konzentrierten sich auf die Vorhersage von Tätigkeiten mit verschiedenen handgeführten Werkzeugen und jeweils unterschiedlichen Power-Tools. Schmidt (2019) generalisiert in seiner Methodik Tätigkeiten anhand von Clusterkriterien. Für Winkelschleifer nennt Schmidt (2019) als Clusterkriterium das verwendete Werkzeug (Trennscheibe, Schleifscheibe, Schruppscheibe, Fächerscheibe oder Polierscheibe) und die Arbeitsweise (Schleifen, Trennen, Schruppen oder Polieren). Im Stand der Forschung ist unklar geblieben, wie Tätigkeiten auf einem höheren

Detailierungsgrad innerhalb eines Power-Tools erkannt werden können, beispielsweise in Bezug auf verwendete Werkzeuge oder unterschiedliche Arbeitsweisen.

Bei Akkuschraubern wurde in zwei Studien die Vorhersage der Tätigkeiten *Festziehen* und *Lösen von Schraubverbindungen* (Löffler et al., 2021) sowie *Schrauben in Holz* und *Bohren in Holz* (Heinis et al., 2018) mit Machine-Learning auf Basis von Messdaten aus Sensormodulen mit einer IMU und einem Mikrofon untersucht. Außerdem wurde der Einfluss der Sensorposition und der Sensortypen auf die Vorhersage von Werkzeugbewegungen und der Tätigkeiten beim Schrauben erforscht (Günther et al., 2019). Dies zeigt, dass die Verwendung eines Sensormoduls in Verbindung mit einem virtuellen Sensor mittels Machine-Learning in der Lage ist, Tätigkeiten unbeobachtet und aufgrund des Sensormoduls mit skalierbarem Aufwand vorherzusagen. Aufgrund des starken Einflusses der anwendenden Person auf die Prozessleistung und -konstanz (Bales et al., 2016) beim Schleifprozess bleibt die Vorhersage von Tätigkeiten eine Herausforderung beim Schleifen mit Power-Tools.

Beim Schleifen mit einem Geradschleifer konnten bei einem kleinen Datensatz mit einer anwendenden Person die Zustände *Schleifen* und *Kein Werkzeugkontakt* mit einer Genauigkeit von 93 % und die Tätigkeiten *Bearbeitung von Stahl* und *Bearbeitung von Aluminium* mit einer Genauigkeit von 90 % unter Verwendung von Beschleunigungsmesser, Gyroskop, Mikrofon und Stromsensor unterschieden werden (Voet et al., 2019). Die Genauigkeit der Vorhersage wurde anhand einer Kreuzvalidierung bewertet (Voet et al., 2019). Dies zeigt, dass die binäre Unterscheidung zwischen einer Tätigkeit, bei der der Geradschleifer in Kontakt mit dem Werkstück ist, und Tätigkeiten, bei denen der Geradschleifer nicht in Kontakt mit dem Werkstück ist, möglich ist. Zudem kann zwischen unterschiedlichem Werkstücken differenziert werden.

Heinis et al. (2018) untersuchen die Vorhersage von sechs verschiedenen Tätigkeiten beim Schleifen mit einem Winkelschleifer aus Messdaten einer manuellen Studie. Es wurde eine Genauigkeit von 100 % erzielt. Die ausgewerteten Messdaten der Studie umfassten Messsignale mit einer Gesamtlänge von insgesamt 104,2 Sekunden. Die Versuche in der Studie wurden durch eine anwendende Person durchgeführt. Die unabhängigen Variablen des statistischen Modells waren Sensordaten, die mit einem Labor-Messsystem mit einer Abtastfrequenz von 25 kHz in einer Studie von Matthiesen et al. (2016) gemessen wurden. Dazu wurden sechs berührungslose Abstandssensoren zur Messung der Wellenverschiebungen, ein Drehzahlsensor und ein Stromsensor verwendet (Matthiesen et al., 2016). Die Genauigkeit der Vorhersage wurde anhand eines



Validierungsdatensatzes bestimmt, der aus 30 % der Daten des Datensatzes gebildet wurde. (Heinis et al., 2018)

Die Ergebnisse der Studie von Heinis et al. (2018) zeigen, dass in einem einfachen Datensatz verschiedene Tätigkeiten bei einem Winkelschleifer mit hoher Genauigkeit vorhergesagt werden können. Die Verwendung eines Labor-Messsystems mit einer Abtastfrequenz von 25 kHz ist nicht mit skalierbarem Aufwand möglich. Daher ist die Übertragbarkeit in die Nutzungsphase nicht gegeben. Zudem ist die Übertragbarkeit der Ergebnisse zur Vorhersage der Tätigkeit aufgrund der geringen Größe und Variation des Datensatzes sowie durch die Validierung mit einem Validierungsdatensatz unklar.

Zusammenfassend gibt es viele Ansätze zur Vorhersage einer Tätigkeit im Forschungsfeld HAR. Im Bereich von Power-Tools existieren diesbezüglich nur wenige Ansätze. Für Akkuschauber existieren Modelle, um die Tätigkeiten unbeobachtet und mit skalierbarem Aufwand aus Messdaten eines Sensormoduls vorherzusagen. Die Übertragbarkeit der Modelle auf das Schleifen mit Power-Tools muss aufgrund der Streuung und der geringeren Prozesskonsistenz beim Schleifen untersucht werden. Für das Schleifen mit Power-Tools ist unklar, ob die Vorhersage der durchgeführten Tätigkeit auch mit unabhängigen Variablen möglich ist, die in einer manuellen Studie bei stärkeren Störgrößen mit einem PEID erhoben wurden. Zudem ist die Übertragbarkeit der Ergebnisse aufgrund der unterschiedlichen Methoden zur Bewertung der Vorhersage unklar.

#### **2.4.2 Nutzungselement: Kräfte im Werkzeugkontakt**

*Der Stand der Forschung dieses Kapitels basiert zu Teilen auf der nachfolgenden Veröffentlichung:*

*- „Prediction of Tool Forces in Manual Grinding Using Consumer-Grade Sensors and Machine Learning“ (Dörr, Ott et al., 2021)*

*Teile des folgenden Textes sind ohne Veränderung in übersetzter Form aus der Veröffentlichung übernommen. Sie werden aus Gründen der Übersichtlichkeit nicht gesondert gekennzeichnet.*

Wie in den Grundlagen in 2.1.1 erläutert, setzen sich die Kräfte am Werkzeugkontakt aus der Tangential- und der Normalkraft zusammen. Beim Schleifen mit Power-Tools kommt die Führungskraft durch die anwendende Person hinzu (Internationale Organisation für Normung [ISO] 15230:2007). Das Problem ist, dass beim Schleifen mit Power-Tools die Kräfte nicht direkt im Schleifkontakt gemessen werden können (A. Lim et al., 2013). Die Vorhersage der Kräfte im Werkzeugkontakt durch Ansätze wie virtuelle Sensoren oder Sensorapplikation in das Werkstück oder die Maschine

ist eine Herausforderung, wenn die Bewegung nicht eindeutig definiert ist (Phan et al., 2020).

Im Bereich des automatisierten Schleifens, wo das Werkzeug oder Werkstück von einer Maschine oder einem Roboter geführt und gesteuert wird, wird das Problem der Vorhersage der Werkzeugkräfte durch die Messung mit Kraftsensoren an starr angebundenen Teilsystemen, beispielsweise unter dem Werkstück, oder durch virtuelle Sensoren gelöst (Kaufmann et al., 2020). Für virtuelle Sensoren werden empirische, numerische, analytische oder mittels Machine-Learning parametrisierte Modelle verwendet (Arrazola et al., 2013; Kuntoğlu et al., 2020). Virtuelle Sensoren mit durch Machine-Learning parametrisierten Modellen zeigen dabei vielversprechende Ergebnisse bei der Vorhersage von Kräften im Werkzeugkontakt (Sousa et al., 2020). Als Eingangsgrößen für die Modelle werden sowohl die Sollwertvariablen als auch Messgrößen von Sensoren verwendet.

Die Korrelation zwischen durchschnittlichen Kräften im Werkzeugkontakt und den Parametern des Schleifprozesses deutet darauf hin, dass das Schleifen mit Power-Tools ein kraftgesteuerter und kein weggesteuerter Prozess ist (Kamath et al., 2020). Daher gilt es zu untersuchen, inwieweit die Ansätze zur Vorhersage der Werkzeugkräfte im Bereich des automatisierten Schleifens auf handgeführte Power-Tools übertragbar sind.

Ein Ansatz von A. Lim et al. (2013) besteht darin, die Beschleunigung am Handgriff zu messen und die Werkzeugkräfte mit einer experimentell ermittelten Übertragungsfunktion zu berechnen. Das Übertragungsverhalten eines linearen zeitinvarianten Systems kann im Frequenzbereich durch Übertragungsfunktionen modelliert werden, die experimentell ermittelt werden können (Sang, 2020). Beim Ansatz von A. Lim et al. (2013) wurde die Übertragungsfunktion mit einem Impulshammer für die Richtung der Andruckkraft ermittelt (A. Lim et al., 2013). Dies ermöglicht lediglich die Ermittlung des dynamischen (hochpassgefilterten) Anteils der Kraft im Werkzeugkontakt. Der stationäre Anteil, beispielsweise die stationäre Andruckkraft einer anwendenden Person, kann nicht ermittelt werden. Des Weiteren entspricht das stationäre Verhalten eines Power-Tools im Stillstand, in dem die Übertragungsfunktion mit dem Impulshammer bestimmt wird, nicht zwangsläufig dem dynamischen Verhalten im Betrieb bei einer hohen Drehzahl.

Beim Schleifen mit Power-Tools werden die Werkzeugkräfte hauptsächlich in stationären Versuchsaufbauten gemessen. Dabei wird ein Kraftsensor zwischen dem Werkstück und dem Versuchsaufbau oder der Umgebung angebracht (Das & Linke, 2016; Matthiesen et al., 2018; Matthiesen, Gwosch & Bruchmüller, 2017). Die Verwendung von stationären Versuchsaufbauten beschränkt die Kraftmessung

jedoch auf Probandenversuche in einer Laborumgebung. Ein weiterer Ansatz von A. Lim et al. (2013) ist die Messung der Beschleunigung am zu bearbeitenden Werkstück und die Berechnung der Werkzeugkräfte mit einer experimentell ermittelten Übertragungsfunktion. Allerdings ist der Einsatz beider Ansätze auf stationäre Versuchsaufbauten und Werkstücke mit applizierter Messtechnik beschränkt, so dass die Kraftmessung nur für Probandenstudien während der Produktentwicklung genutzt werden kann. Eine Übertragung in die unbeobachtete Nutzungsphase mit beliebigen Werkstücken ist nicht möglich.

Ansätze zur Vorhersage der Kräfte am Antriebsstrang, beispielsweise von Phan et al. (2017) und Matthiesen et al. (2016), sind für die Vorhersage der Kräfte im Werkzeugkontakt bei Winkelschleifern nicht geeignet, da das Übertragungsverhalten des Werkzeugs, sofern es nicht als starr angenommen werden kann, berücksichtigt werden muss. Diese Ansätze werden in Kapitel 2.4.3 ausführlicher vorgestellt.

In anderen Domänen ist die Vorhersage von Kräften oder Bewegungen mittels Machine-Learning aus Messdaten von einer oder mehrerer IMU ein klassisches Problem. So wurden in der Biomechanik Körperkräfte und -bewegungen wie Gelenkkräfte (Giarmatzis et al., 2020; Stetter et al., 2019), Gelenkmomente (H. Lim et al., 2019), Bewegungsabsichten (H. Lu et al., 2020), Neigungswinkel des Massenmittelpunkts (Choi et al., 2019) und die Bodenreaktionskraft (Wu et al., 2020) mithilfe einer oder mehrerer IMU vorhergesagt. Die Ergebnisse zeigen, dass die Vorhersage der Bewegungen und Kräfte einer anwendenden Person mit einer IMU prinzipiell möglich ist. Allerdings wird die Vorhersage der Kräfte im Werkzeugkontakt durch die Interaktion mit dem Power-Tool und dem Bearbeitungsprozess stark beeinflusst. Daher muss untersucht werden, ob dieser Ansatz auch beim Schleifen mit Power-Tools möglich ist.

Voet et al. (2019) sagen die Andruckkraft an einem Geradschleifer, über eine binäre Klassifikation in einen hohen Kraftbereich (4 – 8 N) und einen niedrigen Kraftbereich (0 – 2,5 N), mithilfe einer Support-Vektor-Maschine (SVM) mit einer Genauigkeit von 79,58 % vorher. Die Eingangsdaten für die Klassifikation wurden mit einem Beschleunigungssensor (drei Richtungen), einem Gyroskop (drei Richtungen), einem Schallemissionssensor (20 – 500 kHz) und einem Stromsensor gemessen. Die Genauigkeit wurde über eine Kreuzvalidierung, wie in Kapitel 2.1.2 erläutert, validiert. Dies zeigt, dass qualitative Kraftbereiche bei einem Winkelschleifer vorhergesagt werden können. Die Verwendung umfangreicher Labor-Messsysteme, wie eines Schallemissionssensors, erschwert die Übertragbarkeit in die Nutzungsphase beispielsweise durch unterschiedlichen, unbekanntem Umgebungslärm. Um die vorgestellten Zusammenhänge in der Produktentwicklung

nutzen zu können, sollten die Kräfte in allen drei Raumrichtungen, idealerweise mit Angabe der Unsicherheit der Vorhersage, quantitativ vorliegen.

Zusammenfassend gibt es für das Schleifen mit Power-Tools bisher keine geeigneten Ansätze zur Vorhersage der quantitativen Kraft in allen drei Raumrichtungen in der Nutzungsphase. Beim automatisierten Schleifen mit Werkzeugmaschinen werden für die Vorhersage der Kräfte im Werkzeugkontakt Sensoren in dessen Nähe appliziert oder virtuelle Sensoren eingesetzt. In der Biomechanik existieren Modelle, um die Tätigkeiten unbeobachtet und mit skalierbarem Aufwand aus Messdaten einer oder mehrerer IMU vorherzusagen. Eine Übertragung der Modelle für die Verwendung eines virtuellen Sensors muss aufgrund der Streuung und der geringeren Prozesskonsistenz beim Schleifen untersucht werden.

### **2.4.3 Nutzungselement: Kräfte am Antriebsstrang**

*Der Stand der Forschung dieses Kapitels basiert zu Teilen auf der nachfolgenden Veröffentlichung:*

- „*Approach for Modelling the Dynamic Transmission Behavior of Grinding Discs Using Transfer Functions*“ (Dörr, Dürkopp et al., 2021).

*Teile des folgenden Textes sind ohne Veränderung in übersetzter Form aus der Veröffentlichung übernommen. Sie werden aus Gründen der Übersichtlichkeit nicht gesondert gekennzeichnet.*

Ein Ansatz zur Erfassung der translatorischen Kräfte ist die Berechnung der am Antriebsstrang wirkenden Kräfte anhand der Verschiebung der Arbeitswelle (Sarhan et al., 2006). Die Auslenkung des Antriebsstrangs zur Vorhersage der Kräfte am Antriebsstrang eines Winkelschleifers wurde berührungslos durch Matthiesen et al. (2016) gemessen, wobei das Steifigkeitsverhältnis zwischen Kraft und Verschiebung experimentell auf einem Prüfstand vermessen wurde. Die Verschiebung der Welle wird bei einem niedrigen Frequenzbereich durch die Belastung bestimmt. Bei der Frequenz der 1. Ordnung der Drehzahl des Antriebsstrangs weist die Verschiebung der Welle einen dynamischen Anteil auf, der nicht durch die Kraft im Werkzeugkontakt erklärt werden kann. Dieser wird zum Beispiel durch einen Rundlauffehler oder einen Unwucht-Fehler der Antriebswelle verursacht. Daher kann dieser Ansatz nur für den Frequenzbereich unterhalb der 1. Ordnung der Drehzahl des Antriebsstrangs verwendet werden (Matthiesen et al., 2016). In Abbildung 2.16 ist das Konzept mit mehreren Wegsensoren dargestellt (Matthiesen et al., 2014). Um aus der Verformung der Lagerstellen auf die Kräfte im Werkzeugkontakt zu schließen, schlägt Matthiesen et al. (2014) die Verwendung eines Modells vor.

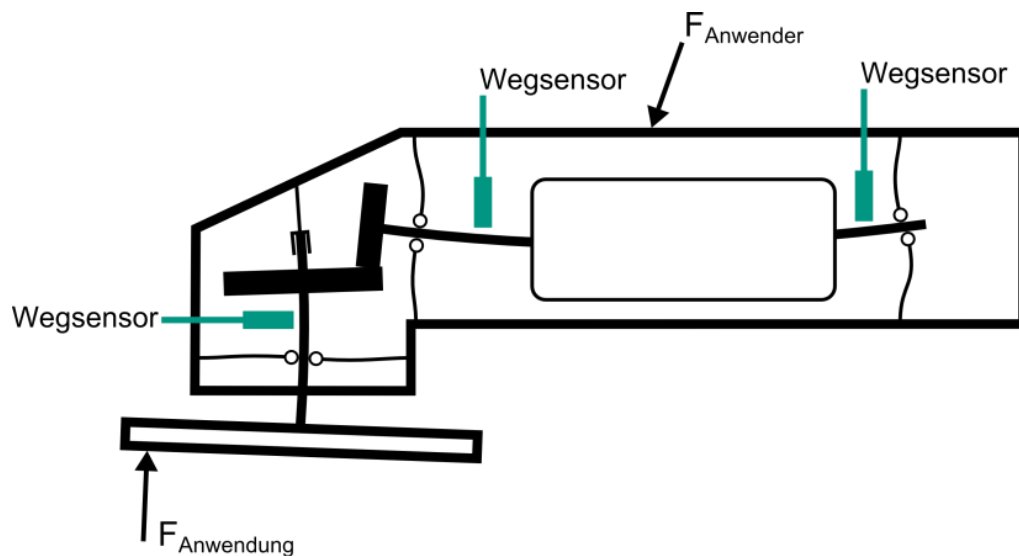


Abbildung 2.16: Ansatz zur Messung der Kräfte am Antriebsstrang eines Winkelschleifers durch berührungslose Wegsensoren. (Matthiesen et al., 2014, S. 58)

Ein Ansatz von Phan et al. (2020) zur Messung der Kräfte am Antriebsstrang sind die Applikation von Kraftsensoren am Gehäuse und der Einbau einer Nachgiebigkeit in die Antriebswelle. Das Konzept und die Umsetzung sind in Abbildung 2.17 dargestellt (Phan et al., 2017). Zu diesem Zweck wird mit einem Versuchsaufbau eine Kalibrierungsmatrix parametrisiert, wobei die Ergebnisse nur in einem Bereich bis zu  $2000 \text{ min}^{-1}$  und bis  $7 \text{ N}$  verifiziert wurden (Phan et al., 2020). Dies liegt deutlich unter dem Arbeitsbereich eines Winkelschleifers mit einer Andruckkraft von  $35 - 70 \text{ N}$  (Gärtner, 2004) und einer Drehzahl von bis  $11000 \text{ min}^{-1}$ . Phan et al. (2020) treffen die Annahme, dass das Werkzeug starr ist, und schlagen daher im Ausblick vor, dass für nachgiebigere Werkzeuge dynamische Modelle spezifisch für das jeweilige Werkzeug verwendet werden müssen.




Abbildung 2.17: Ansatz zur Messung der Kräfte am Antriebsstrang eines Winkelschleifers durch Applikation eines Kraft-Momenten-Sensors am Gehäuse und Einbau einer Nachgiebigkeit in den Antriebsstrang: Skizze des Ansatzes **(a)** und an einem handelsüblichen Winkelschleifer angebrachter Prototyp **(b)**. In Anlehnung an Phan et al. (2017, S. 552)

Für die Modellierung des Übertragungsverhaltens beim manuellen Schleifen nehmen Dong et al. (2020) für steife Werkzeuge an, dass das Übertragungsverhalten des Werkzeugs vom Werkzeug-Werkstück-Kontakt zum Antriebsstrang der Maschine im niedrigen Frequenzbereich konstant ist. Für nachgiebigere Werkzeuge, wie sie beim Winkelschleifer vorliegen, muss untersucht werden, wie höherfrequente Kraftanregungen im Werkzeugkontakt am Antriebsstrang übertragen werden können. Die experimentelle Ermittlung einer Übertragungsfunktion für ein rotierendes Werkzeug stellt eine große Herausforderung dar (Dong et al., 2020).

Zusammenfassend gibt es Ansätze, um Kräfte am Antriebsstrang im niedrigen Frequenzbereich zu messen. Dies setzt jedoch Labor-Messsysteme voraus, womit kein skalierbarer Einsatz während der Nutzungsphase möglich ist. Ein Ansatz ist die Berechnung der Kräfte am Antriebsstrang aus Kräften im Werkzeugkontakt mittels eines modellierten Übertragungsverhaltens des Werkzeugs. Die Modellierung des Übertragungsverhaltens eines Werkzeugs beim Schleifen kann durch dynamische Modelle (Phan et al., 2020) oder durch Übertragungsfunktion (Dong et al., 2020) erfolgen.

## 2.5 Fazit zu Grundlagen und Stand der Forschung

Für die Produktentwicklung wird die Produktnutzung durch Informationen zur Produktnutzung (PUI) mittels Nutzungselementen mit definierten Parametern oder Zuständen charakterisiert. PUI können direkt gemessen oder aus Sensordaten abgeleitet werden. Für die messtechnische Erfassung der PUI in der Nutzungsphase besteht der Bedarf, Ansätze für die unbeobachtete Erfassung und Analyse von PUI mit skalierbarem Aufwand zu entwickeln.

Zur Erfassung von Parametern und Zuständen von Nutzungselementen, die nur schwer oder gar nicht messbar sind, kann der Ansatz des virtuellen Sensors genutzt werden. Für die Anwendung eines virtuellen Sensors müssen Modelle gebildet und validiert werden. Die dafür notwendigen Eingangsgrößen können mit einem Sensormodul gemessen werden. Das Sensormodul ermöglicht es, die Integration eines in ein Produkt eingebetteten Informationsmoduls (PEID) in wissenschaftlichen Studien oder in den frühen Phasen der Produktentwicklung abzubilden. Somit ermöglicht die Verwendung eines Sensormoduls für einen virtuellen Sensor die unbeobachtete Erfassung und Analyse von PUI mit skalierbarem Aufwand. Es fehlt jedoch an Wissen, um Modelle zur Vorhersage von Nutzungselementen aus Sensordaten für virtuelle Sensoren zu bilden und zu validieren.

Beim Schleifen mit Power-Tools sind drei relevante Nutzungselemente die durchgeführte Tätigkeit, die Kräfte im Werkzeugkontakt und die Kräfte am Antriebsstrang. Es gibt bisher keine validierten Ansätze für die unbeobachtete Erfassung der durchgeführten Tätigkeit und der quantitativen Kraft im Werkzeugkontakt während der Nutzungsphase in alle drei Raumrichtungen mit skalierbarem Aufwand. Weiter gibt es für die Kräfte am Antriebsstrang keinen Ansatz, um diese unbeobachtet und skalierbar während der Nutzungsphase zu erfassen. Die Modellierung des Übertragungsverhaltens eines Werkzeugs würde die Berechnung der Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt ermöglichen.





### 3 Motivation und Zielsetzung

Um eine breite Informationsbasis für die Produktentwicklung zu schaffen, sind Lösungen zur unbeobachteten und skalierbaren Datenerfassung und Informationsgewinnung während der Nutzungsphase notwendig. Von besonderem Interesse für die Produktentwicklung sind PUI, die durch Nutzungselemente beschrieben werden können. Wie der Stand der Forschung zeigt, bietet der Ansatz der virtuellen Sensoren eine skalierbare Lösung für die unbeobachtete Erfassung von Nutzungselementen.

Virtuelle Sensoren stützen sich auf mathematische Modelle und Sensordaten von physisch vorhandenen Sensoren. Der Einsatz eines Sensormoduls ermöglicht die Integration von Sensoren, wie sie in der Nutzungsphase durch PEID vorliegen. Das Sensormodul bildet zusammen mit einem mathematischen Modell einen virtuellen Sensor. Die Implementierung von Modellen für einen virtuellen Sensor ist in Abhängigkeit des Systems auf vielfältige Weise möglich. Es braucht jedoch systemspezifisches Wissen für die Bildung und Validierung von Modellen, um aus Sensordaten in Abhängigkeit des Systems das Nutzungselement vorherzusagen.

Ein Beispiel für Produkte, bei denen ein Bedarf nach einer unbeobachteten und skalierbaren Datenerfassung von PUI besteht, sind Power-Tools, die zum Schleifen eingesetzt werden. Relevante Nutzungselemente sind die durchgeführte Tätigkeit, die Kräfte im Werkzeugkontakt und die Kräfte am Antriebsstrang. Das am häufigsten eingesetzte Power-Tool zum Schleifen, mit dem verschiedene Tätigkeiten ausgeführt werden können, ist der Winkelschleifer (Schweizer, 2005), der daher als Beispielsystem für diese Forschungsarbeit dient. Das Verhalten eines Winkelschleifers unterscheidet sich vor allem durch Tätigkeiten mit unterschiedlichen Werkzeugen, wie *Trennen mit einer Trennscheibe* und *Schleifen mit einer Fächerschleifscheibe*. Daher ist die Kenntnis der mit verschiedenen Werkzeugen durchgeführten Tätigkeit notwendig, um separate Modelle für einen virtuellen Sensor zur Erfassung der Kräfte im Werkzeugkontakt und am Antriebsstrang bilden und wechseln zu können. Es fehlt jedoch Wissen, wie Modelle für virtuelle Sensoren für diese drei Nutzungselemente bei Winkelschleifern gebildet und validiert werden können. Daraus folgt die Zielsetzung:

Das Ziel dieser Forschungsarbeit sind die Bildung und Validierung von Modellen für virtuelle Sensoren zur Erfassung der durchgeführten Tätigkeit, der Kräfte im Werkzeugkontakt und der Kräfte am Antriebsstrang aus Sensordaten eines Sensormoduls bei Winkelschleifern.



## 4 Forschungsdesign

In diesem Kapitel wird das Forschungsdesign bestehend aus Forschungsfragen und dem Vorgehen zu deren Beantwortung beschrieben. Aus dem Ziel, Modelle für virtuelle Sensoren zur Vorhersage der durchgeführten Tätigkeit, der Kräfte im Werkzeugkontakt und der Kräfte am Antriebsstrang zu bilden und zu validieren, ergibt sich die folgende übergeordnete Forschungsfrage:

**Übergeordnete Forschungsfrage:** Wie können durch Modelle für virtuelle Sensoren die Nutzungselemente ausgeführte Tätigkeit, Kräfte im Werkzeugkontakt und Kräfte auf den Antriebsstrang bei Winkelschleifern anhand von Sensordaten erfasst werden?

Zur Beantwortung der übergeordneten Forschungsfrage werden drei Forschungsfragen mit je zwei Teilforschungsfragen definiert. Jede Forschungsfrage ist einem Nutzungselement zugeordnet. Die Forschungsfragen lauten:

**Forschungsfrage 1:** Wie lässt sich bei Winkelschleifern die durchgeführte Tätigkeit anhand von Sensordaten durch statistische Modelle vorhersagen?

**Teilforschungsfrage 1.1:** Welches Verfahren ist geeignet, um die Vorhersage der ausgeübten Tätigkeit unter starkem Störgrößeneinfluss zu bewerten?

**Teilforschungsfrage 1.2:** Welche statistischen Modelle eignen sich zur Vorhersage der durchgeführten Tätigkeit anhand von Sensordaten?

**Forschungsfrage 2:** Wie lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt anhand von Sensordaten durch statistische Modelle vorhersagen?

**Teilforschungsfrage 2.1:** Für welche Krafrichtungen und Tätigkeiten lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt anhand von Sensordaten durch statistische Modelle vorhersagen?

**Teilforschungsfrage 2.2:** Mit welcher Abtastrate lassen sich die Kräfte im Werkzeugkontakt aus Sensordaten vorhersagen?

**Forschungsfrage 3:** Wie lassen sich bei Winkelschleifern mittels Übertragungsfunktionen die Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt berechnen?

**Teilforschungsfrage 3.1:** Wie gut lassen sich Übertragungsfunktionen verschiedener Arbeitspunkte eines Werkzeugs zu einer arbeitspunktunabhängigen Übertragungsfunktion zusammenführen?

**Teilforschungsfrage 3.2:** Wie unterscheiden sich die mit der Übertragungsfunktion berechneten Kräfte am Antriebsstrang von den Kräften im Werkzeugkontakt?

Eingangsgrößen für die Modelle sind Sensordaten, die in einem PEID während der Nutzungsphase gemessen werden können. Der Einsatz eines Sensormoduls demonstriert die Nutzung eines virtuellen Sensors, der Sensordaten von einem PEID verwendet, für das Schleifen mit Power-Tools. Als Hardwaresensoren und MEMS-Sensoren, die üblicherweise auch in einem PEID verwendet werden, werden eine IMU, ein Stromsensor und ein Spannungssensor verwendet.

Die Modelle werden miteinander vernetzt, um die Abhängigkeiten zwischen den Nutzungselementen abzubilden. Durch die Vernetzung können die Modelle Ausgangsgrößen anderer Modelle als Eingangsgrößen zusätzlich zu den Sensordaten des Sensormoduls verwenden. Die Modelle der Forschungsfrage 2 verwenden Ausgangsgrößen aus den Modellen der Forschungsfrage 1 als Eingangsgrößen. Die Modelle der Forschungsfrage 3 verwenden Ausgangsgrößen aus den Modellen der Forschungsfrage 1 und der Forschungsfrage 2 als Eingangsgrößen.

Das Vorgehen zur Beantwortung der übergeordneten Forschungsfrage und die Zusammenhänge zwischen den Forschungsfragen sind in Abbildung 4.1 dargestellt. In dem Vorgehen sind die zu bildenden Modelle, die Eingangsgrößen und die Ausgangsgrößen der Modelle sowie Forschungsinhalte dargestellt.

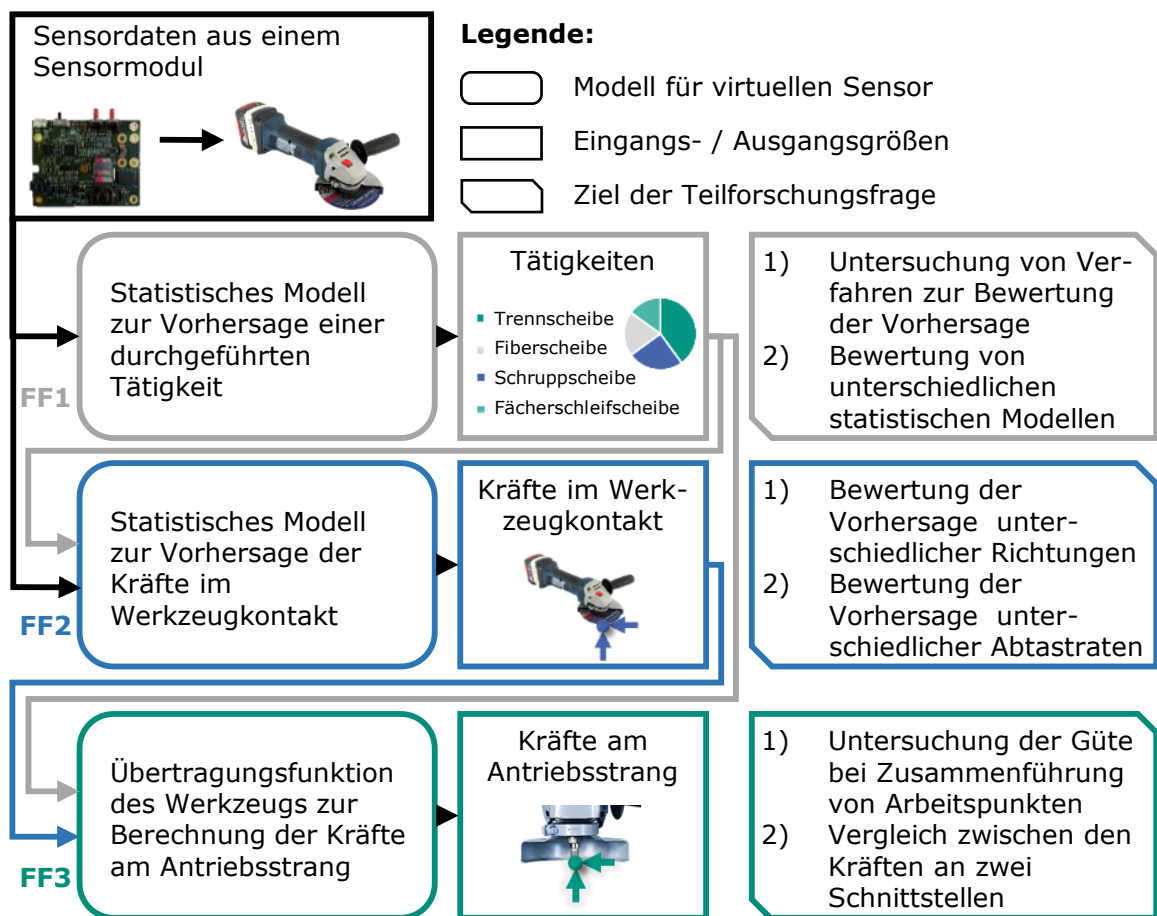


Abbildung 4.1: Forschungsdesign zur Erreichung der Zielsetzung

Forschungsfrage 1 zielt auf die Bildung von Modellen zur Vorhersage der durchgeführten Tätigkeit auf der Grundlage von Sensordaten ab. Im ersten Schritt wird ein Sensormodul entwickelt. In einem zweiten Schritt wird eine manuelle Studie durchgeführt, um Sensordaten für verschiedene Tätigkeiten zu generieren. Darauf erfolgt die Modellentwicklung in Form von statistischen Modellen mittels Machine-Learning auf Basis der Sensordaten. Zur Beantwortung von Teilforschungsfrage 1.1 wird untersucht, welches Verfahren sich zur Bewertung der Vorhersage der durchgeführten Tätigkeit unter starkem Einfluss von Störgrößen eignet, wie sie bei Winkelschleifern beispielsweise durch die anwendende Person oder durch den Verschleiß des Werkzeugs vorliegen. Dazu wird die Bildung des Validierungsdatensatzes variiert. In Teilforschungsfrage 1.2 wird untersucht, welche statistischen Modelle sich zur Vorhersage der durchgeführten Tätigkeit eignen. Dazu wird die Genauigkeit der Vorhersage der durchgeführten Tätigkeiten zwischen verschiedenen Modellen verglichen. Das angestrebte Ergebnis dieser Forschungsfrage sind statistische Modelle, mit denen die durchgeführte Anwendung mit hoher Genauigkeit vorhergesagt werden kann. Die Kenntnis der durchgeführten

Tätigkeit ist für die Modelle von Forschungsfrage 2 und Forschungsfrage 3 notwendig.

Forschungsfrage 2 zielt auf die Entwicklung von statistischen Modellen zur Vorhersage der Kräfte im Werkzeugkontakt auf der Grundlage von Sensordaten ab. Es wird ein Messaufbau zur Messung der Kräfte im Werkzeugkontakt entwickelt und eine manuelle Studie durchgeführt, um Kräfte im Werkzeugkontakt in alle Raumrichtungen zu erfassen. Dazu werden individuelle statistische Modelle für alle drei Krafrichtungen gebildet. Da sich das Verhalten von Winkelschleifern für verschiedene Tätigkeiten unterscheidet, werden die Modelle getrennt für die Tätigkeiten gebildet. In Teilforschungsfrage 2.1 wird untersucht, für welche Krafrichtungen und Tätigkeiten die Vorhersage der Kräfte im Werkzeugkontakt aus Sensordaten möglich ist. Dazu werden Bewertungsgrößen für verschiedene Krafrichtungen und Tätigkeiten verglichen. Messdaten in Form von Zeitreihen, die Kräfte beschreiben, können mit unterschiedlicher Abtastfrequenz bereitgestellt werden. Je höher die Abtastfrequenz ist, desto mehr dynamische Phänomene beinhalten die Messdaten. Das aktive Verhalten einer anwendenden Person, das die ihre Kräfte und Bewegungen durch Muskelaktivität beschreibt, umfasst die Kräfte bis zu einer Abtastfrequenz von 10 Hz (Kern, 2009; Lindenmann, 2022). Daher wird in Teilforschungsfrage 2.2 untersucht, mit welcher Abtastrate<sup>2</sup> sich die Kräfte im Werkzeugkontakt aus Sensordaten mit hoher Genauigkeit vorhersagen lassen. Dazu werden die Abtastraten 1 Hz, 10 Hz und 20 Hz untersucht. Das angestrebte Ergebnis dieser Forschungsfrage sind statistische Modelle, mit denen die Kräfte im Werkzeugkontakt mit unterschiedlicher Abtastrate bestimmt werden können. Die Kenntnis der Kräfte im Werkzeugkontakt ist für Forschungsfrage 3 notwendig, um daraus die Kräfte am Antriebsstrang vorherzusagen.

Forschungsfrage 3 zielt auf die Berechnung der Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt ab. Dazu wird das Übertragungsverhalten von unterschiedlichen Werkzeugtypen modelliert. Bei höherfrequenten Kräften und weniger steifen Werkzeugen, wie sie bei Winkelschleifern verwendet werden, kann nicht von einem frequenzunabhängigen Übertragungsverhalten vom Werkzeugkontakt zum Antriebsstrang ausgegangen werden (Dong et al., 2020). Im Stand der Forschung wurde beispielsweise durch (A. Lim et al., 2013) aufgezeigt, dass Übertragungsfunktionen zur Modellierung des Übertragungsverhaltens eingesetzt werden können. Um die Übertragungsfunktionen eines Werkzeugs bei hoher Drehzahl robust vorherzusagen, eignet sich eine Messung bei konstanten

---

<sup>2</sup> Zur klaren Trennung wird im Rahmen dieser Forschungsarbeit der Begriff Abtastfrequenz für die gemessenen unabhängigen Variablen und der Begriff Abtastrate für die vorherzusagenden abhängigen Variablen verwendet.

Bedingungen eines Arbeitspunktes auf einem Prüfstand. Dabei bleibt unklar, ob gemessene Übertragungsfunktionen eines Werkzeugs nur für den untersuchten Arbeitspunkt oder für einen größeren Arbeitsbereich gültig sind. Daher wird in Teilforschungsfrage 3.1 untersucht, mit welcher Güte sich die Übertragungsfunktionen verschiedener Arbeitspunkte eines Werkzeugs zu einem Modell zusammenführen lassen. Dazu wird die Abweichung zwischen den Übertragungsfunktionen unterschiedlicher Arbeitspunkte analysiert. Die Zusammenführung ermöglicht die Anwendung einer Übertragungsfunktion über einen breiteren Arbeitsbereich. Bei der Anwendung der zusammengeführten Übertragungsfunktionen der Werkzeuge bleibt unklar, in welchem Maße sich die Kräfte durch das frequenzabhängige Übertragungsverhalten des Werkzeugs verändern. Daher wird in Teilforschungsfrage 3.2 untersucht, wie sich die Kraftwerte im Werkzeugkontakt von den Kraftwerten am Antriebsstrang unterscheiden. Der Vergleich ermöglicht eine Aussage darüber, inwieweit die Modellierung eines Werkzeugs angesichts des damit verbundenen Aufwands für die Berechnung der Kräfte am Antriebsstrang von Nutzen ist. Das angestrebte Ergebnis dieser Forschungsfrage sind Modelle in Form von Übertragungsfunktionen, mit denen die Kräfte am Antriebsstrang durch ein modelliertes Übertragungsverhalten von Werkzeugen aus den Kräften im Werkzeugkontakt berechnet werden können.

Die Bildung und Validierung der Modelle der drei Forschungsfragen, die Verwendung eines Sensormoduls und die Vernetzung der Modelle, wie in Abbildung 4.1 dargestellt, ermöglichen die Beantwortung der übergeordneten Forschungsfrage.





## 5 Erfassung der durchgeführten Tätigkeit

In diesem Kapitel werden statistische Modelle gebildet, um die durchgeführte Tätigkeit aus Sensordaten vorherzusagen. Die Vorhersage der durchgeführten Tätigkeit als Nutzungselement ermöglicht unter anderem eine sinnvolle Auswertung von Sensordaten aus der unbeobachteten Erfassung während der Nutzungsphase (Lehmhus et al., 2015). Zudem stellt sie den Kontext für die Modelle aus Forschungsfrage 2 und Forschungsfrage 3 bereit, damit diese in Abhängigkeit der vorhergesagten Tätigkeit getauscht werden können.

Dieses Kapitel beschäftigt sich mit Forschungsfrage 1:

**Forschungsfrage 1:** Wie lässt sich bei Winkelschleifern die durchgeführte Tätigkeit anhand von Sensordaten durch statistische Modelle vorhersagen?

Durch die Beantwortung der Forschungsfrage soll aufgezeigt werden, wie die Vorhersage der Tätigkeit erfolgt. Hierfür sind, wie im Stand der Forschung aufgezeigt, virtuelle Sensoren geeignet. Diese können statistische Modelle verwenden, die mittels Machine-Learning parametrisiert werden. Als Eingangsgrößen für die Modelle werden Sensordaten von einem Sensormodul mit einer IMU, einem Stromsensor und einem Spannungssensor mit einer Abtastfrequenz von 1000 Hz verwendet. Wie in den Grundlagen 2.1.2 aufgezeigt, werden für die Bewertung der Vorhersage unterschiedliche Verfahren umgesetzt.

Daher gliedert sich Forschungsfrage 1 in Teilforschungsfrage 1.1 und Teilforschungsfrage 1.2:

**Teilforschungsfrage 1.1:** Welches Verfahren ist geeignet, um die Vorhersage der ausgeübten Tätigkeit unter starkem Einfluss von Störgrößen zu bewerten?

**Teilforschungsfrage 1.2:** Welche statistischen Modelle eignen sich zur Vorhersage der durchgeführten Tätigkeit anhand von Sensordaten?

Nachfolgend werden in Kapitel 5.1 der Versuchsaufbau und die Modellbildung vorgestellt.

*Der Versuchsaufbau, die Modellbildung, die Ergebnisse und die Diskussion dieses Kapitels basieren zu Teilen auf der nachfolgenden Veröffentlichung:*

- „Activity Recognition With Machine Learning in Manual Grinding“ (Dörr, Spoden et al., 2022)

*Teile des folgenden Textes sind ohne Veränderung in übersetzter Form aus der Veröffentlichung übernommen. Sie werden aus Gründen der Übersichtlichkeit nicht gesondert gekennzeichnet.*

## **5.1 Versuchsaufbau und Modellbildung**

Das folgende Kapitel beschreibt die manuelle Studie einschließlich der verwendeten Sensormodule, die Verarbeitung der Sensordaten und das Vorgehen bei der Modellbildung.

### **5.1.1 Manuelle Studie**

Die Planung und Durchführung einer Studie zur Generierung der Daten bilden die Grundlage für die Modellbildung (Kocijan, 2016). Daher ist das übergeordnete Ziel der manuellen Studie, Sensordaten eines Winkelschleifers als unabhängige Variablen für ein Modell zur Vorhersage der durchgeführten Tätigkeit zu generieren.

Nach Kocijan (2016) muss eine manuelle Studie für die Erfassung von unabhängigen und abhängigen Variablen zur Bildung und Validierung eines statistischen Modells so durchgeführt werden, dass anhand dieser Variablen Datensätze generiert werden, die den zu untersuchenden Arbeitsbereich des Systems beschreiben. Daraus folgt das Ziel für die manuelle Studie, Faktoren und Störgrößen zu berücksichtigen, die bei der Nutzung eines Winkelschleifers auftreten. Dies beinhaltet eine Versuchsdurchführung, bei der sich die Versuche untereinander unterscheiden sollen. Die durchgeführte Tätigkeit soll als abhängige Variable, wie in den Grundlagen in Kapitel 2.1.2 beschrieben, möglichst gleich verteilt sein.

In der manuellen Studie wurde ein breiter Arbeitsbereich durch die Integration von Störgrößen und durch die Verwendung von zwei Winkelschleifern abgebildet, aufgeteilt in vier verschiedene Tätigkeiten von drei anwendenden Personen. Folgende Tätigkeiten wurden durchgeführt: *Trennen mit einer Trennscheibe*, *Schruppen mit einer Schrupscheibe*, *Schruppen mit einer Fiberscheibe* und *Schleifen mit einer Fächerschleifscheibe*. Abbildung 5.1 zeigt die vier verschiedenen Tätigkeiten und die zugehörigen Werkzeuge.



Abbildung 5.1: In der Studie wurden vier Tätigkeiten mit unterschiedlichen Werkzeugen durchgeführt. In Anlehnung an Dörr, Ott et al. (2021, S. 4)

Die Tätigkeit *Trennen mit einer Trennscheibe* wurde mit einer Korund-Trennscheibe durchgeführt. Dabei wurde eine flache Stahlprobe mit den Abmessungen 80 mm x 80 mm x 10 mm mittig getrennt. Die Tätigkeit *Schruppen mit einer Schruppscheibe* wurde mit einer Korund-Schruppscheibe durchgeführt. Die Tätigkeit *Schruppen mit einer Fiberscheibe* wurde mit einer Fiberscheibe mit Keramik-Schleifkorn durchgeführt. Für beide Tätigkeiten wurde eine schmale Stahlprobe mit den Abmessungen 200 mm x 10 mm x 80 mm entlang der Kanten bearbeitet, um die Bearbeitung einer Schweißnaht abzubilden. Die Tätigkeit *Schleifen mit Fächerschleifscheibe* wurde mit einer Fächerschleifscheibe mit Zirkonkorund in konischer Ausführung auf einer Flachstahlprobe von 120 mm x 80 mm x 10 mm mit kreisförmigen Bewegungen durchgeführt.

Für die experimentelle Untersuchung wurden akkubetriebene Winkelschleifer von zwei verschiedenen Herstellern verwendet, der GWS18 (GWS18-125 V-LI, Robert Bosch Power-Tools GmbH, Leinfelden-Echterdingen, Deutschland) und der CCG18 (CCG18-125 BL, C. & E. Fein GmbH, Schwäbisch Gmünd, Deutschland). Beide Winkelschleifer benötigen für die Nutzung 18-Volt-Akkus.

Beim *Trennen mit einer Trennscheibe* wurde der Versuch nach vier Trennvorgängen beendet, was einer gesamten Dauer von etwa drei Minuten entspricht. Bei den Tätigkeiten *Schruppen mit einer Schruppscheibe*, *Schruppen mit einer Fiberscheibe* und *Schleifen mit einer Fächerschleifscheibe* wurde der Versuch nach vier bis fünf Minuten Bearbeitungszeit abgebrochen. Die Werkstücke wurden je nach Materialabtrag nach einem oder zwei Versuchen gewechselt. Die Werkzeuge wurden nach einem oder zwei Versuchen ausgetauscht. Der Akku des Winkelschleifers wurde während der Versuche oder zwischen ihnen gewechselt, um einen realitätsnahen Arbeitsprozess darzustellen. Dies führte zu Unterbrechungen

und unterschiedlichen gemessenen Spannungswerten. Aufgrund der langen Versuchsdauer führte die von den Winkelschleifern erzeugte Wärme in der Maschine in mehreren Versuchen zu einer kurzen Abschaltung oder sogar zum Abbruch des Versuchs. Diese Störgrößen wurden bewusst eingebracht, um die externe Validität der Versuche zu erhöhen, da sie dem realitätsnahen Einsatz von Winkelschleifern in der Nutzungsphase entsprechen.

Neben dem eigentlichen Schleifprozess gibt es bei der Nutzung eines Winkelschleifers auch Phasen, in denen nicht geschliffen wird. Daher wird zusätzlich zu den vier Tätigkeiten mit verschiedenen Werkzeugen die Klasse *Kein Werkzeugkontakt* eingeführt. Diese besteht aus allen weiteren Tätigkeiten und Schritten, die vor, nach und manchmal auch während des eigentlichen Schleifprozesses stattfinden. Die Klasse *Kein Werkzeugkontakt* umfasst somit die gesamte Zeit, in der der Winkelschleifer bewegt wird, mit Leerlaufdrehzahl läuft und ein- oder ausgeschaltet wird. Die restlichen vier Tätigkeiten mit verschiedenen Werkzeugen umfassen nur die Zeit, in der das Werkzeug in Kontakt mit dem Werkstück ist und dabei das Werkstück geschliffen wird.

Bei zwei von drei anwendenden Personen wurde die Messung vor dem eigentlichen Schleifprozess gestartet und nach dem Schleifprozess gestoppt. Daher enthalten diese Versuche eine Kombination aus einer Tätigkeit und, in geringerem Umfang, aus der Klasse *Kein Werkzeugkontakt*. Die in den Versuchen aufgenommene Klasse *Kein Werkzeugkontakt* beschränkt sich, wie in einer realitätsnahen Nutzung üblich, auf einen Einschaltvorgang, einen Ausschaltvorgang und eine geringe Zeitspanne im Leerlaufbetrieb. In der Klasse *Kein Werkzeugkontakt* sind der Einschaltvorgang und die Leerlaufzeit schwieriger zu erkennende Phänomene als der Zeitraum, in dem der Winkelschleifer nicht in Betrieb ist. So liegt beispielsweise beim Anlaufen des Motors die höchste Stromspitze der gesamten Nutzung vor. Daher wurde eine dritte anwendende Person gebeten, diese Vorgänge gezielt in zwei getrennten Versuchen durchzuführen, um Trainingsdatensätze mit schwieriger zu erkennenden Phänomenen für die Vorhersage der Klasse *Kein Werkzeugkontakt* zu erzeugen. Zur Kompensation der zwei getrennten Versuche wurde bei der dritten anwendenden Person nur während des eigentlichen Schleifprozesses gemessen, ohne die Klasse *Kein Werkzeugkontakt* vor und nach dem Schleifprozess. Damit wurde sichergestellt, dass die Klasse *Kein Werkzeugkontakt* über alle anwendenden Personen besser verteilt ist.

Zur Erfassung der Sensordaten wurden die im folgenden Kapitel 5.1.2 vorgestellten Sensormodule verwendet. Aufgrund mangelnder Verfügbarkeit wurden drei verschiedene Varianten von Sensormodulen in der Studie verwendet. Aufgrund unterschiedlicher verbauter IMU resultierten hieraus verschiedene Abtastraten.

Die drei vorgestellten Werkstücke wurden auf zwei verschiedenen Versuchsaufbauten montiert. Der erste Versuchsaufbau T1 ist in Abbildung 5.1 und Abbildung 6.1 in Kapitel 6.1.1 dargestellt. Bei diesem Versuchsaufbau wurde eine statische Soll-Andruckkraft von 25 N vorgegeben, die während des Versuchs auf einem Bildschirm angezeigt wurde. Beim Versuchsaufbau T2 lag keine Kraftvorgabe vor. An beiden Versuchsaufbauten können unterschiedliche Stahlproben befestigt werden, um die vier Tätigkeiten auszuführen. Beide akkubetriebenen Winkelschleifer GWS18 und CCG18 sind einschließlich ihres Sensormoduls mit dem Versuchsaufbau T2 in Abbildung 5.2 dargestellt.



Abbildung 5.2: CCG18 mit Sensormodul und Versuchsaufbau T2 mit dem Werkstück zur Tätigkeit *Schleifen mit einer Fächerschleifscheibe* (a) und GWS18 mit Sensormodul und Versuchsaufbau T2 mit dem Werkstück zur Tätigkeit *Schruppen mit einer Schrappscheibe* (b). (Dörr, Spoden et al., 2022, S. 3)

Anhand der drei anwendenden Personen und zwei Winkelschleifer lassen sich die Versuche durch sechs Versuchscluster beschreiben. Die wesentlichen Aspekte dieser Versuchscluster zur Erfassung von Messdaten bei verschiedenen Versuchen sind in Tabelle 5.1 zusammengefasst. Die verwendeten Sensormodule werden in Kapitel 5.1.2 vorgestellt. Es wurden für jede Maschine insgesamt 26 Versuche durchgeführt, wobei zwei Versuche nur die Klasse *Kein Werkzeugkontakt* enthielten.

Tabelle 5.1: Versuchscluster in Bezug auf Merkmale der Versuche innerhalb des Studiendesigns zur Erfassung von Messdaten abweichender Versuche. In Anlehnung an Dörr, Spoden et al. (2022, S. 3)

<b>Versuchscluster</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
Winkelschleifer	GWS18	GWS18	GWS18	CCG18	CCG18	CCG18
Anwendende Person	1	2	3	1	2	3
Sensormodul	G1	G1	G2	C1	C1	C1
Abtastfrequenz in Hz	1000	1000	300	1000	1000	1000
Testaufbau	T2	T1	T2	T2	T1	T2
Versuchszeit in min	26	49	45	51	53	38
Versuche mit Anwendung	2 * 4	2 * 4	2 * 4	2 * 4	2 * 4	2 * 4
Extra-Versuche mit Klasse <i>Kein Werkzeugkontakt</i>	-	-	2	-	-	2

### 5.1.2 Sensormodul

Für die Messung von Sensordaten bei Power-Tools wurde ein Sensormodul entwickelt. Die Details zum Aufbau sind der Veröffentlichung von Dörr, Peters & Matthiesen (2021) zu entnehmen. Das Sensormodul besteht aus einer selbst entwickelten Leiterplatte und einem Gehäuse, das zwischen Maschine und Akku eingesetzt wird. Die Leiterplatte und das Gehäuse sind in Abbildung 5.3 dargestellt.




Abbildung 5.3: Leiterplatte und Gehäuse des Sensormoduls. In Anlehnung an Dörr, Peters & Matthiesen (2021, S. 4) und Helmstetter et al. (2022, S. 11)

Im Rahmen dieser Studie wurden aufgrund mangelnder Verfügbarkeit drei unterschiedliche Sensormodule mit den Bezeichnungen G1, G2 und C1 verwendet. Die Leiterplatte ist mit einem Mikrocontroller und den folgenden Sensoren ausgestattet: Stromsensor zur Messung des Akkustroms, Spannungsteiler zur Messung der Akkuspannung, einer IMU zur Messung der Beschleunigung, der Winkelgeschwindigkeit und des Magnetfeldes sowie einer Echtzeituhr zur Aufnahme des Zeitsignals. Die verwendeten Bauteile und ihre Hersteller sind im Anhang in Tabelle A aufgeführt. Um dynamische und robuste Messungen zu ermöglichen, wurde ein Ringspeicher zum Puffern neuer Sensorwerte verwendet. Die Zeitreihen wurden mit einer Frequenz von 1000 Hz bei den Sensormodulen G1 und C1 und mit 300 Hz für das Sensormodul G2 gemessen und mit einem Zeitstempel auf einer *SD*-Karte gespeichert.

### 5.1.3 Datenverarbeitung

Bei der Datenverarbeitung wurden die Sensorsignale des Versuchsclusters 3 in Tabelle 5.1 durch lineare Interpolation auf 1000 Hz zurückgerechnet. Die Zuordnung zur Klasse *Kein Werkzeugkontakt* erfolgte manuell nach der Datenerfassung anhand des Stromsignals. Die manuelle Zuordnung erfolgte anhand der höheren Stromaufnahme des Winkelschleifers während des Schleifprozesses im Vergleich zum Leerlaufbetrieb.

Die Vorhersage wird unabhängig für jeweils einen zeitlichen Abschnitt der Messsignale realisiert. Diese Signale werden als Segmente bezeichnet. Bei der Bildung der Segmente wurden aufeinanderfolgende gleitende Segmente mit einer Länge von zwei Sekunden und einer Überlappung von 75 % gewählt. Diese Überlappung verspricht im Forschungsfeld HAR eine bessere Genauigkeit (Nurwulan & Jiang, 2020).

In den Versuchsdaten war die Klasse *Kein Werkzeugkontakt* überrepräsentiert (~7500 Segmente). Zudem ist sie aufgrund des geringeren Energiebedarfs am einfachsten zu erkennen. Daher wurde die Anzahl an Segmenten der Tätigkeit *Kein Werkzeugkontakt* auf die Anzahl der Segmente der zweitgrößten Tätigkeit reduziert. Hierzu wurden Segmente zufällig entfernt. Da die Größe der Datensätze der anderen Tätigkeiten ähnlich ist, wurden die Datensätze nicht angeglichen. Dies hätte zu einer Verringerung des Datensatzes geführt. Die Anzahl und die Verteilung der Segmente der fünf Tätigkeiten sind in Tabelle 5.2 dargestellt. Die Abbildung verdeutlicht, dass die Tätigkeiten nun annähernd gleichmäßig verteilt sind.

Tabelle 5.2: Anzahl der Segmente aller Tätigkeiten nach Reduzierung der Segmente der Klasse *Kein Werkzeugkontakt*. In Anlehnung an Dörr, Spoden et al. (2022, S. 3)

<b>Tätigkeit</b>	<b>GWS18</b>	<b>CCG18</b>
Kein Werkzeugkontakt	2559 Segmente	2918 Segmente
<i>Schleifen mit einer Fächerschleifscheibe</i>	2559 Segmente	2918 Segmente
<i>Schruppen mit einer Fiberscheibe</i>	2533 Segmente	2619 Segmente
<i>Schruppen mit einer Schrappscheibe</i>	2528 Segmente	2886 Segmente
<i>Trennen mit einer Trennscheibe</i>	2368 Segmente	2562 Segmente

In einer Vorstudie wurde anhand eines Akkuschraubers und Winkelschleifers gezeigt, dass manuell definierte Merkmale gleichwertig oder besser als automatisiert erhobene Merkmale sind (Dörr, Ries et al., 2019). Daher wurden für diese Studie die 62 Merkmale aus jedem der 11 Sensorsignale extrahiert. Insgesamt wurden 682 Merkmale für jedes Segment erstellt. Diese Merkmale umfassen:

- Summe, Minimum, Maximum, Mittelwert, Median der absoluten Werte,
- Varianz, quadratischer Mittelwert, Interquartilbereich, mehrere Perzentile, Schiefe, Wölbung,
- Nulldurchgangsrate, mittlere Durchgangsrate,
- quadratischer Mittelwert mehrerer Daubechies-Wavelets,
- mittlere Häufigkeit, mediane Häufigkeit,
- Wert der drei höchsten Peaks im Amplitudenspektrum und die
- spektrale Energie in definierten Abschnitten des Amplitudenspektrums zwischen 0,5 Hz bis 25 Hz und 80 Hz bis 150 Hz.



Das Ergebnis der Merkmalsextraktion ist eine Tabelle mit 682 Merkmalen und einer entsprechenden Zuordnung zu einer Tätigkeit für jedes Segment.

#### **5.1.4 Modellbildung und Validierung zur Vorhersage der durchgeführten Tätigkeit**

Power-Tools unterschiedlicher Hersteller können in ihrer Ausprägung voneinander abweichen, beispielsweise in der Gestaltung des Getriebes, des Gehäuses oder des Motors. Daher erfolgt die Modellbildung in dieser Studie für beide Maschinen getrennt. Das bedeutet, dass die Modelle mittels Machine-Learning für einen Winkelschleifer parametrisiert werden und damit nur für diesen Winkelschleifer gültig sind. Ob eine Übertragung auf andere Maschinen möglich ist, wird durch die Verwendung von zwei Winkelschleifern untersucht.

Um Teilforschungsfrage 1.1 zu beantworten, wurden zwei Verfahren zur Bewertung der Vorhersage untersucht: Eine klassische Kreuzvalidierung (CV) und eine Leave-One-Trial-Out-Kreuzvalidierung (LOTO CV). Bei der klassischen CV werden, wie in den Grundlagen 2.1.2 erläutert, die Daten aller Versuche nach dem Zufallsprinzip auf alle Gruppen verteilt. Bei der LOTO CV wird eine Gruppe nur aus den Daten eines Versuchs gebildet. Zur besseren Vergleichbarkeit wurde die Anzahl der Gruppen bei der CV so gewählt, dass sie der Anzahl der Versuche entspricht (26). Der einzige Unterschied zwischen den beiden Verfahren zur Bewertung der Vorhersage besteht also darin, wie die zur Validierung des statistischen Modells verwendete Gruppe aus dem Datensatz gebildet wird. Die Bildung der Gruppen mittels der beiden Verfahren zur Bewertung der Vorhersage ist in Abbildung 5.4 dargestellt.


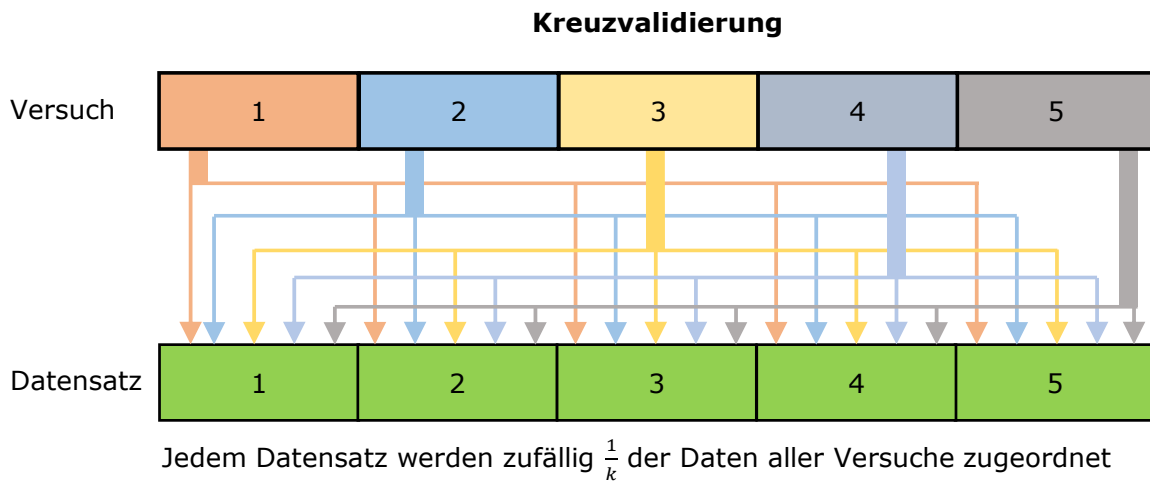


Abbildung 5.4: Bildung der Gruppen bei der Kreuzvalidierung und der Leave-One-Trial-Out-Kreuzvalidierung. In Anlehnung an Dörr, Spoden et al. (2022, S. 4)

Die klassische CV ermöglicht durch die zufällige Aufteilung in Gruppen eine Aussage darüber, ob die Tätigkeiten auf Grundlage der abhängigen Daten (Sensordaten des Sensormoduls) überhaupt vorhergesagt werden können. Versuche beim Schleifen mit Power-Tools weichen aufgrund mangelnder Prozesskonsistenz (Bales et al., 2017) voneinander ab, beispielsweise infolge der in dieser manuellen Studie vorgestellten Störgrößen. Die LOTO CV ermöglicht eine Aussage darüber, wie zuverlässig das gebildete statistische Modell bei unbekanntem Daten abweichender Versuche funktioniert.

Für die Merkmalsselektion wurde der MRMR-Algorithmus (Minimum Redundancy Maximum Relevance) von Ding & Peng (2005) als Filter zur Verbesserung der Genauigkeit und Effizienz sowie zur Vermeidung einer Überanpassung verwendet.

Mit dem MRMR-Algorithmus wurden die 682 extrahierten Merkmale auf die 50 bedeutsamsten Merkmale reduziert.

Für die Parametrierung eines statistischen Modells wurden drei klassische Modelle des Machine-Learnings herangezogen: Ensemble-Methode (EL), k-Nächster-Nachbar-Algorithmus (kNN) und SVM. Diese sind beispielsweise in Bishop (2009) oder Murphy (2013) näher ausgeführt. In dieser Forschungsarbeit beschränken sich die EL auf baumbasierte Modelle, die durch Bagging- oder Boosting-Methoden aggregiert werden.

Zusätzlich zu den genannten Modellen wurde im Rahmen dieser Forschungsarbeit der Ansatz der mehrstufigen binären Klassifikation (MBC) für das Schleifen mit Power-Tools adaptiert. Beim Ansatz der MBC werden mehrere getrennte Modelle verwendet, die eine binäre Unterscheidung zwischen zwei Tätigkeiten vornehmen (Allwein et al., 2000). MBC wurde verwendet, um Domänenwissen in Form einer unterschiedlichen Schwierigkeit bei der Vorhersage einzelner Tätigkeiten zu integrieren. Die Hauptidee besteht darin, die zwei am präzisesten unterscheidbaren Klassen zu ermitteln. So ist es möglich, eine Unterscheidung auf einem niedrigen Detaillierungsgrad mit höherer Genauigkeit und eine Unterscheidung auf hohem Detaillierungsgrad mit niedrigerer Genauigkeit durchzuführen. Die binäre Unterscheidung auf jeder Stufe der MBC wurde mit EL durchgeführt. Die auf das Schleifen mit Power-Tools adaptierte MBC mit den Tätigkeiten oder Klassen ist in Abbildung 5.5 dargestellt.

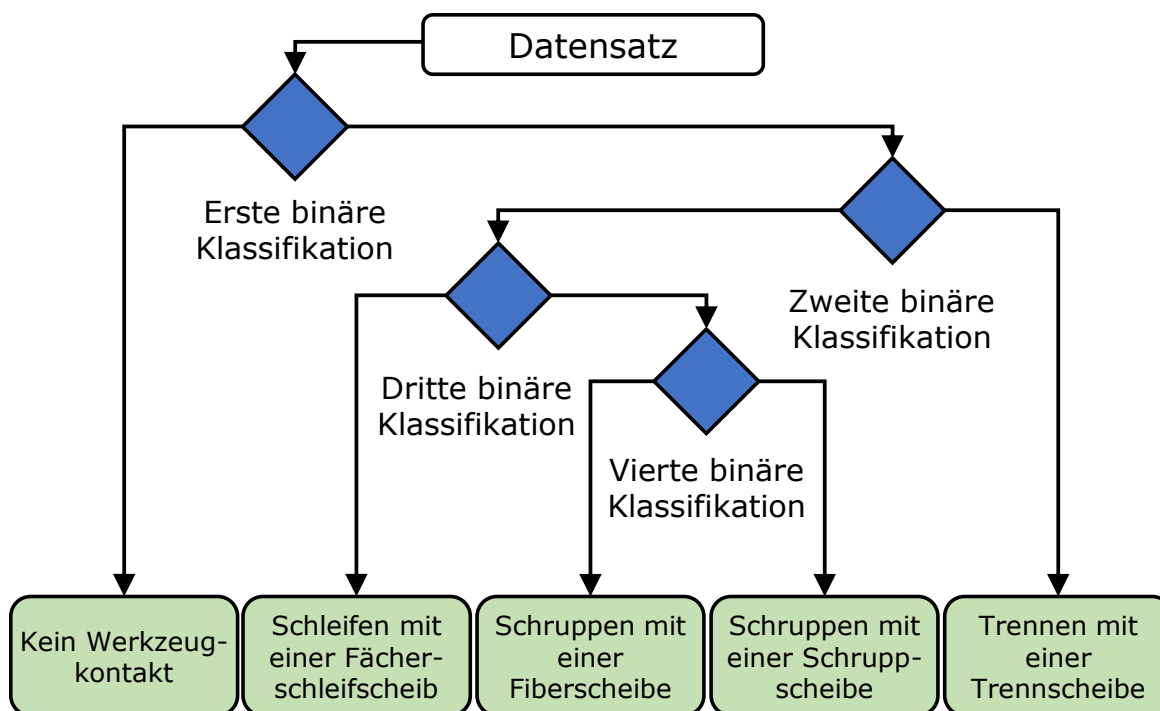


Abbildung 5.5: Auf das Schleifen mit Power-Tools adaptierte mehrstufige binäre Klassifikation. Übersetzt aus Dörr, Spoden et al. (2022, S. 5)

Im Vergleich mit den anderen drei Modellansätzen wird in jeder Stufe eine binäre Unterscheidung durchgeführt, bei der nur die Tätigkeiten berücksichtigt werden, die in einer früheren Stufe nicht erkannt wurden. Die erste Stufe besteht darin, die Klasse *Kein Werkzeugkontakt* von den Tätigkeiten zu trennen, bei denen sich das Werkzeug in Kontakt mit dem Werkstück befindet. Diese binäre Unterscheidung ist die unkomplizierteste, da die Zuordnung wie bei der manuellen Aufbereitung der Daten allein auf der Basis des Stromsignals vorgenommen werden kann. Die zweite Stufe besteht darin, die Tätigkeit *Trennen mit einer Trennscheibe* von den restlichen Tätigkeiten zu trennen. Diese binäre Unterscheidung wurde gewählt, da bei der Tätigkeit *Trennen mit einer Trennscheibe* die Bewegung überwiegend auf einer vertikalen Ebene erfolgt. Die dritte Stufe besteht darin, die Tätigkeit *Schleifen mit einer Fächerschleifscheibe* von den restlichen Tätigkeiten zu trennen. Diese binäre Unterscheidung wurde gewählt, weil die Bewegung beim Schleifen eher zweidimensional ist und oftmals durch kreisförmige Bewegungen erfolgt, während beim Schrumpfen einer Schweißnaht tendenziell eine eindimensionale Bewegung erfolgt. In der vierten und letzten Stufe werden die Tätigkeiten *Schrumpfen mit einer Fiberscheibe* und *Schrumpfen mit einer Schruppscheibe* unterschieden.

Die Hyperparameter-Optimierung erfolgte durch eine automatisierte Naive-Bayes-Hyperparameter-Optimierung. Die Merkmalsselektion und Hyperparameter-Optimierung wurden mit einer verschachtelten CV durchgeführt. Das bedeutet, dass

bei der 26-fachen CV für jeden der Durchgänge jeweils eine innere 10-fache CV für die Merkmalsselektion und die Hyperparameter-Optimierung durchgeführt wurde. Dieses Vorgehen ist in Abbildung 5.6 dargestellt. Innerhalb der Durchgänge sind die Trainingsdatensätze in Grün und die Validierungsdatensatz in Orange dargestellt. Bei der MBC wurde die gesamte verschachtelte CV für jede Stufe durchlaufen.

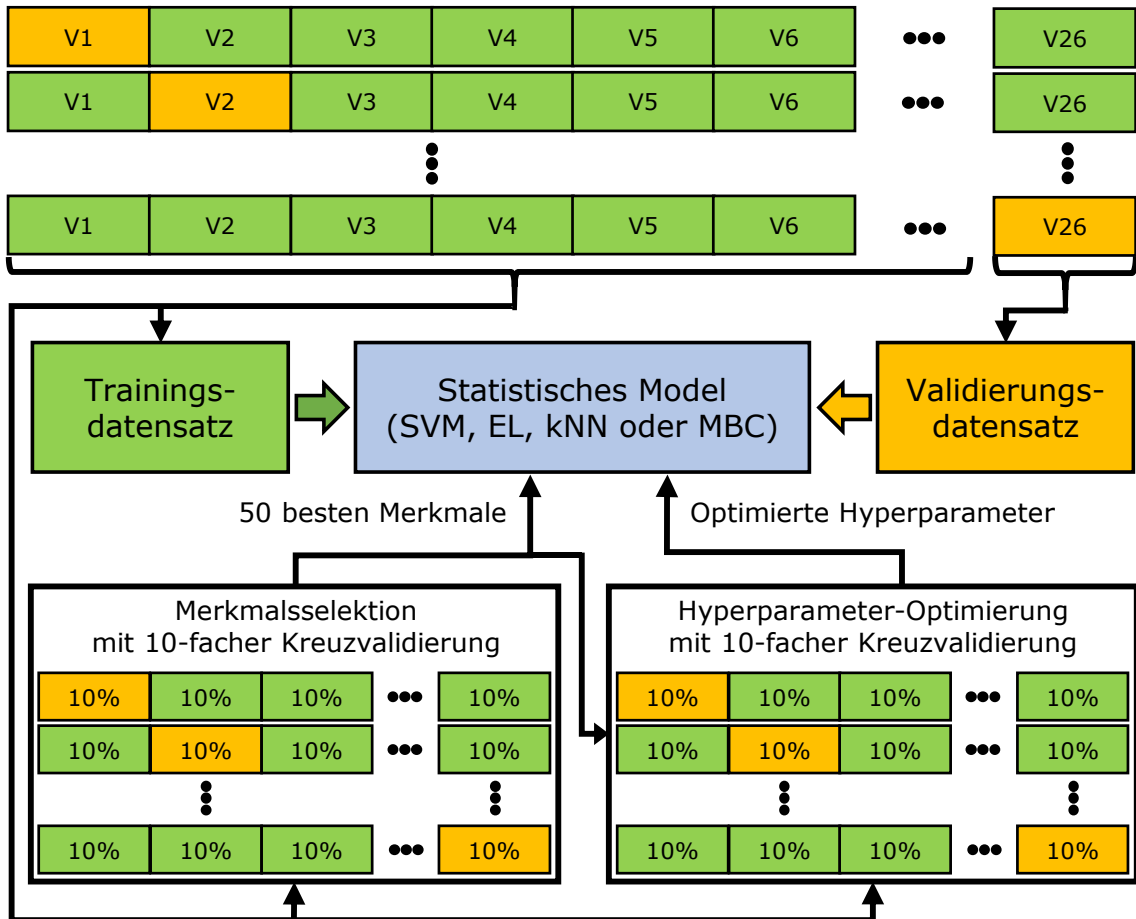


Abbildung 5.6: Vorgehen für die Modellbildung mittels verschachtelter Kreuzvalidierung zur Vorhersage der durchgeführten Tätigkeit. In Anlehnung an Dörr, Spoden et al. (2022, S. 4)

Als Bewertungsgröße wird die in den Grundlagen 2.1.2 vorgestellte Genauigkeit verwendet. Sowohl für die klassische 26-fache CV als auch für die LOTO CV wurden der Mittelwert und die Standardabweichung der Genauigkeit der Gruppen der CV ausgewertet. Die gesamte Datenverarbeitung sowie die Modellbildung erfolgten in MATLAB R2021b (The MathWorks, Vereinigte Staaten).

## 5.2 Ergebnis

Im folgenden Kapitel wird die Genauigkeit der Vorhersage der gewählten statistischen Modelle mit beiden Verfahren zur Bewertung der Vorhersage vorgestellt. Die Ergebnisse der klassischen 26-fachen CV und der LOTO CV mit beiden Winkelschleifern sind in Tabelle 3 dargestellt. Die linke Seite der Tabelle beinhaltet die Ergebnisse für den Winkelschleifer GWS18 und die rechte Seite für den Winkelschleifer CCG18. Der Mittelwert und die Standardabweichung (*SD*) der Genauigkeit sind für alle vier Modelle in Prozent angegeben. Beim GWS18 liegt die mittlere Genauigkeit zwischen 94,91 % und 98,09 % für die 26-fache CV und zwischen 62,76 % und 72,29 % für die LOTO CV. Die höchste Genauigkeit (Mittelwert = 98,09 %, *SD* = 0,49 %) wird für die 26-fache CV mit MBC erreicht. Beim Winkelschleifer CCG18 liegt die mittlere Genauigkeit zwischen 86,29 % und 97,5 % für die 26-fache CV und zwischen 60,65 % und 71,49 % für die LOTO CV. Die höchste Genauigkeit (Mittelwert = 97,5 %, *SD* = 0,84 %) wird für die 26-fache CV mit EL erreicht.

Tabelle 5.3: Genauigkeit der Klassifikation für verschiedene statistische Modelle für zwei Winkelschleifer bei 26-facher CV und bei der LOTO CV. Übersetzt aus Dörr, Spoden et al. (2022, S. 4)

Modell	Winkelschleifer GWS18		Winkelschleifer CCG18	
	CV	LOTO CV	CV	LOTO CV
EL	97.87 % (0.49 %)	72.29 % (31.06 %)	97.50 % (0.84 %)	68.67 % (35.17 %)
kNN	94.55 % (1.45 %)	62.76 % (28.96 %)	89.21 % (2.32 %)	61.84 % (31.36 %)
SVM	94.91 % (2.02 %)	68.08 % (26.98 %)	86.29 % (4.66 %)	60.65 % (29.23 %)
MBC	98.09 %	69.89 %	97.11 %	71.49 %

Die Genauigkeit der Klassifikation der einzelnen Stufen der MBC, die in Abbildung 5.4 dargestellt sind, ist in Tabelle 5.4 aufgeführt. Die Darstellung der Einzelgenauigkeiten der vier Stufen des MBC erfolgt für die LOTO CV für beide Winkelschleifer mit der EL. Die Klasse *Kein Werkzeugkontakt* kann mit einer Genauigkeit von 98,42 % am besten von den anderen Tätigkeiten unterschieden werden. Die binäre Klassifikation in der vierten Stufe zwischen *Schruppen mit einer Fiberscheibe* und *Schruppen mit einer Schrupscheibe* hat mit einer Genauigkeit von 75,82 % die geringste Genauigkeit.

Tabelle 5.4: Genauigkeit der Klassifikation der einzelnen Stufen der mehrstufigen binären Klassifikation (MBC) mittels LOTO CV. In Anlehnung an Dörr, Spoden et al. (2022, S. 5)

<b>Winkel- schleifer</b>	<b>1. Stufe MBC</b>	<b>2. Stufe MBC</b>	<b>3. Stufe MBC</b>	<b>4. Stufe MBC</b>
GWS18	98.52% (2.69 %)	96.41% (11.42 %)	76.91% (37.05 %)	70.90 % (35.94 %)
CCG18	98.33% (3.69 %)	99.02% (2.18 %)	69.77% (32.27 %)	80.73 % (26.13 %)
Mittelwert	98.42 % (3.19 %)	97.71 % (6.80 %)	73.34 % (34.66 %)	75.82 % (31.03 %)

### 5.3 Diskussion

In diesem Kapitel erfolgt der Vergleich der Ergebnisse mit dem Stand der Forschung aus Kapitel 2.4.1. Zudem werden die Beantwortung von Teilforschungsfrage 1.1 und Teilforschungsfrage 1.2 sowie die Übertragbarkeit der Forschungsergebnisse diskutiert.

#### 5.3.1 Vergleich der Ergebnisse mit dem Stand der Forschung

In der Studie von Voet et al. (2019) wurde bei der binären Unterscheidung zwischen der Tätigkeit *Schleifen* und der Klasse *Kein Werkzeugkontakt* eines Geradschleifers mittels CV eine hohe Genauigkeit von 93,15 % erreicht. Wie aus den Ergebnissen dieser Forschungsarbeit zur ersten Stufe der MBC in Tabelle 5.4 hervorgeht, ergibt sich für die Unterscheidung zwischen allen Tätigkeiten und der Klasse *Kein Werkzeugkontakt* mittels LOTO CV eine höhere Genauigkeit von 98,42 % für den Winkelschleifer. Dies legt den Schluss nahe, dass die Unterscheidung auf dieser Detailstufe für Power-Tools, die zum Schleifen eingesetzt werden, mit hoher Genauigkeit möglich ist.

In der Studie von Heinis et al. (2018) wurde mit einem Labor-Messsystem eine Genauigkeit für sechs Tätigkeiten eines kabelgebundenen Winkelschleifers von 100 % unter folgenden Randbedingungen erreicht: Die Messdaten wurden mit einer Abtastfrequenz von 25 kHz aufgezeichnet. Der Datensatz umfasste insgesamt 104,2 Sekunden. Als Eingangsgrößen wurden die Wellenverschiebungen des Antriebsstrangs verwendet. Die Versuche wurden von einer anwendenden Person durchgeführt. Zur Ermittlung der Genauigkeit wurden 30 % der Messdaten als Validierungsdatsatz verwendet. Die Ergebnisse der Studie von Heinis et al. (2018) sind daher nicht direkt mit den Ergebnissen dieser Forschungsarbeit

vergleichbar. Dies liegt unter anderem an der geringen Größe und Vielfalt des verwendeten Datensatzes von Heinis et al. (2018). Es wurde eine anwendende Person untersucht und nur ein Versuch pro Tätigkeit durchgeführt. Zudem ist die Verwendung einer kabelgebundenen Maschine aufgrund der konstanten Spannung im Gegensatz zur variierenden Spannung einer akkubetriebenen Maschine mit weniger Störgrößen verbunden. Dies zeigt, dass die Ermittlung von Tätigkeiten mit hohen Genauigkeiten möglich ist, sofern wenig Störgrößen vorliegen und ein hochfrequent messendes Labor-Messsystem verwendet wird. Der Vergleich mit den Ergebnissen dieser Forschungsarbeit unterstreicht die Notwendigkeit der bewussten Einbringung von Störgrößen und der Verwendung eines größeren Datensatzes, um die Grenzen der Modelle und die Übertragbarkeit der Ergebnisse zu ermitteln.

In einer Vorstudie (Dörr, Ries et al., 2019), die im Rahmen dieser Forschungsarbeit durchgeführt wurde, wurde ein ähnliches Versuchsdesign wie in der Studie von Heinis et al. (2018) verwendet: Es wurden die Klasse *Kein Werkzeugkontakt* und drei Tätigkeiten untersucht, die von einer anwendenden Person mit einem kabelgebundenen Winkelschleifer an zwei unterschiedlichen Versuchstagen durchgeführt wurden. Dabei wurde eine Genauigkeit von 99 % für die Vorhersage von Tätigkeiten innerhalb eines Versuchstages ermittelt. Für die Validierung des statistischen Modells mit dem Validierungsdatensatz des anderen Versuchstages wurde eine Genauigkeit von 81 % erzielt. Dies unterstreicht erneut die Notwendigkeit der bewussten Einbringung von Störgrößen für das statistische Modell in das Studiendesign der manuellen Studie und die Aufteilung des Versuchsdesigns in einzelne Versuche.

Während der Vergleich mit der Studie von Heinis et al. (2018) nicht möglich ist, lässt sich die höhere Genauigkeit dieser Studie trotz der eingebrachten Störgrößen im Vergleich zur eigenen Vorstudie (Dörr, Ries et al., 2019) und der Studie von Voet et al. (2019) durch ein ausgereifteres Vorgehen zur Parametrierung der statistischen Modelle mittels Merkmalsextraktion und Hyperparameter-Optimierung in einer verschachtelten CV erklären.

### 5.3.2 Diskussion zur Teilforschungsfrage 1.1

In diesem Kapitel wird Teilforschungsfrage 1.1 untersucht, die wie folgt lautet:

**Teilforschungsfrage 1.1:** Welches Verfahren ist geeignet, um die Vorhersage der ausgeübten Tätigkeit unter starkem Einfluss von Störgrößen zu bewerten?



Die Ergebnisse der klassischen CV in Tabelle 5.3, die alle drei anwendenden Personen und alle 26 Versuche enthält, erreichen eine sehr hohe Genauigkeit für den Winkelschleifer GWS18 (Mittelwert = 96,36 %,  $SD = 1,32$  %) und für den Winkelschleifer CCG18 (Mittelwert = 92,53 %,  $SD = 2,61$  %). Die geringe  $SD$  zeigt, dass die Genauigkeit der Vorhersage für jede validierte Gruppe hoch ist. Die sehr hohe Genauigkeit bei der klassischen CV bedeutet, dass die Vorhersage der durchgeführten Tätigkeiten mit einem Winkelschleifer anhand von Daten, die mit dem Sensormodul gemessen werden, grundsätzlich bei einem passenden Trainingsdatensatz möglich ist.

Die Ergebnisse der LOTO CV in Tabelle 5.3 erreichen für den Winkelschleifer GWS18 (Mittelwert = 68,36 %,  $SD = 29,00$  %) und für den Winkelschleifer CCG18 (Mittelwert = 65,66 %,  $SD = 31,92$  %) deutlich geringere Genauigkeiten als die Ergebnisse der klassischen 26-fachen CV.

Der Vergleich der durchschnittlichen Genauigkeiten beider Verfahren zur Bewertung der Vorhersage zeigt eine deutlich geringere durchschnittliche Genauigkeit für die LOTO CV. Da der Unterschied zwischen CV und LOTO CV in der durchschnittlichen Genauigkeit und  $SD$  nur in der Zuweisung der Gruppen für die Validierung liegt, ist er in der durchschnittlichen Genauigkeit auf voneinander abweichende Versuche zurückzuführen. Die Abweichung zwischen den Versuchen erklärt sich durch Störgrößen, die zwischen den Versuchen auftreten. Diese können eine unterschiedliche Andruckkraft und eine unterschiedliche Arbeitsweise der anwendenden Person, der Verschleiß des Werkzeugs, die Wärmeentwicklung des Antriebsstrangs des Winkelschleifers, der Ladezustand des Akkus oder die wechselnde Geometrie und Erwärmung des Werkstücks sein.

Der Vergleich der  $SD$  beider Verfahren zur Bewertung der Vorhersage zeigt eine deutlich höhere  $SD$  für die LOTO CV. Die hohe  $SD$  zeigt, dass die Genauigkeit der Ermittlung der Tätigkeit bei jedem einzelnen Versuch sehr unterschiedlich ausfällt. Eine Erklärung der hohen  $SD$  der LOTO CV ist neben den versuchsübergreifenden Störgrößen die ungleiche Verteilung der Tätigkeit *Kein Werkzeugkontakt* unter den Versuchen. So enthält ein Teil der Versuche nur eine Tätigkeit, während der andere Teil sowohl eine Tätigkeit als auch die Klasse *Kein Werkzeugkontakt* umfasst. Da die Unterscheidung der Klasse *Kein Werkzeugkontakt* von einer Tätigkeit am einfachsten ist, trägt dies auch zur hohen  $SD$  der Genauigkeit bei.

Die Aufschlüsselung der Genauigkeit bei Verwendung der MBC in Tabelle 5.4 ermöglicht eine Analyse der  $SD$  ohne die erste Stufe der Tätigkeit *Kein Werkzeugkontakt*. Die Tabelle zeigt, dass die Abweichung hauptsächlich auf die Schwierigkeit der Unterscheidung in den Stufen 3 und 4 zurückzuführen ist.

Während in einigen Versuchen eine hohe Genauigkeit erreicht wurde, war es in anderen Versuchen nicht möglich, die richtige Tätigkeit zu ermitteln. Das zeigt, dass die Vorhersage der durchgeführten Tätigkeit in einem neuen, dem statistischen Modell unbekanntem Versuch davon abhängt, wie stark der Versuch von den Trainingsdaten abweicht. Dies entspricht dem erwarteten Ergebnis, weshalb in dem Studiendesign der manuellen Studie Störgrößen eingebracht wurden.

Die in der Studie vorhandenen Störgrößen sind ebenfalls in der realitätsnahen Nutzung von Winkelschleifern im Feld vorhanden. Somit entspricht die ermittelte Genauigkeit mit dem Verfahren LOTO CV einer realitätsnäheren Modellvalidierung, da das Verfahren LOTO CV die Störgrößen voneinander abweichender Versuche berücksichtigt. Die Streuung, die sich aus den voneinander abweichenden Versuchen ergibt, spiegelt sich in der unterschiedlichen Genauigkeit zwischen CV und LOTO CV wider. Aufgrund der Höhe der Abweichung zwischen den Genauigkeiten der CV und der LOTO CV ist die Verwendung der LOTO CV als sehr relevant zu bewerten.

Somit ist Teilforschungsfrage 1.1 beantwortet. Das Verfahren LOTO CV ist beim Schleifen mit Winkelschleifern besser geeignet als die CV, um die Vorhersage einer durchgeführten Tätigkeit versuchsübergreifend mit einer realitätsnahen Genauigkeit zu bewerten.

### 5.3.3 Diskussion zur Teilforschungsfrage 1.2

In diesem Kapitel wird Teilforschungsfrage 1.2 untersucht, die wie folgt lautet:

**Teilforschungsfrage 1.2:** Welche statistischen Modelle eignen sich zur Vorhersage der durchgeführten Tätigkeit anhand von Sensordaten?

Mit allen vier verwendeten statistischen Modellen konnte eine ähnliche Genauigkeit erzielt werden. Aus Tabelle 5.3 ist ersichtlich, dass EL bei beiden Verfahren zur Bewertung der Vorhersage bis auf zwei Ausnahmen die höchste Genauigkeit aufweist. Beim Vergleich der Modelle zeigt sich, dass EL und MBC ähnlich gut abschneiden, während SVM und kNN in der Genauigkeit abfallen. Während EL im Durchschnitt die höchste Genauigkeit aufweist, hat die MBC andere Vorteile: Durch die schrittweise Klassifikation kann bestimmt werden, bis zu welcher Detailstufe die Vorhersage der Tätigkeit funktioniert. Dies ist sinnvoll, wenn die Vorhersage von Tätigkeiten auf niedrigeren Detailstufen wie *Schruppen mit einer Fiberscheibe* und *Schruppen mit einer Schrupscheibe* eine geringere Genauigkeit aufweist. Diese können für die Produktentwicklung von Bedeutung sein, da indirekt die Unsicherheit der Vorhersage unterschiedlicher Tätigkeiten beschrieben wird. Zudem kann bei der

Vorhersage von Tätigkeiten mit geringer Genauigkeit der Teil des Modells mit hoher Genauigkeit verwendet und ausgewertet werden. Somit eignet sich für die Ermittlung der durchgeführten Tätigkeit entweder EL für die höchste Genauigkeit oder MBC, wenn die Zwischenergebnisse der Vorhersage von Bedeutung sind.

Somit ist Teilforschungsfrage 1.2 beantwortet. Die Ergebnisse zeigen, dass EL und MBC am besten geeignet sind: EL hat die höchste durchschnittliche Genauigkeit. MBC hat den Vorteil, dass auch die Zwischenergebnisse der Vorhersage der einzelnen Stufen zur Verfügung stehen.

In dieser Forschungsarbeit wurden verschiedene Ansätze zur Verbesserung der Genauigkeit verwendet, beispielsweise die automatische Naive-Bayes-Hyperparameter-Optimierung. Es ist aber möglich, dass andere Modelle, wie Hidden-Markov-Modelle oder neuronale Netze, die Genauigkeit geringfügig verbessern könnten. Aufgrund des Unterschieds zwischen CV und LOTO CV kann angenommen werden, dass die fehlende Vielfalt innerhalb der Versuche und die starke Abweichung zwischen den Versuchen die Hauptursache für die geringere Genauigkeit der LOTO CV sind. Daher ist davon auszugehen, dass die mit statistischen Modellen erreichbare Genauigkeit dieses Datensatzes bereits zu einem Großteil ausgeschöpft ist.

### **5.3.4 Einschränkungen und Übertragbarkeit der Ergebnisse**

In dieser Studie wurden alle Versuche mit einem Winkelschleifer des Typs GWS18 und des Typs CCG18 durchgeführt. Es bleibt unklar, inwieweit Toleranzen und der Verschleiß der Gestalt eines Winkelschleifers desselben Typs Störgrößen für die Vorhersage darstellen. Eine mögliche Forschungsrichtung ist die Übertragung und Anpassung der gebildeten statistischen Modelle, zum Beispiel vom GWS18 auf den CCG18, mittels Transfer-Learning. Dies würde den initialen Aufwand für die Datenaufnahme zur Bildung neuer statistischer Modelle verringern.

Die Vorhersage der ersten beiden Stufen der MBC erzielte eine hohe Genauigkeit für die LOTO CV. Es bleibt unklar, mit welcher Genauigkeit die Vorhersage der Tätigkeiten auf der dritten und vierten Stufe bei Verwendung eines Trainingsdatensatzes mit längeren Versuchen möglich ist. Es sollte auch untersucht werden, welche Genauigkeit bei der Vorhersage anderer Tätigkeiten beim Schleifen mit einem Winkelschleifer möglich ist, beispielsweise durch andere Werkstücke und Werkzeuge.

Im Rahmen dieser Studie wurden Winkelschleifer untersucht. Charakteristisch für die Anwendung von statistischen Modellen sind der Schleifprozess, die Störgrößen

und die Interaktion mit der anwendenden Person. Daher kann davon ausgegangen werden, dass das Vorgehen zur Modellbildung und Modellvalidierung sowie die gewählten Modelle auf andere Power-Tools, die zum Schleifen eingesetzt werden, und zum Teil auf andere Mensch-Maschine-Systeme übertragbar sind.

### 5.4 Zwischenfazit

In dieser Studie wurde die Machbarkeit der Vorhersage der durchgeführten Tätigkeit aus Sensordaten einer IMU, einem Stromsensor und einem Spannungssensor an zwei Winkelschleifern mittels unterschiedlicher Verfahren zur Bewertung der Vorhersage untersucht.

Es wurden Teilforschungsfrage 1.1 und Teilforschungsfrage 1.2 beantwortet. Somit lässt sich Forschungsfrage 1 beantworten, die wie folgt lautet:

**Forschungsfrage 1:** Wie lässt sich bei Winkelschleifern die durchgeführte Tätigkeit anhand von Sensordaten durch statistische Modelle vorhersagen?

Zu diesem Zweck wurde die Machbarkeit der Vorhersage von vier durchgeführten Tätigkeiten auf Basis von Daten eines Sensormoduls und statistischer Modelle, die mittels Machine-Learning parametrisiert wurden, an zwei Winkelschleifern untersucht. In einer manuellen Studie wurden Sensordaten von drei anwendenden Personen über eine fünfstündige Bearbeitungszeit aufgezeichnet, wobei Störgrößen gezielt eingebracht wurden. Die Ergebnisse zeigen, dass es möglich ist, die Tätigkeiten mit hoher Genauigkeit vorherzusagen, aber die Genauigkeit davon abhängt, wie stark ein einzelner Versuch von anderen Versuchen abweicht.

Für eine aussagekräftige Validierung unter Berücksichtigung der Störgrößen zwischen einzelnen Versuchen eignet sich das Verfahren LOTO CV. Die Ergebnisse zeigen, dass die Modelle EL und MBC für die Vorhersage der durchgeführten Tätigkeit am besten geeignet sind. Aufgrund der Interaktion mit einer anwendenden Person, ähnlichen Störgrößen und dem Schleifprozess ist anzunehmen, dass dieses Vorgehen und diese Erkenntnisse auf andere Power-Tools, die zum Schleifen eingesetzt werden, und zum Teil auf andere Mensch-Maschine-Systeme übertragbar sind.

## 6 Erfassung der Kräfte im Werkzeugkontakt

In diesem Kapitel werden statistische Modelle vorgestellt, um Kräfte im Werkzeugkontakt aus Sensordaten vorherzusagen. Mit der Vorhersage dieser Kräfte über einen virtuellen Sensor mit einem statistischen Modell wird die Datenerfassung in der Nutzungsphase ermöglicht, woraus sich neue Potenziale für die Produktentwicklung ergeben.

Dieses Kapitel behandelt Forschungsfrage 2:

**Forschungsfrage 2:** Wie lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt anhand von Sensordaten durch statistische Modelle vorhersagen?

Durch die Beantwortung der Forschungsfrage soll aufgezeigt werden, wie die Vorhersage der Kräfte im Werkzeugkontakt erfolgt. Für diese Vorhersage sollen, wie in Forschungsfrage 1, statistische Modelle verwendet werden, die mittels Machine-Learning parametrisiert werden. Es werden Sensordaten von einem Sensormodul mit einer IMU, einem Stromsensor und einem Spannungssensor mit einer Abtastfrequenz von 1000 Hz als Eingangsgrößen für die statistischen Modelle verwendet.

Aufgrund der in den Grundlagen in Kapitel 2.1.1 vorgestellten Zusammenhänge sind die Tangentialkraft und die Normalkraft die relevantesten Kräfte. Für das manuelle Schleifen ist die Führungskraft auch von Bedeutung. Das Verhalten eines Winkelschleifers unterscheidet sich je nach Werkzeug. Die Vorhersage der Kräfte im Werkzeugkontakt ist für unterschiedliche Abtastraten möglich. Daher wird die Vorhersage für alle Raumrichtungen, in vier Tätigkeiten mit variierenden Werkzeugen und drei verschiedenen Abtastraten für zwei unterschiedliche Winkelschleifer untersucht.

Somit gliedert sich die Forschungsfrage 2 in Teilforschungsfrage 2.1 und Teilforschungsfrage 2.2:

**Teilforschungsfrage 2.1:** Für welche Krafrichtungen und Tätigkeiten lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt anhand von Sensordaten durch statistische Modelle vorhersagen?

**Teilforschungsfrage 2.2:** Mit welcher Abtastrate lassen sich die Kräfte im Werkzeugkontakt aus Sensordaten vorhersagen?

Nachfolgend werden in Kapitel 6.1 der Versuchsaufbau und die Modellbildung vorgestellt.

*Der Versuchsaufbau, das Studiendesign, die Ergebnisse und die Diskussion dieses Kapitels basieren zu Teilen auf der nachfolgenden Veröffentlichung:*

*- „Prediction of Tool Forces in Manual Grinding Using Consumer-Grade Sensors and Machine Learning“ (Dörr, Ott et al., 2021)*

*Teile des folgenden Textes sind ohne Veränderung in übersetzter Form aus der Veröffentlichung übernommen. Sie werden aus Gründen der Übersichtlichkeit nicht gesondert gekennzeichnet.*

## **6.1 Studiendesign und Modellentwicklung**

In diesem Kapitel werden die Versuchsdaten zu den Kräften im Werkzeugkontakt sowie den Sensordaten, die Datenverarbeitung und das Vorgehen zur Modellbildung vorgestellt.

### **6.1.1 Manuelle Studie**

Für die Bildung eines statistischen Modells werden Messdaten benötigt. Diese Messdaten enthalten die Kräfte im Werkzeugkontakt als abhängige Variablen und die Sensordaten eines Winkelschleifers als unabhängige Variablen. Dafür wurde ein Teil der Messdaten der manuellen Studie aus Kapitel 5 verwendet, bei denen die Kraft im Werkzeugkontakt gemessen wurde. Die verwendeten Messdaten bestehen aus den Versuchsclustern 2 und 5, die in Tabelle 5.1 beschrieben sind. Daher beinhalten die Versuche die vier Tätigkeiten: *Trennen mit einer Trennscheibe, Schruppen mit einer Schrupscheibe, Schruppen mit einer Fiberscheibe und Schleifen mit einer Fächerschleifscheibe.*

Der Versuchsperson wurde in diesen Versuchsclustern eine statische Soll-Andruckkraft von 25 N vorgegeben, die während des Versuchs auf einem Bildschirm angezeigt wurde. Durch die dominanten dynamischen Komponenten unterscheidet sich die gemessene dynamische Kraft deutlich vom statischen Sollwert in der Andruckrichtung, wie in Abbildung 6.4 exemplarisch verdeutlicht wird.

Zur Messung der Kräfte im Werkzeugkontakt wurde der Versuchsaufbau T1 aus Abbildung 5.1 verwendet. Es wurden drei Piezokraftsensoren (9347C, Kistler Instrumente GmbH, Sindelfingen, Deutschland) verwendet, um die dynamischen Kräfte an einer Stahlprobe in alle drei Raumrichtungen zu messen. Der Versuchsaufbau und die Stahlproben erlauben eine eigenfrequenzfreie Messung

von Kräften im Werkzeugkontakt bis zu 500 Hz. Der Aufbau wurde im Detail in Dörr, Zimprich et al. (2019) veröffentlicht.

Zur Messung der Sensordaten wurden die in Kapitel 5.1 vorgestellten Sensormodule G1 und C1 verwendet. Die beiden Winkelschleifer, die dazugehörigen Sensormodule sowie der Versuchsaufbau T1 mit der Stahlprobe für die Tätigkeiten *Schruppen mit einer Schrappscheibe* und *Schruppen mit einer Fiberscheibe* sind in Abbildung 6.1 dargestellt.



Abbildung 6.1: Verwendete Winkelschleifer mit passendem Sensormodul und Versuchsaufbau zur Messung der Kräfte im Werkzeugkontakt: Winkelschleifer GWS18 (a), Winkelschleifer CCG18 (b) und Versuchsaufbau T1 mit der Stahlprobe für die Tätigkeiten *Schruppen mit einer Schrappscheibe* und *Schruppen mit einer Fiberscheibe* (c). (Dörr, Ott et al., 2021, S. 4)

### 6.1.2 Datenverarbeitung

Aufgrund der drei mehrachsigen Kraftsensoren wurden die Kräfte im Werkzeugkontakt mit neun Messsignalen als Zeitreihen aufgezeichnet. Als Abtastfrequenz wurden 20 kHz verwendet. Die Datenverarbeitung der Kräfte im Werkzeugkontakt erfolgte durch Addition der Zeitreihen der drei Kraftsensoren aus denselben Richtungen (x-Achse, y-Achse, z-Achse), um Zwangskräfte zu kompensieren. Die Transformation der Koordinatensysteme, der am Versuchsaufbau gemessenen Kräfte auf die Kräfte im Werkzeugkontakt, ist in Abbildung 6.2 dargestellt.

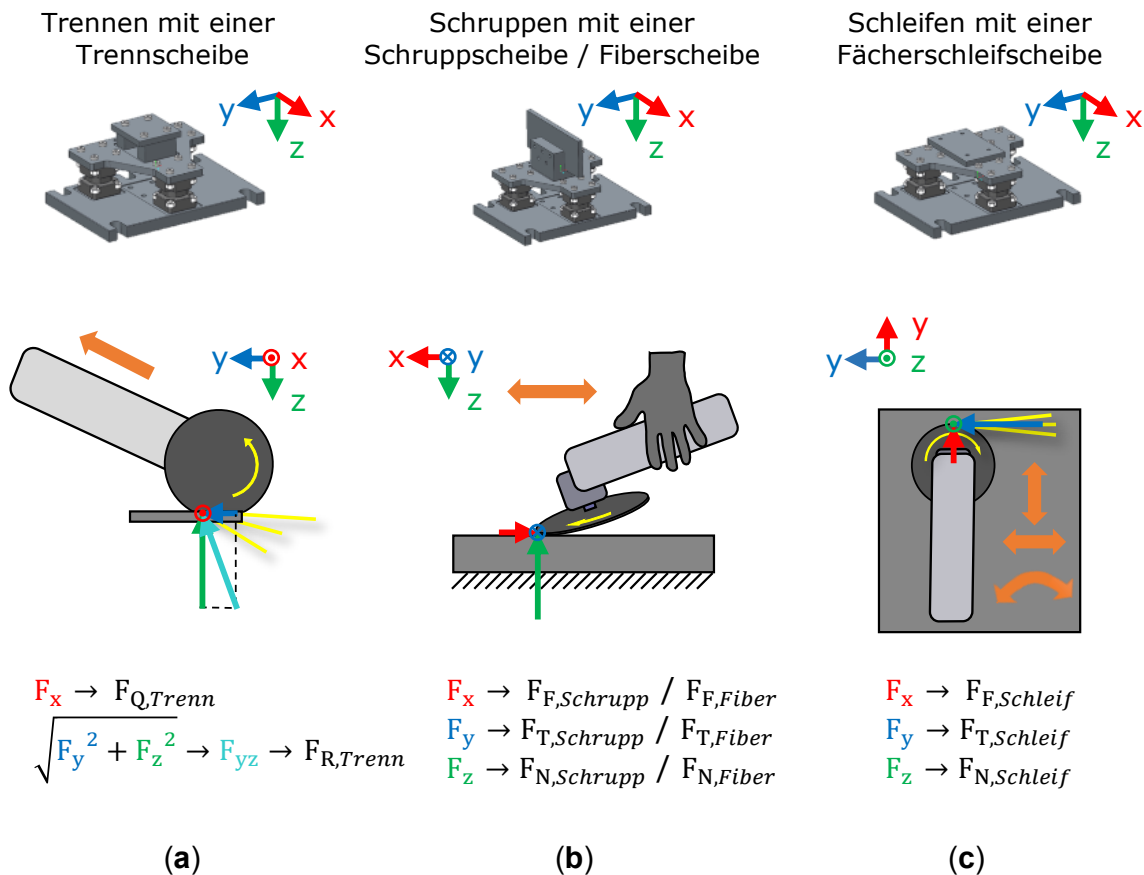


Abbildung 6.2: Transformation der Koordinatensysteme der am Versuchsaufbau gemessenen Kräfte auf die Kräfte im Werkzeugkontakt für alle Tätigkeiten: Transformation für die Tätigkeit *Trennen mit einer Trennscheibe* (a), für die Tätigkeiten *Schruppen mit einer Schruppscheibe* und *Schruppen mit einer Fiberscheibe* (b) und für die Tätigkeit *Schleifen mit einer Fächerschleifscheibe* (c). Übersetzt aus Dörr, Ott et al. (2021, S. 5)

Bei der Tätigkeit *Trennen mit einer Trennscheibe* ist die Kraft in x-Richtung die axiale Querkraft  $F_{Q,Trenn}$ . Beim *Trennen mit einer Trennscheibe* ist es aufgrund des sich ändernden Winkels zwischen Winkelschleifer und Werkstück sinnvoll, die Tangentialkraft und Normalkraft in die Radialkraft  $F_{R,Trenn}$  zusammenzufassen. Die Radialkraft  $F_{R,Trenn}$  wird durch Addition der gemessenen vertikalen und horizontalen Kraft gebildet.

Bei der Tätigkeit *Schruppen mit einer Schruppscheibe* ist die Kraft in x-Richtung nach ISO 15230:2007 (2007) die Führungskraft  $F_{F,Schrupp}$ . Die Kraft in y-Richtung ist die Tangentialkraft  $F_{T,Schrupp}$  und die Kraft in z-Richtung ist die Normalkraft  $F_{N,Schrupp}$ . Bei der Tätigkeit *Schruppen mit einer Fiberscheibe* ist die Kraft in x-Richtung ebenfalls die Führungskraft  $F_{F,Fiber}$ . Die Kraft in y-Richtung ist die Tangentialkraft  $F_{T,Fiber}$  und die Kraft in z-Richtung ist die Normalkraft  $F_{N,Fiber}$ .



Bei der Tätigkeit *Schleifen mit einer Fächerschleifscheibe* sind die Richtungen der Führungskraft und der Tangentialkraft Änderungen unterworfen. Dies ist auf die kreisförmige Arbeitsweise und das stationäre Koordinatensystem des Versuchsaufbaus zurückzuführen. Aufgrund der konstanten Position der anwendenden Person vor dem Versuchsaufbau erfolgt die Änderung der Richtungen nur durch eine geringe Winkeländerung. Daher wurde die Transformation analog zu den beiden Tätigkeiten *Schruppen mit einer Schrupscheibe* und *Schruppen mit einer Fiberscheibe* durchgeführt. Die Kraft in x-Richtung ist die Führungskraft  $F_{F,Schleif}$ , die Kraft in y-Richtung ist die Tangentialkraft  $F_{T,Schleif}$  und die Kraft in z-Richtung ist die Normalkraft  $F_{N,Schleif}$ .

Ein Versuch mit der Tätigkeit *Schruppen mit einer Fiberscheibe* wurde für den GWS18 nicht ausgewertet, da es bei diesem Test zu wiederholten Leistungsunterbrechungen des Motors kam.

Die Abtastrate der Zeitreihen der Kräfte im Werkzeugkontakt wurde auf die Abtastrate der Sensordaten (1000 Hz) angeglichen. Anschließend wurden die Zeitreihen der Kräfte im Werkzeugkontakt und der Messdaten des Sensormoduls synchronisiert. Die Zeitreihen wurden auf den Zeitraum zwischen einer Sekunde vor dem Start des Schleifprozesses und einer Sekunde nach dem Ende des Schleifprozesses zugeschnitten. Der Schleifprozess wurde durch den Kontakt zwischen Werkzeug und Werkstück definiert.

Bei der Datenverarbeitung der Kräfte im Werkzeugkontakt wurde ein Tiefpassfilter von 100 Hz (Butterworth, 4. Ordnung) verwendet. In der Studie wird die Leistung der Vorhersage der Kräfte im Werkzeugkontakt als Zeitreihen mit unterschiedlichen Abtastraten bewertet, um eine optimale Abtastfrequenz zur Vorhersage zu ermitteln. Als Referenz für die Abtastrate werden 10 Hz verwendet, da dies die Grenze für das aktive Anwenderverhalten darstellt. Daher erfolgt die Segmentierung mit drei Segmentlängen:

- Für die Abtastrate von 10 Hz werden Segmente mit einer Länge von 0,1 Sekunden gebildet. Das entspricht 100 Datenpunkten pro Signal und Segment.
- Für die Abtastrate von 1 Hz werden Segmente mit einer Länge von einer Sekunde gebildet. Das entspricht 1000 Datenpunkten pro Signal und Segment.
- Für die Abtastrate von 20 Hz werden Segmente mit einer Länge von 0,05 Sekunden gebildet. Das entspricht 50 Datenpunkten pro Signal und Segment.

Für jedes Segment wurde der Median der Kraft berechnet, der als abhängige Variable für die Vorhersage der Kraft im Werkzeugkontakt verwendet wurde.

Bei der Datenverarbeitung der vom Sensormodul gemessenen Sensordaten wurde kein Filter verwendet. Aus den Zeitreihen der Beschleunigung in drei Richtungen wurde über eine Fast-Fourier-Transformation (FFT) die Drehzahl der Arbeitswelle als Zeitreihe berechnet, da die Drehzahl eine relevante Größe für den Arbeitspunkt eines Winkelschleifers ist. Die unabhängigen Variablen zur Vorhersage der Kräfte im Werkzeugkontakt sind die Beschleunigung in drei Richtungen, die Winkelgeschwindigkeit in drei Richtungen, das Magnetfeld in drei Richtungen, der Strom, die Akkuspannung und die Drehzahl der Arbeitswelle. Die Zeitreihen wurden mittels Segmentierung in Segmente mit gleicher Länge wie die Kräfte unterteilt. Innerhalb der Segmente wurden die Merkmale unabhängig voneinander berechnet. Die Merkmalsextraktion erfolgt manuell auf Basis von statistischen Größen im Zeit- und Frequenzbereich. Insgesamt wurden 965 Merkmale aus den Zeitreihen extrahiert. Nach der Extraktion wurden alle Merkmale standardisiert.

Ein weiterer Nachbearbeitungsschritt umfasst die Überprüfung auf fehlende Werte und Nullwerte bei jedem Merkmal, da durch die unterschiedliche Segmentlänge Merkmale teilweise nicht gebildet werden konnten. Bei mehr als 5 % fehlender Werte wurde das Merkmal entfernt. Zudem wurden Merkmale entfernt, die mehr als 30 % Nullen enthalten. Zur Schätzung von Datenpunkten für Merkmale mit weniger als 5 % fehlenden Werten wurde eine Spline-Interpolation verwendet. Die gesamte Datenverarbeitung sowie die Modellbildung erfolgten in MATLAB R2020b (The MathWorks, Vereinigte Staaten).

### **6.1.3 Modellbildung und Validierung zur Vorhersage der Kräfte im Werkzeugkontakt**

In diesem Kapitel wird das Vorgehen für die Modellbildung eines statistischen Modells, das mittels Machine-Learning parametrisiert wurde, zur Vorhersage der Kräfte im Werkzeugkontakt beschrieben. Das Vorgehen ist in Abbildung 6.3 dargestellt.

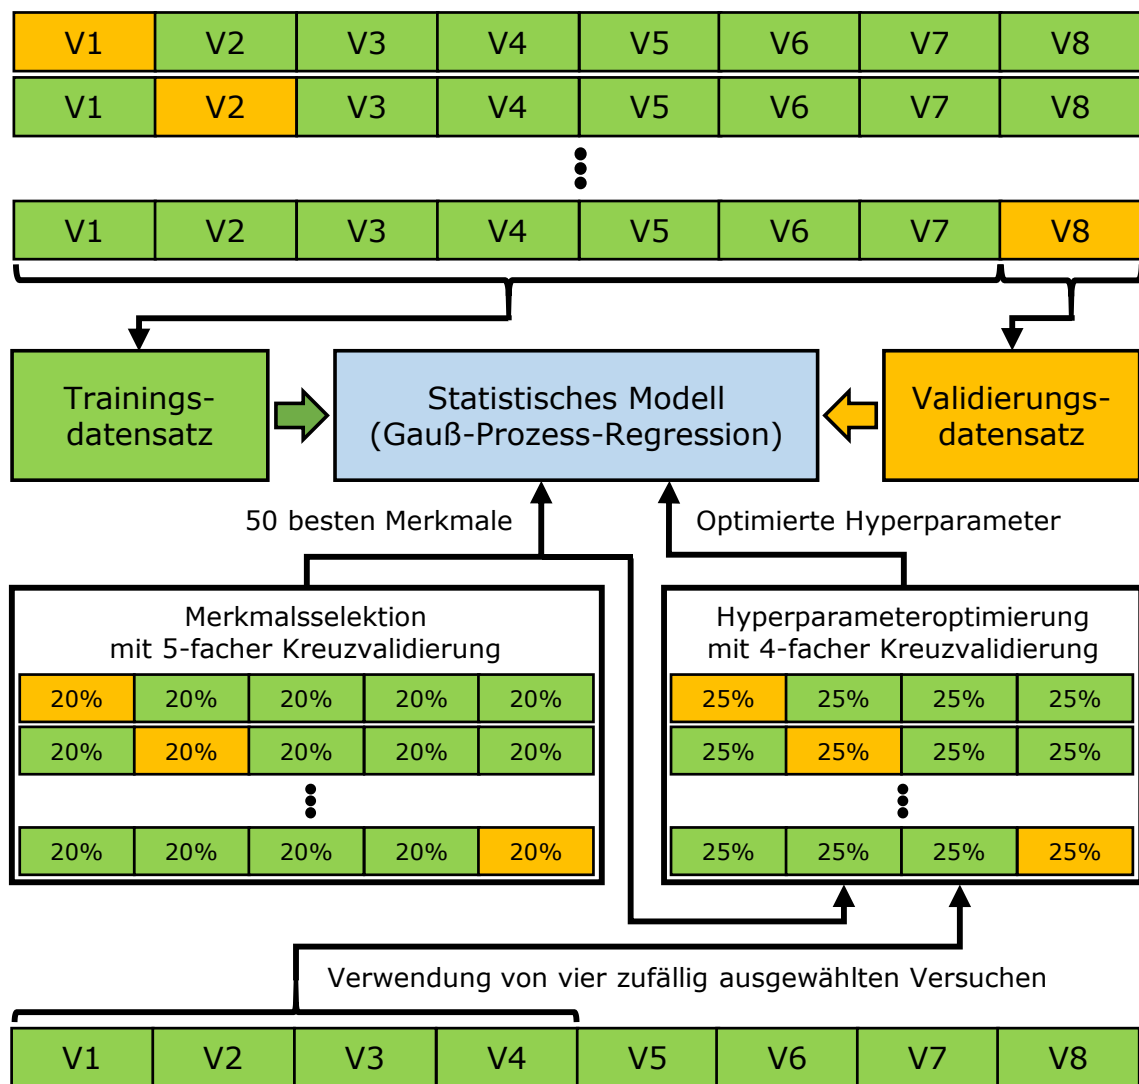


Abbildung 6.3: Vorgehen für die Modellbildung zur Vorhersage der Kräfte im Werkzeugkontakt. In Anlehnung an Dörr, Ott et al. (2021, S. 9)

Als Modell wird ein Gauß-Prozess-Regression (GPR)-Modell verwendet. Eine Erläuterung der GPR ist beispielweise in Carmo Nicoletti & Jain (2009), Rasmussen & Williams (2006) oder Murphy (2013) aufgeführt. Die GPR wurde gewählt, da die Kräfte im Werkzeugkontakt stochastisch verteilt sind. Zudem ermöglicht ein GPR-Modell die Ausgabe des Vorhersageintervalls. Mit diesem kann die Unsicherheit der Vorhersage angegeben werden. Dies ist für die Produktentwicklung von Bedeutung, da dies eine mit Unsicherheit behaftete Betrachtung der Kräfte im Werkzeugkontakt ermöglicht.

Im Vorgehen wurden auf Basis von 50 % der Versuche die Merkmale selektiert und die Hyperparameter optimiert. Zur Merkmalsselektion wurden die Methoden *Mutual*

*Information*, *LASSO* und *RReliefF* verwendet. Zur Merkmalsselektion wurde einzelne Funktionen der Toolbox „Feature Selection Library“ von Giorgio (2017) zurückgegriffen. Die Merkmale wurden nach ihrer Bedeutung geordnet und die 50 besten Merkmale wurden ausgewählt. Die Merkmalsselektion wurde auf Basis von 50 % der Versuche durchgeführt. Es wurde eine 5-fache CV verwendet. Bei der Hyperparameter-Optimierung wurden folgende Hyperparameter optimiert: Basisfunktion (Mittelwertfunktion), Kernel-Funktion (Kovarianzfunktion), Kernel-Skala und Sigma (Rauschen). Die Optimierung wurde mit einem Quasi-Newton-Verfahren (Quasi-Newton Methods, 2006) auf Basis der selektierten Merkmale aus den Daten der Merkmalsselektion mittels einer 4-fachen Kreuzvalidierung durchgeführt.

Die Validierung des Modells erfolgte mittels LOTO CV, da sich das Verfahren in Teilforschungsfrage 1.1 als besser geeignet für die Bewertung der Vorhersage gezeigt hat. Zu diesem Zweck wurde der Datensatz in einer CV in einen Trainingsdatensatz, bestehend aus sieben Versuchen, und in einen Validierungsdatensatz, bestehend aus einem Versuch, aufgeteilt. Das GPR-Modell wurde mit den besten Hyperparametern und den besten 50 Merkmalen auf Basis des Trainingsdatensatzes parametrisiert.

Die Bewertung des parametrisierten Modells für jeden der Versuche erfolgte anhand folgender Bewertungsgrößen, die sich auf das vorhergesagte Kraftsignal ( $F^*$ ) und das gemessene Kraftsignal ( $F$ ) beziehen. Da der absolute Kraftwert für die Bemessung von großer Bedeutung ist, wurde der mittlere absolute Fehler (*MAE*) als Bewertungsparameter verwendet. Um die relative Abweichung der gemessenen und vorhergesagten Kraftwerte zu berücksichtigen, wurde der relative *MAE* (*rMAE*) als zweiter Bewertungsparameter verwendet. Zudem wurde der Pearson-Korrelationskoeffizient ( $r$ ) als dimensionsloser Bewertungsparameter verwendet, der ein Maß für die lineare Korrelation zwischen den gemessenen und vorhergesagten Kraftwerten ist.

Für die Ergebnisse wurden die durchschnittlichen Bewertungsgrößen sowie die *SD* berechnet, um die Varianz zwischen den Versuchen zu quantifizieren. Das Vorgehen wurde jeweils auf beide Winkelschleifer, die drei Abtastraten, alle vier Tätigkeiten und alle Krafrichtungen angewandt. Somit wurden mit dem Vorgehen insgesamt 66 Modelle gebildet und validiert. Die gesamte Datenverarbeitung und Modellbildung erfolgte in MATLAB R2020b (The MathWorks, Vereinigte Staaten).

## 6.2 Ergebnisse

Die Zeitreihen der vorhergesagten ( $F^*$ ) und gemessener ( $F$ ) Kräfte im Werkzeugkontakt für die Tätigkeit *Schruppen mit einer Schrupscheibe* in drei Richtungen ( $F_{F,Schrupp}$ ,  $F_{T,Schrupp}$ ,  $F_{N,Schrupp}$ ) in drei Versuchen sind exemplarisch in Abbildung 6.4 dargestellt. Die vorhergesagten und gemessenen Kraftsignale werden für zwei Versuche aufgezeigt. In der Abbildung 6.4 ist mit dem 5%- und 95%-Vorhersageintervall der vorhergesagten Kraft ein Teilergebnis des Modells abgebildet. Es ist zu erkennen, dass zwischen den vorhergesagten und den gemessenen Kraftsignalen eine gute Übereinstimmung vorliegt. Das Vorhersageintervall für  $F_{F,Schrupp}$  ist größer als für  $F_{T,Schrupp}$  und  $F_{N,Schrupp}$ . Dies bedeutet, dass die Wahrscheinlichkeit einer genauen Vorhersage für  $F_{F,Schrupp}$  geringer ist.

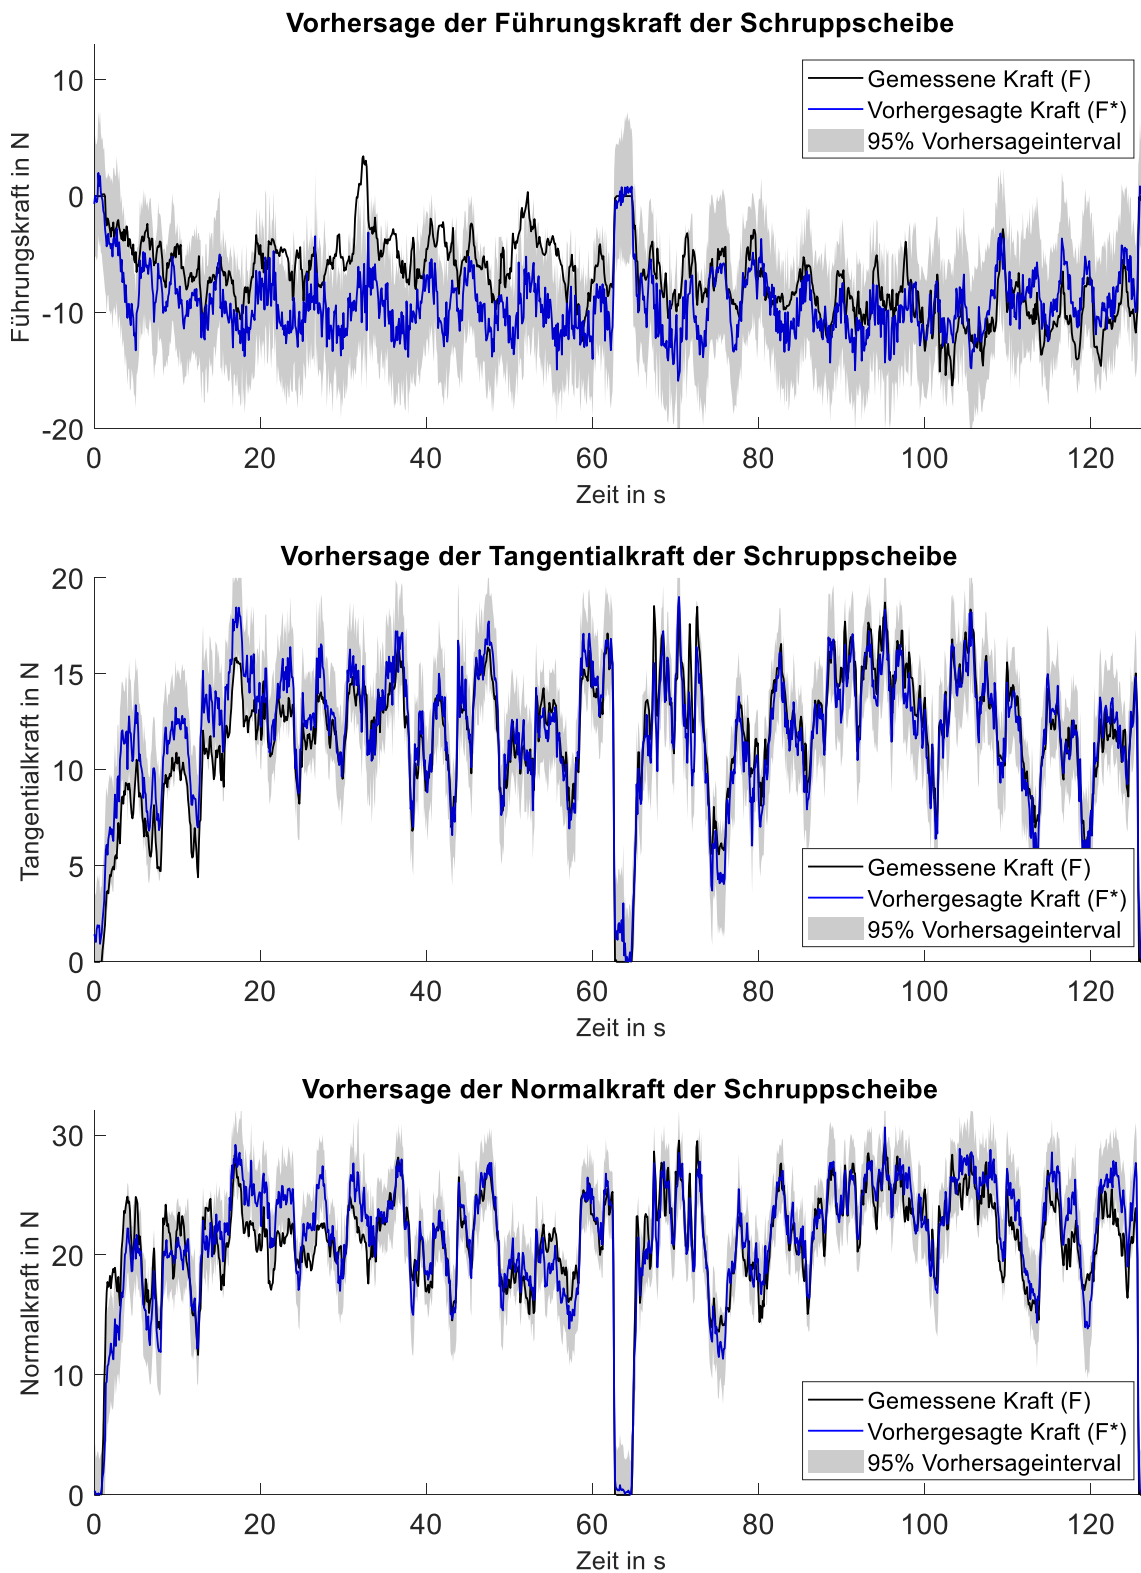


Abbildung 6.4: Gemessene und vorhergesagte Kräfte im Werkzeugkontakt einschließlich Vorhersageintervall beim *Schruppen mit einer Schrupscheibe*. In Anlehnung an Dörr, Ott et al. (2021, S. 11)

Die Ergebnisse in den folgenden beiden Tabellen wurden aufgrund der ähnlichen Ergebnisse für beide Winkelschleifer zur besseren Übersichtlichkeit mithilfe des Mittelwertes zusammengefasst. Die Ergebnisse getrennt für beide Winkelschleifer sind im Anhang in Tabelle B, Tabelle C, Tabelle D und Tabelle E aufgeführt.

Tabelle 6.1 zeigt die Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt bei einer vorherzusagenden Abtastrate von 10 Hz. Die Leistung des GPR-Modells wird als Mittelwert (und *SD*) mit den Bewertungsgrößen *MAE*, *rMAE* und *r* angegeben. Die Ergebnisse beider Winkelschleifer wurden gemittelt. Die vorhergesagten Kräfte ergeben einen *MAE* im Bereich von 1.09 N bis 7.36 N, einen *rMAE* im Bereich von 8.84 % bis 566.95 % und einen *r* im Bereich von 0.13 bis 0.90. Die Leistung des GPR-Modells wird auf Basis von Erfahrungen mit dem System Winkelschleifer bewertet und mittels des *rMAE* in drei Gruppen (<15 %, 15–30 %, >30 %) eingeteilt. Eine sehr gute Vorhersage wurde bei den Kräften  $F_{N,Schrupp}$ ,  $F_{T,Fiber}$  und  $F_{N,Fiber}$  mit einem *MAE* von unter 15 % erzielt. Eine gute Vorhersage wurde bei den Kräften  $F_{T,Schrupp}$ ,  $F_{T,Schleif}$ ,  $F_{N,Schleif}$  und  $F_{R,Trenn}$  mit einem *MAE* zwischen 15 % und 30 % erzielt. Eine unzureichende Vorhersage wurde bei den Kräften  $F_{F,Schrupp}$ ,  $F_{F,Fiber}$ ,  $F_{F,Schleif}$  und  $F_{Q,Trenn}$  mit einem *MAE* über 30 % erzielt.

Tabelle 6.1: Bewertung der Leistung des GPR-Modells zur Vorhersage von Kräften im Werkzeugkontakt bei einer vorherzusagenden Abtastrate von 10 Hz für beide Winkelschleifer. In Anlehnung an Dörr, Ott et al. (2021, S. 10)

Tätigkeit	<i>MAE</i>	<i>rMAE</i>	<i>r</i>	<i>MAE</i>	<i>rMAE</i>	<i>r</i>	<i>MAE</i>	<i>rMAE</i>	<i>r</i>
	[N]	[%]		[N]	[%]		[N]	[%]	
Schruppen mit einer Schruppscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	2.73 (0.71)	110.86 (42.20)	0.32 (0.15)	1.68 (0.42)	22.09 (4.78)	0.83 (0.05)	2.08 (0.47)	9.05 (1.99)	0.88 (0.13)
Schruppen mit einer Fiberscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	2.79 (0.71)	51.71 (24.80)	0.53 (0.15)	1.09 (0.23)	11.72 (3.35)	0.90 (0.06)	1.73 (0.32)	8.84 (1.29)	0.87 (0.11)
Schleifen mit einer Fächer- Schleifscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	7.36 (1.38)	98.50 (60.81)	0.26 (0.15)	1.98 (0.55)	20.84 (10.39)	0.71 (0.11)	2.80 (1.04)	16.43 (9.27)	0.76 (0.09)
Durchschnitt der drei Tätigkeiten des Schruppens und Schleifens	Führungskraft			Tangentialkraft			Normalkraft		
	4.29 (0.93)	87.02 (42.60)	0.37 (0.15)	1.58 (0.40)	18.22 (6.24)	0.81 (0.07)	2.20 (0.61)	11.44 (4.18)	0.84 (0.11)
Trennen mit einer Trennscheibe	Querkraft			Radialkraft					
	3.88 (1.56)	566.95 (710.67)	0.13 (0.15)	3.64 (1.71)	19.67 (6.76)	0.80 (0.05)			

Tabelle 6.2 zeigt die Bewertung der Leistung des GPR-Modells zur Vorhersage der Kräfte im Werkzeugkontakt für die drei Abtastraten 1 Hz, 10 Hz und 20 Hz. Die Leistung des GPR-Modells wird als Mittelwert (und *SD*) mit dem *rMAE* angegeben. Die Ergebnisse beider Winkelschleifer wurden gemittelt. Die Abtastrate von 1 Hz ermöglicht die beste Vorhersage für die Kräfte  $F_{F,Schrupp}$  und  $F_{F,Schleif}$ . Die Abtastrate von 10 Hz ermöglicht die beste Vorhersage für die Kräfte  $F_{T,Fiber}$ ,  $F_{N,Fiber}$ ,  $F_{T,Schleif}$ ,  $F_{N,Schleif}$ ,  $F_{Q,Trenn}$  und  $F_{R,Trenn}$ . Die Abtastrate von 20 Hz ermöglicht die beste Vorhersage für die Kräfte  $F_{F,Schrupp}$ ,  $F_{N,Schrupp}$  und  $F_{F,Fiber}$ .

Tabelle 6.2: Bewertung der Leistung des GPR-Modells zur Vorhersage von Kräften im Werkzeugkontakt für die Abtastraten 1 Hz, 10 Hz und 20 Hz für beide Winkelschleifer. In Anlehnung an Dörr, Ott et al. (2021, S. 11)

Tätigkeit	<i>rMAE</i> [%]			<i>rMAE</i> [%]			<i>rMAE</i> [%]		
	1 Hz	10 Hz	20 Hz	1 Hz	10 Hz	20 Hz	1 Hz	10 Hz	20 Hz
Schruppen mit einer Schruppscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	104.86 (53.88)	110.86 (42.20)	109.53 (45.27)	24.23 (3.03)	22.09 (4.78)	21.96 (5.03)	12.41 (3.22)	9.05 (1.99)	9.00 (1.92)
Schruppen mit einer Fiberscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	55.28 (29.22)	51.71 (24.80)	51.52 (25.62)	19.10 (7.45)	11.72 (3.55)	13.46 (4.41)	11.73 (2.16)	8.84 (1.29)	9.64 (1.78)
Schleifen mit einer Fächer-Schleifscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	92.00 (61.06)	98.50 (60.81)	99.00 (61.55)	48.63 (57.35)	20.84 (10.39)	42.77 (55.08)	19.86 (13.30)	16.43 (9.27)	20.03 (7.29)
Trennen mit einer Trennscheibe	Querkraft			Radialkraft					
	602.64 (839.74)	566.95 (710.67)	587.47 (721.90)	19.89 (8.59)	19.67 (6.76)	21.30 (7.32)			

### 6.3 Diskussion

In diesem Kapitel wird die Beantwortung von Teilforschungsfrage 2.1 und Teilforschungsfrage 2.2 untersucht. Im Stand der Forschung in Kapitel 2.4.2 ist unklar geblieben, ob die quantitativen Kräfte im Werkzeugkontakt in alle drei Raumrichtungen beim Schleifen mit Winkelschleifern vorhergesagt werden können. Daher wird zuerst Teilforschungsfrage 2.1 untersucht und anschließend im nachfolgenden Kapitel mit dem Stand der Forschung aus anderen Bereichen verglichen. Abschließend werden die Beantwortung von Teilforschungsfrage 2.2 und die Übertragbarkeit der Forschungsergebnisse diskutiert.



### 6.3.1 Diskussion zur Teilforschungsfrage 2.1

In diesem Kapitel wird Teilforschungsfrage 2.1 untersucht, die wie folgt lautet:

**Teilforschungsfrage 2.1:** Für welche Krafrichtungen und Tätigkeiten lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt anhand von Sensordaten durch statistische Modelle vorhersagen?

Es wird die Leistung der GPR-Modelle zur Vorhersage der Kräfte im Werkzeugkontakt für unterschiedliche Krafrichtungen und Tätigkeiten diskutiert. Dazu wird der maschinenübergreifende Durchschnitt der Ergebnisse in Tabelle 6.1 dargestellt. Die Ergebnisse für die Winkelschleifer GWS18 und CCG18 sind in Tabelle B und in Tabelle C im Anhang dargestellt.

Die Ergebnisse zeigen für beide Winkelschleifer eine gute Leistung des GPR-Modells für die Radialkraft bei der Tätigkeit *Trennen mit einer Trennscheibe* ( $rMAE = 19,67\%$  und  $r = 0,80$ ) sowie für die Tangentialkraft ( $rMAE = 18,21\%$  und  $r = 0,82$ ) und die Normalkraft ( $rMAE = 11,44\%$  und  $r = 0,84$ ) für die anderen drei Tätigkeiten. Eine Erklärung für die gute Leistung der Normalkraft besteht im physikalischen Zusammenhang der Normalkraft mit dem Drehmoment des Antriebsstrangs des Winkelschleifers. Über die Motorkennlinie besteht ein Zusammenhang des Drehmoments mit dem Strom des Motors (Matthiesen et al., 2016). Diese Erklärung lässt sich auf die Radialkraft bei der Tätigkeit *Trennen mit einer Trennscheibe* übertragen. Eine Erklärung für die gute Leistung der Schleiftangentialkraft besteht im physikalischen Zusammenhang der Tangentialkraft mit der Normalkraft über den Reibungskoeffizienten zwischen Werkzeug und Werkstück (Das et al., 2018). In den Grundlagen wurde in Gleichung 2.4 dargelegt, dass die Zusammenhänge komplexer sind. Die Aufteilung der Kräfte in  $F_{N,SI}$  und  $F_{N,C}$  sowie  $F_{T,SI}$  und  $F_{T,C}$  zeigt, dass die Vorhersage über ein statistisches Modell zielführend ist, da die Kraftanteile stochastisch verteilt sind und kaum gemessen werden können.

Die Vorhersage der Querkraft bei der Tätigkeit *Trennen mit einer Trennscheibe* ( $rMAE = 566,95\%$  und  $r = 0,13$ ) zeigt eine schlechte Leistung für das GPR-Modell. Die Leistung des GPR-Modells zur Vorhersage der Führungskraft ( $rMAE = 87,02\%$  und  $r = 0,37$ ) ist bei den anderen drei Tätigkeiten ebenfalls schlecht. Dies ist durch die im Vergleich zu den anderen Richtungen geringeren Kraftwerte in axialer Krafrichtung zu erklären. Aufgrund der geringen Kraftwerte haben das stochastische Verhalten des Schleifprozesses und die lokalen Vibrationen des Werkzeugs einen verhältnismäßig größeren Einfluss als in den anderen Krafrichtungen. Eine weitere Erklärung ist der starke Einfluss der anwendenden

Person auf die Führungskraft durch seine Bewegung und Arbeitsweise. Das Verhalten der anwendenden Person wird durch die gewählten Messgrößen (Strom, Spannung, Beschleunigung, Winkelgeschwindigkeit und Magnetfeld) im Gegensatz zum Maschinenverhalten nur schwach repräsentiert. Messgrößen zur Erfassung des Verhaltens der anwendenden Person werden in der Regel durch Sensoren erfasst. Diese sind an der anwendenden Person appliziert oder extern aufgestellt, beispielsweise als Kamera-System. Um die Kräfte in x-Richtung mit höherer Genauigkeit vorhersagen zu können, sollten weitere Sensoren verwendet werden, die an der anwendenden Person appliziert oder in der Umgebung aufgestellt sind. Dies würde jedoch die Skalierbarkeit und die unbeobachtete Erfassung der PUI beeinträchtigen.

Beim Vergleich der Tätigkeiten wird deutlich, dass die GPR-Modelle für die Tätigkeiten *Schruppen mit einer Schrupscheibe* und *Schruppen mit einer Fiberscheibe* die besten Leistungen aufweisen. Dies lässt sich durch die überwiegend lineare Bewegung des Werkzeugs durch die anwendende Person erklären, wie in Abbildung 6.2 skizziert ist. Aufgrund der überwiegend linearen Bewegung sind der Winkel zwischen Maschine und Werkstück und die seitliche Bewegung von untergeordneter Bedeutung. Eine weitere Erklärung ist die höhere Steifigkeit und geringere Dämpfung der Schrupscheibe und des Stütztellers der Fiberscheibe im Vergleich zur Fächerscheibe, was zu einem geringeren Informationsverlust zwischen dem Werkzeugkontakt und dem Sensormodul zwischen Maschine und Akku führt. Bei der Tätigkeit *Schleifen mit einer Fächerschleifscheibe* lassen sich die schlechteren Ergebnisse für die Führungs- und Tangentialkraft durch die mehrdimensionale Bewegung in dieser Tätigkeit erklären. Die mehrdimensionale Bewegung erschwert die Zuordnung der gemessenen Kräfte zur Führungs- und Tangentialkraft durch das feste, vom Winkelschleifer abweichende Koordinatensystem des Versuchsaufbaus. Dies führt schon vor der Vorhersage der Kraft zu einem Fehler im Trainingsdatensatz, der nicht durch die unabhängigen Variablen erklärbar ist. Bei der Tätigkeit *Trennen mit einer Trennscheibe* sind der Eingriffswinkel und Kontaktpunkt volatil, sodass keine Auftrennung in Normal- und Tangentialkraft sinnvoll ist. Die Leistung des GPR-Modells für die Radialkraft erreicht ähnlich gute Werte wie die Tangentialkraft und Normalkraft bei den anderen Tätigkeiten. Die Vorhersage der Querkräfte weist mit Abstand die schlechteste Leistung auf. Beim *Trennen mit einer Trennscheibe* beschreiben die Querkräfte Querschwingungen beziehungsweise ein Flattern der Trennscheibe. Die Querkräfte und damit die Querschwingungen konnten in dieser Studie mit den Messdaten des Sensormoduls nicht mit ausreichender Güte vorhergesagt werden.

Zusammenfassend wurde gezeigt, dass die Radialkraft beim *Trennen mit einer Trennscheibe* ( $rMAE = 19,67\%$  und  $r = 0,80$ ) sowie die Tangentialkräfte ( $rMAE = 18,21\%$  und  $r = 0,82$ ) und die Normalkräfte ( $rMAE = 11,44\%$  und  $r = 0,84$ ) bei den anderen drei Tätigkeiten gut vorhergesagt werden können. Die Führungskräfte können nur schlecht ( $rMAE = 87,02\%$  und  $r = 0,37$ ) und die Querkraft beim *Trennen mit einer Trennscheibe* kann nicht vorhergesagt werden ( $rMAE = 566,95\%$  und  $r = 0,13$ ).

Somit wurde Teilforschungsfrage 2.1 beantwortet. Mit der Tangentialkraft und Normalkraft sowie der Radialkraft beim *Trennen mit einer Trennscheibe* können aufgrund des Zusammenhangs mit der Produktivität und Qualität des Arbeitsergebnisses die für die Produktentwicklung besonders relevanten Kräfte mit der vorgestellten Vorgehensweise wie auch dem GPR-Modell vorhergesagt werden.

### 6.3.2 Vergleich der Ergebnisse mit dem Stand der Forschung

In einer Vorstudie (Matthiesen et al., 2018), die im Rahmen dieser Forschungsarbeit durchgeführt wurde, wurde das Bestimmtheitsmaß  $R^2$  als Bewertungsgröße verwendet. Zum Vergleich der Ergebnisse wurden diese in Tabelle F im Anhang aufbereitet. Die Ergebnisse der Vorstudie zeigen eine bessere Leistung des statistischen Modells für die Tangentialkraft ( $R^2 = 0,91$ ) und die Normalkraft ( $R^2 = 0,97$ ) im Vergleich zur Tangentialkraft ( $R^2 = 0,67$ ) und Normalkraft ( $R^2 = 0,79$ ) dieser Studie. Die geringere Leistung des statistischen Modells im Vergleich zu den anderen Krafrichtungen gilt sowohl für die Führungskraft und die Querkraft der Vorstudie ( $R^2 = 0,33$ ) als auch für diese Studie ( $R^2 = 0,35$ ). Die geringe Leistung des statistischen Modells dieser Studie entspricht dem erwarteten Ergebnis, da die Qualität der Sensordaten als abhängige Variablen für das statistische Modell im Vergleich zu dieser Studie besser war und die Qualität der unabhängige Variable durch die Verwendung desselben Versuchsaufbaus zur Messung der Kräfte identisch war. Die bessere Qualität der abhängige Variablen wird im folgenden Absatz ausgeführt.

In der Vorstudie (Matthiesen et al., 2018) wurden kabelgebundene Sensoren mit einem Labor-Messsystem statt einem Sensormodul verwendet. So lag eine höhere Abtastfrequenz (20 kHz) und ein geringeres Signal-Rausch-Verhältnis vor. Einen großen Einfluss auf die Signalqualität haben außerdem die Lage und Applikation der Sensoren in Bezug auf den Ort der Kräfte im Werkzeugkontakt. Während in der Vorstudie der Beschleunigungssensor fest am Getriebegehäuse verschraubt war, sind die Sensoren im Sensormodul aufgrund des Polymergehäuses in dieser Studie weiter vom Werkzeug-Werkstück-Kontakt entfernt und weniger starr verbunden. Zudem wurden in dieser Studie akkubetriebene Winkelschleifer verwendet, während

in der Vorstudie kabelgebundene verwendet wurden. Dies führt zu den in Kapitel 5.3.2 diskutierten Störgrößen des Akku-Ladezustands.

Der Vergleich mit dem Modell zur Vorhersage der Andruckkraft von Voet et al. (2019), das auf einer binären Klassifikation der Kraftbereiche basiert, zeigt eine ähnliche Leistung. Während hier die Kraftwerte in alle drei Raumrichtungen einschließlich der Unsicherheit der Vorhersage vorhergesagt werden, liefert das Modell von Voet et al. (2019) nur eine eingeschränkte Datenbasis für die Produktentwicklung durch die Vorhersage der zwei Kraftbereiche 2,5 N bis 5 N und über 8 N.

In beiden genannten Studien wurde die CV verwendet. Beim Schleifen mit Power-Tools weichen einzelne Versuche voneinander ab. Daher ergibt sich für die Verwendung der LOTO CV in dieser Studie eine geringere Leistung des GPR-Modells im Vergleich zur CV. Dafür berücksichtigt die mit LOTO CV ermittelte Leistung die Abweichung der einzelnen Versuche voneinander. Somit handelt es sich um eine realitätsnähere Validierung der Modelle.

Die Vorhersage von Kräften im Werkzeugkontakt durch Machine-Learning beim automatisierten Schleifen mit Werkzeugmaschinen zeigt im Durchschnitt eine höhere Leistung für das automatisierte Schleifen als für das manuelle Schleifen mit Power-Tools. Eine Ursache dafür sind Störgrößen beim Schleifen mit Power-Tools wie die Arbeitsweise der anwendenden Person, der Ladezustand des Akkus und die geringere Steifigkeit des Werkzeugs im Vergleich zu Werkzeugen, die in Werkzeugmaschinen eingesetzt werden. Dies steht im Einklang mit dem erwarteten Ergebnis, dass die Kräfte beim manuellen Schleifen mit Power-Tools volatil sind, da sie von der Bewegung und den Kräften der anwendenden Person beeinflusst werden (Odum et al., 2014). Aufgrund dieser Störgrößen sind die Kräfte beim Schleifen mit Power-Tools schwieriger vorherzusagen. Dies zeigt, dass noch Bedarf an Studien zur Vorhersage der Kräfte im Werkzeugkontakt bei starkem Einfluss von Störgrößen besteht.

Der Vergleich mit den Studien von Choi et al. (2019), Giarmatzis et al. (2020), H. Lim et al. (2019), Stetter et al. (2019) und Wu et al. (2020) zur Vorhersage von Körperkräften und -bewegungen wie Kniegelenkskräften mit einer oder mehreren IMU zeigen einen ähnlichen Ansatz (Leave-One-Out-Kreuzvalidierung und klassische sowie Deep-Learning-Ansätze) und ähnliche Ergebnisse. Beispielsweise erreichen (Stetter et al. (2019) mit ihren Modellen ähnliche Leistungen für verschiedene Tätigkeiten für die vertikalen Gelenkkräfte ( $r = 0,60$  bis  $r = 0,94$ ), für die anterior-posterioren Gelenkkräfte ( $r = 0,73$  bis  $r = 0,97$ ) und für die medial-lateralen Gelenkkräfte ( $r = 0,25$  bis  $r = 0,60$ ). Bei der Vorhersage von Körperkräften

entstehen die Störgrößen vor allem durch die anwendende Person. Bei der Vorhersage beim Schleifen besteht die Herausforderung in der zusätzlichen Berücksichtigung von Störgrößen wie dem Werkzeugverschleiß, der Temperatur des Winkelschleifers, dem Ladezustand des Akkus und prozessbedingten Streuungen. Das ähnliche Vorgehen, die Verwendung von IMU und die ähnliche Leistung der Modelle deutet darauf hin, dass das in diesem Kapitel vorgestellte Vorgehen und die Modelle auch auf den Bereich der Biomechanik übertragbar sind.

### 6.3.3 Diskussion zur Teilforschungsfrage 2.2

In diesem Kapitel wird Teilforschungsfrage 2.2 untersucht, die wie folgt lautet:

**Teilforschungsfrage 2.2:** Mit welcher Abtastrate lassen sich die Kräfte im Werkzeugkontakt aus Sensordaten vorhersagen?

Im Folgenden wird der Einfluss der Abtastrate ausgehend von der Abtastrate 10 Hz als Referenz diskutiert, da bei dieser Abtastrate für 6 von 11 Krafrichtungen die beste Leistung zur Vorhersage erzielt wurde. Dazu wird der geräteübergreifende Durchschnitt der Ergebnisse in Tabelle 6.2 herangezogen. Die Ergebnisse für die Winkelschleifer GWS18 und CCG18 sind in Tabelle D und in Tabelle E im Anhang dargestellt. Das erwartete Ergebnis ist, dass die Leistung des GPR-Modells mit höherer vorherzusagender Abtastrate abnimmt, da weniger Sensordaten pro Segment zu Verfügung stehen.

Die Reduzierung der Abtastrate von 10 Hz auf 1 Hz durch Vergrößerung der Segmentlänge von 0,1 s auf 1 s führt nicht zu einer generellen Verbesserung der Leistung des GPR-Modells, sondern in den meisten Fällen zu einer Verschlechterung. Bei dieser Abtastrate wurde für 2 von 11 Krafrichtungen die beste Leistung zur Vorhersage erzielt. Dies lässt sich durch den von der anwendenden Person aktiv erzeugten Anteil der Kraft im Werkzeugkontakt erklären, der eine Frequenz bis zu 10 Hz hat (Kern, 2009; Lindenmann, 2022). Daher fließt dieser Anteil in die unabhängigen Variablen (Sensordaten des Sensormoduls), aber nicht in die abhängige Variable (Kraft im Werkzeugkontakt) ein. Zudem ist die Anzahl der Segmente zehnmal kleiner, was die Parametrierung von GPR-Modellen erschwert.

Die Erhöhung der Abtastrate von 10 Hz auf 20 Hz in Form der Verkleinerung der Segmentlänge von 0,1 s auf 0,05 s führt nicht, wie erwartet, zu einer generellen Verschlechterung des GPR-Modells. Bei dieser Abtastrate wurde für 3 von 11 Krafrichtungen die beste Leistung zur Vorhersage erzielt. Für die Vorhersage größerer dynamischer Kräfte im Werkzeugkontakt ist die Bedeutung von Merkmalen

im Frequenzbereich besonders hoch. Die kürzere Segmentlänge bedeutet, dass die Datenmenge in einem Segment kleiner ist, was zu einer geringeren Abtastrate bei der FFT führt. Dies bedeutet, dass viele Merkmale im Frequenzbereich bei kleineren Segmentlängen für Sensordaten mit einer Frequenz von 1000 Hz nicht sinnvoll genutzt werden können. Zur Vorhersage von Abtastraten von 20 Hz oder darüber hinaus sollten Sensordaten bei höheren Frequenzen gemessen werden, um auch bei kleinen Segmentlängen mehr Merkmale im Frequenzbereich zu erhalten.

Zusammenfassend wurde gezeigt, dass die in Teilforschungsfrage 2.1 gut vorhersagbaren Kräfte mit allen drei gewählten Abtastraten ähnlich gut vorhergesagt werden können. In dieser Studie lieferte die Abtastrate von 10 Hz für die meisten Krafrichtungen das beste Ergebnis. Aus den Ergebnissen ist der Einfluss der Abtastrate im Vergleich zum Einfluss der Tätigkeit und der Krafrichtung als gering zu bewerten.

Somit wurde Teilforschungsfrage 2.2 beantwortet. Aufgrund der Bedeutung des aktiven Verhaltens der anwendenden Person für die Produktentwicklung lässt sich ableiten, dass bei einem ausreichend großen Datensatz eine Abtastrate von 10 Hz gewählt werden sollte. Bei kleineren Datensätzen sollte die Abtastrate erhöht werden, um den Trainingsdatensatz auf Kosten höherfrequenter Merkmale im Frequenzbereich zu vergrößern.

### **6.3.4 Einschränkungen und Übertragbarkeit der Ergebnisse**

In diesem Kapitel werden zuerst die Leistung und Validierung der statistischen Modelle diskutiert. Die Übertragbarkeit von statistischen Modellen ist immer von einem vielfältigen und repräsentativen Datensatz abhängig. Daher wird im Folgenden auf den Datensatz eingegangen und anhand dessen werden die Übertragbarkeit des statistischen Modells wie auch die Übertragbarkeit des Vorgehens zur Modellbildung diskutiert.

Die Leistung des statistischen Modells wurde mittels verschiedener Hyperparameter in einem mehrstufigen Vorgehen optimiert. Aufgrund dieses Vorgehens kann davon ausgegangen werden, dass die Leistung des GPR-Modells bei diesem Datensatz weitgehend ausgeschöpft wurde. Im Vergleich zu SVM, linearer Regression, Gauß-Kernel, Random Forests und Entscheidungsbäumen erwies sich das GPR-Modell in einer Vorstudie als besser in Bezug auf Leistung und Stabilität der Ergebnisse. Aufgrund der Vielfalt der für die Regression zur Verfügung stehenden Algorithmen kann nicht ausgeschlossen werden, dass andere Methoden wie neuronale Netze, die bereits beispielsweise von Aykut et al. (2007), Giarmatzis et al. (2020), Meddour et al. (2018), Sharma et al. (2008) oder Stetter et al. (2019) erfolgreich für ähnliche

Probleme eingesetzt wurden zu einer noch besseren Leistung geführt hätten. Gerade bei Deep-Learning-Ansätzen mit einer großen Anzahl von Parametern muss ein größerer Datensatz zur Verfügung stehen.

Für den Einsatz von statistischen Modellen in der Nutzungsphase ist es notwendig, das Modell spezifisch für einen Winkelschleifer in Kombination mit einem Werkzeugtyp für jede Krafrichtung bei einer definierten Abtastrate zu parametrieren. Bei jeder Tätigkeit mit einem Winkelschleifer muss für jede Krafrichtung ein Modell parallel ausgeführt werden. Ändert sich die Tätigkeit, müssen auch die Modelle ausgetauscht werden. Daher ist die Kenntnis der Tätigkeit für die Anwendung in der Nutzungsphase notwendig. Dies wird erst durch Modelle zur Vorhersage der Tätigkeit ermöglicht, die in Forschungsfrage 1 untersucht wurden.

Es wurden insgesamt 66 statistische Modelle für die Faktoren Winkelschleifer, Abtastrate, Tätigkeiten und Krafrichtungen gebildet, die mittels LOTO CV validiert wurden. Für die einzelnen Modelle wurden teilweise unterschiedliche Merkmale selektiert und verschiedene Werte für die Hyperparameter optimiert. Dies zeigt, dass für unterschiedliche Winkelschleifer, Abtastraten, Tätigkeiten und Krafrichtungen die statistischen Modelle neu gebildet werden müssen. Dies entspricht dem erwarteten Ergebnis, da die Faktoren stark variieren. So unterscheiden sich die Winkelschleifer beispielsweise durch den Antriebsstrang, das Gehäuse und die damit verbundene Steifigkeit, die Lagerung und unterschiedliche implementierte Regler. Die verschiedenen Abtastraten unterscheiden sich durch einen abweichenden Anteil an aktiven und passiven Interaktionen der anwendenden Person und vor allem der Segmentlänge, was zu unterschiedlichen Merkmalen führt. Die Tätigkeiten unterscheiden sich durch verschiedene Werkzeugtypen, die sich wiederum durch die Steifigkeit und den Dämpfungskoeffizienten unterscheiden. Die verschiedenen Krafrichtungen variieren beispielsweise durch den jeweiligen Einfluss der Maschine und der anwendenden Person.

Der Versuchsraum der manuellen Studie umfasste eine anwendende Person. Der Zusammenhang zwischen den Kräften im Werkzeugkontakt und den Sensordaten des Sensormoduls wird durch die Interaktion mit einer anwendenden Person beeinflusst. Nach Kern (2009) und Lindenmann (2022) kann die Interaktion einer anwendenden Person in ein aktives und passives Verhalten eingeteilt werden. Das aktive Verhalten einer anwendenden Person umfasst Kräfte durch muskuläre Aktivität bis zu einer Frequenz von 10 Hz. Das passive Verhalten hingegen umfasst Kräfte durch dynamische Eigenschaften, die aus an der Interaktion beteiligten Körpermassen hauptsächlich über einer Frequenz von 10 Hz entstehen. Die

Körpermassen beziehen sich vor allem auf die an der Bewegung des Hand-Arm-Systems beteiligten Muskeln. Nach Odum et al. (2014) sind die Einflussgrößen einer anwendenden Person auf den manuellen Schleifprozess die Körperhaltung, Körpermaße, der Muskelaufbau, die Greifkraft, Bewegung sowie die Kräfte der anwendenden Person. Ihre Bewegungen und aufgebrauchten Kräfte adressieren das aktive Verhalten bis 10 Hz. Es stellt sich für das aktive Verhalten einer anwendenden Person die Frage, ob die Versuche im Datensatz genügend Arbeitspunkte für eine Übertragbarkeit auf andere anwendende Personen enthalten. Der übliche Arbeitsbereich wird von Herstellern mit einem Intervall von maximal  $\pm 5$  N beziffert. Durch die Anzahl und Länge der Versuche sowie die Variabilität innerhalb der Versuche kann angenommen werden, dass der übliche Arbeitsbereich des Winkelschleifers (Drehzahl und Kräfte aus dem aktiven Verhalten bis 10 Hz) ausgeschöpft wurde. Abbildung 6.4 zeigt die Variabilität der Kräfte und damit die Ausschöpfung des üblichen Arbeitsbereichs. Da die Körperhaltung, Körpermaße, der Muskelaufbau und die Greifkraft nur die passive Interaktion und damit den Frequenzbereich ab 10 Hz adressieren, sind diese für die Vorhersage der Kräfte im Werkzeugkontakt bis zu einer Abtastrate von 10 Hz von untergeordneter Bedeutung. Für die Sensordaten ist die passive Interaktion teilweise relevant, da hier Frequenzen bis 1000 Hz betrachtet wurden. Es sollte also untersucht werden, ob eine abweichende passive Interaktion einer anwendenden Person, beispielsweise durch einen abweichenden Muskelaufbau, eine Störgröße für die Übertragbarkeit der Vorhersage der Kräfte im Werkzeugkontakt auf andere anwendende Personen darstellt. Da für die gut vorhersagbare Tangentialkraft und Normalkraft sowie Radialkraft beim *Trennen mit einer Trennscheibe* der Einfluss der Maschine größer als für die Führungskraft ist, kann von einem geringen Einfluss und damit von guter Übertragbarkeit auf andere anwendende Personen für diese Kräfte ausgegangen werden.

Der Versuchsraum der manuellen Studie umfasste zwei Winkelschleifer, die unterschiedliche Absolutwerte für die Kräfte im Werkzeugkontakt und deutlich unterschiedliche Absolutwerte für die Sensordaten Strom, Beschleunigung und Magnetfeld aufweisen. Die Leistung der GPR-Modelle zur Vorhersage der Kräfte ist bei beiden Winkelschleifern ähnlich, wie in den Ergebnissen in Tabelle B, Tabelle C, Tabelle D und Tabelle E aufgezeigt. Dies verdeutlicht, dass das Vorgehen zur Modellbildung und Modellvalidierung auf andere Winkelschleifer übertragbar ist. Im Vergleich zu anderen Systemen zeichnet sich die Vorhersage der Kräfte im Werkzeugkontakt bei Winkelschleifern vor allem durch den Schleifprozess, die Störgrößen und die Interaktion mit der anwendenden Person aus. Daher ist anzunehmen, dass das Vorgehen zur Modellbildung und Modellvalidierung auf Power-Tools, die zum Schleifen verwendet werden, übertragbar ist.



Der Versuchsraum umfasste vier Tätigkeiten. Da die Tangentialkraft und die Normalkraft bei allen getesteten Tätigkeiten gut vorhergesagt werden konnten, kann davon ausgegangen werden, dass die Vorhersage der Kräfte im Werkzeugkontakt für andere Tätigkeiten ebenfalls erfolgreich sein wird, wenn das Modell speziell für diese neue Tätigkeit parametrisiert wurde. Es sollte in weiteren Studien untersucht werden, wie übertragbar die Vorhersage mit demselben Werkzeug auf andere Werkstücke ist. Dies stellt eine besondere Herausforderung dar, da die Validierung der Vorhersage nur durch den Vergleich der gemessenen Kraft im Werkzeugkontakt mit den vorhergesagten Kraftwerten möglich ist.

Der Versuchsraum umfasst nur das ordnungsgemäße Arbeiten durch eine anwendende Person mit Erfahrung im Umgang mit Winkelschleifern. Die Übertragbarkeit auf Missbrauchsfälle, bei denen der Arbeitsprozess erheblich von einer ordnungsgemäßen Arbeitsweise abweicht, beispielsweise durch Flattern des Werkzeugs aufgrund einer sehr niedrigen Andruckkraft, sollte untersucht werden. Auch kann die Übertragbarkeit auf Laien untersucht werden, deren Arbeitsbereich deutlicher als  $\pm 5$  N von der empfohlenen Andruckkraft abweichen kann.

## 6.4 Zwischenfazit

In dieser Studie wurde die Machbarkeit der Vorhersage der Kräfte im Werkzeugkontakt für unterschiedliche vorherzusagende Abstraten aus Sensordaten einer IMU, einem Stromsensor und einem Spannungssensor an zwei Winkelschleifern untersucht.

Es wurden Teilforschungsfrage 2.1 und Teilforschungsfrage 2.2 beantwortet. Somit lässt sich Forschungsfrage 2 beantworten, die wie folgt lautet:

**Forschungsfrage 2:** Wie lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt anhand von Sensordaten durch statistische Modelle vorhersagen?

Mit einem GPR-Modell, das mit dem vorgestellten Vorgehen gebildet und validiert wurde, lassen sich die Tangentialkraft, Normalkraft und die Radialkraft beim *Trennen mit einer Trennscheibe* im Werkzeugkontakt aus Sensordaten unter Angabe des Vorhersageintervalls vorhersagen.

Die Übertragbarkeit des Vorgehens auf andere Winkelschleifer wurde anhand von zwei verschiedenen Winkelschleifern demonstriert. Die Übertragbarkeit des Vorgehens auf andere Tätigkeiten wurde anhand von vier verschiedenen

Tätigkeiten demonstriert. Von einer guten Übertragbarkeit des Vorgehens auf andere anwendende Personen kann für die Tangentialkraft, die Normalkraft und für die Radialkraft beim *Trennen mit einer Trennscheibe* bis 10 Hz bei ordnungsgemäßer Verwendung des Winkelschleifers ohne Missbrauchstätigkeiten ausgegangen werden. Es ist anzunehmen, dass aufgrund der Interaktion mit der anwendenden Person und des Schleifprozesses das Vorgehen auch auf andere Power-Tools, die zum Schleifen verwendet werden, und zum Teil auch auf andere Mensch-Maschine-Systeme übertragbar ist. Aufgrund der Ähnlichkeiten mit dem Stand der Forschung kann davon ausgegangen werden, dass das Vorgehen auch auf den Bereich der Biomechanik übertragbar ist.

Die Vorhersage von Kräften im Werkzeugkontakt mit dem vorgeschlagenen GPR-Modell ermöglicht die Datenerfassung und -auswertung mit einem PEID in der Nutzungsphase. Die erreichte Leistung des GPR-Modells in Kombination mit dem Vorhersageintervall ermöglicht die Verwendung der Kraft im Werkzeugkontakt für die Produktentwicklung von Power-Tools. Die Unsicherheit aus dem Vorhersageintervall kann beispielsweise in der Auslegung von Werkzeugen berücksichtigt werden. Zudem ermöglicht die Vorhersage der Kraft im Werkzeugkontakt die Entwicklung und den Einsatz einer adaptiven Regelung, eines vorausschauenden Wartungsmodells mittels Predictive Maintenance, eines Modells zur Vorhersage des Materialabtrags oder eines Modells zur erreichten Oberflächenqualität.

## 7 Erfassung der Kräfte am Antriebsstrang durch Modellierung des Werkzeugs

In Kapitel 6 wurde die Erfassung der Kräfte im Werkzeugkontakt vorgestellt. Für die Auslegung des Antriebsstrangs oder einer hierfür unterstützenden Simulation des Schwingungsverhaltens eines Antriebsstrangs sind jedoch die Kenntnisse über die Kräfte am Antriebsstrang erforderlich. Auch für Lebensdauertests mit mehrdimensionaler Belastung an einem Prüfstand sind die Kräfte am Antriebsstrang erforderlich (Dörr, Mertens et al., 2021; Matthiesen, Gwosch, Mangold et al., 2017). Bei höherfrequenten Kraftanregungen im Bereich der 1. Ordnung der Arbeitswelle und nachgiebigen Werkzeugen, beispielsweise einer Fächerschleifscheibe, kann nicht von einem frequenzunabhängigen Übertragungsverhalten ausgegangen werden. Im Stand der Forschung wurde aufgezeigt, dass Übertragungsfunktionen eine gängige Modellierung bei frequenzabhängigem Übertragungsverhalten darstellen.

Daher beschäftigt sich dieses Kapitel mit Forschungsfrage 3:

**Forschungsfrage 3:** Wie lassen sich bei Winkelschleifern mittels Übertragungsfunktionen die Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt berechnen?

Mit der Beantwortung der Forschungsfrage wird gezeigt, wie sich die Kräfte am Antriebsstrang aus Kräften im Werkzeugkontakt für verschiedene Werkzeuge mittels experimentell gemessener Übertragungsfunktionen berechnen lassen. Der Schleifprozess mit einem Werkzeug kann in verschiedene Arbeitspunkte unterteilt werden. Daher ist das erste Ziel dieses Kapitels, für verschiedene Werkzeuge und verschiedene Arbeitspunkte Übertragungsfunktionen zu bilden, mit denen die Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt berechnet werden können. Dabei wird geprüft, mit welcher Güte eine Zusammenführung der Übertragungsfunktionen verschiedener Arbeitspunkte möglich ist.

Bei der Aufprägung einer stationären Kraft im Werkzeugkontakt (Systemeingang) liegt diese aufgrund der Krafterhaltung äquivalent am Antriebsstrang (Systemausgang) an. Durch das frequenzabhängige Übertragungsverhalten des Werkzeugs verändern sich jedoch im dynamischen Bereich die Amplituden und Frequenzen der Kräfte. Diese sind relevant, da die Amplituden und Frequenzen im Kraftsignal einen Einfluss auf die Belastung und damit auf die Betriebsfestigkeit

haben (Radaj & Vormwald, 2007). Es bleibt unklar, in welchem Maße sich die Kräfte durch das frequenzabhängige Übertragungsverhalten des Werkzeugs verändern. Somit ist unklar, welchen Nutzen die Modellierung des Übertragungsverhaltens besitzt, beispielsweise für die Auslegung des Antriebsstrangs. Daher ist das zweite Ziel des Kapitels die Untersuchung, inwieweit sich die Kräfte am Antriebsstrang von den Kräften im Werkzeugkontakt unterscheiden. Dies ermöglicht eine Aussage darüber, ob die Modellierung eines Werkzeugs für die Bestimmung der Kräfte am Antriebsstrang von Nutzen ist.

Somit gliedert sich Forschungsfrage 3 in Teilforschungsfrage 3.1 und Teilforschungsfrage 3.2:

**Teilforschungsfrage 3.1:** Wie gut lassen sich Übertragungsfunktionen verschiedener Arbeitspunkte eines Werkzeugs zu einer arbeitspunktunabhängigen Übertragungsfunktion zusammenführen?

**Teilforschungsfrage 3.2:** Wie unterscheiden sich die mit der Übertragungsfunktion berechneten Kräfte am Antriebsstrang von den Kräften im Werkzeugkontakt?

Die Beantwortung von Teilforschungsfrage 3.1 wird in Kapitel 7.1 vorgestellt. Die Beantwortung von Teilforschungsfrage 3.2 wird in Kapitel 7.2 vorgestellt.

*Der Versuchsaufbau, das Studiendesign, die Ergebnisse und die Diskussion dieses Kapitels basieren zu Teilen auf der nachfolgenden Veröffentlichung:*

*- „Approach for Modelling the Dynamic Transmission Behavior of Grinding Discs Using Transfer Functions“ (Dörr, Dürkopp et al., 2021).*

*Teile des folgenden Textes sind ohne Veränderung in übersetzter Form aus der Veröffentlichung übernommen. Sie werden aus Gründen der Übersichtlichkeit nicht gesondert gekennzeichnet.*

## **7.1 Zusammenführung von Übertragungsfunktionen verschiedener Arbeitspunkte**

In diesem Kapitel erfolgt die Modellierung des Übertragungsverhaltens von drei Werkzeugen mittels Übertragungsfunktionen für verschiedene Arbeitspunkte. Dabei wird die Güte bei der Zusammenführung der Übertragungsfunktionen verschiedener Arbeitspunkte zu einer Übertragungsfunktion quantitativ und qualitativ untersucht.

Die Bestimmung des Übertragungsverhaltens eines Werkzeugs erfolgt durch die experimentelle Bestimmung des Eingangs- und Ausgangssignals. Dies gestaltet sich bei einem rotierenden Werkzeug schwierig, da die Signale bei einer hohen

Drehzahl gemessen werden müssen (Dong et al., 2020). Deshalb muss die Messung des Eingangs- und des Ausgangssignals bei konstanten Bedingungen eines definierten Arbeitspunktes auf einem Prüfstand erfolgen. Aus dem Eingangs- und Ausgangssignal zu einem Arbeitspunkt kann das Übertragungsverhalten durch eine Übertragungsfunktion angenähert werden. Dabei bleibt unklar, mit welcher Güte die Übertragungsfunktionen verschiedener Arbeitspunkte zusammengeführt werden können. Dies führt zu Teilforschungsfrage 3.1:

**Teilforschungsfrage 3.1:** Wie gut lassen sich Übertragungsfunktionen verschiedener Arbeitspunkte eines Werkzeugs zu einer arbeitspunktunabhängigen Übertragungsfunktion zusammenführen?

Zur Beantwortung der Teilforschungsfrage werden die Kräfte im Werkzeugkontakt als Eingangssignal und die Kräfte am Antriebsstrang als Ausgangssignal bei drei verschiedenen Werkzeugen an einem Prüfstand erhoben. Es werden daraus Übertragungsfunktionen für verschiedene Arbeitspunkte gebildet. Die gebildeten Übertragungsfunktionen werden auf Abweichungen untersucht, um die Güte bei der Zusammenführung verschiedener Arbeitspunkte zu einer Übertragungsfunktion zu bewerten.

### 7.1.1 Versuchsaufbau und Bildung der Übertragungsfunktionen

In diesem Kapitel werden der Prüfstand zur Messung der Kraftverläufe, das Vorgehen zur Bildung der Übertragungsfunktionen, der Versuchsplan und die Datenauswertung vorgestellt. Es wurden drei verschiedene Werkzeuge untersucht: Eine Fächerschleifscheibe, eine Trennscheibe und eine Schruppscheibe. Die Werkzeuge sind einschließlich der Koordinatensysteme im Werkzeugkontakt und am Antriebsstrang in Abbildung 7.1 dargestellt.




Abbildung 7.1: Untersuchte Werkzeuge, einschließlich Koordinatensysteme im Werkzeugkontakt und am Antriebsstrang. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 4-5)

Für die Erfassung der Rohdaten wurde ein Prüfstand des Institut für Werkzeugforschung und Werkstoffe e.V. (IFW) im Rahmen eines Verbundprojektes

verwendet. Der Prüfstand kann die Kräfte in allen drei Richtungen im Werkzeugkontakt und am Antriebsstrang für verschiedene Arbeitspunkte messen. Eine Skizze des Prüfstands ist in Abbildung 7.2 dargestellt.




Abbildung 7.2: Skizze des Prüfstands zur Messung der Kräfte in allen drei Richtungen im Werkzeugkontakt und am Antriebsstrang für verschiedene Arbeitspunkte. Übersetzt aus Dörr, Dürkopp et al. (2021, S. 2)

Der Prüfstand besteht aus einer Vorschubeinheit für das Werkstück und einer Antriebseinheit für das Werkzeug. Die Vorschubeinheit besteht aus einer Lineareinheit, mit der das Werkstück mit einem Kontaktwinkel von  $30^\circ$  auf das Werkzeug gedrückt wird. Der Kontaktwinkel beträgt für die Schruppscheibe und die Fächerschleifscheibe konstant  $30^\circ$ . Für die Trennscheibe liegt der Kontaktwinkel bei  $90^\circ$ . Über die Vorschubeinheit wird auf eine konstante Vorschubkraft geregelt. Die Antriebseinheit besteht aus einem Synchronmotor, mit dem das Werkzeug auf eine konstante Drehzahl geregelt wird. Der Prüfstand ermöglicht die Messung dynamischer Kräfte in drei Richtungen bis zu einer Frequenz von 200 Hz auf der Antriebsseite und auf der Werkstückseite, wobei auf eine konstante Vorschubkraft geregelt wird.

Wie aus Formel 2.5 hervorgeht, beeinflussen die Umfangsgeschwindigkeit, der Reibungskoeffizient, die Normalkraft, die Kraftkomponenten der Normalkraft und der Tangentialkraft zur Zerspanung die Schleifleistung. Die Umfangsgeschwindigkeit und die Normalkraft sind die Variablen, die sich am einfachsten durch die anwendende Person beeinflussen lassen. Eine unabhängige Betrachtung der

Umfangsgeschwindigkeit und der Normalkraft, wie in den Grundlagen 0 dargestellt, ermöglicht die maschinenunabhängige Untersuchung von Arbeitspunkten. Daher werden im Rahmen dieser Studie Arbeitspunkte mit Bezug auf die Normalkraft und die Umfangsgeschwindigkeit untersucht. Letztere wird im Rahmen der Studie mit der Drehzahl des Werkzeugs beschrieben.

Es wurde ein Versuchsplan entwickelt, um die Kräfte zur Bildung von Übertragungsfunktionen für verschiedene Arbeitspunkte zu messen. Um die drei Werkzeugtypen in einem realitätsnahen Arbeitsbereich zu testen, wurden die Faktorwerte des Versuchsplans anhand von Messdaten aus einer manuellen Versuchsreihe einer professionellen anwendenden Person mit einem kabelgebundenen Winkelschleifer mit einer Leistung von 800 Watt bestimmt. Die Versuche sind in Dörr, Zimprich et al. (2019) veröffentlicht. Es wurde der Faktor *Normalkraft* mit fünf Faktorstufen und der Faktor *Drehzahl* mit vier Faktorstufen variiert. Daraus wurde ein vollfaktorieller Versuchsplan mit zwei Replikationen entwickelt, was zu 40 Versuchen pro Werkzeug führt. Der Versuchsplan ist in Tabelle 7.1 dargestellt.

Tabelle 7.1: Versuchsplan zur Messung der Kräfte im Werkzeugkontakt und am Antriebsstrang bei maschinenunabhängigen Arbeitspunkten. Übersetzt aus Dörr, Dürkopp et al. (2021, S. 3)

Fächerschleifscheibe: 40 Versuche (2 Replikationen)

Normalkraft in N	20	25	30	35	40
Drehzahl in min <sup>-1</sup>	5500	6000	6500	7000	

Trennscheibe: 40 Versuche (2 Replikationen)

Normalkraft in N	15	20	25	30	35
Drehzahl in min <sup>-1</sup>	5500	6000	6500	7000	

Schruppscheibe: 40 Versuche (2 Replikationen)

Normalkraft in N	35	40	50	60	70
Drehzahl in min <sup>-1</sup>	5500	6000	6500	7000	

Die Versuche wurden randomisiert durchgeführt. Während eines Versuchs wurde der Motor auf eine konstante Drehzahl geregelt. Das Werkstück wurde mit der definierten Normalkraft auf das Werkzeug angedrückt. Die Versuchsdauer betrug für die Fächerschleifscheibe und die Schruppscheibe 30 Sekunden. Bei der Trennscheibe dauerte der Versuch bis zum Durchtrennen des Werkstücks. Für

einen konstanteren Schleifprozess wurden die Werkzeuge in vier Vorversuchen eingefahren. Die Erstellung des Versuchsplans erfolgte im Rahmen dieser Forschungsarbeit. Die Versuche wurden auf Basis des Versuchsplans vom Institut für Werkzeugforschung und Werkstoffe e.V. (IFW) im Zuge eines Verbundprojekts durchgeführt. Innerhalb dieser Forschungsarbeit wurden die Rohdaten ausgewertet und die Übertragungsfunktionen gebildet. Ein Versuch bei der Fächerschleifscheibe war aufgrund fehlender Messsignale nicht auswertbar. Daher wurden für die Fächerschleifscheibe nur 39 Versuche ausgewertet.

Die Modellierung des Übertragungsverhaltens eines Werkzeugs aus Übertragungsfunktionen wurde anhand der Rohdaten getrennt für alle drei Richtungen durchgeführt. Die Eingangsgrößen für die Parametrierung der Übertragungsfunktionen sind die Messsignale der Kräfte im Zeitbereich, die von den Kraftsensoren in allen drei Richtungen auf beiden Seiten des Prüfstands gemessen wurden. Die Rohdaten wurden um Ausreißer, Offset und Drift bereinigt. Die Messsignale wurden mit Tiefpassfilter von 200 Hz gefiltert, um die Daten ohne Eigenfrequenzen des Prüfstands zu analysieren. Das Koordinatensystem der Vorschubeinheit wurde so rotiert, dass es mit dem Koordinatensystem des Antriebsstrangs übereinstimmt.

Aus den Signalen der Kraft wurde mittels einer FFT ein Amplitudenspektrum für jede Richtung berechnet. Die Abtastrate des Amplitudenspektrums wurde auf 1 Hz zusammengeführt. Die Übertragungsfunktionen wurden berechnet, indem das Amplitudenspektrum der Antriebseinheit (Ausgang) durch das Amplitudenspektrum der Vorschubeinheit (Eingang) dividiert wurde. Im Rahmen dieser Forschungsarbeit werden nur die Amplituden betrachtet, da die Amplituden für die Belastung des Antriebsstrangs relevanter sind als die Phasenverschiebung. Somit bildet die Modellierung mittels Übertragungsfunktion ab, ob die Höhe einer Kraft bei einer bestimmten Frequenz verstärkt oder gedämpft wird. Dies wird durch den Verstärkungsfaktor beschrieben. Ein Verstärkungsfaktor größer als eins entspricht einer Verstärkung, während ein Verstärkungsfaktor kleiner als eins einer Dämpfung entspricht.

Abschließend wurden die Übertragungsfunktionen mit einem gleitenden Mittelwertfilter mit einer Spanne von 7 Hz nachbearbeitet. Der Mittelwertfilter wurde mit einer Gauß-Verteilung gewichtet, sodass Datenpunkte, die weiter vom zu filternden Wert entfernt sind, einen niedrigeren Einfluss auf den Filter haben. Die Vorgehensweise zur Bildung von Übertragungsfunktionen eines Werkzeugs bei einem Arbeitspunkt ist am Beispiel der Schruppscheibe bei einer Normalkraft von 70 N und einer Drehzahl von  $6500 \text{ min}^{-1}$  in Abbildung 7.3 dargestellt.



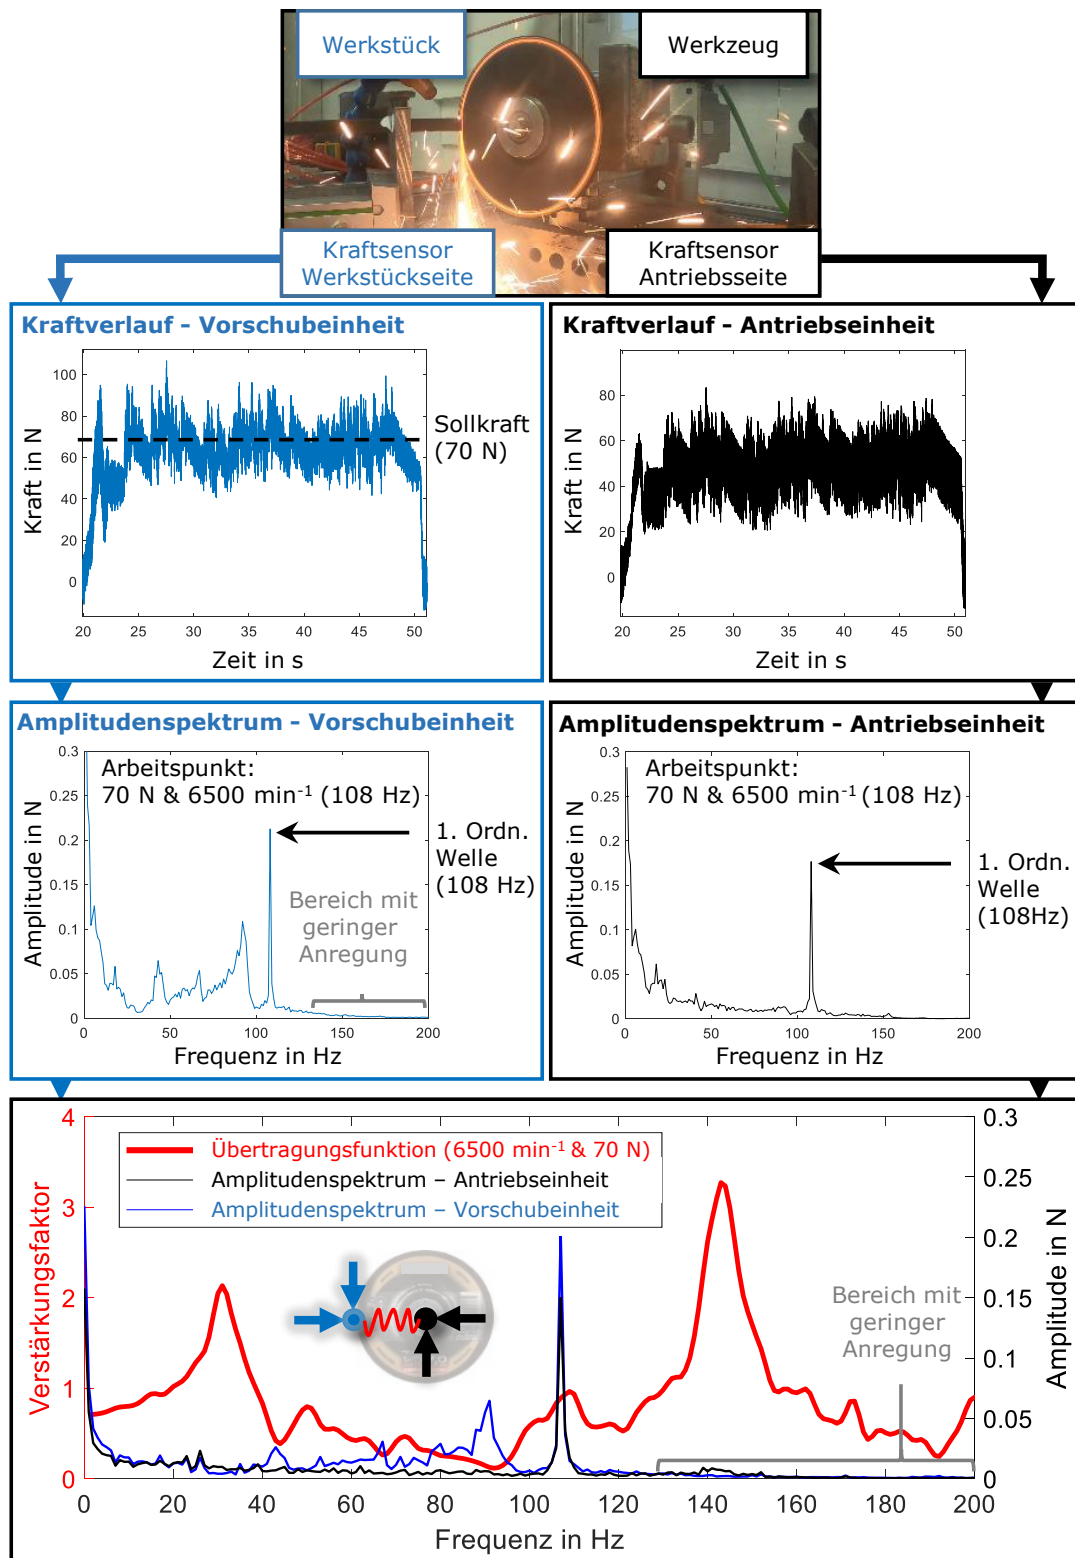


Abbildung 7.3: Vorgehen zur Bildung einer Übertragungsfunktion aus einem einzelnen Versuch am Beispiel für die untersuchte Schruppscheibe bei einer Normalkraft von 70 N und einer Drehzahl von 6500 min<sup>-1</sup>. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 3)

Um Teilforschungsfrage 3.1 zu beantworten, wurden alle 40 Versuche eines Werkzeugs miteinander verglichen. Die Zusammenführung der einzelnen Übertragungsfunktionen erfolgte durch den Median der 40 Übertragungsfunktionen. Es wurde qualitativ analysiert, wie groß die Streuung der 40 Übertragungsfunktionen ist und ob trotz unterschiedlicher Normalkräfte und einer unterschiedlichen Drehzahl Bereiche der Verstärkung und Dämpfung erkennbar sind.

Zudem wurde quantitativ analysiert, wie groß die Abweichung zwischen den 40 Übertragungsfunktionen ist. Dabei wurde die Abweichung zwischen Gruppen berechnet, die sich aus den Faktoren des Versuchsplans ergeben. Die Gruppen, die anhand des Versuchsplans gebildet wurden, und die Berechnung der Abweichung ist im folgenden Abschnitt ausgeführt:

- (1) Übertragungsfunktionen mit gleicher Normalkraft und gleicher Drehzahl:  
Berechnung der Abweichung zwischen Übertragungsfunktionen mit gleicher Normalkraft und gleicher Drehzahl und damit des gleichen Arbeitspunkt. Es wurden die 20 Übertragungsfunktionen des gleichen Arbeitspunktes mit identischen Faktoren miteinander verglichen.
- (2) Übertragungsfunktionen mit gleicher Normalkraft und unterschiedlicher Drehzahl:  
Berechnung der Abweichung zwischen Übertragungsfunktionen mit gleicher Normalkraft und unterschiedlicher Drehzahl. Es wurde für eine Normalkraft jeweils ein vollständiger Paarvergleich zwischen allen 10 Übertragungsfunktionen dieser Normalkraft durchgeführt. Somit wurden 90 ( $10^2 - 10$ ) Abweichungen für eine Faktorstufe der Normalkraft untersucht. Dieses Vorgehen wurde für alle 4 Faktorstufen der Normalkraft durchgeführt. Somit wurden insgesamt  $360 = 4 * (10^2 - 10)$  Abweichungen untersucht.
- (3) Übertragungsfunktionen mit gleicher Drehzahl und unterschiedlicher Normalkraft:  
Berechnung der Abweichung zwischen Übertragungsfunktionen mit unterschiedlicher Normalkraft und gleicher Drehzahl. Das Vorgehen entspricht dem Vorgehen der Gruppe (2). Da insgesamt 5 Faktorstufen mit jeweils 8 Übertragungsfunktionen für die Drehzahl verwendet wurden, wurden insgesamt  $280 = 5 * (8^2 - 8)$  Abweichungen untersucht.
- Gruppe 4: Übertragungsfunktionen mit unterschiedlicher Drehzahl und unterschiedlicher Normalkraft:  
Berechnung der Abweichung zwischen Übertragungsfunktionen mit unterschiedlicher Normalkraft und unterschiedlicher Drehzahl und damit von unterschiedlichen Arbeitspunkten. Es erfolgte ein vollständiger Paarvergleich für alle Übertragungsfunktionen. Somit wurden insgesamt  $1560 = 40^2 - 40$  Abweichungen untersucht.

Als Bewertungsgröße zur Quantifizierung der Abweichung wurde der *MAE* verwendet. Aus allen mit dem *MAE* bewerteten Abweichungen einer Gruppe wurde der Mittelwert für die Gruppe gebildet. Die gesamte Datenverarbeitung und Modellbildung erfolgte in MATLAB R2022a (The MathWorks, Vereinigte Staaten).

### 7.1.2 Ergebnisse

In den folgenden drei Abbildungen werden drei für jeweils ein Werkzeug gebildete Übertragungsfunktionen vorgestellt. Dies ermöglicht die qualitative Analyse, wie gut die verschiedenen Arbeitspunkte zusammengeführt werden können.

In jeder Abbildung ist der Bereich, in dem sich die Datenpunkte der 40 Übertragungsfunktionen befinden, durch eine dünne blaue Linie dargestellt. Der Bereich, der alle Datenpunkte vom 25-%-Perzentil bis zum 75-%-Perzentil enthält, ist als dunkelblaues Band dargestellt. Ausreißer werden als blaue Kreise abgebildet und sind definiert als Datenpunkte, die um mehr als das 1,5-fache des Interquartils vom 25-%-Perzentil nach unten oder vom 75-%-Perzentil nach oben abweichen. Die über den Median zusammengeführte Übertragungsfunktion ist in schwarzer Farbe dargestellt.

Für die Fächerschleifscheibe in Abbildung 7.4 ist eine Dämpfung für alle Richtungen im Bereich von 50 – 100 Hz zu erkennen. Für die Schruppscheibe in Abbildung 7.5 ist eine Dämpfung für die x- und z-Richtung im Bereich von 70 – 95 Hz zu erkennen. Für die Trennscheibe in Abbildung 7.6 ist eine starke Dämpfung für die z-Richtung im Bereich von 70 – 130 Hz und eine starke Verstärkung von bis zu einem Verstärkungsfaktor von 15 für die x-Richtung bei 25 Hz zu erkennen. Für die x- und z-Richtung der Fächerschleifscheibe, die x- und z-Richtung der Schruppscheibe und die z-Richtung der Trennscheibe ist zu erkennen, dass die Streuung im unsicherheitsbehafteten Bereich größer ist.

Die Amplituden der Kräfte im Werkzeugkontakt sind oberhalb der 1. Ordnung der Arbeitswelle im Vergleich zu den Amplituden unterhalb der 1. Ordnung der Arbeitswelle vergleichsweise gering. Dies ist exemplarisch im Amplitudenspektrum zur Vorschubeinheit in Abbildung 7.2 zu erkennen. Das bedeutet, dass die Anregung in diesem Bereich gering ist. Durch die mathematische Division durch das Eingangssignal (Amplitudenspektrum der Kräfte im Werkzeugkontakt) unterliegen die Übertragungsfunktionen oberhalb der 1. Ordnung der Arbeitswelle Unsicherheiten. Daher wird dieser Bereich in den drei Abbildungen grau markiert. Diese Einordnung wird in der Diskussion in Kapitel 7.1.3 erörtert.

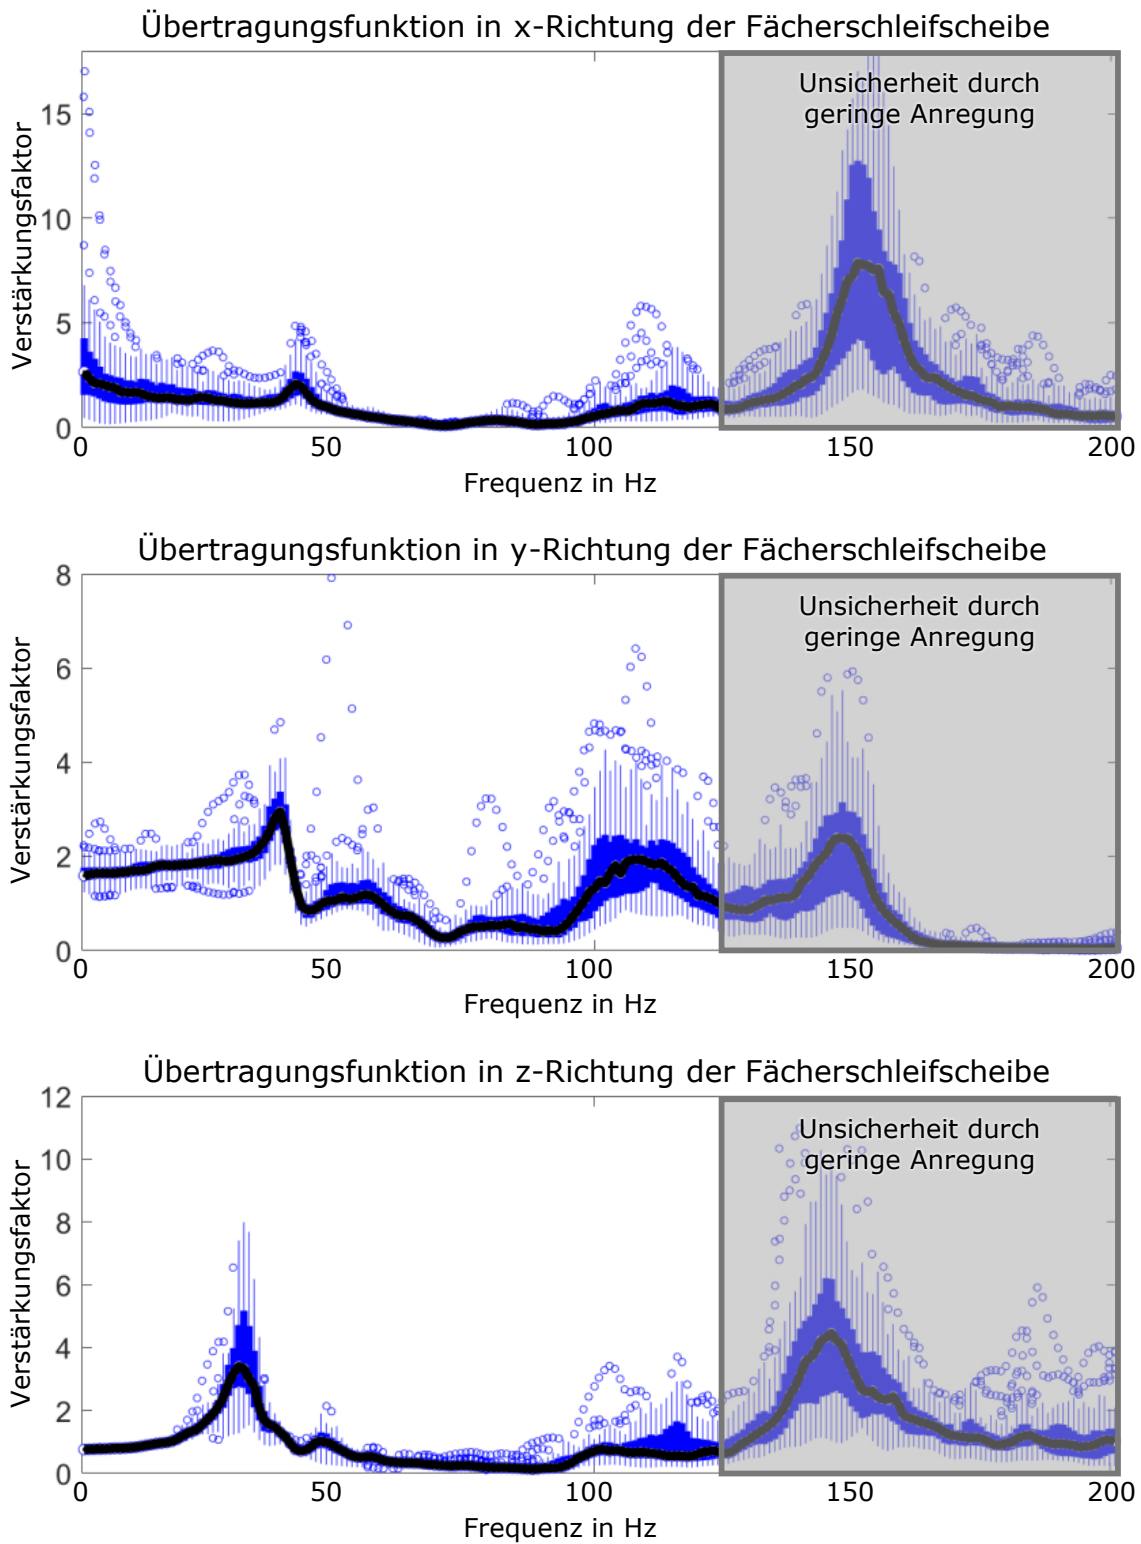


Abbildung 7.4: Streuung von 40 Übertragungsfunktionen für 20 Arbeitspunkte für die untersuchte Fächerschleifscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 4)

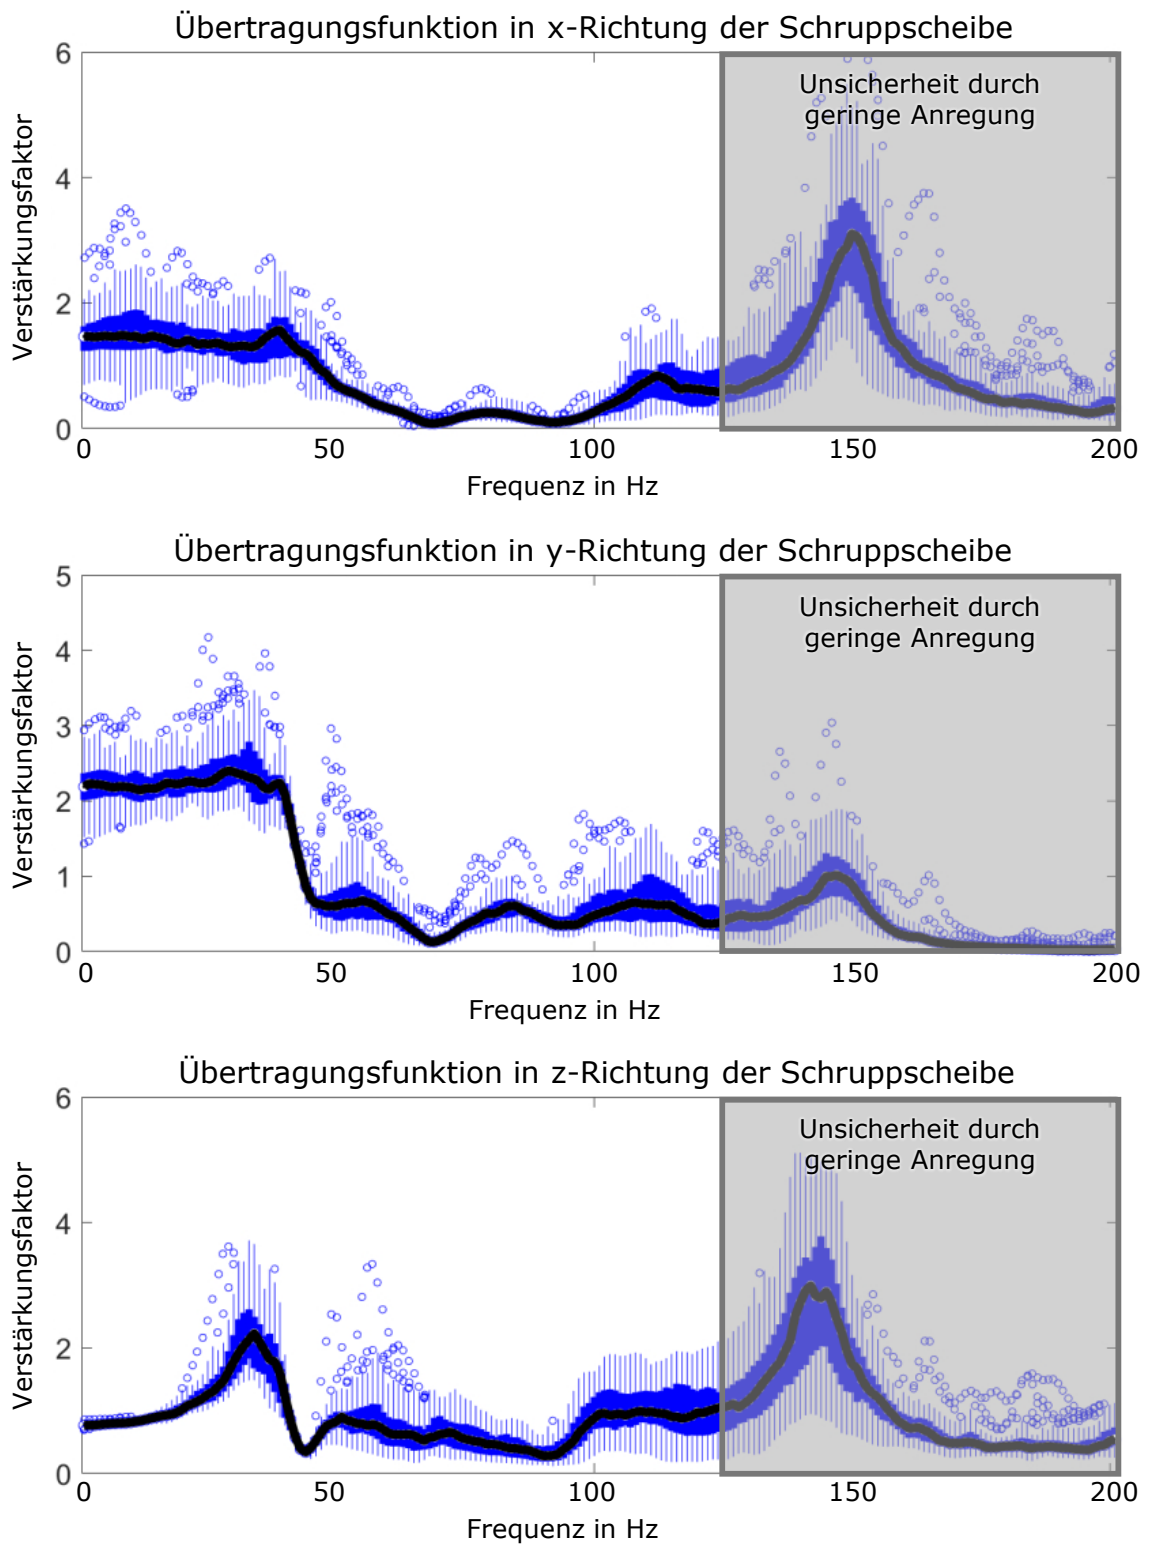


Abbildung 7.5: Streuung von 40 Übertragungsfunktionen über 20 Arbeitspunkte für die untersuchte Schruppscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 5)

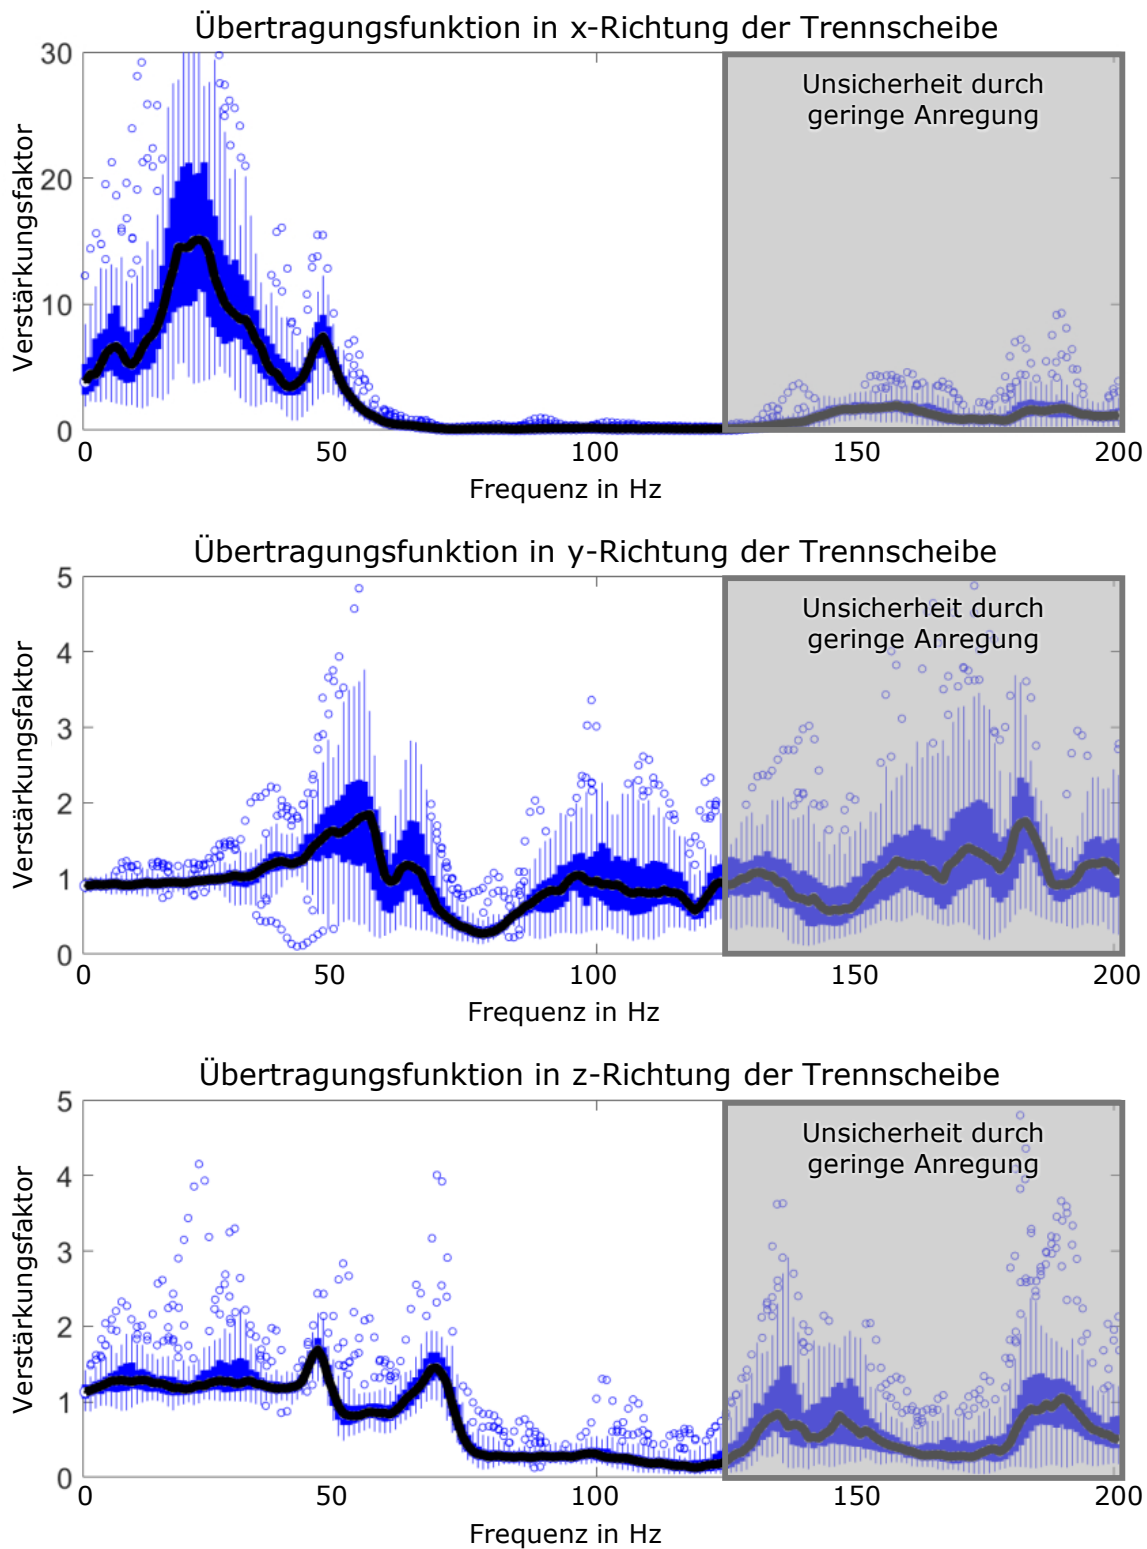


Abbildung 7.6: Streuung von 40 Übertragungsfunktionen über 20 Arbeitspunkte für die untersuchte Trennscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 5)

Die quantitative Untersuchung der Abweichung zwischen Übertragungsfunktionen verschiedener Arbeitspunkte erfolgt zwischen den in Kapitel 7.1.1 vorgestellten Gruppen. Die Abweichungen sind als *MAE* in Tabelle 7.2 aufgeführt. In der rechten Spalte wird die prozentuale Abweichung zwischen der *MAE* von Übertragungsfunktionen des gleichen Arbeitspunktes (1) und der *MAE* von Übertragungsfunktionen unterschiedlicher Arbeitspunkte (4) dargestellt. Die kleinste und größte prozentuale Abweichung ist jeweils fett dargestellt.

Tabelle 7.2: Durchschnittliche Abweichungen als mittlerer absoluter Fehler (*MAE*) zwischen verschiedenen Gruppen von Übertragungsfunktionen, die anhand der Faktoren des Versuchsdesigns eingeteilt wurden.

Werkzeug	(1) Gleicher Arbeitspunkt	(2) Gleiche Normalkraft	(3) Gleiche Drehzahl	(4) Untersch. Arbeitspunkte	Prozentuale Abweichung
Fächerschleif-scheibe	Gruppe 1	Gruppe 2	Gruppe 3	Gruppe 4	Gruppe 1 vs. Gruppe 4
x-Richtung	0.89	0.94	0.95	0.97	9.6%
y-Richtung	0.42	0.43	0.46	0.46	9.7%
z-Richtung	<b>0.50</b>	0.58	0.58	<b>0.64</b>	<b>28.2%</b>
Schrupp-scheibe	Gruppe 1	Gruppe 2	Gruppe 3	Gruppe 4	Gruppe 1 vs. Gruppe 4
x-Richtung	0.35	0.36	0.37	0.38	7.4%
y-Richtung	<b>0.25</b>	0.25	0.26	<b>0.26</b>	<b>5.2%</b>
z-Richtung	0.33	0.36	0.36	0.38	16.3%
Trenn-scheibe	Gruppe 1	Gruppe 2	Gruppe 3	Gruppe 4	Gruppe 1 vs. Gruppe 4
x-Richtung	1.37	1.41	1.46	1.49	9.0%
y-Richtung	0.42	0.43	0.44	0.45	5.4%
z-Richtung	0.27	0.28	0.29	0.29	6.5%
Durchschnitt					<b>10.8%</b>

Die größte Abweichung liegt in der z-Richtung der Trennscheibe vor: Während der *MAE* für den gleichen Arbeitspunkt 0.50 beträgt, beträgt der *MAE* für unterschiedliche Arbeitspunkte 0.64. Damit weist die Übertragungsfunktion des gleichen Arbeitspunktes für die z-Richtung bei der Trennscheibe eine um 28.2 % größere Abweichung als die arbeitspunktabhängige Streuung auf. Durchschnittlich weisen die Übertragungsfunktionen unterschiedlicher Arbeitspunkte für alle Richtungen und alle Werkzeuge eine um 10.8 % größere Abweichung als die arbeitspunktabhängige Streuung auf.

### 7.1.3 Diskussion

In den Übertragungsfunktionen der x- und z-Richtung der Fächerschleifscheibe, der x- und z-Richtung der Schruppscheibe und der z-Richtung der Trennscheibe ist eine größere Streuung im Bereich oberhalb der 1. Ordnung der Arbeitswelle als im restlichen Bereich sichtbar. Dies ist auf die geringe Anregung in diesem Bereich zurückzuführen, wie exemplarisch im Amplitudenspektrum der Kräfte im Werkzeugkontakt in Abbildung 7.3 zu erkennen ist. Aufgrund der geringen Anregung im Werkzeugkontakt ist es schwierig, das reale Übertragungsverhalten des Werkzeugs zu erfassen, da das Signal-Rausch-Verhältnis bei geringeren Anregungen größer ist. Zudem führt die Division durch kleinere Werte zu einer größeren Unsicherheit im Verstärkungsfaktor. Bei der Fächerschleifscheibe und Schruppscheibe ist eine große Verstärkung in diesem Bereich im System zu erkennen. Da sich diese Verstärkung über alle 40 Übertragungsfunktionen ausbildet, kann mit einer gewissen Unsicherheit angenommen werden, dass diese auch gültig ist. Zur Reduzierung der Unsicherheit sollte das Übertragungsverhalten mit einer stärkeren Anregung, beispielsweise durch Erhöhung der Drehzahl, untersucht werden.

In den Übertragungsfunktionen ist bei verschiedenen Werkzeugen und Richtungen eine Verstärkung im Bereich deutlich unterhalb der 1. Ordnung der Arbeitswelle sichtbar. Eine Erklärung für diese Verstärkung ist die konstruktive Gestaltung des Werkzeugs mit einer Eigenfrequenz unterhalb der 1. Ordnung der Arbeitswelle des Winkelschleifers, da die Anregung in einem Bereich gering ist.

Für die x-Richtung ist bei der Trennscheibe das Übertragungsverhalten schon bei niedrigen Frequenzen frequenzabhängig. Zudem ist der Verstärkungsfaktor bei der Trennscheibe mit einem Wert von 15 sehr hoch und weist dabei eine große Streuung auf. Die Streuung und die daraus resultierende Unsicherheit decken sich mit den Ergebnissen aus Kapitel 6. Die Querkräfte und damit die Querschwingungen sowie das Flattern der Trennscheibe lassen sich nur mit hoher Unsicherheit modellieren.

Die in einer früheren Studie von Dong et al. (2020) getroffene Annahme, dass das Übertragungsverhalten eines Werkzeugs bei niedrigen Frequenzen konstant ist, gilt in dieser Studie für die untersuchten Werkzeuge bis zu einer Frequenz von ungefähr 40 Hz. Eine Ausnahme bildet die x-Richtung der Trennscheibe. Die stationäre Abweichung bei der Schruppscheibe und der Fächerschleifscheibe lässt sich durch die Koordinatentransformation sowie durch die Geometrie der Werkzeuge erklären. Da wie erwartet ein nicht konstantes Übertragungsverhalten vorliegt, wird Teilforschungsfrage 3.1 untersucht, die wie folgt lautet:



**Teilforschungsfrage 3.1:** Wie gut lassen sich Übertragungsfunktionen verschiedener Arbeitspunkte eines Werkzeugs zu einer arbeitspunktunabhängigen Übertragungsfunktion zusammenführen?

Zur Beantwortung der Teilforschungsfrage wurden mit einem Prüfstand Übertragungsfunktionen für einzelne Arbeitspunkte für verschiedene Werkzeuge eines Winkelschleifers nach dem in Abbildung 7.3 dargestellten Vorgehen gebildet. Es wird qualitativ und quantitativ analysiert, inwieweit eine Zusammenführung möglich ist.

Bei den Abbildungen ist bei allen Werkzeugen und Richtungen eine Streuung ersichtlich. Dies ist darauf zurückzuführen, dass das Schleifen ein Arbeitsprozess mit starker Streuung ist. Eine Erklärung für die prozessbedingte Streuung ist die Änderung in den Variablen Reibungskoeffizient sowie die Kraftkomponenten der Normalkraft und der Tangentialkraft zur Zerspanung mittels Schleifkorn. Die Änderung lässt sich durch den Verschleiß des Werkzeugs über die Versuche hinweg erklären. Eine Ursache für die starke Streuung ist zudem die Verwendung einer hohen Abtastrate von 1 Hz bei der FFT. Mit dem gleitenden Mittelwertfilter von 7 Hz, der mit einer Gauß-Verteilung gewichtet wurde, werden diese Ausreißer nicht gefiltert, sondern nur gedämpft.

In der qualitativen Analyse werden in den Abbildungen trotz der Streuung Bereiche der Verstärkung und Dämpfung ersichtlich. Vor allem der Bereich vom 25%-Perzentil bis zum 75%-Perzentil der 40 Übertragungsfunktionen lässt klare Bereiche der Verstärkung und Dämpfung erkennen. Diese Bereiche werden durch die mit dem Median zusammengeführte Übertragungsfunktion gut abgebildet.

Die Ergebnisse der quantitativen Analyse in Tabelle 7.2 zeigen, dass die Übertragungsfunktionen gleicher Arbeitspunkte die geringste Abweichung und Übertragungsfunktionen unterschiedlicher Arbeitspunkte die höchste Abweichung aufweisen. Bei der Variation eines Faktors ergibt sich eine mittlere Abweichung. Dies entspricht dem erwarteten Ergebnis, dass die Übertragungsfunktion unterschiedlicher Faktoren beziehungsweise unterschiedlicher Arbeitspunkte stärker abweichen. Es zeigt sich, dass die höhere Abweichung durch unterschiedliche Arbeitspunkte im Verhältnis zur generellen Abweichung aus der prozessbedingten Streuung gering ist.

Um sicherzustellen, dass die Unsicherheit im höheren Frequenzbereich die Ergebnisse nicht beeinträchtigt, wurde untersucht, wie sich die Abweichungen im Frequenzbereich von 1 Hz bis 125 Hz verhalten. Die Ergebnisse in Tabelle G im Anhang bestätigen die Tendenz der Ergebnisse in Tabelle 7.2.

Aus der qualitativen und quantitativen Analyse wird deutlich, dass die Übertragungsfunktionen prozessbedingt stark streuen. Dies bestätigt die Aussage von Dong et al. (2020), dass die experimentelle Ermittlung einer Übertragungsfunktion für ein schnell rotierendes Werkzeug eine sehr große Herausforderung darstellt. Es wurde gezeigt, dass sich die Übertragungsfunktionen durch den Median zusammenführen lassen und diese zusammengeführte Übertragungsfunktion den Bereich vom 25-%-Perzentil bis zum 75-%-Perzentil gut abbildet. In der quantitativen Analyse wurde festgestellt, dass es, wie erwartet, eine starke Abweichung zwischen Übertragungsfunktionen unterschiedlicher Arbeitspunkte gibt. Diese durchschnittliche Abweichung beträgt 10.8 % und ist somit im Vergleich zur allgemeinen Streuung der Übertragungsfunktion gering.

Somit wurde Teilforschungsfrage 3.1 beantwortet. Die starke prozessbedingte Streuung unterstreicht den Nutzen dieses Vorgehens, da bei dieser Streuung eine hohe Anzahl an Versuchen für jeden Arbeitspunkt bei arbeitspunktabhängiger Betrachtung der Übertragungsfunktionen zur Beherrschung der Unsicherheit durchgeführt werden sollte. Somit können alle Versuche gemeinsam in ein Modell überführt werden. Die arbeitspunktabhängige Betrachtung der Streuung erfordert es, ausreichend Versuche für jeden Arbeitspunkt durchzuführen. Dies würde den Versuchsaufwand vervielfachen.

Die Berechnung der Übertragungsfunktion ist nur für den untersuchten Arbeitsbereich aussagekräftig. Im Rahmen dieser Studie waren dies Drehzahlen von  $5500 \text{ min}^{-1}$  bis  $7000 \text{ min}^{-1}$ , die einem Frequenzbereich von  $\sim 92 \text{ Hz}$  bis  $117 \text{ Hz}$  entsprechen, und Kräfte, die in Abhängigkeit des Werkzeugs definiert wurden. Eine Aussage über diesen Arbeitsbereich hinweg ist schwierig zu treffen, da sich das Verhalten der Werkzeuge sowie des Schleifprozesses stark verändern kann. So kann eine zu hohe oder zu niedrige Normalkraft den Reibungskoeffizienten und damit das Übertragungsverhalten verändern. Auch können zusätzliche Phänomene auftreten, wie das Verglasen des Werkzeugs. Für die künftige Anwendung des Vorgehens oder dieser spezifischen Übertragungsfunktionen ist es erforderlich, den Gültigkeitsbereich auf Grundlage der Arbeitspunkte zu berücksichtigen.

Für die Studie in Kapitel 7.2 kann der Bereich mit geringer Anregungsfrequenz vernachlässigt werden, da auch bei einer manuellen Tätigkeit, wie in Abbildung 7.6 dargestellt, eine geringe Anregung oberhalb von  $140 \text{ Hz}$  auftritt.

Die Vorgehensweise kann auf andere Werkzeuge übertragen werden, die in Power-Tools oder Werkzeugmaschinen eingesetzt werden. Zunächst müssen für das neue Werkzeug die relevanten Faktoren, die einen Arbeitspunkt bilden, ermittelt werden. Dann müssen für diese Faktoren bei einzelnen konstanten Arbeitspunkten einzelne

Übertragungsfunktionen bestimmt werden. Zudem muss untersucht werden, ob sie zusammengeführt werden können. Die in dieser Studie untersuchten Werkzeuge haben im Vergleich zu anderen Werkzeugen, beispielsweise einem Metallbohrer, eine hohe Nachgiebigkeit und eine hohe Dämpfung. Für neue Werkzeuge muss auf Basis der Steifigkeit, Dämpfung und Masse des untersuchten Werkzeugs bestimmt werden, ab welcher Frequenz das Übertragungsverhalten nicht mehr konstant ist.

## 7.2 Anwendung der zusammengeführten Übertragungsfunktionen

Im vorherigen Kapitel wurde die Zusammenführung der Übertragungsfunktion gezeigt und diskutiert. Diese Zusammenführung ermöglicht es, Kräfte am Antriebsstrang aus Kräften im Werkzeugkontakt für verschiedene Arbeitspunkte im Untersuchungsbereich zu berechnen. Es bleibt unklar, in welchem Maße sich die Kräfte am Antriebsstrang gegenüber den Kräften am Werkzeug verändern. Dies ist relevant, um den Nutzen der Modellierung, beispielsweise für die Auslegung, zu bewerten. Dies führt zu Teilforschungsfrage 3.2:

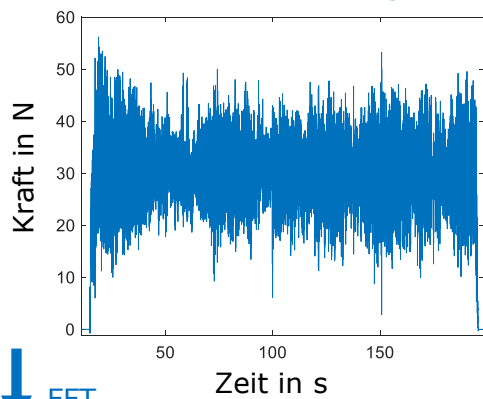
**Teilforschungsfrage 3.2:** Wie unterscheiden sich die mit der Übertragungsfunktion berechneten Kräfte am Antriebsstrang von den Kräften im Werkzeugkontakt?

### 7.2.1 Vorgehen zur Anwendung der zusammengeführten Übertragungsfunktionen

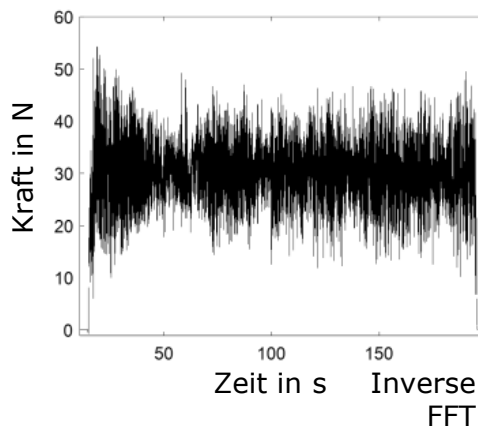
Für die Berechnung der Kräfte am Antriebsstrang mittels Übertragungsfunktion werden Kräfte im Werkzeug benötigt. In dieser Studie wurden Kräfte im Werkzeugkontakt verwendet, die in manuellen Versuchen gemessen wurden. Es wurden die gleichen Werkzeuge wie in Kapitel 7.1 verwendet. Der Aufbau und die Durchführung der manuellen Versuche wurden durch Dörr, Zimprich et al. (2019) veröffentlicht. Der in den Versuchsdaten enthaltene Arbeitsbereich entspricht dem Arbeitsbereich der in Kapitel 7.1 gebildeten Übertragungsfunktionen.

Abbildung 7.7 zeigt das Vorgehen zur Berechnung der Kräfte am Antriebsstrang aus den Kräften am Werkzeugkontakt. Aus den gemessenen Kräften im Werkzeugkontakt wurde mittels FFT ein Amplitudenspektrum gebildet. Das Amplitudenspektrum für den Antriebsstrang wurde mittels der in Kapitel 7.1 gebildeten Übertragungsfunktion aus dem Amplitudenspektrum der Kräfte im Werkzeugkontakt berechnet. Aus dem Amplitudenspektrum wurde mittels einer inversen FFT die Kraft im Zeitbereich für den Antriebsstrang berechnet. Die Verifikation der FFT und der inversen FFT erfolgte durch die energetische Betrachtung mittels des Parsevalschen Theorems.

In manuellen Versuch gemessener Kraftverlauf im Werkzeugkontakt

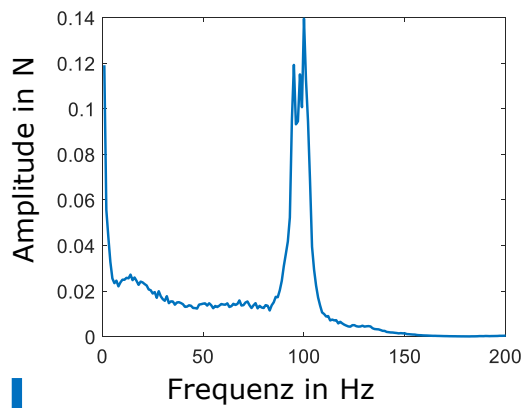


Berechneter Kraftverlauf am Antriebsstrang




↓ FFT

Amplitudenspektrum – Kräfte im Werkzeugkontakt



Amplitudenspektrum – Kräfte am Antriebsstrang



↑ Inverse FFT



Amplitudenspektrum Antriebsstrang  
= Amplitudenspektrum Werkzeugkontakt ×  
Kombinierte Übertragungsfunktion




Abbildung 7.7: Vorgehen zur Ermittlung der Kräfte am Antriebsstrang eines Winkelschleifers anhand einer Übertragungsfunktion für die untersuchte Schruppscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 4)

Zur Beantwortung von Teilforschungsfrage 3.2 wurden aus den berechneten Kräften für den Antriebsstrang Histogramme gebildet. Um zu untersuchen, ob sich die Kräfte im Werkzeugkontakt von den Kräften am Antriebsstrang unterscheiden, werden die Histogramme beider Kräfte in allen drei Richtungen verglichen.

### **7.2.2 Ergebnisse**

Die folgenden Abbildungen zeigen die Histogramme der Kräfte am Antriebsstrang und der Kräfte im Werkzeugkontakt.

Für die Fächerschleifscheibe in Abbildung 7.8 sind kleinere Kraftwerte für die Kräfte in y-Richtung zu erkennen. Für die z-Richtung sind höhere Kraftwerte für die Kräfte am Antriebsstrang dargestellt.

Die Schruppscheibe in Abbildung 7.9 zeigt ein nahezu ähnliches Verhalten wie die Fächerschleifscheibe in Abbildung 7.8. Es zeigen sich niedrigere Kraftwerte in y-Richtung und höhere für die Kräfte im Werkzeugkontakt im Vergleich zu den Kräften am Antriebsstrang.

Bei der Trennscheibe in Abbildung 7.10 sind die größten Unterschiede in der z-Richtung zu erkennen. Die Werte der Kräfte am Antriebsstrang weisen eine deutlich geringere Streuung auf.

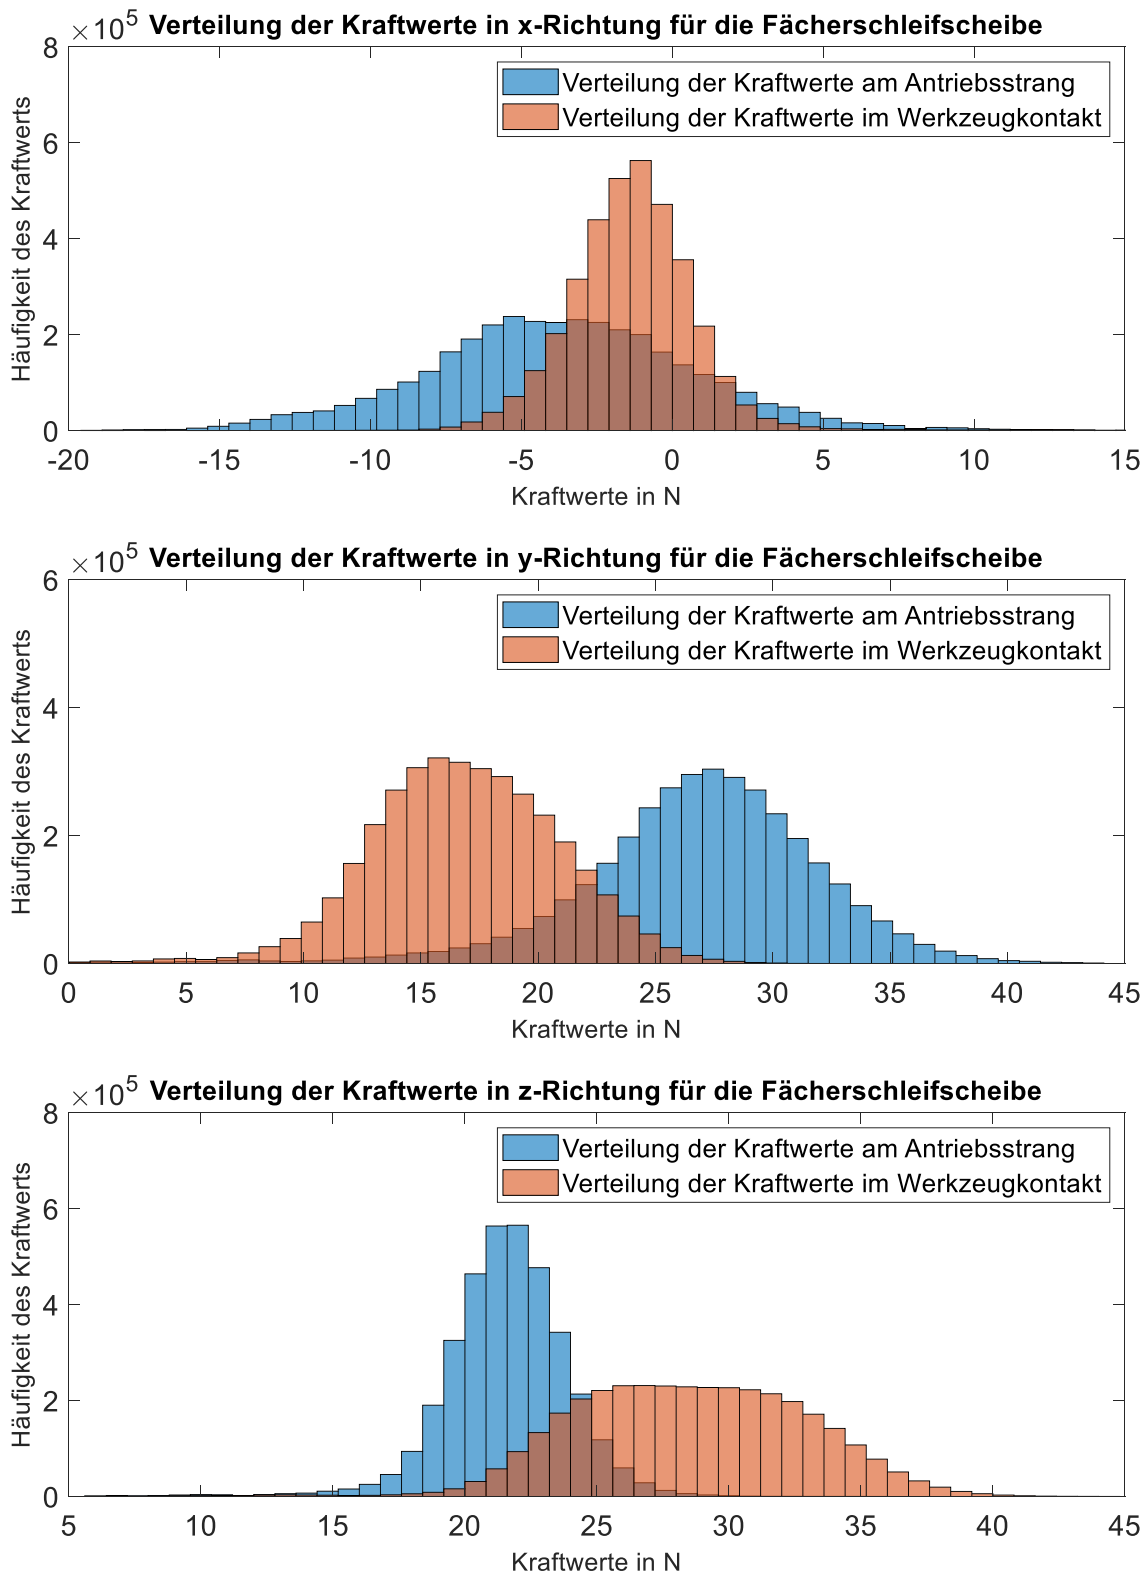


Abbildung 7.8: Verteilung der Kraftwerte im Werkzeugkontakt und am Antriebsstrang in alle Richtungen für die untersuchte Fächerschleifscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 5)

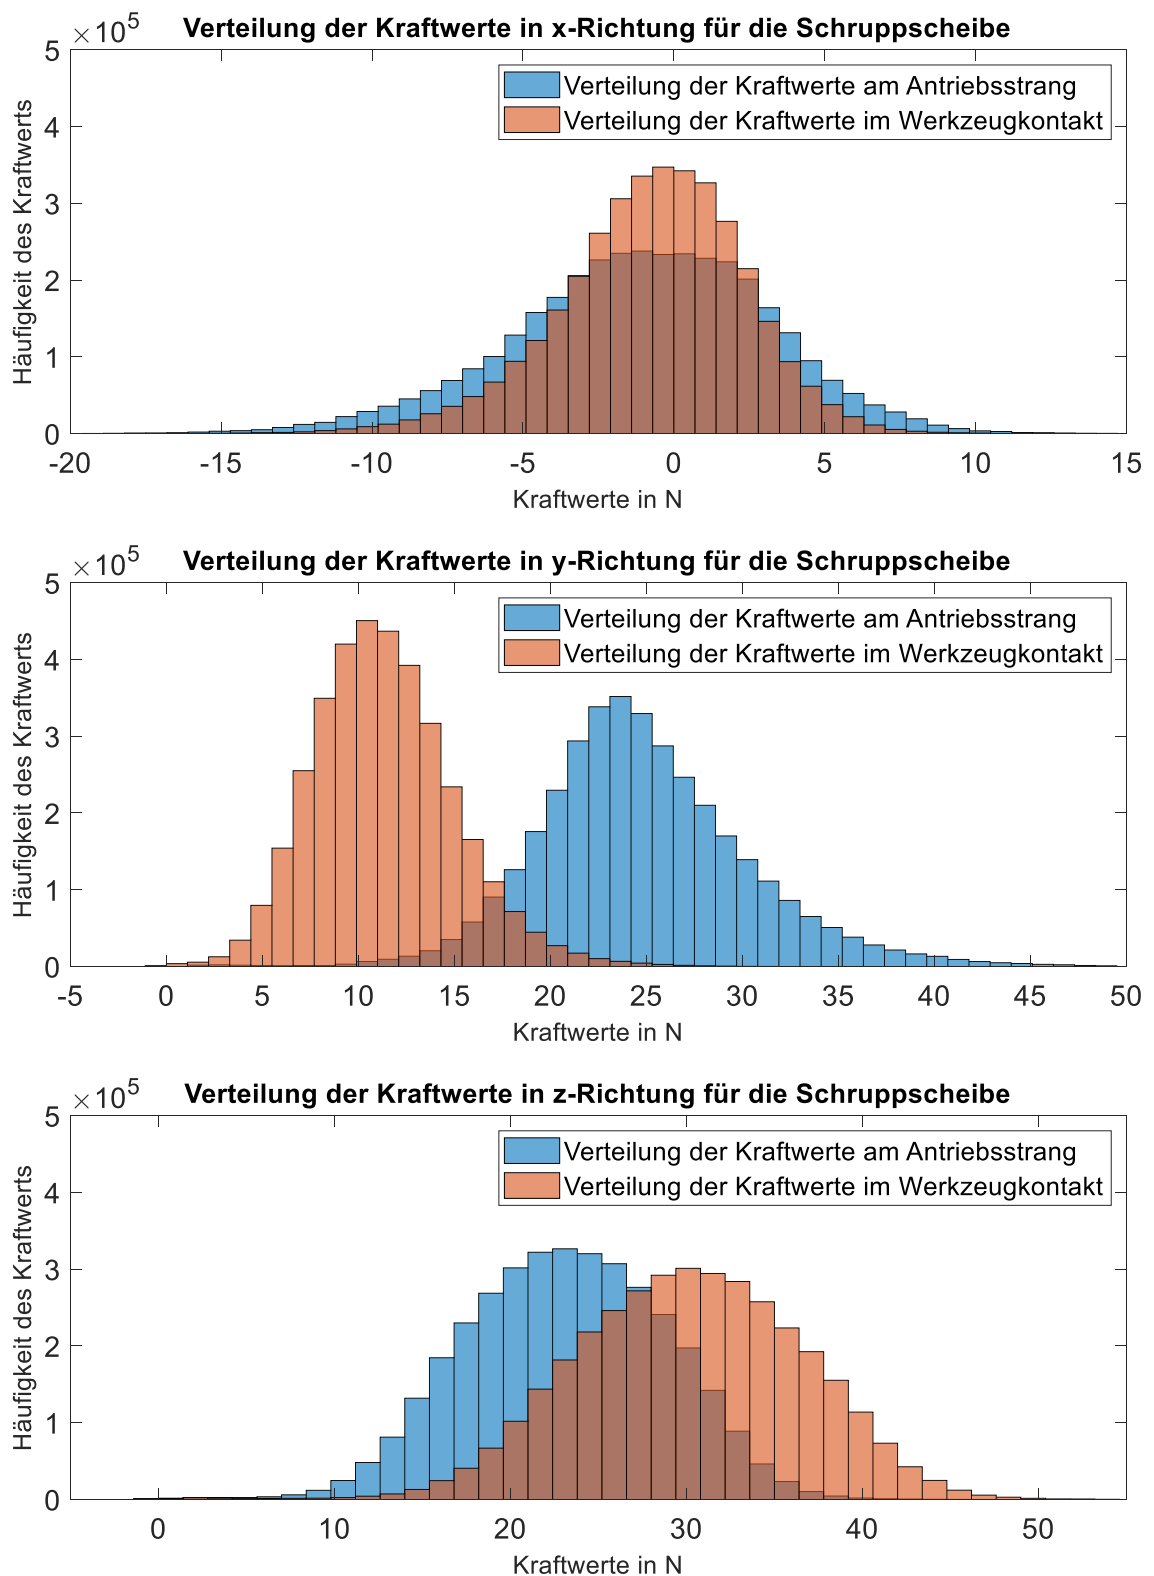


Abbildung 7.9: Verteilung der Kraftwerte im Werkzeugkontakt und am Antriebsstrang in alle Richtungen für die untersuchte Schruppscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 6)

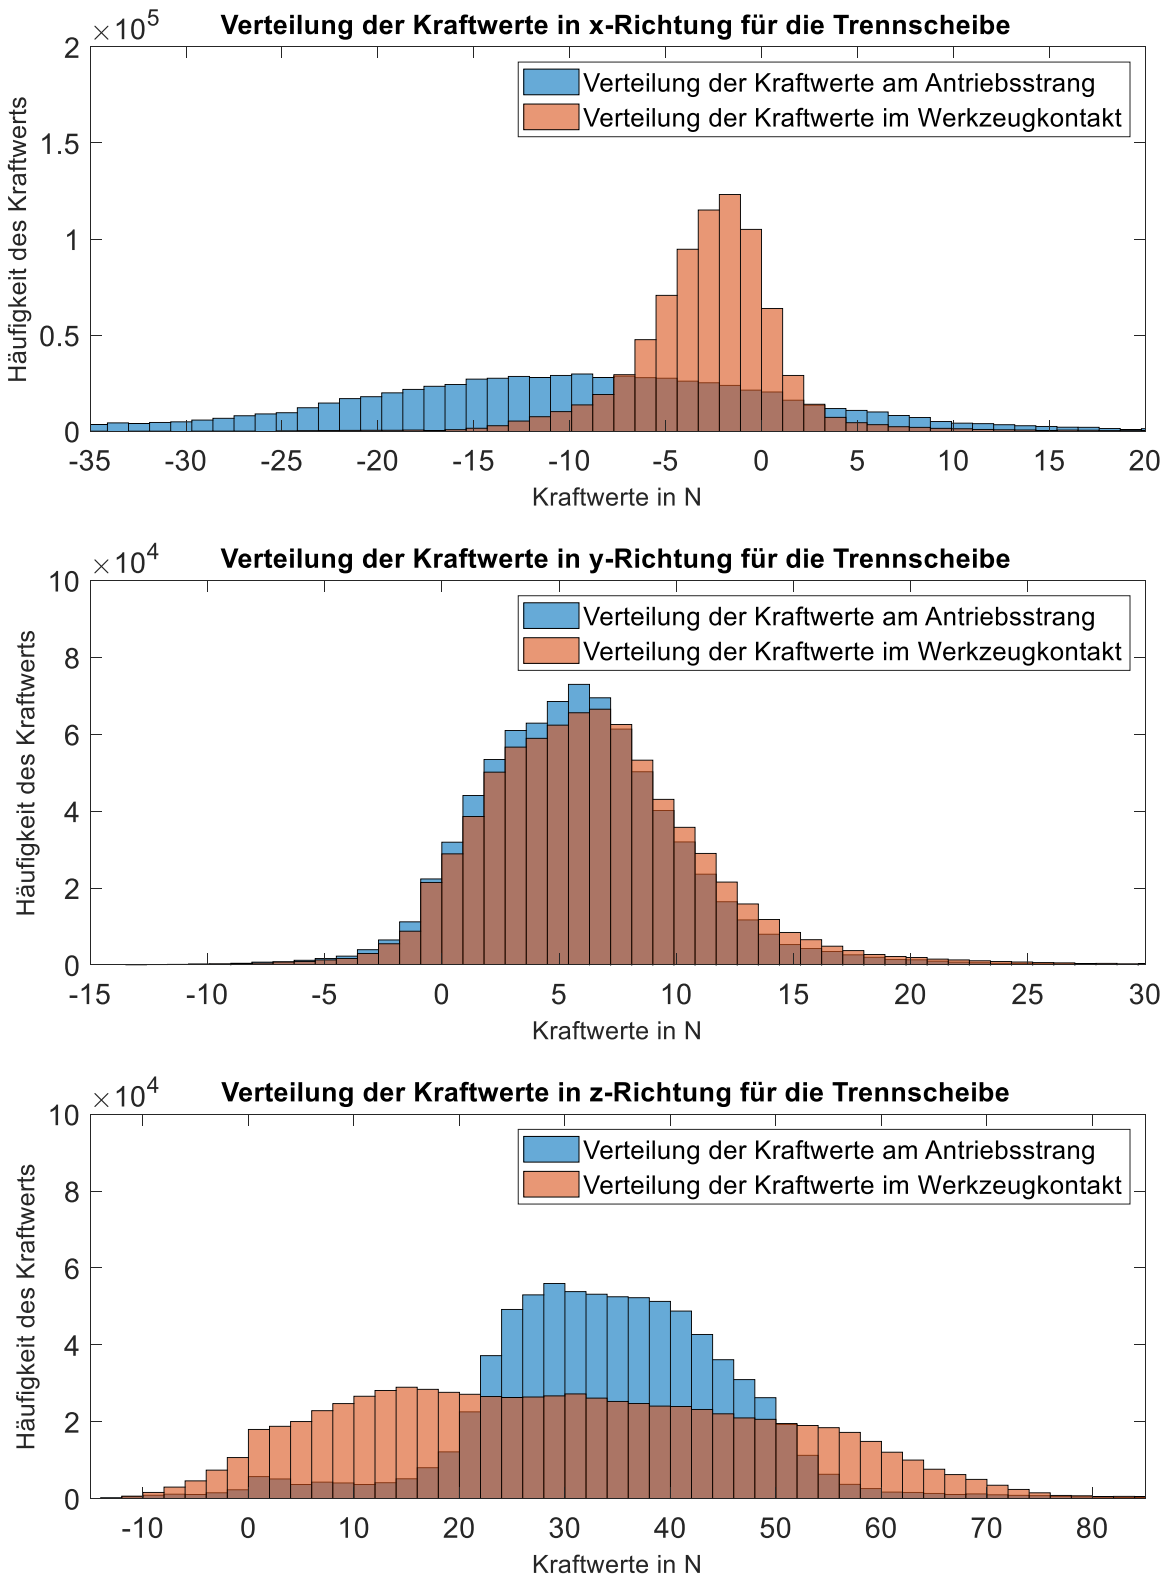


Abbildung 7.10: Verteilung der Kraftwerte im Werkzeugkontakt und am Antriebsstrang in alle Richtungen für die untersuchte Trennscheibe. In Anlehnung an Dörr, Dürkopp et al. (2021, S. 6)



### 7.2.3 Diskussion

Die Änderung der Kräfte ist durch eine Dämpfung der Kräfte im Bereich der 1. Ordnung der Arbeitswelle zwischen  $5500 \text{ min}^{-1}$  (91 Hz) und  $7000 \text{ min}^{-1}$  (117 Hz) bei mehreren Krafrichtungen und Werkzeugen erklärbar. Besonders deutlich wird dies bei der Trennscheibe. Das bedeutet, dass das Übertragungsverhalten der untersuchten Werkzeuge die am Antriebsstrang resultierende Kraft dämpft.

Die wechselseitige Änderung der Kraft in y-Richtung und in z-Richtung bei der Fächerschleifscheibe und der Schruppscheibe lässt sich unter anderem durch die Geometrie der Werkzeuge erklären. Eine weitere Erklärung sind der in Abbildung 7.2 dargestellte Kontaktwinkel von  $30^\circ$  für die Fächerschleifscheibe und die Schruppscheibe sowie die damit verbundene Koordinatentransformation.

In diesem Kapitel wird Teilforschungsfrage 3.2 untersucht, die wie folgt lautet:

**Teilforschungsfrage 3.2:** Wie unterscheiden sich die mit der Übertragungsfunktion berechneten Kräfte am Antriebsstrang von den Kräften im Werkzeugkontakt?

Der Vergleich der Histogramme zeigt, dass sich die Werte der Kräfte am Antriebsstrang deutlich erkennbar von den Kräften im Werkzeugkontakt unterscheiden. Für die Fächerschleifscheibe und Schruppscheibe ergibt sich für die y- und z-Richtung jeweils eine gegenseitige Verschiebung der Kraftwerte. Für die Trennscheibe ergibt sich in z-Richtung für die Kräfte eine deutlich kleinere Streuung. Dies zeigt, dass die Berechnung der Kräfte am Antriebsstrang mittels einer Übertragungsfunktion aus den Kräften im Werkzeugkontakt eine präzisere Ermittlung der Belastung ermöglicht.

Somit wurde Teilforschungsfrage 3.2 beantwortet. Das bedeutet, dass zur Berechnung der Kräfte am Antriebsstrang eines schnell drehenden Power-Tools das dynamische Übertragungsverhalten des Werkzeugs berücksichtigt werden sollte. Dieses dynamische Übertragungsverhalten kann mit dem vorgestellten Vorgehen ermittelt und mittels einer Übertragungsfunktion modelliert werden.

Für die Auslegung von Winkelschleifern ist je nach Werkzeugtyp abzuwägen, ob der Mehraufwand die erhöhte Genauigkeit bei der Ermittlung der Belastung und damit eine verbesserte Auslegung rechtfertigt. Neben der Ermittlung der Kraftwerte kann die Übertragungsfunktion in Simulationsmodelle integriert werden. Eine Einsatzmöglichkeit in der Auslegung einer Maschine ist die Integration in ein Simulationsmodell zur Untersuchung des Einflusses einer anwendenden Person auf die Belastung einer Maschine durch Gwosch et al. (2021). Darüber hinaus kann das Werkzeugmodell in einen Prüfstand für Lebensdauertests integriert werden, so dass

verschiedene Werkzeuge reproduzierbar variiert werden können (Dörr, Mertens et al., 2021).

Neben der Auslegung können die gewonnenen Erkenntnisse zum Übertragungsverhalten auch genutzt werden, um Wissen über die Werkzeuge für die Produktentwicklung zu erlangen. Das Wissen ermöglicht eine bessere Abstimmung der Werkzeuge mit der Maschine. Mit einer dynamischen Vermessung und Auslegung der Werkzeuge kann die Optimierung der Produktivität und der Leistung für eine spezifische Tätigkeit und Maschine erfolgen oder die Reduktion von Schwingungen im Gesamtsystem und an einer anwendenden Person für eine spezifische Maschine erreicht werden.

### 7.3 Zwischenfazit

In der ersten Studie wurde die Modellierung des Übertragungsverhaltens für verschiedene Arbeitspunkte und Werkzeuge vorgestellt. In der zweiten Studie wurde aufgezeigt, dass die Anwendung der Übertragungsfunktion zu unterschiedlichen resultierenden Kraftwerten führt.

Es wurden Teilforschungsfrage 3.1 und Teilforschungsfrage 3.2 beantwortet. Somit lässt sich Forschungsfrage 3 beantworten, die wie folgt lautet:

**Forschungsfrage 3:** Wie lassen sich bei Winkelschleifern mittels Übertragungsfunktionen die Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt berechnen?

Die Kräfte am Antriebsstrang lassen sich mittels einer Übertragungsfunktion, die mit Messdaten aus Prüfstandversuchen parametrisiert wird, aus den Kräften im Werkzeugkontakt berechnen. Es wurde gezeigt, dass Übertragungsfunktionen für konstante Arbeitspunkte gebildet und zu einer Übertragungsfunktion für verschiedene Arbeitspunkte zusammengeführt werden können. Es wurde nachgewiesen, dass die mit der Übertragungsfunktion berechneten Kräfte am Antriebsstrang für die untersuchten Werkzeugtypen deutlich von den Kräften im Werkzeugkontakt abweichen können. Damit wird die präzisere Bestimmung der Belastung ermöglicht.

## 8 Zusammenfassung und Ausblick

In diesem Kapitel erfolgt die Zusammenfassung der Ergebnisse und es wird ein Ausblick auf weiterführende Forschungsthemen gegeben.

### 8.1 Zusammenfassung

In dieser Forschungsarbeit wurden Ansätze zur unbeobachteten und skalierbaren Erfassung von Nutzungselementen untersucht. Dafür wurden drei Nutzungselemente am Beispielsystem Winkelschleifer betrachtet. Die Nutzungselemente sind die durchgeführte Tätigkeit, die Kräfte im Werkzeugkontakt und die Kräfte, die auf den Antriebsstrang wirken. Der Ansatz des virtuellen Sensors wurde zur Vorhersage der Nutzungselemente verwendet. Dazu wurden Sensordaten mit einem Sensormodul als Teil des virtuellen Sensors erfasst. Für die Umsetzung des Ansatzes des virtuellen Sensors fehlte es an Wissen zur Bildung und Validierung von mathematischen Modellen, die die Nutzungselemente erfassen. Daraus wurde das Ziel der Forschungsarbeit hergeleitet. Das Ziel dieser Forschungsarbeit bestand in der Bildung und Validierung von Modellen für virtuelle Sensoren zur Erfassung der durchgeführten Tätigkeit, der Kräfte im Werkzeugkontakt und der Kräfte am Antriebsstrang aus Sensordaten eines Sensormoduls bei Winkelschleifern.

Anhand der Zielsetzung wurde folgende übergeordnete Forschungsfrage formuliert.

**Übergeordnete Forschungsfrage:** Wie können durch Modelle für virtuelle Sensoren die Nutzungselemente ausgeführte Tätigkeit, Kräfte im Werkzeugkontakt und Kräfte auf den Antriebsstrang bei Winkelschleifern anhand von Sensordaten erfasst werden?

Die übergeordnete Forschungsfrage lässt sich wie folgt beantworten:

Die unbeobachtete und skalierbare Erfassung von Nutzungselementen ist über virtuelle Sensoren möglich, die durch Vernetzung von Modellen nur Sensordaten eines Sensormoduls als Eingangsgrößen benötigen. Für die Erfassung der durchgeführten Tätigkeiten und der Kraft im Werkzeugkontakt können statistische Modelle mittels Machine-Learning parametrisiert werden. Die Daten zur Parametrierung müssen in manuellen Studien erhoben werden. Die Kräfte am

Antriebsstrang können mittels arbeitspunktunabhängiger Übertragungsfunktionen aus den Kräften im Werkzeugkontakt erfasst werden. Die Übertragungsfunktionen müssen in Prüfstandsversuchen experimentell ermittelt werden. Sind die Modelle gebildet und validiert, ermöglichen diese die unbeobachtete Erfassung von Nutzungselementen mit skalierbarem Aufwand in der Nutzungsphase. Damit leistet diese Forschungsarbeit einen Beitrag zur skalierbaren und unbeobachteten Erfassung der Informationen zur Produktnutzung (PUI) während der Nutzungsphase.

Zur Beantwortung dieser übergeordneten Forschungsfrage wurden im Rahmen dieser Forschungsarbeit drei Forschungsfragen formuliert und beantwortet.

**Forschungsfrage 1:** Wie lässt sich bei Winkelschleifern die durchgeführte Tätigkeit anhand von Sensordaten durch statistische Modelle vorhersagen?

**Forschungsfrage 2:** Wie lassen sich bei Winkelschleifern Kräfte im Werkzeugkontakt aus Sensordaten durch statistische Modelle vorhersagen?

**Forschungsfrage 3:** Wie lassen sich bei Winkelschleifern mittels Übertragungsfunktionen die Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt berechnen?

In Forschungsfrage 1 wurden Modelle zur Vorhersage der durchgeführten Tätigkeit auf Grundlage von Sensordaten gebildet. Es wurde ein Sensormodul entwickelt und eine manuelle Studie durchgeführt, um Sensordaten für verschiedene Tätigkeiten aufzunehmen. Hierfür wurden statistische Modelle mittels Machine-Learning auf Basis der Sensordaten parametrisiert. Zuerst wurde untersucht, welches Verfahren geeignet ist, um die Genauigkeit bei der Vorhersage der durchgeführten Tätigkeit zu bewerten. Anforderung an das Verfahren zur Bewertung der Vorhersage ist die Berücksichtigung von Störgrößen zwischen einzelnen Versuchen. Bei Winkelschleifern ist dies zum Beispiel der Einfluss der anwendenden Person oder der Verschleiß des Werkzeugs. Die Ergebnisse zeigen, dass Leave-One-Trial-Out-Kreuzvalidierung (LOTO CV) zur Validierung der Genauigkeiten bei der Vorhersage der durchgeführten Tätigkeit beim Schleifen mit Winkelschleifern geeignet ist, da LOTO CV die Störgrößen zwischen Versuchen berücksichtigt. Darauf wurde untersucht, welche statistischen Modelle sich zur Vorhersage der Tätigkeit eignen. Die Ergebnisse zeigen, dass sich Ensemble Methode (EL) und mehrstufige binären Klassifikation (MBC) am besten zur Vorhersage eignen.

Somit wurde Forschungsfrage 1 beantwortet. Es wurde gezeigt, dass sich bei Winkelschleifern die Tätigkeit am besten mittels EL oder MBC vorhersagen lässt, wobei als Verfahren LOTO CV verwendet werden sollte. Aufgrund der Ähnlichkeit

kann davon ausgegangen werden, dass die Vorgehensweise sowie die Verwendung der MBC und das Verfahren LOTO CV sich auf andere Power-Tools, die zum Schleifen verwendet werden, und teilweise auch auf andere Mensch-Maschine-Systeme übertragen lassen.

In Forschungsfrage 2 wurden statistische Modelle zur Vorhersage der Kräfte im Werkzeugkontakt auf Grundlage von Sensordaten gebildet. Es wurde ein Aufbau zur Messung der Kräfte im Werkzeugkontakt entwickelt. Zudem wurde eine manuelle Studie durchgeführt, um Kräfte im Werkzeugkontakt in alle Raumrichtungen zu erfassen. Es wurde untersucht, für welche Krafrichtungen und Tätigkeiten die Vorhersage der Kräfte im Werkzeugkontakt mit den ausgewählten Sensordaten möglich ist. Dazu wurde ein Gauß-Prozess-Regression (GPR)-Modell verwendet. Die Ergebnisse zeigen, dass eine sehr gute Vorhersage der Normalkraft, eine gute Vorhersage der Tangentialkraft und eine gute Vorhersage für die Radialkraft beim *Trennen mit einer Trennscheibe* möglich sind. Die Vorhersage der Führungskraft sowie der Querkraft für das *Trennen mit einer Trennscheibe* unterliegt einer hohen Unsicherheit und ist damit nicht möglich. Zudem wurde untersucht, mit welcher Abtastrate die Kräfte vorhergesagt werden können. Die Ergebnisse zeigen, dass die Vorhersage der mit 10 Hz abgetasteten Kräfte im Werkzeugkontakt für die meisten Krafrichtungen das beste Ergebnis liefert.

Somit wurde Forschungsfrage 2 beantwortet. Bei Winkelschleifern lassen sich die relevanten Krafrichtungen mit einem GPR-Modell mit einer Abtastrate von 10 Hz vorhersagen. Aufgrund der Ähnlichkeit kann davon ausgegangen werden, dass sich die Vorgehensweise und das verwendete GPR-Modell auf andere Power-Tools, die zum Schleifen verwendet werden, und teilweise auch auf Mensch-Maschine-Systeme sowie den Bereich der Biomechanik übertragen lassen.

In Forschungsfrage 3 wurde das frequenzabhängige Übertragungsverhalten von Werkzeugen zur Berechnung der Kräfte am Antriebsstrang aus den Kräften im Werkzeugkontakt modelliert. Die frequenzabhängige Modellierung erfolgte mit Übertragungsfunktionen. Es wurden Versuche mit konstanten Bedingungen verschiedener Arbeitspunkte auf einem Prüfstand durchgeführt, um Messdaten zur Parametrierung der Übertragungsfunktion zu generieren. In der ersten Studie wurde untersucht, wie gut sich die Übertragungsfunktionen von verschiedenen Arbeitspunkten eines Werkzeugs zu einem arbeitspunktunabhängigen Modell zusammenführen lassen. Die Ergebnisse zeigen, dass die Abweichungen von Übertragungsfunktionen unterschiedlicher Arbeitspunkte im Vergleich zur Streuung des Schleifprozesses gering sind. Damit lassen sich Übertragungsfunktionen unterschiedlicher Arbeitspunkte zusammenführen. In einer zweiten Studie wurde untersucht, in welchem Maße sich die Kräfte am Antriebsstrang gegenüber den

Kräften am Werkzeug verändern. Für die drei untersuchten Werkzeuge wurde gezeigt, dass sich die Werte der Kräfte am Antriebsstrang deutlich erkennbar von den Kräften im Werkzeugkontakt unterscheiden. Das bedeutet, dass bei der Berechnung der Kräfte auf den Antriebsstrang das dynamische Übertragungsverhalten des Werkzeugs berücksichtigt werden sollte.

Somit wurde Forschungsfrage 3 beantwortet. Die Modellierung eines Werkzeugs als Übertragungsfunktion ist durch das Zusammenführen von Übertragungsfunktionen verschiedener Arbeitspunkte möglich. In Verbindung mit den Kräften im Werkzeugkontakt wird eine präzisere Erfassung der Kräfte und damit der Belastung ermöglicht. Die Vorgehensweise zur Bildung einer arbeitspunktunabhängigen Übertragungsfunktion lässt sich auf andere nachgiebige Werkzeuge übertragen, die ebenfalls ein frequenzabhängiges Übertragungsverhalten aufweisen.

## 8.2 Ausblick

In dieser Forschungsarbeit wurden Modelle für virtuelle Sensoren gebildet und validiert, um Nutzungselemente bei Power-Tools anhand von Sensordaten aus einem Sensormodul zu erfassen. Auf Basis dieser Forschungsarbeit lassen sich weitere Forschungsrichtungen aufzeigen.

Für die Produktentwicklung von Power-Tools, die zum Schleifen eingesetzt werden, sind neben den drei genannten Nutzungselementen weitere Nutzungselemente von Bedeutung. Diese können Größen des Schleifprozesses sein, wie der Verschleiß der Werkzeuge, die Produktivität oder die Qualität des Arbeitsergebnisses. Im Stand der Forschung sind bereits Zusammenhänge und Auswirkungen aufgezeigt worden, die mit virtuellen Sensoren umgesetzt werden können. Zudem gibt es weitere relevante Nutzungselemente mit Bezug zur anwendenden Person. Ein relevantes Nutzungselement ist zum Beispiel das subjektive Empfinden der Vibration durch eine anwendende Person. Dieses kann über ein frequenzabhängiges Modell bestimmt werden (Zimprich et al., 2021). Um die PUI um weitere Nutzungselemente zu erweitern, kann es notwendig werden, weitere Sensoren in der Maschine zu applizieren. Hierfür eignen sich insbesondere sensorintegrierte Maschinenelemente (Peters et al., 2022; Vorwerk-Handing et al., 2020). Durch die Verknüpfung von Modellen, wie in dieser Forschungsarbeit gezeigt, lassen sich Synergieeffekte erzielen, sodass mit geringerem Aufwand umfassende PUI für ein Power-Tool erhoben werden können.

Während die Vorhersage von Kräften im Werkzeugkontakt beim automatisierten Schleifen mit Werkzeugmaschinen aufgrund des weggesteuerten Schleifprozesses

(Kamath et al., 2020) und der vergleichsweise geringeren Störgrößen weitgehend erforscht ist, besteht noch Potenzial im Bereich der Power-Tools. Ein Problem stellen Störgrößen und unterschiedliche Kontexte in Form von Tätigkeiten und Arbeitspunkten dar. Zur Lösung ist es notwendig, vielfältige und repräsentative Datensätze in manuellen Studien zu erfassen. Die gebildeten Modelle müssen mittels LOTO CV validiert werden. Dabei müssen weitere Faktorstufen wie andere Tätigkeiten, andere Werkzeuge oder Werkstücke aus anderen Materialien untersucht werden. Auch bei Verwendung eines Sensormoduls sind die Datenaufnahme und die neue Parametrierung der statistischen Modelle mit hohem Aufwand verbunden. Daher ist eine weitere Forschungsrichtung der Transfer von statistischen Modellen (Transfer-Learning) auf einen neuen Kontext oder eine neue Maschine.

Die Integration der virtuellen Sensoren in die Umgebung stellt eine interessante Forschungsrichtung dar. So ist beispielsweise bei Fertigungsprozessen, an denen eine anwendende Person beteiligt ist, die Vernetzung der anwendenden Person über das Power-Tool ein Ziel moderner Fertigungsprozesse im Kontext von Industrie 5.0. Eine weitere relevante Umgebung sind Baustellen, die durch Building-Information-Modeling und den vermehrten Einsatz von Produkten mit eingebetteten Informationsmodule (PEID) immer stärker vernetzt werden (Yang et al., 2020). Bei der Integration der virtuellen Sensoren in die Umgebung muss die Datenrate der Kommunikation berücksichtigt werden. Dies gilt insbesondere, wenn die Echtzeitfähigkeit gefordert ist. Um die Datenrate zu verringern, könnte eine Forschungsrichtung darin bestehen, die Messdaten zu reduzieren, indem weniger Signale oder eine niedrige Abtastrate für die Vorhersage verwendet werden. Eine andere Forschungsrichtung ist die Durchführung der Merkmalsextraktion oder der Vorhersage auf einem Mikrocontroller in einem PEID, beispielsweise mittels Edge-Computing oder Fog-Computing.





## Literaturverzeichnis

- Abowd, G. D., Dey, A. K., Brown, P. J., Davies, N., Smith, M. & Steggles, P. (1999). Towards a Better Understanding of Context and Context-Awareness. In H.-W. Gellersen (Hrsg.), *HUC '99: Proceedings of the 1st international symposium on Handheld and Ubiquitous Computing* (S. 304–307). Berlin, Heidelberg: Springer. [https://doi.org/10.1007/3-540-48157-5\\_29](https://doi.org/10.1007/3-540-48157-5_29)
- Abramovici, M. & Lindner, A. (2011). Providing product use knowledge for the design of improved product generations. *CIRP Annals*, 60(1), 211–214. <https://doi.org/10.1016/j.cirp.2011.03.103>
- Abramovici, M., Neubach, M., Fathi, M. & Holland, A. (2009). Knowledge-Based Feedback of Product Use Information into Product Development. In M. Norell Bergendahl, M. Grimheden, L. Leifer, P. Skogstad & U. Lindemann (Hrsg.), *DS 58-8: Proceedings of ICED 09, the 17th International Conference on Engineering Design: Design Information and Knowledge* (S. 227–238). The Design Society
- Aiello, G., Certa, A., Abusohyon, I., Longo, F. & Padovano, A. (2021). Machine Learning approach towards real time assessment of hand-arm vibration risk. *IFAC-PapersOnLine*, 54(1), 1187–1192. <https://doi.org/10.1016/j.ifacol.2021.08.140>
- Akhavian, R. & Behzadan, A. H. (2016). Smartphone-based construction workers' activity recognition and classification. *Automation in Construction*, 71, 198–209. <https://doi.org/10.1016/j.autcon.2016.08.015>
- Alcayaga, A., Wiener, M. & Hansen, E. G. (2019). Towards a framework of smart-circular systems: An integrative literature review. *Journal of Cleaner Production*, 221, 622–634. <https://doi.org/10.1016/j.jclepro.2019.02.085>
- Allwein, E. L., Schapire, R. E. & Singer, Y. (2000). Reducing Multiclass to Binary: A Unifying Approach for Margin Classifiers. *Journal of machine learning research*, 1, 113–141. <https://doi.org/10.1162/15324430152733133>
- Arrazola, P. J., Özel, T., Umbrello, D., Davies, M. & Jawahir, I. S. (2013). Recent advances in modelling of metal machining processes. *CIRP Annals*, 62(2), 695–718. <https://doi.org/10.1016/j.cirp.2013.05.006>
- Aykut, Ş., Gölcü, M., Semiz, S. & Ergür, H. S. (2007). Modeling of cutting forces as function of cutting parameters for face milling of satellite 6 using an artificial neural

network. *Journal of Materials Processing Technology*, 190(1-3), 199–203.  
<https://doi.org/10.1016/j.jmatprotec.2007.02.045>

Bales, G. L., Das, J., Linke, B. S. & Kong, Z. (2016). Recognizing Gaze-Motor Behavioral Patterns in Manual Grinding Tasks. *Procedia Manufacturing*, 5, 106–121. <https://doi.org/10.1016/j.promfg.2016.08.011>

Bales, G. L., Das, J., Tsugawa, J., Linke, B. S. & Kong, Z. (2017). Digitalization of Human Operations in the Age of Cyber Manufacturing: Sensorimotor Analysis of Manual Grinding Performance. *Journal of Manufacturing Science and Engineering*, 139(10), Artikel 101011. <https://doi.org/10.1115/1.4037615>

Becker, T. & Krause, D. (2010). Softsensorysysteme - Mathematik als Bindeglied zum Prozessgeschehen. *Chemie Ingenieur Technik*, 82(4), 429–440.  
<https://doi.org/10.1002/cite.201000015>

Bertoni, A. (2020). Data-driven design in concept development: systematic review and missed opportunities. In *Proceedings of the Design Society: DESIGN Conference* (S. 101–110). Cambridge University Press. <https://doi.org/10.1017/dsd.2020.4>

Beverungen, D., Müller, O., Matzner, M., Mendling, J. & vom Brocke, J. (2019). Conceptualizing smart service systems. *Electronic Markets*, 29(1), 7–18.  
<https://doi.org/10.1007/s12525-017-0270-5>

Bieber, G., Kaulbars, U., Trimpop, J. & Hofmann, A. (2016). Individuelle Bestimmung der Hand-Arm-Vibrationsdosis mit Smartwatches. In 6. *VDI-Tagung Humanschwingungen 2016* (S. 111–126). Düsseldorf: VDI-Verlag.

Bishop, C. M. (2009). *Pattern recognition and machine learning* (8. Aufl.). *Information science and statistics*. New York, NY: Springer.

Bracke, S., Hinz, M., Inoue, M., Patelli, E., Kutz, S., Gottschalk, H., Ulutas, B., Hartl, C., Mörs, P. & Bonnaud, P. (2016). Reliability engineering in face of shorten product life cycles: Challenges, technique trends and method approaches to ensure product reliability. In L. Walls, M. Revie & T. Bedford (Hrsg.), *Risk, Reliability and Safety: Innovating Theory and Practice: Proceedings of ESREL 2016* (S. 2884–2891). London: CRC Press. <https://doi.org/10.1201/9781315374987-438>

Bustillo, A., Correa, M. & Reñones, A. (2011). A virtual sensor for online fault detection of multitooth-tools. *Sensors*, 11(3), 2773–2795. <https://doi.org/10.3390/s110302773>

- C. & E. Fein GmbH. (2019). *Ersatzteilkatalog. Modell: WSG 11-125 (50/60Hz, 220/230V)*. Zugriff am 28.10.2022.  
<https://etk.fein.de/spc/index.php?r=item%2Flist&id=3769>
- Camacho, J. & Picó, J. (2006). Online monitoring of batch processes using multi-phase principal component analysis. *Journal of Process Control*, 16(10), 1021–1035.  
<https://doi.org/10.1016/j.jprocont.2006.07.005>
- Carmo Nicoletti, M. d. & Jain, L. C. (Hrsg.). (2009). *Studies in Computational Intelligence: Bd. 218. Computational intelligence techniques for bioprocess modelling, supervision and control*. Berlin: Springer.
- Chéry, A. (1997). Software sensors in bioprocess engineering. *Journal of Biotechnology*, 52(3), 193–199. [https://doi.org/10.1016/S0168-1656\(96\)01644-6](https://doi.org/10.1016/S0168-1656(96)01644-6)
- Choi, A., Jung, H. & Mun, J. H. (2019). Single Inertial Sensor-Based Neural Networks to Estimate COM-COP Inclination Angle During Walking. *Sensors*, 19(13), Artikel 2974. <https://doi.org/10.3390/s19132974>
- Das, J., Bales, G. L., Kong, Z. & Linke, B. S. (2018). Integrating Operator Information for Manual Grinding and Characterization of Process Performance Based on Operator Profile. *Journal of Manufacturing Science and Engineering*, 140(8), Artikel 081011. <https://doi.org/10.1115/1.4040266>
- Das, J. & Linke, B. S. (2016). Effect of Manual Grinding Operations on Surface Integrity. *Procedia CIRP*, 45, 95–98. <https://doi.org/10.1016/j.procir.2016.02.091>
- Deng, Q. & Thoben, K.-D. (2022). A Systematic Procedure for Utilization of Product Usage Information in Product Development. *Information*, 13(6), Artikel 267. <https://doi.org/10.3390/info13060267>
- Deng, Q., Wellsandt, S., Hribernik, K. A. & Thoben, K.-D. (2019). Towards Understanding the Role of Product Usage Information in Product Design Improvement. In C. Fortin, L. Rivest, A. Bernard & A. Bouras (Hrsg.), *Product Lifecycle Management in the Digital Twin Era: IFIP Advances in Information and Communication Technology* (S. 369–378). Cham: Springer.  
[https://doi.org/10.1007/978-3-030-42250-9\\_35](https://doi.org/10.1007/978-3-030-42250-9_35)
- Deng, Q., Wellsandt, S., Hribernik, K. A. & Thoben, K.-D. (2021). Understanding users and products in product development: the application of product usage information and its challenges. In *Proceedings of the Design Society: DESIGN Conference* (S. 3299–3308). Cambridge University Press. <https://doi.org/10.1017/pds.2021.591>

- Deutsches Institut für Normung e.V. (2003). *Fertigungsverfahren Spanen\_- Teil\_0: Allgemeines; Einordnung, Unterteilung, Begriffe* (DIN 8589-0:2003-09). Berlin: Beuth Verlag.
- Deutsches Institut für Normung e.V. (2017). *Sicherheitsanforderungen für Schleifmittel auf Unterlagen* (DIN EN 13743:2017-04). Berlin: Beuth Verlag.
- Deutsches Institut für Normung e.V. (2019). *Sicherheitsanforderungen für Schleifwerkzeuge aus gebundenem Schleifmittel* (DIN EN 12413:2019-12). Berlin: Beuth Verlag.
- Ding, C. & Peng, H. (2005). Minimum redundancy feature selection from microarray gene expression data. *Journal of Bioinformatics and Computational Biology*, 3(2), 185–205. <https://doi.org/10.1142/s0219720005001004>
- Dong, R. G., Welcome, D. E., Xu, X. S. & McDowell, T. W. (2020). Identification of effective engineering methods for controlling handheld workpiece vibration in grinding processes. *International Journal of Industrial Ergonomics*, 77, Artikel 102946. <https://doi.org/10.1016/j.ergon.2020.102946>
- Eckstein, C. (2017). *Ermittlung repräsentativer Lastkollektive zur Betriebsfestigkeit von Ackerschleppern* [Dissertation]. Technischen Universität Kaiserslautern, Kaiserslautern.
- Ehrlenspiel, K. & Meerkamm, H. (2017). *Integrierte Produktentwicklung. Denkabläufe, Methodeneinsatz, Zusammenarbeit*. München: Carl Hanser Verlag. <https://doi.org/10.3139/9783446449084>
- Facco, P., Doplicher, F., Bezzo, F. & Barolo, M. (2009). Moving average PLS soft sensor for online product quality estimation in an industrial batch polymerization process. *Journal of Process Control*, 19(3), 520–529. <https://doi.org/10.1016/j.jprocont.2008.05.002>
- Fathi, M. & Holland, A. (2009). Knowledge-based feedback integration to facilitate sustainable product innovation. In *2009 IEEE Conference on Emerging Technologies & Factory Automation* (S. 1–8). IEEE. <https://doi.org/10.1109/ETFA.2009.5347018>
- Gärtner, H. (2004). *Einflussgrößen auf die Geräuschemission von handgeführten Schleifmaschinen unter Berücksichtigung des Abtrags- und Verschleißverhaltens* [Dissertation]. Universität Stuttgart, Stuttgart.

- Germine, L., Strong, R. W., Singh, S. & Sliwinski, M. J. (2021). Toward dynamic phenotypes and the scalable measurement of human behavior. *Neuropsychopharmacology*, 46(1), 209–216. <https://doi.org/10.1038/s41386-020-0757-1>
- Ghosh, D., Olewnik, A. & Lewis, K. (2018). Application of Feature-Learning Methods Toward Product Usage Context Identification and Comfort Prediction. *Journal of Computing and Information Science in Engineering*, 18(1), Artikel 011004. <https://doi.org/10.1115/1.4037435>
- Ghosh, D., Olewnik, A., Lewis, K., Kim, J. & Lakshmanan, A. (2017). Cyber-Empathic Design: A Data-Driven Framework for Product Design. *Journal of Mechanical Design*, 139(9), Artikel 091401. <https://doi.org/10.1115/1.4036780>
- Giarmatzis, G., Zacharaki, E. I. & Moustakas, K. (2020). Real-Time Prediction of Joint Forces by Motion Capture and Machine Learning. *Sensors*, 20(23), Artikel 6933. <https://doi.org/10.3390/s20236933>
- Graziani, S. & Xibilia, M. G. (2020). Deep Learning for Soft Sensor Design. In W. Pedrycz & S.-M. Chen (Hrsg.), *Studies in Computational Intelligence: Bd. 867. Development and Analysis of Deep Learning Architectures* (S. 31–59). Cham: Springer. [https://doi.org/10.1007/978-3-030-31764-5\\_2](https://doi.org/10.1007/978-3-030-31764-5_2)
- Günther, L. C., Kärcher, S. & Bauernhansl, T. (2019). Activity recognition in manual manufacturing: Detecting screwing processes from sensor data. *Procedia CIRP*, 81, 1177–1182. <https://doi.org/10.1016/j.procir.2019.03.288>
- Gwosch, T. (2019). Antriebsstrangprüfstände zur Ableitung von Konstruktionszielgrößen in der Produktentwicklung handgehaltener Power-Tools [Dissertation]. In A. Albers & S. Matthiesen (Hrsg.), *Forschungsberichte des IPEK - Institut für Produktentwicklung: Systeme, Methoden, Prozesse* (Bd. 117). Karlsruher Institut für Technologie (KIT), Karlsruhe. <https://doi.org/10.5445/IR/1000096256>
- He, L., Chen, W., Hoyle, C. & Yannou, B. (2012). Choice Modeling for Usage Context-Based Design. *Journal of Mechanical Design*, 134(3), Artikel 031007. <https://doi.org/10.1115/1.4005860>
- Heinis, T. B., Loy, C. L. & Meboldt, M. (2018). Improving Usage Metrics for Pay-per-Use Pricing with IoT Technology and Machine Learning. *Research Technology Management*, 61(5), 32–40. <https://doi.org/10.1080/08956308.2018.1495964>

- Heinrich, D. (2016). Modellierung des Fahrerverhaltens zur Ermittlung von Bauteilbelastungen im Fahrzeugantriebsstrang [Dissertation]. In A. Albers & S. Matthiesen (Hrsg.), *Forschungsberichte des IPEK - Institut für Produktentwicklung: Systeme, Methoden, Prozesse* (Bd. 92). Karlsruher Institut für Technologie (KIT), Karlsruhe. <https://doi.org/10.5445/IR/1000054681>
- Holler, M., Stöckli, E., Übernickel, F. & Brenner, W. (2016). Towards understanding closed-loop PLM : the role of product usage data for product development enabled by intelligent properties. In *29th Bled eConference Proceedings* (S. 479–491). Association for Information Systems (AIS) eLibrary. Zugriff am 29.03.2023. <https://aisel.aisnet.org/bled2016/13/>
- Hou, L. & Jiao, R. J. (2020). Data-informed inverse design by product usage information: a review, framework and outlook. *Journal of Intelligent Manufacturing*, 31(3), 529–552. <https://doi.org/10.1007/s10845-019-01463-2>
- Hubka, V. & Eder, W. (1992). *Einführung in die Konstruktionswissenschaft – Übersicht, Modell, Anleitungen*. Berlin: Springer.
- Huikari, V., Koskimäki, H., Siirtola, P. & Röning, J. (2010, 1. Dezember). User-independent activity recognition for industrial assembly lines-feature vs. instance selection. In A. LaMarca, M. Langheinrich & K. N. Truong (Hrsg.), *5th International Conference on Pervasive Computing and Applications (ICPCA)* (S. 307–312). IEEE. <https://doi.org/10.1109/ICPCA.2010.5704118>
- Ibarguren, A., Maurtua, I., Susperregi, L. & Sierra, B. (2006). Machine learning algorithms for task identification. In O. Herzog, H. Kenn, M. Lawo, P. Lukowicz & G. Tröster (Hrsg.), *3rd International Forum on Applied Wearable Computing (IFAWC)*. Berlin: VDE-Verlag.
- Internationale Organisation für Normung 15230:2007 (2007). *Mechanical vibration and shock — Coupling forces at the man—machine interface for hand-transmitted vibration* (ISO 15230:2007). Berlin: Beuth Verlag.
- Jiang, Y., Yin, S., Dong, J. & Kaynak, O. (2021). A Review on Soft Sensors for Monitoring, Control, and Optimization of Industrial Processes. *IEEE Sensors Journal*, 21(11), 12868–12881. <https://doi.org/10.1109/JSEN.2020.3033153>
- Jin, J., Liu, Y., Ji, P. & Kwong, C. K. (2019). Review on Recent Advances in Information Mining From Big Consumer Opinion Data for Product Design. *Journal of Computing and Information Science in Engineering*, 19(1), Artikel 010801. <https://doi.org/10.1115/1.4041087>

- Joshua, L. & Varghese, K. (2011). Accelerometer-Based Activity Recognition in Construction. *Journal of Computing in Civil Engineering*, 25(5), 370–379. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000097](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000097)
- Joshua, L. & Varghese, K. (2014). Automated recognition of construction labour activity using accelerometers in field situations. *International Journal of Productivity and Performance Management*, 63(7). <https://doi.org/10.1108/IJPPM-05-2013-0099>
- Jun, H.-B., Shin, J.-H., Kim, Y.-S., Kiritsis, D. & Xirouchakis, P. (2009). A framework for RFID applications in product lifecycle management. *International Journal of Computer Integrated Manufacturing*, 22(7), 595–615. <https://doi.org/10.1080/09511920701501753>
- Kabadayi, S., Pridgen, A. & Julien, C. (2006). Virtual Sensors: Abstracting Data from Physical Sensors. In *2006 International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM'06)* (S. 587–592). IEEE. <https://doi.org/10.1109/WOWMOM.2006.115>
- Kadlec, P., Gabrys, B. & Strandt, S. (2009). Data-driven Soft Sensors in the process industry. *Computers & Chemical Engineering*, 33(4), 795–814. <https://doi.org/10.1016/j.compchemeng.2008.12.012>
- Kamath, A. K., Linke, B. S. & Chu, C.-H. (2020). Enabling Advanced Process Control for Manual Grinding Operations. *Smart and Sustainable Manufacturing Systems*, 4(2), Artikel 20190045. <https://doi.org/10.1520/SSMS20190045>
- Kaufmann, T., Sahay, S., Niemiets, P., Trauth, D., Maas, W. & Bergs, T. (2020). AI-based Framework for Deep Learning Applications in Grinding. In *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)* (S. 195–200). IEEE. <https://doi.org/10.1109/SAMI48414.2020.9108743>
- Kern, T. A. (2009). *Entwicklung haptischer Geräte: ein Einstieg für Ingenieure*. Berlin, Heidelberg: Springer. <https://doi.org/10.1007/978-3-540-87644-1>
- Kiritsis, D. (2011). Closed-loop PLM for intelligent products in the era of the Internet of things. *Computer-Aided Design*, 43(5), 479–501. <https://doi.org/10.1016/j.cad.2010.03.002>
- Kiritsis, D., Bufardi, A. & Xirouchakis, P. (2003). Research issues on product lifecycle management and information tracking using smart embedded systems. *Advanced Engineering Informatics*, 17(3-4), 189–202. <https://doi.org/10.1016/j.aei.2004.09.005>

- Klee, C. & Faisst, H.-J. (2013). *Angle grinder comprising a yaw rate sensor for measuring the housing rotation* (US20130189901A1). United States Patent and Trademark Office. Zugriff am 17.11.2022.  
<https://patentcenter.uspto.gov/applications/13642177>
- Klein, P., van der Vegte, W. F., Hribernik, K. A. & Klaus-Dieter, T. (2019). Towards an Approach Integrating Various Levels of Data Analytics to Exploit Product-Usage Information in Product Development. In *Proceedings of the Design Society: DESIGN Conference* (S. 2627–2636). Cambridge University Press.  
<https://doi.org/10.1017/dsi.2019.269>
- Kocijan, J. (2016). System Identification with GP Models. In J. Kocijan (Hrsg.), *Modelling and Control of Dynamic Systems Using Gaussian Process Models* (Advances in Industrial Control, S. 21–102). Cham: Springer.  
[https://doi.org/10.1007/978-3-319-21021-6\\_2](https://doi.org/10.1007/978-3-319-21021-6_2)
- Koskimäki, H., Huikari, V., Siirtola, P., Laurinen, P. & Röning, J. (2009, 24. Juni). Activity recognition using a wrist-worn inertial measurement unit: A case study for industrial assembly lines. In *2009 17th Mediterranean Conference on Control and Automation*. IEEE. <https://doi.org/10.1109/MED.2009.5164574>
- Kuntoğlu, M., Aslan, A., Pimenov, D. Y., Usca, Ü. A., Salur, E., Gupta, M. K., Mikolajczyk, T., Giasin, K., Kapłonek, W. & Sharma, S. (2020). A Review of Indirect Tool Condition Monitoring Systems and Decision-Making Methods in Turning: Critical Analysis and Trends. *Sensors*, 21(1), Artikel 108.  
<https://doi.org/10.3390/s21010108>
- Küstner, C. (2020). *Assistenzsystem zur Unterstützung der datengetriebenen Produktentwicklung* [Dissertation]. Friedrich-Alexander-Universität Erlangen-Nürnberg, Erlangen.
- Lachmayer, R., Mozgova, I., Reimche, W., Colditz, F., Mroz, G. & Gottwald, P. (2014). Technical Inheritance: A Concept to Adapt the Evolution of Nature to Product Engineering. *Procedia Technology*, 15, 178–187.  
<https://doi.org/10.1016/j.protcy.2014.09.070>
- Lara, O. D. & Labrador, M. A. (2013). A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys & Tutorials*, 15(3), 1192–1209.  
<https://doi.org/10.1109/SURV.2012.110112.00192>



- Lee, S., Liu, L. [Li], Radwin, R. & Li, J. (2021). Machine Learning in Manufacturing Ergonomics: Recent Advances, Challenges, and Opportunities. *IEEE Robotics and Automation Letters*, 6(3), 5745–5752. <https://doi.org/10.1109/LRA.2021.3084881>
- Lehmhus, D., Wuest, T., Wellsandt, S., Bosse, S., Kaihara, T., Thoben, K.-D. et al. (2015). Cloud-Based Automated Design and Additive Manufacturing: A Usage Data-Enabled Paradigm Shift. *Sensors*, 15(12), 32079–32122. <https://doi.org/10.3390/s151229905>
- Liljelind, I., Pettersson, H., Nilsson, L., Wahlström, J., Toomingas, A., Lundström, R. et al. (2013). Determinants Explaining the Variability of Hand-Transmitted Vibration Emissions From Two Different Work Tasks: Grinding and Cutting Using Angle Grinders. *The Annals of Occupational Hygiene*, 57(8), 1065–1077. <https://doi.org/10.1093/annhyg/met020>
- Liljelind, I., Wahlström, J., Nilsson, L., Persson, M. & Nilsson, T. (2010). Can we explain the exposure variability found in hand-arm vibrations when using angle grinders? A round robin laboratory study. *International archives of occupational and environmental health*, 83(3), 283–290. <https://doi.org/10.1007/s00420-009-0498-2>
- Lim, A., Kim, J. & Zechmann, E. (2013). Development of an Experimental Method to Estimate the Operating Force of a Hand-Held Power Tool Utilizing Measured Transfer Functions. In *Proceedings of ASME 2013 International Mechanical Engineering Congress and Exposition: Volume 4A: Dynamics, Vibration and Control*. ASME. <https://doi.org/10.1115/IMECE2013-65801>
- Lim, H., Kim, B. & Park, S. (2019). Prediction of Lower Limb Kinetics and Kinematics during Walking by a Single IMU on the Lower Back Using Machine Learning. *Sensors*, 20(1), Artikel 130. <https://doi.org/10.3390/s20010130>
- Lindenmann, A. (2023). Abbildung der Schwingungseigenschaften des menschlichen Hand-Arm-Systems in translatorischer Richtung in einem einstellbaren physischen Hand-Arm-Modell [Dissertation]. In A. Albers & S. Matthiesen (Hrsg.), *Forschungsberichte des IPEK - Institut für Produktentwicklung: Systeme, Methoden, Prozesse* (Bd. 166). Karlsruher Institut für Technologie (KIT), Karlsruhe. <https://doi.org/10.5445/IR/1000161145>
- Liu, L. [Lichuan], Kuo, S. M. & Zhou, M. (2009). Virtual sensing techniques and their applications. In *2009 IEEE Conference on Emerging Technologies & Factory Automation* (S. 31–36). IEEE. <https://doi.org/10.1109/ICNSC.2009.4919241>

- Löffler, C., Nickel, C., Sobel, C., Dzibela, D., Braat, J., Gruhler, B., Woller, P., Witt, N. & Mutschler, C. (2021). Automated Quality Assurance for Hand-Held Tools via Embedded Classification and AutoML. In F. Hutter, K. Kersting, J. Lijffijt & I. Valera (Hrsg.), *Lecture notes in computer science Lecture notes in artificial intelligence: Bd. 12461, ECML PKDD: Joint European Conference on Machine Learning and Knowledge Discovery in Databases* (S. 532–535). Cham: Springer.  
[https://doi.org/10.1007/978-3-030-67670-4\\_33](https://doi.org/10.1007/978-3-030-67670-4_33)
- Lu, H., Schomaker, L. R. & Carloni, R. (2020). IMU-based Deep Neural Networks for Locomotor Intention Prediction. In *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (S. 4134–4139). IEEE.  
<https://doi.org/10.1109/IROS45743.2020.9341649>
- Lu, N. & Gao, F. (2005). Stage-Based Process Analysis and Quality Prediction for Batch Processes. *Industrial & Engineering Chemistry Research*, 44(10), 3547–3555.  
<https://doi.org/10.1021/ie048852l>
- Malkin, S. (2008). *Grinding technology. Theory and applications of machining with abrasives* (2. Aufl.). New York, NY: Industrial Press.
- Matthiesen, S., Gwosch, T. & Bruchmüller, T. (2017). Experimentelle Identifikation von Schwingungsursachen in Antriebssträngen von Power-Tools. In *VDI-Berichte: Bd. 2295, VDI Fachtagung Schwingungen 2017: Berechnung, Überwachung, Anwendung* (S. 311–322). Düsseldorf: VDI Verlag.  
<https://doi.org/10.51202/9783181022955-311>
- Matthiesen, S., Gwosch, T. & Mangold, S. (2014). Eine Methode für eine Prüf- und Validierungsumgebung zur Komponentenuntersuchung handgehaltener Geräte in der Produktentwicklung. In F. Rieg, K. Brökel, J. Feldhusen, K.-H. Grote & R. Stelzer (Hrsg.), *12. gemeinsames Kolloquium Konstruktionstechnik* (S. 51–61). Bayreuth: Universität Bayreuth.
- Matthiesen, S., Gwosch, T., Mangold, S., Dültgen, P., Pelshenke, C. & Gittel, H.-J. (2017). Realitätsnahe Komponententests zur Unterstützung der Produktentwicklung bei der Validierung von Power-Tools. *Konstruktion*, 69(7-8), 76–81.
- Matthiesen, S., Gwosch, T., Schäfer, T., Dültgen, P., Pelshenke, C. & Gittel, H.-J. (2016). Experimentelle Ermittlung von Bauteilbelastungen eines Power Tool Antriebsstrangs durch indirektes Messen in realitätsnahen Anwendungen als ein Baustein in der Teilsystemvalidierung. *Forschung im Ingenieurwesen*, 80(1-2), 17–27. <https://doi.org/10.1007/s10010-016-0203-z>

- Meddour, I., Yallese, M. A., Bensouilah, H., Khellaf, A. & Elbah, M. (2018). Prediction of surface roughness and cutting forces using RSM, ANN, and NSGA-II in finish turning of AISI 4140 hardened steel with mixed ceramic tool. *The International Journal of Advanced Manufacturing Technology*, 97(5), 1931–1949. <https://doi.org/10.1007/s00170-018-2026-6>
- Mehlstäubl, J., Nicklas, S., Gerschütz, B., Sprogies, N., Schleich, B., Lohner, T., Wartzack, S., Stahl, K. & Paetzold, K. (2021). Voraussetzungen für den Einsatz datengetriebener Methoden in der Produktentwicklung. In D. Krause, K. Paetzold & S. Wartzack (Hrsg.), *DS 111: Proceedings of the 32nd Symposium Design for X (DFX2021)*. The Design Society. <https://doi.org/10.35199/dfx2021.13>
- Murphy, K. P. (2013). *Machine Learning. A Probabilistic Perspective* (Adaptive computation and machine learning series). Cambridge, MA: MIT Press.
- Nurwulan, N. & Jiang, B. C. (2020). Window selection impact in human activity recognition. *International Journal of Innovative Technology and Interdisciplinary Sciences*, 3(1), 381–394. <https://doi.org/10.15157/IJITIS.2020.3.1.381-394>
- Odum, K., Castillo, M. C., Das, J. & Linke, B. S. (2014). Sustainability Analysis of Grinding with Power Tools. *Procedia CIRP*, 14, 570–574. <https://doi.org/10.1016/j.procir.2014.03.011>
- Phan, G.-H., Hansen, C., Tommasino, P., Hussain, A. & Campolo, D. (2020). Design and characterization of an instrumented hand-held power tool to capture dynamic interaction with the workpiece during manual operations. *The International Journal of Advanced Manufacturing Technology*, 111(1-2), 199–212. <https://doi.org/10.1007/s00170-020-06066-3>
- Phan, G.-H., Kanam S. & Campolo, D. (2017). Instrumentation of a grinding tool for capturing dynamic interactions with the workpiece. In *2017 IEEE International Conference on Cybernetics and Intelligent Systems (CIS) and IEEE Conference on Robotics, Automation and Mechatronics (RAM)* (S. 551–555). IEEE. <https://doi.org/10.1109/ICCIS.2017.8274836>
- Pirola, F., Boucher, X., Wiesner, S. & Pezzotta, G. (2020). Digital technologies in product-service systems: a literature review and a research agenda. *Computers in Industry*, 123, Artikel 103301. <https://doi.org/10.1016/j.compind.2020.103301>
- Quasi-Newton Methods (2006). In J. Nocedal & S. J. Wright (Hrsg.), *Numerical Optimization* (S. 135–163). New York, NY: Springer. [https://doi.org/10.1007/978-0-387-40065-5\\_6](https://doi.org/10.1007/978-0-387-40065-5_6)

- Radaj, D. & Vormwald, M. (2007). *Ermüdungsfestigkeit*. Berlin, Heidelberg: Springer.  
<https://doi.org/10.1007/978-3-540-71459-0>
- Raheja, D. (2012). Design for Reliability Paradigms. In D. Raheja & L. Gullo (Hrsg.), *Design for reliability* (S. 1–13). Hoboken, NJ: Wiley Online Library.  
<https://doi.org/10.1002/9781118310052.ch1>
- Ram, S. & Jung, H.-S. (1990). The conceptualization and measurement of product usage. *Journal of the Academy of Marketing Science*, 18(1), 67–76.  
<https://doi.org/10.1007/BF02729763>
- Ranasinghe, S., Al Machot, F. & Mayr, H. C. (2016). A review on applications of activity recognition systems with regard to performance and evaluation. *International Journal of Distributed Sensor Networks*, 12(8).  
<https://doi.org/10.1177/1550147716665520>
- Rasmussen, C. E. & Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning* (Adaptive computation and machine learning). Cambridge, MA: MIT Press.
- Redžepagić, A., Löffler, C., Feigl, T. & Mutschler, C. (2020). A Sense of Quality for Augmented Reality Assisted Process Guidance. In *2020 IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct)* (S. 129–134). IEEE. <https://doi.org/10.1109/ISMAR-Adjunct51615.2020.00046>
- Roblek, V., Meško, M. & Krapež, A. (2016). A Complex View of Industry 4.0. *SAGE Open*, 6(2). <https://doi.org/10.1177/2158244016653987>
- Ryu, J., Seo, J., Jebelli, H. & Lee, S. (2019). Automated Action Recognition Using an Accelerometer-Embedded Wristband-Type Activity Tracker. *Journal of Construction Engineering and Management*, 145(1), Artikel 04018114.  
[https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001579](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001579)
- Sang, Y. (2020). *System and Measurements*. Berlin, Boston: De Gruyter.  
<https://doi.org/10.1515/9783110624397>
- Sanhudo, L., Calvetti, D., Martins, J. P., Ramos, N. M., Mêda, P., Gonçalves, M. C. & Sousa, H. (2021). Activity classification using accelerometers and machine learning for complex construction worker activities. *Journal of Building Engineering*, 35, Artikel 102001. <https://doi.org/10.1016/j.jobe.2020.102001>
- Sarhan, A. A. D., Matsubara, A., Sugihara, M., Saraie, H., Ibaraki, S. & Kakino, Y. (2006). Monitoring method of cutting force by using additional spindle sensors.

*JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing*, 49(2), 307–315. <https://doi.org/10.1299/jsmec.49.307>

- Schäfer, T. (2018). Ein gesamtsystemischer Ansatz zur simulationsgestützten Analyse und Optimierung eines Bohrhammerschlagwerkes [Dissertation]. In A. Albers & S. Matthiesen (Hrsg.), *Forschungsberichte des IPEK - Institut für Produktentwicklung: Systeme, Methoden, Prozesse* (Bd. 111). Karlsruher Institut für Technologie (KIT), Karlsruhe. <https://doi.org/10.5445/IR/1000085321>
- Schmid, H., Pfeiffer, T. & Krauss, M. (2021). Handgerät (DE102020109735A1). Deutsche Patent- und Markenamt. Zugriff am 17.11.2022. <https://depatisnet.dpma.de/DepatisNet/depatisnet?action=bibdat&docid=DE102020109735A1>
- Schmidt, S. (2019). Erweiterte Anwendungsfallmodellierung (e-AFM) Ein Beitrag zur nutzerzentrierten Entwicklung von Power-Tools [Dissertation]. In A. Albers & S. Matthiesen (Hrsg.), *Forschungsberichte des IPEK - Institut für Produktentwicklung: Systeme, Methoden, Prozesse* (Bd. 114). Karlsruher Institut für Technologie (KIT), Karlsruhe. <https://doi.org/10.5445/IR/1000089238>
- Schweizer, H. H. (Hrsg.). (2003). *Elektrowerkzeuge und ihre Anwendung. 1500 Fragen und Antworten* (1. Aufl.). Konstanz: Technisches Institut für Aus- und Weiterbildung GmbH & Co. KG.
- Schweizer, H. H. (2005). *Taschenbuch für Handwerk und Industrie* (6. Aufl.). Leinenfelden-Echterdingen: Robert Bosch GmbH.
- Sharma, V. S., Dhiman, S., Sehgal, R. & Sharma, S. K. (2008). Estimation of cutting forces and surface roughness for hard turning using neural networks. *Journal of Intelligent Manufacturing*, 19(4), 473–483. <https://doi.org/10.1007/s10845-008-0097-1>
- Shin, J.-H., Kiritsis, D. & Xirouchakis, P. (2015). Design modification supporting method based on product usage data in closed-loop PLM. *International Journal of Computer Integrated Manufacturing*, 28(6), 551–568. <https://doi.org/10.1080/0951192X.2014.900866>
- Sousa, V. F. C., Silva, F. J. G., Fecheira, J. S., Lopes, H. M., Martinho, R. P., Casais, R. B. & Ferreira, L. P. (2020). Cutting Forces Assessment in CNC Machining Processes: A Critical Review. *Sensors*, 20(16), Artikel 4536. <https://doi.org/10.3390/s20164536>

- Souza, F. A., Araújo, R. & Mendes, J. (2016). Review of soft sensor methods for regression applications. *Chemometrics and Intelligent Laboratory Systems*, 152, 69–79. <https://doi.org/10.1016/j.chemolab.2015.12.011>
- Stetter, B. J., Ringhof, S., Krafft, F. C., Sell, S. & Stein, T. (2019). Estimation of Knee Joint Forces in Sport Movements Using Wearable Sensors and Machine Learning. *Sensors*, 19(17), Artikel 3690. <https://doi.org/10.3390/s19173690>
- Stiefmeier, T., Roggen, D., Ogris, G., Lukowicz, P. & Tröster, G. (2008). Wearable Activity Tracking in Car Manufacturing. *IEEE Pervasive Computing*, 7(2), 42–50. <https://doi.org/10.1109/MPRV.2008.40>
- Tao, W., Lai, Z.-H., Leu, M. C. & Yin, Z. (2018). Worker Activity Recognition in Smart Manufacturing Using IMU and sEMG Signals with Convolutional Neural Networks. *Procedia Manufacturing*, 26, 1159–1166. <https://doi.org/10.1016/j.promfg.2018.07.152>
- Tönshoff, H. K., Peters, J., Inasaki, I. & Paul, T. (1992). Modelling and Simulation of Grinding Processes. *CIRP Annals*, 41(2), 677–688. [https://doi.org/10.1016/S0007-8506\(07\)63254-5](https://doi.org/10.1016/S0007-8506(07)63254-5)
- Van Horn, D. & Lewis, K. (2015). The use of analytics in the design of sociotechnical products. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 29(1), 65–81. <https://doi.org/10.1017/S0890060414000614>
- Verwaltungs-Berufsgenossenschaft. (2022). 2006/42/EG Lt - Leitfaden für die Anwendung der Maschinenrichtlinie 2006/42/EG. § 278 Ergänzende Anforderungen an handgehaltene und/oder handgeführte tragbare Maschinen. Zugriff am 21.10.2022. [http://regelwerke.vbg.de/vbg\\_egr/e2006-42lt/e2006-42lt\\_293\\_.html](http://regelwerke.vbg.de/vbg_egr/e2006-42lt/e2006-42lt_293_.html)
- Vichare, N., Rodgers, P., Eveloy, V. & Pecht, M. (2007). Environment and Usage Monitoring of Electronic Products for Health Assessment and Product Design. *Quality Technology & Quantitative Management*, 4(2), 235–250. <https://doi.org/10.1080/16843703.2007.11673148>
- Voet, H., Altenhof, M., Ellerich, M., Schmitt, R. H. & Linke, B. S. (2019). A Framework for the Capture and Analysis of Product Usage Data for Continuous Product Improvement. *Journal of Manufacturing Science and Engineering*, 141(2), Artikel 021010. <https://doi.org/10.1115/1.4041948>

- Vorwerk-Handing, G., Gwosch, T., Schork, S., Kirchner, E. & Matthiesen, S. (2020). Classification and examples of next generation machine elements. *Forschung im Ingenieurwesen*, 84(1), 21–32. <https://doi.org/10.1007/s10010-019-00382-1>
- Ward, J. A., Lukowicz, P., Tröster, G. & Starner, T. E. (2006). Activity recognition of assembly tasks using body-worn microphones and accelerometers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(10), 1553–1567. <https://doi.org/10.1109/TPAMI.2006.197>
- Wellsandt, S., Hribernik, K. A. & Thoben, K.-D. (2015). Sources and Characteristics of Information about Product Use. *Procedia CIRP*, 36, 242–247. <https://doi.org/10.1016/j.procir.2015.01.060>
- Wilwer, J., Germann, R., Dörner, P.-T. & Matthiesen, S. (2020). SMART assistive systems in power tools – Identification of product requirements in application studies. In D. Krause, K. Paetzold & S. Wartzack (Hrsg.), *DS 106: Proceedings of the 31st Symposium Design for X (DFX2020)* (S. 141–150). The Design Society. <https://doi.org/10.35199/dfx2020.15>
- Wu, C.-C., Wen, Y.-T. & Lee, Y.-J. (2020). IMU sensors beneath walking surface for ground reaction force prediction in gait. *IEEE Sensors Journal*, 20(16), 9372–9376. <https://doi.org/10.1109/JSEN.2020.2988296>
- Wynn, D. C. & Maier, A. M. (2022). Feedback systems in the design and development process. *Research in Engineering Design*, 33(3), 273–306. <https://doi.org/10.1007/s00163-022-00386-z>
- Yan, S., Eiber, A. & Schiehlen, W. (2005). Interaction between Electrical and Mechanical Components in Hand-held Electrical Tools. *Mechanics Based Design of Structures and Machines*, 33, 271–292. <https://doi.org/10.1080/15367730500374241>
- Yang, X., Wang, F., Li, H., Yu, Y., Luo, X. & Zhai, X. (2019). A Low-Cost and Smart IMU Tool for Tracking Construction Activities. In M. Al-Hussein (Hrsg.), *2019 Proceedings of the 36th International Symposium on Automation and Robotics in Construction (ISARC 2019)* (S. 35–41). International Association for Automation and Robotics in Construction (IAARC). <https://doi.org/10.22260/ISARC2019/0005>
- Yang, X., Yu, Y., Shirowzhan, S., Sepasgozar, S. & Li, H. (2020). Automated PPE-Tool pair check system for construction safety using smart IoT. *Journal of Building Engineering*, 32, Artikel 101721. <https://doi.org/10.1016/j.jobe.2020.101721>

- Yusuf, Z. N. M., Sidek, N. S. D., Hamid, M. N. A. & Teoh, P. Y. (2019). Monitoring of Gear Surface Roughness in Angle Grinder using Vibration Analysis. In *IOP Conference Series: Bd. 815, Materials Science and Engineering. 3rd International Conference on Vibration, Sound and System Dynamics (ICVSSD 2019)*. Bristol: IOP Publishing. <https://doi.org/10.1088/1757-899X/815/1/012005>
- Zhang, M., Chen, S., Zhao, X. & Yang, Z. (2018). Research on Construction Workers' Activity Recognition Based on Smartphone. *Sensors*, 18(8), Artikel 2667. <https://doi.org/10.3390/s18082667>
- Zimprich, S., Germann, R., Helmstetter, S., Saurbier, S. & Matthiesen, S. (2021). An Objective Rating Approach for Vibration Discomfort Evaluation in Power Tool Ergonomics – Examination of Higher Frequency Components. In T. Ahram, R. Taiar, K. Langlois & A. Choplin (Hrsg.), *Advances in Intelligent Systems and Computing: Bd. 1253. Human Interaction, Emerging Technologies and Future Applications III* (S. 84–90). Cham: Springer. [https://doi.org/10.1007/978-3-030-55307-4\\_13](https://doi.org/10.1007/978-3-030-55307-4_13)
- Zingel, C. (2013). Basisdefinition einer gemeinsamen Sprache der Produktentwicklung im Kontext der Modellbildung technischer Systeme und einer Modellierungstechnik für Zielsystem und Objektsystem technischer Systeme in SysML auf Grundlage des ZHO-Prinzips [Dissertation]. In A. Albers & S. Matthiesen (Hrsg.), *Forschungsberichte des IPEK - Institut für Produktentwicklung: Systeme, Methoden, Prozesse* (Bd. 70). <https://doi.org/10.5445/IR/1000037421>

## **Studentische Abschlussarbeiten die im Kontext dieser Dissertation am IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT) vom Autor Co-betreut wurden:**

- Bassala, F. (2020). *Entwicklung eines modularen Datenloggers für akkubetriebene Power Tools* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Chen, J. (2018). *Klassifikation von Anwendungsfällen mit Fokus auf Merkmalsextraktion und Merkmalsselektion am Beispiel Akkuschauber* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.



- Duttlinger, F. (2022). *Erstellung von Testfallverfahren für Flugsteuerungssysteme durch Anwendungen von Prinzipien des Machine Learning* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Gallagher, P. (2018). *Konzeptionierung eines Entwicklungsprüfstandes für Winkelschleifer* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Gan, J. (2018). *Klassifikation von Power Tool Anwendungen durch unüberwachtes Lernen* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Gehrlein, S. (2019). *Entwicklung eines Hand-Arm-Systems an einem dynamischen Winkelschleiferprüfstand* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Kaiser, J. (2018). *Entwicklung eines vernetzten Datenloggers zur Messung an Power-Tools* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Karam, M. (2021). *Optimale Testplanung mittels genetischem Algorithmus für die Simulation eines elektrohydraulischen Aktuators* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Meewassana, B. (2020). *Optimierung der Datenspeicherung auf einer Datenlogger-Platine* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Mertens, J. (2019). *Entwicklung und Konstruktion eines dynamischen Prüfstandes für Winkelschleifer* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Peters, J. (2020). *Optimierung eines kompakten Sensormoduls zur Ermittlung von Betriebsgrößen an akkubetriebenen Power-Tools* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Rothweiler, A. (2020). *Erfassung der Anwenderkräfte eines Winkelschleifers an einem Prüfaufbau* [Unveröffentlichte Bachelorarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Song, R. (2020). *Klassifikationen und Segmentierung von Zeitreihen bei Power Tools* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.

- Spoden, F. (2021). *Klassifikation von vielfältigen Anwendungsfällen eines Winkelschleifers durch maschinelles Lernen* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Wang, F. (2022). *Optimale Testplanung für das Testing von Flugsteuerungssystemen auf Basis von Machine Learning* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Wu, P. (2019). *Robuste Klassifikation zahlreicher Anwendungsfälle eines Akkuschraubers* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Yang, J. (2020). *Klassifizierung und Segmentierung von Zeitreihen bei Power Tools* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Zhou, T. (2019). *Implementierung einer Regelung auf einem Geräteprüfstand für Winkelschleifer* [Unveröffentlichte Masterarbeit]. Karlsruher Institut für Technologie (KIT), Karlsruhe.

## **Veröffentlichungen, die unter Mitautorenschaft des Autors dieser Forschungsarbeit entstanden sind:**

- Albers, A., Walter, B., Gladysz, B., Reiß, N., Dörr, M. & Hinkelmann, M. (2014). Ansatz zur situations- und bedarfsgerechten Methodenauswahl in der Produktentwicklung basierend auf dem Systemtripel aus Zielsystem, Handlungssystem und Objektsystem. In F. Rieg, K. Brökel, J. Feldhusen, K.-H. Grote & R. Stelzer (Hrsg.), *12. gemeinsames Kolloquium Konstruktionstechnik* (S. 83–94). Bayreuth: Universität Bayreuth.
- Bruchmüller, T., Dörr, M., Neugebauer, W., Steck, M. & Matthiesen, S. (2019). *Testvorrichtung für Bohrhämmer* (EP 3581911 B1). Europäische Patentorganisation (EPO). Zugriff am 30.03.2023. <https://data.epo.org/gpi/EP3581911B1>
- Dörr, M., Dürkopp, A., Zimprich, S., Gwosch, T., Gittel, H.-J., Pelshenke, C. et al. (2021). Approach for Modelling the Dynamic Transmission Behavior of Grinding Discs Using Transfer Functions. In *Proceedings of ASME 2021 International Mechanical Engineering Congress and Exposition. Volume 7B: Dynamics, Vibration, and Control*. ASME. <https://doi.org/10.1115/IMECE2021-69393>

- Dörr, M., Karam, M., Wolter, K., Leitenberger, F., Gwosch, T. & Matthiesen, S. (2021, 25.-29. Oktober). *Approach to Automated Testing by Combining Simulations and Bench Tests Conducted on an Electrohydraulic Actuator* [Konferenzbeitrag]. NAFEMS World Congress (NWC 2021), Onlinekonferenz.
- Dörr, M., Leitenberger, F., Wolter, K., Matthiesen, S. & Gwosch, T. (2022). Model-Based Control Design of an EHA Position Control Based on Multicriteria Optimization. *Machines*, 10(12), Artikel 1190. <https://doi.org/10.3390/machines10121190>
- Dörr, M., Mertens, J., Gwosch, T. & Matthiesen, S. (2021). A New Dynamical Test Bench for Multi-Axial Loading of Angle Grinders. *KIT Scientific Working Papers*, (159). <https://doi.org/10.5445/IR/1000130022>
- Dörr, M., Ott, L., Matthiesen, S. & Gwosch, T. (2021). Prediction of Tool Forces in Manual Grinding Using Consumer-Grade Sensors and Machine Learning. *Sensors*, 21(21), Artikel 7147. <https://doi.org/10.3390/s21217147>
- Dörr, M., Peters, J. & Matthiesen, S. (2021). Data-Driven Analysis of Human-Machine Systems – A Data Logger and Possible Use Cases for Field Studies with Cordless Power Tools. In T. Ahram, R. Taiar, K. Langlois & A. Choplin (Hrsg.), *Advances in Intelligent Systems and Computing: Bd. 1253. Human Interaction, Emerging Technologies and Future Applications III* (S. 56–62). Cham: Springer. [https://doi.org/10.1007/978-3-030-55307-4\\_9](https://doi.org/10.1007/978-3-030-55307-4_9)
- Dörr, M., Ries, M., Gwosch, T. & Matthiesen, S. (2019). Recognizing Product Application based on Integrated Consumer Grade Sensors: A Case Study with Handheld Power Tools. *Procedia CIRP*, 84, 798–803. <https://doi.org/10.1016/j.procir.2019.04.317>
- Dörr, M., Spoden, F., Matthiesen, S. & Gwosch, T. (2022). Activity Recognition With Machine Learning in Manual Grinding. *Journal of Manufacturing Science and Engineering*, 144(9), Artikel 094504. <https://doi.org/10.1115/1.4054905>
- Dörr, M., Dürkopp, A., Zimprich, S., Gwosch, T., Gittel, H.-J., Pelshenke, C., Dültgen, P. & Matthiesen, S. (2019). Experimental Abrasive Contact Analysis – Dynamic Forces between Grinding Discs and Steel for common Angle Grinder Applications. In C. Broeckmann (Hrsg.), *Proceedings of the 11th TOOLING conference & Exhibition*. Aachen: TEMA Technologie Marketing AG.
- Gwosch, T., Dörr, M. & Matthiesen, S. (2021). Modeling of Human-Machine Systems for System Reliability Testing: Investigation of the User Impact on the Load of the Machine. In H. Binz, B. Bertsche, D. Spath & D. Roth (Hrsg.), *Stuttgarter*

*Symposium für Produktentwicklung SSP 2021* (Bd. 6, S. 455–464). Stuttgart: Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO.

- Gwosch, T., Steck, M., Dörr, M. & Matthiesen, S. (2020). Frontloading in Aircraft Development Process by Integration of a new Validation Method. *KIT Scientific Working Papers*, (139). <https://doi.org/10.5445/IR/1000117783>
- Helmstetter, S., Dörr, M., Germann, R. & Matthiesen, S. (2022). User-centered design of power tools: a generic process for evaluation of usability aspects. *Forschung im Ingenieurwesen*, 86, 93–104. <https://doi.org/10.1007/s10010-021-00546-y>
- Leitenberger, F., Dörr, M. & Matthiesen, S. (2023, 15.-18. Mai). *Approach to Twinning with High Twinning Rates: Enabling the Use of Data-Driven Methods for Digital Twins* [Konferenzbeitrag]. NAFEMS World Congress (NWC 2023), Tampa, FL.
- Matthiesen, S., Dörr, M. & Zimprich, S. (2018). Testfallgenerierung - Vorgehen zur Lastkollektivermittlung durch Data Mining am Winkelschleifer. In D. Krause, K. Paetzold & S. Wartzack (Hrsg.), *Design for X. Beiträge zum 29. DfX-Symposium 2018* (295-306). Hamburg: TuTech Verlag.
- Peters, J., Ott, L., Dörr, M., Gwosch, T. & Matthiesen, S. (2021). Design of sensor integrating gears: methodical development, integration and verification of an in-Situ MEMS sensor system. *Procedia CIRP*, 100, 672–677. <https://doi.org/10.1016/j.procir.2021.05.142>
- Peters, J., Ott, L., Dörr, M., Gwosch, T. & Matthiesen, S. (2021). Sensor-integrating gears: wear detection by in-situ MEMS acceleration sensors. *Forschung im Ingenieurwesen*, 86, 421–432. <https://doi.org/10.1007/s10010-021-00575-7>

# Glossar

<b>Begriff</b>	<b>Definition</b>
Anwendung	Eine Anwendung im Kontext von Power-Tools beschreibt die Aneinanderreihung von Tätigkeiten zur Erfüllung einer Arbeitsaufgabe. (Gwosch, 2019)
Datengetriebene Produktentwicklung	Bei der datengetriebenen Produktentwicklung wird die Konstruktion durch die Analyse erfasster Daten unterstützt, in dem die Ursache für ein Produktverhalten identifiziert und erklärt wird. (Küstner, 2020)
Handgeführte Maschine	Unter einer handgeführten Maschine wird eine tragbare Maschine verstanden, deren Gewicht ganz oder teilweise zum Beispiel auf einer Werkbank, auf dem bearbeiteten Werkstoff oder Werkstück oder auf dem Boden, abgestützt wird und dessen Bewegung von einer anwendenden Person während der Bedienung der Maschine mit der Hand geführt wird. (VBG, 2022)
Informationen zur Produktnutzung (PUI)	PUI beschreiben alle dem Produkt zugeordneten Informationen, die aus der Nutzungsphase zurück in die Produktentwicklung fließen. (Fathi & Holland, 2009)
Kontext	Kontext kann als jede Information definiert werden, die zur Charakterisierung der Situation eines Produkts verwendet werden kann. (Abowd et al., 1999)
Kreuzvalidierung (CV)	Die Kreuzvalidierung (englisch cross-validation) ist ein Verfahren zur Bewertung der Vorhersagegenauigkeit von statistischen Modellen.
Labor-Messsysteme	Messsysteme, bei denen nur der Messaufnehmer am oder im Power-Tool appliziert ist, der Messumformer und die Auswerteeinheit stationär sind sowie die Datenübertragung per Kabel erfolgt.
Leave-One-Trial-Out Kreuzvalidierung (LOTO CV)	Leave-One-Trial-Out Kreuzvalidierung (LOTO CV) ist eine spezielle Form der Kreuzvalidierung. Bei der LOTO CV werden die Daten in Versuche unterteilt.
Nutzungselement	Relevante Bestandteile der PUI. Nutzungselemente beschreiben einzelne Tätigkeiten oder Parameter, die als PUI erfasst werden. In Anlehnung an Voet et al. (2019)
Nutzungszustand	Werte oder Zustände, die quantitativ oder qualitativ ein Nutzungselement beschreiben werden. In Anlehnung an Voet et al. (2019)

PEID (In ein Produkt eingebettetes Informationsmodul)	System innerhalb eines Produkts, das die Erfassung, Verarbeitung und Speicherung von Sensordaten ermöglicht. (Jun et al., 2009)
Power-Tool	Power-Tools sind handgehaltene oder handgeführte Maschinen. (VBG, 2022)
Sensormodul	Messsysteme, bei denen der Messaufnehmer, der Messumformer und die Auswerteeinheit als kompaktes Modul mit integrierter Speichereinheit und Stromversorgung ausgeführt sind.
Skalierbare Erfassung	Unter skalierbarer Erfassung im Kontext der messtechnischen Erfassung von PUI wird verstanden, dass die weitere messtechnische Erfassung von PUI bei weiteren anwendenden Personen mit geringem Aufwand verbunden ist. In Anlehnung an Ghosh et al. (2017) und Germine et al. (2021)
Tätigkeit	Eine Tätigkeit beschreibt im Kontext von Power-Tools eine Handlung oder Aktion, die eine anwendende Person mit einem Power-Tool durchführt.
Unbeobachtete Erfassung	Unbeobachtete Erfassung im Kontext der messtechnischen Erfassung von PUI bedeutet, dass der Kontext nur durch Kontextdaten geschaffen wird.
Verhalten	Unter dem Verhalten eines Produkts wird dessen Reaktion auf einwirkende Einflussgrößen verstanden. (Zingel, 2013)
Virtueller Sensor	Virtuelle Sensoren bestehen aus mehreren physisch vorhandenen Sensoren und mathematischen Modellen, die eine quantitative oder qualitative Zielgröße aus den Sensordaten berechnen oder vorhersagen. In Anlehnung an Becker & Krause (2010)
Werkzeugkontakt	Schnittstelle zwischen dem Werkstück und Werkzeug eines Power-Tools.
Winkelschleifer	Winkelschleifer sind Rotationsschleifer, bei denen die Drehachse des Werkzeugs in einem Winkel von 90° zur Antriebsachse angeordnet ist. (Schweizer, 2005)

# Anhang

## Spezifikation der verwendeten Sensormodule

Tabelle A listet die relevanten Bauteile auf, die in die Sensormodule C1, G1 und G2 integriert wurden.

Tabelle A: In den Sensormodulen C1, G1 und G2 integrierte Bauteile.

<b>Sensormodul C1</b>		<b>Bezeichnung</b>	<b>Hersteller</b>
Microcontroller	ATSAMD21G		ARM Limited, Cambridge, Vereinigtes Königreich
IMU	LSM9DS0		STMicroelectronics, Genf, Schweiz
Stromsensor	ACS758 - 100U		Texas Instruments, Dallas, Texas, USA
Echtzeituhr	DS3231		Maxim Integrated, San José, Kalifornien, Vereinigte Staaten

<b>Sensormodul G1</b>		<b>Bezeichnung</b>	<b>Hersteller</b>
Microcontroller	ATSAMD21G		ARM Limited, Cambridge, Vereinigtes Königreich
IMU	LSM9DS0		STMicroelectronics, Genf, Schweiz
Stromsensor	INA 169		Texas Instruments, Dallas, Texas, USA
Echtzeituhr	DS3231		Maxim Integrated, San José, Kalifornien, Vereinigte Staaten

<b>Sensormodul G2</b>		<b>Bezeichnung</b>	<b>Hersteller</b>
Microcontroller	ATSAMD21J		ARM Limited, Cambridge, Vereinigtes Königreich
IMU	LSM9DS1		STMicroelectronics, Genf, Schweiz
Stromsensor	ACS758 - 100U		Texas Instruments, Dallas, Texas, USA
Echtzeituhr	DS3231		Maxim Integrated, San José, Kalifornien, Vereinigte Staaten

## Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt getrennt für den Winkelschleifer GWS18

Tabelle B zeigt die Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt der Versuche (N = 31) des Winkelschleifers GWS18 für eine Abtastrate von 10 Hz. Die Leistung des GPR-Modells wird als Mittelwert (und *SD*) mit dem *MAE*, dem *rMAE* und dem *r* angegeben. Die vorhergesagten Kräfte ergeben einen *MAE* im Bereich von 1,03 N bis 6,84 N, einen *rMAE* im Bereich von 9,42 % bis 630,23 % und einen *r* im Bereich von 0,09 bis 0,91. Die Bewertung der Leistung des GPR-Modells wird anhand der Bewertungsgröße *rMAE* in drei Gruppen (<15%, 15-30%, >30%) eingeteilt. Die Kräfte im Werkzeugkontakt, die einen *rMAE* von unter 15 % aufwiesen, sind die Kräfte  $F_{N,Schrupp}$ ,  $F_{T,Fiber}$ , und  $F_{N,Fiber}$ . Dies entspricht einer sehr guten Vorhersage. Die Kräfte im Werkzeugkontakt mit einem *rMAE* zwischen 15 % und 30 % sind die Kräfte  $F_{T,Schrupp}$ ,  $F_{T,Schleif}$ ,  $F_{N,Schleif}$ , und  $F_{R,Trenn}$ . Dies entspricht einer guten Vorhersage. Die Kräfte im Werkzeugkontakt mit einem *rMAE* über 30 % sind die Kräfte  $F_{F,Schrupp}$ ,  $F_{F,Fiber}$ ,  $F_{F,Schleif}$ , und  $F_{Q,Trenn}$ . Dies entspricht einer schlechten Vorhersage

Tabelle B: Bewertung der Vorhersage der Kräfte im Werkzeugkontakt für den Winkelschleifer GWS18 für eine Abtastrate von 10 Hz. Übersetzt aus Dörr, Ott et al. (2021, S. 10)

Tätigkeit	<i>MAE</i> [N]	<i>rMAE</i> [%]	<i>r</i>	<i>MAE</i> [N]	<i>rMAE</i> [%]	<i>r</i>	<i>MAE</i> [N]	<i>rMAE</i> [%]	<i>r</i>
Schruppen mit einer Schrappscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	2.83 (0.64)	137.25 (67.77)	0.47 (0.12)	1.66 (0.43)	20.91 (4.09)	0.85 (0.04)	2.15 (0.56)	9.42 (2.31)	0.91 (0.04)
Schruppen mit einer Fiberscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	2.64 (0.52)	64.38 (42.52)	0.48 (0.11)	1.03 (0.21)	11.11 (2.43)	0.89 (0.05)	1.80 (0.36)	10.06 (1.57)	0.80 (0.19)
Schleifen mit einer Fächer-Schleifscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	6.84 (1.77)	108.93 (67.21)	0.10 (0.19)	2.28 (0.73)	27.71 (16.37)	0.59 (0.14)	3.79 (1.67)	25.34 (16.83)	0.58 (0.16)
Trennen mit einer Trennscheibe	Querkraft			Radialkraft					
	3.14 (1.08)	630.23 (888.75)	0.09 (0.14)	4.66 (2.99)	24.03 (9.88)	0.70 (0.05)			



## Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt getrennt für den Winkelschleifer CCG18

Tabelle C zeigt die Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt der Versuche (N = 32) des Winkelschleifers CCG18 für eine Abtastrate von 10 Hz. Die Leistung des GPR-Modells wird als Mittelwert (und SD) mit dem *MAE*, dem *rMAE* und dem *r* angegeben. Die vorhergesagten Kräfte ergeben einen *MAE* im Bereich von 1,14 N bis 7,87 N, einen *rMAE* im Bereich von 7,52 % bis 503,67 % und einen *r* im Bereich von 0,16 bis 0,94. Die Leistung der Vorhersage des GPR-Modells wird anhand der Bewertungsgröße *rMAE* in drei Gruppen (<15%, 15-30%, >30%) eingeteilt. Die Kräfte im Werkzeugkontakt, die einen *rMAE* von unter 15 % aufwiesen, sind die Kräfte  $F_{N,Schrupp}$ ,  $F_{T,Fiber}$ , und  $F_{N,Fiber}$ . Die Kräfte im Werkzeugkontakt mit einem *rMAE* zwischen 15 % und 30 % sind die Kräfte  $F_{T,Schrupp}$ , und  $F_{R,Trenn}$ . Die Kräfte im Werkzeugkontakt mit einem *rMAE* über 30 % sind die Kräfte  $F_{F,Schrupp}$ ,  $F_{F,Fiber}$ ,  $F_{F,Schleif}$ ,  $F_{T,Schleif}$ ,  $F_{N,Schleif}$  und  $F_{Q,Trenn}$ .

Tabelle C: Bewertung der Vorhersage der Kräfte im Werkzeugkontakt für den Winkelschleifer CCG18 für eine Abtastrate von 10 Hz. Übersetzt aus Dörr, Ott et al. (2021, S. 12)

Tätigkeit	MAE [N]	rMAE [%]	r	MAE [N]	rMAE [%]	r	MAE [N]	rMAE [%]	r
Schruppen mit einer Schruppscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	2.63 (0.78)	84.47 (16.62)	0.17 (0.17)	1.69 (0.40)	23.27 (5.47)	0.81 (0.06)	2.01 (0.38)	8.68 (1.67)	0.85 (0.21)
Schruppen mit einer Fiberscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	2.94 (0.90)	39.04 (7.08)	0.58 (0.07)	1.14 (0.25)	12.32 (4.67)	0.91 (0.07)	1.66 (0.27)	7.62 (1.01)	0.94 (0.02)
Schleifen mit einer Fächer-Schleifscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	7.87 (0.99)	88.06 (54.40)	0.41 (0.11)	1.67 (0.37)	13.97 (4.40)	0.83 (0.08)	1.81 (0.40)	7.52 (1.71)	0.94 (0.02)
Trennen mit einer Trennscheibe	Querkraft			Radialkraft					
	4.62 (2.04)	503.67 (532.58)	0.16 (0.16)	2.61 (0.42)	15.31 (3.63)	0.90 (0.04)			

## Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt für verschiedene Abtastfrequenzen getrennt für den Winkelschleifer GWS18

Tabelle D zeigt die Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt der Versuche (N = 32) des Winkelschleifers GWS18 für drei verschiedene Abtastfrequenzen für die Bewertungsgröße relativer mittlerer absoluter Fehler (*rMAE*).

Tabelle D: Bewertung der Leistung der Vorhersage von Kräften für den Winkelschleifer GWS18 für verschiedene Abtastfrequenzen. Die Leistung des GPR-Modells wird als Mittelwert (und Standardabweichung) mit dem relativen mittleren absoluten Fehler (*rMAE*) für die Abtastfrequenzen von 1 Hz, 10 Hz, 20 Hz angegeben. In Anlehnung an Dörr, Ott et al. (2021, S. 12)

Tätigkeit	rMAE [%]			rMAE [%]			rMAE [%]		
	1 Hz	10 Hz	20 Hz	1 Hz	10 Hz	20 Hz	1 Hz	10 Hz	20 Hz
Schruppen mit einer Schruppscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	131.60 (75.57)	137.25 (67.77)	136.87 (69.77)	23.73 (3.10)	20.91 (4.09)	20.82 (3.58)	12.79 (4.95)	9.42 (2.31)	9.41 (2.73)
Schruppen mit einer Fiberscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	71.57 (51.55)	64.38 (42.52)	62.99 (40.15)	14.27 (3.54)	11.11 (2.43)	12.62 (2.88)	11.42 (1.03)	10.06 (1.57)	10.90 (2.41)
Schleifen mit einer Fächer-Schleifscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	100.82 (69.40)	108.93 (67.21)	102.40 (64.12)	80.61 (109.90)	27.71 (16.37)	71.59 (106.04)	30.49 (24.28)	25.34 (16.83)	31.96 (12.95)
Trennen mit einer Trennscheibe	Querkraft			Radialkraft					
	490.22 (517.88)	630.23 (888.75)	644.98 (886.18)	19.94 (11.69)	24.03 (9.88)	23.34 (9.00)			

## Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt für verschiedene Abtastfrequenzen getrennt für den Winkelschleifer CCG18

Tabelle E zeigt die Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt der Versuche (N = 32) des Winkelschleifers CCG18 für drei verschiedene Abtastfrequenzen für die Bewertungsgröße relativer mittlerer absoluter Fehler (*rMAE*).

Tabelle E: Bewertung der Leistung der Vorhersage von Kräften im Werkzeugkontakt für den Winkelschleifer CCG18 für verschiedene Abtastfrequenzen. Die Leistung des GPR-Modells wird als Mittelwert (und Standardabweichung) mit dem relativen mittleren absoluten Fehler (*rMAE*) für die Abtastfrequenzen von 1 Hz, 10 Hz, 20 Hz angegeben. In Anlehnung an Dörr, Ott et al. (2021, S. 13)

Tätigkeit	rMAE [%]			rMAE [%]			rMAE [%]		
	1 Hz	10 Hz	20 Hz	1 Hz	10 Hz	20 Hz	1 Hz	10 Hz	20 Hz
Schruppen mit einer Schruppscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	78.12 (32.19)	84.47 (16.62)	82.18 (20.77)	24.73 (2.95)	23.27 (5.47)	23.09 (6.48)	12.02 (1.49)	8.68 (1.67)	8.59 (1.11)
Schruppen mit einer Fiberscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	38.99 (6.89)	39.04 (7.08)	40.05 (11.08)	23.92 (11.36)	12.32 (4.67)	14.30 (5.94)	12.03 (3.28)	7.62 (1.01)	8.37 (1.14)
Schleifen mit einer Fächer-Schleifscheibe	Führungskraft			Tangentialkraft			Normalkraft		
	83.18 (52.71)	88.06 (54.40)	95.59 (58.97)	16.65 (4.80)	13.97 (4.40)	13.95 (4.12)	9.23 (2.32)	7.52 (1.71)	8.10 (1.62)
Trennen mit einer Trennscheibe	Querkraft			Radialkraft					
	715.05 (1161.6)	503.67 (532.58)	529.96 (557.62)	19.83 (5.49)	15.31 (3.63)	19.26 (5.64)			

## Vergleich der Bewertung der Vorhersage der Kräfte im Werkzeugkontakt für die Vorstudie und die Ergebnisse dieser Arbeit

Tabelle F vergleicht die Ergebnisse der im Rahmen dieser Forschungsarbeit durchgeführten Vorstudie (Matthiesen et al., 2018) mit den Ergebnissen dieser Forschungsarbeit. Da die Leistung der Regression in der Vorstudie mit dem Bestimmtheitsmaß  $R^2$  und mit dem Verfahren CV bewertet wurde, wird das Vorgehen aus Forschungsfrage 2 zur Generierung vergleichbarer Ergebnisse angepasst. Dazu wird eine klassische CV durchgeführt. Für die Tätigkeit *Trennen mit einer Trennscheibe* werden, wie in Kapitel 6.1.2 erläutert, die y-Richtung und z-Richtung zusammengefasst. Die Ergebnisse dieser Forschungsarbeit mit dem Bestimmtheitsmaß  $R^2$  und der CV sind in Dörr, Ott et al. (2021) veröffentlicht.

Tabelle F: Vergleich der Bewertung der Vorhersage der Kräfte im Werkzeugkontakt zwischen der in dieser Forschungsarbeit durchgeführten Studie und den Ergebnissen dieser Forschungsarbeit durchgeführt wurde, mit dem Bestimmtheitsmaß  $R^2$ . In Anlehnung an Matthiesen et al. (2018, S. 302) und Dörr, Ott et al. (2021, S. 12)

Tätigkeit	Leistung Regression in Vorstudie (Matthiesen et al., 2018),			Leistung Regression in dieser Forschungsarbeit		
	x-Richtung	y-Richtung	z-Richtung	x-Richtung	y-Richtung	z-Richtung
	Schruppen mit einer Schrupscheibe	0.27	0.94	0.97	0.58	0.81
Schleifen mit einer Fächer-Schleifscheibe	0.22	0.97	0.97	0.24	0.68	0.71
Trennen mit einer Trennscheibe	0.51	0.83	0.98	0.24	0.52	0.80
Durchschnitt für alle Tätigkeiten	0.33	0.91	0.97	0.35	0.67	0.79

### Abweichung zwischen verschiedenen Gruppen von Übertragungsfunktionen bei einer Auswertung von 1 Hz bis 125 Hz

Tabelle G zeigt die Ergebnisse zu den durchschnittlichen Abweichungen zwischen den verschiedenen Gruppen von Übertragungsfunktionen, die anhand der Faktoren des Versuchsdesigns gebildet wurden, für den Frequenzbereich von 1 Hz bis 125 Hz. Dies ermöglicht einen Vergleich der Frequenzbereiche.

Tabelle G: Durchschnittliche Abweichungen als *MAE* zwischen verschiedenen Gruppen von Übertragungsfunktionen, die anhand der Faktoren des Versuchsdesigns eingeteilt wurden, für den Frequenzbereich von 1 Hz bis 125 Hz.

Werkzeug	(1) Gleicher Arbeitspunkt	(2) Gleiche Drehzahl	(3) Gleiche Normalkraft	(4) Untersch. Arbeitspunkte	Prozentuale Abweichung
Fächerschleif-scheibe	Gruppe 1	Gruppe 2	Gruppe 3	Gruppe 4	Gruppe 1 vs. Gruppe 4
x-Richtung	0.45	0.54	0.55	0.58	29.3 %
y-Richtung	0.44	0.44	0.49	0.49	9.5 %
z-Richtung	0.26	0.28	0.31	0.32	26.0 %
Schrupp-scheibe	Gruppe 1	Gruppe 2	Gruppe 3	Gruppe 4	Gruppe 1 vs. Gruppe 4
x-Richtung	1.83	1.87	1.92	1.98	8.3 %
y-Richtung	0.35	0.34	0.35	0.35	1.4 %
z-Richtung	0.19	0.20	0.20	0.20	6.0 %
Trenn-scheibe	Gruppe 1	Gruppe 2	Gruppe 3	Gruppe 4	Gruppe 1 vs. Gruppe 4
x-Richtung	1.83	1.87	1.92	1.98	8.3 %
y-Richtung	0.35	0.34	0.35	0.35	1.4 %
z-Richtung	0.19	0.20	0.20	0.20	6.0 %
Durchschnitt					<b>12.9 %</b>

