

Prozessparallele Prognose der Werkstückqualität mithilfe von NC-internen Daten und maschinellem Lernen

Dissertation

zur Erlangung des Grades
des Doktors der Ingenieurwissenschaften
der Naturwissenschaftlich-Technischen Fakultät
der Universität des Saarlandes

von

Sebastian Schorr

Saarbrücken

2021

Tag des Kolloquiums: 27.07.2021
Dekan: Univ.-Prof. Dr. rer. nat. Jörn Walter
Berichterstatter: Univ.-Prof. Dr.-Ing. Dirk Bähre
Univ.-Prof. Dr. rer. nat. Andreas Schütze
Vorsitz: Univ.-Prof. Dr.-Ing. Matthias Nienhaus
Akad. Mitarbeiter: Dr.-Ing. Michael Schwarz

Kurzzusammenfassung

Methoden des maschinellen Lernens werden in dieser Arbeit eingesetzt, um die Qualitätsmerkmale von einer gebohrten und geriebenen Bohrung auf der Basis von NC-internen Fertigungsgrößen zu prognostizieren. Die Technologie maschinelles Lernen wird in der notwendigen Tiefe erläutert und ein Vorgehensmodell wird präsentiert, welches bei der Einführung von maschinellem Lernen in die Fertigung als Leitfaden dienen soll. Eine Kleinserienfertigung von Hydraulikventilen dient als Anwendungsfall, um das Vorgehensmodell zu detaillieren und eine hohe Praxistauglichkeit zu garantieren. In der Arbeit wird zudem das Vorgehen zur Definition des Ordnungsrahmens und des Zielzustandes als auch die Bestimmung der richtigen Fertigungsgrößen, der Merkmalsextraktions- und Merkmalsselektionsmethoden sowie der geeigneten Methoden des maschinellen Lernens erläutert. Eine detaillierte Betrachtung der Einflussgrößen: Datenquelle, Abtastfrequenz, Merkmalsgruppe und Trainingsdatensmenge wird vorgenommen. Letztendlich werden sehr genaue Prognoseergebnisse erzielt, die mittels zwei adaptierter Verfahren, welche ursprünglich aus dem maschinellen Lernen und dem Qualitätsmanagement stammen, validiert werden. Die bestimmten Parameterkonfigurationen werden genutzt, um eine Qualitätsprognose auf dem Shopfloor zu implementieren und somit eine deutliche Transparenzsteigerung über die aktuelle Fertigungsqualität zu erhalten. Final werden Lehrsätze formuliert, die die gewonnenen Erkenntnisse abstrakt zusammenfassen und somit die Möglichkeit eines Transfers auf weitere Fertigungsverfahren bieten sollen.

Abstract

In this thesis, the methods of machine learning are used to predict the quality characteristics of a drilled and reamed bore based on the NC-internal signals. The technology of machine learning is explained in the appropriate detail and a procedure model is presented, which is intended to serve as a guide for implementation of machine learning into production. A small series production of hydraulic valves serves as a use case in order to detail the procedure model and to guarantee a high level of applicability. The procedure for defining the framework and the target state is explained as well as the determination of the correct production parameters, the feature extraction and feature selection methods and the suitable methods of machine learning. A detailed consideration of the influencing variables: data source, sampling frequency, feature group and amount of training data is carried out. Very precise quality predictions are achieved and are validated using two adapted methods, which originally come from machine learning and quality management. The determined parameter configurations are used to implement a quality prediction on the shop floor and thus a significant increase in transparency about the current production quality is obtained. Finally, tenets are formulated that abstractly summarize the knowledge gained. Hence, the possibility is offered to transfer the quality prognosis, which was developed for drilling and reaming, to other manufacturing processes.

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als Doktorand bei der Bosch Rexroth AG an dem Fertigungsstandort Homburg (Saar) in Kooperation mit dem Lehrstuhl für Fertigungstechnik (LFT) der Universität des Saarlandes.

Ich danke Herrn Dr.-Ing. Matthias Möller dafür, mich als Doktorand bei der Bosch Rexroth AG beschäftigt zu haben und mir hierdurch die Möglichkeit gegeben zu haben meine Forschungsarbeit zu einer solchen zukunftsweisenden und innovativen Technologie wie dem maschinellen Lernen in einer laufenden Serienfertigung durchzuführen. Die eingeräumten Freiheiten, die erhaltene Unterstützung und das Mindset stets nach Innovationen zu streben, haben diese Arbeit erst ermöglicht.

Meinem Doktorvater Herrn Univ.-Prof. Dr.-Ing. Dirk Bähre danke ich vielmals für seine Bereitschaft, diese externe Promotion an seinem Lehrstuhl zu betreuen. Die regelmäßigen sachlichen Diskussionen, die fachliche Betreuung sowie die gewährte hohe Freiheit bei der Gestaltung der Forschung waren für den Erfolg der Arbeit von entscheidender Bedeutung.

Ich danke Herrn Univ.-Prof. Dr. Andreas Schütze für das Interesse an dieser Arbeit, die fachlichen Anregungen und die Übernahme des Zweitgutachtens.

Ein großer Dank geht auch an Herrn Jörg Heib für seine bedingungslose Unterstützung, den gelebten Optimismus, die gegebenen Ratschläge sowie die angenehme Zeit in seiner Gruppe der TEF1. Der interdisziplinäre Charakter dieses Forschungsthemas verlangte eine Zusammenarbeit mit den Fachabteilungen: Fertigungsprozessentwicklung, Fertigung, Qualitätsmanagement und industrielle IT. Von den Mitarbeitern dieser Abteilungen erhielt ich die notwendige Unterstützung, sodass ich mich bei diesen Kollegen für die professionelle und kollegiale Zusammenarbeit bedanken möchte. Hervorheben möchte ich die Zusammenarbeit mit Herrn Olaf König, welcher durch seinen Einsatz erst die vollautomatische Datenerfassung ermöglichte, sodass die Implementierung der Qualitätsprognose realisiert werden konnte.

In Erinnerung bleibt mir auch der freundliche Empfang und die positive Stimmung der Mitarbeiter des LFT. Bedanken möchte ich mich besonders bei Dr.-Ing. Sven Klein und Dr.-Ing. Shiqi Fang für die Zusammenarbeit und die geschlossene Freundschaft.

Den größten Dank richtet sich jedoch an meine Eltern Elisabeth und Helmut, die stets an mich geglaubt haben und mir meine akademische Ausbildung im In- und Ausland erst ermöglichten. Meinem Bruder Pascal danke ich für seine mit mir geteilten Erfahrungen zur wissenschaftlichen Praxis. Von ganzem Herzen danke ich meiner lieben Lebensgefährtin Anna für ihre Liebe, ihr Verständnis, ihre Geduld und für die intensive Durchsicht dieser Arbeit. Ich danke Euch für den Zuspruch, die Unterstützung und den Verzicht auf viel gemeinsame Zeit!

Lebenslauf

Persönliche Angaben

Name Sebastian Schorr
Geburtsdatum & -ort 18. Januar 1990 in Saarbrücken, Deutschland

Beruflicher Werdegang

Seit 02/2021 Ingenieur Fertigungsprozessentwicklung,
Bosch Rexroth AG, Homburg, Deutschland

02/2018-01/2021 Doktorand, Bosch Rexroth AG, Homburg / Lehrstuhl für
Fertigungstechnik der Universität des Saarlandes, Saar-
brücken, Deutschland

09/2016-11/2017 Studentische Hilfskraft, Fraunhofer-Institut für Produkti-
onstechnologie, Aachen, Deutschland

11/2014-06/2015 Studentische Hilfskraft, Forschungsinstitut für Rationalisie-
rung e. V., Aachen, Deutschland

09/2014-10/2014 Praktikant, Muhr und Bender KG, Žebrák, Tschechien

03/2014-09/2014 Praktikant, Daimler AG, Böblingen, Deutschland

07/2009-03/2010 Grundwehrdienst

Studium und Schulbildung

04/2015-11/2017 Master of Science, Wirtschaftsingenieurwesen mit Fach-
richtung Maschinenbau, RWTH Aachen, Deutschland

09/2015-07/2016 Master of Science in Engineering, Management Science
and Engineering, Tsinghua University, Peking, China
(Doppelmasterprogramm: RWTH Aachen - Tsinghua University)

09/2012-01/2013 Erasmus-Semester, Vilnius Gediminas Technical Universi-
ty, Vilnius, Litauen

10/2010-03/2015 Bachelor of Science, Wirtschaftsingenieurwesen mit Fach-
richtung Maschinenbau, RWTH Aachen, Deutschland

08/2006-06/2009 Abitur, Technisch-Wissenschaftliches Gymnasium, Dillin-
gen, Deutschland

08/2000-06/2006 Realschulabschluss, Erweiterte Realschule, Lebach,
Deutschland

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Formelzeichen und Abkürzungsverzeichnis	III
1 Einleitung	1
1.1 Ausgangssituation und Motivation	1
1.2 Zielsetzung der Arbeit	4
1.3 Aufbau der Arbeit	8
2 Grundlagen und Stand der Forschung und Technik	9
2.1 Zerspanung mit geometrisch bestimmten Schneiden	9
2.1.1 Bohren	10
2.1.2 Reiben	12
2.2 Qualitätsmanagement	14
2.2.1 Fertigungsmesstechnik	15
2.2.2 Eignungsnachweise von Mess- und Prüfprozessen	17
2.3 Datenerfassung und Datenaufbereitung	19
2.3.1 Datenquellen in der industriellen Fertigung	20
2.3.2 Datenerfassung mittels Steuerung und Sensorik der Werkzeugmaschine	21
2.3.3 Merkmalsextraktion	28
2.3.4 Merkmalsselektion	32
2.4 Maschinelles Lernen	34
2.4.1 Grundlagen des maschinellen Lernens	34
2.4.2 Methoden des maschinellen Lernens	36
2.4.3 Random Forest Regressor und Gradient Boosting Regressor	42
2.4.4 Lineare Diskriminanzanalyse	47
2.4.5 Verfahren der Prognosevalidierung	49
2.5 Vorstellung existierender Forschungsarbeiten	50
2.5.1 Integration von maschinellem Lernen in das Qualitätsmanagement	51
2.5.2 Einsatz von maschinellem Lernen zur Qualitätsprognose in der Zerspanung	52
3 Forschungshypothese und Konkretisierung der Forschungsfragen	57
4 Konzeption eines Vorgehensmodells zur Gestaltung einer prozessparallelen Qualitätsprognose	60
4.1 Die Systemtechnik als Basis für die Modellkonzeption	60
4.2 Vorgehensmodell zur Nutzung von Methoden des maschinellen Lernens zur prozessparallelen Qualitätsprognose	62
5 Detaillierung und Realisierung einer prozessparallelen Qualitätsprognose	68

5.1	Festlegung des Ordnungsrahmens und Definition des Zielzustandes	68
5.1.1	Beschreibung der Ventilkomponente und Festlegung des Ordnungsrahmens	68
5.1.2	Definition des Zielzustandes	72
5.2	Herausstellung von Wirkzusammenhängen mittels fertigungstechnischen Wissens	73
5.2.1	Einflussgrößen und Wirkzusammenhänge bei Bohr- und Reibprozessen	73
5.2.2	Festlegung der zu erfassenden Daten	75
5.2.3	Bestimmung der relevanten Abschnitte der erfassten Fertigungsdaten	77
5.2.4	Einfluss des Werkzeugverschleißes und der Gusscharge auf den Drehmomentverlauf.....	81
5.3	Datengewinnung, Datenspeicherung & Kontextualisierung.....	83
5.3.1	Erfassung der Fertigungsdaten	83
5.3.2	Erfassung der Qualitätsdaten.....	87
5.4	Merkmalsextraktion und Merkmalsselektion.....	89
5.4.1	Merkmalsextraktion	89
5.4.2	Lineare Diskriminanzanalyse zur Detektion von Anomalien.....	92
5.4.3	Merkmalsselektion	94
5.5	Einsatz der Methoden des maschinellen Lernens.....	100
5.5.1	Auswahl von geeigneten Methoden des maschinellen Lernens...	101
5.5.2	Einfluss der Datenquellen auf die Prognosegenauigkeit	107
5.5.3	Bestimmung der Abtastfrequenz und der Merkmalsgruppe	117
5.5.4	Bestimmung der notwendigen Trainingsdatenmenge	121
5.5.5	Übersicht über die ermittelten Parameterkombinationen	126
5.6	Validierung der Prognosegüte	127
5.6.1	Validierung mittels Kennzahlen	127
5.6.2	Herleitung und Adaption einer fertigungstechnischen Validierung	133
5.6.3	Durchführung der fertigungstechnischen Validierung.....	138
5.7	Implementierung in die Fertigung	145
5.7.1	Integration der Qualitätsprognose in die Qualitätsregelkreise	146
5.7.2	Implementierung auf dem Shopfloor bei der Bosch Rexroth AG..	148
6	Ableitung von ingenieurwissenschaftlichen Lehrsätzen	152
7	Zusammenfassung und Ausblick.....	158
7.1	Zusammenfassung.....	158
7.2	Ausblick.....	160
8	Literaturverzeichnis.....	162
Anhang	171

Formelzeichen und Abkürzungsverzeichnis

Symbol	Einheit	Bedeutung
$Ampl$		Minimum-zu-Maximum Amplitude
c		Index einer Klasse
C_g		potentieller Fähigkeitsindex
C_{gk}		kritischer Fähigkeitsindex
CF		Crest Faktor
D		Trainingsdatensatz
ENE		spektrale Energie
e_j		Eigenvektor
ε		Residuum
f		Fensterweite eines gleitenden Fensters
F_c	N	Schnittkraft
F_f	N	Vorschubkraft
F_p	N	Passivkraft
g		Anzahl von Klassen
GRR		Wiederhol- und Vergleichpräzision des Messprozesses
i		Index einer Größe (z. B. für: Werkstück, Signalwert)
l		Maximale Anzahl einer Größe
I_{ist}	A	momentaner Wert des Stroms durch eine Wicklung im feststehenden Teil eines Motors
$I(X, Y)$		Transinformationswert
k		Menge an Merkmalen
K		Anzahl der Teilmengen einer Kreuzvalidierung
$KuBP$		Wölbung der spektralen Leistung nach Welch
l_{ist}	mm	momentane Lage einer Achse
m		arithmetischer Mittelwert
m_q		quadratischer Mittelwert

M		Anzahl der berechneten Werte des Spektrums nach Welch
MAX		maximale auftretender Fehler
MAE		mittlerer absoluter Fehler
$MaxBP$		maximale spektrale Leistungsamplitude nach Welch
MBP		durchschnittliche spektrale Leistung nach Welch
MF		durchschnittliche spektrale Leistung
MSE		mittlerer quadrierter Fehler
n		Anzahl von einer Größe (z. B. Werkstücke, Signalwerte)
$n_x(i)$		Anzahl der Daten in der i-ten Gruppe der Variable X
n_{ist}	U/min	momentane Drehzahl
N		Anzahl der berechneten Werte eines Spektrums
ndc		Anzahl unterscheidbarer Klassen innerhalb der Streubreite der Messobjekte
P_i		Amplitudenwert des Spektrums nach Welch
$p(x,y)$		Verteilungsfunktion
$p(x)$		Dichte einer Inputgröße
$p_x(i)$		Dichte der i-ten Gruppe der Inputgröße x
$p(y)$		Dichte einer Zielgröße
$p_y(j)$		Dichte der j-ten Gruppe der Zielgröße y
PV		Teilestreuung
PKW		maximale spektrale Leistungsamplitude
r		Anzahl Wiederholmessungen
r_i		Residuum
\hat{r}_i		Prognosewert für eine Residuum
$r_{x,y}$		Pearson Korrelationswert
R^2		Bestimmtheitsmaß
s		Schiefe
s_g		Standardabweichung der Messwerte x_i
S		Untermenge von Trainingsdaten
$SkBP$		Schiefe der spektralen Leistung nach Welch

SS_b		Streuung zwischen Klassen
SS_w		Streuung innerhalb einer Klasse
std		Standardabweichung
T	mm	Toleranz (des zu messenden Merkmals)
T		Anzahl an Bäume
t		Anzahl der Trainingsdaten für die die Steigung der Lernkurve bestimmt wird
t_{ist}	°C	momentane Temperatur
U_{ist}	V	momentaner Wert der Spannung an einer Wicklung im feststehenden Teil eines Motors
v_j		Eigenwert
var		Varianz
VBP		Varianz der spektralen Leistung nach Welch
VB_{max}	mm	Verschleißmarkenbreite
w		Wölbung
x		Variable bzw. Inputgröße
x_i		Wert einer Inputgröße
x_m		Referenzwert
\bar{x}		Mittelwert
\bar{x}_g		Mittelwert der Messwerte x_i
y_i		Wert einer Zielgröße
\hat{y}_i		Prognosewert für eine Zielgröße
\bar{y}		Mittelwert aller berücksichtigten Zielgrößen
Y_i		Amplitudenwert eines Spektrums
$y(x)$		Allgemeine Funktion in Abhängigkeit der Variable x
%GRR	%	GRR bezogen auf eine Bezugsgröße (z. B. Toleranz)
%PV	%	Teilestreuung Bezogen auf eine Bezugsgröße
%RE	%	Auflösung des Messeinrichtung Bezogen auf eine Bezugsgröße

Abkürzung	Bedeutung
AIAG	Automotive Industry Action Group
Aufl.	Auflage
Aufs.	Aufsatznummer
BAZ	Bearbeitungszentrum
bzw.	beziehungsweise
ca.	circa
CNN	Convolutional Neural Network
CRISP-DM	Cross-industry standard process for data mining
DF	Diskriminanzfunktion
DIN	Deutsches Institut für Normung e.V.
EB	Entscheidungsbaums
ERP	Enterprise Resource Planning
ff.	folgend
FFT	Fast Fourier Transform
GBR	Gradient Boosting Regressor
GRR	Gage Repeatability and Reproducibility
GUM	Guide to expression of Uncertainty in Measurement
HMI	Human Machine Interface
HSK	Hohlschaftkegel
i.O.	in Ordnung
inkl.	inklusive
IPC	Industrial Personal Computer
ISO	International Organization for Standardization
IT	Informationstechnik
Jg.	Jahrgang
KDD	Knowledge discovery in databases
KNN	Künstliches Neuronales Netz
MES	Manufacturing Execution System
MSA	Measurement System Analysis
MSE	mittlere quadrierte Fehler

MTX	MachineToolX NC-Steuerung
n.i.O.	nicht in Ordnung
NC	Numerical Control
Nr.	Nummer
NTP	Net Time Protocol
OGW	oberer Grenzwert
OPC-UA	Open Platform Communications Unified Architecture
PC	Personal Computer
PCA	Principal Component Analysis
PCs	Principal Components
RFC	Random Forest Classifier
RFR	Random Forests Regressor
S.	Seite
SCADA	Supervisory Control and Data Acquisition
Sercos	Serial Realtime Communication System
SPC	Statistical Process Control
SPS	speicherprogrammierbare Steuerung
SVM	Support Vector Machine
SVR	Support Vector Regressor
TCP/IP	Transmission Control Protocol/Internet Protocol
TSFEL	Time Series Feature Extraction Library
tsfresh	Time Series FeatuRe Extraction on basis of Scalable Hypothesis tests
u.	und
u. a.	unter anderem
UGW	unterer Grenzwert
USA	United States of America
vgl.	vergleiche
XAI	Explainable Artificial Intelligence
z. B.	zum Beispiel

1 Einleitung

Künstliche Intelligenz – sowie maschinelles Lernen als ein Teilgebiet – sind aktuell in aller Munde [OETT18, S. 3] und stellen eine Technologie dar, die zu Effizienzsteigerung [JESC19, S. 3] und der Entwicklung neuer Geschäftsmodelle [ENNE19, S. 4] führt. Der erfolgreiche Einsatz von maschinellem Lernen ist in der Konsumentenwelt schon allgegenwärtig und springt nun auf die industrielle Fertigung über [OETT18, S. 3]. Befähigt wird dies durch die in den letzten Jahren stattfindende rasante Entwicklung von Cloud-Technologien und den Zugang zu performanter und preiswerter Rechenleistung sowie Datenspeicherung [WIEC20, S. 4; OETT18, S. 3]. Verstärkt wird der Trend der Anwendung des maschinellen Lernens durch breit verfügbare Open-Source-Software und Technologien, die die notwendigen Disziplinen einem breiten Anwenderkreis, auch außerhalb der Wissenschaft, zugänglich machen [OETT18, S. 3].

1.1 Ausgangssituation und Motivation

Die Herausforderungen, mit denen sich die fertigende Industrie konfrontiert sieht, sind vielfältig und immens. Sie entstehen durch eine zunehmende Produktkomplexität, die eine immer längere und komplexere Fertigungskette verursacht [SCHM20, S. 227]. Zudem kommt es zu einer Verkürzung der Produktlebenszyklen [BREC20, S. 187] und zu einer steigenden Produktvielfalt aufgrund einer vom Kunden geforderten Individualisierung der Produkte, welche die bisherigen Skaleneffekte einer Massenfertigung zunichtemachen [NGO16, S. 498; BREC20, S. 187–188]. Erhöht wird der Druck zusätzlich durch die von der Gesellschaft und der Politik geforderte Reduzierung des Ressourcenverbrauchs und durch die verschärften Nachhaltigkeitsanforderungen [SCHM20, S. 228; WELC20, S. 3]. Die Lösung dieser Herausforderungen wird in der Digitalisierung [SCHM20, S. 228] und der Vernetzung [BREC20, S. 187] der Fertigung sowie in der Anwendung von künstlicher Intelligenz bzw. maschinellem Lernen zur Informationsgenerierung aus den erzeugten Daten gesehen [WILL20, S. 22]. Um die Herausforderungen zu bewältigen, gilt es, das Potenzial dieser Technologien zu nutzen [WELC20, S. 3]. Diese Notwendigkeit des Handelns und der Entwicklung sehen auch die von BITKOM RESEARCH befragten 552 Industrieunternehmen [BERG20]. Die Digitalisierung wird von 93 % der Befragten als Chance gesehen und als Voraussetzung für den Erhalt der Wettbewerbsfähigkeit. Mit Problemen bei der Umsetzung der Digitalisierung sehen sich jedoch 31 % der Unternehmen konfrontiert und 89 % stellen fest, dass interdisziplinäre Kompetenzen zur Vernetzung von Fabriken notwendig sind. Obwohl mehr als die Hälfte der Unternehmen davon ausgeht, dass künstliche Intelligenz ihr Geschäftsmodell tiefgreifend verändern wird, setzt erst jedes siebte Unternehmen (14 %) künstliche Intelligenz in der eigenen Fertigung ein. Es wird erwartet, dass ein Drittel des bis 2023 aufkommenden Wachstums im produzierenden Gewerbe durch den Einsatz von künstlicher Intelligenz hervorgerufen wird, was einer Bruttowertschöpfung von 31,8 Milliarden Euro entspricht [WIEC20, S. 4]. Die Bundesregierung hat erkannt, dass von der künstlichen Intelligenz zusätzliches

Wirtschaftswachstum sowie Produktivitätssteigerungen zu erwarten sind und dass sie eine Schlüsseltechnologie für die Zukunft darstellt. Um dieses Potenzial zu heben und international auf dem Gebiet der künstlichen Intelligenz führend zu sein, hat die Bundesregierung die „Strategie Künstliche Intelligenz“ (KI-Strategie) herausgegeben und fördert bis vorerst 2025 die KI-Forschung, den Aufbau von KI-Ökosystemen sowie die KI-Anwendung mit fünf Milliarden Euro [BUND20]. Die von der Bundesregierung für künstliche Intelligenz bereitgestellten Mittel sollten für die fertigende Industrie eine Chance und einen Ansporn darstellen, diese Technologie aktiv mitzugestalten.

Die stetige Integration von Sensoren in die Fertigung zur Zustandskontrolle, Steuerung oder Automatisierung von Anlagen generiert eine Datenbasis, welche mithilfe des maschinellen Lernen zusätzlich ausgewertet werden kann. Der hierdurch zusätzlich generierte Nutzen kann den initialen Nutzen bzw. Grund der Sensorintegration übertreffen. [ENNE19, S. 5] Das Ziel ist die Realisierung der in den Daten steckenden Potenziale [SCHM20, S. 247]. Die Sensorintegration ermöglicht einen Fertigungsprozess hinsichtlich der Zielgrößen: Qualität, Produktivität und Verfügbarkeit (siehe Abbildung 1-1) [BREC20, S. 189], auf einem Niveau zu betreiben, dass die bisherigen Anforderungen erfüllt.

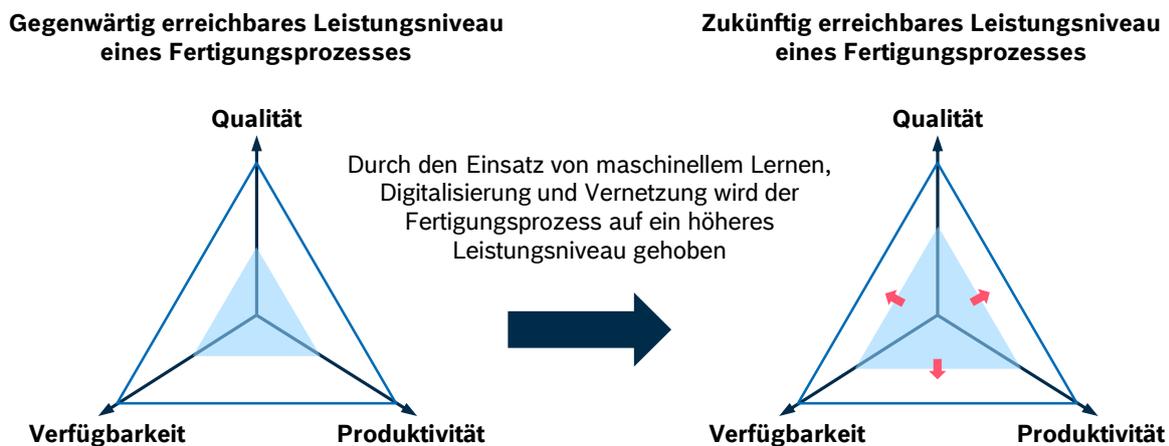


Abbildung 1-1: Darstellung des erreichbaren Leistungsniveaus im Vergleich zur Leistungsgrenze eines Fertigungsprozesses in Abhängigkeit von den eingesetzten Technologien [BREC20, S. 189]

Aufgrund von fehlender Prozesstransparenz, langen Regelzyklen und unbekanntem Ursachen-Wirkungs-Zusammenhängen ist es nicht möglich, mit der eingesetzten Technologie über das erreichte Niveau hinauszukommen und aus diesem Grund den Fertigungsprozess auch nicht an der maximalen Leistungsgrenze zu betreiben. Die erwähnten Herausforderungen, mit denen sich die fertigenden Betriebe konfrontiert sehen, verlangen jedoch nun nach einer Steigerung des Leistungsniveaus und der Beherrschung der Prozesse in der Nähe der Leistungsgrenze. Die Prozesse zu dem neuen Leistungsniveau zu führen und dort zu betreiben, verlangt nach einer zuverlässigen Verhaltensvorhersage, indem komplexe Ursachen-Wirkungs-Zusammenhänge durchdrungen werden. In diesem Punkt kommt das maschinelle

Lernen zum Zug, welches auf der bestehenden Technologie und Datenbasis aufsetzt und durch das Erkennen von komplexen Zusammenhängen Handlungsempfehlungen ausgibt, die zu einem höheren Leistungsniveau führen. [BREC20, S. 188–189; KRAU19, S. 493]

Zur Auslegung der Leistungsgrenze eines Prozesses werden bisweilen hauptsächlich sogenannte White-Box-Modelle eingesetzt. Diese entstehen durch das Formulieren von bekannten physikalischen Ursachen-Wirkungs-Zusammenhängen in sogenannten Modellformulierungen (z. B. Gleichungen und Bedingungen) [BREC20, S. 188–190]. Neben der Abbildung der Ursachen-Wirkungs-Zusammenhängen besteht die Herausforderung zusätzlich in der Bestimmung von richtigen Modellparametern, um die Zielgröße mit der geforderten Genauigkeit zu prognostizieren. Die Bestimmung der Modellparameter ist mit einem hohen Aufwand verbunden, da oftmals Versuche mit zugehöriger Datenerfassung notwendig sind. Das formulierte Modell gilt zudem nur für einen konkret definierten Fertigungszustand, für den die Modellparameter bestimmt wurden, und benötigt für eine Live-Prognose auch die aktuellen Fertigungsdaten. Demgegenüber bietet das maschinelle Lernen sogenannte Black-Box-Modelle, welche die Ursachen-Wirkungs-Zusammenhänge selbstständig aus einer Datenbasis erlernen und hierdurch auch Abhängigkeiten abbilden, die von dem Menschen aufgrund der Komplexität kaum gänzlich beschrieben werden können. [BREC20, S. 188–190] Das Lernen der Zusammenhänge erfolgt durch das Training des Modells mit Fertigungsdaten, welche nach der Modellerstellung für die Live-Prognose ebenfalls erfasst werden. Das Einbringen von domänenspezifischem Wissen ist bei beiden Modellklassen auf unterschiedliche Weise möglich und führt zu einer Prognoseverbesserung, jedoch ist es bei den Black-Box Modellen nicht zwingend erforderlich. Dahingegen ist ein gewisses Verständnis der Funktionsweise der vielen verschiedenen Black-Box-Modelle des maschinellen Lernens für eine erfolgreiche Anwendung notwendig.

Der Fokus dieser Arbeit liegt auf der Prognose der Werkstückqualität, um die Fertigung hinsichtlich Qualität, Produktivität und Ressourcenverbrauch auf ein höheres Leistungsniveau zu bringen. Durch die Qualitätsprognose bekommt der Anwender, die Möglichkeit auf Basis einer datengetriebenen Vorhersage zu handeln und somit frühzeitig auf qualitätsbeeinflussende Ereignisse zu reagieren [SCHM20, S. 228]. Mit dem Aufkommen der Qualitätsprognose beginnt eine Weiterentwicklung des Qualitätsmanagements, bei der die bestehenden Methoden nicht zwangsläufig ersetzt, sondern um die Prognose ergänzt werden [SCHM20, S. 227 u. 231]. Dies erschließt sich auch aus der Natur des Qualitätsmanagements, bei dem nahezu alle Entscheidungen auf umfassender Datenerfassung und -analyse beruhen [SCHM20, S. 232]. Der Erfolg einer derartigen Ergänzung ist von der Datenqualität und -menge, von der technischen Infrastruktur hinsichtlich Datenerfassung und -analyse sowie von der Expertise der involvierten Domänen abhängig [SCHM20, S. 248].

Die Entwicklung einer derartigen Qualitätsprognose soll in der Form eines Prototyps für das Bohren und Reiben von Bohrungen in Hydraulikventile der Bosch Rexroth AG am Standort Homburg (Saar) erfolgen. Die Bosch Rexroth AG ist ein global agieren-

des deutschen Industrieunternehmens, das sich auf die Entwicklung und Herstellung von Antriebs- und Steuerungstechnik für den internationalen Maschinen- und Anlagenbau spezialisiert hat. Das Produktspektrum umfasst elektrische Antriebe und Steuerungen, Industrie- und Mobilhydraulik, Linear- und Montagetechnik sowie Servicedienstleistungen. Die Produkte der bedienten Branchen sind charakterisiert durch Vielfältigkeit und hohe Individualisierung, was sich bei Bosch Rexroth in einer hohen Produktvarianz bei einer gleichzeitigen kleinen bis moderaten Losgrößenfertigung sowie einer langen Ersatzteilverfügbarkeit äußert. Die in Homburg angesiedelte Herstellung von Hydraulikventilen kann mit einer Kleinserienfertigung verglichen werden. Aufgrund der Hochautomatisierung von Handling und Zerspanung ist ein Zustand erreicht worden, welcher die Integration von neuen Technologien verlangt, um eine weitere und bedeutsame Effizienzsteigerung zu erzielen. Die dritte industrielle Revolution, geprägt durch Automatisierung, Serienfertigung und IT-Integration [VOGE17, S. 2], kann für die betrachtete Fertigung als weitestgehend vollendet angesehen werden. Die Fertigung wird an dem Limit des beherrschbaren Leistungsniveaus betrieben, sodass nun die Technologien (u. a. maschinelles Lernen, Digitalisierung, Vernetzung) der nächsten industriellen Evolutionsstufe zum Einsatz kommen müssen, um das Leistungsniveau zu steigern und in die Nähe der Leistungsgrenze zu bringen (siehe Abbildung 1-1). Wie es zu der Verschiebung des Leistungsniveaus kommen kann, wird in dem folgenden Kapitel vorgestellt und als Ziel dieser Arbeit ausgewiesen.

1.2 Zielsetzung der Arbeit

Die anfänglich erwähnten Herausforderungen, mit denen sich die fertigende Industrie konfrontiert sieht, sind auch bei der betrachteten Fertigung allgegenwärtig. Die Produktvarianten steigen aufgrund einer kundenindividuellen Fertigung stark an, was zu einer höheren Fertigungsvarianz mit kleineren Losgrößen und häufigerem Umrüsten führt. Um die Vorteile einer statistischen Prozesslenkung (SPC) für die Qualitätssicherung nutzen zu können, ist die Fertigung einer gleichbleibenden Produktvariante über einen gewissen Zeitraum notwendig. Wird hingegen eine Vielzahl von Varianten gefertigt, steigt auch die Anzahl der zu leistenden Qualitätsmessungen mit industrieller Messtechnik stark an, was zu einem Kostenanstieg führt. Wird über einen längeren Zeitraum die gleiche Produktvariante gefertigt, so greifen zwar die Vorteile der SPC, jedoch befindet sich die Fertigung zwischen zwei Stichproben, in einer Art „Blindflug“ hinsichtlich der gefertigten Werkstückqualität. Um diese Problematik zu lösen und die Kosten für die Werkstückmessung, welche eine nicht werterzeugende Tätigkeit darstellt, nicht in die Höhe steigen zu lassen, wird der Einsatz von maschinellem Lernen zur Prognose der Werkstückqualität angestrebt und als Ziel dieser Arbeit ausgegeben.

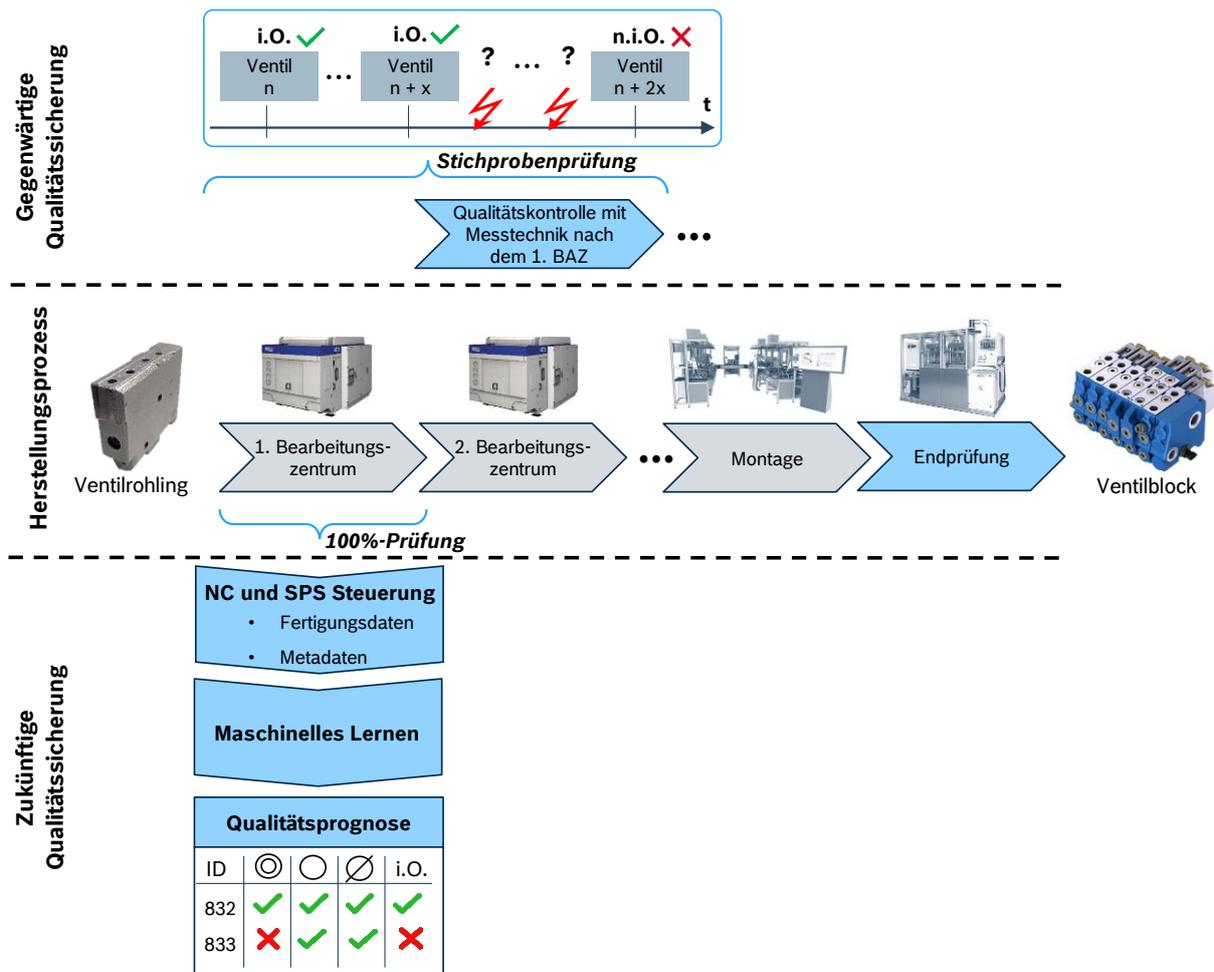


Abbildung 1-2: Herstellungsprozess eines Ventils mit gegenwärtiger sowie zukünftiger Qualitätssicherung (Bildquellen: [GROB20; BOSCH21])

In der Mitte von Abbildung 1-2 ist der Herstellungsprozess eines Ventils dargestellt. Dieser beginnt mit der spanenden Bearbeitung eines vorgegossenen Ventilrohlings auf mehreren Bearbeitungszentren und mit verschiedenen Fertigungsverfahren. Ist die spanende Bearbeitung abgeschlossen, erfolgt die Montage sowie die Kalibrierung des Ventils. Als letzter Schritt durchläuft jedes Ventil eine Funktions- und Endprüfung. Im gegenwärtigen Zustand besteht die Qualitätssicherung der spanenden Bearbeitung durch die Entnahme von Werkstücken (Stichproben) und der Vermessung der Qualitätsmerkmale eines Ventils mit industrieller Messtechnik. Die Entnahme erfolgt hierfür zu definierten Zeitpunkten oder nach dem Eintreten von bestimmten Ereignissen (z. B. Werkzeugwechsel, Umrüsten, Wechsel Produktvariante). Der Vorteil dieses Vorgehens liegt in den sehr genauen und verlässlichen Messwerten, die auf diese Weise erzielt werden. Solange die Qualitätsmerkmale von zwei Stichproben innerhalb der Toleranz liegen, so kann davon ausgegangen werden, dass auch die dazwischenliegenden Ventile mit einer hohen Wahrscheinlichkeit i.O. (in Ordnung) sind. Der Nachteil besteht jedoch darin, dass zwischen der Fertigung eines Ventils und der Kenntnis der zugehörigen Qualitätsmessungen eine, unter Umständen hohe, Latenzzeit liegt. Während dieser Zeitspanne kann ein Produktionslos bereits die nächsten Fertigungsschritte durchlaufen, obwohl eventuell ein Qualitäts-

merkmal sich außerhalb der Toleranz befindet, welches durch einen vorherigen Fertigungsschritt erzeugt wurde. Ebenso ist in einem solchen Fall nicht bekannt, wann seit der letzten Stichprobe die Toleranzüberschreitung zum ersten Mal aufgetreten ist. Folglich ist auch nicht die Anzahl der betroffenen Ventile bekannt. In einer solchen Situation lassen sich die n.i.O. (nicht in Ordnung) Ventile nur mittels einer 100%-Prüfung detektieren, entweder durch den Einsatz von Messtechnik oder durch die Endprüfung. Der Aufwand und die Ressourcen, die in die Fertigung von n.i.O. Ventilen eingeflossen sind, werden als verloren angesehen und beeinflussen negativ die finanzielle und ökologische Bilanz des Unternehmens. Mit der bisherigen Anzahl der zu fertigenden Ventilvarianten befand sich die Gleichung aus Stichprobenanzahl, Messmittelverfügbarkeit, Latenzzeit, Bearbeitungskosten und Fehlerkosten in ihrem wirtschaftlichen sowie ökologischen Optimum und das erreichbare Leistungsniveau mit der eingesetzten Technologie wurde erreicht. Für den nun eintretenden Anstieg der zu fertigenden Ventilvarianten kann das Dilemma nur gelöst werden, indem die Transparenz über den Fertigungsprozess erhöht wird und die Regelzyklen verkürzt werden. Dies ist bei dem Einsatz der gegenwertigen Technologie nur dadurch möglich, indem die Stichprobenanzahl erhöht wird, was sich in erheblichen Mehrinvestitionen für Messmittel und Personal äußert. Anzustreben ist hingegen eine möglichst kostenneutrale Erreichung der notwendigen Transparenzsteigerung zur Qualitätssicherung. Dies lässt sich nur erreichen, indem auf die veränderten Bedingungen mit anderweitigen Lösungsansätzen und Technologien geantwortet wird.

Die Lösung wird in der Nutzung von verfügbaren Fertigungsdaten und dem Einsatz von maschinellem Lernen für die Prognoseerstellung gesehen. Das Ziel besteht darin, die Prognosen auf die in einem Bearbeitungszentrum bereits existierenden Daten zu stützen und auf eine zusätzliche Sensorintegration zu verzichten. Ein Bearbeitungszentrum verfügt standardmäßig über eine Vielzahl von Sensoren, welche für die Regelung und Steuerung sowie für das Monitoring notwendig sind. Diese Sensoren ermöglichen eine Erfassung der Fertigungsbedingungen während der Bearbeitung, welche Rückschlüsse auf die Werkstückqualität zulassen können. Die Ursachen-Wirkungs-Beziehungen zwischen Fertigungsdaten und Werkstückqualität sollen mittels der Methoden des maschinellen Lernens selbstständig erlernt werden. Nach der Trainingsphase sollen die Methoden automatisiert, in Echtzeit¹ und prozessparallel die Qualität eines jeden Ventils prognostizieren. Die Einführung einer derartigen Qualitätsprognose würde den Ort der Fehlerdetektion in den Prozessschritt legen, welcher den Fehler verursacht bzw. wo der Fehler entsteht. Hierdurch würde die Latenzzeit verschwinden, sodass schneller auf Qualitätsabweichungen reagiert werden könnte, was die Qualität, die Produktivität, die Fehlerkosten und den Ressourcenverbrauch positiv beeinflussen würde. Die gesteigerte Transparenz ermöglichte somit die Beherrschung des Fertigungsprozesses auf einem höheren Leistungsniveau.

¹ Echtzeit definiert eine individuell festgelegte Zeitspanne, in der ein permanent betriebsbereites Rechensystem die geforderte Datenverarbeitung bzw. Ergebnisse liefern muss. [DIN88; DUDE21]

Mit der Anwendung von maschinellem Lernen würde ein Paradigmenwechsel in der Qualitätskontrolle vollzogen, indem eine bisherige dem Fertigungsschritt nachgelagerte und zur Fertigungskette horizontal verlaufende sowie mit hauptsächlich direkten Messmitteln durchgeführte Qualitätsmessung durch eine in den Fertigungsschritt integrierte und somit zeitlich parallel (vertikal) verlaufende sowie auf selbstlernende Methoden beruhende Qualitätsprognose ergänzt, eventuell teilweise ersetzt würde. Zudem würde die Stichprobenprüfung kosten- und zeitneutral zu einer 100%-Prüfung erweitert werden.

Ziel der Arbeit ist für das Bohren und Reiben von Bohrungen eine prozessparallele Qualitätsprognose basierend auf maschineninternen (NC-interne) Daten und den Methoden des maschinellen Lernens zu erforschen und zu initiieren. Fragen, die hierdurch beantwortet werden sollen, sind z. B.:

- Welches Fachwissen ist für die erfolgreiche Anwendung der Technologie notwendig?
- Welche Methoden des maschinellen Lernens sind für den Anwendungsfall passend?
- Wie ist die Herangehensweise für die Nutzung und die Implementierung der Technologie?
- Welche Fertigungsdaten müssen erfasst werden und mit welcher Abtastfrequenz?
- Welche Prognosegenauigkeit und -zuverlässigkeit erzielt eine derartige Qualitätsprognose?

Aufgrund der Komplexität und der Vielfältigkeit der möglichen Einsatzszenarien existiert keine universelle Lösung zur Umsetzung von maschinellem Lernen in der fertigen Industrie, sondern lediglich der Hinweis, sich mit einem klar definierten Pilotprojekt der Thematik zu nähern [KOLL18, S. 10; ENNE19, S. 4]. Zudem ist eine allgemeine Quantifizierung des Nutzens nicht möglich, da dieser sehr kontextspezifisch von dem Anwendungsfall abhängt [SCHM20, S. 232]. Dies führt dazu, dass Unternehmen das Kosten-Nutzen-Verhältnis nicht einschätzen können [REIM18, S. 27]. Zudem fehlen Fachwissen und Erfahrungen für die Einführung und Nutzung von maschinellem Lernen in der Fertigung [REIM18, S. 27]. Dies führt dazu, dass Unternehmen die ersten Projekte zu groß und komplex gestalten [KOLL18, S. 10]. Die Folge ist, dass sie mit der Menge an auftretenden Fragen und Herausforderungen nicht zurechtkommen und das Interesse an der Technologie verlieren [KOLL18, S. 11]. Aus diesem Grund soll ein Vorgehensmodell entwickelt werden, welches dem Fertigungsingenieur das maschinelle Lernen näherbringt und ihn bei der Integration in die Fertigung unterstützt. Anhand der Fertigungstechnologien Bohren und Reiben und der Qualitätsmerkmalen Durchmesser, Konzentrität, Geradheit und Rundheit wird dann das Vorgehensmodell detailliert und ein Praxisbezug hergestellt. Das finale Ziel besteht schließlich darin, die durch die Detaillierung gewonnenen Erkenntnisse in sogenannte Lehrsätze zu überführen. Die Lehrsätze verfügen über einen gewissen Grad an Abstraktheit und sollen hierdurch den Transfer der Erkenntnisse so-

wie die Implementierung einer Qualitätsprognose auf weitere Fertigungsverfahren und Qualitätsmerkmale ermöglichen.

1.3 Aufbau der Arbeit

In dem ersten Kapitel wird die Ausgangssituation und die Herausforderungen der fertigen Industrie beschrieben, aus denen sich die Zielsetzung der Arbeit zur Entwicklung einer prozessparallelen Qualitätsprognose mittels maschineninterner Daten und Methoden des maschinellen Lernens ergibt. Das zweite Kapitel widmet sich den für die Arbeit relevanten Grundlagen. Diese sind sehr vielfältig aufgrund der interdisziplinären Thematik. Aus dem Bereich der Fertigungstechnik werden die Eigenschaften der Fertigungstechnologien Bohren und Reiben erläutert. Zudem wird die Fertigungsmesstechnik sowie die zugehörigen Methoden zum Nachweisen der Messmittelfähigkeit beschrieben. Daten nehmen eine Schlüsselstellung bei dem maschinellen Lernen ein, sodass mögliche Datenquellen und Datenerfassungsmöglichkeiten in der industriellen Fertigung aufgezeigt sowie verschiedene Datenaufbereitungsmethoden vorgestellt werden. Neben den Daten sind die Methoden des maschinellen Lernens ein Kernthema dieser Arbeit, weshalb eine detaillierte Beschreibung der Grundidee und der Funktionsweise dieser Methoden erfolgt. Der Fokus liegt hierbei auf den für diese Arbeit relevanten Methoden. Die präsentierten Forschungsarbeiten geben den Stand der Forschung zu der Qualitätsprognose mittels maschinellen Lernens in der Fertigungstechnik wieder. Auf der Basis dieses Forschungsstandes ergibt sich die aufgestellte Forschungshypothese sowie die Forschungsfragen für diese Arbeit, welche in dem dritten Kapitel verfasst sind. Angelehnt an diese Fragen wird im vierten Kapitel schließlich ein Vorgehensmodell konzipiert, welches bei der Erzielung einer Qualitätsprognose und der Beantwortung der Fragen unterstützen soll. Das Vorgehensmodell setzt sich aus insgesamt sieben Stufen sowie aus der Ableitung von Lehrsätzen zusammen. Die Detaillierung einer jeden Stufe des Vorgehensmodells erfolgt in dem fünften Kapitel anhand eines Anwendungsfalls und der iterativen Bestimmung der besten Lösung sowie Technologie zu einer jeden Stufe. Die gewonnenen Erkenntnisse bei der Detaillierung der Stufen werden in dem sechsten Kapitel in Lehrsätze überführt sowie zusammengefasst und können als abstrakte Antworten auf die Forschungsfragen verstanden werden. Das abschließende siebte Kapitel liefert eine Zusammenfassung der Arbeit und skizziert weiteres Forschungs- und Anwendungspotential für maschinelles Lernen in der Fertigung.

2 Grundlagen und Stand der Forschung und Technik

Die Thematik dieser Arbeit bedarf dem Zusammenwirken von verschiedenen Themenfeldern. Um ein erfolgreiches Ineinandergreifen der Themenfelder zu initiieren ist ein Verständnis der involvierten Technologien, Strukturen und Funktionsprinzipien notwendig. In diesem Kapitel werden die benötigten Themenfelder aufgegriffen und in der für diese Arbeit notwendigen Tiefe beschrieben. Zudem wird der aktuelle Forschungsstand zur Qualitätsprognose mittels maschinellen Lernens vorgestellt und hieraus die Forschungsfragen abgeleitet.

2.1 Zerspanung mit geometrisch bestimmten Schneiden

Fertigungsverfahren, die zur Schaffung eines Werkstücks den Zusammenhalt des Werkstückmaterials aufheben, werden der 3. Hauptgruppe (Trennen) der DIN 8580 zugeordnet [DIN 03b]. Erfolgt das Trennen durch das Abtragen des Werkstückmaterials mittels eines Werkzeuges in der Form von Spänen, so wird zudem zwischen dem Spanen mit geometrisch bestimmter und geometrisch unbestimmter Schneide unterschieden. Die in dieser Arbeit betrachteten Fertigungsverfahren Bohren und Reiben fallen in die Gruppe der Fertigungsverfahren mit geometrisch bestimmten Schneiden.

Die durch Bohren und Reiben erzeugte Bohrung muss definierte Qualitätsanforderungen erfüllen. Die Qualität der Bohrung wird demnach bestimmt anhand der Maß- und Formgenauigkeit der Bohrung, der Oberflächenbeschaffenheit der Bohrungswand sowie in bestimmten Fällen zudem durch die Materialstruktur des Werkstoffes in Bohrungswandnähe. Die Maßgenauigkeit umfasst zumeist den Durchmesser der Bohrung, kann jedoch auch die Länge sowie die Position der Bohrung beinhalten. Bei der Formgenauigkeit werden zumeist die Rundheit, die Zylinderform sowie die Geradheit der Bohrung toleriert. Bezüglich der Anforderungen an die Oberfläche der Bohrung wird die Oberflächenrauheit und die Welligkeit als Qualitätsmerkmale herangezogen. Die Materialstruktur wird oftmals nur bei sicherheitskritischen Bauteilen überwacht und teilt sich auf in die Härte, die Eigenspannungen und die Gefügestruktur des Werkstoffes in unmittelbarer Nähe zur Bohrung.

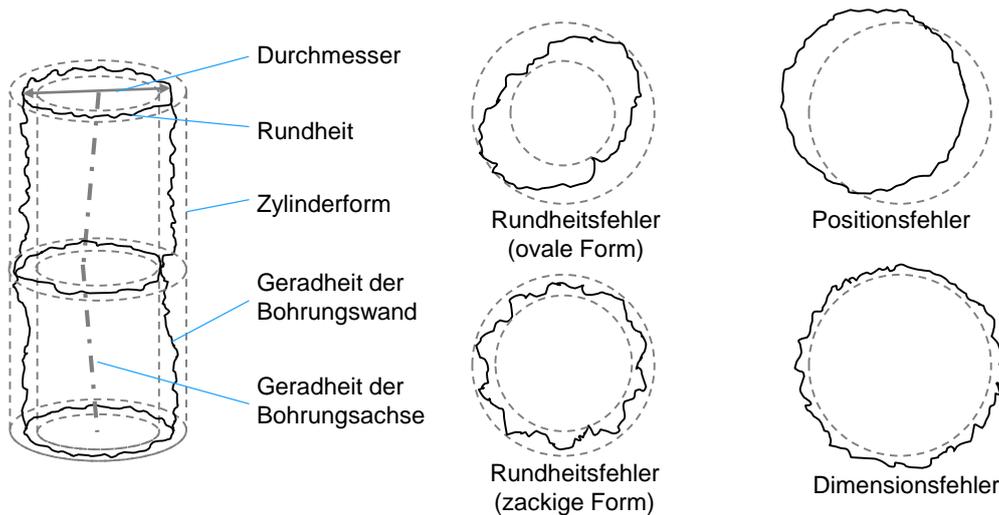


Abbildung 2-1: Geometrie einer Bohrung (Maß-, Form- und Lageabweichungen)

In Abbildung 2-1 sind typische Maß-, Form- und Lageabweichungen einer Bohrung aufgezeigt. In den folgenden Unterkapiteln wird im Detail auf das Bohren und Reiben mit geometrisch bestimmter Schneide eingegangen und Ursachen für auftretende Qualitätsabweichungen aufgeführt sowie Fertigungsgrößen bestimmt, mit denen die Qualitätsabweichungen detektiert werden können.

2.1.1 Bohren

Unter Bohren wird ein spanendes Verfahren verstanden, bei dem ein Werkzeug eine rotatorische Schnittbewegung entlang der Vorschubachse erfährt, welche koaxial mit der erzeugten kreiszylindrischen Innenfläche des Werkstückes ist [DIN 03a]. Das Bohren ist charakterisiert durch eine von der Bohrerwand bis hin zur Bohrermitte auf null absinkende Schnittgeschwindigkeit. Des Weiteren unterliegen die Schneidecken einem erhöhten Verschleiß und während des Bohrvorgangs tritt eine Reibung zwischen den Führungsfasen des Bohrers und der Bohrungswand auf. [KLOC18, S. 566] Zum Abtransport der entstehenden Späne, zur Wärmeabfuhr an der Wirkstelle und zur Reduzierung des Reibwiderstandes ist oftmals der Einsatz eines Kühlschmierstoffes notwendig. Der Bohrprozess gliedert sich in eine Phase, in der der Bohrer in das Werkstück eindringt, gefolgt von einer Phase, die den eigentlichen Bohrprozess (positiver Vorschub) umfasst, und einer letzten Phase, bei der der Bohrer aus der Bohrung zurückgezogen wird.

In der DIN 8589-2 sind die verschiedenen Verfahrens- und Werkzeugvarianten des Bohrens aufgeführt. Die größte Bedeutung kommt dem Wendelbohrer zu, dessen Anteil an der spanenden Fertigung auf 20–25 % geschätzt wird [KLOC18, S. 568]. Wendelbohrer werden zum Bohren ins Volle oder zum Aufbohren von einer bereits vorgebohrten oder gegossenen Bohrung verwendet. Ein Bohrer setzt sich grundsätzlich aus dem Schaft und dem Schneidteil zusammen. Um die Anforderungen hinsichtlich der zu erreichenden Bohrungsqualität und der Zerspanungsleistung zu er-

reichen, existieren diverse geometrische Gestaltungsformen des Bohrers, unzählige Anschliffarten der Bohrspitze sowie zahlreiche werkstoff- und beschichtungsspezifische Bohrerprofile [KLOC18, S. 568].

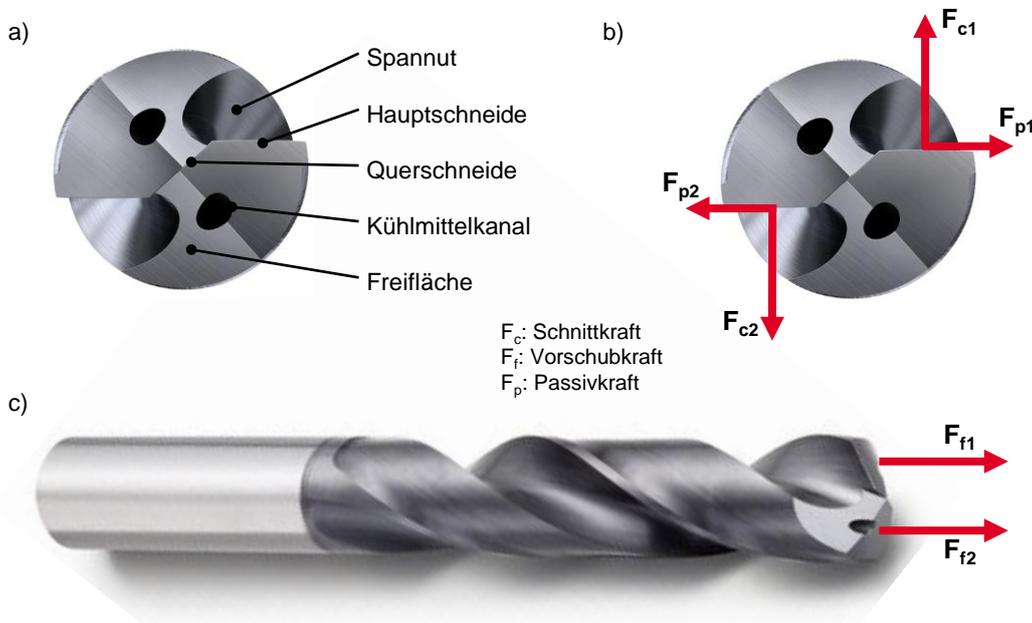


Abbildung 2-2: a) Bohrspitze eines Wendelbohrers, c) Wendelbohrer in Längsansicht, b) & c) Kräfte an der Bohrspitze (Bildquelle: [SAND20])

Die Symmetrie des Bohrspitzenanschliffes beeinflusst die Verteilung der radial wirkenden Passivkräfte an der Bohrspitze, was sich auf die Selbstzentrierung des Bohrers und die hiermit verbundene Form- und Maßgenauigkeit auswirkt [KLOC18, S. 572 u. 575]. Die Oberflächengüte der Bohrungswand wird hingegen nur unwesentlich durch den Anschliff beeinflusst [KLOC18, S. 575]. Ungleichmäßig hohe Passivkräfte verursachen eine Biegung des Bohrers beim Bohren und eine Vergrößerung des Bohrungsdurchmessers. Ungleichmäßige Passivkräfte können neben einem fehlerhaften Bohrspitzenanschliff zudem durch Rundlauffehler und durch ungleichmäßig scharfe Schneiden aufgrund von Verschleiß verursacht werden [DROZ83, S. 9.2; KLOC18, S. 575]. Eine Reduzierung des Bohrungsdurchmessers wird durch den Verschleiß an den Schneidecken und den Führungsphasen hervorgerufen. Grundsätzlich wird durch den Verschleiß an Schneidenecken der Hauptschneiden und Führungsphasen die Maß- und Formgenauigkeit der Bohrung maßgeblich beeinflusst [KLOC18, S. 575]. Der Verschleiß der Schneidecken und Schneidkanten äußert sich durch einen Anstieg des Schnittmoments, wohingegen ein Verschleiß der Querschneide einen Anstieg der Vorschubkraft zur Folge hat [VESE12, S. 79 u. 82]. Die Art und der Fortschritt des Verschleißes lässt sich sehr valide über die Stromaufnahme von Spindel und Vorschubachse bestimmen [VESE12, S. 79 u. 82]. Untersuchungen haben gezeigt, dass der Spindelstrom mit dem Werkzeugverschleiß (VB_{max} : Verschleißmarkenbreite) degressiv ansteigt, und dass eine Bestimmung des Ver-

schleißes mittels der Erfassung von Schwingungen hingegen wenig aussagefähig ist [VESE12, S. 86]. Zudem wurde eine Pearson-Korrelation von 0,96 zwischen dem Werkzeugverschleiß (VB_{max}) und dem Drehmoment der Spindel bestimmt [VESE12, S. 88].

Für einen Wendelbohrer verteilt sich das aufgebrachte Drehmoment der Spindel zu 65–75 % auf die Hauptschneide, zu 15–20 % auf die Führungsfasen und zu 10–14 % auf die Querschneide. Für die Vorschubkraft ergibt sich eine umgekehrte Verteilung, hier fällt der größte Anteil mit 65–75 % auf die Querschneide, gefolgt von der Hauptschneide mit 17–25 % und der Führungsfasen mit 7–8 %. [KLOC18, S. 577]

2.1.2 Reiben

Reiben wird zur Präzisionsbearbeitung von Bohrungen eingesetzt und ist nach DIN 8589-2 das Aufbohren von Bohrungen mit geringer Spannungsdicke, um kreiszylindrische Innenflächen mit hoher Maß-, Form- und Oberflächengüte zu erzielen [DIN 03a]. Es ist meist der letzte Schritt in einer Bearbeitungsfolge einer Bohrung und erzeugt die finale Qualität einer Bohrung hinsichtlich Oberflächenrauheit, Durchmesser und Form [BRET18, S. 267; KLOC18, S. 587]. Die Position einer Bohrung wird durch das Reiben hingegen nicht mehr beeinflusst [KOPP08, S. 4] und die Bohrung sollte grundsätzlich schon eine gute Rundheit und Geradheit aufweisen [DROZ83, S. 9.107]. Die für das Reiben von Bohrungen eingesetzten Werkzeuge werden Reibahle genannt und werden anhand ihrer Schneiden in Einschneiden-Reibahle und Mehrschneiden-Reibahle unterteilt. Einschneiden-Reibahle besitzen um den Umfang verteilt angeordnete Führungsleisten, die die Reibahle in der Bohrung führen und hierdurch eine Ablenkung der Schneide aufgrund von Kräften verhindern. Neben der abstützenden Funktion bewirken die Führungsleisten eine zusätzliche Glättung der Bohrungsoberfläche [KLOC18, S. 590]. Bei Mehrschneiden-Reibahle erfolgt die Führung in der Bohrung durch die am Umfang angeordneten Schneiden. Die Schneiden verhindern somit ein Abdrängen der Reibahle. Der Einsatz einer Einschneiden-Reibahle (siehe Abbildung 2-3) garantiert eine höhere Bearbeitungsqualität bei gleichzeitiger hoher Wiederholgenauigkeit im Vergleich zu der Verwendung einer Mehrschneiden-Reibahle. Eine Mehrschneiden-Reibahle weist hingegen eine höhere Vorschubgeschwindigkeit auf und steigert hierdurch die Produktivität gegenüber einer Einschneiden-Reibahle. [KOPP08, S. 25] Der Einsatz von Kühlschmierstoff reduziert die Reibung zwischen Führungsleisten und Bohrungswand aufgrund der Bildung eines dünnen Gleitfilmes. Zudem führt der Kühlschmierstoff entstehende Späne und Wärme ab.



Abbildung 2-3: a) Einschneiden-Reibahle mit Führungsleisten, b) Kräfte an der Wendeschneidplatte (Bildquelle: [WALT20])

Die Kinematik des Reibens gleicht der des Bohrens, indem die Reibahle um ihre Längsachse mit hoher Drehzahl rotiert und entlang dieser Achse einen Vorschub in die Bohrung erfährt. Der Reibprozess lässt sich in drei Phasen einteilen, beginnend mit der Eintrittsphase, bei der die Reibahle in die Bohrung eintritt, gefolgt von der Bearbeitungsphase, bei der die Reibahle das Reiben der Bohrung durchführt (positiver Vorschub) sowie der Rückzugsphase, bei der die Reibahle aus der Bohrung gezogen wird (negativer Vorschub). Die im Folgenden erläuterten Zusammenhänge beziehen sich auf das Reiben einer Bohrung mit einer Einschneiden-Reibahle. Während der Eintrittsphase berührt die Schneide zuerst die Bohrungswand und kann aufgrund der entstehenden Schnitt- und Passivkraft abgelenkt werden, wodurch eine Exzentrizität entsteht, die zu Form- und Maßabweichungen führen kann. Dieser Effekt wird verstärkt, wenn die Fläche, welche die Bohrung beinhaltet, nicht senkrecht zu der Achse der Reibahle steht. Das Kräfteungleichgewicht wird abgebaut, sobald die Führungsleisten einen Kontakt zu der Bohrungswand haben. Befinden sich Schneide wie auch Führungsleisten im Eingriff, so stabilisiert sich der Reibprozess und die Maß- und Formgenauigkeiten können erzielt werden. Die Eintrittsphase ist eine kritische Phase, bei der die Rundheit der Bohrung maßgeblich negativ beeinflusst und eine Zackenform hervorgerufen werden kann (siehe Abbildung 2-1). Ist die Exzentrizität zwischen Reibahle und Bohrung oder der Rundlauffehler der Spindel zu groß, dann führt dies zu einer radialen Bewegung der Reibahle während des Reibvorganges, was wiederum auch die Rundheit der Bohrung negativ beeinflusst (Zackenform). Eine ovale Bohrungsform wird dann hervorgerufen, wenn die Wandstärken um die Bohrung herum unterschiedlich dick und damit unterschiedlich nachgiebig sind oder durch die Spannvorrichtung eine Verformung des Werkstückes eintritt. Die Geradheit ist ein weiteres wichtiges Kriterium an die Form einer Bohrung und wird u. a. durch eine zu flexible Reibahle oder einen Versatz von Spindel-, Werkzeug-, und/oder Bohrungsschneide negativ beeinflusst. [KOPP08, S. 6–22]

Wird eine Rundheits- oder Geradheitsabweichung aufgrund eines Versatzes zwischen der Spindel- und Werkzeugachse mit der Bohrungsschneide hervorgerufen, dann führt dies zu Schwankungen bei der Schnitt- und Passivkraft, was wiederum zu einer Oszillation der resultierenden Gesamtkraft führt, welche im Normalzustand konstant

ist. Besteht die Möglichkeit die auftretenden Kräfte während des Reibvorganges in radialer Richtung an dem Bauteil zu messen, so kann auf die Prozessinstabilität und die hieraus entstehenden Formabweichungen geschlossen werden. [KOPP08, S. 49] Werden die Formabweichungen hingegen durch einen Rundlauffehler der Spindel hervorgerufen, verursacht dies keine Veränderung der Zerspanungskräfte im Vergleich zu dem Normalzustand. Das Detektieren von Formabweichungen durch die Kontrolle der Kräfte in radiale Richtung ist somit nicht möglich. [KOPP08, S. 50]

Eine Einschneiden-Reibahle wird zumeist so konstruiert, dass sie fest integrierte, nicht justierbare Führungsleisten sowie eine radial und axial einstellbare Schneidplatte hat. Die Führungsleisten verschleifen über die Zeit und bestimmen hierdurch die Lebensdauer der Reibahle. Die Anzahl und die Positionierung der Führungsleisten beeinflussen das Bearbeitungsergebnis, sodass mit einer höheren Anzahl von Führungsleisten der Rundheitsfehler reduziert wird. Die Schneidplatte weist gegenüber den Führungsleisten in axiale und radiale Richtung einen Versatz auf. Über Schrauben lässt sich die radiale Lage sowie der Neigungswinkel der Schneidplatte einstellen. Die radiale Verstellung der Schneidplatte legt den erreichbaren Durchmesser und somit die wichtigste Maßgröße der geriebenen Bohrung fest. Mit dem stattfindenden Verschleiß der Schneidplatte über die Zeit findet eine Verengung des Durchmessers statt und macht ein Nachjustieren oder Austauschen der Schneidplatte notwendig. [KOPP08, S. 6 u.19] Der Verschleiß lässt sich durch ein ansteigendes Drehmoment detektieren.

Der Neigungswinkel der Schneidplatte hat einen starken Einfluss auf die Oberflächenrauheit der Bohrung. Wirkt sich jedoch nur sehr geringfügig auf die Schnitt- und Passivkraft aus. [KOPP08, S. 6–8] Somit ist die Ableitung der Oberflächenrauheit auf Basis von erfassten Kräften während der Bearbeitung nicht möglich.

2.2 Qualitätsmanagement

Die Hauptaufgabe des Qualitätsmanagements ist nach ISO 9000:2015 die „Erfüllung der Kundenanforderungen und das Bestreben, die Kundenerwartungen zu übertreffen“ [DIN15, S. 13]. Die Kunden können hierbei sowohl unternehmensinterne als auch unternehmensexterne Abnehmer der erbrachten Leistung sein, welche sich von einer Dienstleistung bis zu einem physischen Produkt erstrecken kann. Das Qualitätsmanagement entwickelte sich über die Zeit zu dem heute alle Unternehmensbereiche umfassenden Total-Quality-Management [MASI14, S. 6]. Es ist eine Managementdisziplin und umfasst das Festlegen der Qualitätspolitik, der Qualitätsziele, der Qualitätsplanung, der Qualitätssicherung, der Qualitätssteuerung und der Qualitätsverbesserung [DIN15, S. 31]. Zur Überprüfung der Qualität haben sich Regelkreise mit unterschiedlichem Betrachtungsradius bewährt. Die Qualitätsregelkreise erstrecken sich zum einen vertikal über die verschiedenen Organisationsebenen eines Unternehmens sowie horizontal innerhalb einer Ebene [GEVA06, S. 202]. Von Interesse für diese Arbeit sind ausschließlich die Regelkreise der operativen Ebene eines fertigen Unternehmens. Der Fokus liegt somit auf der Fertigungsmesstechnik, welche

durch das Ausführen von Mess- und Prüfaufgaben die grundlegende und essentielle Kontrollinstanz des Qualitätsmanagements in einem Fertigungsbetrieb darstellt [ZOLL14, S. 25]. Unter Qualität versteht die ISO 9000:2015 den „Grad, in dem ein Satz inhärenter Merkmale eines Objektes Anforderungen erfüllt“ [DIN15, S. 39]. Unter inhärente Merkmale werden hierbei messbare Merkmale verstanden.

2.2.1 Fertigungsmesstechnik

Zur Sicherstellung der Werkstückqualität ist eine Prüfung der Qualitätsmerkmale in der Fertigung notwendig. Die Qualität kann mittels einer 100%-Prüfung oder einer Strichprobenprüfung abgesichert werden. Ist eine Stichprobenprüfung zulässig, so wird diese aufgrund der Kosten- und Zeitersparnis bevorzugt eingesetzt. Prüfen bedeutet feststellen, ob ein Werkstück die Toleranzen der Qualitätsmerkmale, wie z. B. Form und Maß, einhält. Unterschieden wird zwischen subjektivem Prüfen (Sinneswahrnehmung des Prüfers) und objektivem Prüfen (Einsatz von Prüfmittel). Die Prüfmittel werden in Messgeräte und Lehren eingeteilt. Mit einem Messgerät wird ein Merkmal gemessen, sodass als Ergebnis ein Messwert vorliegt. Unter Messen wird das Vergleichen eines Merkmals mit einem Normal verstanden. Mit einer Lehre wird das Maß und/oder die Form eines Merkmals überprüft. Das Ergebnis besteht in der Information, ob die Qualitätsanforderungen eingehalten werden oder nicht (i.O. oder n.i.O.). [KLOC18, S. 12] Obwohl diese klare Unterscheidung zwischen den Begriffen „Prüfen“ und „Messen“ besteht, ist bei der Verwendung dieser Begriffe die Bedeutung weniger konsistent. So wird z.B. unter dem Begriff „Messmanagementsystem“ nicht nur Messmittel, sondern auch Lehren verwaltet, die nur Prüfentscheide liefern können [DIET14, S. 715].

Die Fertigungsmesstechnik stellt die bedeutende Kontrollinstanz für die Qualitätsprüfung in der Fertigung dar. Die Qualitätsprüfung lässt sich gliedern in Pre-, In- und Post-Prozessprüfung [KRÜG14, S. 22]. Der überwiegende Anteil der Qualitätsprüfungen erfolgt bisher nach Beendigung des Fertigungsprozesses (Post-Prozessprüfung). Um maschinennahe Regelkreise zu erreichen, mit denen Qualitätsabweichungen schnell entdeckt werden und Maßnahmen ergriffen werden können, fand eine Verlagerung der Messtechnik in die Produktion und zwar möglichst nahe an die fertigende Maschine statt. [KEFE17, S. 10–11] Wie in der Einleitung dieser Arbeit bereits erwähnt, setzt zudem eine Entwicklung ein, die eine In-Prozessprüfung als Ziel hat und eine wirtschaftliche 100%-Prüfung der Werkstückqualität anstrebt. Dies würde einem maschineninternen Regelkreis entsprechen und somit eine gesteigerte Transparenz und noch schnelleres Handeln ermöglichen.

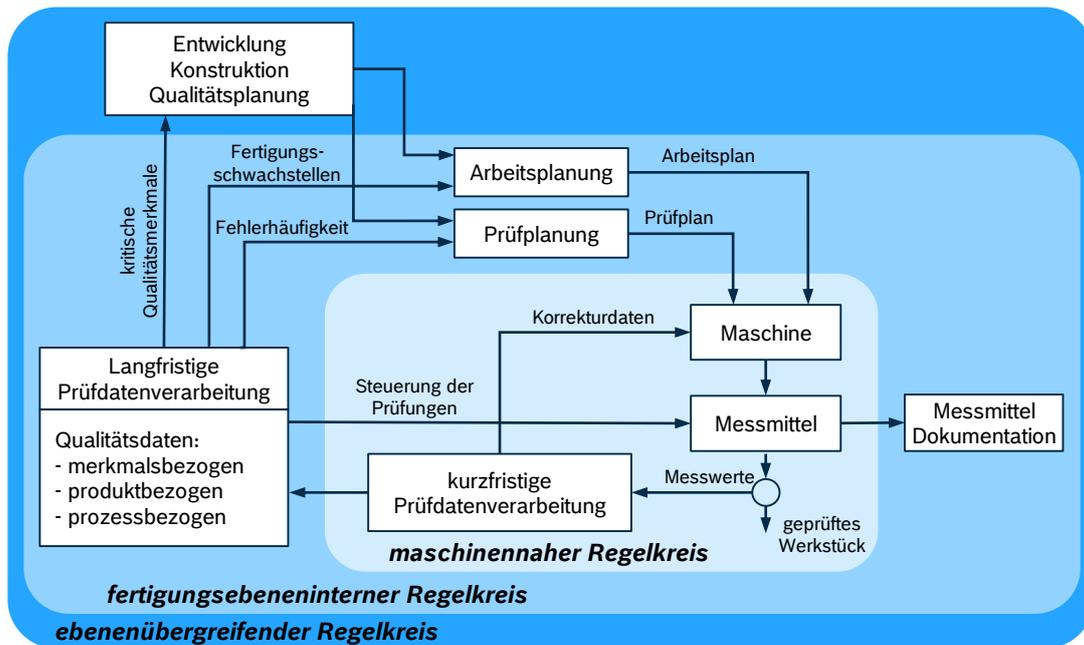


Abbildung 2-4: Regelkreise mit Bezug zur Fertigungsmesstechnik [GEVA06, S. 202; KEFE17, S. 11]

In Abbildung 2-4 sind drei Regelkreise mit Bezug zur Fertigungsmesstechnik und unterschiedlichem Aktionsradius dargestellt. Der maschinennahe Regelkreis umfasst die Mess- und Prüfmittel sowie die zugehörigen Prozesse, um nach der Fertigung eines Werkstückes deren Qualität zu bestimmen. Die gewonnenen Messergebnisse fließen in die kurzfristige Prüfdatenverarbeitung ein und werden direkt für die Optimierung bzw. Korrektur des Fertigungsprozesses genutzt. Des Weiteren werden die Messergebnisse in der langfristigen Prüfdatenverarbeitung des fertigungsebeneninternen Regelkreises gespeichert und stehen hier für ebenenübergreifende Regelkreise zur Verfügung. Die Qualitätsdaten werden merkmals-, produkt- und prozessbezogen gespeichert. Auf der Basis dieser strukturiert gespeicherten Qualitätsdaten kann eine Steuerung der Messungen erfolgen sowie der Prüfplan und der Arbeitsplan anhand der Fehlerhäufigkeit sowie der erkannten Fertigungsschwachstellen entworfen werden. Die Qualitätsdaten zeigen zudem der Entwicklung und der Konstruktion die für die Fertigung besonders kritischen Werkstückmerkmale auf, sodass bei Neukonstruktionen ein besonderes Augenmerk auf diese Merkmale gelegt werden kann und sie nach Möglichkeit vermieden bzw. größere Toleranzgrenzen ermöglicht werden. Zu der Ebene, auf der die Fertigungsmesstechnik angesiedelt ist, zählt nicht nur die Dokumentation der Qualitätsergebnisse, sondern auch die Überwachung der eingesetzten Messmittel sowie die dazugehörige Dokumentation. Die ISO 10012:2003 legt unter dem Punkt „Metrologische Bestätigung und Realisierung von Messprozessen“ die notwendigen Fähigkeitsuntersuchungen und die Messmitteldokumentation fest [DIN 03c]. Im folgenden Kapitel 2.2.2 wird auf das Vorgehen sowie die zugrundeliegenden Berechnungen einer Messmittelfähigkeitsuntersuchung eingegangen.

2.2.2 Eignungsnachweise von Mess- und Prüfprozessen

Um sicher zu stellen, dass ein Messmittel (Messgerät) am Einsatzort ein Qualitätsmerkmal mit ausreichend kleiner Unsicherheit (Messabweichung und Messwertstreuung) in Bezug auf die Merkmalstoleranz bestimmen kann, sind Fähigkeitsuntersuchungen notwendig [KEFE17, S. 281]. Es existieren unterschiedliche Vorgehensweisen, um die Fähigkeit eines Mess- bzw. Prüfprozesses nachzuweisen. Die für den Praxiseinsatz entwickelten Fähigkeitsuntersuchungen basieren auf der in dem „Guide to expression of Uncertainty in Measurement“ (GUM) beschriebenen Vorgehensweise, welche sehr umfassend und präzise, jedoch zugleich sehr komplex ist. Für den Praxiseinsatz haben sich die Vorgehensweisen etabliert, die in dem Band 5 „Prüfprozesseignung“ von dem Verband der deutschen Automobilindustrie oder im Leitfaden „Measurement System Analysis“ (MSA) der in den USA ansässigen Automotive Industry Action Group veröffentlicht sind. Zusätzlich haben sich Firmenrichtlinien etabliert wie etwa das von der BOSCH Group herausgegebene Heft 10 „Fähigkeit von Mess- und Prüfprozessen“. Jede dieser Richtlinien hat das Ziel, einen GRR-Wert (Gage Repeatability and Reproducibility) zu ermitteln. Der Fähigkeitsnachweis eines Prüfprozesses erfolgt schließlich durch den Vergleich des ermittelten GRR-Wertes mit vorgegebenen Grenzwerten. Die genannten Vorgehensweisen bzw. Firmenrichtlinie stellen Standardverfahren dar, mit denen die Fähigkeit von einer großen Anzahl von Prüfprozessen bestimmt werden kann. Für Prüfprozesse, die Sonderfälle darstellen, müssen ebenfalls Fähigkeitsnachweise durchgeführt werden. Hierfür können die Standardverfahren in angepasster Form ebenfalls eingesetzt werden bzw. Anregungen für ein mögliches Vorgehen zur Beurteilung der Fähigkeit liefern. [DIET17, S. V–VI]

In dieser Arbeit wird das in der BOSCH Group etablierte Vorgehen für den Fähigkeitsnachweis von Mess- und Prüfprozessen angewandt, welches in dem Heft 10 hergeleitet und dokumentiert ist [TILS 19a]. Auch außerhalb der BOSCH Group wird dieses Vorgehen angewandt und wird u. a. von DIETRICH ET AL. und KEFERSTEIN ET AL. beschrieben [DIET17; KEFE17]. Das Heft beschreibt insgesamt fünf verschiedene Verfahren, mit denen eine Beurteilung der Messmittel- und Prüfprozessfähigkeit durchgeführt werden kann. Um die Fähigkeit der im Rahmen dieser Arbeit eingesetzten Methoden des maschinellen Lernens für die Qualitätsprognose zu bewerten, sind die Verfahren eins (Systematische Messabweichung und Wiederholbarkeit) und drei (Wiederhol- und Vergleichpräzision ohne Bedienerinfluss) ausreichend. Diese beiden Verfahren werden im Folgenden etwas detaillierter vorgestellt und schließlich in Kapitel 5.6.2 angewandt.

Beide Verfahren dienen zur Bewertung der Messprozessfähigkeit mittels kontinuierlicher Merkmale und es sind Normale oder Werkstücke aus der Fertigung notwendig, welche mehrfach vermessen werden. Zudem wird eine Normalverteilung der Messwerte bei der statistischen Auswertung unterstellt. Außerdem müssen die verwendeten Messmittel über eine Auflösung verfügen, die kleiner gleich 5 % der Toleranz des zu prüfenden Merkmals ist. Mit Verfahren eins wird die Fähigkeit eines Messprozesses (Prüfprozess) bezüglich der Lage und der Streuung der Messwerte im Toleranz-

feld des zu prüfenden Merkmals nachgewiesen. Es erfolgt somit eine Beurteilung der systematischen Messabweichung und der Wiederholbarkeit des Messergebnisses (Streuung des Messmittels), die die Fähigkeit des Messmittels bewerten. Das Verfahren wird mit einem Normal durchgeführt, welches 50-mal gemessen wird ($n = 50$). Vor der Durchführung einer Messung muss das Normal aus der Aufspannung herausgenommen und wieder erneut eingespannt werden, sodass alle Handhabungsschritte zwischen den Messungen vollständig ausgeführt werden. Existiert kein Normal, so kann auch ein kalibriertes Werkstück verwendet werden. Das zu prüfende Merkmal muss mittels eines unteren und eines oberen Grenzwertes (UGW und OGW) definiert sein (spezifizierte oder natürliche Grenzwerte), sodass die Toleranz T berechnet werden kann. Der Referenzwert des Normals x_m sollte möglichst in der Mitte der Toleranz liegen. Die systematische Messabweichung ergibt sich aus der Differenz des Mittelwertes \bar{x}_g der Messwerte mit dem Referenzwert x_m . Die Standardabweichung s_g der Messwerte ist ein Maß für die Wiederholbarkeit der Messung. Der Nachweis der Messmittelfähigkeit erfolgt durch die Berechnung der Fähigkeitsindizes C_g und C_{gk} , welche einen Wert größer gleich 1,33 annehmen müssen, damit der Messprozess als fähig eingestuft werden kann. Hierbei werden schließlich die systematische Messabweichung und die Wiederholbarkeit in Zusammenhang mit der Toleranz betrachtet. [KEFE17, S. 281–284; DIET17, S. 52–68; TILS 19a, S. 8-11]

Toleranz des zu messenden Merkmals:

$$T = OGW - UGW \quad (2.1)$$

Mittelwert der Messwerte:

$$\bar{x}_g = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.2)$$

Standardabweichung der Messwerte:

$$s_g = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_g)^2} \quad (2.3)$$

Potentieller Fähigkeitsindex:

$$C_g = \frac{0,2 * T}{6 * s_g} \quad (2.4)$$

Kritischer Fähigkeitsindex:

$$C_{gk} = \frac{0,1 * T - |\bar{x}_g - x_m|}{3 * s_g} \quad (2.5)$$

Wurde das Verfahren eins erfolgreich durchlaufen, so kann mittels Verfahren drei die Fähigkeit eines Messprozesses hinsichtlich seines Streuverhaltens anhand von Messungen an Werkstücken aus der Serienfertigung erbracht werden. Hierbei wird vorausgesetzt, dass von dem Bedienpersonal kein Einfluss auf den Messprozess aus-

geht. Kann dies nicht ausgeschlossen werden, so ist das hier nicht beschriebene Verfahren zwei anzuwenden. Mit Verfahren drei werden im Unterschied zu Verfahren eins eventuelle Wechselwirkungen zwischen Messobjekt (Werkstück) und Messverfahren berücksichtigt. Die Streuung der Werkstücke und die damit verbundene Verteilung der Messwerte über einen größeren Messbereich des Messmittels können Effekte hervorbringen, die bei der Messung eines Normals nicht auftreten. Für die Durchführung werden mindestens 25 Werkstücke ($n \geq 25$) aus der Serienfertigung benötigt, die zufällig ausgewählt werden und deren Merkmalswerte innerhalb der Toleranz liegen. Mindestens zwei Mal ($r \geq 2$) werden die Werkstücke in zufälliger Reihenfolge in r Messreihen gemessen. Ziel ist die Bestimmung der Gesamtstreuung %GRR (Wiederhol- und Vergleichspräzision) des Messprozesses. Anhand von definierten Grenzwerten für %GRR erfolgt schließlich die Bestimmung der Fähigkeit des Messprozesses.

- %GRR \leq 10 % Messprozess fähig,
- 10 % < %GRR \leq 30 % Messprozess bedingt fähig,
- 30 % < %GRR Messprozess nicht fähig.

Aufgrund der komplizierten Berechnung von GRR ist eine Statistik-Software einzusetzen. Der Wert für %GRR berechnet sich durch die Berücksichtigung der Toleranz des Merkmals. [TILS 19a, S. 15–17; KEFE17, S. 287–288; DIET17, S. 104–107]

$$\%GRR = \frac{6 * GRR}{T} * 100 \% \quad (2.6)$$

Nach AIAG MSA soll bei Verfahren drei zudem die Zahl der durch den Messprozess noch unterscheidbaren Messwertklassen ndc bestimmt werden. Ist der ndc -Wert ≥ 5 , dann ist sichergestellt, dass die Streuung der Messeinrichtung kleiner ist als die Streuung der Werkstücke und somit die Messeinrichtung unterschiedliche Teilequalitäten unterscheidbar messen kann. Zur Bestimmung von ndc wird die Teilstreubreite PV benötigt. Diese berechnet sich aus der Differenz des größten und des kleinsten Mittelwertes von zwei Wiederholmessungen multipliziert mit einem Faktor aus einer Tabelle, der sich nach der Teileanzahl und der Anzahl der Wiedermessungen orientiert. Die Teilstreuung PV ist selbst keine kritische Größe. [AIAG10]

$$ndc = \frac{PV}{GRR} * \sqrt{2} \quad (2.7)$$

2.3 Datenerfassung und Datenaufbereitung

Daten stellen die Grundlage für die Anwendung von maschinellem Lernen dar. Es bedarf jedoch der Erfassung von geeigneten Daten und einer passenden Aufbereitung, um sie zusammen mit dem maschinellen Lernen zum Lösen einer Aufgabe zu verwenden. Die in der fertigen Industrie vorzufindenden Datenquellen sowie

Möglichkeiten zur Datenerfassung werden in diesem Kapitel vorgestellt. Anschließend erfolgt die Beschreibung von Verfahren zur Merkmalsextraktion und -selektion.

2.3.1 Datenquellen in der industriellen Fertigung

Die in der industriellen Fertigung verfügbaren Daten entstammen unterschiedlichen Ebenen. Die Ebenen stehen im Austausch zueinander und sind durch den Grad der Informationsverdichtung, ihre Echtzeitfähigkeit bei der Datenverarbeitung und der Übernahme sowie Verantwortung von Aufgaben in der Produktion charakterisiert. Die hierarchische Gliederung der in einem Fertigungsunternehmen vorzufindenden Ebenen werden in der sich etablierten Automatisierungspyramide dargestellt (siehe Abbildung 2-5).

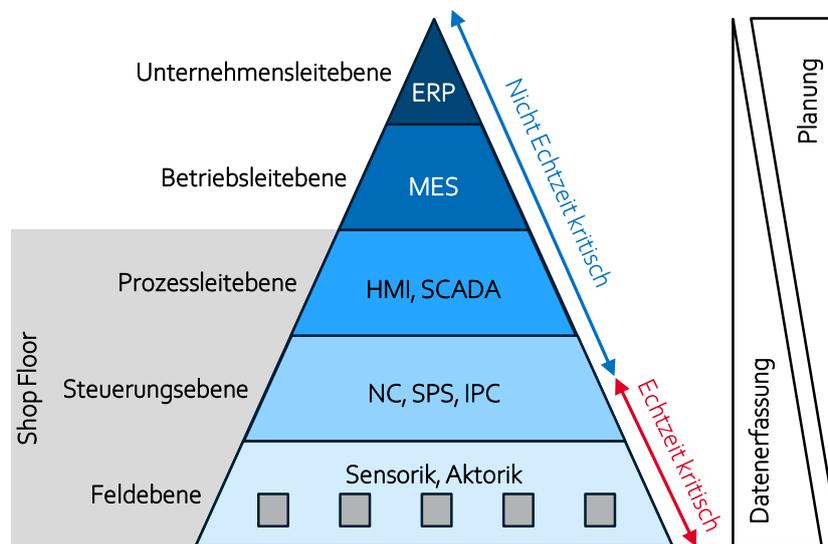


Abbildung 2-5: Automatisierungspyramide der industriellen Fertigung

Die oberste Ebene stellt die Unternehmensleitenebene dar und dient zur Abwicklung aller betriebswirtschaftlichen Prozesse eines Unternehmens. Operative Unterstützung erhält sie durch ein Enterprise Resource Planning System (ERP). Die darunterliegende Betriebsleitenebene umfasst alle Aufgaben zur Planung und Durchführung von Fertigungsprozessen und -ressourcen. Ausgeführt wird sie durch ein Manufacturing Execution System (MES). Die Prozessleitenebene befindet sich auf dem Shopfloor und mit ihr erfolgen die Prozessüberwachung, -sicherung und -optimierung. Zum Einsatz kommende Systeme sind Supervisory Control and Data Acquisition (SCADA) sowie Human Machine Interfaces (HMI). Die Steuerungsebene übernimmt die Steuerung und Regelung eines jeden Fertigungsprozesses. Hierfür wertet sie die in der Feldebene aufgenommenen Sensordaten aus und gibt Parameterwerte zur Ansteuerung der Aktoren zurück. Die Steuerungs- und Regelungsaufgaben werden gewöhnlich von der NC-Steuerung (Numerical Control), der SPS (speicherprogrammierbare Steuerung) oder dem IPC (Industrie PC) ausgeführt. Die unterste Ebene bildet die

Feldebene, welche über Sensoren und Aktoren die Schnittstelle zum Fertigungsprozess herstellt. Auf dieser Ebene befinden sich demnach die Sensoren und Aktoren, die der Steuerungsebene einen direkten Zugang und Zugriff auf den Fertigungsprozess ermöglichen. [GÜNT17, S. 18–19; GORE17, S. 555–556]

Das in dieser Arbeit entwickelte System einer Qualitätsprognose erstreckt sich zwangsläufig über die unteren drei Ebenen und kann zudem wichtige Informationen für die Betriebsleitebene liefern. Die Qualitätsprognose erhält die notwendigen Fertigungsdaten von den Sensoren der Feldebene, welche von der NC und SPS aufbereitet und zur Verfügung gestellt werden. Die Verarbeitung der Daten sowie die Prognoseerstellung mittels den Methoden des maschinellen Lernens erfolgt ebenfalls auf der Steuerungsebene mit IPCs. Die Ergebnisse werden den Mitarbeitern auf dem Shopfloor über HMI mitgeteilt und fließen somit direkt in die Prozessüberwachung sowie -sicherung auf der Prozessleitebene ein. Zudem besteht die Möglichkeit, die Werkstückqualität bzw. die Gutteileausbringung auf der Betriebsleitebene einzusteuern und somit zur Planung der Fertigung beizutragen.

Die für die Prognosen benötigten Daten bzw. Informationen über den Fertigungsprozess werden aus der Feld- und der Steuerungsebene erfasst. Mittels den in der Feldebene vorliegenden Sensoren lassen sich die benötigten Fertigungsdaten (z. B. Drehmoment, Achsposition) mit einer hohen Erfassungsfrequenz gewinnen. Metadaten (z. B. Werkstückbezeichnung, Werkzeugnummer, Fertigungsschritt) werden aus der Steuerungsebene und den dort vorliegenden NC- und SPS-Steuerungen mit niedriger Frequenz erfasst.

2.3.2 Datenerfassung mittels Steuerung und Sensorik der Werkzeugmaschine

Die Steuerung einer Werkzeugmaschine erfolgt mit Steuerungssystemen, die sich aufteilen in die NC-Steuerung und die Ablaufsteuerung (SPS). Die von den Steuerungen auszuführenden Anweisungen sind in einem sogenannten NC-Programm hinterlegt. Die NC-Steuerung decodiert das Programm und interpretiert die enthaltenen Befehle und Parameter. Die berechneten und interpolierten Sollwerte (technologisch und geometrisch) werden an die Antriebe und die Schaltfunktionen an die SPS weitergeleitet. Sie überwacht fortlaufend die Regelgröße („Ist-Wert“) und gleicht diese mit der Führungsgröße („Soll-Wert“) ab. Mittels einer Stellgröße greift sie in den Fertigungsprozess ein und gleicht die Regelgröße an die Führungsgröße an. In diesem Sinne ist die NC-Steuerung eher eine Regelung anstatt eine Steuerung. Die NC-Steuerung übernimmt noch weitere Aufgaben, wie z. B. die Temperaturkompensation. Die SPS stellt eine Ablaufsteuerung dar und steht zum Datenaustausch und zur Befehlsübergabe in stetiger Verbindung zur NC-Steuerung. Sie dient hauptsächlich zur Steuerung und Überwachung von mechanischen Funktionseinheiten, wie z. B. Werkzeugwechsel, Ein-/Ausschalten der Kühlmittelzufuhr, des Späneförderers etc. Sie kommuniziert zudem mit weiteren SPS-Steuerungen und übergibt Parameter, wie z. B. die Werkstücknummer oder der Werkstücktyp. [WECK06, S. 154–165; HEHE20, S. 91–94] Die meisten NC-Steuerungen besitzen zudem Schnittstellen,

über die sie die steuerungsintern vorliegenden Soll- als auch die Ist-Werte des Fertigungsprozesses ausgeben. Über diese Schnittstellen lassen sich zusätzliche Prozessüberwachungssysteme anschließen, die z. B. einen Werkzeugbruch detektieren und daraufhin die Bearbeitung stoppen.

Die Soll-Werte werden der NC-Steuerung durch das NC-Programm mitgeteilt. Die Ist-Werte hingegen müssen mittels Sensoren erfasst bzw. aus Sensorwerten berechnet werden. Die für die Steuerung der Maschine notwendigen Sensoren sind zumeist in die Achsen, die Achsregelung und die Spindel integriert. Zudem können zusätzliche Sensoren z. B. in den Arbeitsraum, in das Werkstückspannsystem oder in den Werkzeughalter integriert werden. Zumeist werden diese zusätzlichen Sensoren jedoch nur für die Prozessüberwachung integriert und genutzt. Die allgemeine Funktion von Sensoren besteht darin, physikalische Messgrößen in elektrische Signale umzuwandeln. Die Umwandlung der zu messenden, physikalischen Größe in elektrische Ausgangssignale erfolgt in dem Sensorelement durch naturwissenschaftliche Gesetze. Ein solches elektrisches Ausgangssignal ist in seiner reinen Form für die industrielle Anwendung nicht nutzbar. Es bedarf einer zusätzlichen Auswerteelektronik, um industriell nutzbare Signale zu erhalten. Die Auswerteelektronik bearbeitet das elektrische Ausgangssignal mittels Softwareprogramm und Schaltungselektronik, sodass ein für die industrielle Nutzung geeignetes Sensorausgangssignal vorliegt. [HER10, S. 1–2]

Die bei der Fertigung erzeugte Qualität eines Werkstückes ist auf die auftretenden Effekte an der Wirkstelle des Werkzeuges zurückzuführen. Ein Großteil der Effekte ist auf die während der Bearbeitung auftretende Zerspankraft zurückzuführen. In Kapitel 2.1 erfolgt die Darstellung der Kräfte der eingesetzten Werkzeuge beim Bohren und Reiben einer Bohrung sowie eine Erläuterung ihrer Wirkung auf den Fertigungsprozess und die Bohrungsqualität. Die auftretenden Effekte lassen sich nur indirekt anhand von Sensorsignalen erfassen und beruhen zumeist auf der Zerspankraft. Für die Erfassung der Effekte können entweder Sensoren in den Fertigungsprozess integriert werden (externe Sensoren), oder die bereits in der Maschine standardmäßig vorhandenen Sensoren (interne Sensoren) verwendet werden. [HESS14, S. 1–4] Beide Strategien haben ihre Vor- und Nachteile. Durch die Nutzung von externen Sensoren lassen sich individuell die Effekte oder Fertigungsgrößen erfassen, von denen der größte Einfluss auf die Werkstückqualität vermutet wird. Nachteilig ist hingegen der zusätzliche Aufwand für die Integration in die Maschine oder in den Bearbeitungsraum. In der industriellen Fertigung kann zudem die Integration von zusätzlicher Sensorik unmöglich bzw. unwirtschaftlich sein, wenn Kühlschmierstoff eingesetzt wird, ein häufiges Umrüsten aufgrund von Produktwechsel stattfindet oder zusätzlicher Wartungsaufwand generiert wird. Eine alternative Lösung hierzu ist die Nutzung der zum Betrieb der Maschine standardmäßig vorliegenden internen Sensoren in den Antrieben und Achsreglern. Über Zugriffsschnittstellen der NC-Steuerung lassen sich diese Sensoren auslesen und für die gewünschten Vorhaben nutzen. Des Weiteren sind alle über den Prozessablauf notwendigen Informationen (z. B. Werkstücknummer, Werkzeugnummer, NC-Satz, etc.) aus einer Datenquelle verfügbar. Die meisten

Prozessüberwachungssysteme arbeiten somit rein auf der Basis der so verfügbaren Sensorsignale (z. B. ARTIS MARPOSS, ToolScope). Der Nachteil bei der Nutzung der internen Sensoren liegt in der durch die Steuerung limitierte Abtastfrequenz, die zumeist maximal gleich dem Interpolationstakt ist. Ein weiterer Nachteil besteht darin, dass manche Fertigungsgrößen aus den Signalen anderer Sensorwerte berechnet und nicht mittels Sensoren erfasst werden. In Abbildung 2-6 sind die Sensorsignalur-sprünge sowie die Erfassungsstrategien durch die Nutzung von internen oder externen Sensoren aufgezeigt.

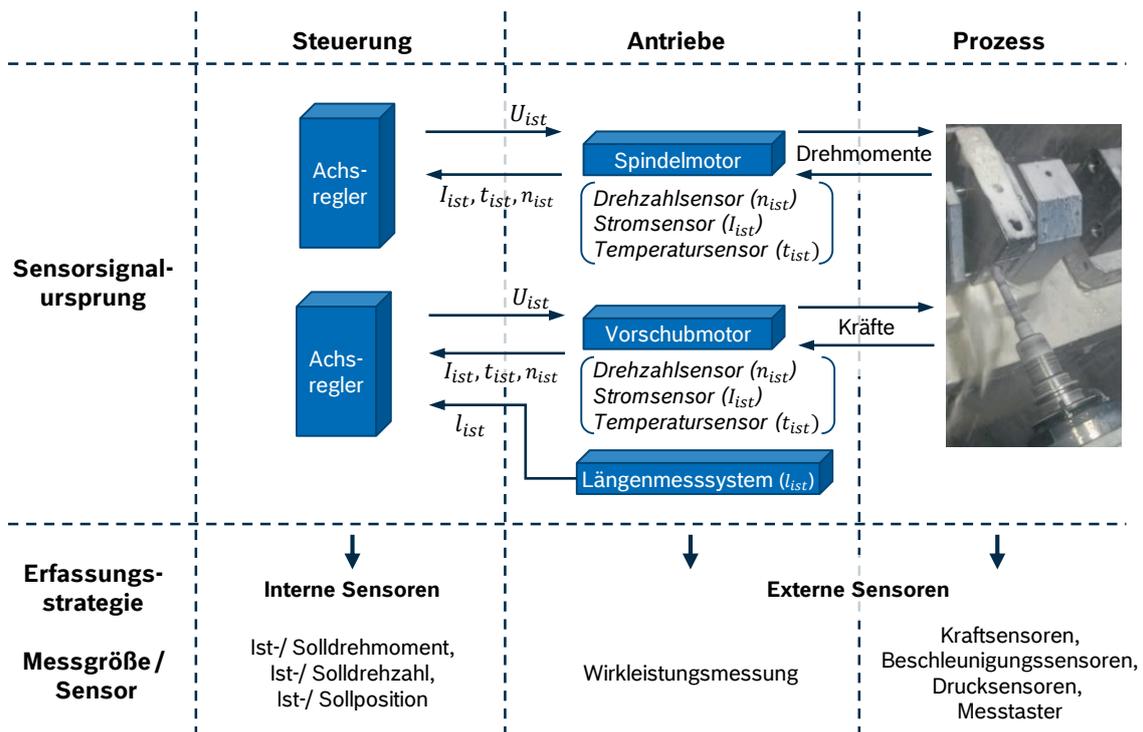


Abbildung 2-6: Sensorsignalur-sprung und Möglichkeiten der Fertigungsdatenerfassung [BRIN09, S. 13]

Die in dieser Arbeit entwickelte Qualitätsprognose soll rein auf der Basis von Fertigungsgrößen erfolgen, die von den internen Sensoren der Maschine erfasst und über die NC-Steuerung bzw. die Achsregler zur Verfügung gestellt werden. Von Interesse ist nun die Geschwindigkeit bzw. die Frequenz, mit der die Fertigungsgrößen berechnet und aktualisiert werden, sowie die Genauigkeit der Sensoren. Dies soll anhand der Steuerungs- und Antriebstechnik der Firma Bosch Rexroth erläutert werden, da diese Technik bei der in dieser Arbeit eingesetzten Maschine verbaut ist. Das Funktionsprinzip ist grundsätzlich auch bei anderen Herstellern von NC-Steuerungstechnik identisch. Gegenwertige Antriebstechnik für die Regelung von Achsbewegungen basiert auf einer kaskadierten Regelung aus Lage-, Drehzahl- und Stromregelung (siehe Abbildung 2-7). Bei der zum Einsatz kommenden Steuerung von Bosch Rexroth mit der Bezeichnung ADVANCED beträgt die Zykluszeit des Lagereglers 250 μ s, des Drehzahlreglers 125 μ s und des Stromreglers 62,5 μ s. Die ei-

gentliche NC-Steuerung arbeitet mit einem Interpolationstakt von 1 ms. Die NC-Steuerung berechnet aus dem NC-Programm die Sollwerte der einzelnen Parameter und übergibt diese jede Millisekunde an die Achsregler. Die Achsregler regeln dann die Achsen mit den angegebenen Zykluszeiten. Die Kaskaden der Regelung der Größen Drehzahl, Position und Drehmoment werden im Folgenden näher betrachtet. Zudem wird aufgezeigt, an welcher Stelle die Größen abgegriffen werden können. An dieser Stelle soll darauf hingewiesen werden, dass bei der Antriebstechnik von Bosch Rexroth unter Geschwindigkeit die Drehzahl gemeint ist.

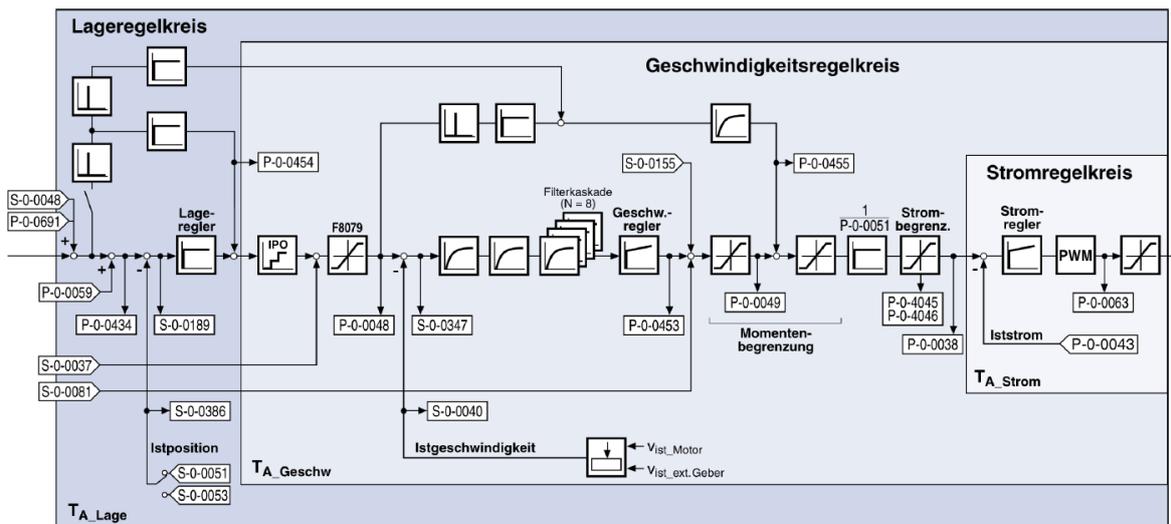


Abbildung 2-7: Gesamtstruktur des Regelkreises [REXR08, S. 273]

Die bereits erwähnten drei Regelkreise zur Regelung der Achsbewegungen und ihre Verknüpfungen untereinander sind in Abbildung 2-7 dargestellt. Jeder Parameter ist über seine Bezeichnung eindeutig identifizierbar. Die Bezeichnungen beginnen entweder mit einem „S“ für Standardparameter oder einem „P“ für produktspezifische Parameter gefolgt von einer Nummer. Die für die Qualitätsprognose relevanten Parameterwerte sind die von den Sensoren erfassten Istwerte. Diese sind die Istposition (S-0-0055) des direkten Wegmesssystems bzw. (S-0-0051) des indirekten Wegmesssystems des Antriebs, die Istgeschwindigkeit (S-0-0040) sowie der drehmomentbildende Iststrom (P-0-0043), aus dem das Istdrehmoment berechnet wird. Die Bezeichnung der restlichen Parameter können dem Anhang A entnommen werden.

bildenden Stroms aus, der notwendig ist, um die Soll-Geschwindigkeit zu erreichen. Dieser drehmomentbildende Soll-Strom wird durch eine Strombegrenzung auf den maximal zulässigen Wert begrenzt und schließlich mit dem gemessenen drehmomentbildenden Ist-Strom verglichen. Die hieraus entstehende Regelabweichung wird in den Stromregler eingespeist, um hierdurch die drehmomentbildende Ist-Spannung zu bestimmen und diese schließlich in dem Wechselrichter zu Wechselspannung umzuwandeln. Parallel hierzu verläuft die Bestimmung der flussbildenden Ist-Spannung. Diese wird jedoch nicht durch die Geschwindigkeit, sondern durch die Motormaximalspannung bestimmt. Die Spannung sowie der Strom teilen sich somit in einen flussbildenden sowie einen drehmomentbildenden Teil auf. Für die Gewinnung von Informationen über den Fertigungsprozess ist nur der drehmomentbildende Ist-Strom von Interesse. Das wirksame Ist-Drehmoment lässt sich somit berechnen aus dem drehmomentbildenden Ist-Strom multipliziert mit der zu dem individuellen Motor bestimmten Drehmomentkonstante. Um den benötigten Stromanteil zu erhalten, werden die Phasenströme des Drehstrommotors gemessen. Schließlich wird der resultierende drehmoment- und flussbildende Anteil aus dem gemessenen Gesamtstrom in dem Achsregler berechnet. [REXR08] Das Messen der Ströme erfolgt mittels Sensoren, die den Halleffekt nutzen und auf der Stromschiene bzw. direkt im Motor selbst verbaut sind. Die von den Sensoren ausgegebenen Sensorausgangssignale stellen das aufbereitete Signal des Sensorelementes dem Achsregler zur Verfügung. Die Genauigkeit eines solchen Sensors liegt bei ca. 3 %, die Zykluszeit, mit der die Sensorausgangssignale bereitgestellt werden, beträgt ca. 9 μs und die Bauform nimmt nur wenige mm^3 ein. [INF120]

In der Abbildung 2-9 ist die Struktur des Lagereglers dargestellt. Der Lagesollwert wird von der NC-Steuerung aus den in dem NC-Programm angegebenen Werten interpoliert und in die Lagereglung des Achsregelmoduls übergeben. Die Lagereglung führt einen Abgleich mit dem Lageistwert durch und bestimmt den Schleppabstand. Der Lageregler bestimmt die notwendige Soll-Geschwindigkeit (Drehzahl) der Achse, um den Lagesollwert zu erreichen. Die Soll-Geschwindigkeit wird schließlich an den Stromregler weitergeleitet. Von Bedeutung für die Qualitätsprognose ist nur der Lageistwert der Achse. Dieser kann auf zwei Wege (ähnlich der Drehzahl) bestimmt werden. Der Parameter S-0-0051 gibt die aktuelle Lage des Motorgebers und der Parameter S-0-0053 die aktuelle Lage des externen Gebers (Längenmessgerät) wieder. In Abhängigkeit von dem eingesetzten Motortyp (Rotations- oder Linearmotor) können beide oder nur ein Positionswert vorliegen. In beiden Fällen erfolgt die Lagebestimmung über ein absolutes oder ein inkrementelles Messsystem. In der in dieser Arbeit eingesetzten Maschine erfolgt die Lagebestimmung über ein externes absolutes Längenmesssystem. [REXR08]

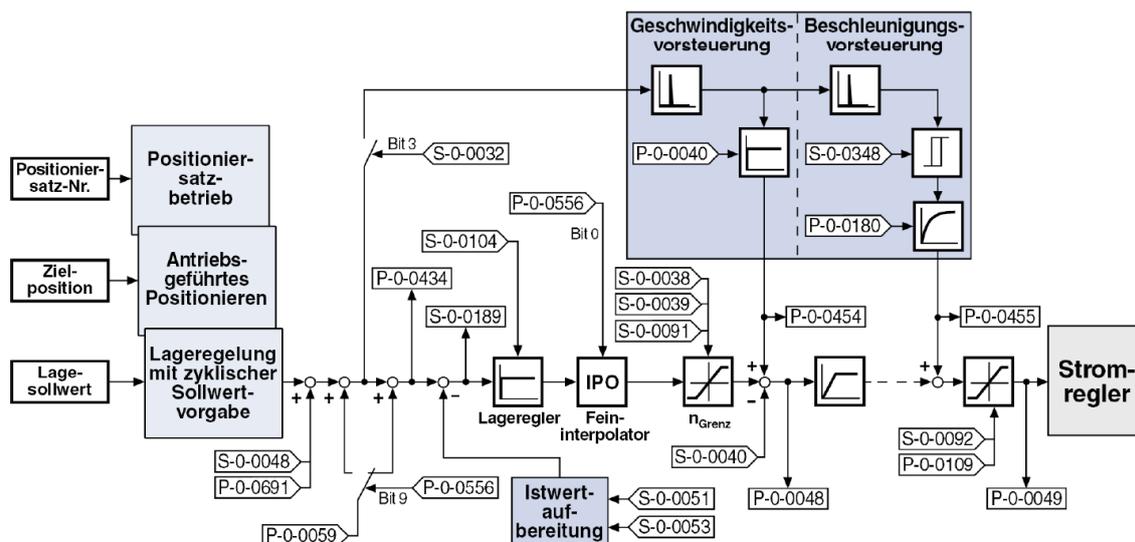


Abbildung 2-9: Struktur der Lageregelung [REXR08, S. 333]

Als Längenmesssystem kommt ein Positionsmesssensor mit fotoelektrischer Abtastung zum Einsatz. Dieser funktioniert nach dem Prinzip, dass zwei Strichgitter (bezeichnet als Abtastplatte und Maßverkörperung) zueinander parallel angebracht sind, von einer parallelen Lichtquelle bestrahlt werden und dass ein Fotoelemente-Array die entstehenden Hell/Dunkel-Felder bei der Relativbewegung der beiden Gitter in elektrische Signale umwandelt. Die spezielle Strichgitterstruktur der Abtastplatte filtert dabei den Lichtstrom auf eine Weise, dass sinusförmige Ausgangssignale entstehen. Die im Positionsmesssensor enthaltene Auswerteeinheit interpoliert die empfangenen analogen Signale und erhöht hierdurch zusätzlich die Auflösung. Die Herstellung der Bezugsposition erfolgt durch das Verfahren der Achsen über den Referenzpunkt. Die Genauigkeit des Messsystems liegt bei $\pm 0,1 \mu\text{m}$ und die Zykluszeit zur Ausgabe des aktuellen Lageistwertes beträgt $5 \mu\text{s}$. [HEID19]

Die Betrachtung der in den Antrieben und Führungen verbauten Sensoren zeigt auf, dass diese die jeweils benötigte Größe mit sehr hoher Genauigkeit erfassen und somit auf Änderungen schnell reagieren können. Die Zykluszeit (Taktrate) der Auswerteeinheit der Sensoren, mit der die Signale für die Achsregler bereitgestellt werden, liegt zudem deutlich unter der Zykluszeit des zugehörigen Regelkreises. Es kann somit sichergestellt werden, dass die für die Regelung eingespeisten Istwerte den tatsächlichen und aktuellen Fertigungszustand exakt wiedergeben. Die limitierenden Komponenten bei der Erfassung des Fertigungszustandes sind somit nicht die Genauigkeit oder die Zykluszeit der Sensoren, sondern gehen von der Zykluszeit der Achsregler und der von der NC-Steuerung bereitgestellten Schnittstelle zur Datenerfassung aus. Die Datenerfassung ist maximal mit dem Interpolationstakt der NC-Steuerung möglich, für die in dieser Arbeit verwendeten MTX ADVANCED beträgt dieser 1.000 Hz (1 ms). Somit ist ein Erfassen des Fertigungszustandes nur jede Millisekunde möglich. Für die spätere Zuordnung der erfassten Daten zu einem Werkstück sowie die Synchronisation der Daten ist eine gemeinsame und eindeutige Bezugsgröße notwendig. Diese Bezugsgröße stellt die Zeit dar. Erst durch identische

Zeitstempel wird es möglich, die verteilt aufgezeichneten Daten zu synchronisieren und somit die vom Fertigungsprozess ausgehenden Effekte in Zusammenhang zu bringen. Um dies zu erreichen, müssen die Uhren der NC-Steuerung sowie der einzelnen Achsregler synchron laufen. Für die Synchronisation wird ein Net Time Protocol (NTP) verwendet, welches täglich die einzelnen Uhren mit der Master Clock abgleicht.

Für die Kommunikation und Synchronisation zwischen Steuerung, Achsreglern und Sensoren werden echtzeitfähige Feldbusse benötigt (z. B. Sercos). Für den Austausch von weniger zeitkritischen Daten werden weniger performante Protokolle verwendet, wie z. B. TCP/IP oder OPC-UA. Mit ihnen erfolgt zumeist auch die Kommunikation zwischen der Steuerungsebene und den darüber liegenden Schichten der Automatisierungspyramide.

Die erfassten Daten müssen an einem Ort gespeichert und verarbeitet werden. Hierfür bieten sich zwei verschiedene Ansätze an, die bezeichnet werden als Edge-Computing und Cloud-Computing. Bei dem Edge-Computing wird der Speicherplatz sowie die Rechenleistung in der Nähe der Maschine bereitgehalten. Dies kann z. B. in der Form eines IPCs im Schaltschrank oder durch einen Server in der Werkhalle geschehen. Die Vorteile liegen z. B. in einer geringen Latenzzeit zwischen dem Erfassen der Daten und ihrer Verarbeitung sowie dem eindeutig klaren Eigentum an den Daten, da diese das Werk bzw. das Unternehmen nicht verlassen. Nachteilig ist hingegen die geringe Skalierbarkeit hinsichtlich Speicherplatz und Rechenleistung, wenn eines Tages mehrere Fertigungsschritte analysiert oder Trends über einen langen Zeitraum bestimmt werden sollen. In dem Punkt der Skalierbarkeit bietet das Cloud-Computing hingegen unbegrenzte Möglichkeiten. Nachteilig ist hingegen die Speicherung und Verarbeitung der Daten außerhalb des Werkes bzw. eventuell außerhalb des Unternehmens und die damit einhergehende Frage hinsichtlich Dateneigentum. Zusätzlich ist eine stabile und leistungsfähige Datenübertragung (hohe Bandbreite) über das interne Firmen- als auch über das öffentliche Telekommunikationsnetzwerk notwendig. [BREC17, S. 171–175] Unabhängig von dem gewählten Ort für die Speicherung und Verarbeitung der Daten ist zumeist ein Gateway notwendig, welches die Verbindung zwischen NC-Steuerung und Speichermedium herstellt und die verschiedenen Schnittstellen vereint.

2.3.3 Merkmalsextraktion

Die über die NC-Steuerung bzw. die Achsregler erfassten Istwerte der jeweiligen Fertigungsgrößen stellen bereits von der Sensorik aufbereitete Signale dar. Eine Aufbereitung mittels Filterung oder Verstärkung ist somit nicht mehr notwendig. Die erfassten Istwerte liegen in Zeitreihen vor und werden im Folgenden als Rohdaten bezeichnet. Um diese Rohdaten für einen Großteil der Methoden des maschinellen Lernens nutzbar zu machen, ist es notwendig die Dimension und die Menge der Daten zu reduzieren. Dies geschieht durch das Extrahieren von Merkmalen aus den Rohdaten. Nur die Methoden, die über tiefe Strukturen verfügen, können direkt die

Rohdaten als Input verarbeiten (siehe Kapitel 2.4.1). In Abbildung 2-10 ist der Prozess der Merkmalsextraktion dargestellt. Die Rohdaten, welche im Zeitbereich vorliegen, können zudem in den Frequenzbereich transformiert werden, bevor eine Merkmalsextraktion durchgeführt wird. Die extrahierten Merkmale aus dem Zeit- und Frequenzbereich werden anschließend noch einer Merkmalsselektion unterzogen, um nur die Merkmale mit dem höchsten Informationsgehalt für die weiteren Analysen zu berücksichtigen.

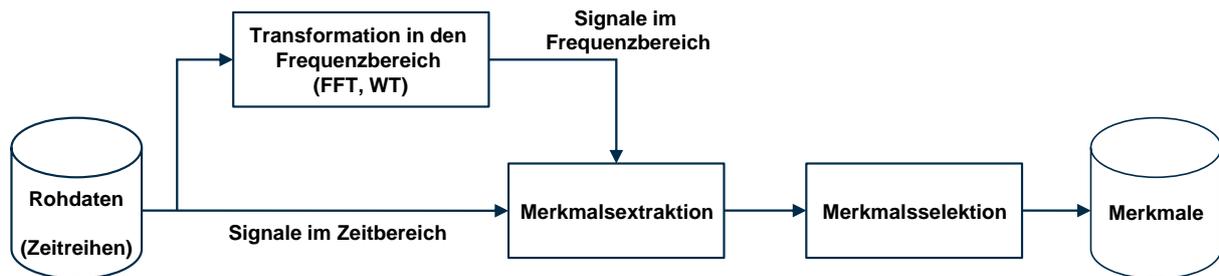


Abbildung 2-10: Ablauf der Gewinnung von Merkmalen aus Rohdaten

Für die Extraktion von Merkmalen existieren zwei verschiedene Vorgehensweisen bzw. Strategien. Sie lassen sich einteilen in eine „manuelle“ Merkmalsextraktion (engl. Feature Engineering) und eine „automatisierte“ Merkmalsextraktion (engl. Feature Learning). [WANG18, S. 146–147; HOPP19, S. 847–848]

Die manuelle Merkmalsextraktion setzt Domänenwissen über den betrachteten Fertigungsprozess sowie die Kenntnis der Berechnungsmethoden der ausgewählten Merkmale voraus. Die Auswahl der Merkmale ist entweder erfahrungsbasiert oder beruht auf den extrahierten Merkmalen eines ähnlichen Fertigungsprozesses. TETI ET AL. empfiehlt für spanende Fertigungsprozesse die Extraktion der Merkmale: arithmetischer Mittelwert, quadratischer Mittelwert, Varianz, Standardabweichung, Schiefe, Wölbung, Minimum-zu-Maximum Amplitude und Crest-Faktor aus dem Zeitbereich der erfassten Rohdaten. Um weitere Informationen aus den erfassten Daten zu gewinnen, kann eine Überführung der Signale aus dem Zeitbereich in den Frequenzbereich z. B. mittels Fast Fourier Transform (FFT) durchgeführt werden. [TETI10, S. 722–724] Zusätzlich ist vor der Berechnung der FFT eine Aufteilung des Zeitsignals in einzelne Abschnitte, die sich überlappen können, möglich. Hierfür eignet sich die Welch Methode, die nach dem Aufteilen des Zeitsignals die spektrale Leistungsdichte (Periodogramm) mittels FFT von jedem Zeitabschnitt berechnet und final aus allen Periodogrammen die gemittelte spektrale Leistungsdichte bestimmt. Die Welch Methode hat zudem den Vorteil, dass sie das Rauschen in der spektralen Leistungsdichte reduziert. [WELC67] Von den transformierten Signalen in dem Frequenzbereich erfolgt ebenso eine Extraktion von Merkmalen. Diese sind zum größten Teil identisch zu den zuvor bereits erwähnten Merkmalen für den Zeitbereich und werden ergänzt um z. B. die Amplitude von dominanten spektralen Spitzen oder die Signal-

stärke in spezifischen Frequenzabschnitten. [TET10, S. 722–724] In der Tabelle 1 sind die Berechnungsformeln der erwähnten Merkmale.

Zeitbereich		Frequenzbereich	
Merkmal	Formel	Merkmal	Formel
arith. Mittelwert	$m = \frac{1}{n} \sum_{i=1}^n x_i$	durchschnittliche spektrale Leistung	$MF = \frac{1}{N} \sum_{i=1}^N Y_i$
quadr. Mittelwert	$m_q = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$	spektrale Energie	$ENE = \sum_{i=1}^N Y_i^2$
Varianz	$var = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$	max. spektrale Leistungsamplitude	$PKM = \max(Y)$
Standardabweichung	$std = \sqrt{var}$	durchschnittliche spektrale Leistung nach Welch	$MBP = \frac{1}{M} \sum_{i=1}^M P_i$
Schiefe	$s = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - m}{std} \right)^3$	Varianz der spektralen Leistung nach Welch	$VBP = \frac{1}{M} \sum_{i=1}^M (P_i - MBP)^2$
Wölbung	$w = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - m}{std} \right)^4$	Schiefe der spektralen Leistung nach Welch	$SkBP = \frac{1}{M} \sum_{i=1}^M \left(\frac{P_i - MBP}{\sqrt{VBP}} \right)^3$
Minimum-zu-Maximum Amplitude	$Ampl = \min(x) - \max(x) $	Wölbung der spektralen Leistung nach Welch	$KuBP = \frac{1}{M} \sum_{i=1}^M \left(\frac{P_i - MBP}{\sqrt{VBP}} \right)^4$
Crest Faktor	$CF = \frac{\max(x)}{m_q}$	max. spektrale Leistungsamplitude nach Welch	$MaxBP = \max(P)$
<p>n: Anzahl der aufgezeichneten Werte eines Signals</p> <p>x_i: Amplitudenwert eines Signals</p>		<p>N: Anzahl der berechneten Werte des Spektrums</p> <p>Y_i: Amplitudenwert des Spektrums</p> <p>M: Anzahl der berechneten Werte des Spektrums nach Welch</p> <p>P_i: Amplitudenwert des Spektrums nach Welch</p>	

Tabelle 1: Formeln zur Berechnung von Merkmalen im Zeit- und Frequenzbereich [BINS09, S. 4730; SARC17, S. 263]

Die zweite Vorgehensweise den Informationsgehalt, der in den Rohdaten steckt, mit möglichst wenigen Merkmalen zu erfassen, besteht in der Anwendung einer automatisierten Merkmalsextraktion. Hierfür ist kein Domänenwissen über den Fertigungsprozess oder die Merkmalsbestimmung erforderlich [HOPP19, S. 847]. Die Extraktion erfolgt mittels vorkonfigurierter Software Paketen (sogenannte Packages), die eine

Vielzahl von verschiedenen Extraktionsmethoden umfassen und oftmals auch eine Merkmalsselektion durchführen. Für die Extraktion von Merkmalen aus Zeitreihen existieren u. a. anderem die zwei Packages `tsfresh` (Time Series FeatuRe Extraction on basis of Scalable Hypothesis tests) [CHRI18] und `TSFEL` (Time Series Feature Extraction Library) [BARA20] für die Programmiersprache Python. Andere Programmiersprachen bzw. Softwareprogramme beinhalten ähnliche Packages.

Zu der Gruppe der automatisierten Merkmalsextraktion gehört auch die Principal Component Analysis (PCA), welche eine klassische Methode zur Dimensionsreduzierung darstellt [TET10, S. 722; HOPP19, S. 849–850]. Mittels einer linearen Transformation werden die Rohdaten von einem hochdimensionalen in einen niedrigdimensionalen Raum überführt, unter Beibehaltung eines Großteils der in den Rohdaten enthaltenen Varianz. Die hierdurch extrahierten Merkmale werden als Principal Components (PCs) bezeichnet. Die PCs werden in absteigender Reihenfolge entsprechend der Varianz, die sie abbilden, gelistet. Nur die obersten PCs werden schließlich für die weitere Analyse berücksichtigt. [KESS07, S. 21 ff.] In dieser Arbeit liegen die Rohdaten in der Form einer Matrix X bestehend aus W Zeilen (Anzahl von Ventilen) und D Spalten (Anzahl von Messpunkten) vor.

$$X = \begin{bmatrix} x_{11} & \cdots & x_{1D} \\ \vdots & \ddots & \vdots \\ x_{W1} & \cdots & x_{WD} \end{bmatrix} \quad (2.8)$$

Diese Matrix wird in eine Matrix Y transformiert, bei der jede Spalte ein Mittelwert von null besitzt. Dies wird erreicht durch die Anwendung der Formel (2.9) für jedes Element der Matrix X .

$$y_{wd} = x_{wd} - \frac{1}{W} * \sum_{w=1}^W x_{wd} \quad (2.9)$$

Von der Matrix Y wird die Kovarianzmatrix berechnet, um die Varianz sowie die Kovarianz von allen Messpunkten zu erhalten.

$$\Sigma = cov(Y) = \begin{bmatrix} \sigma_1^2 & \cdots & \sigma_{1D} \\ \vdots & \ddots & \vdots \\ \sigma_{D1} & \cdots & \sigma_D^2 \end{bmatrix} \quad (2.10)$$

Zudem müssen die Eigenvektoren e_j sowie die Eigenwerte v_j von der Kovarianzmatrix bestimmt werden.

$$\Sigma * e_j = v_j * e_j \quad (2.11)$$

Die Eigenwerte geben den Anteil an der Varianz der Rohdaten wieder, der von dem jeweiligen Eigenvektor repräsentiert wird. Die Eigenvektoren werden in absteigender Reihenfolge entsprechend der Größe ihrer Eigenwerte gelistet. Nur die Eigenvektoren, deren kumulierte Summe der Eigenwerte einen definierten Grenzwert erreicht, stellen die Merkmale (PCs) dar, die für die weiteren Analysen berücksichtigt werden. Der gewählte Grenzwert beschreibt den Anteil an der Varianz der Rohdaten, der von

J PCs mindestens repräsentiert bzw. erreicht werden soll. Die PCs werden berechnet durch:

$$PC_j = Y * e_j^T \quad ; \quad j = 1, \dots, J \quad (2.12)$$

Durch dieses Vorgehen wird die ursprüngliche Ausgangsmatrix der Rohdaten mit der Größe $W \times D$ zu der Merkmalsmatrix mit der Größe $W \times J$ komprimiert. Die PCs sind zudem miteinander unkorreliert, da die Eigenvektoren orthogonal zueinander sind.

2.3.4 Merkmalsselektion

Durch die Merkmalsextraktion wird eine Vielzahl von Merkmalen aus den Rohdaten gewonnen. Eine hohe Anzahl von Merkmalen kann dazu führen, dass eine größere Trainingsdatenmenge als absolut notwendig benötigt wird, um die Methoden des maschinellen Lernens zu trainieren [TET10, S. 725]. Des Weiteren wächst mit der Anzahl der Merkmale auch die Dauer für das Trainieren der Algorithmen und das Erstellen der Prognosen sowie die Gefahr des Auftretens von Overfitting [GUYO06, S. 4–5; SCHN18]. Zudem sinkt die Prognosegenauigkeit, wenn bedeutungslose Merkmale bei der Prognoseerstellung mitberücksichtigt werden [HOPP19, S. 849]. Um diesen Problemen zu entgehen und eine genaue sowie effiziente Prognose zu erhalten, ist es notwendig, die Anzahl von Merkmalen mittels einer Merkmalsselektion zu reduzieren. Ziel ist es, nur noch die Merkmale in die Prognose mit einzubeziehen, welche die Informationen aus den Rohdaten umfassen, die von Bedeutung bzw. signifikant für die Prognose der Zielgröße sind. Eine Merkmalsselektion kann mittels verschiedener Verfahren bzw. Ansätze erfolgen.

Ein Ansatz zur Durchführung der Merkmalsselektion basiert auf der Berechnung der Pearson Korrelation zwischen jedem einzelnen Merkmal und der Zielgröße. Der Korrelationskoeffizient $r_{x,y}$ zwischen einem Merkmal x und der Zielgröße y wird berechnet mit:

$$r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.13)$$

Der Korrelationskoeffizient nimmt Werte zwischen -1 (für eine starke negative Korrelation) und +1 (für eine starke positive Korrelation) an. Die Merkmale, deren Korrelationskoeffizient betragsmäßig einen Wert nahe der Eins annimmt, werden als signifikant für das Prognosemodell angesehen. Die Pearson Korrelation gibt jedoch nur Aufschluss über den linearen Zusammenhang zwischen einem Merkmal und der Zielgröße. Besteht ein starker nichtlinearer Zusammenhang, so kann dies mittels der Pearson Korrelation nicht aufgedeckt werden. Aus diesem Grund wird es als notwendig angesehen, auch Verfahren für die Merkmalsselektion anzuwenden, die einen nichtlinearen Zusammenhang erkennen. [PUHA20, S. 49–50; TET10, S. 725]

Mittels Verfahren, die Transinformationen bzw. gegenseitige Informationen $I(X;Y)$ zwischen einem Merkmal und der Zielgröße bestimmen, ist die Darstellung von nicht-linearen Zusammenhängen möglich. Sind die beiden Variablen (Merkmal u. Zielgröße) voneinander abhängig, dann enthält die eine Variable Informationen, mit denen auf die andere Variable, mit einer gewissen Wahrscheinlichkeit, geschlossen werden kann. Der Wert für $I(X;Y)$ ist immer positiv und steigt mit der Abhängigkeit von den beiden Variablen an. Sind die Variablen voneinander unabhängig, so ist $I(X;Y)$ gleich null. Für den Fall, dass beide Variablen aus kontinuierlichen Werten bestehen, wird $I(X;Y)$ nach der Formel 2.14 berechnet. Es wird angenommen, dass $\log(0)$ gleich null ist.

$$I(X, Y) = \iint p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) dx dy \quad (2.14)$$

Hierbei ist $p(x,y)$ die Verteilungsfunktion sowie $p(x)$ und $p(y)$ die Dichten der stetigen Randverteilungen der beiden Variablen X und Y . Oftmals ist die Verteilungsfunktion jedoch unbekannt oder die erfassten Werte sind nicht kontinuierlich, sondern diskret. In einem solchen Fall kann die Transinformation mittels „Binning“ und der Formel 2.15 näherungsweise berechnet werden.

$$I(X, Y) \approx I_{\text{binned}}(X, Y) \equiv \sum_{ij}^N p(i, j) \log \left(\frac{p(i, j)}{p_x(i)p_y(j)} \right) \quad (2.15)$$

Durch das „Binning“ werden die Daten der Variablen X und Y in eine definierte Anzahl N an Gruppen aufgeteilt. Im Anschluss wird die Anzahl der Daten in jeder Gruppe bestimmt. Wenn $n_x(i)$ [$n_y(j)$] die Anzahl der Daten repräsentiert, die in der i -ten Gruppe der Variable X [in der j -ten Gruppe der Variable Y] sich befindet und $n(i,j)$ die Anzahl der Daten wiedergibt, die sich in der Schnittmenge der beiden Gruppen befindet, dann gelten folgende Abschätzungen: $p_x(i) \approx n_x(i)/N$, $p_y(j) \approx n_y(j)/N$ und $p(i,j) \approx n(i,j)/N$. Die Formel 2.15 konvergiert gegen $I(X, Y)$, wenn N gegen unendlich geht. [KRAS04; ROSS14]

Nach der Berechnung der Pearson Korrelation oder der Transinformation erfolgt für jedes der zwei Selektionsverfahren eine Auflistung der Merkmale in absteigender Reihenfolge gemäß den berechneten Werten. Der Anwender wählt zudem für jedes Selektionsverfahren einen Grenzwert aus, bis zu dessen Wert ein Merkmal noch für die Prognoseerstellung berücksichtigt wird.

2.4 Maschinelles Lernen

Die in den erfassten Daten enthaltenen Informationen sollen mit den Methoden des maschinellen Lernens gewonnen und nutzbar gemacht werden. Um eine richtige Anwendung der Methoden zu ermöglichen, werden in diesem Kapitel zuerst die Grundlagen für das maschinelle Lernen gelegt und anschließend die Funktionsprinzipien der einzelnen Methoden erläutert. Mit den Verfahren zur Prognosevalidierung endet das Kapitel.

2.4.1 Grundlagen des maschinellen Lernens

Maschinelles Lernen (engl. machine learning) ist ein Teilgebiet der künstlichen Intelligenz (engl. artificial intelligence), dessen erstmalige Erwähnung auf die Dartmouth Conference im Jahr 1956 zurückzuführen ist [WELS18, S. 370]. Das Ziel der Konferenz war herauszufinden, wie Maschinen Fähigkeiten erlangen können, die bis dahin nur Menschen vorenthalten waren [MCCA55]. Auf eine Phase voller Euphorie und optimistischen Fehleinschätzungen, was die Entwicklungsgeschwindigkeit der künstlichen Intelligenz betraf, folgte von 1965 bis 1975 eine Zeitspanne, in der die Forschung nahezu pausierte [BUXM19, S. 4]. In den Folgejahren entstand das maschinelle Lernen, das erst mit der Entwicklung von komplexen Algorithmen in den 90er-Jahren an Bedeutung gewann [BUXM19, S. 5; WELS18, S. 370]. Die Grundkonzepte des maschinellen Lernens existierten demnach schon seit längerer Zeit. Jedoch erst durch das Erreichen des benötigten Technologiereifegrades und den richtigen Rahmenbedingungen, hinsichtlich Datenverfügbarkeit, Speicherplatz, Rechenleistung, Leistungsfähigkeit der Algorithmen sowie Zugänglichkeit zu Software, konnte sich das maschinelle Lernen zu der heutigen Form entwickeln [BUXM19, S. 7]. Das Jahr 2010 wird als der Beginn des Zeitalters des maschinellen Lernens angesehen [BUXM19, S. 6]. So zählen als Entwicklungsfortschritte der Sieg des von Google entwickelten Computerprogramms AlphaGo über einen professionellen Go-Spieler im Jahre 2016 [WELS18, S. 370] oder die Reduzierung der Fehlerrate von 30 % auf weniger als vier Prozent innerhalb der Jahre 2010 bis 2016 für das Erkennen von Millionen Bildern der Datenbank ImageNet [BUXM19, S. 9–10]. Dies hat dazu geführt, dass maschinelles Lernen einen Einzug in Anwendungen in Industrie und Wirtschaft sowie im privaten Bereich erhalten hat [WROB12, S. 405]. Das maschinelle Lernen umfasst Methoden, die mittels Lernprozessen Zusammenhänge in einer Menge von Daten erkennen können, um dann Prognosen auf Basis des Gelernten zu treffen [BUXM19, S. 8; WELS18, S. 370]. Eine Maschine bzw. vielmehr ein Algorithmus erhält die Fähigkeit, gewisse Aufgaben selbstständig zu erlernen, indem er auf der Basis von Daten trainiert wird, ohne ihn explizit zu programmieren [MITC97, S. 2]. Diese Eigenschaft entfaltet ihr volles Potential besonders bei sehr komplexen Anwendungen, für die das Programmieren jeder einzelnen Beziehung viel zu aufwendig wäre bzw. die Zusammenhänge nicht vollständig erkannt und beschrieben werden können. In dieser Arbeit existiert eine solche Komplexität zwischen dem betrachteten Zerspanungsprozess, der aufgrund diverser Effekte nicht vollständig ana-

lytisch beschrieben werden kann, und der erzeugten Werkstückqualität. Demnach ist das maschinelle Lernen ein geeignetes Verfahren, um das Ziel einer Qualitätsprognose auf der Basis von Fertigungsdaten zu erzielen. Die Methoden des maschinellen Lernens lassen sich in drei Kategorien einteilen: überwachtes Lernen (engl. supervised learning), unüberwachtes Lernen (engl. unsupervised learning) und verstärkendes Lernen (engl. reinforcement learning).

Das überwachte Lernen ist die am meisten angewandte und erforschte Kategorie von maschinellen Lernverfahren. Der verwendete Algorithmus bekommt zum Training einen Datensatz, bei dem die Eingabewerte sowie die dazugehörigen Ausgabewerte vorliegen. Die Zusammenhänge zwischen den Eingabe- und Ausgabewerten sollen dann von dem Algorithmus erkannt und gelernt werden. Nachdem das Training abgeschlossen ist, prognostiziert der Algorithmus für einen ihm bisher unbekanntem Datensatz von Eingabewerten die zugehörigen Ausgabewerte. Das Ziel des überwachten Lernens ist das Erreichen einer möglichst präzisen Prognose. [WROB12, S. 405]

Bei dem unüberwachten Lernen beinhaltet der Trainingsdatensatz keine Ausgabewerte, sondern er besteht ausschließlich aus Eingabewerten. Der eingesetzte Algorithmus hat die Aufgabe, bisher unbekannte Zusammenhänge, Struktur und Muster aufzuzeigen. Somit ist das unüberwachte Lernen eher von deskriptiver Natur. [WROB12, S. 405]

Die letzte Kategorie umfasst das verstärkende Lernen, welches die Aufgabe hat, für ein bestehendes Problem eine möglichst optimale Lösungsstrategie zu finden. Der Algorithmus erlernt mittels Belohnung und Bestrafung über eine lange Folge von Handlungen die optimalste Lösung für die zu lösende Aufgabe. [WROB12, S. 406; BUXM19, S. 11]

Die Methoden des maschinellen Lernens, die zu der Kategorie des überwachten Lernens zählen, sind von allen aufgeführten Kategorien am stärksten in der industriellen Fertigung vertreten. In Abhängigkeit von der zu prognostizierenden Zielvariable und des zu lösenden Problems werden die Methoden in Regressionsprobleme und Klassifikationsprobleme weiter unterteilt. Es handelt sich um ein Regressionsproblem, wenn die zu prognostizierende Zielvariable eine reelle Zahl darstellt. Ein Klassifikationsproblem besteht dann, wenn die Zielvariable einen diskreten Wert annimmt. In dieser Arbeit kommen ausschließlich überwachte maschinelle Lernverfahren zum Einsatz und die zu prognostizierenden Zielvariablen sind reelle Zahlen, sodass es sich um Regressionsprobleme handelt. An dieser Konstellation orientieren sich die folgenden Unterkapitel und erläutern das notwendige Wissen für die Anwendung des maschinellen Lernens.

Das Trainieren eines Algorithmus sowie das Testen seiner Prognosegenauigkeit erfolgt mittels sogenannter Trainings- und Testsätze. Dies werden von dem ursprünglichen verfügbaren Datensatz erstellt, indem dieser in zwei Datensätze aufgeteilt wird. Ein Verhältnis von 70–80 % Trainingsdaten zu 30–20 % Testdaten hat sich hierfür bewährt. In den meisten Fällen wird nach dem Trainieren des Algorithmus eine Vali-

dierung der Prognosegenauigkeit mit den zurückgehaltenen Testdaten durchgeführt. [WELS18, S. 371] Es ist aber auch möglich, weitere neue Daten zu erfassen und damit eine Validierung durchzuführen.

2.4.2 Methoden des maschinellen Lernens

Es existiert eine Vielzahl von verschiedenen Methoden bzw. Algorithmen des maschinellen Lernens. Nach dem No-Free-Lunch Theorem existiert kein Algorithmus, der jedes Problem gleichgut zu lösen vermag. Die Anwendungsfälle sowie die möglichen Daten sind in der realen Welt so vielfältig und unterschiedlich, sodass es zu der Entwicklung der vielen verschiedenen Algorithmen gekommen ist und stets weitere Algorithmen erforscht werden [WOLP97, S. 67; MURP12, S. 24–25]. GEORG BOX beschreibt es mit dem folgenden Satz sehr zutreffend:

„All models are wrong, but some models are useful. So the question you need to ask is not "Is the model true?" (it never is) but "Is the model good enough for this particular application?"“ [BOX09, S. 61]

Anhand der Struktur der bisher entwickelten Algorithmen werden diese in die zwei Gruppen Shallow Structure (flache Strukturen) und Deep Structure (tiefe Strukturen) eingeteilt. Algorithmen mit flachen Strukturen setzen eine Datenaufbereitung der Rohdaten in der Form einer Merkmalsextraktion (siehe Kapitel 2.3.3) voraus. Die erreichte Prognosegenauigkeit ist stark von den extrahierten Merkmalen abhängig und somit auch oftmals von den fachlichen Fähigkeiten und dem problemspezifischen Wissen der Person, die die Merkmale auswählt. Diese Gruppe von Algorithmen hat jedoch den Vorteil, dass sie im Vergleich zu den Deep Structure Algorithmen eine geringere Anzahl von Trainingsdaten sowie eine deutlich geringere Rechenleistung für das Trainieren und Prognostizieren benötigt. Die Deep Structure Algorithmen lernen auf der Basis der Rohdaten und extrahieren selbstständig die benötigten Merkmale, somit ist es möglich, eine Prognose direkt von einer Zeitreihe oder einem Bild zu erhalten, ohne spezifische Kenntnisse über die Rohdaten zu besitzen. Der Nachteil dieser Methoden ist der bereits erwähnte hohe Bedarf an Trainingsdaten und Rechenleistung. [WANG18, S. 146–148] Alle Methoden haben gemein, dass sie als Black-Box Modelle angesehen werden können und oftmals keine Rückschlüsse liefern, weshalb sie zu einer bestimmten Entscheidung gekommen sind [MURP12, S. 585; WELS18, S. 378]. Dies ist zu beachten, falls nicht nur eine Prognose oder Entscheidung von finaler Bedeutung ist, sondern auch der Weg bzw. die Einflüsse, die zu dem Ergebnis geführt haben, benötigt werden.

Jede Methode des maschinellen Lernens verfügt über eine gewisse Anzahl von Parametern, sogenannte Hyperparameter, mit denen diese auf den Anwendungsfall so angepasst werden kann, dass sich der Prognosefehler reduziert. Die besten Werte und Kombinationen der Parameter müssen individuell für jeden Anwendungsfall durch Ausprobieren ermittelt werden. Dieses Vorgehen gleicht dem einer statistischen Versuchsplanung (Design of Experiments), jedoch bedarf es keiner physikalischen Versuche oder Experimente, sondern lediglich des Trainierens und Testens

des Algorithmus mit veränderter Parameterkombination auf einer gleichbleibenden Datenbasis. Im maschinellen Lernen haben sich hierfür die beiden Verfahren Grid Search und Random Search etabliert. Bei der Grid Search werden feste Werte für jeden Parameter definiert und jede Kombination, die sich aus den Parametern und ihren Werten ergibt, wird getestet. Die Kombination, die für den betrachteten Anwendungsfall die höchste Prognosegenauigkeit erzielt, wird schließlich für das Prognosemodell beibehalten. Bei der Random Search werden keine festen Werte, sondern Intervalle für jeden Parameter sowie eine Anzahl von Iterationsschritten festgelegt. Per Zufallsprinzip erfolgt eine Auswahl der Parameterwerte und im Anschluss wird die Prognosegenauigkeit bestimmt. Die zufällig ausgewählte Kombination von Parameterwerten, die zu der höchsten Prognosegenauigkeit führt, wird beibehalten. Beide Verfahren sind in der Lage, mit vertretbarem Rechen- und Zeitaufwand eine sehr gute Parameterkombination zu finden, die jedoch nicht zwangsläufig die optimalste Kombination sein muss. Mittels der Random Search kann oftmals in kürzerer Zeit eine sehr gute Kombination bestimmt werden. Zudem ermöglichen die Intervalle auch eine größere Kombinationsvielfalt. [KRAU18, S. 49; SWAM19, S. 314–316]

Im Folgenden werden Methoden des maschinellen Lernens vorgestellt, die zu der Gruppe der Shallow Structure Algorithmen gehören und zur Lösung von Regressionsproblemen eingesetzt werden können.

Das künstliche neuronale Netz (KNN) beruht auf dem Vorbild eines Netzwerkes aus Nervenzellen des Gehirns von Menschen und Tieren. Das Lernen wird beim KNN mittels mathematischer Funktionen nachgebildet. Es setzt sich aus einzelnen Schichten von künstlichen Neuronen zusammen, die von Schicht zu Schicht miteinander verbunden sind (siehe Abbildung 2-11). Über die Eingabeschicht werden die erfassten Daten in das Netz eingegeben und jeder Eingangsvariable wird ein Neuron zugeordnet. Darauf folgt eine verdeckte Schicht. Diese verdeckte Schicht besteht aus mindestens einer Schicht von Neuronen, kann jedoch auch eine Vielzahl von Schichten enthalten. Jede Schicht besteht wiederum aus einer Anzahl von Neuronen. Das KNN schließt mit der Ausgabeschicht ab, die für jede zu prognostizierende Zielvariable ein Neuron beinhaltet und das Prognoseergebnis ausgibt. Jedes Neuron verfügt über eine Aktivierungsfunktion, die das Neuron aktiviert, sobald der Aktivierungsgrad erreicht wurde. Alle Signale, die über die Verbindungen in das Neuron eingehen, werden zu einem Eingabewert verdichtet und entsprechend der Aktivierungsfunktion wird das Neuron entweder aktiviert oder bleibt deaktiviert. Im Falle einer Aktivierung leitet das Neuron ein neues Signal weiter. Ziel des KNN ist es nun, durch einen Lernprozess die Neuronen so zu aktivieren, dass auf der Basis der Eingangsvariablen die zu prognostizierenden Zielvariablen möglichst genau abgebildet werden. Die Anpassung eines KNN an einen Anwendungsfall kann über diverse Parameter erfolgen. Diese sind z. B. die Anzahl der Neuronen pro verdeckter Schicht sowie die Anzahl der verdeckten Schichten, die Art der Aktivierungsfunktion, der Aktivierungsgrad, die Funktion für das Zusammenfassen der Eingangssignale, der Wert, mit dem ein Signal eines Neurons gewichtet wird, sowie die Anzahl von Iterationen oder die zu erreichende Prognosegenauigkeit, bis das Lernen beendet wird. Dies führt dazu,

dass eine große Menge an Trainingsdaten vorliegen muss, um ein valides Modell zu erhalten. [RUNK15, S. 72–76; BACK16, S. 604–605]

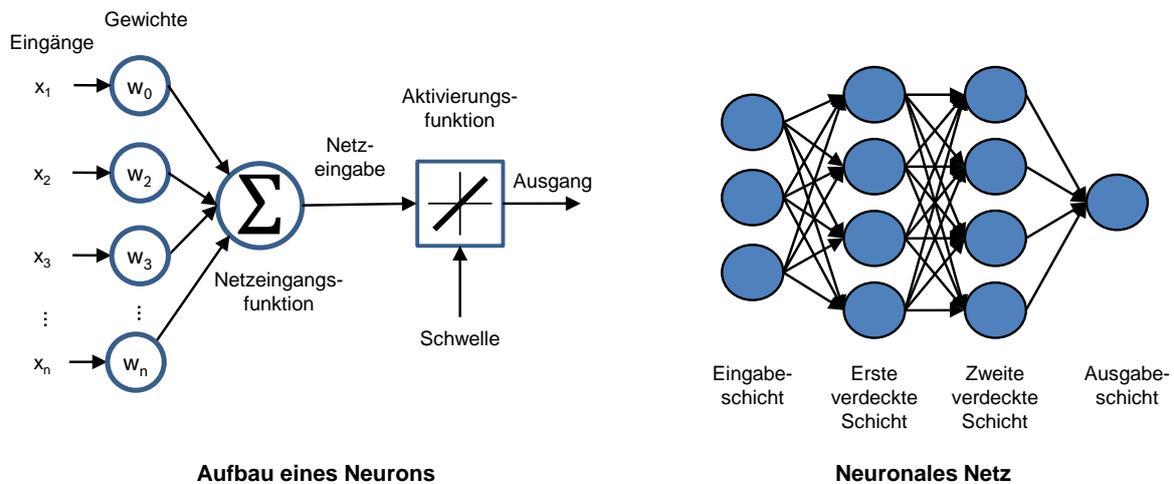


Abbildung 2-11: Aufbau eines künstlichen Neurons und Zusammenschluss zu einem neuronalen Netz

Eine Support Vector Machine (SVM) für ein Regressionsproblem (SVR) ist ein Algorithmus, der die Eingangsdaten mittels Stützvektoren (Supportvektoren) in einen höherdimensionalen Raum überführt, wo sie linear trennbar sind. Das Ziel bei der Nutzung einer SVM für ein Regressionsproblem besteht darin, eine Funktion $y(x)$ zu finden, deren Prognoseabweichungen kleiner als ϵ sind. ϵ stellt den Raum einer Hüllkurve um die Funktion dar, in dem die Prognosen liegen dürfen (siehe Abbildung 2-12). Prognosen außerhalb dieser Hüllkurve sollen nach Möglichkeit verhindert werden, indem die Funktion angepasst wird. Die Komplexität (Dimension) der ermittelten Funktion soll dabei möglichst niedrig sein. Bei der Bestimmung der Funktion ist ein Kompromiss einzugehen zwischen der Komplexität der Funktion und dem zulässigen Prognosefehler ϵ . [MAIM05, S. 266–268; MURP12, S. 496–498]

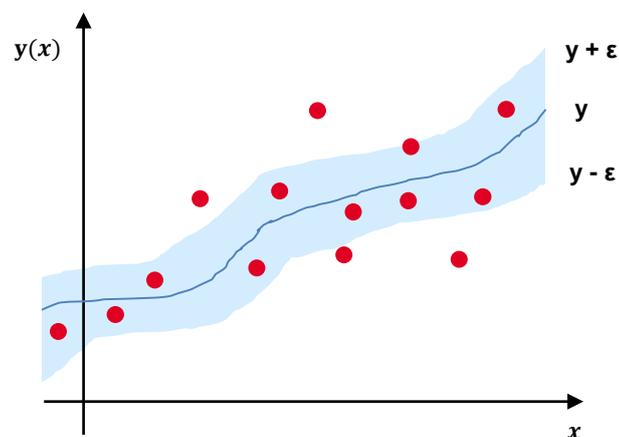


Abbildung 2-12: Darstellung des ϵ -Raums einer SVM Regression im Zweidimensionalen

Das Extrahieren von Wissen aus Daten mittels eines Entscheidungsbaums (EB) ist ein sehr praktisches, effizientes, schnelles und zugleich recht einfaches Verfahren aus dem Gebiet des maschinellen Lernens. Die von einem Baum gelernten bzw. abgeleiteten Entscheidungsregeln sind in der Form von Knoten und gerichteten Graphen visualisierbar und ergeben eine Baumstruktur (siehe Abbildung 2-13). Somit kann das Zustandekommen einer Prognose von einem Menschen leicht nachvollzogen und kontrolliert werden. Der Startknoten eines Baumes wird als Wurzel bezeichnet und die Knoten, die nicht weiter verzweigt werden, tragen den Namen Blätter. Die Entstehung eines Entscheidungsbaumes sowie die Prognosebestimmung werden im Folgenden für einen binären Baum erläutert. Ziel ist es, passende Entscheidungsregeln zu bestimmen, die eine Prognose der gesuchten Zielgröße auf der Basis der Eingangsdaten ermöglichen. Hierfür werden die Trainingsdaten in einem Knoten auf der Basis eines berechneten Schwellenwertes in zwei neu entstehende Knoten so aufgeteilt, dass sie möglichst gut durch eine Konstante in jedem der beiden Knoten approximiert werden. Auf die Teilmengen in den beiden Knoten wird das Prozedere erneut angewendet und somit weitere Unterknoten erschaffen. Dieses Vorgehen wird solange wiederholt, bis ein Abbruchkriterium erfüllt wird. Dieses kann z. B. eine zu verbleibende Mindestanzahl von Trainingsdaten pro Knoten, eine maximal zulässige Tiefe des Baumes (Anzahl von Knotenschichten) oder ein Unterschreiten einer Varianzschranke eines Knoten (Streuung der Trainingsdaten in einem Knoten) sein. Erfolgt keine Begrenzung des Baumes, so kann dies zu einem Over Fitting führen, welches eine schlechte Generalisierbarkeit des trainierten Baumes verursacht. Ein Zurückschneiden (engl. pruning) des Baumes wird im Falle eines Over Fittings notwendig und ein Kompromiss zwischen der Berücksichtigung der Varianz der Trainingsdaten und der Generalisierbarkeit des Baumes ist zu finden. [PETE05, S. 182,186; RICH19, S. 163–167; JOSH20, S. 56]

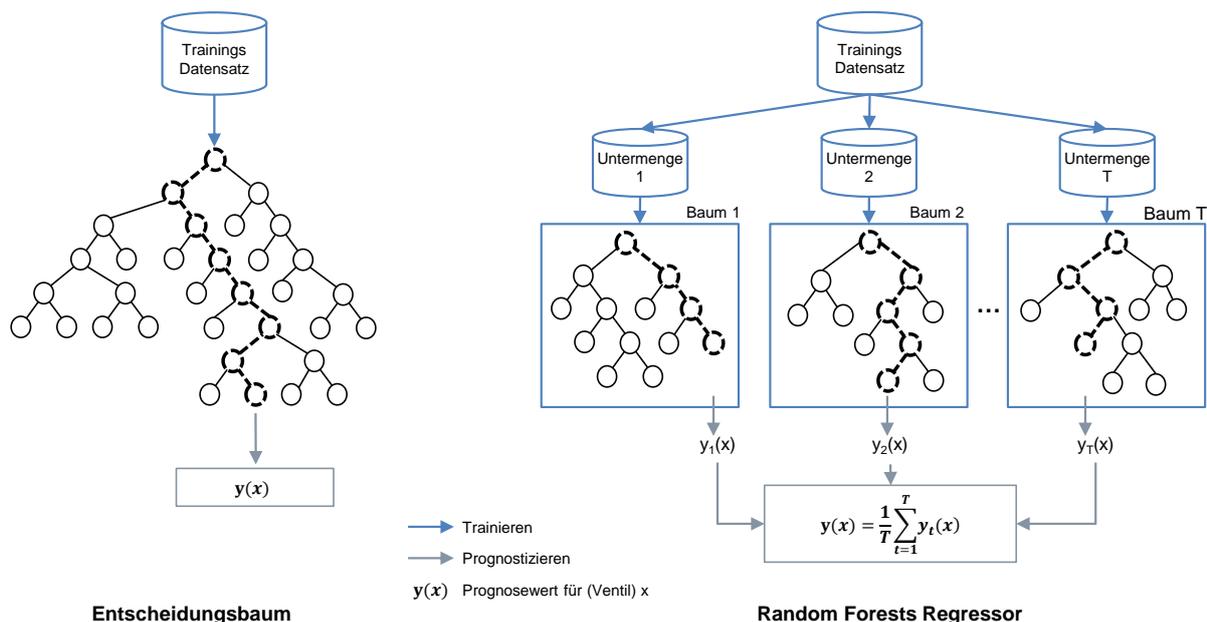


Abbildung 2-13: Aufbau und Funktionsprinzip des EB und RFR

Der Einsatz eines Entscheidungsbaums kann oft zu guten Ergebnissen führen. Die Prognosegenauigkeit und die Robustheit kann jedoch oftmals erhöht werden, wenn eine Vielzahl von Bäumen erzeugt wird und diese zu einem Prognosemodell zusammengefasst werden. Diese Klasse von Prognosemodellen wird als Ensemble Methode bezeichnet. Eine Ensemble Methode setzt sich aus sogenannten Weak Learner (z. B. Entscheidungsbäume) zusammen, die jeweils nur einen bestimmten Zusammenhang in den Trainingsdaten abbilden. Das Zusammenfassen und Mitteln der Prognoseergebnisse aller involvierten Weak Learner führt zu einer höheren Prognosegenauigkeit und zu einer Reduktion des Overfittings. [JOSH20, S. 60] Die in dieser Arbeit eingesetzten Ensemble Methoden sind der Random Forests Regressor (RFR) und der Gradient Boosting Regressor (GBR).

Random Forests ist eine Methode des maschinellen Lernens, welche von BREIMAN entwickelt wurde [BREI01]. In dieser Arbeit wird sie für ein Regressionsproblem eingesetzt, sodass sie als Random Forests Regressor (RFR) bezeichnet wird. Die Methode setzt sich aus einer Anzahl von Entscheidungsbäumen zusammen, die von dem Anwender bestimmt werden muss. Jeder einzelne Entscheidungsbaum wird auf einer zufällig ausgewählten Untermenge des kompletten Trainingsdatensatzes entwickelt (siehe Abbildung 2-13). Das Erzeugen der Untermenge wird als Bagging oder auch als Bootstrap Aggregation bezeichnet und ist eine bedeutende Charakteristik des RFR. Es reduziert deutlich die Gefahr des Overfittings und macht das Zurückschneiden (pruning) der Bäume überflüssig. Zudem ist die Methode sehr robust gegen Ausreißer bei den Inputdaten. Für die Aufspaltung eines Knoten wird erneut nur eine Untermenge der in dem Knoten verfügbaren Trainingsdaten berücksichtigt und das Merkmal für die Aufspaltung ausgewählt, welches den Prognosefehler für den jeweiligen Knoten minimiert. Dies führt dazu, dass die einzelnen Bäume voneinander unabhängig sind und parallel entwickelt werden können. Ein Ast des Baumes wird solange entwickelt, bis keine Trainingsdaten mehr zum Aufspalten des Knoten verfügbar sind, eine zu verbleibende Anzahl von Trainingsdaten in einem Knoten erreicht ist oder ein zulässiger Prognosefehler unterschritten wurde. Dies wird für jeden Baum angewendet und nachdem alle Bäume entwickelt wurden, kann die gewünschte Zielgröße mit dem RFR prognostiziert werden. Das Prognoseergebnis ist schließlich der Mittelwert der Prognosen der einzelnen Bäume. [BIAU12, S. 1063–1065; CUTL12, S. 157–164; JOSH20, S. 61] Aufgrund der Bedeutung des RFR für diese Arbeit ist das Funktionsprinzip der Baumentwicklung in Kapitel 2.4.3 anhand eines Beispiels detaillierter erläutert.

Eine auf Entscheidungsbäumen ebenso basierende Methode ist der Gradient Boosting Regressor (GBR). Der GBR unterscheidet sich von dem RFR durch das verwendete Boosting Verfahren. Hierbei werden die einzelnen Entscheidungsbäume nicht parallel erzeugt, sondern nacheinander und unter Berücksichtigung der Prognosegenauigkeit der vorherigen Bäume. Zudem prognostizieren die Entscheidungsbäume nicht den Zielwert, sondern den Prognosefehler. Ausgehend von einem Startwert und den Prognosefehlern der Bäume wird der gesuchte Zielwert berechnet. Der erste Baum wird wie beim RFR von einer zufällig erstellten Untermenge des

Trainingsdatensatzes erzeugt. Der zweite Baum ist von der Prognosegenauigkeit des ersten Baumes abhängig und es werden nun die Trainingsdaten stärker berücksichtigt, für die der erste Baum schlechte Prognosewerte erzielt hat. Dieses Vorgehen wird für die folgenden Bäume wiederholt. Aus diesem Grund muss das Training nacheinander ablaufen, was die Trainingsdauer verlängert. Mit jedem hinzugefügten Baum konvergiert das Prognoseergebnis gegen den wahren Wert, was einem Gradientenverfahren gleichkommt. [JOSH20, S. 62–63; MURP12, S. 554–555] Eine Darstellung des Funktionsprinzips erfolgt anhand von Beispieldaten in dem Kapitel 2.4.3.

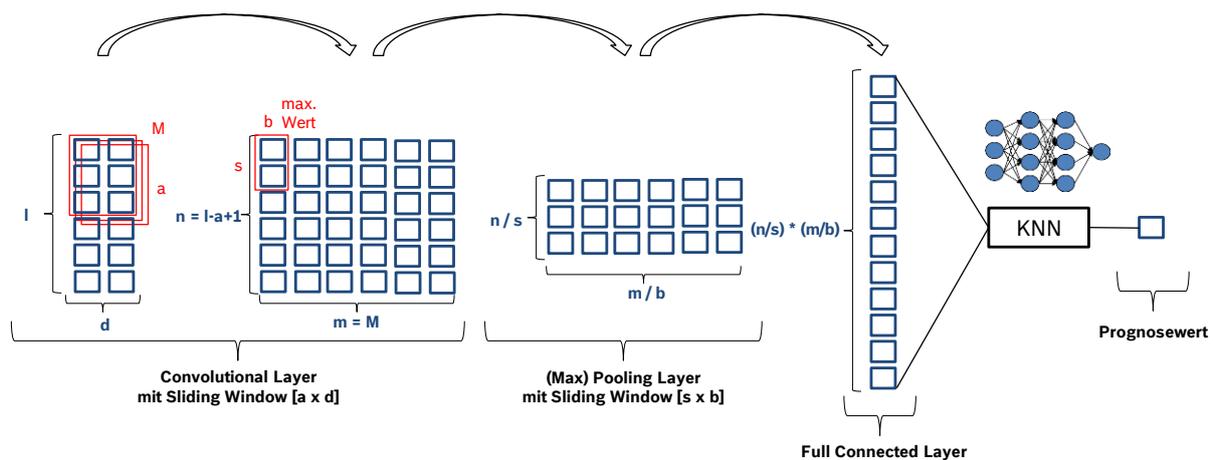


Abbildung 2-14: Schematische Darstellung des Funktionsprinzips eines CNN

Die bis dahin aufgeführten Methoden des maschinellen Lernens verfügen über Algorithmen mit flachen Strukturen. Das Convolutional Neural Network (CNN) hingegen extrahiert die benötigten Merkmale selbstständig aus den Rohdaten und zählt somit zu den Algorithmen mit tiefen Strukturen. Ein CNN ist ein vielschichtiges KNN, welches Rohdaten verarbeiten kann, die zweidimensional (z. B. Bild) oder eindimensional (z. B. Zeitreihe) sind. Aufgrund der zu verarbeitenden Zeitreihen in dieser Arbeit ist es für den Anwendungsfall geeignet. Bestandteile eines CNN sind die Convolutional Layer, die Pooling Layer sowie der Fully Connected Layer. Die Convolutional Layer extrahieren Merkmale aus den Rohdaten, indem sie entsprechende Filtermethoden anwenden. Von den extrahierten Merkmalen werden mittels der Pooling Layer die signifikantesten Merkmale innerhalb des Betrachtungsbereiches (Sliding Window) bestimmt, z. B. der Maximalwert. Hierdurch wird eine Reduktion der Merkmale bewirkt. Die Kombination aus Convolutional und Pooling Layer kann erneut auf die erhaltene Matrix mit den signifikantesten Merkmalen angewendet werden. Letztendlich erfolgt über den Fully Connected Layer eine Transformation der Matrix in einen Spaltenvektor. Dieser Spaltenvektor dient dann als Input für eine Methode des maschinellen Lernens mit flacher Struktur, oftmals ein KNN. [WANG18, S. 147–148] In Abbildung 2-14 ist ein CNN mit einem Convolutional, einem Pooling und einem Full Connected Layer abgebildet. Die Rohdaten stammen von d Datenquellen (z. B. Anzahl der Fertigungsgrößen) und besitzen die Länge l (z. B. Dauer einer Aufzeich-

nung). Auf diese Daten wird ein Filter angewandt, dessen Sliding Window die Größe $a \times d$ besitzt und insgesamt M Merkmale extrahiert. Auf die neu entstehende Matrix der Größe $n \times m$ wird ein Pooling Layer angewandt, der jeweils nur die Maximalwerte berücksichtigt und ein Sliding Window der Größe $s \times b$ hat. Die hieraus entstehende Matrix wird in einen Spaltenvektor umgewandelt und beinhaltet die Eingangsdaten für ein KNN.

2.4.3 Random Forest Regressor und Gradient Boosting Regressor

Aufgrund der besonderen Bedeutung der Methoden RFR und GBR für die Qualitätsprognose in dieser Arbeit wird deren Funktionsweise jeweils anhand eines Beispiels näher erläutert sowie verdeutlicht. Die in Kapitel 2.4.2 bereits gegebene Beschreibung der Methoden wird hierdurch detailliert und um ein fiktives Beispiel ergänzt. Die zugrundeliegenden mathematischen Formeln können für den RFR unter [CUTL12, S. 157–161] und für den GBR unter [MURP12, S. 560–561] nachgelesen werden.

Bei dem RFR (siehe Abbildung 2-13) besteht der Trainingsdatensatz $D = \{(x_i, y_i), i = (1, \dots, I)\}$ aus I einzelnen Trainingsdaten. Hierbei umfasst x_i die Menge k an Merkmalen [$x_i = (x_{i1}, \dots, x_{ik})$], welche die Inputgrößen darstellen, und y_i repräsentiert die Zielgröße (im späteren Verlauf die zu prognostizierende Größe). Aus diesem Trainingsdatensatz wird für jeden zu entwickelnden Baum T_j eine Untermenge D_j mit S Trainingsdaten erzeugt. In dem präsentierten Beispiel wird nun angenommen, dass der Trainingsdatensatz D aus insgesamt 10 Trainingsdaten [$I = 10$] besteht und dass jede Trainingsdateneinheit i sechs Merkmale [$k = 6$] und eine Zielgröße y beinhaltet. Dieser Trainingsdatensatz ist in Abbildung 2-15 unter I abgebildet. Im nächsten Schritt wird die Untermenge (D_1) erstellt, mit der der erste Baum (T_1) erzeugt wird. Das Erstellen der Untermenge wird als „Bagging“ bezeichnet. In diesem Beispiel soll die Untermenge 60 % der Daten des Trainingsdatensatzes enthalten, sodass aus der zugrundeliegenden Gesamtmenge $I = 10$ des Trainingsdatensatzes durch zufälliges Ziehen eine Untermenge der Größe $S = 6$ erzeugt wird. Alle nicht berücksichtigten Trainingsdaten sind in der Grafik II der Abbildung 2-15 mit grauen horizontalen Balken überdeckt. Nachdem die Untermenge feststeht, kann der erste Split (Knoten) des Baumes erzeugt werden. Für die Durchführung des Splits wird wiederum nur eine Teilmenge der Merkmale betrachtet. In diesem Fall wird \sqrt{k} zur Reduzierung der Merkmalsanzahl gewählt, was in diesem Zahlenbeispiel $\sqrt{6} = 2,4 \approx 2$ Merkmalen entspricht. Diese zwei Merkmale werden erneut zufällig aus den existierenden sechs Merkmalen gezogen. Die nicht zu berücksichtigenden Merkmale sind in der Grafik II ausgegraut. Die Grafik III zeigt schließlich den Datensatz auf, mit dem der erste Split durchgeführt wird.

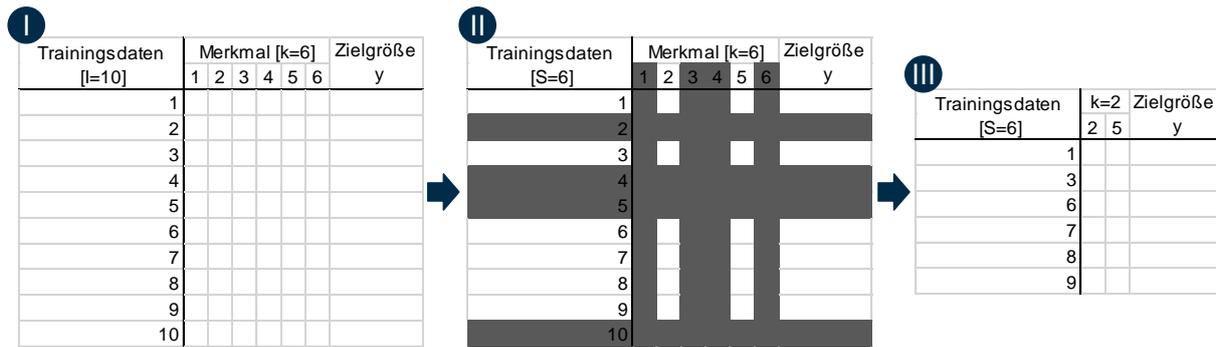


Abbildung 2-15: Trainingsdatensatz D (I), Untermenge D_1 mit Trainingsdaten zur Erzeugung eines Baumes (II) und Trainingsdaten zur Erzeugung eines Knotens (III)

Ziel ist es nun, ein Merkmal und den zugehörigen Merkmalswert (bzw. Intervallmitte-Wert) zu identifizieren, für die der durchgeführte Split den kleinsten Prognosefehler (hier: quadratischer Fehler) hervorbringt. Der Split teilt die Untermenge D_1 in zwei neue Knoten (Knoten links und Knoten rechts) auf. In der Ausgangsbedingung ergibt sich der betrachtete Knoten mit seinen beiden Unterknoten wie in der Abbildung 2-16 dargestellt. Bekannt ist der Prognosefehler (MSE), die Anzahl der Trainingsdaten $S=6$ und der Prognosewert \hat{y} für die Zielgröße y . Zu bestimmen ist das Merkmal und der Intervallmitte-Wert für die Durchführung des Splits.

$$\text{Prognosewert: } \hat{y} = \frac{1}{S} \sum_{j=1}^S y_j \tag{2.16}$$

$$\text{Prognosefehler: } MSE = \frac{1}{S} \sum_{j=1}^S (y_j - \hat{y})^2 \tag{2.17}$$

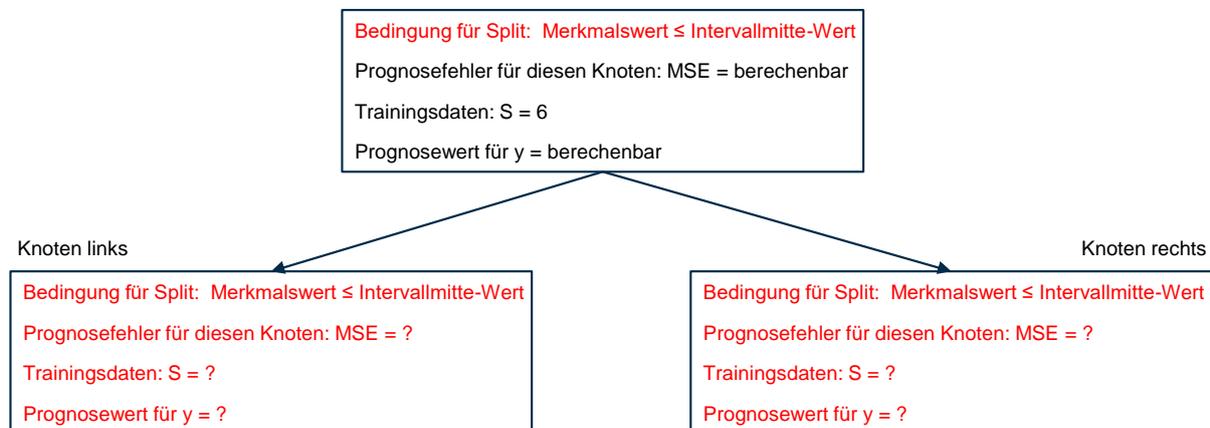


Abbildung 2-16: Ausgangszustand für die Bestimmung des ersten Splits (bekannte Größen sind in schwarz, unbekannte Größen sind in rot dargestellt)

Der Split wird für das Merkmal durchgeführt, welches die Summe der Prognosefehler der beiden entstehenden Knoten minimiert. Demnach ist die folgende Gleichung zu erfüllen:

$$MSE_{Split} = MSE_L + MSE_R \rightarrow \min \quad (2.18)$$

Mit:

$$MSE_L = \frac{1}{S_L} \sum_{j=1}^{S_L} (y_{jL} - \hat{y}_L)^2 \quad ; \quad \hat{y}_L = \frac{1}{S_L} \sum_{j=1}^{S_L} y_{jL} \quad (2.19)$$

$$MSE_R = \frac{1}{S_R} \sum_{j=1}^{S_R} (y_{jR} - \hat{y}_R)^2 \quad ; \quad \hat{y}_R = \frac{1}{S_R} \sum_{j=1}^{S_R} y_{jR} \quad (2.20)$$

Hierbei ist S_L die Anzahl der Trainingsdaten, welche aufgrund der Bedingung „Merkmalswert \leq Intervallmitte-Wert“ zum linken Knoten übergehen und dort dann den neuen Datensatz S bilden. Die Trainingsdaten des rechten Knoten erfüllen die Bedingung „Merkmalswert \geq Intervallmitte-Wert“.

Das Merkmal und der zugehörige Intervallmitte-Wert, die die oben aufgeführte Gleichung (Prognosefehler) minimieren, werden wie folgt bestimmt:

1. Das erste Merkmal wird ausgewählt. (Hier: Merkmal 2, siehe Abbildung 2-17)
2. Die Merkmalswerte werden der Größe nach sortiert. Die Reihenfolge der Datensätze kann sich hierdurch ändern. (Hier: Es wird angenommen, dass die Merkmalswerte bereits der Größe nach sortiert sind.)
3. Die Intervallmitte-Werte von zwei nebeneinanderliegenden Merkmalswerten werden bestimmt. (Hier: Es entstehen 5 Intervallmitte-Werte: 1-3, 3-6, 6-7, 7-8, 8-9. Für die fiktiven Merkmalswerte des Merkmals 2 ergeben sich die Intervallmitte-Werte demnach zu: 0,5; 1; 2; 3,5; 4,5.)

Trainingsdaten [S=6]	k=2		Zielgröße
	2	5	y
1	0		
3	1		
6	1		
7	3		
8	4		
9	5		

(0+1)/2 = 0,5
1
2
3,5
4,5

Abbildung 2-17: Bestimmung der Intervallmittel-Werte für jedes Merkmal

4. Für jeden berechneten Intervallmitte-Wert wird ein Split durchgeführt, indem die Trainingsdaten S entsprechend der Bedingung „Merkmalswert \leq Intervallmitte-Wert“ auf den linken und rechten Knoten verteilt werden. Zudem wird MSE_{Split} für jeden der Intervallmitte-Werte (hier: 5) berechnet.
5. Jedes der verbliebenen Merkmale durchläuft die Schritte eins bis vier.
6. Das Merkmal und der zugehörige Intervallmitte-Wert werden ausgewählt, welche den niedrigsten MSE_{Split} Wert haben.
7. Der Split wird durchgeführt und es werden die beiden neuen Knoten (Knoten links und Knoten rechts) erzeugt.
8. Die Anzahl der Trainingsdaten S_L und S_R sind nun bekannt und es können die Prognosewerte sowie die Prognosefehler in den Knoten bestimmt werden (siehe Abbildung 2-18).

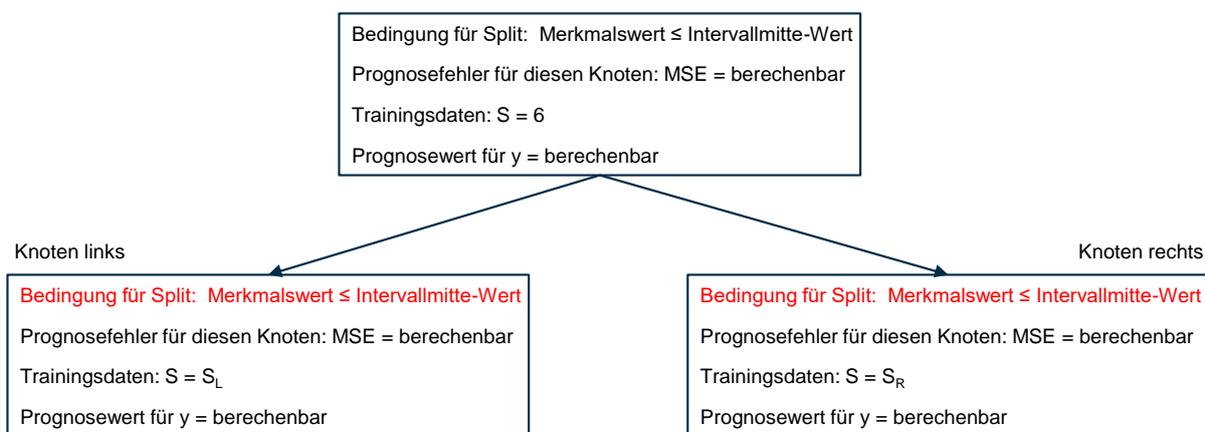


Abbildung 2-18: Zustand nach der Durchführung des ersten Splits

Die Trainingsdaten S_L und S_R verfügen jeweils über die volle Anzahl von Merkmalen (hier: 6 Stück). Sie sind lediglich eine Aufteilung der ursprünglichen Untermenge D_1 (hier: $S = 6$). In Abhängigkeit von den gewählten Grenzen für die minimale Anzahl von Trainingsdaten S pro Knoten oder dem maximal zulässigen Prognosefehler MSE pro Knoten werden weitere Splits durchgeführt (erzeugte Knoten werden weiter aufgeteilt). Weitere Splits werden erzeugt, indem die hier beschriebenen Schritte erneut durchgeführt werden. Auf diese Weise wird jeder einzelne Baum in der RFR Methode erzeugt.

Bei der RFR Methode werden die Bäume parallel und unabhängig voneinander erzeugt. Dies ist ein bedeutender Unterschied zu der GBR Methode, bei der die Bäume nacheinander und unter Berücksichtigung der Prognosefehler der bereits existierenden Bäume erstellt werden. Die Bäume werden wie bei der RFR Methode erstellt. Der Anwender entscheidet jedoch, ob ein Baum auf der Basis von allen verfügbaren Datensätzen erstellt wird oder ob das „Bagging“ und die nur teilweise Berücksichtigung der Merkmale angewendet wird. In der Abbildung 2-19 ist beispielhaft ein Trainingsdatensatz mit insgesamt drei Trainingsdaten dargestellt. Für das erste Merkmal sowie die Zielgröße sind Werte angegeben, mit denen das Funktionsprinzip des GBR erläutert wird. Im ersten Schritt wird der Prognosewert \hat{y}_0 berechnet, welcher in die-

sem Fall gleich dem Mittelwert der bekannten Zielgrößenwerte ist. Für die Berechnung des Prognosewertes \hat{y}_0 kann anstelle des Mittelwertes auch eine andere Kennzahl verwendet werden. Im zweiten Schritt erfolgt die Berechnung der Differenz r_0 (Residuum) zwischen den Zielgrößenwerten y und den Prognosewerten \hat{y}_0 . Für die berechneten Residuen erfolgt die Entwicklung eines Baumes, mit dem diese Werte prognostiziert werden können. Es wird somit kein Baum entwickelt, der die Zielgrößen y möglichst genau prognostiziert, sondern ein Baum, welcher möglichst genau die Residuen r prognostizieren soll. Dies ist ein bedeutender Unterschied des GBR im Vergleich zu dem RFR.

In der Tabelle in Abbildung 2-19 sind die Prognosewerte \hat{y}_0 für die Zielgröße sowie die zugehörigen Residuen r_0 angegeben. Auf der rechten Seite ist der Entscheidungsbaum dargestellt, welcher für die Prognose der Residuen entwickelt wurde. Für die Erstellung des Entscheidungsbaumes sind die Werte des ersten Merkmals sowie die Werte der Residuen r_0 verwendet worden. Aufgrund der Konstellation des Beispieldatensatzes, kann nur ein Split durchgeführt werden und die entstehenden Knoten sind automatisch die Endknoten bzw. die Blätter des Entscheidungsbaumes.

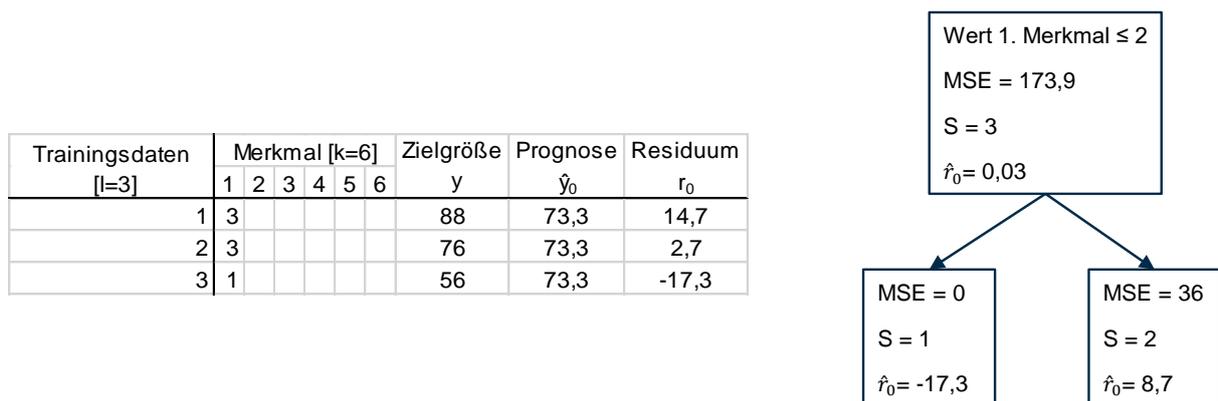


Abbildung 2-19: Tabelle mit Daten für die Demonstration des Funktionsprinzips des GBR sowie der erste Entscheidungsbaum zur Prognose der Residuen \hat{r}_0

Die Berechnung der Prognosen \hat{y}_a für jede Trainingsdateneinheit erfolgt mit der folgenden Formel sowie den Prognosewerten aus dem Entscheidungsbaum:

$$\hat{y}_a = \hat{y}_{a-1} + \nu * \hat{r}_{a-1} \quad (2.21)$$

Der Index a ($a \geq 1$) gibt die Anzahl der Iterationsschritte an. Der Parameter ν wird als Lernrate bezeichnet und beschreibt den Anteil, mit dem das prognostizierte Residuum eines Baumes berücksichtigt wird. Aufgrund der Lernrate wird eine Überanpassung der Methode an den Trainingsdatensatz reduziert und somit die Generalisierbarkeit der trainierten Methode ermöglicht. In der Abbildung 2-20 sind die berechneten Prognosewerte für \hat{y}_1 sowie die zugehörigen Residuen r_1 angegeben. Der \hat{y}_1 -Wert für

das erste Merkmal ergibt sich aus $\hat{y}_0 = 73,3$, $\hat{r}_0 = 8,7$ (siehe Baum in Abbildung 2-19) und einer vom Anwender bestimmten Lernrate $\nu = 0,1$.

$$\hat{y}_1 = \hat{y}_{1-1} + \nu * \hat{r}_{1-1} = 73,3 + 0,1 * 8,7 \approx 74,2 ; \text{ z. B. für die 1. Trainingsdateneinheit}$$

Analog erfolgt die Berechnung für die verbliebenen Trainingsdaten. Es ist zu erkennen, dass die Prognosewerte \hat{y}_1 im Vergleich zu \hat{y}_0 etwas näher an dem wahren Wert y liegen. In einem nächsten Schritt wird nun ein Entscheidungsbaum für die Residuen r_1 entwickelt und die bisher aufgeführten Schritte werden erneut durchlaufen. Es lässt sich erahnen, dass mit jedem weiteren Durchlauf eine Annäherung an den wahren Wert der Zielgröße stattfindet. Dieses Vorgehen wird solange durchgeführt, bis die vom Anwender vorgegebene Anzahl von Bäumen erreicht ist.

Trainingsdaten [l=3]	Merkmal [k=6]						Zielgröße	Prognose	Residuum	Prognose	Residuum
	1	2	3	4	5	6	y	\hat{y}_0	r_0	\hat{y}_1	r_1
1	3						88	73,3	14,7	74,2	13,8
2	3						76	73,3	2,7	74,2	1,8
3	1						56	73,3	-17,3	71,6	-15,6

Abbildung 2-20: Prognosewerte und Residuen des Ausgangszustandes (Index: 0) und nach der Entwicklung des ersten Baumes (Index: 1)

2.4.4 Lineare Diskriminanzanalyse

Die lineare Diskriminanzanalyse (engl. linear discriminant analysis, LDA) ist ein Verfahren zur Bestimmung von Klassenunterschieden auf der Basis von einer Anzahl von Merkmalen und der Kenntnis der Klassen der Merkmalsträger. Ziel ist es, eine Diskriminanzfunktion durch eine Linearkombination der Merkmale zu ermitteln, welche die vorhandenen Klassen signifikant voneinander trennt. Die benötigten Diskriminanzwerte können schließlich mit der Diskriminanzfunktion und den Merkmalswerten berechnet werden. Die LDA trennt die vorhandenen Klassen in Abhängigkeit von den Merkmalen, welche die größte Varianz zwischen den einzelnen Klassen besitzen. Hierdurch unterscheidet die LDA sich u. a. von der mit ihr verwandten PCA, welche eine Trennung anhand der Merkmale durchführt, die die größte Varianz in den Daten besitzen. [KOH05, S. 481–483] Die Problemstellungen bzw. die Aufgaben, die mit einer LDA gelöst werden, sind vielfältig. SCHNEIDER ET AL. verwendet die LDA u. a. für die Klassifikation des Zustandes eines Hydrauliksystems im Rahmen eines auf Sensordaten gestützten Condition Monitoring Modells [SCHN18]. Der Verschleißzustand einer Kugelrollspindel in Abhängigkeit von der Position der Spindelmutter klassifiziert HELWIG ET AL. ebenfalls mit einer LDA auf der Basis von diversen Sensordaten [HELW17].

Mathematisch lässt sich die LDA wie folgt beschreiben: Eine Grundgesamtheit Ω besteht aus mindestens zwei verschiedenen Klassen ($g \geq 2$) und jedes Objekt ω der Grundgesamtheit setzt sich aus einem p -dimensionalen Merkmalsvektor x sowie einer zugehörigen Klasse c zusammen. Mithilfe von einem solchen Datensatz wird die Diskriminanzfunktion geschätzt. Mit der geschätzten Diskriminanzfunktion kann

schließlich einem Objekt ω , mit dem zugehörigen Merkmalsvektor x , eine Klasse eindeutig zugeordnet werden. Jede Klasse wird durch ein Zentrum charakterisiert und ein Objekt ω wird der Klasse c zugeteilt, wenn das Zentrum des zu dem Objekt gehörenden Merkmalsvektors dem Zentrum von c am nächsten ist. Die lineare Diskriminanzfunktion (Linearkombination) lässt sich formulieren durch:

$$y = v'x \quad (2.22)$$

Sie stellt die bestmögliche Zusammenfassung der p Merkmale dar, mit v' als einen zu schätzenden p -dimensionalen Parametervektor. Die Diskriminanzvariable wird durch y repräsentiert. Durch die Diskriminanzfunktion wird das p -dimensionale Problem auf ein eindimensionales Problem reduziert, sodass den Objekten eine Klasse zugeordnet werden kann. Zur Bestimmung der Unterschiede der Klassen ist ein Kriterium notwendig, welches als Diskriminanzkriterium Γ bezeichnet wird. Die Schätzung der Diskriminanzfunktion erfolgt durch die Maximierung des Diskriminanzkriteriums.

$$\Gamma = \frac{SS_b}{SS_w} \rightarrow \max \quad (2.23)$$

mit

$$SS_b = \sum_{c=1}^g n_c (\bar{y}_c - \bar{y})^2 \quad (2.24)$$

$$SS_w = \sum_{c=1}^g \sum_{i=1}^{n_c} (y_{ci} - \bar{y}_c)^2 \quad (2.25)$$

Die Idee besteht nun darin, durch die Maximierung des Diskriminanzkriteriums die Streuung zwischen den Klassen SS_b zu maximieren und gleichzeitig die Streuung innerhalb der Klassen SS_w zu minimieren. Die Streuungen werden jedoch nur durch die Summe der quadrierten Abweichungen vom Mittelwert ausgedrückt. Die Streuung zwischen den Klassen SS_b wird durch die quadrierte Differenz aus den Klassenmittelwerten \bar{y}_c der g Klassen und dem Gesamtmittelwert \bar{y} gemessen. Die Differenzen werden mit den jeweiligen Klassengrößen n_c multipliziert, um die verschiedenen Klassengrößen zu berücksichtigen. Die Streuung in den Klassen SS_w wird durch die quadrierte Differenz aus den Klassenelementen y_{ci} und dem Mittelwert der jeweiligen Klasse \bar{y}_c bestimmt. Die Klassenelemente y_{ci} repräsentieren die Linearkombinationen aus den p Merkmalen.

Durch das Ersetzen mit Linearkombinationen $y_{ci} = v'x_{ci}$, $\bar{y}_c = v'\bar{x}_c$ und $\bar{y} = v'\bar{x}$ ergibt sich das zu maximierende Diskriminanzkriterium in Matrixschreibweise:

$$\Gamma = \frac{v' (\sum_{c=1}^g n_c (\bar{x}_c - \bar{x})(\bar{x}_c - \bar{x})') v}{v' (\sum_{c=1}^g \sum_{i=1}^{n_c} (x_{ci} - \bar{x}_c)(x_{ci} - \bar{x}_c)') v} \quad (2.26a)$$

$$= \frac{v' B_{(p \times p)} v}{v' W_{(p \times p)} v} \rightarrow \max_{v \neq 0} \quad (2.26b)$$

Bei den Matrizen B und W handelt es sich um Varianz-/Kovarianzmatrizen und bei v um einen Eigenvektor, welcher zu schätzen ist. Die hier beschriebene lineare Diskriminanzanalyse ist gleich der Diskriminanzanalyse nach FISCHER und setzt keine bestimmte Verteilung der Grund- bzw. Teilgesamtheiten Ω voraus. [KOH05, S. 481–485]

2.4.5 Verfahren der Prognosevalidierung

Um die Prognosegenauigkeit eines trainierten Algorithmus zu bewerten, bedarf es deutbarer Kennwerte. Nur durch das Aufstellen von definierten Kennwerten wird es möglich, die Eignung eines Algorithmus für einen Anwendungsfall zu bewerten und die Algorithmen untereinander zu vergleichen. Für die Validierung eines Algorithmus wird der extra hierfür zurückgehaltene Testdatensatz verwendet. Das trainierte Modell prognostiziert die Zielgröße und ein Vergleich mit dem vorliegenden Originalwert ermöglicht die Beurteilung der Prognosegenauigkeit. Zum Erreichen eines validen Ergebnisses ist es notwendig, die Kennwerte für möglichst viele Kombinationen von Trainings- und Testsätzen durchzuführen. Hierfür eignet sich die sogenannte Kreuzvalidierung. Bei der Kreuzvalidierung wird der existierende Datensatz in K gleich große Teilmengen zerlegt. Im Anschluss folgt ein K -maliges Training und Testen, bei denen der Algorithmus jeweils mit $K-1$ Teilmengen trainiert und mit der verbleibenden Teilmenge getestet wird. Bei jedem Durchlauf werden somit andere Daten zum Trainieren und Testen genutzt. Die finale Kennzahl zu der Prognosegenauigkeit ergibt sich aus dem Mittelwert der Kennzahlen von jedem Durchlauf (siehe Formel 2.27). [CLEV16, S. 241–242] Dabei nimmt K üblicherweise Werte zwischen fünf und zehn an.

$$\text{Kennzahl} = \frac{\sum_{j=1}^K \text{Kennzahl}_j}{K} \quad (2.27)$$

Als Kennzahl können verschiedene Größen herangezogen werden [JOSH20, S. 170]. Für die Berechnung der Kennzahlen wird jeweils die Anzahl von Prognosen n , der Prognosewert \hat{y}_i und der tatsächliche Wert y_i von jeder Prognose i benötigt. Berechnet werden kann z. B.: der mittlere absolute Fehler (MAE):

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (2.28)$$

Sind Ausreißer bei den Prognosen von höherer Wichtigkeit, dann kann auch der mittlere quadrierte Fehler (MSE) berechnet werden, der diese stärker gewichtet.

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (2.29)$$

Als Kennzahl kann auch der maximal auftretende Fehler (MAX) ermittelt werden. Dieser Fehler darf jedoch nicht zusätzlich gemittelt werden, wenn er von den Ergebnissen einer Kreuzvalidierung bestimmt wird.

$$MAX = \max_{n,i} |y_i - \hat{y}_i| \quad (2.30)$$

Eine weitere Kennzahl ist das Bestimmtheitsmaß (R^2), das den Anteil der von dem Algorithmus erklärten bzw. berücksichtigten Varianz der Originalwerte angibt. Es ist gleich eins, wenn der Algorithmus ideale Prognosen (Prognosewert gleich Originalwert) hervorbringt (Zähler $\rightarrow 0$). R^2 nimmt den Wert Null an, wenn der Prognosewert stets gleich dem Mittelwert ist. Der Wert von R^2 kann jedoch auch negativ werden, wenn die Prognosen außerordentlich unpräzise sind (Zähler $\rightarrow \infty$). In einem solchen Fall ist die Verwendung des berechneten Mittelwertes als Prognosewert geeigneter als der von dem trainierten Algorithmus erhaltene Prognosewert.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.31)$$

Die vorgestellten Kennzahlen werden im maschinellen Lernen häufig verwendet, um die Prognosegenauigkeit zu bewerten. Aufgrund des Kontextes dieser Arbeit sind auch Validierungsmethoden denkbar, die aus dem Qualitätsmanagement stammen und z. B. die Messmittelfähigkeit bewerten (siehe Kapitel 2.2.2).

2.5 Vorstellung existierender Forschungsarbeiten

In diesem Kapitel wird ein Überblick über wissenschaftliche Arbeiten gegeben, die sich mit der Prognose der Qualität von Werkstücken durch die Nutzung von Fertigungsdaten und der Anwendung von maschinellem Lernen beschäftigen. Zudem wird auf die ersten Ansätze und Bestrebungen eingegangen, die eine Zertifizierung einer derartigen Qualitätsprognose in einem Fertigungsunternehmen zum Ziel haben.

Die Veröffentlichungen haben eine große Schnittmenge mit der Thematik von dieser Arbeit, zeigen jedoch zugleich noch bestehende Forschungslücken auf und bilden hierdurch die Grundlage für die in Kapitel 3 aufgestellten Forschungsfragen.

2.5.1 Integration von maschinellem Lernen in das Qualitätsmanagement

Von Unternehmen wird es verlangt, dass diese ihre Produkte sowie Dienstleistungen als auch ihre Produktionsprozesse zertifizieren, um das nötige Maß an Qualität sicherzustellen. Eine solche Zertifizierung ist jedoch bisher für Produktionsprozesse, welche mittels künstlicher Intelligenz oder maschinellen Lernens geführt oder abgesichert werden, noch nicht möglich. Die Hauptursache hierfür liegt in der Neuartigkeit dieser Technologie in Bezug auf ihre Anwendung in der Produktion. Die Herausforderungen aber auch Lösungsmöglichkeiten, die bei der Zertifizierung einer von künstlicher Intelligenz unterstützten Produktion auftreten, werden von BRANDSTÄTTER erläutert. Fünf verschiedene Kategorien, mit und ohne Bezug auf die künstliche Intelligenz, in denen eine Zertifizierung der Vorgänge mittels zugehöriger Normen geschieht, werden vorgestellt. Eine Kategorie umfasst die Normen zur Qualitätssicherung mit Bezug auf die Produktion (z. B. ISO 9001), jedoch ohne Berücksichtigung von künstlicher Intelligenz. Eine weitere Kategorie fasst die Normen zur Zertifizierung von Software und IT-Sicherheit zusammen, aber ohne den Einsatz von künstlicher Intelligenz bei der Produkterstellung. Zwei weitere Kategorien listen Normen zur Zertifizierung von Vorgängen auf, bei denen künstliche Intelligenz zum Einsatz kommt, jedoch ohne expliziten Bezug auf die Produktion. Die letzte Kategorie führt die sich gerade im Entwurf befindende Richtlinie VDI/VDE 3714 „Implementierung und Betrieb von Big-Data-Anwendungen in der produzierenden Industrie“ auf, die als erste Richtlinie indirekt darauf abzielt, eine Zertifizierung von Produktionsprozessen zu erreichen, bei denen künstliche Intelligenz zum Einsatz kommt. Der Autor schlussfolgert, dass noch nicht abzusehen ist, in welche Richtung sich die künstliche Intelligenz hinsichtlich Transparenz und Erklärbarkeit entwickelt, und dass dies ausschlaggebend für zukünftige Normen und Zertifizierungen sein wird. Unabhängig von der sich entwickelnden Zertifizierung sollten die Mitarbeiter eines Unternehmens für die künstliche Intelligenz sensibilisiert und geschult werden, sodass sie mögliche Einsatzgebiete besser identifizieren und die mit der künstlichen Intelligenz erzielten Prognosen besser bewerten können. [BRAN19, S. 553–562]

Von der VDI/VDE 3714 Richtlinie sind zum momentanen Zeitpunkt drei der insgesamt sieben Blätter als Entwurf verfügbar. Die Richtlinie hat das Ziel, „den ökonomischen und ökologischen Nutzen von Big Data aufzuzeigen, den Wissenstransfer über verschiedene Industrien und Branchen hinweg zu verbessern und die Implementierung und den Betrieb von Big-Data-Anwendungen in der produzierenden Industrie voranzutreiben und zu vereinheitlichen“ [VDI19, S. 2]. Die Daten sollen von der in der Produktion anzutreffenden Mess- und Regelungstechnik gewonnen werden, welche bisher nur für die Steuerung- und Regelung der Produktion verwendet werden. Die noch nicht veröffentlichten Blätter vier, fünf und sechs handeln über

Analyseverfahrensklassen, Modellierungsverfahren und die Validierung von Modellen. Es ist abzuwarten, ob in diesen Blättern auch Methoden der künstlichen Intelligenz bzw. des maschinellen Lernens aufgeführt werden und somit eine erste Richtlinie für die Zertifizierung von mit künstlicher Intelligenz unterstützten Produktionsprozessen geschaffen wird.

Der Einsatz von maschinellem Lernen zur automatischen und prädiktiven Risikobewertung in Fertigungsprozessen, um die in der ISO 9001:2015 vorgeschriebenen Anforderungen eines integrierten Risikomanagements in Unternehmen zu erfüllen, wird von MUELLER beschrieben. Die Risikobewertung erfolgt auf Basis der Prognose der Werkstückqualität und der Einordnung der Prognosen in eine Qualitätsregelkarte der statistischen Prozessregelung. Erstellt werden die Prognosen mit Hilfe von den Methoden des maschinellen Lernens und den Sensordaten aus dem Fertigungsprozess. Das entwickelte Vorgehen wird anhand eines Anwendungsfalls (Spritzgießen von dünnwandigen Kunststoffbauteilen) validiert. Es wird aufgezeigt, dass die Anzahl von Werkstückmessungen durch die Prognosen reduziert wird, die Ausschussquote sich verringert und weniger häufig in den Fertigungsprozess regelnd eingegriffen werden muss. Das Risiko, ein fehlerhaftes Werkstück zu produzieren, lässt sich somit bewerten. [MUEL19, S. 91–100]

2.5.2 Einsatz von maschinellem Lernen zur Qualitätsprognose in der Zerspanung

Im Folgenden werden relevante Veröffentlichungen zur Qualitätsprognose von zerspanend gefertigten Werkstücken aufgeführt. Zudem existiert eine Vielzahl von Publikationen, die Fertigungsdaten und Methoden des maschinellen Lernens nutzen, um den Werkzeugverschleiß zu bestimmen oder mittels der Auswertung von Bildern die Werkstückqualität zu bewerten. Solche Publikationen passen nur bedingt in den Kontext dieser Arbeit und sind daher hier nicht erwähnt.

Die Rundheit, die Oberflächenrauheit und die Eigenspannungen von geriebenen Bohrungen in Stahl prognostiziert MATHEWS ET AL. mittels eines künstlichen neuronalen Netzes (mit Back Propagation Algorithmus). Als Inputgrößen werden das Drehmoment, die Vorschubkraft, der akustische Schall sowie die Vibrationen verwendet, die während des Reibprozesses an dem Werkstück gemessen werden. Als Werkzeug wird eine HSS Reibahle mit Durchmesser 20 mm eingesetzt, um die Bohrungen mit einem Aufmaß von 0,5 mm zu bearbeiten. Die Bearbeitung der Werkstücke und die damit verbundene Datenerfassung erfolgt bei vier verschiedenen Kombinationen der Schnitt- und Vorschubgeschwindigkeit. Die Schnittgeschwindigkeit wird zwischen 6 m/min und 12 m/min und die Vorschubgeschwindigkeit wird zwischen 0,18 mm/U und 0,62 mm/U variiert. Die Prognosegenauigkeit ist abhängig von der Kombination der Schnittparameter und die maximal auftretenden Abweichungen betragen für die Rundheit 5 μm und für die Oberflächenrauheit 0,5 μm . Insbesondere die Einflüsse auf die Qualität der Bohrung, die von einer Veränderung der Schnittparameter ausgehen, werden von dem KNN erkannt. Eine Erhöhung der Schnitt- und Vorschubge-

schwindigkeit führt zu einer Verschlechterung der Rundheit, was von dem KNN auf Basis der Inputdaten erkannt und entsprechend prognostiziert wird. [MATH99]

QUINTANA ET AL. prognostiziert die Oberflächenrauheit beim Fräsen von Stahl (C45) mit einem künstlichen neuronalen Netzwerk. Die Prognosen werden zum Ersten rein auf der Basis der verfügbaren NC-internen Daten und zum Zweiten rein auf der Basis von den Daten eines Beschleunigungssensors prognostiziert. Von der NC-Steuerung wird mit einer Abtastrate von 500 Hz der drehmomentbildende Strom der X-, Y-, und Z-Achse und der Spindel erfasst. Zusätzlich erfolgt die Erfassung der Position des Werkzeuges sowie die Drehzahl der Spindel. Der Beschleunigungssensor erfasst die Vibrationen in X- und Y-Richtung mit einer Erfassungsfrequenz von 5 kHz. Insgesamt umfasst der Datensatz 72 Schnitte, welche mit verschiedenen Schnitttiefen, Vorschubgeschwindigkeiten und Spindeldrehzahlen durchgeführt werden. Mit den Daten der NC-Steuerung erreicht das KNN ein R^2 von 95,95 % und mit den Daten des Beschleunigungssensors ein R^2 von 94,35 %. Für jeden Datensatz wird ein separates KNN mit 70 % der Daten trainiert. Mit den Daten ausschließlich von der NC-Steuerung wird ein etwas besseres Prognoseergebnis erzielt. Es ist die von den Autoren bevorzugte Lösung für die Rauheitsprognose nicht nur wegen der höheren Prognosegenauigkeit, sondern auch im Hinblick auf den geringeren zusätzlichen Aufwand für die Datengewinnung, da keine Integration von Sensorik und Auswerteeinheit in die Maschine erfolgen muss. [QUIN11]

NETO ET AL. prognostiziert den Durchmesser von Bohrungen in Titan Ti6Al4V und Aluminium 2024-T3 auf Basis von Kräften in X-, Y- und Z-Richtung, dem Strom der Spindel, dem akustischen Schall sowie anhand von Vibrationen am Werkstückhalter. Die Erfassungsfrequenz liegt für jede der Größen bei 2,5 kHz und von den erfassten Signalen wird der quadratische Mittelwert berechnet, welcher als Inputwert für das Modell des maschinellen Lernens dient. Insgesamt werden Daten zu 1.143 Bohrungen erfasst. Diese Bohrungen werden mit neun verschiedenen Kombinationen der Drehzahl und dem Vorschub durchgeführt, welche jedoch nicht dem Modell des maschinellen Lernens mitgeteilt werden. Für jede Bohrung wird der kleinste und der größte Durchmesserwert bestimmt und hieraus der Mittelwert berechnet, welcher die zu prognostizierende Größe darstellt. Als Methoden des maschinellen Lernens werden ein künstliches neuronales Netz (KNN) und ein adaptives Neuro-Fuzzy-Inferenzsystem (ANFIS) verwendet. Die erzielten Prognoseergebnisse sind bei dem KNN minimal besser als bei dem ANFIS. Mit dem KNN wird ein durchschnittlicher Prognosefehler von 11,4 μm (7,4 μm) und ein maximaler Fehler von 45,4 μm (36 μm) für die Bohrungen in Aluminium (Titan) erzielt. Wichtige Inputgrößen sind jeweils die Kräfte in X- und Z-Richtung sowie die Vibrationen (bei Aluminium) und der Strom der Spindel (bei Titan). [NETO13]

Mit der prozessparallelen Prognose der auftretenden Kräfte beim Fräsen beschäftigt sich WIESCH ET AL. Steuerungsinterne Daten (Beschleunigung und Geschwindigkeit der Achsen, Rücke, Stromaufnahme der Spindel sowie Spindeldrehzahl) werden erfasst sowie der Grad des Werkzeugeingriffes wird mittels eines Simulationsmodells (Dexel-Modell) bestimmt. Sie dienen als Inputgrößen für ein künstliches neuronales

Netz, um die Prozesskräfte in X- und Y-Richtung sowie die Schnittkraft zu prognostizieren. Die Anwendung erfolgt für das Planfräsen von Aluminium bei unterschiedlichen Eingriffsverhältnissen mit jeweils den gleichen Schnittparametern. Zum Antrainieren des KNN sowie zum Validieren der prognostizierten Kräfte ist eine Kraftmessplattform unter dem Werkstück angebracht. Mit zwei Schnitten wird das KNN antrainiert, bevor die Kräfte selbständig prognostiziert werden. Eine Bewertung der Prognosegenauigkeit erfolgt nur visuell durch das Übereinanderlegen der prognostizierten und gemessenen Kräfteverläufe. Abweichungen sind nahezu nicht zu erkennen, was für eine hohe Prognosegenauigkeit spricht. Auch für Schnittverläufe, für die das KNN nicht trainiert wurde, werden sehr gute Prognoseergebnisse erzielt, was für eine gute Generalisierbarkeit des Modells im jeweiligen Betrachtungsbereich steht. [WIES17] In dem Forschungsprojekt REFFIZ wurde zudem nachgewiesen, dass der steuerungsintern verfügbare momentbildende Strom der Achsen mit der Schnittkraft stark korreliert und es zu einer mittleren Abweichung von unter 10 % kommt [BREC15, S. 94–95]. Somit ist der momentbildende Strom für die Bestimmung der Schnittkräfte und den damit verbundenen Auswirkungen nutzbar.

Eine weitere Veröffentlichung, die prozessparallel den Reibprozess und die resultierende Qualität optimiert, stammt von BRETZ ET AL. BRETZ ET AL. detektiert den Achsversatz zwischen Reibahle und Bohrung durch die Erfassung der Kräfte in X-, Y- und Z-Richtung mittels einer Kraftmessplattform, berechnet die Merkmale Standardabweichung, Mittelwert sowie Peak-to-Peak Wert von den erfassten Daten und führt diese als Inputwerte einem künstlichen neuronalen Netz zu. Das KNN prognostiziert schließlich den Versatz der Achse in X- und Y-Richtung und gibt einen Korrekturfaktor vor, sodass kurz nach dem Beginn des Reibprozesses eine Achskorrektur durchgeführt werden kann. Das verwendete KNN ist ein Feedforward Netzwerk mit einer Input-, einer Verdeckten- und einer Output-Schicht. Durch die Achskorrektur können Rundheits- und Durchmesserabweichungen reduziert werden. Die eingesetzte Reibahle ist eine Mehrschneidenreibahle mit sechs Schneiden und einem Durchmesser von 14 mm. Für die zwei Werkstückwerkstoffe Gusseisen (EN-GJL-250) und Stahl (42CrMo4V) werden die Versuche durchgeführt. Für jeden Werkstoff wird ein eigenes KNN trainiert, welches für den Gusseisenwerkstoff ein R^2 von 89,7 % und für den Stahl ein R^2 von 91,5 % hinsichtlich des prognostizierten Korrekturfaktors erzielt. [BRET18]

Mit der Prognose der Oberflächenrauheit für gefräste Flächen in Stahl (C45) beschäftigt sich auch PIMENOV ET AL. Er erstellt die Prognosen auf Basis der Leistungsaufnahme der Spindel, der Werkzeugeinsatzzeit sowie der Verschleißmarkenbreite. Die Spindelleistung wird über die NC-Steuerung direkt abgegriffen und es werden der Minimal-, Maximal- und Mittelwert der Leistung für jeden Schnitt bestimmt. Insgesamt umfasst der Datensatz 34 Schnitte und die Schnittparameter bleiben für alle Schnitte konstant. Als Methoden des maschinellen Lernens kommen Random Forest, Regressionsbäume, künstliches neuronales Netz und radiale Basisfunktionen zum Einsatz. Die Prognosen des Random Forest erreichen eine Genauigkeit (Wurzel der mittleren Fehlerquadratsumme) von 0,27 μm und sind damit im Durchschnitt

33 % besser als die Prognoseergebnisse der verbliebenen Methoden. Es zeigt sich zudem, dass die minimale und die maximale Spindelleistung einen zu vernachlässigenden Einfluss auf die Prognosegenauigkeit haben. Aufgrund der sehr guten Prognosegenauigkeit und der besseren Deutbarkeit bzw. Nachvollziehbarkeit des Zustandekommens der Prognose ist der Random Forest die bevorzugte Methode. [PIME18]

KÖNIGS ET AL. prognostiziert die Geradheit von in Grauguss gefrästen linearen Konturen mittels eines Simulationsmodells, der Positionsangaben aus der NC-Steuerung und den erfassten Kräften in X-, Y- und Z-Richtung. Die Simulation der gefertigten Qualität erfolgt parallel zum Fräsprozess mit einem Zeitversatz von 1,2 ms. Das Simulationsmodell umfasst eine FE-Simulation der Maschine, um Verformungen von Maschinenkomponenten und damit einhergehende Abweichungen des Werkzeuges von der Soll-Geometrie zu bestimmen. Die FE-Simulation stützt die berechnete Werkzeugabweichung auf den erhaltenen Positionsangaben der NC und den erfassten Kräften. Die Werkzeugabweichung wird von dem Simulationsmodell für die Qualitätsprognose letztendlich genutzt, um die reale Position des Werkzeuges zu bestimmen und auf die Geradheit der gefrästen Konturen zu schließen. Die Erfassung der Positionen erfolgt mittels der NC-Steuerung und einer Abtastfrequenz von 0,5 kHz. Mit einer Kraftmessplattform, auf die das Werkstück gespannt ist, werden die auftretenden Kräfte mit einer Frequenz von 1 kHz aufgezeichnet. Die erhaltenen Prognosen für die Geradheit haben eine maximale Abweichung von ca. 3 μm von den gemessenen Werten. In einer Weiterentwicklung des Simulationsmodells soll das Messen der Kräfte durch ein Schnittkraftmodell ersetzt werden. [KÖNI18]

BRECHER ET AL. prognostiziert ebenfalls die Geradheit einer Seitenflanke, welche mit einem Schafffräser in den Stahlwerkstoff C45 gefräst wird. Die Prognose findet prozessparallel mittels eines Simulationsmodells statt und basiert ausschließlich auf steuerungsinternen Daten. Von der NC-Steuerung werden mit einer Frequenz von 0,5 kHz die Position der Achsen, die Drehzahl der Spindel sowie die momentbildenden Ströme der Spindel und Vorschubachsen erfasst. Zusätzlich erfolgt die Speicherung des NC-Satzes sowie der Werkzeugwechsel. Diese Ist-Werte werden von einem Simulationsmodell dazu verwendet, einen Materialabtrag zu bestimmen, woraus die Geradheit der gefrästen Flanke abgeleitet wird. Das Simulationsmodell umfasst zudem Modelle, die die Werkzeugdurchbiegung und die genaue Lage des Tool Center Points bestimmen. Zudem ist es notwendig, die Maschine geometrisch und statisch zu vermessen und das Geometriemodell entsprechend zu parametrieren. Bei dem durchgeführten Versuch wird der Vorschub verändert, was zu unterschiedlichen Abdrängungen des Werkzeuges führt und hiermit die Geradheit der Flanke lokal verändert. Die Abweichung zwischen der gemessenen und der prognostizierten Geradheit beträgt ca. 0,04 mm. Zudem stimmen die Verläufe der Geradheitslinien nahezu überein. Es wird von dem Autor angemerkt, dass die Prognosegenauigkeit sinken kann, wenn das Simulationsmodell für einen Bearbeitungsfall angewendet wird, der für eines der in dem Simulationsmodell enthaltenen Modelle unbekannt ist. [BREC19]

ZIEGENBEIN ET AL. prognostiziert die Qualität von Bohrungen anhand von Fertigungsdaten aus der NC-Steuerung und dem Einsatz des Random Forest Classifier (RFC) als Methode des maschinellen Lernens. Anhand der gemessenen Rundheit, der Position und des Durchmessers einer Bohrung sowie der zugehörigen Toleranzgrenzen wird jede einzelne der insgesamt 2.400 Bohrungen als i.O. oder n.i.O. Bohrung eingestuft. Von der NC-Steuerung werden mit einer Frequenz von 33,3 Hz insgesamt 54 verschiedene Fertigungsgrößen aufgezeichnet, von denen jedoch nur der drehmomentbildende Strom der Spindel sowie der X-, Y- und Z-Achse als besonders relevant für die Prognosen angesehen wird. Es erfolgt eine Berechnung der Merkmale: Varianz, Standardabweichung, Minimum, Maximum, Schiefe, Wölbung, Median, Mittelwert und Wertesumme. Zudem werden mittels Principal Component Analysis noch weitere Merkmale berechnet. Anhand der Merkmalswerte und der Zeitreihenverläufe wird versucht, die n.i.O. Bohrungen durch das Anwenden von fertigungstechnischem Wissen zu detektieren, was aber keinen Erfolg hat. Daraufhin wird die RFC Methode eingesetzt, was den gewünschten Erfolg bringt. Die durchschnittliche Prognosegenauigkeit liegt bei 98 %. Sie ist jedoch davon abhängig, wie viele i.O. bzw. n.i.O. Bohrungen zum Trainieren des RFC verwendet werden. [ZIEG20]

3 Forschungshypothese und Konkretisierung der Forschungsfragen

In der Einleitung dieser Arbeit wurde die Motivation für die Einführung einer prozessparallelen Qualitätsprognose erläutert sowie die Zielsetzung definiert. Die Nutzung von maschineninternen Daten und Methoden des maschinellen Lernens wird als eine Möglichkeit gesehen, die Prognose von Qualitätsmerkmalen einer geriebenen Bohrung zu realisieren. Die gegenwertigen und etablierten Methoden der Qualitätssicherung in der Serienfertigung wurden in Kapitel 2.2 beschrieben. In Kapitel 2.5 erfolgte die Nennung und die Beschreibung von bereits existierenden wissenschaftlichen Publikationen, die sich mit der Qualitätsprognose von spanend gefertigten Werkstücken auf der Basis von Fertigungsdaten und Methoden des maschinellen Lernens beschäftigen. Die Analyse dieser Publikationen liefert einen ersten Ansatz dafür, dass das Vorhaben der Einführung einer prozessparallelen Qualitätsprognose möglich sein könnte. Zugleich tun sich jedoch Forschungslücken auf, die mit der Implementierung einer solchen Prognose für einen Bohr- und Reibprozess in der Serienfertigung verbunden sind.

Der Forschungsbedarf ergibt sich demnach aus dem in der Zielsetzung dieser Arbeit (Kapitel 1.2) hergeleiteten Handlungsbedarf und den existierenden Forschungslücken aufgrund von fehlenden Anwendungen in Theorie und Praxis. Dieser Forschungsbedarf lässt sich in der handlungsleitenden Forschungshypothese zusammenfassen:

Die prozessparallele Prognose von Qualitätsmerkmalen einer geriebenen Bohrung auf der Basis von NC-internen Fertigungsdaten und Methoden des maschinellen Lernens ist für die industrielle Serienfertigung möglich!

Von dieser Forschungshypothese ausgehend lassen sich konkrete Forschungsfragen ableiten, welche die Validierung der aufgestellten Hypothese unterstützen.

Die Qualitätsprognosen stützen sich auf die Daten, die während des Bohrens und Reibens der Bohrung erfasst werden und die die Einflussgrößen sowie die Effekte abbilden müssen, welche die Bohrungsqualität beeinflussen. Als Erstes muss daher die Frage beantwortet werden:

Welche Wirkzusammenhänge bestehen zwischen dem Bohrprozess sowie dem Reibprozess und der Werkstückqualität?

Daran schließt sich die Frage an:

Welche Daten müssen aufgezeichnet werden und welche Erfassungsfrequenz ist notwendig, um zum einen die Wirkzusammenhänge abzubilden und zum anderen eine werkstückbezogene Zuordnung zu ermöglichen?

Für die Anwendung von maschinellen Lernverfahren ist es oftmals notwendig, Merkmale aus den erfassten Daten zu extrahieren. Die Merkmale müssen mittels Extrakti-

ons- und Selektionsverfahren aus den Fertigungsdaten gewonnen werden, sodass sich die Frage auftut:

Welche Merkmalsextraktions- und Merkmalsselektionsverfahren sind am besten geeignet, um die benötigten Merkmale aus den Fertigungsdaten zu gewinnen?

In den in Kapitel 2.5 aufgeführten Veröffentlichungen sind die extrahierten Merkmale zumeist statistische Größen aus dem Zeitbereich der erfassten Daten. Für den in dieser Arbeit betrachteten Fall muss daher die Frage beantwortet werden:

Welche Merkmale stellen den Zusammenhang zwischen den Fertigungsdaten und der Werkstückqualität am besten dar und sind daher aus den erfassten Daten zu extrahieren?

Die Methode des maschinellen Lernens bestimmt maßgeblich den Erfolg und die Genauigkeit des Prognoseergebnisses. In den genannten Veröffentlichungen (Kapitel 2.5) werden zumeist künstliche neuronale Netze eingesetzt, um die Zielgröße zu prognostizieren. Es ist jedoch zu erwähnen, dass die erfassten Fertigungsdaten nicht bei gleichbleibenden Prozessparametern bzw. Schnittwerten erfasst wurden. Demzufolge setzten sich die verwendeten Daten in den Publikationen aus einzelnen, kleinen Datensets zusammen, die völlig verschiedene Ausgangsbedingungen und Qualitätsergebnisse umfassen. In dieser Arbeit soll hingehen eine Qualitätsprognose für eine Serienfertigung initiiert werden, bei der die Prozessparameter folglich einmalig festgelegt werden und dann unverändert bleiben. Lediglich PIMENOV ET AL. und ZIEGENBEIN ET AL. erstellen Qualitätsprognosen für gleichbleibende Prozessparameter und erzielen die höchste Prognosegenauigkeit mit der Methode Random Forest. Somit ergibt sich die Frage:

Welche Methoden des maschinellen Lernens erzielen bei gleichbleibenden Prozessparametern die höchste Prognosegenauigkeit für den betrachteten Anwendungsfall?

Ein Teil der aufgeführten Publikationen benötigt für die Prognose neben den Fertigungsdaten auch noch den Materialabtrag, welcher aus einem Simulationsmodell gewonnen wird. Dies ist besonders dann anzuwenden, wenn es sich um das Fräsen von Freiformen bei der Einzelstückfertigung handelt. In der Serienfertigung ist der Materialabtrag während eines spezifischen Bearbeitungsschrittes aufgrund identischer Rohlinge zumeist gleichbleibend und somit sollte es ausreichen, die Methode des maschinellen Lernens ausschließlich auf der Basis der Fertigungsdaten zu trainieren. Die Frage, die sich stellt, ist:

Welche Anzahl von Trainingsdaten ist notwendig, um das maschinelle Lernverfahren zu trainieren, sodass eine hohe Prognosegenauigkeit für den betrachteten Anwendungsfall erreicht wird?

Um die Menge der zu erfassenden Daten möglichst klein und damit effizient zu halten, stellt sich die Frage nach der Wichtigkeit jeder einzelnen Datenquelle (z. B. Achse, Spindel) für das Prognoseergebnis:

Welchen Anteil an der Prognosegenauigkeit haben die Fertigungsdaten der einzelnen Datenquellen eines Bearbeitungszentrums?

Aufgrund der Neuartigkeit der Qualitätsprognose für die fertigende Industrie muss zudem noch die Art und Weise der Validierung der erzielten Prognoseergebnisse bestimmt werden. Demnach ist die Frage zu beantworten:

Wie hat eine Validierung der erzielten Qualitätsprognosen bei einer Serienfertigung im industriellen Einsatz zu erfolgen?

Die in dieser Arbeit beschriebene Qualitätsprognose wird anhand einer Bohrung erforscht. Für die industrielle Fertigung ist es von Interesse, diese Art der Qualitätskontrolle auch auf weitere Fertigungsverfahren und Qualitätsmerkmale übertragen zu können. Um dies mit einer möglichst hohen Effizienz durchzuführen, wäre ein entsprechendes generisches Vorgehensmodell von Bedeutung, welches neben dem technischen auch den fachlichen Hintergrund berücksichtigt. Dies stellt die Frage nach dem Aufbau und der Gestaltung eines solchen Modells:

Wie ist ein Vorgehensmodell aufzubauen und aus welchen Stufen setzt sich dieses zusammen, um die prozessparallele Qualitätsprognose in der spanenden Fertigung zu implementieren?

4 Konzeption eines Vorgehensmodells zur Gestaltung einer prozessparallelen Qualitätsprognose

In diesem Kapitel erfolgt die Konzeption und Beschreibung des Vorgehensmodells zur Gestaltung und Einführung einer prozessparallelen Qualitätsprognose auf Basis von Fertigungsdaten und Methoden des maschinellen Lernens. Die Konzeption des Vorgehensmodells stützt sich auf den Erkenntnissen der Systemtechnik und der Modellierung, weshalb mit der Beschreibung dieser Techniken begonnen wird. Im Anschluss wird das Vorgehensmodell vorgestellt sowie jede einzelne Stufe im Groben erläutert. Das Vorgehensmodell soll Transparenz und Klarheit schaffen sowie den Fertigungsingenieur bei der Umsetzung der Qualitätsprognose begleiten.

4.1 Die Systemtechnik als Basis für die Modellkonzeption

Die in dieser Arbeit betrachtete prozessparallele Prognose der Werkstückqualität ist ein komplexes Vorhaben (System), welches nach einem Vorgehensmodell verlangt, um die Komplexität zu bewältigen und Transparenz zu schaffen, den Betrachtungsbereich klar abzugrenzen sowie die involvierten Themenfelder zu berücksichtigen und in der notwendigen Tiefe zu ergründen. Für diese Aufgabe eignet sich die Systemtechnik, welche Methoden und Verfahren der Systemwissenschaft zur Konzipierung, Analyse, Strukturierung und Realisierung von komplexen Systemen bereitstellt [ZANG14, S. 23; WINZ16, S. 2].

Ein System besteht aus Elementen und grenzt sich durch seine Systemgrenze von dem ihm umgebenden Umfeld ab. Handelt es sich um ein offenes System, dann weist es mit seinem Umfeld und den dort existierenden Systemen Beziehungen auf. Systeme lassen sich untergliedern und in einer Systemhierarchie abbilden. Die Hierarchie besteht aus dem Übersystem, dem betrachteten System, den Untersystemen mit verschiedener Ordnung sowie der Elementarstufe. Die Elementarstufe stellt die unterste Hierarchieebene dar und beinhaltet die Elemente, welche nicht weiter unterteilt und somit als Black-Boxes betrachtet werden können. [HABE12, S. 38] Die Abbildung 4-1 visualisiert beispielhaft das in dieser Arbeit betrachtete System der Qualitätsprognose und die hieraus entstehende Systemhierarchie. Die Abbildung hat keinen Anspruch auf Vollständigkeit, sondern soll vielmehr die Idee der Komplexitätsreduzierung durch das Bilden von Systemen verkörpern.

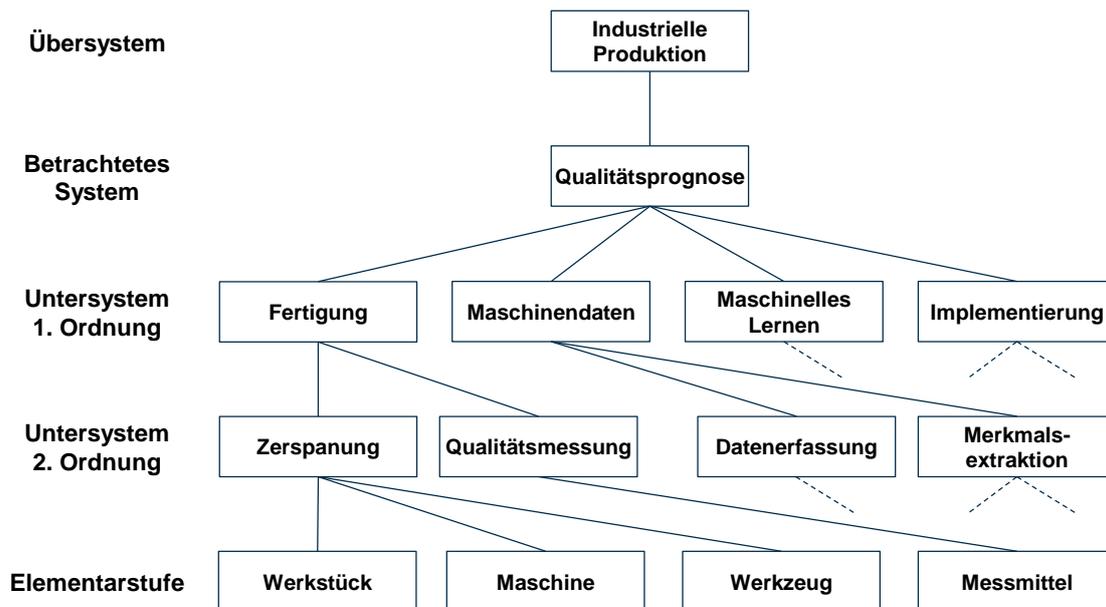


Abbildung 4-1: Systemhierarchie des betrachteten Systems der Qualitätsprognose

Die Systeme können anhand des bekannten analytischen Zusammenhangs zwischen System-Input und System-Output in Black-Box, Grey-Box und White-Box Systeme unterteilt werden. Hierbei steht das Black-Box System für ein System, für das der innere Aufbau, die Zusammenhänge sowie die Wechselwirkungen zwischen Elementen und weiteren Systemen gänzlich unbekannt sind. Das Grey-Box System ist eine Mischung aus Black-Box und White-Box, indem bestimmte Zusammenhänge und Strukturen detailliert beschrieben werden und andere wiederum nicht. Bei dem White-Box System wird der Zusammenhang zwischen Systeminput und Systemoutput exakt und detailliert beschrieben. [HABE12, S. 38] Um diese Unterteilung durchzuführen, bedarf es der Überführung eines Systems in ein Modell [WINZ16, S. 3]. Hierdurch wird es möglich, ein komplexes System in einer abstrahierten Form, auf das Wesentliche beschränkt, wiederzugeben. Ein Modell ist nach STACHOWIAK gekennzeichnet durch die drei Merkmale: Abbildungsmerkmal, Verkürzungsmerkmal und pragmatisches Merkmal. Das Abbildungsmerkmal besagt, dass ein Modell ein Abbild eines existierenden Originals ist. Von einem Modell werden nur die Attribute des Originals berücksichtigt, die von dem Erfasser als notwendig angesehen werden, was durch die Verkürzungsmerkmale zum Ausdruck gebracht wird. Die pragmatischen Merkmale besagen, dass ein Modell nur für einen klar definierten Zustand Gültigkeit besitzt. [STAC13, S. 131–133]

Die Systemtechnik überführt demnach ein reales System in ein Abbild, ein sogenanntes Modell des Systems, welches auf den Anwendungsfall bezogen zielgerichtet gestaltet werden kann [WINZ16, S. 7]. Durch die Überführung des Gesamtsystems in Untersysteme bzw. einzelne Modelle wird die Komplexität des Gesamtsystems reduziert und die Basis geschaffen, um ein Vorgehensmodell zu gestalten, welches den Weg zu dem Ziel – in diesem Fall die Qualitätsbestimmung – nachvollziehbar veranschaulicht [HABE12, S. 33]. Das Vorgehensmodell soll so gestaltet sein, dass es

einem Top-down-Ansatz folgt, also einer hierarchischen Gliederung vom Groben zum Detail, um nicht in einem frühen Stadium den Blick für das Ganze zu verlieren. Darauf folgt das zeitliche Gliedern der einzelnen Modelle (Untersysteme) in einzelne Phasen (Stufen). Für jede Phase sollen mehrere Lösungsvarianten gefunden werden, um für das jeweilige Modell ausreichend Lösungsalternativen zu haben. Die optimale Lösung wird innerhalb des Problemlösungszyklus gefunden, welcher einer Logik zur Auswahl der besten Lösungsmöglichkeit folgt und Vor- sowie Rückkopplungen beinhaltet. [BRUN91, S. 4; KLOT10, S. 6–7; HABE12, S. 57]

In dieser Arbeit wird die Systemtechnik genutzt, um ein Vorgehensmodell (siehe Abbildung 4-2) zu entwickeln, mit dem die Gestaltung und Implementierung einer prozessparallelen Qualitätsprognose auf Basis maschineninterner Daten und Methoden des maschinellen Lernens ermöglicht wird. Das Vorgehensmodell folgt dem empfohlenen Top-down-Ansatz, indem es mit der Festlegung des Ordnungsrahmens sowie der Zieldefinition (1. Stufe) beginnt und nur grob den Lösungsweg skizziert. Die Detaillierung der einzelnen Stufen erfolgt schließlich individuell auf den jeweiligen Anwendungsfall bezogen. Des Weiteren wird die Gliederung des Vorgehensmodells in Stufen, die chronologisch aufeinander aufbauen, befolgt. Jede Stufe kann als ein Untersystem des Gesamtsystems betrachtet werden, welches klar definierte Funktionalitäten und Aufgaben übernimmt, jedoch mit den anderen Untersystemen im Austausch steht. Jedes Untersystem stellt zudem ein Modell dar, da es nur die Inputgrößen berücksichtigt und nur den Detaillierungsgrad aufweist, der von dem Modellersteller als sinnvoll erachtet wird. So repräsentiert die 2. Stufe eher ein White-Box Modell, bei dem die physikalischen Zusammenhänge erklärt und nachvollziehbar sind. Die 5. Stufe hingegen umfasst die Methoden des maschinellen Lernens, welche oftmals aufgrund der fehlenden Information und Nachvollziehbarkeit der Ergebnisfindung als Black-Box Modelle aufgefasst werden können. Jede Stufe ist soweit generisch gestaltet, dass sie das Testen von verschiedenen Lösungsalternativen zulässt, um das jeweilige Ziel der Stufe zu erreichen. Die optimale Lösung für das Gesamtsystem kann dann innerhalb des Problemlösungszyklus gefunden werden, indem iterativ über die Stufen hinweg sowie innerhalb einer Stufe die beste Lösungsalternative bestimmt wird.

4.2 Vorgehensmodell zur Nutzung von Methoden des maschinellen Lernens zur prozessparallelen Qualitätsprognose

Aus dem vorherigen Kapitel wird ersichtlich, dass die Anwendung der Systemtechnik für die Konzeption eines Vorgehensmodells für das in dieser Arbeit betrachtete System der Qualitätsprognose geeignet und gerechtfertigt ist. Erst hierdurch wird das System beherrschbar, indem die mit der Umsetzung notwendigen Aufgaben sowie involvierten fachlichen Disziplinen erkannt, gruppiert und chronologisch berücksichtigt werden. Die Modellierung kommt zudem zum Einsatz, um Untersysteme zu erschaffen, die nur die als notwendig erachteten Inputgrößen zur Zielerreichung berücksichtigen und somit zur Komplexitätsreduktion beitragen. Das durch das Befol-

gen dieses Vorgehens abgeleitete sowie im weiteren Verlauf dieser Arbeit genutzte Vorgehensmodell ist in Abbildung 4-2 dargestellt. In diesem Kapitel erfolgt die Konzeption und Beschreibung des Modells von einer Metaebene aus. In dem Kapitel 5 wird schließlich, bezogen auf den Anwendungsfall, die Detaillierung jeder einzelnen Stufe vollzogen, indem erneut die methodischen Grundlagen der Systemtechnik zum Tragen kommen.

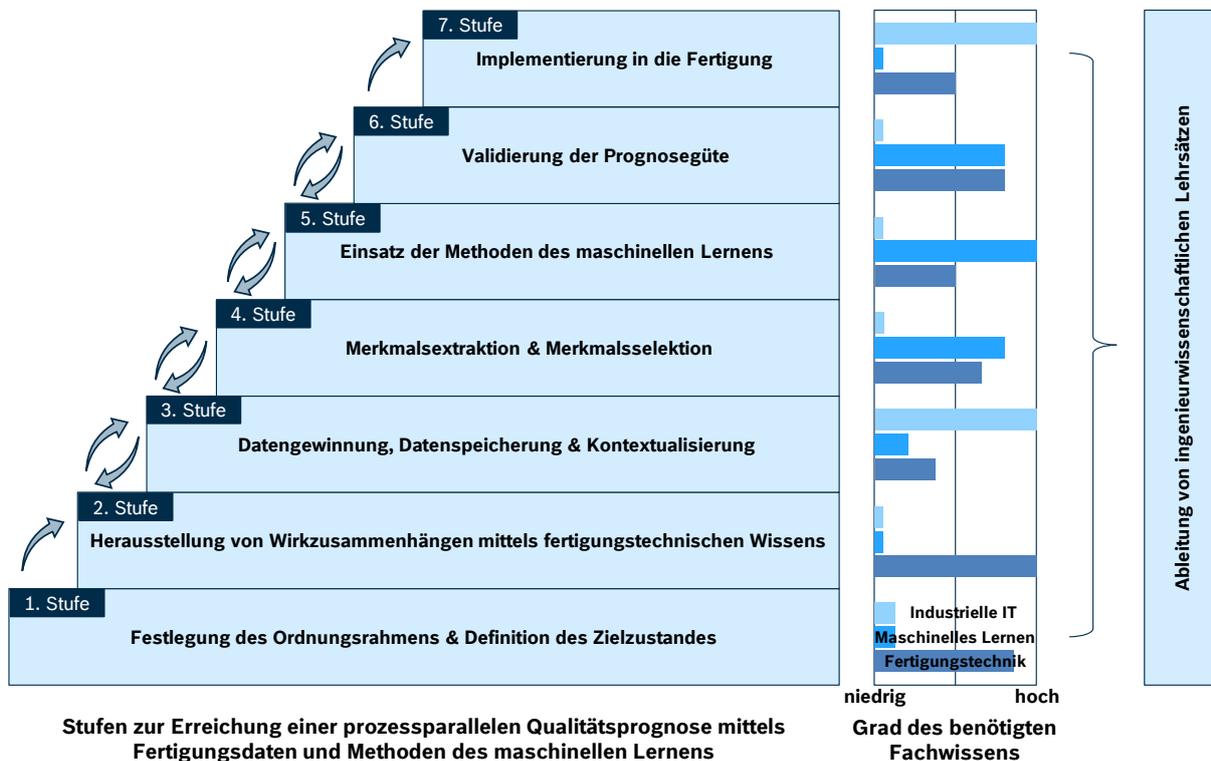


Abbildung 4-2: Vorgehensmodell zur Etablierung einer prozessparallelen Qualitätsprognose

Das Vorgehensmodell gliedert sich in insgesamt sieben horizontale Stufen, die die involvierten Aufgaben auf dem Weg zu einer Qualitätsprognose im Kontext dieser Arbeit darstellen, sowie zwei vertikale Balken, welche zum einen ingenieurwissenschaftliche Lehrsätze ableiten, zum anderen den Grad des benötigten Fachwissens der Hauptdomänen (Fertigungstechnik, maschinelles Lernen und industrielle IT) zu den Stufen qualitativ aufzeigen. Jede Stufe hat ihren festen Platz in der Abfolge sowie einen klar abgegrenzten Aufgabenumfang. Prinzipiell baut eine Stufe auf den Erkenntnissen der vorherigen Stufe bzw. Stufen auf, dennoch sind Iterationen über mehrere Stufen möglich, was durch die Pfeile angedeutet ist. Bei der Festlegung der Inhalte und der Reihenfolge der Stufen sind die Methoden CRISP-DM (Cross-industry standard process for data mining) [SHEA00] und KDD (Knowledge discovery in databases) [FAYY96] sowie die im Rahmen dieser Dissertation diesbezüglich gesammelten Erfahrungen eingeflossen.

Das Ableiten von ingenieurwissenschaftlichen Lehrsätzen soll dazu beitragen, die gewonnen Erkenntnisse auf jeder Stufe prägnant zusammenzufassen und somit die

Basis für einen Transfer auf weitere Fertigungsverfahren oder Qualitätsmerkmale zu ermöglichen. Insbesondere für die Stufen, für die Fachwissen zu dem maschinellen Lernen von hoher Relevanz ist und das fertigungstechnische Verständnis in den Hintergrund rückt, stellen solche Lehrsätze eine Orientierungshilfe und Wissenserweiterung für den Fertigungsingenieur dar. Die qualitative Verteilung des benötigten Fachwissens aus den Domänen Fertigungstechnik, maschinelles Lernen und industrielle IT ist gesondert zu jeder Stufe dargestellt. Das fertigungstechnische Wissen ist auf nahezu jeder Stufe des Vorgehensmodells gefragt. Es ist notwendig, um die Wirkzusammenhänge zwischen dem Fertigungsprozess und der Fertigungsqualität zu beschreiben und somit die relevanten Fertigungsgrößen auszuwählen. Zudem kann die Bewertung der selektierten Merkmale sowie der erzielten Qualitätsprognosen und die Validierung mit Qualitätsmanagementmethoden nur mit Hilfe von fertigungstechnischem Wissen erfolgen. Das maschinelle Lernen gewinnt mit den oberen Stufen des Modells an Bedeutung, bei denen es um die Verarbeitung der erfassten Daten sowie die Auswahl und Validierung von Algorithmen zur Qualitätsprognose geht. Die industrielle IT umfasst alle Tätigkeiten für die horizontale und die vertikale Vernetzung der Komponenten der Automatisierungspyramide. Sie ist unverzichtbar für die programmiertechnische Umsetzung der Datenerfassung, Datenspeicherung, Kontextualisierung sowie für die Implementierung der Qualitätsprognose in der Fertigung.

Bevor im Kapitel 5 die Detaillierung des Vorgehensmodells vollzogen wird, soll im Folgenden der Inhalt sowie der Zweck jeder einzelnen Stufe kurz vorgestellt werden. Begonnen wird chronologisch mit der ersten Stufe „Festlegung des Ordnungsrahmens & Definition des Zielzustandes“. Die erste Stufe dient dazu, den Ausgangszustand aufzunehmen sowie den angestrebten Zielzustand klar zu definieren. Es sollen die folgenden grundlegenden Punkte geklärt und dokumentiert werden:

- Um welches Werkstück handelt es sich und welche Werkstückkomponente wird detailliert betrachtet?
- Welches Ziel wird mit der Einführung einer prozessparallelen Qualitätskontrolle angestrebt?
- An welcher Stelle der Prozesskette ist der Fertigungsschritt einzuordnen?
- Mit welchen Fertigungsverfahren wird die Werkstückkomponente gefertigt?
- Welche Qualitätsmerkmale und Toleranzen charakterisieren die Komponente?

Auf Basis der erhaltenen Antworten werden für die folgenden Stufen notwendige sowie richtungsweisende Informationen generiert, wie z. B. die Anzahl der zu berücksichtigenden Fertigungsschritte oder ob es sich um ein Regressions- oder Klassifikationsproblem handelt, was maßgeblich die Auswahl der Methoden des maschinellen Lernens beeinflusst.

Die zweite Stufe „Herausstellung von Wirkzusammenhängen mittels fertigungstechnischen Wissens“ zielt darauf ab, die auf die Werkstückqualität einwirkenden Einflussgrößen zu beleuchten sowie ihre Wichtigkeit für das Prognosemodell zu bewerten. Für die Berücksichtigung einer Größe in dem Prognosemodell spielt zum einen

ihre technische sowie wirtschaftliche Erfassbarkeit und zum anderen ihr Beitrag an der Prognosegenauigkeit eine Rolle. Eine Entscheidung bzw. ein Kompromiss muss für jede Größe einzeln erfolgen. Neben der Anzahl der zu erfassenden Größen spielt auch z. B. die Frequenz, mit der die Größen aufgezeichnet werden, eine entscheidende Rolle und beeinflusst maßgeblich die Menge der zu speichernden und zu verarbeitenden Daten. Der Informationsgehalt, ausgehend von einer Größe und der Erfassungsfrequenz, lässt sich jedoch oftmals erst auf späteren Stufen bewerten und macht somit ein iteratives Vorgehen notwendig. Bei der Bewertung von Wirkzusammenhängen ist das Einbringen von fertigungstechnischem Wissen sowie das tiefgehende Verständnis des Fertigungsprozesses unabdingbar. Somit hat die Skala, die den Grad des benötigten Fachwissens zu jeder Stufe abbildet, bei dieser Stufe die maximale Ausprägung bei der Fertigungstechnik.

Nachdem die zu erfassenden Daten bestimmt wurden, beschäftigt sich die dritte Stufe mit der „Datengewinnung, Datenspeicherung & Kontextualisierung“. Unter Datengewinnung wird das Festlegen der Datenquellen sowie der Übertragungstechnologie verstanden. Als Datenquellen können u. a. die NC-Steuerung, die SPS oder zusätzliche Sensorik dienen. Für die Übertragung der Daten zum Datenspeicher sind zudem geeignete Kommunikationsprotokolle sowie Übertragungstechnologien in Abhängigkeit von ihrer Übertragungsrate und Kompatibilität auszuwählen. Die Datenspeicherung legt zum einen die Speichertechnologie (z. B. Datenbank oder Filesystem) und zum anderen den Speicherort fest. Grundsätzlich wird bei dem Ort der Datenspeicherung zwischen unternehmensexterner (z. B. in einer Cloud) und unternehmensinterner (z. B. Server, PC) Speicherung unterschieden. Beide Varianten haben ihre Vor- und Nachteile hinsichtlich Skalierbarkeit, Verfügbarkeit und des Schutzes der Daten vor unberechtigtem Zugriff durch Dritte. Die Wahl des Speicherortes wird zudem durch die verfügbare Infrastruktur und den Ort, an dem die Datenverarbeitung stattfinden soll, mitbestimmt. Unter dem Punkt Kontextualisierung wird die kontextbasierte Speicherung der erfassten Daten verstanden. Die gewonnenen Daten von den einzelnen Datenquellen werden über einen eindeutigen Bezug (z. B. Zeitstempel, NC-Satz) zusammengefasst und eine Zugehörigkeit zu einem Werkstück, einer Maschine, einem Werkzeug oder einem Bearbeitungsschritt wird hierdurch erst vollzogen. Zu der Kontextualisierung kann zudem noch eine Datenaufbereitung gezählt werden, die z. B. das Eliminieren von Ausreißern oder das Auffüllen von fehlenden Daten umfasst. Aber auch die Konvertierung der Daten in ein Format, das für die spätere Merkmalsextraktion oder die genutzte Methode des maschinellen Lernens notwendig ist, fällt darunter. Die für diese Stufe benötigten Fähigkeiten kommen hauptsächlich aus dem Bereich der industriellen IT.

Nachdem ein Bezug der Daten zu einem Werkstück hergestellt wurde, folgt mit der vierten Stufe die „Merkmalsextraktion & Merkmalsselektion“. Die Merkmalsextraktion wird notwendig, um die oftmals in Zeitreihen vorliegenden Daten in einzelne Werte zu überführen, die die charakteristischen Merkmale der Zeitreihe abbilden und die Anzahl von Datenpunkten deutlich reduzieren. Es existieren viele verschiedene Ansätze und Verfahren für eine Merkmalsextraktion, welche jeweils individuell zu der

Struktur der Zeitreihe oder zur Bestimmung von bereits bewährten Merkmalen ausgewählt werden. Grundsätzlich folgt die Bestimmung der Merkmale einem „Try and Error“ Ansatz, bei dem am Ende nur die Merkmale beibehalten werden, die zu einer hohen Prognosegenauigkeit bei der gewählten Methode des maschinellen Lernens führen. Ein limitierender Faktor bei der Auswahl der Extraktionsmethode kann die benötigte Berechnungsdauer sein, wenn eine Prognose in nahezu Echtzeit notwendig sein sollte. Erst durch die Merkmalsextraktion wird der Einsatz von Methoden des maschinellen Lernens mit flachen Strukturen möglich, da sie die hohe Anzahl von Daten einer Zeitreihe nicht verarbeiten können. Methoden mit tiefen Strukturen können hingegen die Zeitreihen direkt für die Prognosen nutzen (siehe Kapitel 2.4). Auf die Merkmalsextraktion folgt die Merkmalsselektion, die die Anzahl der Merkmale reduziert, indem sie den Grad des Zusammenhangs zwischen Merkmal und Zielgröße (Qualitätsmerkmal) bestimmt. Erst auf Basis des Prognoseergebnisses kann final eine Entscheidung getroffen werden, welche Merkmale für die gewählte Methode des maschinellen Lernens von Relevanz sind. Entsprechend sind Iterationen zwischen der vierten und der fünften Stufe oftmals unumgänglich.

Die fünfte Stufe adressiert schließlich den „Einsatz der Methoden des maschinellen Lernens“. Das Ziel der Stufe ist es, die zu dem Anwendungsfall bzw. dem Qualitätsmerkmal am besten geeignete Methode aus dem Bereich des maschinellen Lernens für die angestrebte Prognose zu bestimmen. Um die beste Parametrierung der Methoden zu erreichen, wird eine Grid Search oder eine Random Search angewendet. Mittels Kreuzvalidierung wird die Prognosegenauigkeit und Prognosezuverlässigkeit bestimmt. Durch die Berechnung von Indikatoren, wie z. B. Standardabweichung der Prognosen, maximaler Prognosefehler oder mittlerer absoluter Prognosefehler, wird eine Vergleichbarkeit der einzelnen Methoden ermöglicht. Zusätzlich lässt sich die Eignung der Methoden durch das Auswerten der Lernkurven bewerten. Wie bereits erwähnt, steht die fünfte Stufe im engen Austausch mit der vorangegangenen Stufe aufgrund der Auswahl von geeigneten Merkmalen, die den Zusammenhang zwischen Fertigungsdaten und Zielgröße am besten beschreiben. Bei dieser Stufe ist zudem ein hoher Grad an Fachwissen zu der Thematik maschinelles Lernen notwendig, was in dem Vorgehensmodell durch die entsprechende Skala angedeutet ist.

Die vorletzte (sechste) Stufe beschäftigt sich mit der „Validierung der Prognosegüte“ auf zwei Arten. Zum Ersten werden die klassischen Validierungsansätze des maschinellen Lernens angewendet, die auch schon auf der fünften Stufe zum Tragen gekommen sind. Und zum Zweiten wird eine Validierung der Prognose mittels der Methoden des Qualitätsmanagements in der Fertigung angestrebt, indem z. B. eine Art Messmittelfähigkeit für die trainierte Methode des maschinellen Lernens bestimmt wird.

Mit der letzten Stufe des Vorgehensmodells „Implementierung in die Fertigung“ erfolgt schließlich die Implementierung und die Integration der prozessparallelen Qualitätsprognose auf Basis von Fertigungsdaten und Methoden des maschinellen Lernens in den Fertigungsprozess. Somit führt das Vorgehensmodell von der Aufnahme des Ausgangs- und Zielzustandes über die Herleitung und Findung einer adäquaten

Lösung (durch teilweise iteratives Vorgehen) hin zu einem Zustand, bei dem eine Umsetzung der gefundenen Lösung in die Fertigung möglich wird.

Außerdem werden die gewonnenen Erkenntnisse von jeder Stufe in ingenieurwissenschaftliche Lehrsätze überführt. Diese Lehrsätze sind generisch formuliert und sollen hierdurch den Transfer der Inhalte einer jeden Stufe auf Fertigungsverfahren und Qualitätsmerkmale ermöglichen, die in dieser Arbeit nicht betrachtet werden. Der Fertigungsingenieur erhält mit den Lehrsätzen somit eine auf seinen Tätigkeitsbereich abgestimmte Erläuterung des Themenfeldes „maschinelles Lernen“.

5 Detailierung und Realisierung einer prozessparallelen Qualitätsprognose

In diesem Kapitel erfolgt die Detailierung des in Kapitel 4.2 eingeführten Vorgehensmodells. Hierfür wird jede Stufe des Vorgehensmodells im Detail betrachtet und die notwendigen Schritte sowie Technologien zur Einführung einer prozessparallelen Qualitätsprognose erläutert. Sukzessiv werden die Inhalte einer jeden Stufe anhand des in Kapitel 1 eingeführten Anwendungsfalls aus der industriellen Fertigung erarbeitet. Hierdurch werden die in Kapitel 3 aufgestellten Forschungsfragen beantwortet und die Technologie maschinelles Lernen dem Fertigungsingenieur nahegebracht. Der hierbei entwickelte Prototyp einer Qualitätsprognose und die gewonnenen Erkenntnisse dienen letztendlich zur Ableitung von Lehrsätzen.

5.1 Festlegung des Ordnungsrahmens und Definition des Zielzustandes

In diesem Kapitel wird der konkrete Anwendungsfall erläutert und in den Kontext eingeordnet, für den die Qualitätsprognose durch die Anwendung des Vorgehensmodells erstellt werden soll. Hierbei wird strikt die Leitidee einer hierarchischen Gliederung vom Groben zum Detail (Top-down-Ansatz) der Systemtechnik und der Modellierung befolgt. Demnach wird zuerst das Hydraulikventil im Ganzen vorgestellt und dann der Fokus auf die Komponente gerichtet, für die die Qualitätsprognose eingeführt werden soll. Durch die Betrachtung aller Schritte der Ventilherstellung wird ein Ordnungsrahmen geschaffen, welcher es für die betrachtete Ventilkomponente ermöglicht, ein Untersystem mit den zu berücksichtigenden Fertigungsschritten sowie den zu berücksichtigenden Einflussgrößen zu bilden. Mit der Definition des Zielzustandes wird gleichzeitig auch schon eine Vorauswahl an möglichen Methoden des maschinellen Lernens getroffen.

5.1.1 Beschreibung der Ventilkomponente und Festlegung des Ordnungsrahmens

In Kapitel 1.2 wurde als Ziel dieser Arbeit die Einführung einer Qualitätsprognose auf Basis von maschineninternen Daten und Methoden des maschinellen Lernens ausgegeben. Hierdurch wäre es möglich, die Qualitätskontrolle, welche im gegenwertigen Zustand zeitlich nach dem Fertigungsprozess erfolgt, in den Fertigungsprozess zu integrieren und somit zeitparallel die Qualität zu kontrollieren. Die Kenntnis der Qualität von jedem einzelnen Werkstück in kürzester Zeit nach einem Fertigungsschritt würde neue Handlungs- und Gestaltungsmöglichkeiten bei dem Fertigungsprozess sowie innerhalb der Prozesskette eröffnen.

Eine derartige Qualitätsprognose soll in dieser Arbeit für die Fertigung von Hydraulikventilen am Beispiel der in Abbildung 5-1 dargestellten Komponente Druckwaagenbohrung aufgebaut werden. Ein Hydraulikventil hat die Aufgabe, die von einer Pumpe

für einen Verbraucher bereitgestellte hydraulische Energie zu regeln. Die Druckwaage in einem Hydraulikventil hat hierbei die Funktionalität, einen konstanten Durchflussstrom bei wechselnden Druckverhältnissen zu garantieren. Druckgradienten können somit von dem Ventil kompensiert werden. Die Druckwaage setzt sich aus der Druckwaagenbohrung mit ihren Funktionsflächen sowie einem variablen verstellbaren Schieber zur Sperrung oder Öffnung von Kanälen zur Druck- und Volumenstromregelung zusammen. Die Funktionalität der Druckwaage wird maßgeblich beeinflusst durch den Dichtspalt zwischen Funktionsflächen und Schieber, der ein axiales Klemmen des Schiebers sowie eine zu hohe Leckage des Fluides zwischen den Kanälen verhindern soll. Enge Maß-, Lage- und Formtoleranzen für die Druckwaagenbohrung sowie unterschiedliche Durchmesserklassen für den Schieber ermöglichen entsprechende Paarungen zur Erreichung des benötigten Dichtspaltes. Eine Qualitätsprognose soll für die Qualitätsmerkmale Durchmesser, Rundheit, Geradheit und Konzentrität der Druckwaagenbohrung erfolgen, indem die Fertigungsgrößen, die während dem Bohren und Reiben der Bohrung auftreten, erfasst und für die Prognose genutzt werden.

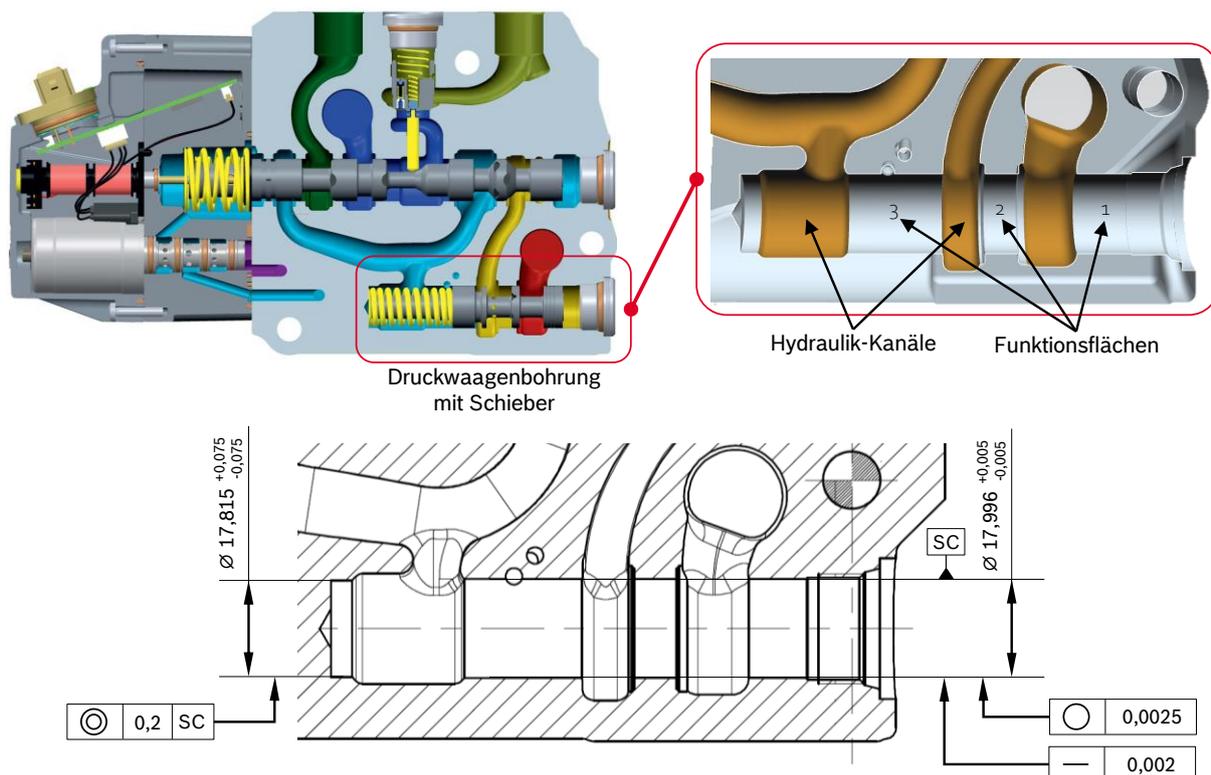


Abbildung 5-1: Schnittmodell des betrachteten Ventils sowie Toleranzen der Druckwaagenbohrung

Von größtem Interesse ist eine möglichst genaue Prognose des Durchmessers, da dieser in der Fertigung die größte Streuung von allen Qualitätsmerkmalen aufweist. Aufgrund der Durchmesserschwankung muss in der Montage eine manuelle Messung des Durchmessers durchgeführt werden und Schieber mit unterschiedlichen Durchmessern vorgehalten werden, um eine Kompensation der Schwankungen aus-

gleichen zu können. Demnach ist eine individuelle Paarung von Bohrung und Schieber für jedes Ventil notwendig. Die Qualitätsprognose ließe eine Fertigung des Durchmessers mit geringerer Streuung zu oder ermöglichte bereits in einem frühen Zeitpunkt der Fertigungskette die Bereitstellung der Information, welche Anzahl von Schiebern von jeder Durchmesserklasse für ein Produktionslos in der Montage benötigt wird. Alle weiteren Qualitätsmerkmale können im Durchschnitt stets im geforderten Toleranzfenster mit niedriger Streuung erreicht werden. Eine möglichst genaue Prognose dieser Merkmale wird zwar nach Möglichkeit auch angestrebt, hat jedoch im Vergleich zum Durchmesser einen geringeren Stellenwert bzw. eine geringere wirtschaftliche Bedeutung. Die Bohrung hat keine durchgehende Außenwand, sondern wird aufgrund der Kanäle in drei Abschnitte geteilt. Dies führt zu einem unterbrochenen Schnitt bei der Bearbeitung, welcher im Kapitel 5.2 näher betrachtet wird.

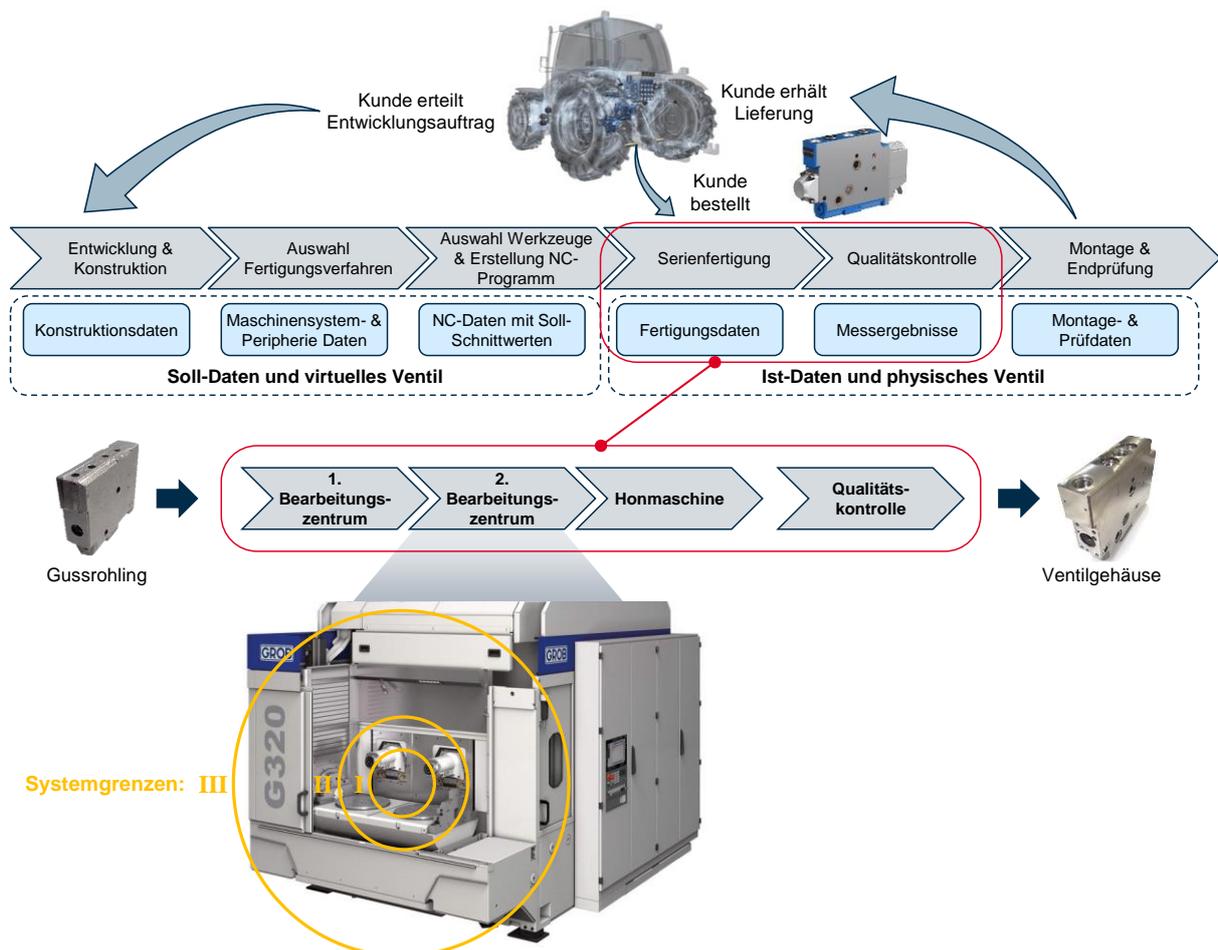


Abbildung 5-2: Ordnungsrahmen für die Qualitätsprognose in dieser Arbeit (Bildquellen: [GROB20; BOS21])

In Abbildung 5-2 ist der Ordnungsrahmen aufgezeigt, der den betrachteten Anwendungsfall umgibt bzw. aus dem der betrachtete Anwendungsfall stammt. Demnach beginnt die Initiierung eines Hydraulikventils mit dessen Entwicklung und Konstruktion aufgrund eines Kundenauftrages. Auf Basis der Konstruktionszeichnung erfolgt

dann die Auswahl der technisch und wirtschaftlich am geeignetsten Fertigungsverfahren. Sind die Fertigungsverfahren bestimmt, folgt darauf die Auswahl der Zerspanungswerkzeuge und die Erstellung des NC-Programms. Daran schließt sich die Fertigung und die Qualitätskontrolle der Ventilgehäuse an. Letztendlich erfolgt die Montage des Ventils, indem alle notwendigen Komponenten in dem Ventilgehäuse verbaut werden. Die Endprüfung garantiert die Funktionsfähigkeit des Ventils und deckt Qualitätsabweichungen auf, die bis zu diesem Zeitpunkt unentdeckt geblieben sind. Der Kunde bekommt letztendlich die von ihm bestellte Anzahl von Hydraulikventilen geliefert.

Bis zu dem Punkt, in dem die Fertigung des Ventils beginnt, existiert das Ventil lediglich virtuell und alle verfügbaren Daten (Konstruktionsdaten, Maschinensystemdaten und Soll-Schnittwerte) repräsentieren ausschließlich die Soll-Geometrie des Ventils oder die Fertigungsgrößen, die während der Fertigung erwartet werden und auftreten sollen. Ab der physischen Fertigung des Ventils existieren dann die tatsächlichen Fertigungsdaten sowie die Ist-Geometrie des nun physisch vorliegenden Ventils, welche in dieser Arbeit erfasst und zur Qualitätsprognose herangezogen werden.

Die Fertigung eines Ventils erfolgt mittels einer Fertigungskette, welche verschiedene spanende Fertigungsverfahren und Bearbeitungszentren umfasst. Das hier betrachtete Ventilgehäuse wird durch die spanende Bearbeitung eines vorgegossenen Graugussrohrlings (GG30) mithilfe von zwei Bearbeitungszentren und einer Honmaschine sowie mehreren Entgrat- und Reinigungsprozessen gefertigt. Die vollständige Bearbeitung der betrachteten Druckwaagenbohrung wird auf dem zweiten Bearbeitungszentrum der Fertigungskette (siehe Abbildung 5-2) durchgeführt und es werden hierzu ein Pilotierer, ein Wendelbohrer sowie eine Reibahle als Zerspanungswerkzeuge verwendet. Da sich die Bearbeitung auf ein Bearbeitungszentrum beschränkt, ist es für die Prognose der Qualitätsmerkmale der Druckwaagenbohrung ausreichend, die Fertigungsdaten nur von dieser einen Maschine zu erfassen. Es muss nun der Betrachtungshorizont hinsichtlich der zu berücksichtigten Einflüsse und Komponenten festgelegt werden. Es bietet sich an, die an dem Zerspanungsprozess beteiligten Komponenten aufgrund ihrer Veränderung über die Zeit in drei Systeme einzuteilen, welche sich durch ihre Systemgrenze (I bis III) von dem sie umgebenden Umfeld abgrenzen. Die Komponenten werden im Folgenden als Elemente im Sinne der Systemtechnik bezeichnet (siehe Kapitel 4.1). In dem ersten System (I) werden die Elemente zusammengefasst, die eine Veränderung in kurzen Zeitabständen erfahren und somit für jedes Ventilgehäuse verschieden sein können. Dies sind zum einen die Zerspanungswerkzeuge, welche einem Verschleiß ausgesetzt sind und zum weiteren der Gussrohling, welcher in Abhängigkeit von der Gusscharge in der Werkstoffzusammensetzung und -härte schwanken kann. In dem zweiten System (II) sind die Elemente enthalten, die nur mittelfristig einer Veränderung unterliegen, hierzu zählen die Werkstückspannvorrichtung, das NC-Programm, Umgebungseinflüsse (Temperatur, Kühlschmierstoff, etc.) sowie der Maschinenbediener. Mit einem dritten System (III) werden die Elemente vereint, die sich nur über einen sehr langen Zeithorizont verändern. Hierzu zählen hauptsächlich Maschinenkomponenten, wie z.B.

Führungsbahnen, Kugellager und Sensorik. Ziel dieser Arbeit ist, den wissenschaftlichen Beweis zu erbringen, dass das Vorhaben einer Qualitätsprognose auf Basis von Fertigungsdaten zusammen mit Methoden des maschinellen Lernens möglich ist. Hierfür sollen vorerst nur die Elemente berücksichtigt werden, welche direkt in den Zerspanungsprozess involviert sind und somit stets einen möglichen Einfluss auf die Werkstückqualität haben. In diesem Fall wären dies die Elemente des ersten Systems. Die Elemente des zweiten Systems sind auch von hoher Wichtigkeit für die erreichte Qualität, werden jedoch in dieser Arbeit nicht berücksichtigt. Dies lässt sich dadurch rechtfertigen, da diese Elemente einer geringeren zeitlichen Veränderung unterworfen sind und mögliche Abweichungen vom Normalzustand bereits von dem Bearbeitungszentrum überwacht werden. So verfügt das in dieser Arbeit verwendete Bearbeitungszentrum über eine automatische Temperaturkorrektur, um Einflüsse aufgrund von Temperaturschwankungen auszugleichen. Außerdem wird die richtige Positionierung des Gussrohlings in der Spannvorrichtung durch eine Auflagenkontrolle und eine Spanndrucküberwachung während der Bearbeitung gesichert. Der Einfluss des Maschinenbedieners lässt sich nur sehr schwer erfassen und überwachen bzw. in ein Prognosemodell integrieren, zudem verliert sein Einfluss bei einer vollautomatisierten Fertigungsanlage an Bedeutung. Die Elemente und Einflussfaktoren des dritten Systems fallen nicht in den Betrachtungshorizont dieser Arbeit, da sie sich im Normalzustand nur sehr langsam und geringfügig über einen mehrere Jahre umfassenden Zeitraum verändern.

Die in dieser Arbeit entwickelte Qualitätsprognose ist gekennzeichnet einerseits durch das Abbildungsmerkmal, welches ausschließlich die Prognose der Qualität der Druckwaagenbohrung repräsentiert sowie andererseits durch die Verkürzungsmerkmale, welche durch die Elemente des Systems I definiert werden. Die dritte Kennzeichnung der Qualitätsprognose ergibt sich aus den pragmatischen Merkmalen, die den Zustand definieren, für die die Qualitätsprognose an Gültigkeit besitzt. Die Prognose besitzt demnach an Gültigkeit, wenn die Elemente der Systeme II und III keinen Einfluss auf den Zerspanungsprozess haben, da sie entweder keiner Veränderung im Betrachtungszeitraum unterliegen oder durch die Maschine bereits kompensiert bzw. überwacht werden. Durch diese drei Merkmale wird grundsätzlich ein Modell definiert, sodass die Qualitätsprognose auch als ein Modell betrachtet werden kann, bei dem die Inputgrößen reale Fertigungsdaten sind und der Zusammenhang zwischen Inputgrößen und Qualitätsmerkmalen durch die Methoden des maschinellen Lernens hergestellt wird.

5.1.2 Definition des Zielzustandes

Der allgemeine Zielzustand, die Einführung einer Qualitätsprognose, ist in Kapitel 1.2 bereits ausführlich erläutert. In diesem Kapitel soll nun die Qualitätsprognose auf den spezifischen Anwendungsfall heruntergebrochen und konkretisiert werden. Ziel ist es demnach, den Durchmesser, die Rundheit, die Geradheit sowie die Konzentrizität einer Bohrung zu prognostizieren, wobei das Augenmerk auf einer möglichst genau-

en Prognose des Durchmessers liegt. Die Prognosen sollen in numerischer Form (Dezimalzahlen) vorliegen, wie sie auch beim Messen der Qualitätsmerkmale üblich sind. Anhand dieser Prognosewerte ließe sich eine Beurteilung treffen, ob die Bohrung noch innerhalb der Toleranz bzw. wie nah an der Toleranzgrenze liegt. Demnach handelt es sich, mit Blick auf die Methoden des maschinellen Lernens, um ein Regressionsproblem (siehe Kapitel 2.4). Dementsprechend müssen geeignete Regressions-Methoden für die Prognose ausgewählt werden. In der Montage werden drei Klassen von Schieber verwendet, um die Durchmesserschwankungen der Druckwaagenbohrung zu kompensieren. Soll hingegen nur die zu montierende Klasse an Schieber prognostiziert werden, so kann die Durchmesserprognose auch als ein Klassifikationsproblem aufgefasst werden. In dieser Arbeit soll der Schwerpunkt auf der Prognose von numerischen Werten anstelle von Klassen liegen.

Die Prognosen sollen auf der Basis von NC-internen Fertigungsdaten, welche von den Spindel- und Achsantrieben des Bearbeitungszentrums stammen, erzielt werden. Das Nutzen von maschineninternen Daten stellt eine sehr wirtschaftliche und für die industrielle Fertigung geeignete sowie zuverlässige Lösung dar. Eine zusätzliche Integration von Sensorik am Werkzeug oder Spannvorrichtung ist aufgrund des Einsatzes von Kühlschmierstoff, der Anzahl von Werkzeugen sowie des Rotierens der Spannvorrichtung während der Bearbeitung für den betrachteten Anwendungsfall nicht umsetzbar. Welche Fertigungsdaten im Speziellen erfasst werden sollen, wird auf der nächsten Stufe dieses Vorgehensmodells „Herausstellung von Wirkzusammenhängen mittels fertigungstechnischen Wissens“ detailliert aufgeführt.

5.2 Herausstellung von Wirkzusammenhängen mittels fertigungstechnischen Wissens

Dieses Kapitel leitet die zu erfassenden Daten auf der Basis bekannter Ursachen-Wirkungs-Zusammenhänge her und bewertet die Notwendigkeit von einzelnen Größen.

5.2.1 Einflussgrößen und Wirkzusammenhänge bei Bohr- und Reibprozessen

In Kapitel 5.1 wurde das Hydraulikventil sowie die betrachtete Bohrung mit den charakterisierenden Qualitätsmerkmalen und der Ordnungsrahmen vorgestellt. Im Folgenden sollen nun Fertigungsgrößen durch den Einsatz von fertigungstechnischem Wissen bestimmt werden, die zur Prognose der Qualitätsmerkmale herangezogen werden können. In Kapitel 2.1 wurden die Fertigungstechnologien Bohren und Reiben eingeführt und mögliche Ursachen, die zu Qualitätsabweichungen bei der Bohrung führen können, beschrieben. Dieses Wissen zusammen mit einem physikalischen Grundverständnis zu dem vorliegenden Fertigungsprozess sowie der Maschinenkinematik ermöglicht das Aufstellen der Tabelle 2.

Qualitätsmerkmal	Häufig auftretende Ursachen für eine Qualitätsabweichung in der Serienfertigung		Maschineninterne Signale für die Prognose
	Bohrer	Reibahle	
Durchmesser	- Verschleiß an den Schneidecken, Schneidkanten & Führungsphasen	- radiale Lage der Schneidplatte - Verschleiß an der Schneidplatte	- Drehmoment der Spindel - Werkzeugeinsatzzeit
Rundheit	- ungleichmäßige Passivkräfte an der Bohrspitze - ungleichmäßiger Verschleiß - Rundlauffehler	- Versatz zwischen Spindel- und Werkzeugachse mit Bohrungsachse (->Schwankungen der Schnitt- & Passivkraft)	- Drehmoment der Spindel - Werkzeugeinsatzzeit - Position/ Stromaufnahme der X- & Y-Achse
Geradheit	- ungleichmäßige Passivkräfte an der Bohrspitze - Zentrierwirkung des Bohrspitzenanschliffes - ungleichmäßiger Verschleiß - Rundlauffehler	- Versatz zwischen Spindel- und Werkzeugachse mit Bohrungsachse (->Schwankungen der Schnitt- & Passivkraft)	- Drehmoment der Spindel - Werkzeugeinsatzzeit - Position/ Stromaufnahme der X- & Y-Achse
Konzentrität	- ungleichmäßige Passivkräfte an der Bohrspitze - Zentrierwirkung des Bohrspitzenanschliffes - ungleichmäßiger Verschleiß - Rundlauffehler		- Drehmoment der Spindel - Werkzeugeinsatzzeit - Position/ Stromaufnahme der X- & Y-Achse

Tabelle 2: Maschineninterne Signale zur Prognose der Qualität der Bohrung in Abhängigkeit von den in der Serienfertigung am häufigsten auftretenden Ursachen

Der Durchmesser einer Bohrung wird durch einen Verschleiß der Schneidecken und Führungsphasen des Bohrers sowie durch die radiale Lage und den Verschleiß der Schneidplatte der Reibahle beeinflusst. Die Schnittkraft steigt degressiv mit dem Verschleiß an und äußert sich in einem entsprechenden Anstieg des Drehmomentes der Spindel (siehe Kapitel 2.1.1). Das von der Spindel aufgebraachte Drehmoment entfällt zu ca. 75% auf die Aufbringung der benötigten Schnitt- und Passivkraft der Hauptschneide sowie zu ca. 20% auf die Reibung der Führungsphasen und eignet sich demnach als ein guter Indikator für die Verschleißerkennung und für die resultierende Durchmesserreduzierung. Die Aufnahme der aktuellen Werkzeugeinsatzzeit als weitere Inputgröße für das Prognosemodell ermöglicht, im Zusammenhang mit dem vorliegenden Drehmoment, eine bessere Bewertung des Verschleißzustandes und eine genauere Prognose des Bearbeitungsergebnisses.

Die Rundheit, die Geradheit und die Konzentrität der Bohrung kann durch unterschiedlich stark auftretende Passivkräfte an den Hauptschneiden des Bohrers negativ beeinflusst werden. Die nicht gleichmäßig verteilten Passivkräfte verhindern die Selbstzentrierung des Bohrers und führen so zu Abweichungen von der geforderten Form und Lage der Bohrung. Ein fehlerhafter Bohrspitzenanschliff, ein ungleichmäßiger Verschleiß der Hauptschneide oder ein Rundlauffehler können die Verteilung der Passivkräfte beeinflussen und schwankende Schnittkräfte hervorrufen. Von dem Verlauf des Drehmoments der Spindel lassen sich mögliche Schwankungen der Schnittkraft sowie der Werkzeugverschleiß feststellen. Die Berücksichtigung der Werkzeugstandzeit soll die Prognosegenauigkeit zusätzlich erhöhen. Die unterschiedlich stark auftretenden Passivkräfte können bei starker Ausprägung durch die Abweichung der X- und Y-Achse von ihrer durch das NC-Programm vorgegebenen Soll-Position detektiert werden. Ebenso die Stromaufnahme dieser Achsen, welche

notwendig ist, um die Soll-Position zu halten, kann einen Rückschluss auf die Passivkräfte geben.

Die Koaxialität wird durch die Reibahle nicht beeinflusst, da durch den Reibprozess kein Einfluss auf die Lage der Bohrung genommen werden kann. Schwankende Schnitt- und Passivkräfte während des Reibens sind die Gründe für Rundheits- und Geradheitsabweichungen. Diese werden durch einen Versatz zwischen Spindel- und Werkzeugachse mit der Bohrungsachse hervorgerufen. Die alternierenden Kräfteverhältnisse können bei starker Ausprägung über das Drehmoment der Spindel sowie die Position oder die Stromaufnahme der X- und Y-Achsen festgestellt werden. Bei dem Reibprozess stellt das Eindringen der Reibahle in die Bohrung einen für die Qualität kritischen Moment dar. Dies kommt aufgrund des in diesem Moment noch fehlenden Kontakts der Führungsleisten mit der Bohrungswand, obwohl der Eingriff der Wendeschneidplatte bereits erfolgt und es hierdurch zu einer Ablenkung der Reibahle aus ihrer axialen Lage kommen kann.

In Tabelle 2 sind mögliche Ursachen für Maß-, Form- und Lageabweichungen einer Bohrung aufgeführt. Sie stellen die am häufigsten auftretenden Ursachen für eine Qualitätsabweichung der betrachteten Bohrung in der Serienfertigung dar. Weitere Ursachen, wie z.B. ein ins Spannfutter falsch eingespanntes Werkzeug, Materialfehler beim Werkzeug, Späne in der Werkzeugaufnahme der Spindel, etc., stellen Ausnahmezustände dar, welche in ihrer Häufigkeit unterrepräsentiert sind und daher bei der Erstellung des Prognosemodells nicht berücksichtigt werden. Das Prognosemodell soll die Standardeinflüsse der Serienfertigung umfassen und hierzu valide Prognosen liefern. Bei einer Weiterentwicklung des Prognosemodells können weitere Einflussgrößen sukzessiv mit aufgenommen werden. Welche Effekte die Qualität am stärksten beeinflussen (Bohrer oder Reibahle) und wie stark sie in den maschineninternen Signalen sich widerspiegeln, könnte statistisch bewertet werden, sollte jedoch vielmehr von den eingesetzten Methoden des maschinellen Lernens auf Basis der Trainingsdaten automatisch erkannt werden. Das automatisierte Lernen bietet die Möglichkeit, den Einsatz von menschlicher Intelligenz und Erfahrungswissen ab einem gewissen Punkt zu reduzieren und zudem komplexe Zusammenhänge zu erkennen, die für den Menschen nicht mehr erkennbar bzw. nachvollziehbar sind. Diese Fähigkeit des maschinellen Lernens soll genutzt werden, um die Prognosen zu erstellen, und der Mensch soll lediglich die hierfür notwendigen Daten auswählen sowie das Prognoseergebnis bewerten.

5.2.2 Festlegung der zu erfassenden Daten

Nach DENKENA kann ein Zerspanprozess im systemtechnischen Sinne als eine Black-Box mit Eingangs- und Ausgangsoperanden dargestellt werden (siehe Abbildung 5-3) [DENK11, S. 8]. Die Eingangsoperanden können in System- und Stellgrößen aufgeteilt werden. Die Systemgrößen stellen die Komponenten dar, die für den Zerspanungsprozess notwendig sind. Diese sind z. B. das Bearbeitungszentrum, die Spannvorrichtung, die Werkzeuge sowie die Form des Rohlings und der Werkstoff.

Die Stellgrößen sind hauptsächlich im NC-Programm hinterlegt (z. B. Drehzahl, Vorschubgeschwindigkeit, Position, Spannkraft) und geben vor, wie der Zerspanprozess ablaufen soll. Die Eingangsoperanden spiegeln die aus dem vorherigen Kapitel 5.1 (Stufe 1) erwähnten Soll-Daten wieder, die über einen längeren Zeithorizont invariant sind und somit auch als Metadaten bezeichnet werden können. Eine Erfassung von diesen Daten zu jedem Ventil ist ratsam, um die Ausgangsbedingungen für die Zerspanung im Nachhinein noch nachvollziehen zu können. Aufgrund ihrer Existenz über einen langen Zeitraum ist ihre Erfassung einmalig pro Ventil ausreichend (echtzeitunkritisch). Von höherer Bedeutung für die Qualitätsprognose sind die Fertigungsdaten, die nur während des Zerspanprozesses anfallen und daher in Echtzeit und mit möglichst hoher Abtastfrequenz erfasst werden müssen. Sie ermöglichen einen direkten Rückschluss auf die während der Zerspanung vorherrschenden Bedingungen. Zu den Fertigungsgrößen zählen z. B. das Drehmoment der Spindel oder die Position der Achsen. Nach dem Zerspanprozess liegen permanente Ergebnisse an dem Werkstück (Ventil), dem Werkzeug und dem Bearbeitungszentrum vor.

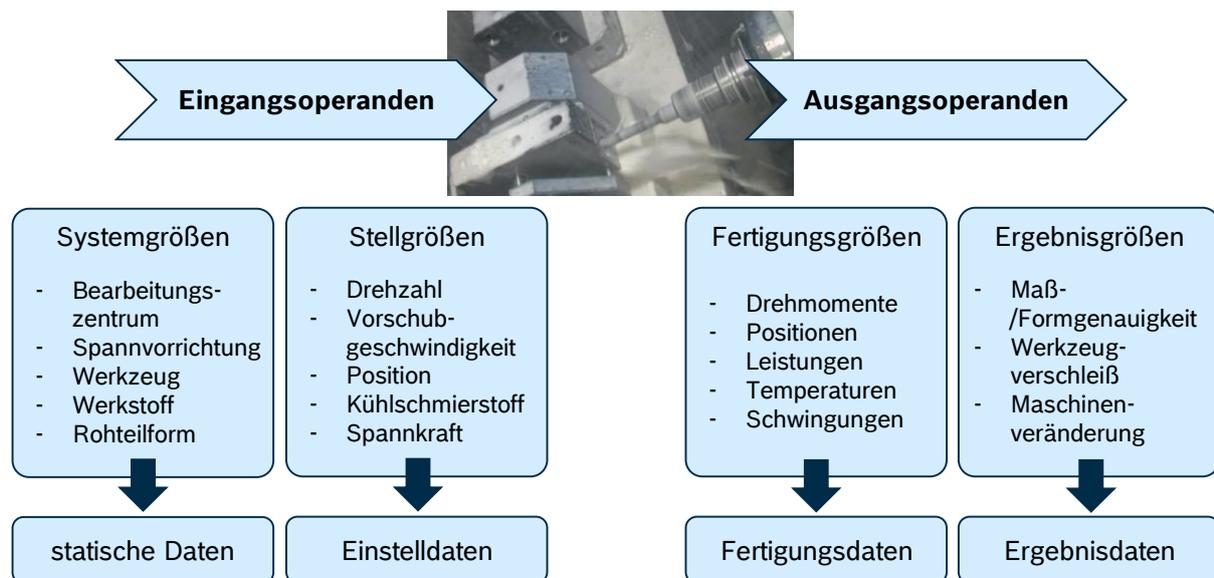


Abbildung 5-3: Eingangs- und Ausgangsoperanden bei der spanenden Bearbeitung [DENK11, S. 8]

Aufgrund des in dieser Arbeit betrachteten Zeithorizontes sind die Ergebnisse an dem Ventil sowie die Veränderungen des Werkzeuges von Relevanz für die Prognose. Die Ergebnisdaten erfassen somit die erreichte Maß-, Form- und Lagegenauigkeit der Bohrung des Ventils sowie die Standzeitveränderung der Bohrer und Reibahle. Eine Erfassung ist einmalig pro Ventil nach der Zerspanung ausreichend.

In Tabelle 3 sind die Größen der spanenden Bearbeitung aufgelistet, welche in dieser Arbeit bei der Prognose der Bohrungsqualität berücksichtigt werden. Unterscheidungsmerkmale der Größen sind ihre zeitliche Erscheinungsdauer sowie die Häufigkeit ihrer Erfassung pro Ventil. Größen, die sich während der Bearbeitung mit einer hohen Frequenz ändern können, müssen entsprechend hochfrequent und in Echtzeit

erfasst werden. Die Erfassung von echtzeitkritischen Daten stellt einen höheren Anspruch an die eingesetzte Technologie hinsichtlich ihrer Verfügbarkeit, Zuverlässigkeit und Verarbeitungsgeschwindigkeit (siehe Kapitel 5.3). Alle echtzeitunkritischen Daten stellen hingegen keine hohen zeitlichen Anforderungen an ihre Erfassungsfrequenz und eine einmalige Erfassung pro Ventil ist ausreichend.

System-, Stell-, Fertigungs- & Ergebnisgrößen der spanenden Bearbeitung	Einheit / Bezeichnung	Datenerfassung
Bearbeitungszentrum	ID-Nummer	Echtzeitunkritisch / einmalige Erfassung pro Ventil
Spannvorrichtung	ID-Nummer	
Werkzeugtyp	Lieferant & Benennung	
Ventiltyp	Benennung	
Gusscharge	Lieferant & Gießdatum	
NC-Programm	Version	
Drehmoment (Spindel, Achsen)	Nm bzw. %	Echtzeitkritisch / hochfrequente Erfassung
Drehzahl (Spindel)	1/min	
Position (Achsen)	mm	
Uhrzeit	hh:mm:ss:ms	
Datum	tt:mm:jjjj	Echtzeitunkritisch / einmalige Erfassung pro Ventil
Ventil ID	ID-Nummer	
Werkzeug ID	ID-Nummer	
Werkzeugeinsatzzeit	Sekunden	
Kühlschmierstoff	Lieferant & Konzentration	
Durchmesser	mm	
Geradheit	mm	
Rundheit	mm	
Konzentritizität	mm	

Tabelle 3: Berücksichtigte System-, Stell-, Fertigungs- und Ergebnisgrößen bei der spanenden Bearbeitung der Druckwaagenbohrung eines Ventils

5.2.3 Bestimmung der relevanten Abschnitte der erfassten Fertigungsdaten

In den Abbildungen 5-4 bis 5-6 sind die Verläufe der maschineninternen Signale über die Bearbeitungszeit für die drei Bearbeitungsschritte Pilotieren, Bohren und Reiben dargestellt. Zu den erfassten Signalen zählen die Position der X-, Y- und Z-Achse, die Drehzahl der Spindel sowie das Drehmoment der Spindel und der Z-Achse. Die Signale (Fertigungsdaten) werden während der Zerspanung eines Ventils mit einer Abtastfrequenz von 1.000 Hz mit dem Oszilloskop der NC-Steuerung der Maschine erfasst. Eine detailliertere Beschreibung der Datenerfassung für den Serienbetrieb erfolgt in Kapitel 5.3. In den Abbildungen sind neben den Verläufen der Signale auch markante, charakteristische Merkmale hervorgehoben, die Rückschlüsse auf den Zerspanprozess zulassen und eine Bestimmung der Signalabschnitte ermöglichen,

welche für die Prognosen als relevant erachtet werden. Der Fokus in diesem Kapitel liegt auf der Bestimmung dieser Signalabschnitte.

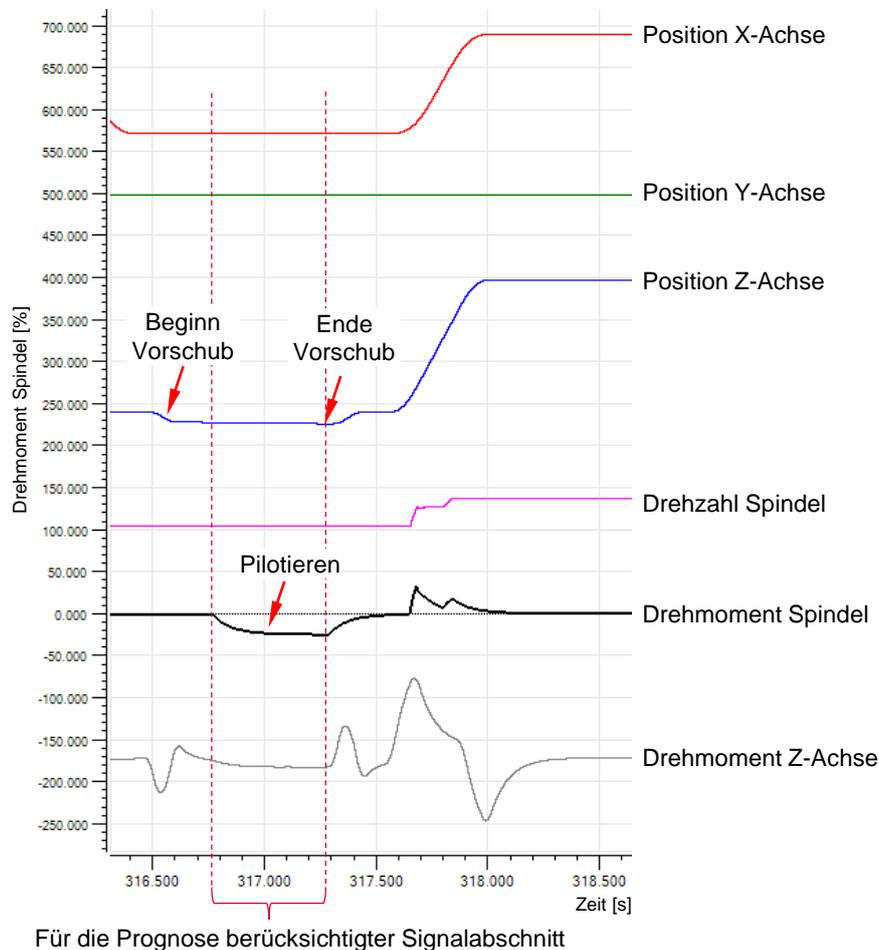


Abbildung 5-4: Verläufe der erfassten maschineninternen Signale für das Pilotieren der Druckwaagenbohrung

Die Verläufe der erfassten maschineninternen Signale, die während des Pilotierens der Druckwaagenbohrung aufgezeichnet werden, sind in Abbildung 5-4 dargestellt. Sobald die X- und Y-Achse ihre Soll-Position erreicht haben, beginnt der Vorschub des Bohrers, was neben der Positionsveränderung der Z-Achse zu einem Ausschlag des Drehmomentes der Z-Achse (negativer Wert) führt. Zu diesem Zeitpunkt ist die Soll-Drehzahl bereits erreicht. Trifft die Bohrspitze auf das Ventilgehäuse, dann steigt das Drehmoment der Spindel solange an, bis ein konstanter Wert erreicht ist. Das Ende des Vorschubs und das damit eingeleitete Zurückziehen des Bohrers aus der Bohrung führt zu einem Ausschlag des Drehmomentes der Z-Achse (positiver Wert), zu einer Veränderung der Position der Z-Achse sowie zu einer Abnahme des Spindeldrehmomentes. Für die spätere Prognose der Qualität werden nur die Signalwerte berücksichtigt, die zwischen dem Kontakt der Bohrspitze mit dem Gehäuse und dem Ende des Vorschubs des Bohrers anfallen. In der Abbildung 5-4 ist dieser Bereich entsprechend rot markiert und hat eine Länge von 0,5 Sekunden. Durch

das Pilotieren werden die ersten 6 mm der vorgegossenen Bohrung aufgebohrt. Der Bohrer für die Pilotierung hat einen Durchmesser von 20 mm, besteht aus dem Hartmetall DK 460UF und verfügt über vier Schneiden, welche ab einem Innendurchmesser von 10 mm der vorgegossenen Bohrung anfangen zu schneiden.

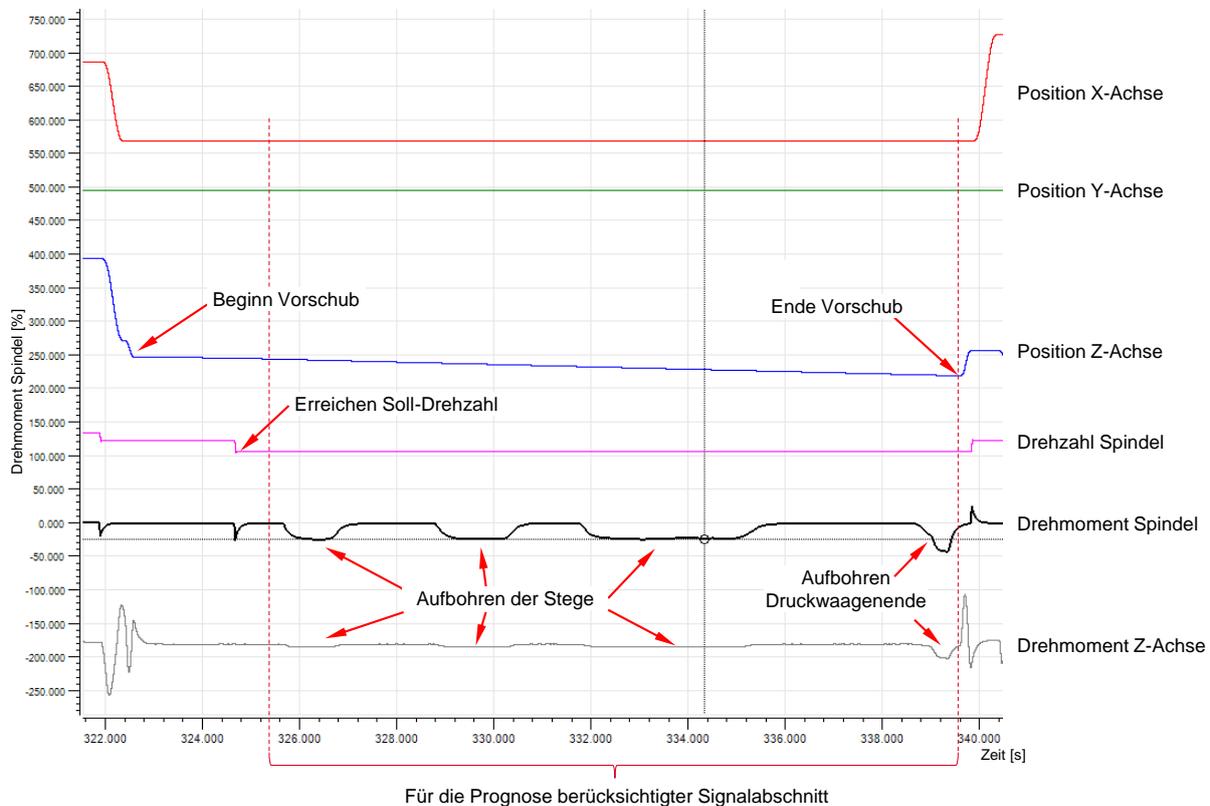


Abbildung 5-5: Verläufe der erfassten maschineninternen Signale für das Aufbohren der Druckwaagenbohrung

In Abbildung 5-5 sind die Verläufe der Signale für das Bohren der Druckwaagenbohrung aufgezeigt. Für das Bohren wird ein Spiralbohrer mit zwei Schneiden und einem Durchmesser von 17,815 mm eingesetzt. Der Vorschub der Z-Achse in Richtung der Bohrung erfolgt, sobald die Soll-Position der X- und Y-Achse erreicht ist. Der Beginn des Vorschubs sowie das Zurückziehen der Z-Achse verursachen entsprechende Spitzen in dem Verlauf des Drehmomentes der Z-Achse. Die Drehzahl wird stufenweise auf die Soll-Drehzahl erhöht, mit der die Bohrung durchgeführt werden soll. Der Anstieg sowie die Reduzierung der Drehzahl führen zu Spitzen in dem Verlauf des Drehmomentes der Spindel und sind zudem aus dem Signalverlauf der Drehzahl ersichtlich. Das Aufbohren der drei Stege ist eindeutig anhand des Anstiegs des Spindeldrehmomentes zu erkennen. Mit dem Auftreffen der Bohrspitze auf einen Steg, steigt das Spindeldrehmoment kontinuierlich an, bis es einen konstanten Wert erreicht hat. Nach dem Aufbohren eines Stegs und dem damit verbundenen Austreten des Bohrers an dem Ende eines Stegs sinkt das Spindeldrehmoment wieder ab. Dieser charakteristische Verlauf tritt genau drei Mal auf, was der Anzahl von Stegen entspricht. Das Aufbohren des Endes der Druckwaage äußert sich in einem Spindel-

drehmoment, welches fast doppelt so hoch ist als das aufgebrachte Drehmoment für das Aufbohren der Stege. Dies kommt daher, da die Bohrung am Druckwaagenende nicht vorgegossen ist und der Bohrer somit ins Volle bohrt. Das Aufbohren der Stege äußert sich nur in einem minimalen Anstieg des Drehmomentes der Z-Achse, da es sich um das Aufbohren einer vorgegossenen Bohrung handelt und die Querschneide des Bohrers sich nicht im Eingriff befindet. Bei dem Aufbohren des Druckwaagenendes ist die Querschneide im Eingriff und das Drehmoment der Z-Achse steigt entsprechend an. Das Drehmoment der Z-Achse ist im Vergleich zu dem Drehmoment der Spindel jedoch deutlich niedriger, was dem in Kapitel 2.1.1 beschriebenen Verhältnis der Verteilung der Kräfte beim Bohren entspricht bzw. widerspiegelt. Eine Abweichung bei den Positionen der X- und Y-Achse ist in der hier dargestellten Auflösung der Signale nicht zu erkennen. Die in Kapitel 5.4 berechneten Merkmale ermöglichen jedoch das Erkennen von Abweichungen bzw. Schwankungen der Position durch die Betrachtung von einer größeren Anzahl von Bohrungen. Der Signalabschnitt des Bohrens der Druckwaagenbohrung, welcher für die Prognose berücksichtigt wird, ist 14,2 Sekunden lang und in der Abbildung 5-5 markiert.

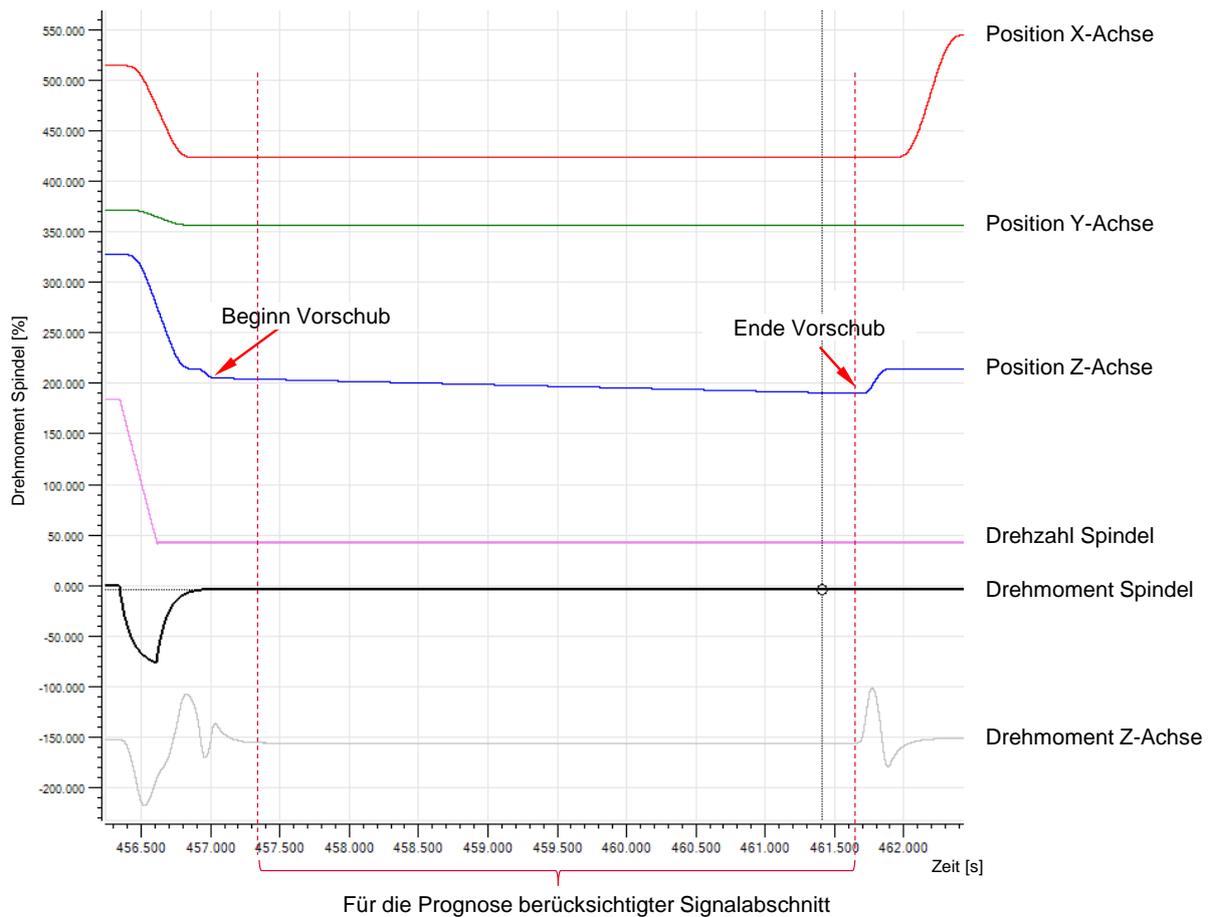


Abbildung 5-6: Verläufe der erfassten maschineninternen Signale für das Reiben der Druckwaagenbohrung

Die Verläufe der erfassten Signale während des Reibens der Druckwaagenbohrung sind in Abbildung 5-6 visualisiert. Zum Einsatz kommt eine Einschneiden-Reibahle mit zwei Führungsleisten aus Cermet. Die Schneide ist durch eine CBN Wendschneidplatte repräsentiert. Mit dieser Reibahle soll der Durchmesser der Druckwaagenbohrung von 17,998 mm gefertigt werden. Wie schon bei den zuvor betrachteten Bohrprozessen beginnt auch der Vorschub der Z-Achse bei dem Reibprozess erst dann, wenn die X- und Y-Achse ihre Sollposition eingenommen haben und die Nennzahl erreicht ist. Das Hochfahren der Spindeldrehzahl äußert sich in einem starken Anstieg des Drehmomentes der Spindel. Nach diesem Spitzenwert fällt das Spindeldrehmoment auf nahezu 0 % zurück. Aufgrund der kleinen Prozesskräfte während des Reibens ist das Reiben der Stege aus den Drehmomentverläufen der Spindel und der Z-Achse in der Abbildung 5-6 nicht ersichtlich. Die Abbildung 5-7 hat eine höhere Auflösung und ermöglicht hierdurch das Erkennen der Drehmomentveränderung der Spindel während des Reibens der einzelnen Stege. Dieser Drehmomentverlauf ähnelt dem des Bohrens. Für die Prognose wird ein Signalabschnitt von 4,3 Sekunden als relevant angesehen.

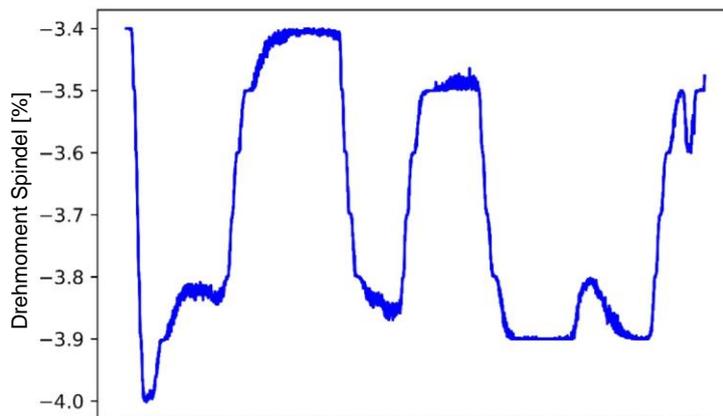


Abbildung 5-7: Drehmoment der Spindel während des Reibens der Druckwaagenbohrung

5.2.4 Einfluss des Werkzeugverschleißes und der Gusscharge auf den Drehmomentverlauf

Der Werkzeugverschleiß und die Gusscharge können in einer Serienfertigung einen Einfluss auf den Prozessverlauf bzw. auf den Wert einer Fertigungsgröße haben. Um ein valides Prognosemodell trainieren zu können, bedarf es der Kenntnis des Einflusses. Nur so kann dieser gegebenenfalls im Prognosemodell berücksichtigt werden. In dieser Arbeit wird der Einfluss, der von dem Werkzeugverschleiß und der Gusscharge ausgeht anhand der Veränderung des Drehmomentes der Spindel bewertet. Als Werkzeug wird der Spiralbohrer gewählt, der die vorgegossene Bohrung aufbohrt und so eventuellen Aufmaßschwankungen oder unterschiedlichen Härten der Gusshaut ausgesetzt ist. Es wird ein Ventil gewählt, das dem zuvor beschriebenen Ventil nahezu identisch ist (Abmaß, Grauguss, Lieferant) und sich nur in der Breite der einzelnen Stege unterscheidet, jedoch zum Augenblick der Analysen in

deutlich höherer Stückzahl gefertigt wird. Um die Veränderung des Drehmomentes zu bewerten, die von dem Werkzeugverschleiß hervorgerufen wird, werden Drehmomentaufzeichnungen bei dem Einsatz eines neuen, scharfen Werkzeuges (Standzeitanfang) und bei dem Einsatz eines stumpfen Werkzeuges (Standzeitende) durchgeführt. Es werden jeweils die ersten und die letzten 10 Bohrungen, die mit einem Werkzeug durchgeführt werden, betrachtet. Mit beiden Werkzeugstandzeiten erfolgt die Zerspanung von Ventilgehäusen, die aus drei verschiedenen Gusschargen stammen. Die Chargen stammten zeitlich aus dem September (rot), Januar (blau) und dem Mai (grün) und sind entsprechend farblich in der Abbildung 5-8 markiert. Hierdurch ist es möglich, den Einfluss einer Gusscharge auf das Drehmoment der Spindel zu bewerten. Die Analyse des Einflusses erfolgt grafisch und visuell auf Basis der Verläufe der Drehmomentkurven. Die Darstellung erfolgt in einer 3D und in einer 2D Grafik. Die drei Achsen der 3D Grafik repräsentieren die Dauer des Bohrvorgangs, die Anzahl von Ventilen pro Gusscharge sowie das Drehmoment der Spindel während des Bohrens. Die 2D Grafik bildet den Verlauf des Drehmomentes über die Dauer des Bohrvorganges ab und die einzelnen Gusschargen sind nur noch über die ihnen zugeordnete Farbe zu identifizieren.

Der Einfluss der Standzeit des Bohrers ist aus den Drehmomentverläufen eindeutig zu erkennen. So liegt das Drehmoment bei ca. 20% der Spindelleistung, wenn ein Bohrer noch über seine volle Standzeit verfügt. Zudem sind die einzelnen Stege und Kanäle der Druckwaagenbohrung anhand der Kontur der Drehmomentkurve eindeutig zu erkennen (Abbildung 5-8 unten links). Mit dem Erreichen des Standzeitendes des Bohrers steigt das Drehmoment auf bis zu ca. 35% an. Anhand der Kontur der Drehmomentkurve ist nun das Aufbohren der einzelnen Stege nur noch zu erahnen (Abbildung 5-8 unten rechts). Zum einen wird der Anstieg des Drehmomentes durch den Verschleiß der Schneidecken des Bohrers hervorgerufen. Der Verschleiß führt zudem zu einer Verkleinerung des Durchmessers, wodurch die Führungsphasen des Bohrers verstärkt an der Bohrungswand reiben. Dieser Effekt trägt somit ebenso zum Anstieg des Drehmomentes bei und scheint auch die klassische Kontur der Drehmomentkurve zu verzerren.

Der Einfluss auf das Drehmoment, der von einer Gusscharge ausgeht, ist im Vergleich dazu deutlich niedriger. Die Drehmomentkurven von allen drei Gusschargen liegen nahezu übereinander und weichen nur minimal voneinander ab. Die Drehmomentkurve der Charge aus dem September (rot) liegt teilweise minimal über den Drehmomentkurven der beiden anderen Chargen. Dies bedeutet, dass für die September Charge ein etwas niedrigeres Drehmoment für das Bohren aufgebracht werden musste (sowohl für den scharfen als auch für den stumpfen Bohrer), was ein Zeichen für einen Guss mit geringerer Härte oder ein geringeres Aufmaß sein kann. Die Drehmomentkurven der Gusschargen aus dem Januar (blau) und dem Mai (grün) sind für einen scharfen Bohrer absolut identisch und liegen somit übereinander. Bei einem stumpfen Bohrer liegen sie ebenfalls übereinander, jedoch zeigt die Charge aus dem Januar eine minimal höhere Streuung.

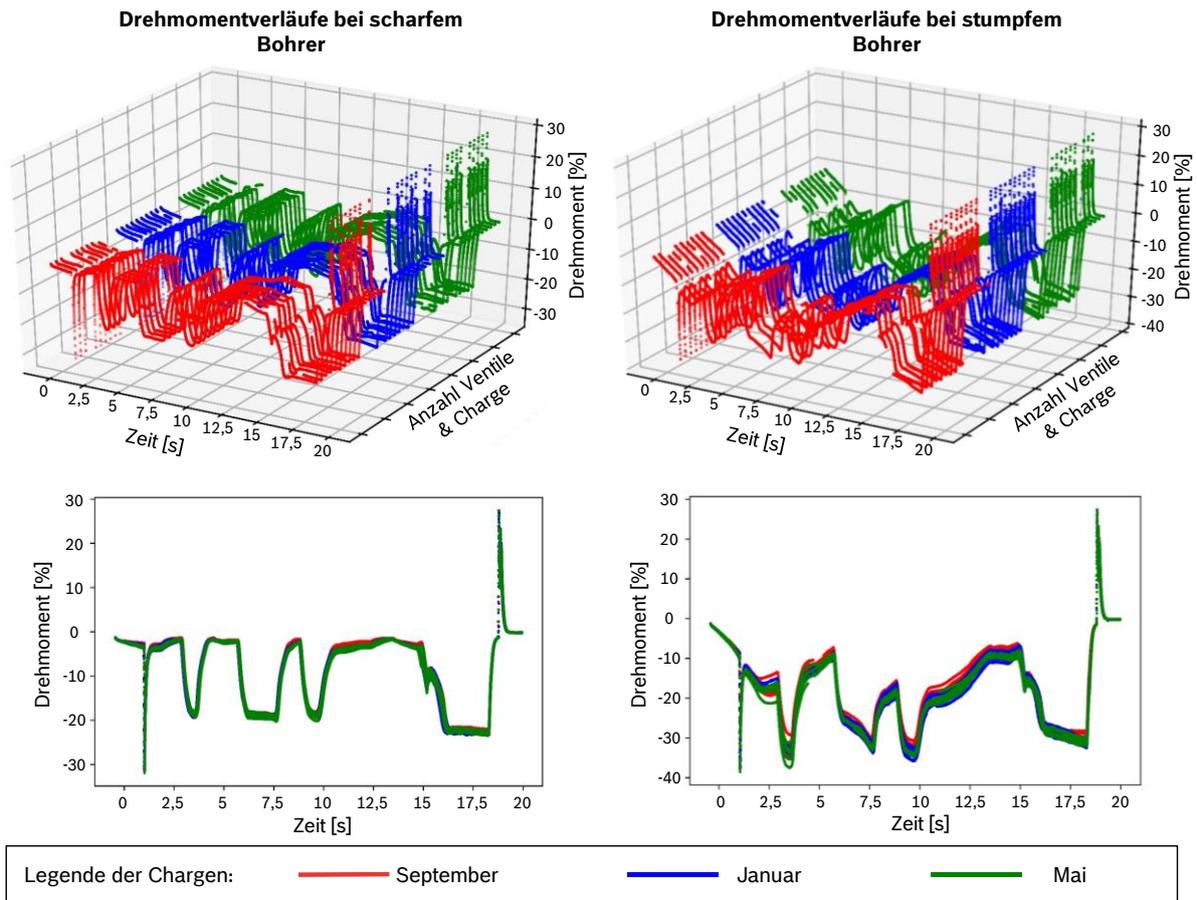


Abbildung 5-8: Drehmomentverläufe für verschiedene Gusschargen und Werkzeugzustände

Aus der Analyse der Drehmomentkurven lässt sich für das Prognosemodell die Schlussfolgerung ziehen, dass der Werkzeugverschleiß aufgrund der hohen Schwankung über die Werkzeugstandzeit definitiv als separate Inputgröße in das Modell mit aufgenommen werden muss. Die einzelne Gusscharge hat hingegen nur einen minimalen Einfluss auf das Drehmoment der Spindel, der im Vergleich zu dem Effekt, der von dem Werkzeugverschleiß ausgeht, vernachlässigt werden kann. Aus diesem Grund wird die Gusscharge nicht gesondert in dem Prognosemodell berücksichtigt.

5.3 Datengewinnung, Datenspeicherung & Kontextualisierung

Dieses Kapitel beschreibt die Erschließung der für das maschinelle Lernen essentiell wichtigen Daten beginnend mit der Beschreibung der eingesetzten Werkzeugmaschine. Das Vorgehen sowie die verwendeten Technologien bzw. Messmittel werden erläutert, mit denen die Fertigungs- als auch die Qualitätsdaten erfasst werden.

5.3.1 Erfassung der Fertigungsdaten

Die Untersuchungen zur Qualitätsprognose und die damit verbundene Datenerfassung werden an einem 4-Achs Bearbeitungszentrum der Firma Grob durchgeführt.

Das Bearbeitungszentrum ist mit zwei HSK 63 Spindeln mit jeweils einer Antriebsleistung von 40 kW, einem Spindeldrehmoment von 64 Nm und einer maximalen Drehzahl von 12.000 min^{-1} ausgestattet. Die Antriebe der X- und Y-Achse (Z-Achse) verfügen über ein maximales Drehmoment von 160 Nm (138 Nm), einer Vorschubkraft von 5 kN (6 kN) und einer maximalen Beschleunigung von 5 m/s^2 (15 m/s^2). Als Steuerung kommt die MTX ADVANCED der Firma Bosch Rexroth zum Einsatz mit einem Interpolationstakt von 1.000 Hz. In der Abbildung 5-9 ist das Bearbeitungszentrum sowie seine Achsen dargestellt. Das hier eingeführte Koordinatenkreuz gilt als Referenz für alle in dieser Arbeit angegebenen Koordinaten.

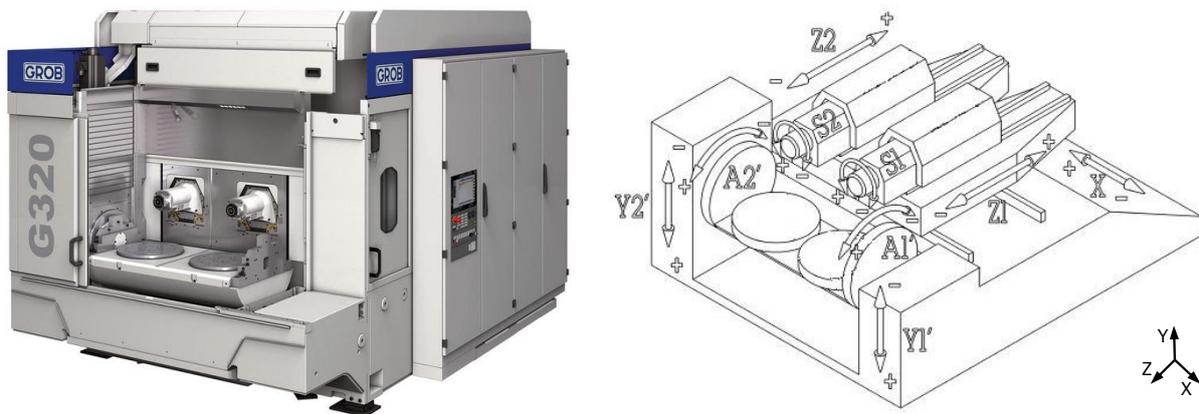


Abbildung 5-9: Bearbeitungszentrum G320 der Firma Grob (Bildquelle: [GROB20])

In dieser Arbeit wird zwischen einer „hochfrequenten“ und einer „niederfrequenten“ Datenerfassung unterschieden. Unter die hochfrequente Datenerfassung fallen alle Fertigungsdaten, die dem Zerspanungsprozess direkt entstammen. Hierunter zählen das Drehmoment und die Drehzahl der Spindeln sowie das Drehmoment und die Position der X-, Y- und Z-Achse. Diese Daten werden mit einer Frequenz von 1.000 Hz direkt von dem jeweiligen Antrieb erfasst und stellen die von den Sensoren gemessenen Ist-Werte einer Fertigungsgröße dar. Die Antriebe erstellen Datenpakete, welche über die Sercos-Ethernet Schnittstelle der NC-Steuerung abrufbar sind. Die Funktionsweise der Antriebsregelung und die verwendeten maschineninternen Sensoren wurden in Kapitel 2.3.2 erläutert. Unter die niederfrequenten Daten fallen all diejenigen, welche keine Erfassung in Echtzeit voraussetzen, da sie über eine vergleichsweise lange Zeitdauer existent sind. Dies sind die Bezeichnung des Ventils (Ventil-Typ), die Identifikationsnummer des aktuell gefertigten Ventils (Ventil-ID) sowie das sich gerade im Eingriff befindende Werkzeug (Werkzeug-ID) mitsamt seiner zugehörigen Werkzeugeinsatzzeit. Diese Daten werden von der NC-Steuerung über den OPC-UA Server bereitgestellt. Die Datenerfassung und Speicherung erfolgt mit einem IPC der Firma Bosch Rexroth. Der IPC ist mit einem Intel Core i7-6600U Prozessor sowie mit 16GB RAM und einer 300GB SSD-Festplatte ausgestattet. Als Verbindungsmodul zwischen Antriebsregelung, NC-Steuerung und IPC wird ein Gateway (IOT Gateway von Bosch Rexroth) eingesetzt, welches als reine Softwarelösung

direkt auf dem IPC ausgeführt wird und den OPC-UA Client darstellt. Die Verbindung zwischen den Geräten erfolgt mittels Ethernet und der Protokolle TCP/IP und OPC-UA. Die vom Gateway empfangenen Daten werden von diesem in einer auf dem IPC befindlichen Datenbank (MongoDB) gespeichert. In Abbildung 5-10 ist die Architektur der Fertigungsdatenerfassung visualisiert.

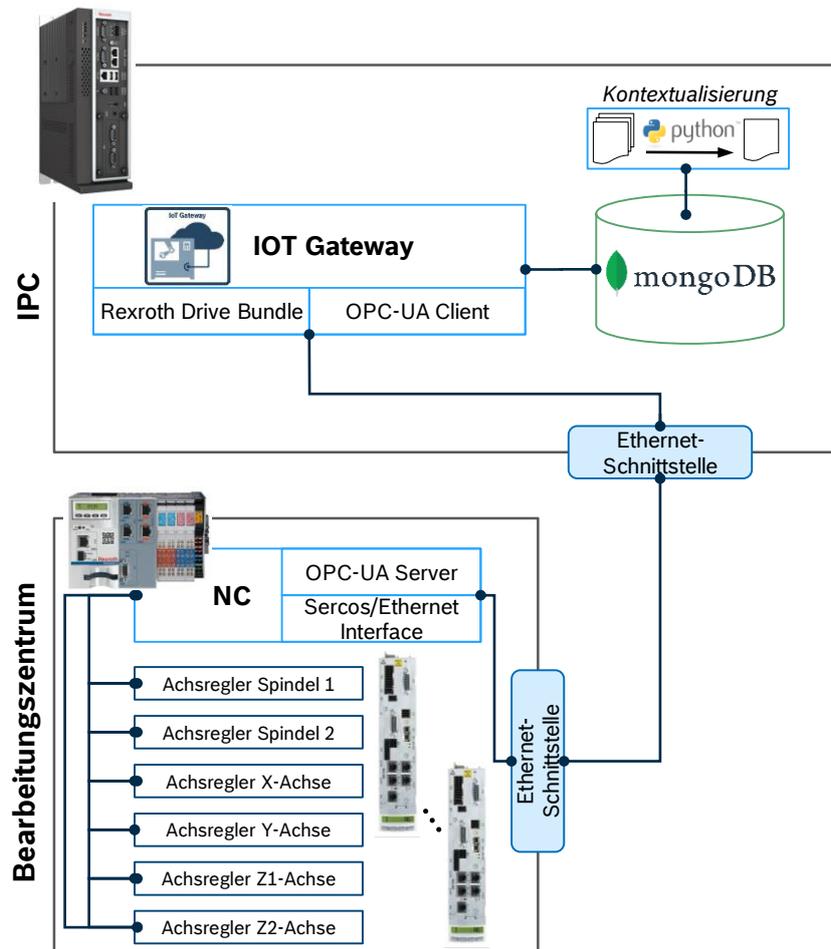


Abbildung 5-10: Architektur der Fertigungsdatenerfassung (Bildquellen: [MONG20; PYTH20; REXR20])

Die Daten werden vorerst ohne Bezug zu einem Ventil mit der von dem IOT Gateway vorgegebenen Struktur in der mongoDB gespeichert. Für die Qualitätsprognose müssen die Daten jedoch den Ventilen zugeordnet werden. Diese Zuordnung wird in dieser Arbeit als Kontextualisierung bezeichnet, da eine kontextbezogene Speicherung der verteilt aufgezeichneten Daten vollzogen wird. Die Speicherung der Fertigungsdaten einer Datenquelle geschieht kontinuierlich und jeweils separat in einer sogenannten Collection in der mongoDB ohne Bezug auf ein Werkzeug oder Ventil. Für jede Spindel und jede Achse existiert schließlich eine Collection mit den jeweiligen Fertigungsdaten in dem Datenformat JSON. Jeder Eintrag (Frame) in eine Collection setzt sich aus den Fertigungsdaten und einem Zeitstempel, welcher den Zeitpunkt der Erfassung dokumentiert, zusammen. Neben den Collections, die die Ferti-

gungsdaten enthalten, besteht zudem eine einzige Collection, die die Werkzeug-ID, die Ventil-ID und den Ventil-Typ sowie den Zeitstempel des Werkzeugeinsatzes beinhaltet. Diese Collections sind in der Abbildung 5-11 zu sehen.

DateTime	Time	Tool_ID	Valve_Type_Number	Workpiece_1	Workpiece_2
2020-06-04 08:28:33.043Z	10:28:33	17537	17011848	7920034912040620	7920034922040620
2020-06-04 08:28:42.071Z	10:28:42	17931	17011848	7920034912040620	7920034922040620

⋮ Aufzeichnungen der einzelnen Datenquellen

DateTime	TrendingSp1
2020-06-04 08:29:26.754Z	{ "frames": { "timeStamp": { "year": 2020, "month": 6, "day": 4, "hour": 10, "minute": 29, "second": 26, "ms": 91, "us": 0 }, "data": [-1696.0716, -19.1, 12.025] }
2020-06-04 08:29:27.107Z	{ "frames": { "timeStamp": { "year": 2020, "month": 6, "day": 4, "hour": 10, "minute": 29, "second": 26, "ms": 423, "us": 0 }, "data": [-1682.7392, -6.9, 5.029] }
2020-06-04 08:29:27.226Z	{ "frames": { "timeStamp": { "year": 2020, "month": 6, "day": 4, "hour": 10, "minute": 29, "second": 26, "ms": 877, "us": 0 }, "data": [-1695.4422, -7.8, 6.819] }



Kontextualisierung

Key	Value	Type
(1) ObjectId("5edf843aba51bd07c8726d56")	{ 15 fields }	Object
_id	ObjectId("5edf843aba51bd07c8726d56")	ObjectId
index	(2020-06-04 10:31:48.690000, 2020-06-04 10:32:03.734000)	String
Spindel_1	{ 5 fields }	Object
Zeitstempel	[7431 elements]	Array
Drehzahl	[7431 elements]	Array
Drehmoment	[7431 elements]	Array
Drehmomentbildender Strom	[7431 elements]	Array
Index	[7431 elements]	Array
Spindel_2	{ 5 fields }	Object
Achse_A2	{ 6 fields }	Object
Achse_X	{ 5 fields }	Object
Achse_Z2	{ 5 fields }	Object
Achse_Z1	{ 5 fields }	Object
Achse_Y2	{ 5 fields }	Object
Werkzeug_ID	17624	Int32
Ventil_Type_ID	17011848	Int32
Ventil_1	7920034912040620	String
Ventil_2	7920034922040620	String
Ventil_3	7920034932040620	String
Ventil_4	7920034942040620	String
(2) ObjectId("5edf843aba51bd07c8726d57")	{ 15 fields }	Object

Abbildung 5-11: Kontextualisierung der verteilt aufgezeichneten Fertigungsdaten

Eine Kontextualisierung hat nun zu erfolgen, indem die während der Fertigung eines Ventils entstandenen Fertigungsdaten diesem zugeordnet werden. Dies erfolgt durch den Abgleich der aufgezeichneten Zeitstempel. Ein in Python geschriebener Code führt die Kontextualisierung aus, indem er kaskadenartig die Zeitstempel der erfassten Daten durchläuft und die zu einem Ventil zugehörigen Daten in eine neue Collection überführt. Diese Collection umfasst für jedes Ventil die Fertigungsdaten von den Datenquellen in Anhängigkeit von dem Werkzeug-Typ. Auf der rechten Seite der Abbildung 5-11 ist diese finale Collection abgebildet. Die nun so vorliegenden Daten können im nächsten Schritt für die Merkmalsberechnung genutzt werden.

5.3.2 Erfassung der Qualitätsdaten

Im Anschluss an die Fertigung der Ventilgehäuse erfolgt die Messung der Qualitätsmerkmale der betrachteten Bohrung. Zum Einsatz kommt hierfür ein Koordinatenmessgerät mit der Bezeichnung Prismo Accept Vast des Herstellers Zeiss sowie ein Formmessgerät des Herstellers Mahr mit der Bezeichnung MahrForm MFU 800. Beide Messgeräte werden für die Überwachung der Qualität der Serienfertigung eingesetzt. Die Kalibrierung der Messgeräte wird in regelmäßigen Abständen durchgeführt. Zudem wird jährlich die Leistungsfähigkeit des Messgerätes durch den Hersteller überprüft und in einem Kalibrierschein dokumentiert. Dies stellt sicher, dass die im Werksprüfschein angegebenen Spezifikationen erfüllt werden. Zusätzlich wird das Verfahren eins und drei speziell für die Messung der Merkmale der betrachteten Bohrung durchgeführt, um die Fähigkeit des Messprozesses sicherzustellen. Aufgrund dieser Maßnahmen kann davon ausgegangen werden, dass die Messunsicherheiten der Messergebnisse sehr gering sind. Zur Veranschaulichung der Messgenauigkeit wurde eine Bohrung (Druckwaagenbohrung eines Ventils) 25-fach vermessen. Dies lieferte für den Durchmesser ein MAE von $0,0276 \mu\text{m}$, für die Rundheit ein MAE von $0,0043 \mu\text{m}$ und für die Geradheit ein MAE von $0,0073 \mu\text{m}$. Als „tatsächlicher Wert“ wurde der Mittelwert der 25 Messungen angenommen. Die Berechnung erfolgte mit Formel 2.28.

Alle Fertigungschargen werden mit denselben Messgeräten gemessen, welche von derselben Person bedient werden. Der Durchmesser und die Konzentrität werden mit der Koordinatenmessmaschine gemessen. Der Durchmesser wird von jedem der drei Stege sowie an dem Bohrungsende gemessen. Das Gauß-Kreis Verfahren wird eingesetzt, um aus den Messpunkten den jeweiligen Durchmesser zu bestimmen. Für das spätere Training der Methoden des maschinellen Lernens wird der Mittelwert von den Durchmessern der drei Stege bestimmt und nur dieser auch prognostiziert. Die Konzentrität wird über die drei Stege bis zum Bohrungsende bestimmt. Mit dem Formmessgerät erfolgt die Messung der Rundheit und der Geradheit. Die Rundheitsmessung erfolgt für jeden der drei Stege und das Messergebnis wird mittels eines Gaußfilters und einer Grenzwellenzahl von 50 W/U aus den Messpunkten bestimmt. Das Training und die Rundheitsprognose erfolgen für den Mittelwert der drei Rundheitsmesswerte. Die Geradheit wird über die drei Stege bestimmt, indem die aufgenommenen Messpunkte ebenfalls mit einem Gaußfilter geglättet werden. Die Wahl der Filter und die Messstrategie beeinflussen die Messergebnisse maßgeblich. Aus diesem Grund wird großer Wert auf identische Einstellungen der Messmittel und der Auswerteverfahren für das Messen der verschiedenen Fertigungschargen innerhalb des Betrachtungszeitraumes gelegt. Eine Vergleichbarkeit der Ergebnisse wird somit garantiert.

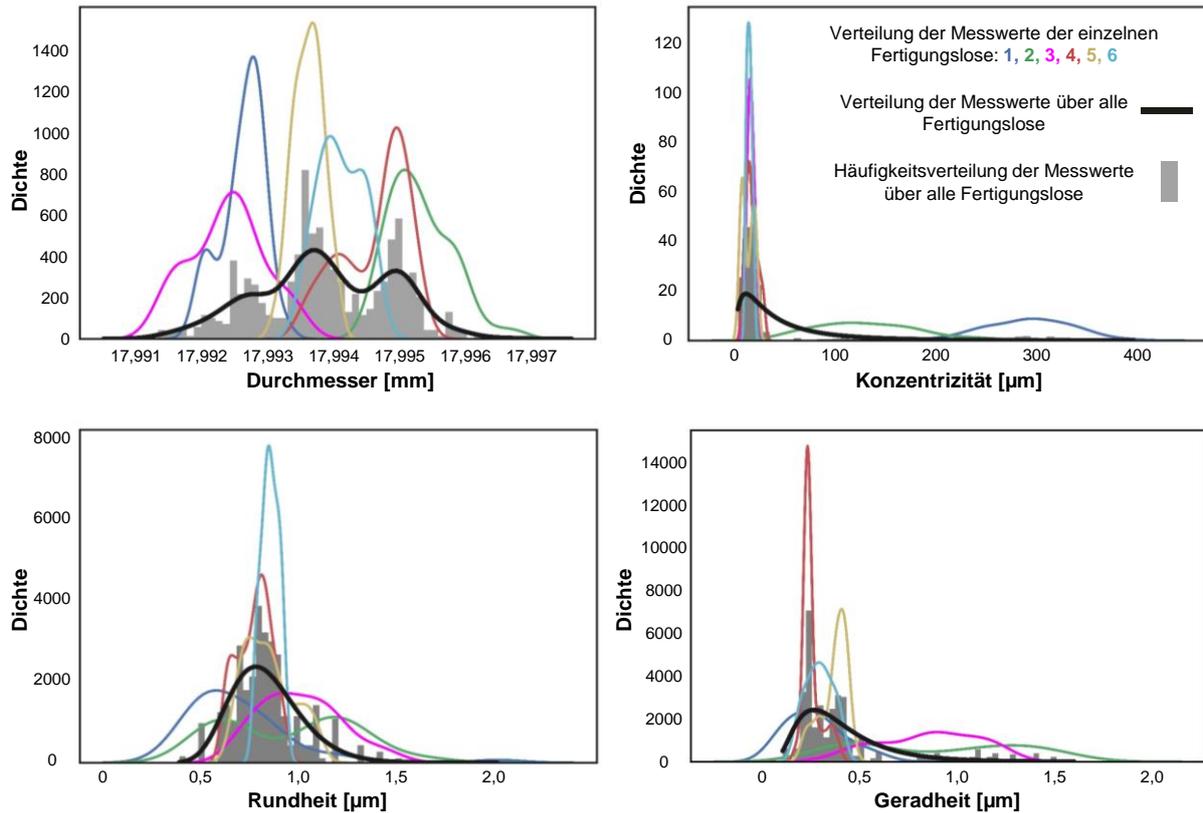


Abbildung 5-12: Verteilung der Messwerte der einzelnen Qualitätsmerkmale und Fertigungslose

Die Erfassung der Fertigungsdaten erfolgte an verschiedenen Tagen und mit unterschiedlichen Einsatzzeiten der Werkzeuge. Hierdurch werden die in der Produktion auftretenden Zustände berücksichtigt und mittels der Stichproben repräsentiert. Nach ISO 22514-2 ist ein Herstellungsprozess in der Realität über die Zeit gesehen nicht zwangsläufig stabil und weist auch keine stationäre Normalverteilung der Merkmalswerte auf [DIN19, S. 6]. Mittels des Verfahrens der Kerndichteschätzung kann eine Wahrscheinlichkeitsdichtefunktion zu vorliegenden Messdaten mit unbekannter Verteilung jedoch geschätzt werden. Die Dichtefunktion ergibt sich aus der skalierten Summe der sich überlagernden Dichten (sogenannte Kerne), welche in Abhängigkeit von der Lage der Messwerte positioniert sind. In der Abbildung 5-12 ist die Verteilung der Messwerte der einzelnen Qualitätsmerkmale dargestellt. Die Darstellung der Messwerte aller Fertigungslose erfolgt in der Form eines gemeinsamen Histogramms, welches bereits einen Rückschluss auf die vorliegende Verteilung erlaubt. Zudem wird die Wahrscheinlichkeitsdichtefunktion von jedem einzelnen Fertigungslos sowie über alle Fertigungslose angegeben. Für die Bestimmung der Dichtefunktionen der Durchmessermessungen wurde bei der Kerndichteschätzung ein Gaußkern gewählt. Es lässt sich erkennen, dass die Verteilung des Durchmessers einer Normalverteilung ähnelt. Insbesondere die Messergebnisse der einzelnen Fertigungslose können als normalverteilt angesehen werden. Ein „Tal“ innerhalb der Dichtefunktion eines einzelnen Fertigungsloses ist auf die Existenz der zwei Spindeln zurückzuführen. Würde eine Dichtefunktion für jede Spindel eines Fertigungsloses bestimmt, so ergäben sich zwei Normalverteilungen. Die Täler in der Dichtefunktion aller

Durchmesser-messungen sind auf eine zahlenmäßige Unterrepräsentation der jeweiligen Durchmesserbereiche zurückzuführen, welche durch die Aufzeichnung von weiteren Fertigungslosen reduziert werden könnten. Bei der Konzentrität, der Rundheit und der Geradheit handelt es sich um einseitig (durch die Null) begrenzte Qualitätsmerkmale. Für die Bestimmung der individuellen Dichtefunktionen der Fertigungslose wurde eine Kerndichteschätzung mit einem Gaußkern verwendet. Da die Verteilungen der Messwerte zum größten Teil einer Normalverteilung ähneln, wurden diese hierdurch am besten abgebildet. Eine logarithmische Normalverteilung (auch Lognormalverteilung genannt) wurde als Dichtefunktion gewählt, um die Verteilung der Messungen aller Fertigungslose zu beschreiben. Der Graph der Lognormalverteilung ist charakterisiert durch eine asymmetrische, durch die Null begrenzte und nach rechts flach auslaufende Kurve. Dies repräsentiert die Verteilung der einseitig begrenzten Merkmale am genauesten. Die Visualisierung der Dichtefunktionen ermöglicht eine Bewertung der Bandbreite und der Abdeckung des Wertebereiches eines Qualitätsmerkmals, welches bei der späteren Bildung von Trainings- und Testdatensatzes hilfreich sein wird.

5.4 Merkmalsextraktion und Merkmalsselektion

In diesem Kapitel erfolgt die Extraktion von Merkmalen aus dem Zeit- und Frequenzbereich sowie die Anwendung einer PCA als auch des Pakets `tsfresh`. Mit Hilfe einer LDA werden Anomalien aufgedeckt und die finalen Datensets bestimmt. Die Pearson Korrelation und die Transinformation werden für die Selektion der wichtigsten Merkmale eingesetzt.

5.4.1 Merkmalsextraktion

Während des Pilotierens, Bohrens und Reibens der Bohrung werden von der Spindel und den Achsen der Maschine Fertigungsdaten erfasst (siehe Kapitel 5.3.1), welche in der Form von Zeitreihen zu jeder Bohrung vorliegen. Um diese Daten für die Qualitätsprognose mit den in Kapitel 5.5 eingesetzten Methoden des maschinellen Lernens zu nutzen, ist es notwendig eine Merkmalsextraktion durchzuführen. Die Merkmale geben die in der jeweiligen Zeitreihe enthaltenen Informationen mit wenigen Datenpunkten wieder und reduzieren hierdurch zudem die Datenmenge sowie die Berechnungszeit der Qualitätsprognose.

In Abbildung 5-13 sind die Mittelwerte und die Standardabweichungen der Zeitreihen der erfassten Daten für jeden Bearbeitungsschritt und für jede Achse bzw. Spindel abgebildet. Durch diese Darstellung wird die Variabilität der einzelnen Fertigungsgrößen für die erfasste Anzahl von Ventilen deutlich. Die Merkmale werden hingegen jeweils von der zu einem Ventil gehörenden individuellen Zeitreihe bestimmt.

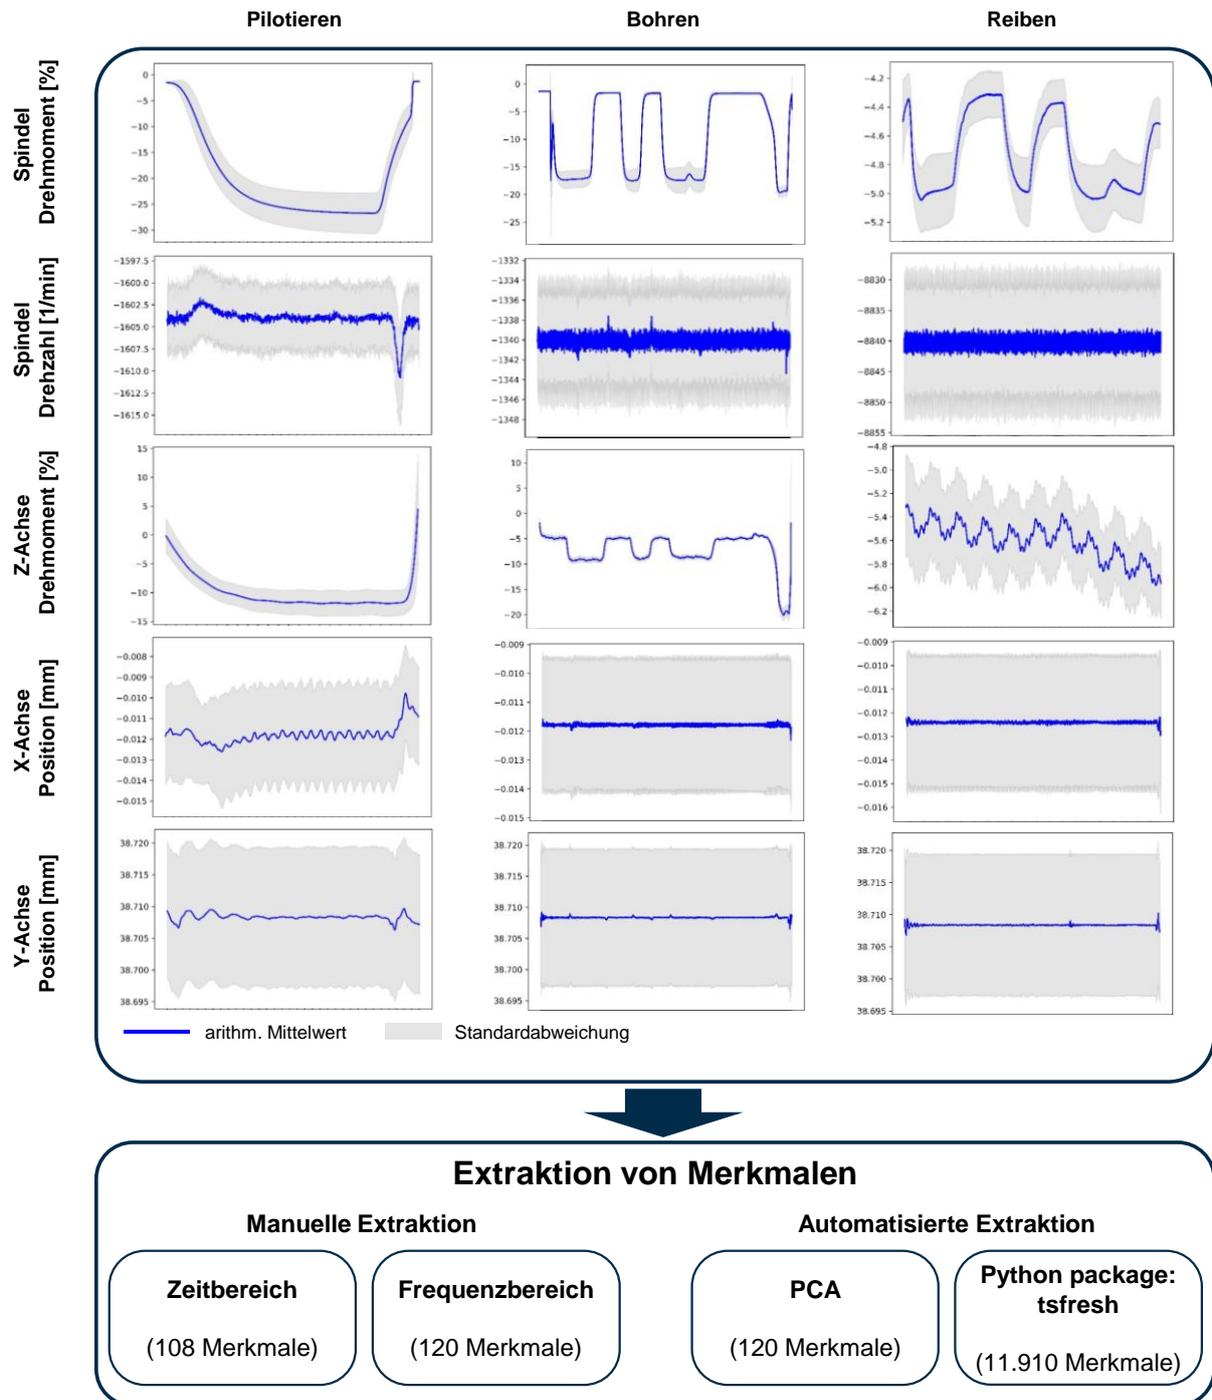


Abbildung 5-13: Erfasste Fertigungsdaten für die Merkmalsextraktion

Die Standardabweichung der einzelnen Kurvenverläufe ist unterschiedlich stark ausgeprägt. So weist das Drehmoment der Spindel hohe Schwankungen auf, die Drehzahl der Spindel hat hingegen nur eine Schwankungsbreite von weniger als 1 %. Das Drehmoment der Z-Achse hat im Vergleich zu dem Drehmoment der Spindel eine niedrigere Schwankung um den Mittelwert. Während des Reibprozesses steigt das Drehmoment der Z-Achse an, umso tiefer die Reibahle in die Bohrung eintritt. Hieran lässt sich der Reibwiderstand zwischen den Führungsleisten und der Bohrungswand erkennen. Die Position der X-Achse schwankt innerhalb eines Bereiches von ca. 5 μm , die Schwankungsbreite der Y-Achse ist mit ca. 20 μm im Vergleich dazu deut-

lich größer. Es muss hier jedoch erwähnt werden, dass während der spanenden Bearbeitung eines Ventils die Positionswerte nicht mit der dargestellten Breite schwanken. Die Schwankungen der Positionswerte kommen vielmehr von der automatischen Temperaturkompensation der Maschine, die nach drei bis vier Fertigungszyklen durchgeführt wird. So sind die Positionswerte während der Zerspanung eines Ventils sehr stabil, weisen jedoch in Bezug auf den Nullpunkt der Maschine unterschiedliche Abstände auf.

Der Einfluss dieser Fertigungsgrößen auf das Qualitätsergebnis bzw. wie die Qualität auf der Basis dieser Größen prognostiziert werden kann, ist das Ziel dieser Arbeit. Um dies zu erreichen, müssen signifikante Merkmale aus den Zeitreihen gewonnen werden. In Kapitel 2.3.3 wurden verschiedene Methoden zur Merkmalsextraktion aufgeführt, welche nun hier zum Einsatz kommen.

Von den erfassten Fertigungsdaten werden Merkmale im Zeitbereich extrahiert. Hierfür haben sich die Merkmale arithmetischer Mittelwert, quadratischer Mittelwert, Standardabweichung, Schiefe, Wölbung, Minimum-zu-Maximum Amplitude sowie der Crest Faktor bewährt (s. Kapitel 2.3.3). Diese sieben Merkmale werden für jedes der 15 aufgezeichneten Fertigungsgrößen (drei Werkzeuge * fünf Signale) bestimmt. Zusätzlich werden die Werkzeugeinsatzzeiten der drei Werkzeuge als zusätzliches Merkmal mit aufgenommen. Somit ergeben sich insgesamt 108 Merkmale (15 Fertigungsgrößen * sieben Merkmale + drei Werkzeugeinsatzzeiten) pro Ventil für den Zeitbereich.

Zusätzlich zu dem Zeitbereich werden die Fertigungsdaten in den Frequenzbereich überführt, aus welchem ebenfalls Merkmale extrahiert werden. Für jede Fertigungsgröße wird eine FFT über die komplette Dauer der Zerspanung durchgeführt. Von dem erhaltenen Amplitudenspektrum wird die durchschnittliche spektrale Leistung, die spektrale Energie sowie die maximale Amplitude als Merkmale bestimmt. Zusätzlich zur Merkmalsextraktion wird die Welch Methode angewendet. Hierbei wird das Signal im Zeitbereich in Segmente eingeteilt und von jedem Segment eine FFT durchgeführt, bei der ein sogenanntes Periodogramm erzeugt wird. Die Merkmale werden schließlich von dem finalen, gemittelten Periodogramm berechnet (siehe Kapitel 2.3.3). Für die Segmentierung kommt die Fensterfunktion Von-Hann-Fenster mit einer Breite von 1.000 Signalwerten und einem Überlappungsgrad von 50 % zum Einsatz. Von dem finalen Periodogramm werden die Merkmale: durchschnittliche spektrale Leistung, die Varianz, die Schiefe, die Wölbung sowie die maximale Amplitude, bestimmt. Demnach ergibt sich eine Anzahl von 120 Merkmalen für den Frequenzbereich (15 Fertigungsgrößen * acht Merkmale).

Neben der manuellen Extraktion von Merkmalen kommen auch Methoden zum Einsatz, die eine automatisierte Extraktion von Merkmalen ermöglichen. Eine Principal Component Analysis (PCA) wird eingesetzt, um die Informationen, die in den Zeitreihen enthalten sind, in möglichst wenigen Merkmalen zusammenzufassen. Die PCA wird hierfür auf jede einzelne der 15 Fertigungsgrößen angewandt. Berücksichtigt werden alle PCs, deren kumulierte Eigenwerte den gewählten Grenzwert von 95%

mindestens erreichen (siehe Kapitel 2.3.3). Um diesen Grenzwert zu überschreiten sind maximal acht PCs bei den hier vorliegenden Fertigungsdaten notwendig. Die Anzahl von extrahierten Merkmalen (PCs) ist somit 120 (15 Fertigungsgrößen * acht PCs).

Eine weitere automatisierte Extraktion von Merkmalen erfolgt durch die Nutzung des in der Software Python hierfür bereitgestellten Pakets `tsfresh` (siehe Kapitel 2.3.3). Dieses Paket ist explizit für die Extraktion von Merkmalen aus Zeitreihen konzipiert. Es umfasst insgesamt 63 Extraktionsmethoden zur Berechnung von 794 Merkmalen und beinhaltet zugleich eine Merkmalsselektion mittels p-Wertes und Hypothesentests. Zu den berechneten Merkmalen zählen z.B. Merkmale aus dem Zeit- und Frequenzbereich sowie eigen konstruierte Merkmale. Für eine vollständige Auflistung der berechneten Merkmale sei auf [CHR18] und [CHR20] verwiesen. Für jede der 15 Fertigungsgrößen werden demnach 794 Merkmale bestimmt, sodass insgesamt 11.910 Merkmale vorliegen. Aus dieser Gesamtmenge an Merkmalen werden dann die signifikantesten Merkmale individuell für jedes Qualitätsmerkmal selektiert. Auf die Merkmalsselektion wird im Kapitel 5.4.3 näher eingegangen.

5.4.2 Lineare Diskriminanzanalyse zur Detektion von Anomalien

Vor der Durchführung der Merkmalsselektion und der anschließenden Bestimmung der geeignetsten Methoden des maschinellen Lernens für die Qualitätsprognosen ist die Anwendung einer LDA zur Detektion von Anomalien in dem Fertigungsprozess ratsam. Mit der LDA können sogenannte Diskriminanzwerte berechnet werden. Diese Diskriminanzwerte werden schließlich dafür genutzt, Intervalle zu definieren, für die der Fertigungsprozess einen definierten Zustand einhält und für die die Methoden des maschinellen Lernens trainiert werden sowie die Prognosen an Gültigkeit besitzen. Das Funktionsprinzip sowie die mathematischen Gleichungen der LDA wurden in Kapitel 2.4.4 erläutert.

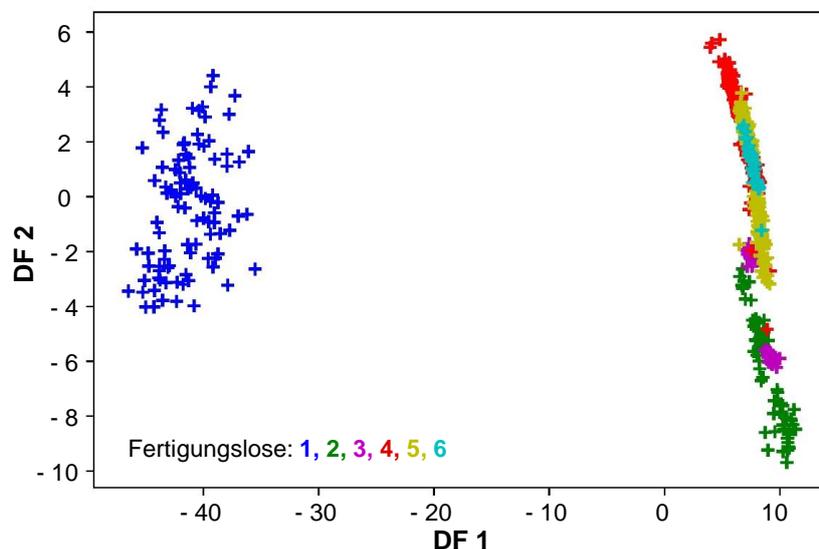


Abbildung 5-14: Erste und zweite Diskriminanzfunktion der LDA für die verschiedenen Fertigungslose

Zur Anwendung der LDA ist die besagte Klassifikation der erfassten Fertigungsdaten (Merkmale) notwendig. Unabhängig von den Qualitätsmerkmalen und den Messwerten erfolgt hier eine Klassifikation der berechneten Merkmale anhand der Fertigungslose. Dies stellt eine sinnvolle Klassifizierung dar, da jedes Fertigungslos einen Zustandsbereich der Zerspanung mit der dazugehörigen Bohrungsqualität widerspiegelt. Abweichungen von dem Normalzustand sollen dann schließlich aufgezeigt werden. Insgesamt ergeben sich somit für die sechs verschiedenen Fertigungslose auch sechs verschiedene Klassen, die in Abbildung 5-14 farblich voneinander unterschieden werden können. Für die Durchführung der LDA wurden die berechneten Merkmale aus dem Zeitbereich von den Drehmomentaufnahmen der Spindeln und Z-Achsen für das Bohren und Reiben verwendet. In Abbildung 5-14 ist das Ergebnis der LDA durch die Angabe der berechneten Diskriminanzwerte für die erste und die zweite Diskriminanzfunktion (DF) dargestellt. Auf den ersten Blick ist erkennbar, dass das erste Fertigungslos sich von den restlichen Fertigungslosen deutlich in dem Wert sowie der Streuung für DF 1 unterscheidet, hingegen für DF 2 im Wertebereich aller Fertigungslose liegt. Dieser signifikante Unterschied lässt auf unterschiedliche Fertigungszustände /-bedingungen zwischen dem ersten und den folgenden Fertigungslosen schließen. Dies ist auch zutreffend, da für das erste Fertigungslos ein Bohrer mit spiralisierter Spannutt verwendet wurde und für alle folgenden Fertigungslose ein Bohrer mit gerade genutteter Spannutt zum Einsatz kam. Ein Wechsel des Bohrer-types war notwendig, da mit dem fortschreitenden Verschleiß des spiralisierten Bohrers ein Verlaufen des Bohrers in der Bohrung eingetreten ist, was zu Konzentrizitätswerten außerhalb der Toleranz führte (siehe Abbildung 5-12). Bei allen folgenden Analysen und Betrachtungen in dieser Arbeit wird das erste Fertigungslos nicht weiterhin berücksichtigt, da es nicht den Normalzustand repräsentiert. Der Fertigungsprozess befindet sich demnach im Normalzustand bzw. die trainierten Prognosemodelle besitzen an Gültigkeit, wenn sich die Werte für DF 1 zwischen drei und elf und für DF 2 zwischen minus zehn und plus sechs bewegen. Liegen die berechneten Diskriminanzwerte außerhalb dieser Intervalle, so liegt eine Anomalie bei dem Fertigungsprozess vor und die Gültigkeit des bis dahin eingesetzten Prognosemodells kann nicht garantiert werden. Eine Abweichung kann z.B. durch den über die Zeit stattfindenden Verschleiß der Achsen und der Lager der Werkzeugmaschine hervorgerufen werden oder durch den Einsatz eines fehlerhaften Werkzeuges. Im ersteren Fall (Verschleiß der Werkzeugmaschine) wäre ein erneutes Training des Prognosemodells mit den veränderten Bedingungen möglich, um die Gültigkeit der Prognosen wiederherzustellen. Im zweiten Fall (fehlerhaftes Werkzeug) wird ein zufälliger Fehler erkannt, für das das Modell nicht trainiert werden kann und nur durch den Einsatz der LDA eine mögliche Ungültigkeit der Prognosen aufgezeigt wird.

In der Abbildung 5-14 ist von dem zweiten bis zu dem sechsten Fertigungslos ein Trend zu erkennen, welcher für DF 1, aus dem positiven Wertebereich kommend, gegen null strebt sowie für DF 2 vom negativen zum positiven Wertebereich verläuft. Da die Fertigungslose in chronologischer Reihenfolge über eine Dauer von ca. 1,5 Jahren erfasst wurden, kann dies eventuell bereits ein erster Hinweis auf eine Ver-

änderung der Werkzeugmaschine hindeuten. Dies würde eine Anpassung des Prognosemodells in regelmäßigen Abständen notwendig machen.

5.4.3 Merkmalsselektion

Auf die Merkmalsextraktion folgt die Merkmalsselektion, um für die Qualitätsprognose nur die Merkmale zu berücksichtigen, die für die Prognose der Zielgröße als signifikant eingestuft werden können. Die Selektion erfolgt für jedes Qualitätskriterium individuell und die angewendete Selektionsmethode ist von der Strategie der Merkmalsextraktion abhängig. Die Auswahl der Merkmale der manuellen Extraktionsstrategie erfolgt über die Pearson Korrelation und die Transinformation mit der Zielgröße. Für die automatisierte Merkmalsextraktion mit dem Python Package `tsfresh` wird die Selektion via Hypothesentests und p-Wert durchgeführt.

In den Abbildung 5-15 bis Abbildung 5-18 sind für jedes der vier Qualitätsmerkmale die 20 Merkmale aus dem Zeit- und Frequenzbereich mit der stärksten Korrelation bzw. der größten Transinformation dargestellt. Die Angabe der Werte der Transinformation erfolgt normiert, sodass der Transinformationswert eines Qualitätsmerkmals mit sich selbst den Wert eins ergibt und folglich die Merkmale einen Wert kleiner eins annehmen. Die Pearson Korrelation nimmt Werte zwischen minus und plus eins an, wobei hier eine Auflistung der Merkmale sich nach den Absolutwerten richtet. Die Beschriftung der Merkmale folgt der Systematik: `Achse_Fertigungsgröße_Werkzeug_Merkmal`. Im Gegensatz zur Pearson Korrelation werden von der Transinformation auch nichtlineare Zusammenhänge berücksichtigt (siehe Kapitel 2.3.4). Aus diesem Grund können je nach Selektionsverfahren die Merkmale mit unterschiedlicher Wichtigkeit für die Prognose einer Zielgröße bewertet werden. Es werden für jedes Qualitätsmerkmal zwei Merkmalssets erstellt, mit denen in Kapitel 5.5.1 die beste Methode des maschinellen Lernens bestimmt wird. Die Merkmale des ersten Merkmalssets² werden mittels der Pearson Korrelation ausgewählt und es umfasst alle Merkmale, deren kumulierte Korrelationswerte einen Anteil von 70 % an der Gesamtkorrelation einnehmen. Das zweite Merkmalsset besteht aus den Merkmalen, deren kumulierte Summe der Transinformationswerte einen Wert von 70 % erreicht. Für jedes Merkmalsset wird zudem der jeweilige Korrelations- und Transinformationswert in Abhängigkeit von dem Qualitätsmerkmal bei der gesetzten 70 % Grenze bestimmt und bei den Analysen in Kapitel 5.5 berücksichtigt. Mit jedem Merkmalsset erfolgt schließlich das Trainieren der Methoden des maschinellen Lernens und anhand der Prognosegüte kann die am geeignetste Extraktions- und Selektionsmethode bestimmt werden (siehe Kapitel 5.5). Im Folgenden wird versucht, den Zusammenhang zwischen den einzelnen Merkmalen und den Qualitäts-

² Ein Merkmalsset ist eine Teilmenge einer Merkmalsgruppe bzw. eine Teilmenge einer Kombination von mehreren Merkmalsgruppen (z. B. Merkmale aus dem Zeitbereich mit einer Pearson Korrelation von mindestens 0,5). In einer Merkmalsgruppe werden die mit einer Extraktionsmethode gewonnenen Merkmale zusammengefasst (Zeitbereich, Frequenzbereich, PCs, `tsfresh`).

merkmalen zu erklären bzw. die Rangfolge der Auflistung zu deuten, indem die in Kapitel 5.2.1 aufgeführten Wirkzusammenhänge berücksichtigt werden. Dies ist jedoch kein zwingender Bestandteil einer Merkmalsselektion, da die Selektion mittels Selektionsverfahren erfolgen kann. Dennoch bietet der Einsatz von fertigungstechnischem Wissen die Möglichkeit, die Selektion hinsichtlich ihrer Plausibilität zu bewerten. An dieser Stelle muss jedoch angemerkt werden, dass Zusammenhänge und Wechselwirkungen zwischen den Fertigungsgrößen und der Qualität nicht immer vollständig von einem Menschen erkannt werden können, sodass dies auch einer der bedeutenden Gründe für den Einsatz der Methoden des maschinellen Lernens ist.

In Abbildung 5-15 sind die 20 Merkmale mit der höchsten Korrelation und Transinformation bezüglich des Durchmessers dargestellt. Lediglich sieben der insgesamt 128 Merkmale weisen eine Korrelation von mehr als 0,5 auf. Somit besteht eine nur sehr schwache lineare Korrelation zwischen den Merkmalen und dem Durchmesser. Die Y-Achsposition des Pilotierers (W1) weist eine ausgesprochen hohe Korrelation mit dem Durchmesser auf. Der Grund hierfür kann in der Wechselwirkung zwischen dem Pilotieren und dem darauffolgenden Bohren liegen. Ist die Lage der Pilotbohrung nicht zentrisch zu dem Bohrer, so kann dies zu einer Abdrängung des Bohrers und zu einem nicht zentrischen Bohrungsverlauf führen, sodass eine Durchmessererweiterung hervorgerufen wird. Der aufgezeigte starke lineare Zusammenhang kann rein zufällig für den vorliegenden Datensatz gelten und z. B. durch die Temperaturkompensation der Maschine verursacht worden sein. Demnach stellt sich die Frage, ob eine so hohe Bewertung eines Merkmals des Pilotiervorgangs für eine generalisierte Durchmesserprognose Gültigkeit besitzt. Eine detaillierte Betrachtung erfolgt in Kapitel 5.5.2. Der Durchmesser wird aus fertigungstechnischer Sicht hauptsächlich durch die Reibahle und den Spiralbohrer bestimmt. Somit sind die höheren Korrelationen von dem Drehmoment der Z-Achse des Spiralbohrers (W2) sowie von dem Spindeldrehmoment der Reibahle (W3) eher nachvollziehbar. Ungeachtet der vermuteten Wichtigkeit einzelner Merkmale für die Durchmesserprognose werden alle Merkmale, die innerhalb der gesetzten 70 % Grenze liegen, zur Prognoseerstellung berücksichtigt. Dies sind insgesamt 107 Merkmale und das letzte berücksichtigte Merkmal besitzt noch eine Korrelation von 0,26. Wird eine Selektion mittels der Transinformation durchgeführt und neben der linearen auch die nichtlinearen Abhängigkeiten berücksichtigt, so gewinnen die Merkmale von den Drehmomenten der Spindel und Z-Achse deutlich an Bedeutung. Die Reibahle (W3) und der Bohrer (W2) sind nun die dominierenden Werkzeuge, was auch mit den fertigungstechnischen Zusammenhängen bei der Erzeugung des Durchmessers übereinstimmt. Die Werkzeugeinsatzzeit der Reibahle ist nun das wichtigste Merkmal, gefolgt von dem Spindeldrehmoment der Reibahle. Weshalb die Werkzeugeinsatzzeit des Pilotierers etwas höher gelistet wird als die Einsatzzeit des Bohrers, kann nicht erklärt werden. Die Position der Achsen sollte aus theoretischer Sicht keinen Einfluss auf den Durchmesser haben. Dennoch erscheint sie mit einem hohen Transinformationswert (bzw. Korrelationswert). Dies könnte ein Zeichen für eine auftretende Unwucht während der Bearbeitung sein, aufgrund von ungleichmäßigen Schnittkräften bzw. aus-

gehend vom Spannfutter und Werkzeug. Diese Unwucht könnte dazu führen, dass die X-Achse und Y-Achse aus ihrer Sollposition gebracht werden und die NC-Steuerung entsprechend nachregeln muss. Die Unwucht bzw. das Nachregeln hätten dann einen Einfluss auf den Durchmesser. Ein zweiter Grund für das Erscheinen der Positionswerte könnte die Temperaturkompensation der Maschine sein. Demnach würde eine gewisse Anzahl von Bohrungen bei einer bestimmten Position gefertigt. Diese Position wird dann in Bezug auf den gefertigten Durchmesser gesetzt, obwohl der Durchmesser nicht durch die Position beeinflusst wird. Dies hätte eine Wirkung auf die Merkmale: arithmetischer Mittelwert (m), quadrierter Mittelwert (mq) sowie Crest Faktor (CF). Der Einfluss der Achspositionen auf die Qualitätsmerkmale wird in Kapitel 5.5.2 genauer betrachtet. Zur Erreichung eines Anteils von 70 % der gesamten Transinformation sind 116 Merkmale notwendig. Das letzte berücksichtigte Merkmal hat noch einen Transinformationswert von 0,11. Demzufolge erfolgt die Durchmesserprognose zum einen mit 107 Merkmalen von der Korrelationsanalyse und zum anderen mit 116 Merkmalen von der Transinformationsanalyse.

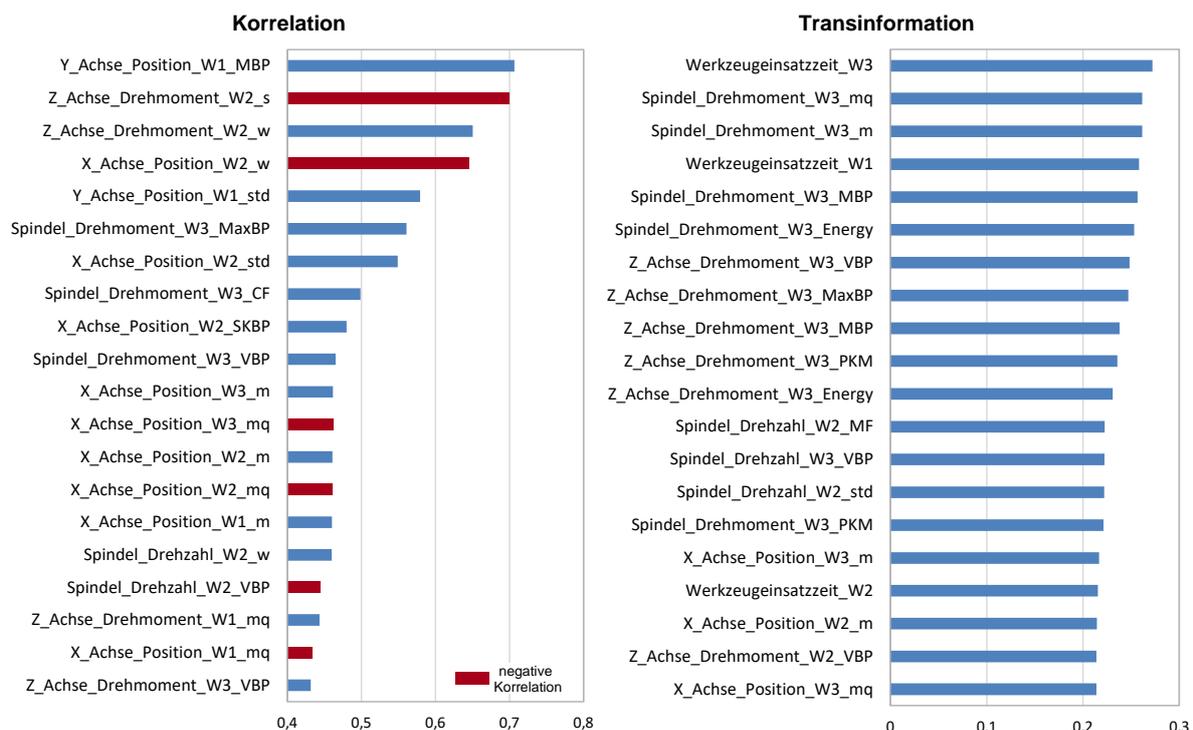


Abbildung 5-15: Die 20 höchstbewerteten Merkmale (Frequenz- und Zeitbereich) bezüglich der Selektionsverfahren Pearson Korrelation und Transinformation für den Durchmesser

Die Zusammenhänge zwischen den Merkmalen und der Konzentrität sind in der Abbildung 5-16 dargestellt. Die linearen Korrelationswerte sind deutlich höher als die für den Durchmesser. Die stärkste Korrelation geht von der Position der X-Achse der Reibahle aus, gefolgt von der Werkzeugeinsatzzeit des Bohrers und dem Spindel-drehmoment der Reibahle. Jeweils mit Werten um die 0,8. Die Position sowie das Spindeldrehmoment des Pilotierers haben ebenfalls eine starke lineare Korrelation

mit der Konzentrität. Bei der Transinformation hingegen verliert der Pilotierer an Bedeutung. Das Spindeldrehmoment des Bohrers weist auch noch eine hohe lineare Korrelation auf. Die Transinformation wird hauptsächlich dominiert von Merkmalen der Reibahle, wobei die Reibahle eigentlich keinen Einfluss auf die Konzentrität einer Bohrung hat. Bei der hier betrachteten Bohrung wird nach dem Bohren nicht die ganze Bohrung gerieben, sondern nur ca. die ersten zwei Drittel der Bohrung (siehe Abbildung 5-1). Die Konzentrität wird jedoch über die komplette Länge der Bohrung bestimmt, sodass der Reibprozess doch einen Einfluss haben kann. Zudem handelt es sich, aufgrund der einzelnen Stege, um ein Bohren und Reiben mit unterbrochenem Schnitt. Des Weiteren hat die Position der X-Achse einen hohen Transinformationswert für alle drei Werkzeuge. Um 70 % der Transinformation (Korrelation) in der Prognose zu berücksichtigen, sind die ersten 119 (115) der insgesamt 228 gelisteten Merkmale zu wählen. Das letzte berücksichtigte Merkmal hat den Wert 0,07 (0,42).

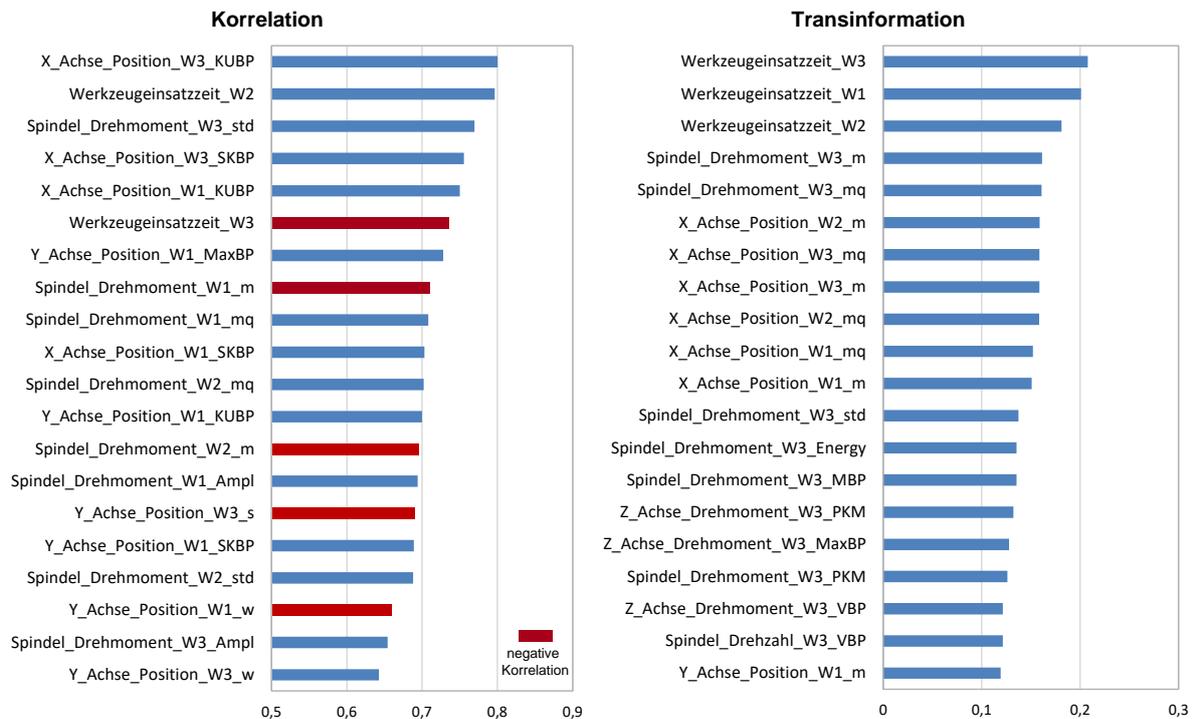


Abbildung 5-16: Die 20 höchstbewerteten Merkmale (Frequenz- und Zeitbereich) bezüglich der Selektionsverfahren Pearson Korrelation und Transinformation für die Konzentrität

Von allen Qualitätsmerkmalen werden für die Geradheit die höchsten Korrelations- und Transinformationswerte erreicht (siehe Abbildung 5-17). Bei der absteigenden Auflistung der Merkmale bezüglich ihres Korrelationswertes rücken die Drehmomente der Spindel und Z-Achse sowie die Drehzahl der Spindel weiter nach oben und die Achspositionen sowie die Werkzeugeinsatzzeiten nach unten. Ein ähnliches Bild zeigt sich für die Transinformationswerte. Hier gewinnt zwar die Werkzeugeinsatzzeit erneut an Bedeutung, jedoch ist nicht ein einziges Merkmal über die Achspositionen

unter den 20 höchstgelisteten Merkmalen. Stattdessen nehmen die Merkmale der Spindeldrehzahl einen höheren Stellenwert ein. Rückschlüsse auf die Geradheit sowie Rundheit sollten vielmehr über die wirkenden Kräfte (bzw. Positionsschwankungen) in der X- und Y-Achse möglich sein. In Bezug auf die Rundheit nehmen die Achspositionen wieder höhere Transinformativswerte an (siehe Abbildung 5-18). Für die Transinformation (Korrelation) wird der bestehende Grenzwert von 70% erreicht, wenn insgesamt 110 (112) Merkmale berücksichtigt werden. Die letzten berücksichtigten Merkmale weisen noch einen Transinformativswert von 0,11 sowie eine Korrelation von 0,63 auf.

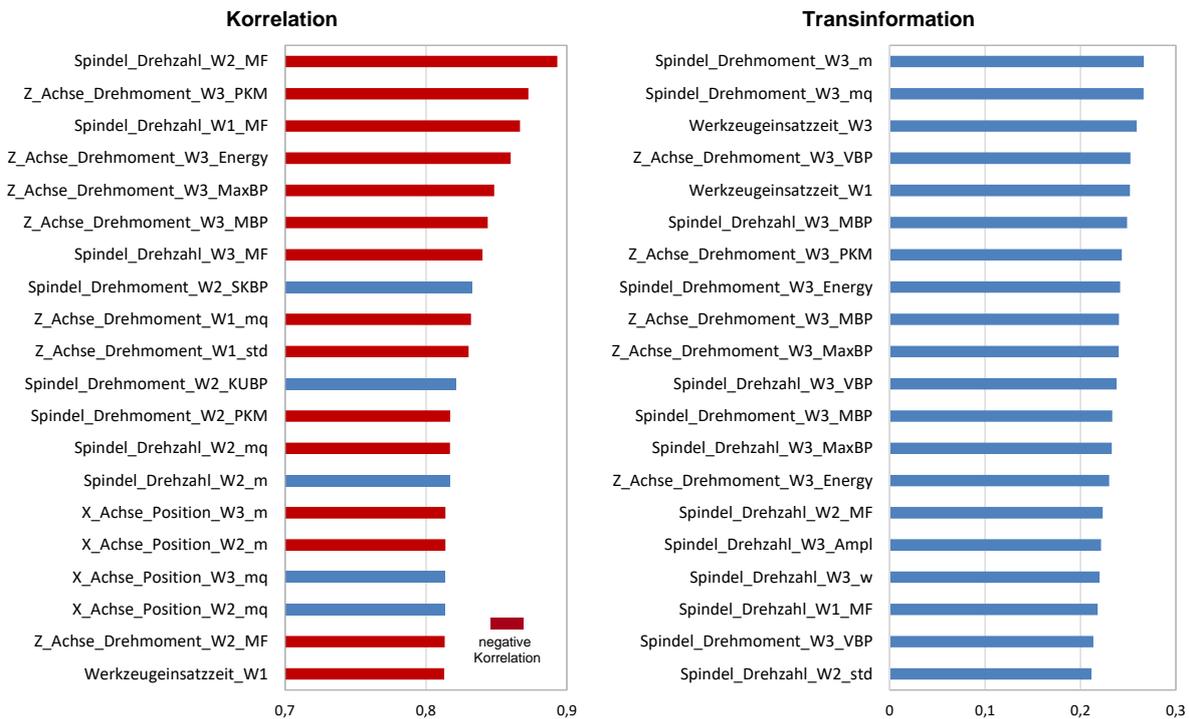


Abbildung 5-17: Die 20 höchstbewerteten Merkmale (Frequenz- und Zeitbereich) bezüglich der Selektionsverfahren Pearson Korrelation und Transinformation für die Geradheit

Die höchste lineare Korrelationen mit der Rundheit der Bohrung geht von den Merkmalen der Spindeldrehzahl des Bohrers aus, gefolgt von den Merkmalen des Drehmoments der Z-Achse mit der Reibahle (siehe Abbildung 5-18). Ein klarer Trend hin zu einer Achse oder einem Werkzeug ist aus der Auflistung der verbleibenden Merkmale nicht zu entnehmen. Insgesamt sind 110 Merkmale notwendig, um einen Anteil von 70% der Gesamtkorrelation abzudecken. Das letzte berücksichtigte Merkmal hat noch einen Korrelationswert von 0,31. Die höchsten Transinformativswerte werden von der Werkzeugeinsatzzeit der Reibahle und des Pilotierers erreicht. Einen hohen Anteil hat zudem die X-Achs-Position der Reibahle und des Bohrers. Dies ist schlüssig, da insbesondere Positionsabweichungen bzw. Achsversatz zwischen Vorbohrer und Reibahle zu Rundheitsfehler führen können. Das Drehmoment der Spindel und Z-Achse während des Reibens erreicht ebenso hohe Transinformativswerte

te. Insgesamt sind 109 Merkmale notwendig, um 70% der Transinformation abzubilden. Der Wert des letzten Merkmals beträgt 0,08.

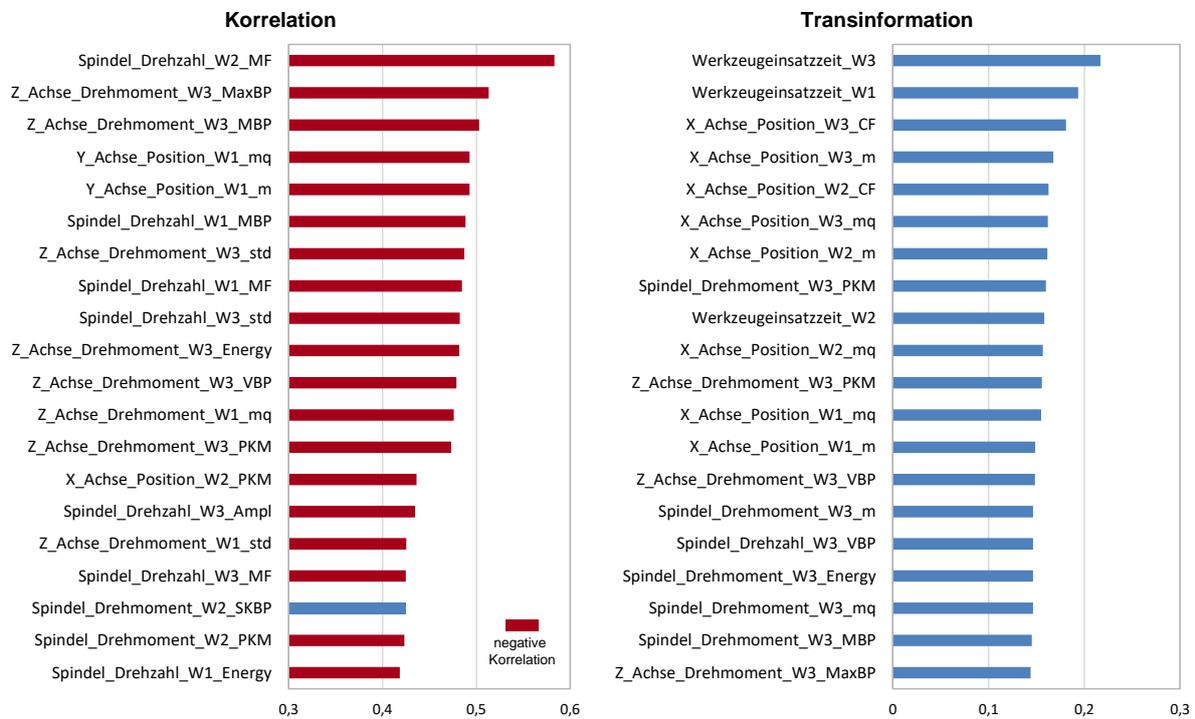


Abbildung 5-18: Die 20 höchstbewerteten Merkmale (Frequenz- und Zeitbereich) bezüglich der Selektionsverfahren Pearson Korrelation und Transinformation für die Rundheit

Zur Auswahl der wichtigsten Merkmale (PCs), die mittels des Extraktionsverfahrens PCA bestimmt werden, bedarf es keines gesonderten Selektionsverfahrens. Durch die Wahl des Grenzwertes, der von der Summe der Eigenwerte der einzelnen Eigenvektoren erreicht werden soll, wird die Anzahl der PCs bestimmt. In dem hier vorliegenden Anwendungsfall wird der Grenzwert von 95 % nach maximal acht PCs erreicht. Somit ergeben sich für die 15 Fertigungsgrößen insgesamt 120 Merkmale.

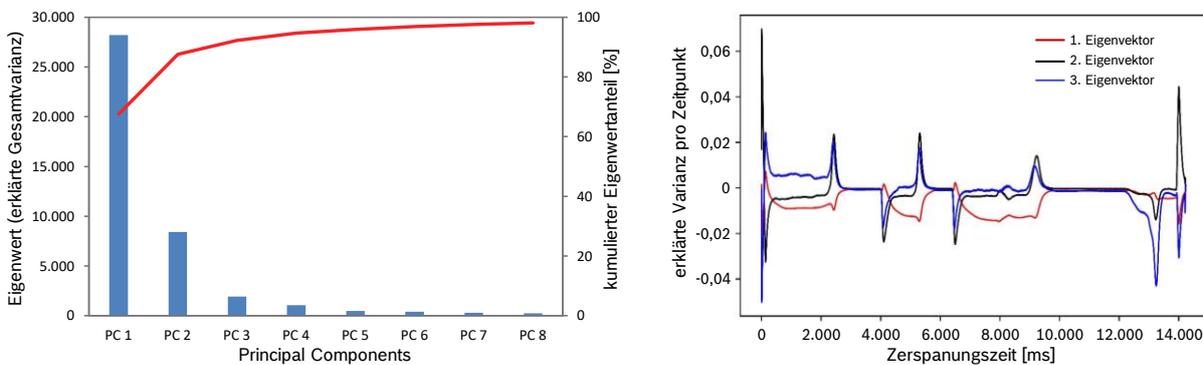


Abbildung 5-19: Eigenwerte und Eigenvektoren für das Spindeldrehmoment des Bohrvorganges

In Abbildung 5-19 sind für die Spindeldrehmomente des Bohrens die acht PCs mit den zugehörigen kumulierten Anteilen ihrer Eigenwerte (linke Grafik) sowie die ersten drei Eigenvektoren (rechte Grafik) dargestellt. Es ist zu erkennen, dass die Eigenvektoren die Varianz der Ausgangsdaten (siehe Abbildung 5-13) abbilden und dass das Aufbohren der einzelnen Stege erkennbar ist (insbesondere für den ersten Eigenvektor).

Die Selektion der wichtigsten Merkmale, die von dem Paket `tsfresh` berechnet wurden, wird vollautomatisch von `tsfresh` durchgeführt. Die Merkmalsselektion erfolgt über die Bestimmung des p-Wertes von jedem einzelnen Merkmal und die anschließende Überprüfung der Signifikanz für die Qualitätsprognose mittels Hypothesentests. Damit die Falscherkennungsrate bei der verschiedenen Anzahl von Hypothesentests nicht zu hoch wird, wird das Signifikanzniveau mittels der Benjamini-Yekutieli-Prozedur ermittelt. Für tiefere Erläuterungen sei auf [CHR17] verwiesen. Für jedes Werkzeug wurden 794 Merkmale pro Achse extrahiert, sodass die Fertigungsdaten aller Achsen und Werkzeugen mittels 11.910 Merkmalen abgebildet werden. Durch die Merkmalsselektion reduziert sich die Anzahl der Merkmale für die Prognose des Durchmessers auf 3.546 Merkmale und für die Konzentrität auf 6.095 Merkmale. Für die Geradheit sind noch 4.551 Merkmale signifikant und die Prognose der Rundheit soll mittels 2.656 Merkmalen erfolgen. Die Anzahl der als signifikant eingestuft Merkmale beträgt für jedes Qualitätsmerkmal mehrere tausend Stück und ist hiermit ausgesprochen hoch. Eine weitere Merkmalsreduktion soll hier nicht vollzogen werden, da diese in dem Paket `tsfresh` nicht standardmäßig implementiert ist.

Die gewählte Strategie der Merkmalsextraktion beeinflusst maßgeblich die benötigte Zeit für die Berechnung der Merkmale. Für die als relevant eingestuft Merkmale aus dem Zeit- und Frequenzbereich kann eine Berechnungszeit von ca. zwei Sekunden pro Ventil angesetzt werden. Die Berechnung der Principal Components dauert pro Ventil ca. acht Sekunden. Zur Berechnung der Merkmale mit `tsfresh` ist im Durchschnitt mit einer Berechnungszeit von 30 Sekunden pro Merkmal zu rechnen. Die Berechnung der als signifikant eingestuft 3.546 Merkmale für den Durchmesser dauert somit 29,5 Stunden. Aufgrund der langen Berechnungsdauer scheidet das hier zum Einsatz kommende Paket zur automatisierten Merkmalsextraktion und -selektion als potentielle Möglichkeit für die Merkmalsberechnung aus. Dennoch sollen im folgenden Kapitel 5.5 die berechneten Merkmale für die Bestimmung der besten Methode des maschinellen Lernens mit einfließen.

5.5 Einsatz der Methoden des maschinellen Lernens

Nachdem die Merkmale aus den Rohdaten gewonnen und die signifikantesten Merkmale im Rahmen der Merkmalsselektion für jedes Qualitätsmerkmal individuell ausgewählt wurden, hat nun eine ebenso individuelle Bestimmung der am besten geeigneten Methode des maschinellen Lernens inkl. ihrer Parametrierung und der Gestalt der Inputdaten für die Prognose eines Qualitätsmerkmals zu erfolgen. Die

Abbildung 5-20 gibt eine Übersicht über die Vorgehensweise und den Inhalt von diesem Kapitel zur Zielerreichung.

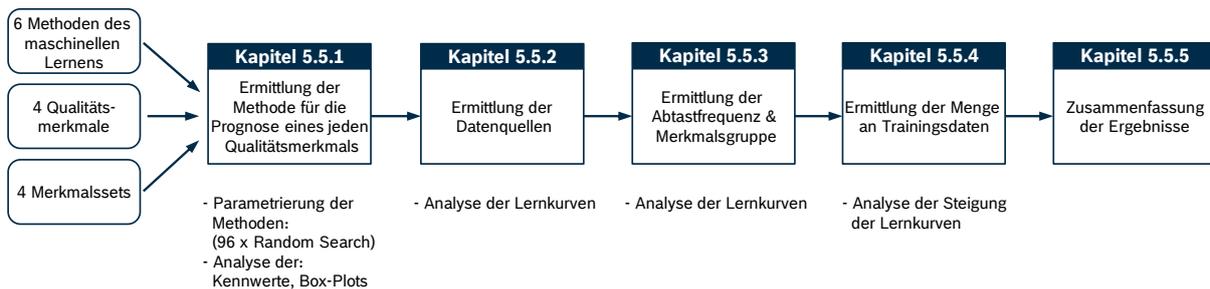


Abbildung 5-20: Aufbau und Inhalt des Kapitels „Einsatz der Methoden des maschinellen Lernens“

5.5.1 Auswahl von geeigneten Methoden des maschinellen Lernens

Im diesem Kapitel erfolgt eine individuelle Bestimmung der am besten geeigneten Methode des maschinellen Lernens für die Prognose eines jeden Qualitätsmerkmals. Grundlage hierfür sind die im vorherigen Kapitel extrahierten und selektierten Merkmale sowie die gemessenen Qualitätswerte. Die Bestimmung der besten Methode erfolgt durch den Vergleich der erreichten Werte für die Kennzahlen: mittlerer absoluter Fehler, maximaler Fehler und Bestimmtheitsmaß. Zudem werden Box-Plot Diagramme zur Beurteilung der Verteilung der Prognosewerte hinzugezogen. Die folgenden Methoden des maschinellen Lernens werden für die Prognose berücksichtigt (siehe Kapitel 2.4.2): künstliches neuronales Netz (KNN), Support Vector Regressor (SVR), Entscheidungsbaum (EB), Random Forest Regressor (RFR), Gradient Boosting Regressor (GBR) und Convolutional Neural Network (CNN). Mittels einer Random Search (siehe Kapitel 2.4.2) werden die Werte der einstellbaren Parameter der erwähnten Methoden bestimmt, welche zu den genauesten Prognosen eines Qualitätsmerkmals, auf der Basis des jeweiligen Merkmalssets, führen. Aufgrund von sechs Methoden des maschinellen Lernens und vier verschiedenen Merkmalssets sind für jedes Qualitätsmerkmal 24 separate Random Search notwendig. Die ermittelten Parameterwerte der Methoden, welche final für die Prognosen genutzt werden, sind im Anhang B aufgeführt. Die Random Search wie auch die Ermittlung der Kennzahlen erfolgt mittels einer 10-fachen Kreuzvalidierung. Die in Kapitel 5.3 erfassten Daten werden zu 80 % für das Trainieren der Methoden und zu 20 % für das Testen verwendet. Die Bestimmung der Kennzahlenwerte erfolgt mittels der zurückbehaltenen Testdaten im Anschluss an das Training der Methoden. Für jedes Qualitätsmerkmal werden die erzielten Kennzahlenwerte in Abhängigkeit von den verwendeten Methoden des maschinellen Lernens und den Merkmalssets grafisch dargestellt. Im Anhang C befindet sich zudem eine tabellarische Aufstellung aller Werte.

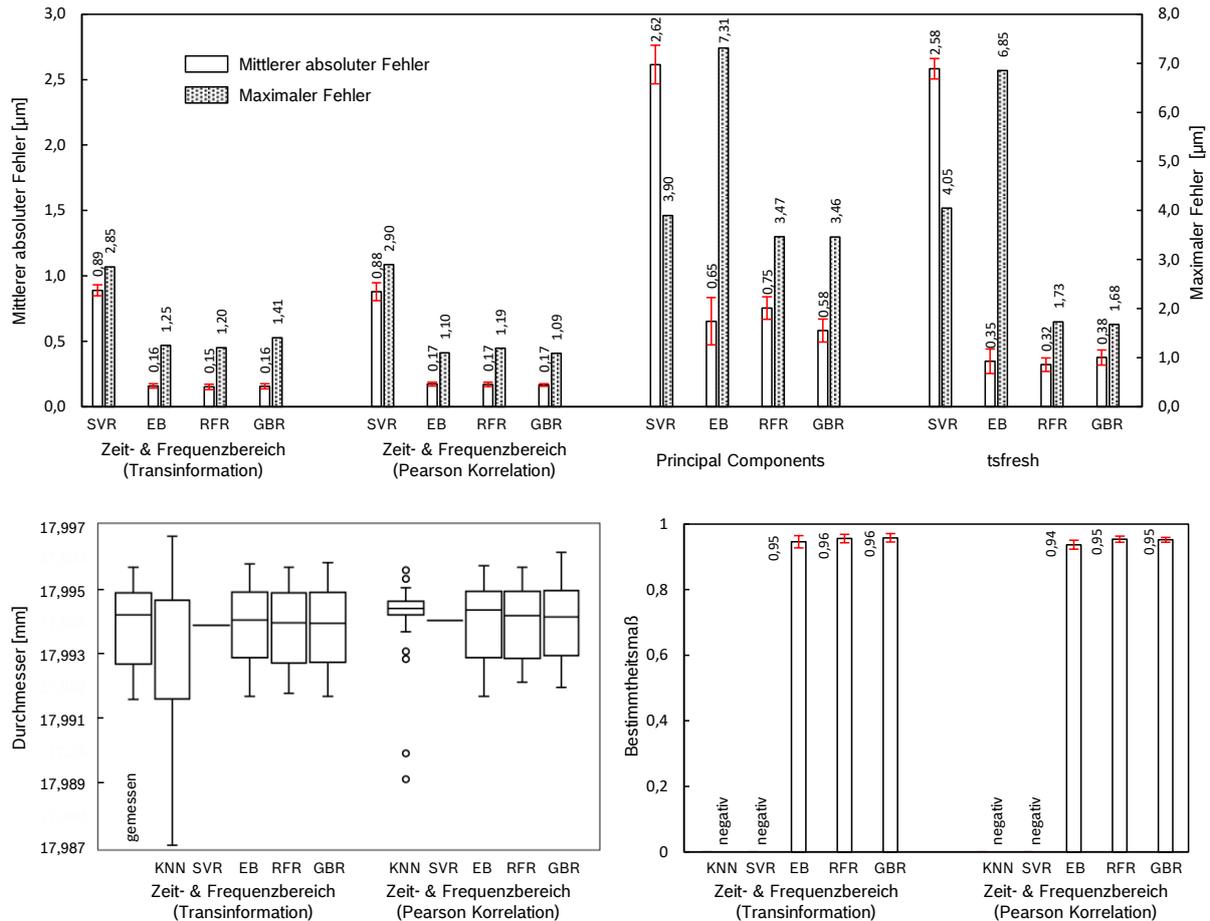


Abbildung 5-21: Prognose des Durchmessers: Prognosefehler, Box-Plot Diagramm und Bestimmtheitsmaß in Abhängigkeit von der Methode des maschinellen Lernens und der Merkmale

In der Abbildung 5-21 sind für die Prognose des Durchmessers die mittleren absoluten Fehler, inklusive der Standardabweichung, die maximalen Fehler, die Box-Plots sowie das Bestimmtheitsmaß dargestellt. Die Standardabweichung entsteht aufgrund der 10-fachen Kreuzvalidierung, der maximale Fehler stellt die größte Abweichung zwischen prognostiziertem und gemessenem Durchmesser dar, der während der Kreuzvalidierung aufgetreten ist. Es ist zu erkennen, dass die besten Prognosen von den Methoden des maschinellen Lernens für die Merkmale aus dem Zeit- und Frequenzbereich unabhängig von der Selektionsmethode erzielt werden. Zudem sind die Standardabweichungen sehr gering, was für eine hohe Wiederholgenauigkeit der Prognosen steht. Für die PCA und tsfresh Merkmale sind die Prognosefehler durchweg deutlich höher. Die Prognosefehler des CNN und KNN sind aufgrund ihrer Größe nicht in dem Diagramm enthalten. Die ermittelten Kennzahlenwerte können der Tabelle im Anhang C entnommen werden. Das Box-Plot Diagramm enthüllt den Bereich, in dem die einzelnen Prognosen der Methoden liegen. Es wird deutlich, dass die Prognosen des KNN und des SVR nicht den Wertebereich der gemessenen Durchmesser widerspiegeln. Dies erklärt auch die hohen Prognosefehler für diese beiden Methoden. Die Merkmalsselektionsmethode scheint einen Einfluss auf das KNN zu haben, jedoch führt dies nur zu einer breiteren oder schmalere Bandbreite

der Prognosewerte. Das Bestimmtheitsmaß ist für KNN und SVR zudem negativ, Werte von über 90 % werden hingegen für die verbliebenen Methoden erzielt. Aufgrund der sehr dicht beieinanderliegenden Kennzahlenwerte hebt sich keine der drei Methoden EB, RFR und GBR als die zwingend beste Methode hervor. Um eine Auswahl dennoch treffen zu können, wird eine Qualitätsprognose für einen Validierungsdatensatz durchgeführt. Der Validierungsdatensatz setzt sich aus Daten zusammen, die weder dem Trainings- noch dem Testdatensatz entstammen und somit für die Methode des maschinellen Lernens absolut unbekannt sind. Die Bewertung der Prognosegenauigkeit erfolgt in diesem Fall grafisch durch den Vergleich der Verteilungskurven der erzielten Prognosewerte. In Abbildung 5-22 sind die Ergebnisse, welche für die Merkmale aus dem Zeit- und Frequenzbereich erzielt wurden, für die drei Methoden dargestellt. Da die Pearson Korrelation nur eine schwache lineare Korrelation der Merkmale mit dem Durchmesser nachweisen konnte (siehe Kapitel 5.4.3), erfolgt die Merkmalsselektion mit der Transinformation. Es zeigt sich, dass der GBR die besten Prognosen für den Validierungsdatensatz liefert, gefolgt von dem RFR und dem EB. Bei den beiden zuletzt genannten Methoden tritt ein Effekt auf, der zu einer Zentralisierung der Prognosewerte in dem Wertebereich der Messungen führt. Hierdurch wird nicht mehr die volle Bandbreite der tatsächlich vorliegenden Messungen wiedergegeben. Die Abbildung 5-22 visualisiert diesen Effekt für die Durchmesserprognose.

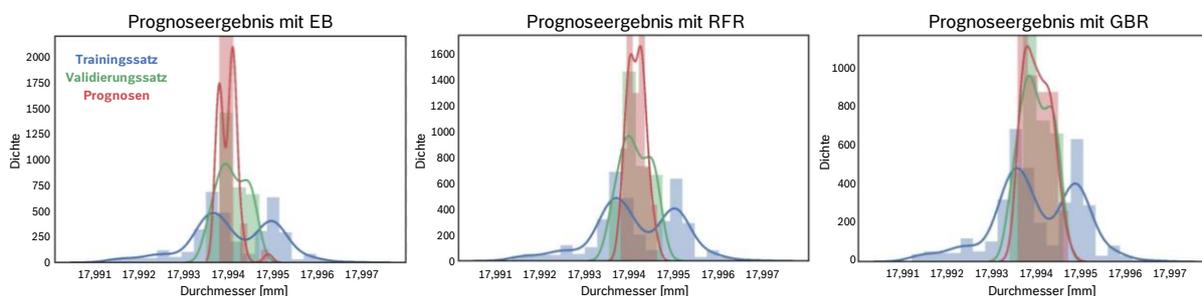


Abbildung 5-22: Einfluss der Methoden EB, RFR und GBR auf die Breite der Verteilung der Prognoseergebnisse des Validierungsdatensatzes unter Verwendung der bestimmten Parametrierung

Die erzielten Kennzahlenwerte für die Prognose der Konzentrität sind in der Abbildung 5-23 abgebildet. Die niedrigsten Prognosefehler werden auf der Basis der Merkmale aus dem Zeit- und Frequenzbereich erzielt. Für die Kennzahl maximaler Fehler kann das Merkmalsset tsfresh teilweise ebenso niedrige Werte hervorbringen, wie mit den Merkmalen aus dem Zeit- und Frequenzbereich, jedoch spricht die hohe Berechnungsdauer der tsfresh Merkmale sowie der höhere mittlere absolute Fehler gegen die Verwendung dieser Merkmale. Für einzelne Merkmalssets werden auch von den Methoden KNN, SVR und CNN relativ gute Konzentritätsprognosen erzielt. Das Box-Plot Diagramm zeigt jedoch auf, dass das KNN und der SVR den Wertebereich der gemessenen Konzentrität nur zu einem sehr geringen Teil abdecken. Das CNN erzielt hingegen eine gute Abdeckung, was sich auch in einem

hohen Bestimmtheitsmaß widerspiegelt. Es existieren keine großen Unterschiede der Prognosegenauigkeit zwischen den Methoden EB, RFR und GBR. Der EB erreicht ein etwas niedrigeres Bestimmtheitsmaß und weist eine höhere Standardabweichung auf, weshalb er nicht weiter berücksichtigt wird. Zudem tritt für die Prognose der Konzentrität des Validierungsdatensatzes derselbe Effekt wie bereits für die Prognose des Durchmessers auf (hier nicht gesondert dargestellt). Es kommt zu einer Zentrierung der Prognosewerte, welche für den GBR am geringsten ausfällt und somit der GBR für die Konzentritätsprognose verwendet wird. Als Merkmalsselektionsverfahren kann sich hierbei die Pearson Korrelation gegenüber dem Transinformativverfahren besser behaupten und wird daher bevorzugt eingesetzt.

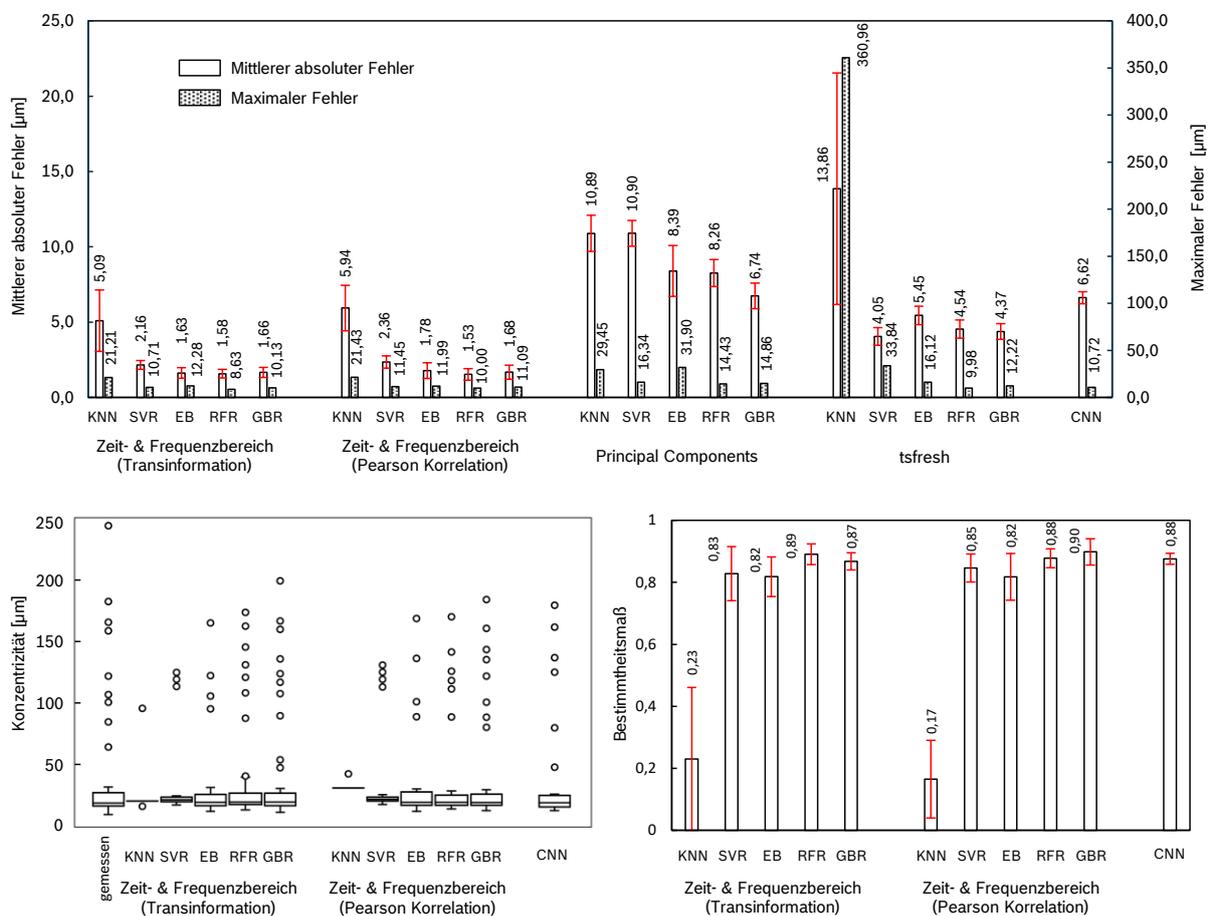


Abbildung 5-23: Prognose der Konzentrität: Prognosefehler, Box-Plot Diagramm und Bestimmtheitsmaß in Abhängigkeit von der Methode des maschinellen Lernens und der Merkmale

Für die Prognose der Geradheit (siehe Abbildung 5-24) erzielen die Methoden EB, RFR und GBR erneut die besten Prognosewerte und zwar nahezu unabhängig von den verwendeten Merkmalen. Die beste Kombination an Werten für den mittleren sowie den maximalen Prognosefehler als auch für das erzielte Bestimmtheitsmaß wird von dem GBR erreicht. Die Merkmale stammen hierbei aus dem Zeit- und Frequenzbereich und werden mittels des Transinformativverfahrens selektiert. Die

Standardabweichungen der Kennzahlen sind zudem sehr gering und es wird eine gute, wenn auch nicht perfekte, Übereinstimmung der Wertebereiche bei den Box-Plots erzielt. Die Betrachtung der Prognoseergebnisse für den Validierungsdatensatz liefert keine zusätzlichen Erkenntnisse. Der zuvor auftretende Effekt der Zentrierung der Prognoseergebnisse bei den beiden Qualitätsmerkmalen Durchmesser und Konzentrität tritt bei der Geradheit für alle der drei Methoden des maschinellen Lernens gleich stark auf (hier nicht gesondert dargestellt).

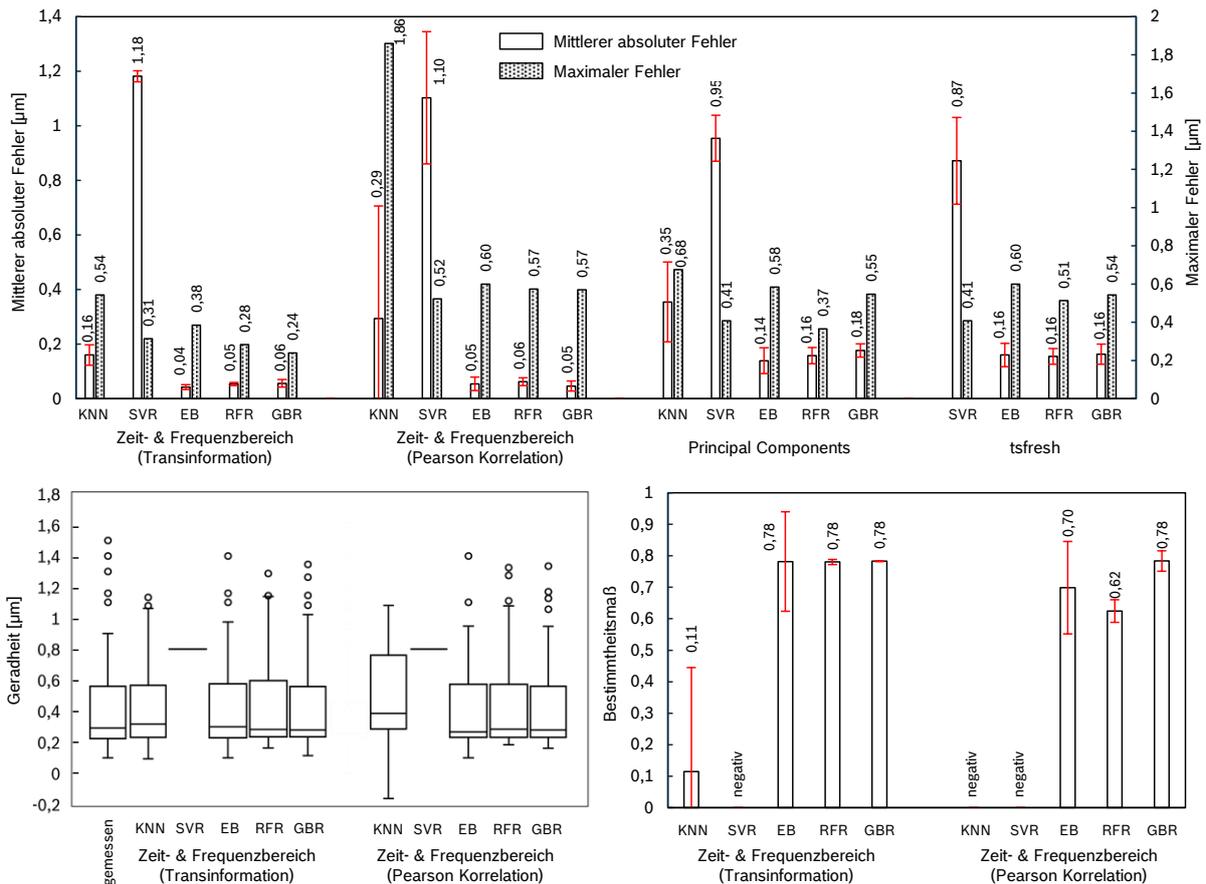


Abbildung 5-24: Prognose der Geradheit: Prognosefehler, Box-Plot Diagramm und Bestimmtheitsmaß in Abhängigkeit von der Methode des maschinellen Lernens und der Merkmale

Die Ergebnisse der Prognosen für die Rundheit (siehe Abbildung 5-25) verhalten sich sehr ähnlich zu den erzielten Ergebnissen für die Geradheit. Erneut sind EB, RFR und GBR die besten Methoden und die Merkmale des Zeit- und Frequenzbereiches führen zu den niedrigsten Prognosefehlern. Für das Bestimmtheitsmaß werden jedoch nur verhältnismäßig niedrige Werte erreicht, was auf eine schlechtere Anpassungsfähigkeit der verwendeten Methoden hindeutet. Eventuell beinhalten die erfassten Daten bzw. die extrahierten Merkmale nicht die notwendigen Informationen, um eine zuverlässige Prognose der Rundheit zu erreichen. In den folgenden Kapiteln wird darauf weiter eingegangen. Die Methode RFR in Kombination mit dem Selektionsverfahren der Transinformation wird für die Prognose der Rundheit genutzt. Entscheidend hierfür ist die gute Übereinstimmung der Box-Plots zwischen der gemess-

senen Rundheit und der RFR Prognose sowie die niedrigen Werte für die Prognosefehler. Hinsichtlich der Prognosegenauigkeit für den Validierungsdatensatz ergeben sich keine besonderen Effekte, die die Wahl einer anderen Methode notwendig machen (hier nicht gesondert dargestellt).

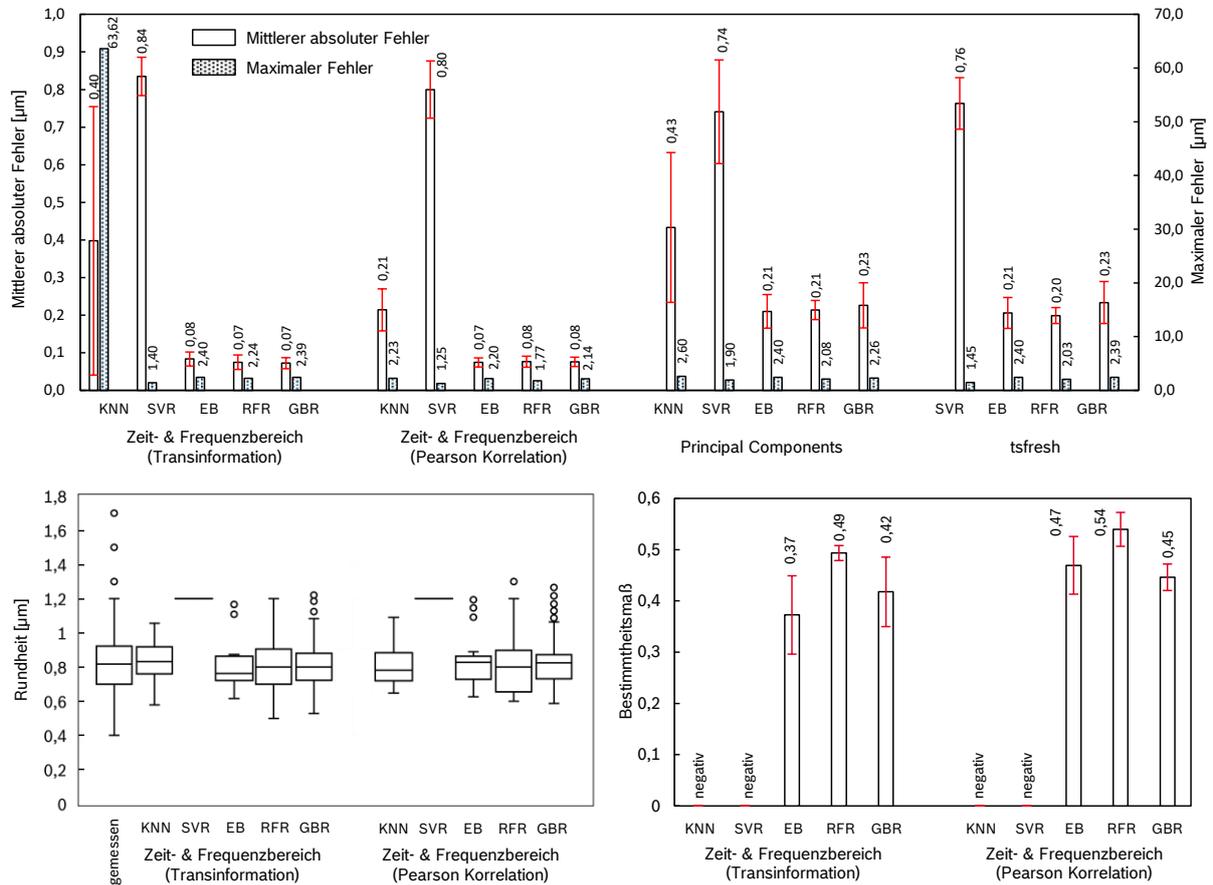


Abbildung 5-25: Prognose der Rundheit: Prognosefehler, Box-Plot Diagramm und Bestimmtheitsmaß in Abhängigkeit von der Methode des maschinellen Lernens und der Merkmale

Das hier aufgezeigte Vorgehen ist notwendig, um aus den verschiedenen Methoden des maschinellen Lernens die Methoden zu bestimmen bzw. in die nähere Auswahl zu nehmen, die für die existierenden Merkmale und für die zu prognostizierenden Größen die besten Prognosewerte liefern. Mittels der Random Search wurde zudem eine geeignete Parametrierung der einzelnen Methoden (siehe Anhang B) bestimmt und vorgenommen, welche die Prognosefehler minimieren. Zusätzlich erfolgte die Festlegung der geeignetsten Merkmalssets. Final lässt sich festhalten, dass die Methoden GBR und RFR zusammen mit den Merkmalen aus dem Zeit- und Frequenzbereich für den hier betrachteten Anwendungsfall der Qualitätsprognose sehr gute Ergebnisse erzielen. Ob für die Merkmalsselektion die Pearson Korrelation oder die Transinformation verwendet wird, macht für die Prognosegenauigkeit des GBR und RFR nahezu keinen Unterschied. Zusätzliche Analysen haben gezeigt, dass bei einer Berücksichtigung von allen Merkmalen weniger gute Prognoseergebnisse erreicht werden. Die besten Kennwerte werden bei der

Berücksichtigung von ca. zwei Drittel (70 %) der Merkmale (gelistet nach dem Korrelationswert oder dem Transinformationswert) erreicht. Dass die beiden Methoden RFR und GBR so identische Ergebnisse liefern, wird sehr wahrscheinlich an ihrem sehr ähnlichen Funktionsprinzip liegen (siehe 2.4.3). Die Methode KNN, CNN und SVR sind für den Anwendungsfall weniger gut geeignet. Obwohl ein sehr breiter Parameterbereich bei der Random Search berücksichtigt wurde, konnte keine Parametrierung gefunden werden, die zu zufriedenstellenden Ergebnissen führt. Eventuell ist auch die Anzahl von Trainingsdaten für diese Methoden nicht ausreichend, um die Zusammenhänge zwischen den Merkmalen und der Qualität zu erlernen. Für die weiterführenden Analysen werden daher die Methoden GBR und RFR mit der ermittelten Parametrierungen genutzt.

5.5.2 Einfluss der Datenquellen auf die Prognosegenauigkeit

Im vorherigen Kapitel 5.5.1 wurden die Methoden des maschinellen Lernens sowie die Merkmale und Merkmalsselektionsverfahren bestimmt, die zu guten Prognosewerten der jeweiligen Qualitätsmerkmale führen. Im Folgenden werden die einzelnen Datenquellen (Spindel und Achsen), die Abtastfrequenz, die Merkmalsgruppe sowie die Anzahl der notwendigen Trainingsdaten bestimmt, die für eine gute Prognosegenauigkeit notwendig sind. Der Hintergrund für diese Analysen beruht auf zwei grundlegenden Problematiken. Die erste Problematik stellt die Erfassung der Fertigungsdaten dar. Je weniger Datenquellen (inkl. Abtastfrequenz) sowie Trainingsdaten benötigt werden, um eine Prognose mit der gewünschten Genauigkeit zu erzielen, umso effizienter wird der Prognoseprozess. Schließlich müssen nur die absolut notwendigen Daten in der Serienfertigung erfasst und verarbeitet werden, was Speicherplatz, Rechenleistung und Zeit spart. Zudem reduziert ein möglichst kleiner Trainingsdatensatz maßgeblich den initialen Implementierungsaufwand, da zum Trainieren der Methoden nicht nur die Fertigungsdaten, sondern auch die Messwerte der Qualitätsmerkmale benötigt werden, welche separat erfasst werden müssen. Die zweite Problematik geht von den Methoden des maschinellen Lernens aus und besteht darin, dass Datenquellen bzw. Merkmale, die in keiner Beziehung zu der zu prognostizierenden Größe stehen, die Prognosegenauigkeit verschlechtern, wenn sie berücksichtigt werden. Zudem ist darauf zu achten, dass durch das Weglassen von redundanten Datenquellen die Robustheit der Prognose nicht gemindert wird. Aus diesen Gründen ist es ratsam, eine detaillierte Bewertung der benötigten Datenquellen und der Anzahl von Trainingsdaten für jedes Qualitätsmerkmal durchzuführen. Dies erfolgt mittels der Erzeugung von sogenannten Lernkurven, welche den mittleren absoluten Prognosefehler in Abhängigkeit von der für das Training verwendeten Anzahl von Trainingsdaten aufzeigen. Hierfür werden von dem zugrundeliegenden Trainingsdatensatz jeweils nur eine zufällig gezogene Teilmenge an Daten für das Training berücksichtigt, welche sich schrittweise bis zum Erreichen der maximalen verfügbaren Anzahl von Trainingsdaten erhöht. Zusätzlich wird von jeder erzeugten Teilmenge 20 % der Daten für das Testen der jeweils trainierten Methode zurückbehalten. Des Weiteren wird mittels eines Validierungsdatensatzes die Generalisierbar-

keit der trainierten Methode überprüft. Der Validierungsdatensatz umfasst 50 Ventile (sechstes Fertigungslos, siehe Kapitel 5.3.2), welcher unabhängig von dem Datensatz ist, aus dem der Trainings- und Testsatz gewonnen wird. Angewandt wird eine fünffache Kreuzvalidierung pro durchgeführten Schritt, sodass fünf Prognosewerte für das Training, Testing und die Validierung vorliegen. Der Mittelwert wird jeweils als Lernkurve (dunkle Linie in den Abbildungen) dargestellt, ergänzt um die Standardabweichung als schattierter Bereich. Die Trainingskurve stellt den Prognosefehler für die Daten dar, mit denen zuvor die Methode trainiert und im Anschluss eine Prognose erstellt wurde. Die Testingkurve repräsentiert den Prognosefehler der trainierten Methode, der für die zurückbehaltenen Testdaten erzielt wird. Letztendlich lässt sich die Generalisierbarkeit der trainierten Methode anhand der Validierungskurve ablesen, welche den Prognosefehler für den Validierungsdatensatz wiedergibt.

In den Abbildung 5-26 bis Abbildung 5-29 sind für die einzelnen Qualitätsmerkmale die drei Lernkurven für das Training, das Testing und die Validierung in den Farben grün, blau, und rot dargestellt. Im oberen rechten Bereich eines jeden Diagramms sind die Datenquellen aufgeführt, welche zur Erzeugung der Lernkurven berücksichtigt wurden. Von Diagramm zu Diagramm (eins bis neun) wird jeweils eine Datenquelle entnommen bzw. wieder hinzugefügt, um den Einfluss der einzelnen Datenquellen auf den Lernprozess aufzudecken. Alle Diagramme haben gemein, dass die Testing- und Validierungskurven aus dem Unendlichen kommen und mit der steigenden Anzahl berücksichtigter Trainingsdaten den Prognosefehler reduzieren und gegen einen Wert konvergieren. Für die Trainingskurven verhält es sich ähnlich, jedoch startet hier der Prognosefehler bei null und erhöht sich dann, bis er schließlich gegen einen Wert konvergiert. Dies kommt aufgrund des Sachverhaltes, dass der Trainingsdatensatz zu Beginn aus nur einem einzigen Ventil besteht und die trainierte Methode für dieses eine Ventil die Qualitätsprognose fehlerfrei reproduzieren kann. Jedoch deckt die trainierte Methode nicht die volle Varianz des Testdaten- und Validierungssatzes ab, sodass hierfür der Fehler maximal ist. Mit der steigenden Anzahl von berücksichtigten Trainingsdaten gleicht sich dieser Effekt aus.

Die Abbildung 5-26 stellt den Einfluss der Datenquellen für die Durchmesserprognose in den zuvor erwähnten neun Diagrammen dar. Im ersten Diagramm erfolgt die Berücksichtigung der Merkmale aller Datenquellen (siehe Kapitel 5.4.1) und es stellen sich Prognosefehler von etwas über (unter) $0,2 \mu\text{m}$ für das Validieren (Testing) sowie von ca. $0,08 \mu\text{m}$ für das Training ein. Im zweiten Diagramm wird der Fertigungsschritt Pilotieren nicht weiterhin berücksichtigt, was auf den Verlauf der drei Kurven und den Prognosefehler keinen Einfluss hat. Lediglich die Standardabweichung der Validierungskurve reduziert sich, was als positiv für die Prognosewiederholbarkeit gedeutet werden kann. Die Nichtberücksichtigung des Pilotiervorgangs für die Durchmesserprognose erweist sich somit als vorteilhaft. Dies ist aus fertigungstechnischer Sicht auch nachvollziehbar, da der Durchmesser durch den Reib- und Bohrprozess erzeugt wird. Demnach ist es auch nicht überraschend, dass der Validierungsfehler im dritten und vierten Diagramm ansteigt, wenn der Bohrvorgang bzw. der Reibvorgang nicht für die Prognose berücksichtigt wird.

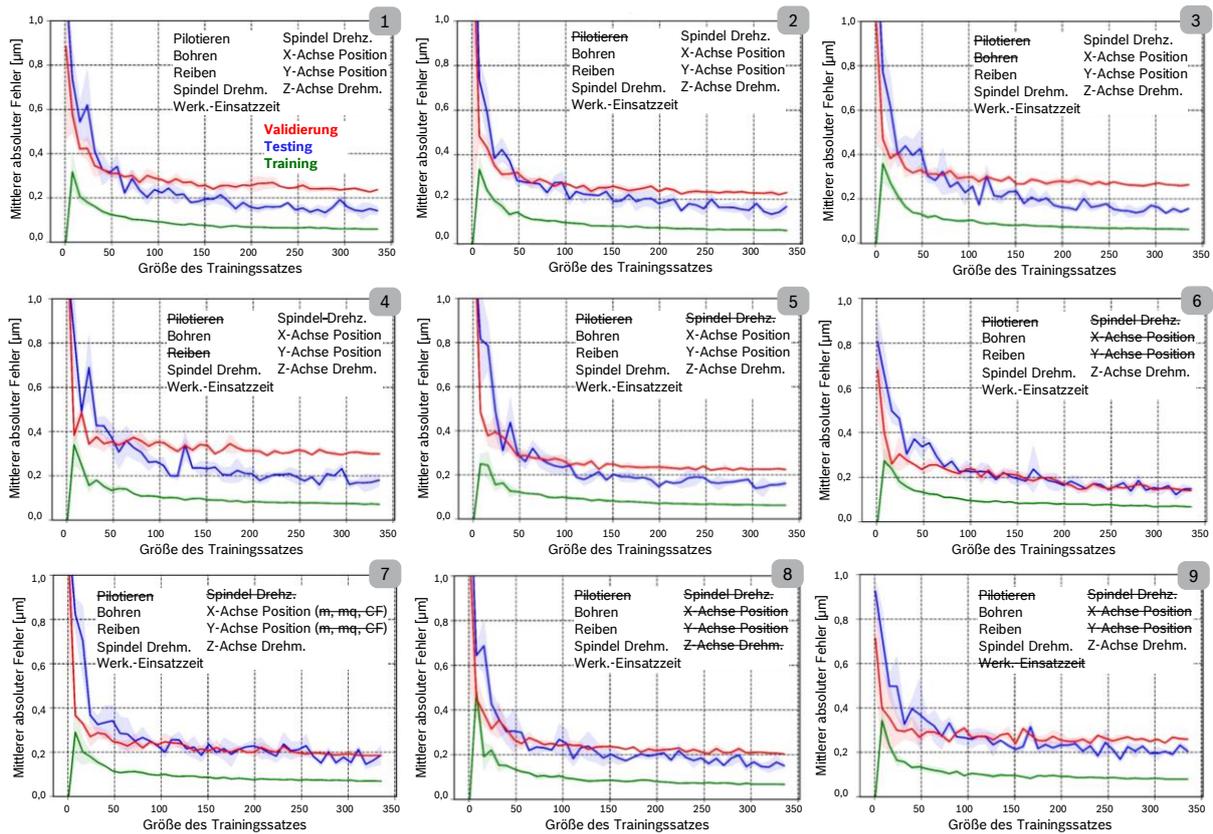


Abbildung 5-26: Lernkurven für die Prognose des Durchmessers mittels GBR

Der finale Durchmesser wird zwar von der Reibahle erzeugt, jedoch hat die Vorbearbeitung einen erheblichen Einfluss auf den Reibprozess und die Höhe der dabei auftretenden Drehmomentwerte. Die bei der Datenerfassung berücksichtigte Kombination von möglichen unterschiedlichen Verschleißzuständen des Bohrers sowie der Reibahle und die daraus resultierenden Wechselwirkungen und Einflüsse auf die Fertigungswerte und den Durchmesser können beim Fehlen der Daten des Bohrprozesses von der Methode des maschinellen Lernens nicht mehr erlernt werden. Somit führt die Prognose ausschließlich mit den Daten des Reibens zu schlechteren Prognosewerten. Analog verhält es sich, wenn die Prognose ohne die Fertigungsdaten des Reibens durchgeführt wird. Durch den Reibprozess wird der finale Durchmesser der Bohrung erzeugt, entsprechend kommt diesem Fertigungsschritt eine bedeutende Stellung zu. Wird dieser nicht beim Training berücksichtigt, so hat dies einen negativen Einfluss auf den Validierungs- als auch auf den Testingfehler. Die Prozessschritte Bohren und Reiben sind somit essentiell für eine zuverlässige Durchmesserprognose und deswegen im Prognosemodell zu berücksichtigen. Die Nichtbeachtung der Spindeldrehzahl und des Pilotierens (fünftes Diagramm) reduziert etwas den Prognosefehler der Validierungskurve. Folglich spielt die Drehzahl, welche sehr konstant während der Bearbeitungsschritte ist, keine Rolle für die Durchmesserprognose. Eine Berücksichtigung im Trainingssatz führt sogar zu einer Prognoseverschlechterung, da die Methode mit Daten trainiert wird, die für die Prognose der Zielgröße irrelevant sind. Dieser Effekt tritt im sechsten Diagramm noch deutlicher hervor, wenn zusätzlich die Positionen der X- und Y-Achse nicht berücksichtigt werden. Dies führt

zu einem sehr deutlichen Abfall des Prognosefehlers für den Validierungsdatensatz. Die Position der Achsen ist aus theoretischer Sichtweise für den Durchmesser irrelevant, Positionsschwankungen können hingegen zu Durchmesserschwankungen führen. Solche Schwankungen werden mit den extrahierten Merkmalen zwar auch berechnet, jedoch können sie aufgrund der hier vorliegenden Bauweise der Maschine (Zwei-Spindler) nicht dem individuellen Ventil zugeschrieben werden. Es erfolgt stets die gleichzeitige Bearbeitung von zwei Ventilen, für die jeweils dieselben Werte für die X- und Y-Achse Position gelten. Die Ursache für die auftretende Positionsschwankung, z. B. durch einen Rundlauffehler eines Werkzeuges oder einen Fluchtungsfehler und die daraus resultierenden Kräfte in die X- und Y-Richtung, lassen sich nicht zu der jeweiligen Spindel und somit auch nicht dem Ventil zuordnen. Lediglich der Gesamteinfluss von beiden Spindeln für die parallele Bearbeitung lässt sich in den Positionsschwankungen der X- und Y-Achse ablesen. Im siebten Diagramm werden die Achspositionen berücksichtigt, jedoch ohne die Merkmale: arithmetischer Mittelwert, quadratischer Mittelwert und Crest Faktor. Anhand dieser drei Merkmale äußert sich die Temperaturkompensation der Maschine. In Kapitel 5.4.3 wurde vermutet, dass diese Merkmale in der Auflistung der Merkmalsselektion nur deswegen erscheinen, da sie in Verbindung mit einer Anzahl von Qualitätsmessungen gebracht werden, die zufällig bei einer bestimmten Position gefertigt wurden. Dies scheint zuzutreffen, da beim Fehlen dieser Merkmale der Testingfehler sich leicht erhöht und der Validierungsfehler sich reduziert (im Vergleich zum fünften Diagramm). Diese Entwicklung ist ein Zeichen dafür, dass die Methode generischer wird. Dennoch werden nicht die niedrigen Prognosefehler aus Diagramm sechs erreicht, wo alle Merkmale zu der X- und Y-Achse ausgeblendet werden. Aus dem achten Diagramm geht hervor, dass der Prognosefehler sich wieder erhöht (im Vergleich zu Diagramm sechs), wenn das Drehmoment der Z-Achse nicht in dem Prognosemodell berücksichtigt wird. Beim Bohren und Reiben entfällt ein nur sehr geringer Anteil der aufgebrauchten Zerspanungskräfte in Richtung der Vorschubachse (siehe Kapitel 2.1), dennoch ist das aufgebrauchte Drehmoment der Z-Achse (Vorschubachse) für die Prognose relevant. Das neunte Diagramm zeigt die Bedeutung der Werkzeugeinsatzzeit auf. Wird diese nicht berücksichtigt, so erhöhen sich die Prognosefehler (im Vergleich zum sechsten Diagramm). Der Validierungsfehler steigt um den doppelten Wert an, im Vergleich zum Testingfehler. Hieraus lässt sich erkennen, dass die Werkzeugeinsatzzeit eine wichtige Größe für das Modell ist, um den Zusammenhang zwischen den Drehmomentwerten, den Verschleißzuständen der einzelnen Werkzeuge und dem Durchmesser herzustellen.

Auffällig ist, dass in allen Diagrammen, unabhängig von der berücksichtigten Anzahl von Datenquellen, die Prognosefehler für den Trainings- als auch für den Testdatensatz nahezu die gleichen Verläufe und Werte aufweisen. Dies deutet darauf hin, dass die eingesetzte Methode stets aus den zur Verfügung gestellten Datenquellen genügend Informationen gewinnt, um eine Prognosegenauigkeit zu erreichen, die für den Anwendungsfall und die vorliegenden Bedingungen möglich ist. Anzumerken ist, dass die Testdaten als auch die Trainingsdaten aus der Grundgesamtheit des glei-

chen Datensatzes stammen und somit über die gleiche Verteilung verfügen. Für diese Daten ist die Methode (GBR) in der Lage, die Zusammenhänge zwischen Merkmalswerten und Durchmesserwerten stupide zu lernen. Jedoch ist die auf diese Weise trainierte Methode nicht generisch und prognostiziert für unbekannte Datensätze weniger akkurate Durchmesserwerte (siehe Validierungsfehler). Dem kann entgegengewirkt werden, indem nur die Datenquellen für das Training berücksichtigt werden, die in einem möglichst direkten physikalischen Zusammenhang mit der Zielgröße (Durchmesser) stehen und jede weitere Datenquelle ausgeschlossen wird. Auf Basis dieser Schlussfolgerung ist das Drehmoment der Spindel und der Z-Achse für den Bohr- als auch für den Reibprozess sowie die Werkzeugeinsatzzeit (siehe sechstes Diagramm) für eine zuverlässige Durchmesserprognose zu berücksichtigen.

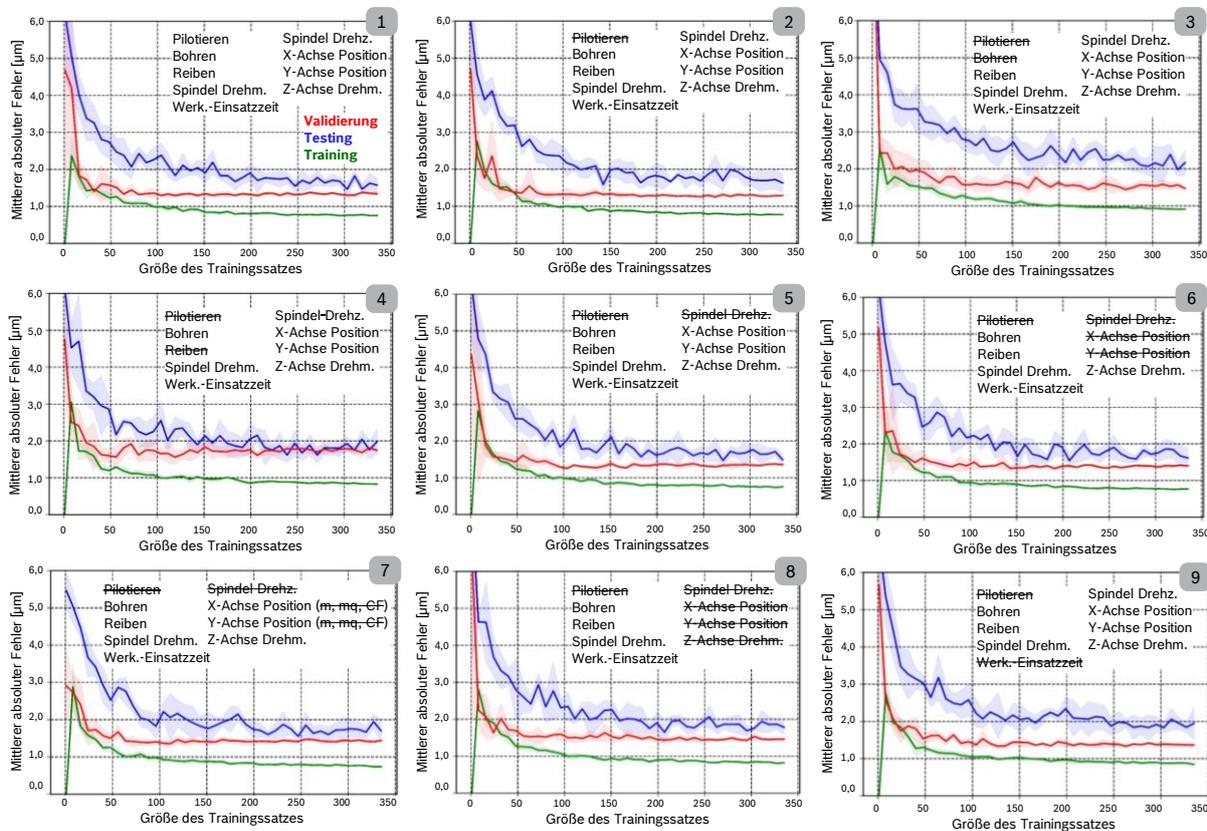


Abbildung 5-27: Lernkurven für die Prognose der Konzentrität mittels GBR

Im Unterschied zu den Lernkurven der Durchmesserprognose befindet sich bei der Konzentritätsprognose die Lernkurve für das Testing stets über der Lernkurve für die Validierung (siehe Abbildung 5-27). Der Prognosefehler für den Testdatensatz ist somit immer größer als der Validierungsfehler, obwohl der Testdatensatz und der Trainingsdatensatz aus derselben Grundmenge an Daten stammen. Der Grund hierfür liegt sehr wahrscheinlich in dem Verhältnis der Messergebnisbreiten (Differenz zwischen dem maximal und dem minimal gemessenen Wert eines Qualitätsmerkmals) von Validierungsdatensatz und Grundmenge sowie der Dichteverteilung der

jeweiligen Datensätze. Für den Durchmesser ergibt sich eine Messergebnisbreite von $1,2 \mu\text{m}$ für den Validierungsdatensatz (Fertigungslos sechs) und von $5,5 \mu\text{m}$ für die Grundmenge (Fertigungslose zwei bis fünf), aus der der Trainings- und Testdatensatz entnommen werden. Die Messergebnisbreite des Validierungsdatensatzes ist somit 4,6-mal kleiner als die des Trainings- bzw. Testdatensatzes. Die Dichteverteilung des Validierungsdatensatzes des Durchmessers liegt, im Unterschied zur Konzentrität, jedoch nicht im Gipfel der Dichteverteilung der Grundmenge des Durchmessers und ist somit weniger häufig in den Trainingsdaten vorhanden (siehe Abbildung 5-12, Abbildung 5-38 und Abbildung 5-39. Hinweis: Fertigungslos eins wird nicht berücksichtigt, siehe Kapitel 5.4.2). Für die Konzentrität liegen die Messergebnisbreiten des Validierungsdatensatzes bei $9,7 \mu\text{m}$ und bei $240,8 \mu\text{m}$ für die Grundmenge des Trainings- und Testdatensatzes. Demnach ist die Breite, auf der sich die gemessenen Konzentritätswerte des Validierungsdatensatzes verteilen, 24-mal kleiner als für den Trainings- und Testdatensatz. Die Verteilung der Konzentritätswerte ähnelt einer Lognormalverteilung mit einem Gipfel bei ca. $10 \mu\text{m}$. In diesem Gipfel liegt zugleich auch der Gipfel der Dichtefunktion des Validierungsdatensatzes. Der Trainingsdatensatz beinhaltet somit verhältnismäßig viele Daten zu diesem Wertebereich und die Methode des maschinellen Lernens kann die jeweiligen Zusammenhänge häufiger und somit besser erlernen. In dem ersten Diagramm der Abbildung 5-27 sind die erreichten Werte und Kurvenverläufe der Konzentritätsprognose für den Ausgangszustand dargestellt. Der Trainingsfehler liegt bei ca. $0,8 \mu\text{m}$ und der Testing- sowie der Validierungsfehler jeweils bei ca. $1,6 \mu\text{m}$ und $1,4 \mu\text{m}$. Auffällig ist der sehr schnelle Abfall des Validierungsfehlers auf den finalen Wert von $1,4 \mu\text{m}$ nach bereits nur 100 Trainingsdaten sowie die sehr niedrige Standardabweichung. Für das Testing sind mindestens 250 Trainingsdaten notwendig, um den Wert von ca. $1,6 \mu\text{m}$ bei einer deutlich höheren Standardabweichung im Vergleich zur Validierung zu erreichen. Wird das Pilotieren bei der Prognoseerstellung nicht berücksichtigt, so reduziert sich der Validierungsfehler um $0,1 \mu\text{m}$ und der Testingfehler steigt um diesen Wert an (Diagramm zwei). Eine zusätzliche Nichtberücksichtigung des Bohrens (Diagramm drei) lässt alle drei Lernkurven ansteigen und führt somit zu höheren Fehlerwerten. Der Bohrprozess ist aus der Theorie essentiell für die Konzentrität der Bohrung, was hier durch die auftretenden Effekte auch so wiederspiegelt wird. Im vierten Diagramm ist ein Anstieg des Validierungsfehlers bis auf das Niveau des Testingfehlers zu erkennen, wenn der Reibprozess der Methode des maschinellen Lernens vorenthalten wird. Insbesondere weil die Konzentrität über alle vier Flächen bestimmt wird (siehe Abbildung 5-1) und nur die ersten drei Flächen gerieben werden, hat auch der Reibprozess einen Einfluss auf die Konzentrität. Bei der Nichtberücksichtigung von einem der beiden Fertigungsschritte werden Wechselwirkungen nicht mehr eindeutig erkannt und ein Genauigkeitsverlust ist die Folge. Die Streichung der Drehzahl (Diagramm fünf) lässt den Validierungsfehler minimal ansteigen, im Vergleich zu Diagramm zwei. Dieser Effekt tritt ebenso ein, wenn zudem die Positionen der X- und Y-Achse nicht berücksichtigt werden (Diagramm sechs) bzw. teilweise nicht berücksichtigt werden (Diagramm sieben). Die Positionsabweichungen der X- und Y-Achse gegenüber dem Normalzustand sind auf die Kräf-

te, welche während der Fertigung in die entsprechende Achsrichtung wirken, zu erklären. Die Kräfte können z. B. durch ein Verlaufen des Bohrers hervorgerufen werden. Im Gegensatz zu der Durchmesserprognose ist die Berücksichtigung der Achspositionen für die Konzentritätsprognose förderlich. Erfolgt zudem die Nichtbeachtung des Drehmomentes der Z-Achse (Diagramm acht), so führt dies zu einem Anstieg des Prognosefehlers bei allen drei Kurven. Insbesondere bei einer vorgegebenen Bohrung mag das notwendige Vorschubdrehmoment der Z-Achse eine Information über die Fluchtung von Bohrung und Bohrer bzw. über ein Verlaufen des Bohrers geben. Ein Anstieg der Prognosefehler, gegenüber der besten Konstellation von Datenquellen aus Diagramm zwei, wird auch dann hervorgerufen, wenn die Werkzeugeinsatzzeit nicht berücksichtigt wird (Diagramm neun). Somit werden die niedrigsten Prognosefehler erreicht, wenn alle Datenquellen bis auf das Pilotieren berücksichtigt werden. Demnach ist die Konstellation, wie im zweiten Diagramm dargestellt, die geeignetste für die Prognose der Konzentrität mittels GBR.

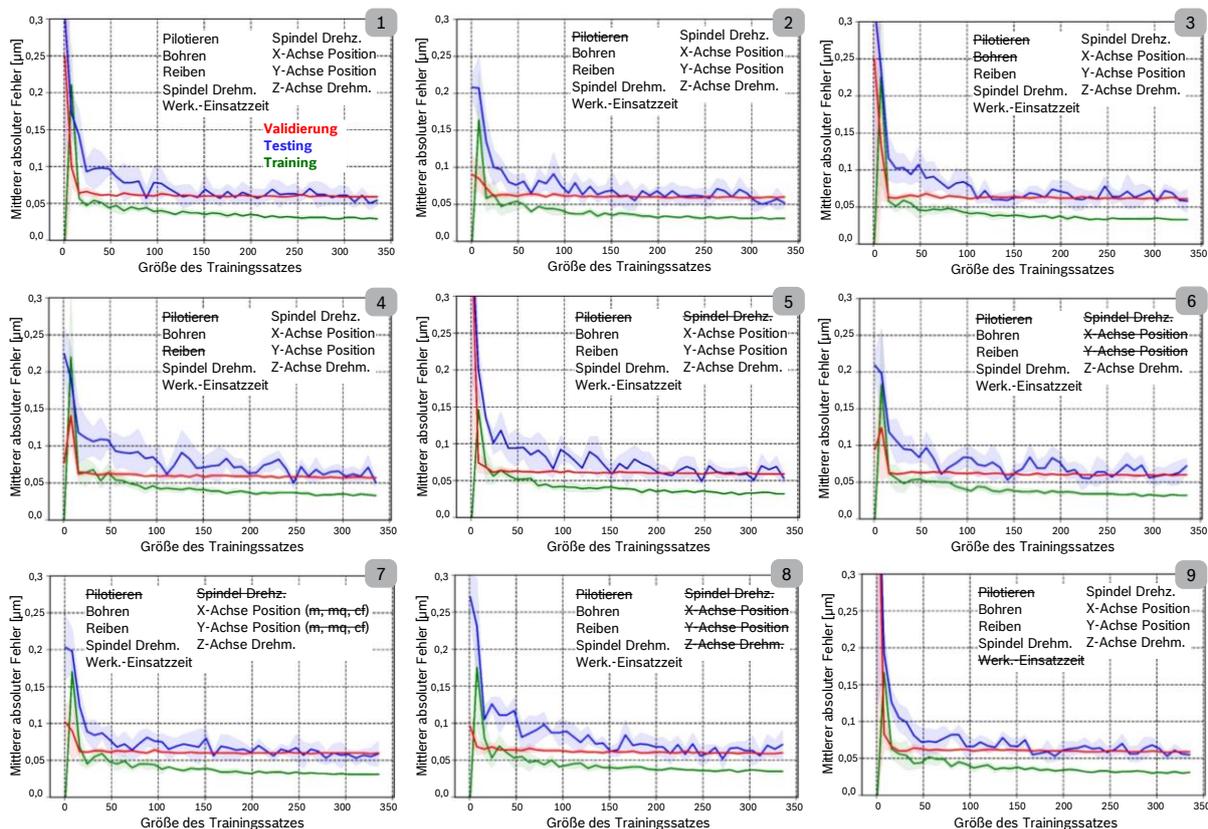


Abbildung 5-28: Lernkurven für die Prognose der Geradheit mittels GBR

In Abbildung 5-28 sind die Lernkurven der Geradheitsprognose abgebildet. Der Validierungsdatensatz, welcher der Validierungskurve zugrunde liegt, umfasst Geradheitsmesswerte, die sich über eine Spanne von 0,234 µm erstrecken. Hiermit ist seine Messwertbreite ca. 6-mal kleiner als die der Grundmenge der Geradheitsmesswerte mit einer Spannweite von 1,44 µm. Die Gipfel der beiden Dichteverteilungen liegen zudem exakt übereinander, sodass aus dem Wertebereich des Validierungs-

datensatzes ein Großteil der Trainingsdaten stammen. Dies führt dazu, dass die Validierungskurve leicht unter bzw. auf der Testingkurve bei einem niedrigen Fehlerniveau liegt. Die Diagramme in Abbildung 5-28 ähneln sich stark. Auffällig für den Validierungsfehler ist sein Sinken auf und sein Verbleib bei $0,06 \mu\text{m}$ nach bereits 50 Trainingsdaten und seine nahezu nicht vorhandene Standardabweichung. Eine Einzelbetrachtung der sieben Diagramme ist aufgrund ihres nahezu gleichen Verlaufes der Kurven nicht notwendig. Werden neben den Fertigungsdaten des Pilotierprozesses weitere Datenquellen nicht berücksichtigt, so hat dies einen leichten Einfluss auf die Steigungsabnahme der Testingkurve. Es werden dann mehr Trainingsdaten benötigt, um ein Konvergieren gegen den Prognosefehler von $0,06 \mu\text{m}$ zu erzielen. Die Verläufe der Trainingskurven, wie auch die der Validierungskurven, bleiben hingegen unverändert. Aufgrund des Verhaltens der Testingkurve werden für die Prognoseerstellung alle Datenquellen bis auf den Pilotierprozess berücksichtigt. Ein Prognosefehler von nur $0,06 \mu\text{m}$ ist für die Geradheit somit erreichbar.

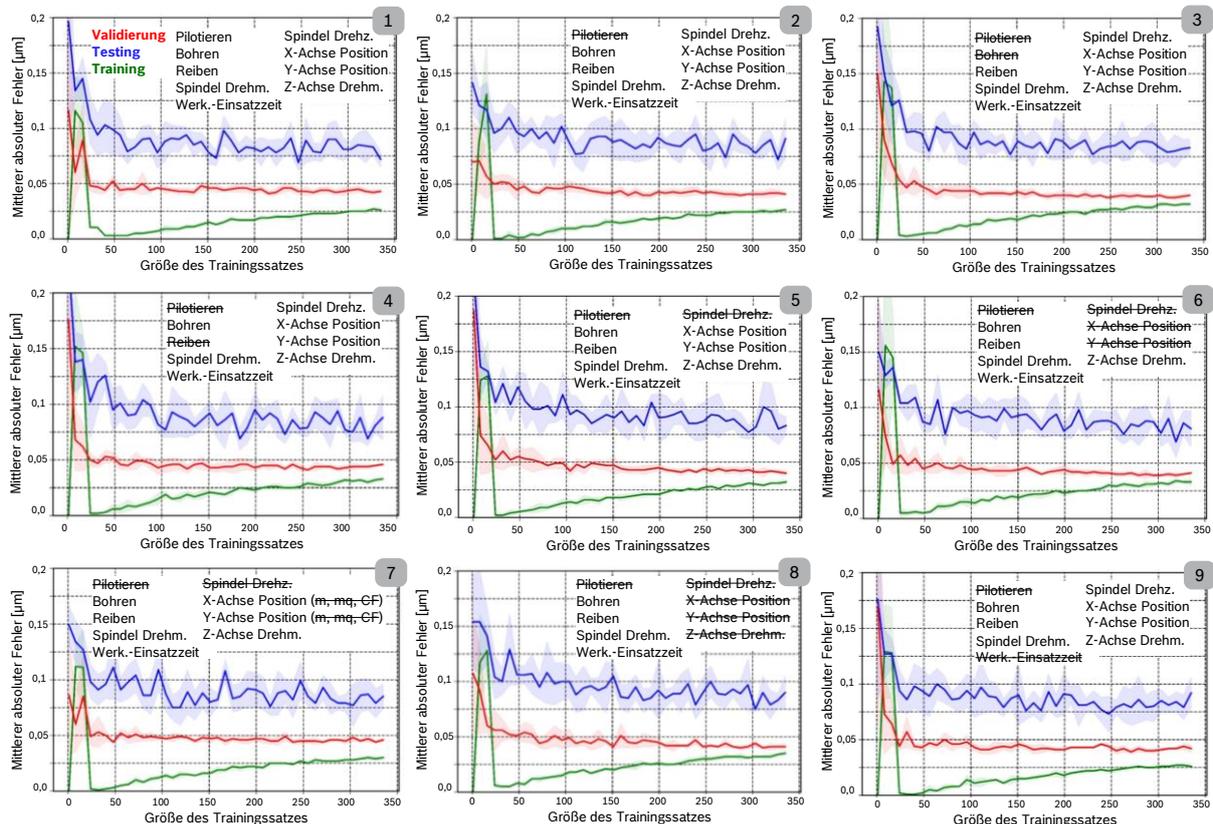


Abbildung 5-29: Lernkurven für die Prognose der Rundheit mittels RFR

Bei den in Abbildung 5-29 dargestellten Lernkurven der Rundheitsprognose liegt der Testingfehler immer über dem Validierungsfehler. Der Grund hierfür liegt in der Verteilung der Messwerte und der damit verbundenen Lage des Validierungsdatensatzes in der Dichteverteilung. Die Messwerte der Rundheit verteilen sich über einen Wertebereich von $0,157 \mu\text{m}$ für den Validierungsdatensatz und $1,2 \mu\text{m}$ für die Grundmenge des Trainings- und Testdatensatzes. Die Grundmenge, mit der die Me-

thode trainiert wird, ist somit 7,6-mal so breit wie der Validierungsdatensatz. Der Gipfel der Dichteverteilung des Validierungsdatensatzes liegt leicht rechts von dem Gipfel der Grundmenge (siehe Abbildung 5-12 und Abbildung 5-40). Demnach repräsentiert der Validierungsdatensatz häufig auftretende Rundheitsmaße sowie die hierfür ursächlichen Fertigungsbedingungen. Der Verlauf der Validierungs- und Testkurve ist derselbe wie bei den zuvor betrachteten Qualitätsmerkmalen. Die Kurven kommen aus dem unendlichen und konvergieren von oben gegen einen Prognosefehler, welcher mit der Methode RFR und den vorliegenden Daten erreichbar ist. Für den Trainingsfehler ergibt sich für eine kleine Anzahl von Trainingsdaten zuerst ein hoher Fehler, welcher dann bis auf null absinkt und von dort gegen den Trainingsfehler von unten kommend konvergiert. Dieser Verlauf der Trainingskurve ist verschieden zu den Verläufen in den vorherigen Diagrammen. Grund ist sehr wahrscheinlich die Anwendung der Methode RFR für die Rundheitsprognose anstatt der Methode GBR, welche für die Prognose der anderen drei Qualitätsmerkmale eingesetzt wurde. Unter Berücksichtigung aller Datenquellen wird ein Testingfehler von $0,075 \mu\text{m}$, ein Validierungsfehler von $0,04 \mu\text{m}$ sowie ein Trainingsfehler von $0,025 \mu\text{m}$ erreicht. Die Nichtberücksichtigung des Pilotierprozesses hat auch für die Rundheitsprognose keinen Einfluss auf die Prognosegenauigkeit. Werden weiter Datenquellen nicht berücksichtigt, so hat dies den größten Einfluss auf den Trainingsfehler, welcher sich dann leicht erhöht. Die Auslassung des Reibprozesses zeigt sich in einem Anstieg des Validierungsfehlers (Diagramm vier). Das Reiben hat als letzter Fertigungsschritt einen bedeutenden Einfluss auf die Rundheit der Bohrung, ist aber auch von dem vorgeschalteten Bohren abhängig. Wird der Bohrprozess nicht mit einbezogen, so reduziert sich hingegen der Validierungsfehler sowie seine Standardabweichung, jedoch erhöht sich der Trainingsfehler (Diagramm drei). Rundheitsfehler können sich durch unregelmäßig auftretende Kräfte in der X- und Y-Richtung bei der hier betrachteten Zerspanung bemerkbar machen, die bei ausreichender Größe eine Positionsveränderung der entsprechenden Achsen hervorrufen können. Demnach wirft die im sechsten und siebten Diagramm auftretende Reduzierung des Validierungsfehlers Fragen auf, wenn ausgerechnet die Achspositionen nicht der Methode zum Lernen mitgeteilt werden. Der Trainingsfehler erhöht sich jedoch (wie erwartet), sodass die Kurve des Trainingsfehlers als die Größe hier betrachtet wird, um die Datenquellen für eine zuverlässige Rundheitsprognose zu bestimmen. Demnach dürfen nur die Fertigungsdaten, die von dem Pilotierprozess stammen, für die Prognose der Rundheit weggelassen werden.

Obwohl auftretende Kräfte in X- und Y-Richtung einen Rückschluss auf mögliche Konzentritäts-, Geradheits- und Rundheitsabweichungen geben können, haben die Positionswerte der X- und Y-Achse für die Prognose der Qualitätsmerkmale keinen besonderen Stellenwert. Dies kann daran liegen, dass die Kräfte zu gering sind, um eine Positionsveränderung / -schwankung zu verursachen. Es kann jedoch auch daran liegen, dass die Positionsveränderungen nicht eindeutig einem Ventil zugeordnet werden können, da sie durch die parallele Zerspanung von zwei Ventilen hervorgerufen werden. Die Berücksichtigung der Position verschlechtert nicht zwangsläufig das

Prognoseergebnis, aber sie verbessert das Ergebnis auch nicht in besonderer Weise. Für den Durchmesser ist die Position der Achsen irrelevant, was sich auch in einem deutlich besseren Prognoseergebnis widerspiegelt, wenn die Positionswerte der Achsen nicht berücksichtigt werden. Dennoch werden bei der Merkmalsselektion in Kapitel 5.4.3 die Merkmale der X- und Y-Achse von der Pearson Korrelation und der Transinformation relativ hoch gelistet. Dies zeigt, dass solche Verfahren angewandt werden können, um eine erste grobe Reduzierung der Merkmalsanzahl durchzuführen. Ob die ausgewählten Merkmale auch von der Methode des maschinellen Lernens zum Erlernen der Zusammenhänge im vollen Umfang benötigt werden bzw. hilfreich sind, kann nicht garantiert werden. Die Lernkurven stellen hingegen eine geeignete Lösung dar, um herauszufinden, welche Merkmale bzw. welche Datenquellen für die Prognose der Zielgröße von der Methode des maschinellen Lernens benötigt werden. Hierdurch lässt sich auch das Entstehen der Prognosefehler besser nachvollziehen und der Prognoseprozess wird insgesamt transparenter.

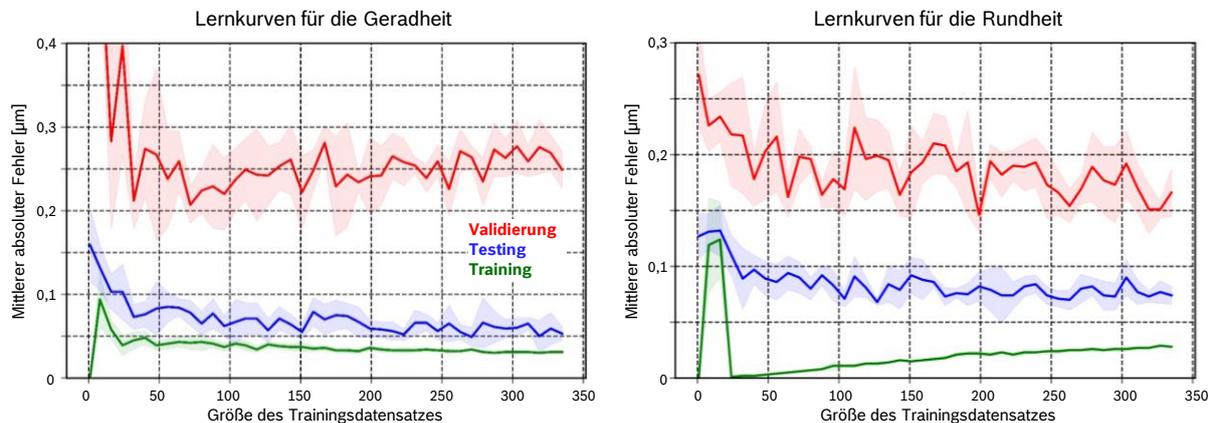


Abbildung 5-30: Lernkurven für die Prognose der Geradheit und der Rundheit mit veränderter Datenkonstellation (Training: Set 2, 4, 5, 6; Validierung: Set 3)

Für die Konzentrität, die Geradheit und die Rundheit liegt die Validierungskurve oberhalb der Testingkurve. Grund hierfür ist die Lage des Validierungsdatensatzes (Set 6) in dem Gipfel der Dichteverteilung der Grundgesamtheit (Set 2, 3, 4 und 5). Es liegen somit ausreichend Trainingsdaten zu dem zu prognostizierenden Qualitätswertebereich vor. Wird ein Set als Validierungsdatensatz gewählt, zu dessen Qualitätswertebereich weniger Trainingsdaten existieren, so steigt der Validierungsfehler an und liegt über dem Testingfehler. In Abbildung 5-30 ist dies für die Geradheits- und die Rundheitsprognose dargestellt, unter Verwendung aller Datenquellen (entspricht dem ersten Diagramm in den vorherigen Abbildungen). Die Grundgesamtheit wird nun durch das zweite, vierte, fünfte und sechste Set repräsentiert und das Validierungsset besteht aus dem dritten Set (siehe Abbildung 5-12). Der Wert des Validierungsfehlers liegt nun deutlich über dem bisherigen Wert und auch die Streuung der Werte nimmt deutlich zu. Hieran wird ersichtlich, dass weitere Trainingsdaten für den Qualitätswertebereich des dritten Sets notwendig sind, um einen

geringeren Prognosefehler zu erzielen. Die Dichte der Trainingsdaten kann somit eine Information darüber liefern, für welchen Wertebereich eines Qualitätsmerkmals mit besonders genauen Prognosen gerechnet werden darf und bei welchem Bereich das trainierte Modell noch Optimierungspotential hat. Für die weiteren Analysen in dieser Arbeit wird die ursprüngliche Konstellation aus Trainings- und Validierungsdaten beibehalten, um Prognosen für alle Qualitätsmerkmale von demselben Datensatz mit dem zugehörigen Fertigungszustand zu erhalten.

5.5.3 Bestimmung der Abtastfrequenz und der Merkmalsgruppe

Nach der Analyse des Einflusses einzelner Datenquellen auf den Verlauf der Lernkurven und auf die Prognosegenauigkeit erfolgt nun für jedes Qualitätsmerkmal die Bestimmung der notwendigen Abtastfrequenz sowie Merkmalsgruppe. Die Analysen erfolgen anhand von Lernkurven individuell für jedes Qualitätsmerkmal auf der Basis der im vorherigen Kapitel 5.5.2 bestimmten Datenquellen. Eine Abtastfrequenz von 1.000 Hz wurde für die ursprüngliche Datenerfassung verwendet. In diesem Kapitel werden zu dem bestehenden Datensatz drei weitere Datensätze mittels Downsampling erzeugt, die die Abtastfrequenzen von 500 Hz, 100 Hz und 33 Hz besitzen. Die letztgenannte Abtastfrequenz stellt hier die niedrigste betrachtete Abtastfrequenz dar und beruht auf den Untersuchungen von ZIEGENBEIN [ZIEG20], welche eine Klassifikation von i.O. und n.i.O. Bohrungsdurchmessern auf der Basis von erfassten Fertigungsdaten mit einer Abtastfrequenz von 33 Hz erzielt (siehe Kapitel 2.5). Der zweite Untersuchungspunkt in diesem Kapitel beschäftigt sich mit dem Einfluss der Merkmale aus dem Zeit- und Frequenzbereich sowie der Kombination der beiden Merkmalsgruppen auf das Prognoseergebnis. Ziel ist es, die Abtastfrequenz und die Merkmalsgruppe zu bestimmen, welche den Prognosefehler minimieren und gleichzeitig die Datenmenge niedrig halten.

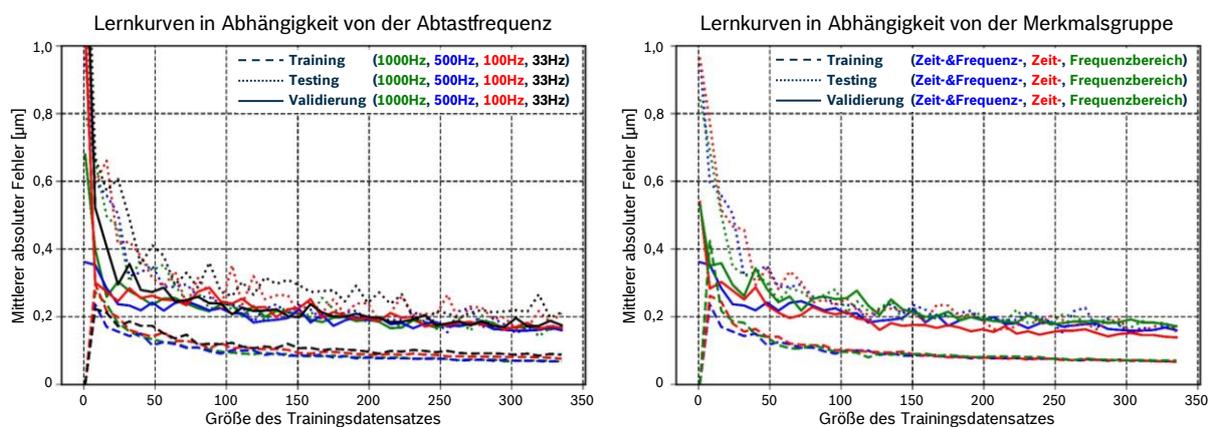


Abbildung 5-31: Lernkurven für die Prognose des Durchmessers in Abhängigkeit von der Abtastfrequenz und der Merkmalsgruppe

Im linken Diagramm der Abbildung 5-31 sind die Verläufe der Lernkurven (Training, Testing und Validierung) für die vier verschiedenen Abtastfrequenz aufgezeigt. Es ist zu erkennen, dass der Prognosefehler mit einer Abnahme der Abtastfrequenz auf 100 Hz und 33 Hz sowohl für das Training, Testing als auch für das Validieren minimal ansteigt. Für eine Abtastfrequenz von 500 Hz ist der Prognosefehler jedoch gleich dem Fehler, der auch bei der ursprünglichen Abtastfrequenz von 1.000 Hz erreicht wird. Die Abtastfrequenz hat demnach eine nur geringe Bedeutung für die Durchmesserprognose. Für das weitere Vorgehen wird eine Frequenz von 500 Hz beibehalten. Für die auf 500 Hz gesampelten Fertigungsdaten werden die Merkmale aus dem Zeit- und Frequenzbereich berechnet und die Methode GBR mit jeder Merkmalsgruppe sowie mit der Kombination von beiden Merkmalsgruppen trainiert. Die Auswirkungen auf den Prognosefehler sind in dem rechten Diagramm der Abbildung 5-31 aufgeführt. Demnach ist kein Unterschied der eingesetzten Merkmalsgruppen bei den Prognosefehlern für das Training und Testing zu erkennen. Lediglich bei der Validierung erzielen die Merkmale rein aus dem Zeitbereich ein etwas besseres Ergebnis, als wenn sie in Kombination mit den Merkmalen aus dem Frequenzbereich für die Prognoseerstellung genutzt werden. Somit sind die Merkmale aus dem Zeitbereich für die Durchmesserprognose ausreichend.

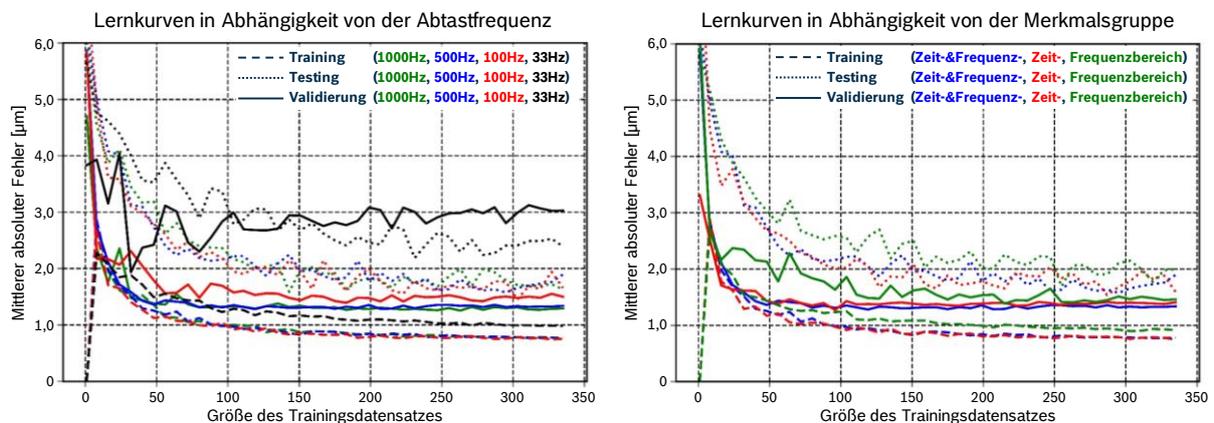


Abbildung 5-32: Lernkurven für die Prognose der Konzentrität in Abhängigkeit von der Abtastfrequenz und der Merkmalsgruppe

Die Prognose der Konzentrität reagiert deutlich differenzierter auf eine reduzierte Abtastfrequenz, als es für den Durchmesser der Fall ist (siehe Abbildung 5-32). Für die Frequenzen 1.000 Hz, 500 Hz und 100 Hz ist kein Unterschied des Prognosefehlers für das Training und Testing festzustellen. Der Prognosefehler für den Validierungsdatensatz steigt hingegen bei einer Abtastfrequenz von 100 Hz merklich an. Am deutlichsten äußert sich der Anstieg des Prognosefehlers, wenn die Fertigungsdaten lediglich mit einer Frequenz von 33 Hz erfasst werden. Der Fehler für das Training und Testing steigt deutlich an, besitzt jedoch nach einer ausreichenden Menge an Trainingsdaten immer noch eine Konvergenz zu einem Wert. Für den Prognosefehler des Validierungsdatensatzes tritt hingegen keine eindeutige Konvergenz ein.

Der erreichte Prognosefehler von ca. 3 μm ist im Vergleich zum Status quo (1.000 Hz oder 500 Hz) mehr als doppelt so hoch. Die Verläufe der Lernkurven für eine Abtastfrequenz von 33 Hz lassen darauf schließen, dass der GBR in der Lage ist, von den Fertigungsdaten einen gewissen Zusammenhang zu erlernen, jedoch ein deutlicher Informationsverlust mit der niedrigen Abtastfrequenz verbunden ist, der zu einem Anstieg des Prognosefehlers (Training und Testing) führt. Eine Übertragbarkeit der erlernten Zusammenhänge auf unbekannte Daten (Validierungsdatensatz) ist hingegen nicht mehr mit der zuvor gewohnten Präzision möglich und führt zu keiner klaren Konvergenz des Prognosefehlers. Hieraus ist zu folgern, dass die Abtastfrequenz einen großen Einfluss auf die Prognosegenauigkeit der Konzentrität hat und in dem hier betrachteten Fall mindestens 500 Hz betragen sollte. Die Lernkurven für die Bewertung des Einflusses der Merkmalsgruppen wurden auf der Basis von Fertigungsdaten mit einer Abtastfrequenz von 500 Hz erstellt. Es tritt hervor, dass die Merkmale aus dem Frequenzbereich stets zu einem höheren Prognosefehler führen, als wenn sie in Kombination mit den Merkmalen aus dem Zeitbereich für die Prognose genutzt werden. Die Kombination der Merkmale erreicht für den Validierungsdatensatz einen etwas niedrigeren Prognosefehler als bei der ausschließlichen Verwendung der Merkmale aus dem Zeitbereich. Demzufolge werden die Merkmale aus dem Zeit- und Frequenzbereich für die Prognose der Konzentrität verwendet.

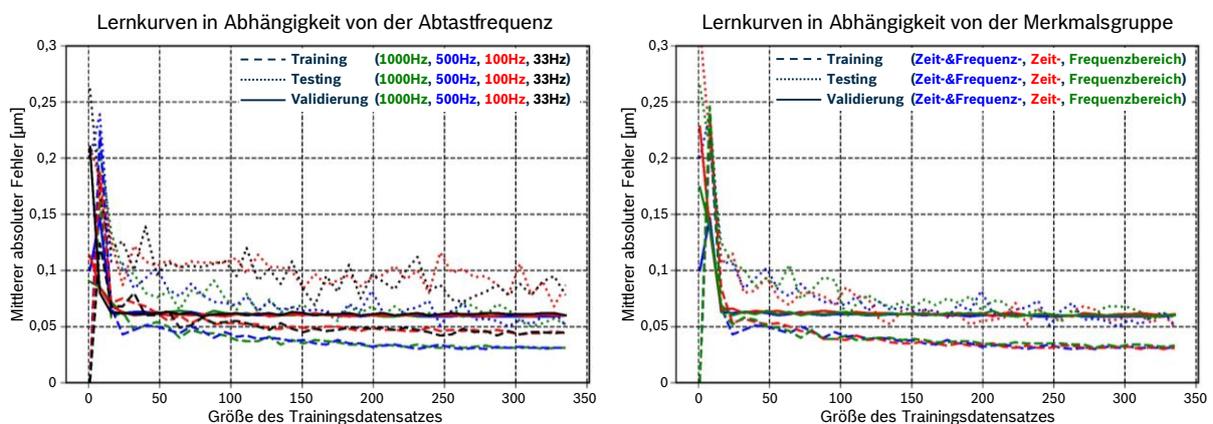


Abbildung 5-33: Lernkurven für die Prognose der Geradheit in Abhängigkeit von der Abtastfrequenz und der Merkmalsgruppe

Die Abtastfrequenzen 100 Hz und 33 Hz treten aufgrund eines deutlich höheren Prognosefehlers für den Trainings- und Testdatensatz bei der Geradheitsprognose hervor (siehe Abbildung 5-33). Nur für die Abtastfrequenzen 1.000 Hz und 500 Hz können die zuvor bestimmten niedrigen Prognosefehler erreicht werden, sodass für die Qualitätsprognose eine Abtastfrequenz von 500 Hz ausreichend ist. Der Validierungsfehler verläuft hingegen erneut konstant und schwankungsfrei. Ein möglicher Grund für den konstanten Verlauf ist die sehr niedrige Streuung der Geradheitsmessungen des Validierungsdatensatzes sowie seine Lage in dem Gipfel der Verteilungsfunktion aller Messwerte, sodass nur der Anschein entsteht, unabhängig von

der Abtastfrequenz zu sein. Unabhängig von der verwendeten Merkmalsgruppe sind die Verläufe der Lernkurven und die Prognosefehler für die drei Datensätze (Training, Testing, Validierung) identisch. Demnach kann der GBR sowohl rein aus den Merkmalen aus dem Zeitbereich als auch rein aus den Merkmalen aus dem Frequenzbereich sowie aus der Kombination der beiden Merkmalsgruppen genügend Informationen gewinnen, um eine gleichwertige Prognosegenauigkeit zu erzielen. Aufgrund dieses Sachverhaltes wird die Kombination von den Merkmalen aus dem Zeit- und Frequenzbereich für die Geradheitsprognose verwendet.

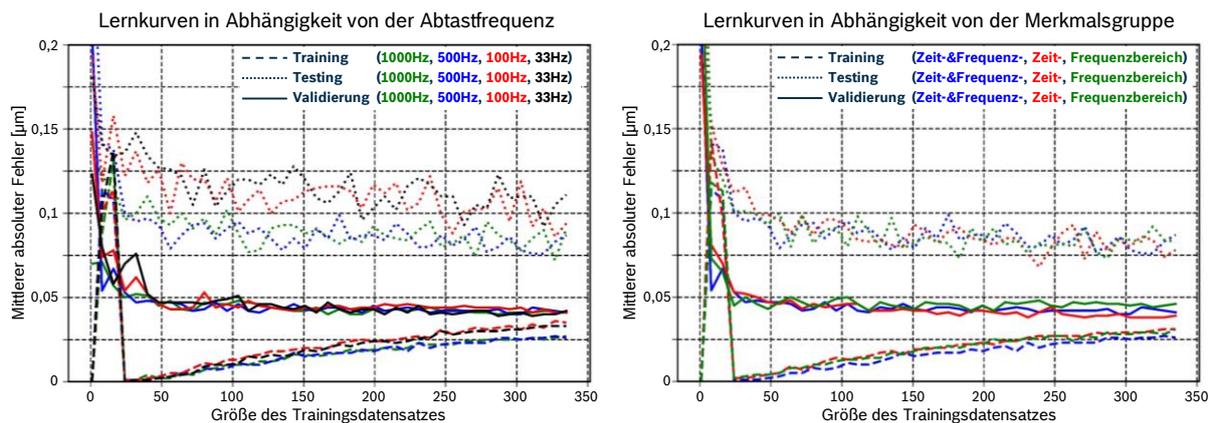


Abbildung 5-34: Lernkurven für die Prognose der Rundheit in Abhängigkeit von der Abtastfrequenz und der Merkmalsgruppe

Für die Prognose der Rundheit in Abbildung 5-34 spielt die Abtastfrequenz eine entscheidende Rolle für die Größe des Prognosefehlers bei dem Training und Testing. Die Prognosefehler, die mit 100 Hz und 33 Hz Abtastfrequenz erreicht werden, liegen sehr dicht beieinander und sind eindeutig größer als die Fehler für eine Abtastfrequenz von 1.000 Hz oder 500 Hz. Der Prognosefehler für den Validierungsdatensatz ist für alle vier Abtastfrequenzen gleich groß. Dies mag vor allem an der Verteilung des Validierungsdatensatzes und seiner Lage im Gipfel der Verteilungsfunktion aller Rundheitsmesswerte liegen. Demnach stehen dem RFR ausreichend Trainingsdaten zu dem Wertebereich des Validierungsdatensatzes zur Verfügung, um die Zusammenhänge, unabhängig von der Abtastfrequenz, zu erlernen. Aufgrund der identischen Größen der Prognosefehler für die Abtastfrequenzen 1.000 Hz und 500 Hz fällt die Wahl auf die niedrigere Abtastfrequenz. Die Merkmale aus dem Zeit- und Frequenzbereich werden von den Fertigungsdaten bestimmt, welche eine Abtastfrequenz von 500 Hz aufweisen. Im rechten Diagramm der Abbildung 5-34 ist der Einfluss der Merkmalsgruppe auf den Prognosefehler dargestellt. Für das Training werden minimal niedrigere Prognosefehler erzielt, wenn die Kombination der Merkmalsgruppen genutzt wird. Kein eindeutiger Unterschied zwischen den erreichten Prognosefehlern mit den einzelnen Merkmalsgruppen ist hingegen für das Testing festzustellen. Für die Validierung weist der Prognosefehler basierend auf den Merkmalen aus dem Zeitbereich den durchgehend niedrigsten Wert auf, jedoch ist der Prognose-

sefehler, welcher von der Kombination der Merkmalsgruppen ausgeht, nahezu identisch. Es ergibt sich kein eindeutiges Bild, ob rein die Merkmale aus dem Zeitbereich oder die Kombination von Merkmalen aus dem Zeit- und Frequenzbereich zu bevorzugen ist. Die Wahl fällt schließlich auf die Kombination der Merkmale aufgrund des etwas niedrigeren Fehlers beim Training.

5.5.4 Bestimmung der notwendigen Trainingsdatenmenge

In den zuvor betrachteten Lernkurven erfolgte stets die Abbildung der Prognosefehler in Abhängigkeit von der verwendeten Datenmenge für das Trainieren der Methode. Im Idealfall konvergieren die Prognosefehler gegen niedrige Werte bei einer möglichst kleinen Anzahl von Trainingsdaten. Der Grad der Konvergenz ist jedoch davon abhängig, ob in den zum Training verwendeten Merkmalen ausreichend Informationen enthalten sind, mit denen die Methode des maschinellen Lernens die Zusammenhänge zwischen den Eingangsdaten (Merkmalen) und der Zielgröße erkennen und erlernen kann. Der Informationsgehalt ist von vielen Einflussgrößen abhängig, wie z. B. Datenquelle, Erfassungsfrequenz, Merkmalsgruppe etc. Ob der Informationsgehalt oder die Trainingsdatenmenge für den jeweiligen Anwendungsfall ausreichend ist, hängt auch von dem gesetzten Grenzwert für den Testingfehler ab, welcher unterschritten werden muss, um die Anforderungen hinsichtlich der Prognosegenauigkeit zu erfüllen. Eine Möglichkeit zur Bewertung, ob eine Methode noch am Lernen ist oder mit dem Lernprozess bereits abgeschlossen hat, besteht in der Analyse der Steigung ihrer Trainingskurve. Solange die Trainingskurve eine Steigung ungleich null aufweist, ist der Lernprozess (die Konvergenz) noch nicht abgeschlossen. Die Steigung einer Kurve ergibt sich durch die mathematische Ableitung ihrer Funktion. Zu den hier vorliegenden Trainingskurven ist jedoch die mathematische Funktion nicht bekannt. Die mathematische Ableitung in einem Punkt stellt den Zahlenwert des Differenzialquotienten in dem jeweiligen Punkt dar. Der Differenzialquotient in einem Punkt der Kurve wird in dieser Arbeit näherungsweise mit der Formel 5.1 auf der Basis der bekannten Kurvenwerte berechnet. Um den Trend der Steigung deutlicher zu erkennen sowie einen geglätteten Kurvenverlauf zu erhalten, werden jeweils die Mittelwerte der Prognosefehler y über ein Intervall der Breite n bestimmt. Dieses Intervall erstreckt sich jeweils in positive sowie negative Richtung, ausgehend vom Wert t , welcher die Anzahl der Trainingsdaten angibt, für die die Steigung bestimmt werden soll. Wird bei der Berechnung der ursprünglichen Trainingskurve eine Schrittweite von eins bei dem Trainingsdatensatz verwendet, so reduziert sich der Nenner von Formel 5.1 auf n , anderenfalls steht x für die jeweilige Anzahl von Trainingsdaten.

$$Steigung(t) = \frac{\delta y}{\delta x} = \frac{\frac{\sum_{i=t}^{t+n} y_i}{n+1} - \frac{\sum_{j=t}^{t-n} y_j}{n+1}}{\frac{\sum_{i=t}^{t+n} x_i}{n+1} - \frac{\sum_{j=t}^{t-n} x_j}{n+1}} \stackrel{Schrittweite=1}{\cong} \frac{\frac{\sum_{i=t}^{t+n} y_i}{n+1} - \frac{\sum_{j=t}^{t-n} y_j}{n+1}}{n} \quad 5.1$$

Analog zur Berechnung der Steigung der Trainingskurve kann die Generalisierbarkeit der trainierten Methode anhand des Verlaufes der Testingkurve sowie der Größe des Prognosefehlers bewertet werden. Um den Einfluss der Anzahl von Trainingsdaten auf den Trend der Testingkurve zu bewerten, wird diese aus den ursprünglichen Werten in geglätteter Form dargestellt. Hierfür wird die Formel 5.2 verwendet, welche einen zentrierten gleitenden Mittelwert berechnet. Die Berechnung erfolgt für jeden Prognosefehler y des Testings in Abhängigkeit von der für das Training verwendeten Trainingsdaten t . Die Stärke der Glättung hängt von der Wahl der durch die Daten gleitenden „Fensterweite“ f ab und steigt mit ihrem Wert. Der Wert für f sollte dabei ungeradzahlig sein.

$$\text{Zentrierter gleitender Mittelwert}(t) = \frac{1}{f} \sum_{i=t-\frac{f-1}{2}}^{t+\frac{f-1}{2}} y_i \quad 5.2$$

Die Abbildung 5-35 visualisiert die Verläufe der Prognosefehler für das Training und das Testing mit der zuvor bestimmten Methode des maschinellen Lernens für jedes Qualitätsmerkmal. Für die Erstellung wurde der Verlauf der ursprünglichen Prognosewerte mittels der Formel 5.2 mit $f = 5$ geglättet und anschließend eine Normierung zwischen null und eins durchgeführt. Hierdurch ist es möglich, die Kurven der vier verschiedenen Qualitätsmerkmale in einem Diagramm darzustellen und eine bessere Beurteilung des Verlaufes in Abhängigkeit von der Trainingsdatenmenge zu erreichen. Die beiden Diagramme dienen jedoch vielmehr als Unterstützung für die aus der Abbildung 5-36 abgeleiteten Erkenntnisse. An dieser Stelle zeichnet es sich jedoch bereits ab, dass eine solide Prognosegenauigkeit bei einem Training mit ca. 300 Daten erzielt werden kann. Dies ist anhand der sich andeutenden Konvergenz der Trainings- und Testingkurven im Bereich um die 300 Trainingsdaten ersichtlich.

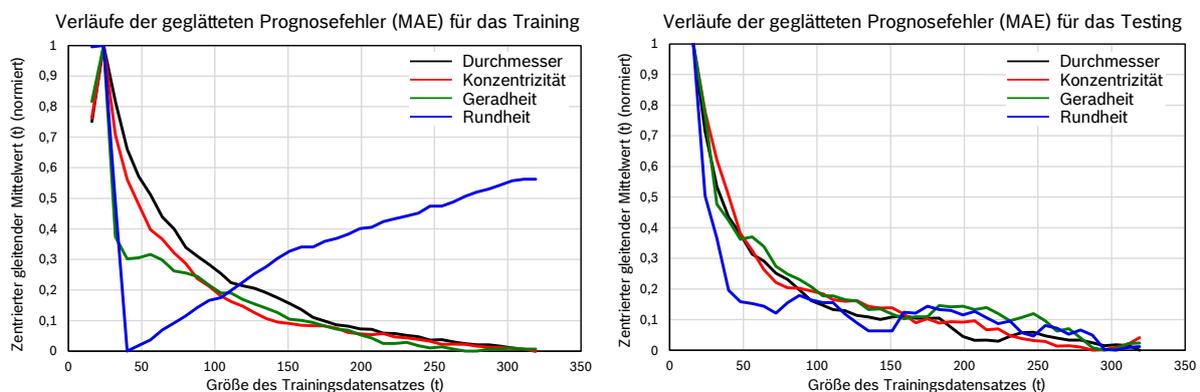


Abbildung 5-35: Verläufe der Prognosefehler (MAE) des Trainings und Testings nach der Kurvenglättung mittels zentrierten gleitenden Mittelwertes und anschließender Normierung

In Abbildung 5-36 ist in dem linken Diagramm der Verlauf der Steigungen der Trainingskurven und im rechten Diagramm die Differenz aus Testing- und Trainingsfehler jeweils für die vier verschiedenen Qualitätsmerkmale dargestellt. Vor der Berechnung der Steigungen wurde eine Normierung der Trainings- und Testkurvenwerte vollzogen, um eine Vergleichbarkeit in einem Diagramm zu ermöglichen und eine eventuelle Systematik besser zu erkennen. Für die Darstellung der Differenzen der Prognosefehler wurde zuerst eine Glättung der ursprünglichen Prognosewerte durchgeführt, gefolgt von der Berechnung der Differenzen und der finalen Normierung der Ergebnisse zwischen null und eins. Für die Berechnung der Steigung wurde n zu vier gesetzt bei einer bestehenden Schrittweite von acht und für die Berechnung der zentrierten Mittelwerte (Glättung) wurde für die Fensterweite f der Wert fünf gewählt. Die Wahl dieser Werte wurde iterativ bestimmt und sie führen zu einer eindeutigen Darstellung der Trendverläufe bei einer gleichzeitigen Bewahrung eines sinnvollen Detaillierungsgrades. Da die ersten sowie die letzten Werte der Ausgangsdaten den Berechnungen zum Opfer fallen, sind die resultierenden Kurven etwas gekürzt.

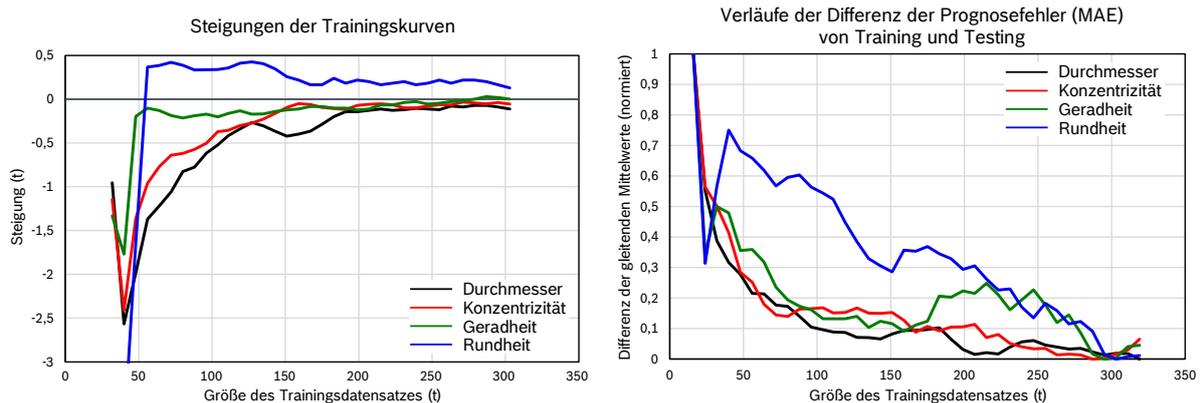


Abbildung 5-36: Steigung der Trainingskurven ausgehend von normierten Prognosefehlern des Trainings und Differenz zwischen den Prognosefehlern des Trainings und Testings in normierter Darstellung

In dem linken Diagramm der Abbildung 5-36 ist die Steigung der Trainingskurven, welche in Abbildung 5-35 in geglätteter und normierter Form und in Kapitel 5.5.3 in der ursprünglichen Form dargestellt wurden, für jedes Qualitätsmerkmal abgebildet. Eine Steigung von null bedeutet, dass die Trainingskurve horizontal verläuft und somit konvergiert ist. Die Hinzugabe von weiteren Trainingsdaten, um den Trainings- oder Testingfehler noch weiter zu reduzieren, ist in einem solchen Fall wenig erfolgversprechend, da die von der Methode erkennbaren Zusammenhänge bereits aufgedeckt, gelernt sowie abgebildet werden. Ändern sich die Umwelteinflüsse oder erfolgt eine Veränderung des Fertigungsprozesses, so bedarf es neuer, weiterer Trainingsdaten, um auch diese hinzugekommenen Abhängigkeiten zu erlernen. Wird mit der ausgelernten Methode jedoch ein Testingfehler erreicht, welcher die Genauigkeitsanforderungen nicht erfüllt, so tragen weitere Trainingsdaten nicht zur Lösung des Problems bei. Vielmehr hat eine Auswahl einer anderen Methode des maschinellen

Lernens oder die Erfassung von anderweitigen Fertigungsdaten bzw. Merkmalen zu erfolgen. In dem linken Diagramm wird nur für die Geradheit mit der Methode GBR ein Trainingszustand nach ca. 290 bis 300 Trainingsdaten erreicht, welcher eine Steigung der Trainingskurve von null aufweist. Für alle anderen Qualitätsmerkmale ist das Training noch nicht abgeschlossen und eine Hinzugabe von weiteren Trainingsdaten kann einen weiteren Beitrag zum Lernen liefern. Der Verlauf der Steigungen der einzelnen Qualitätsmerkmale ist sehr verschieden. Die ersten 50 Trainingsdaten sind notwendig, um eine erste Stabilisierung („Einschwingen“) der Methode zu erreichen. Mit der Hinzugabe von weiteren Trainingsdaten tritt dann eine kontinuierlichere Abnahme der Steigung ein. Dieser Sachverhalt gilt für beide der hier verwendeten Methoden des maschinellen Lernens (GBR und RFR) sowie für alle vier Qualitätsmerkmale. Die Trainingskurve der Methode GBR nähert sich von oben kommend dem Konvergenzwert an (siehe Abbildung 5-35 oder Abbildung 5-31 bis Abbildung 5-33) und weist daher eine negative Steigung auf. Die Trainingskurve des RFR verhält sich genau umgekehrt (siehe Abbildung 5-35 oder Abbildung 5-29) und hat somit eine positive Steigung. Vom Erscheinungsbild her ähneln sich die Verläufe der Steigungen von Rundheit und Geradheit sowie von Durchmesser und Konzentrität. Für Rundheit und Geradheit ist anfänglich eine starke negative Steigung bis auf einen relativ niedrigen Steigungswert zu erkennen, von dem aus eine kontinuierliche Reduzierung der Steigung bis zum Erreichen einer Steigung (im Idealfall) von null einsetzt. Hieraus lässt sich ablesen, dass mit relativ wenigen Trainingsdaten ein starker Lernfortschritt erzielt werden kann, der sich jedoch nach der steilen Lernphase deutlich abschwächt und dass eine hohe Anzahl von Daten notwendig ist, um weiter zu lernen. Für den Durchmesser und die Konzentrität verläuft die anfängliche Lernphase weniger stark und es sind drei- bis viermal so viele Trainingsdaten (150 bis 200) im Vergleich zu der Geradheit notwendig, um ein Wert für die Steigung zu erreichen, der sich nahe der Null bewegt.

Das rechte Diagramm lässt einen Rückschluss auf die Generalisierbarkeit der trainierten Methoden zu, indem die Differenz aus Trainings- und Testingfehler aufgezeigt wird. Zu erwähnen ist, dass die Darstellung in normierter Form erfolgt und somit die Werte null und eins lediglich die Anzahl der Trainingsdaten angeben, für die die kleinste bzw. größte Differenz der Prognosefehler erzielt wurde. Die Werte der Prognosefehler können aus den Abbildung 5-31 bis Abbildung 5-34 entnommen werden. Ist die Differenz sehr groß (kleiner Trainingsfehler und großer Testingfehler), so ist ein Zustand eingetreten, bei dem die Methode sehr genau die Trainingsdaten erlernt hat / abbildet, aber nicht generisch genug ist, um das „Erlernte“ auf neue Daten anzuwenden. Anzustreben ist hingegen ein möglichst niedriger Trainingsfehler zusammen mit einem Testingfehler, welcher sehr nahe an dem Wert des Trainingsfehlers liegt. Hierdurch wird eine Methode mit einer hohen Generalisierbarkeit für den jeweiligen Anwendungsfall charakterisiert. Für die Rundheitsprognose existiert, im Vergleich zu den restlichen Qualitätsprognosen, eine außerordentlich große Differenz zwischen dem Trainings- und Testingfehler. Die Methode kann somit nur sehr schwach generalisieren bzw. hat in diesem Fall (mit Blick auf den Steigungswert ihrer

Trainingskurve im linken Diagramm) einen Großteil der Zusammenhänge in den Daten noch nicht in ausreichender Tiefe erlernen können. Die Differenz reduziert sich mit steigender Anzahl von Trainingsdaten. Dies gilt auch analog für die Prognose der drei anderen Qualitätsmerkmale. Für die Rundheit und den Durchmesser ist bei etwas mehr als 300 Trainingsdaten zwar die bis dahin niedrigste Differenz erreicht, jedoch lässt der Kurvenverlauf sowie die Steigungswerte ein weiteres Sinken der Differenz im Falle von weiteren Trainingsdaten vermuten. Für die Geradheit sowie die Konzentrität wird für 300 Trainingsdaten ebenfalls die niedrigste Differenz der Prognosewerte erreicht, jedoch zeichnet sich ein erneuter Anstieg des Differenzwertes für mehr als 300 Trainingsdaten an. Die Vergrößerung der Differenz ist auf konstant bleibende Trainingsfehler sowie ansteigende Testingfehler zurückzuführen (siehe Abbildung 5-35). Die Trainingskurve der Geradheitsprognose hat bereits eine Steigung von null und die Steigung der Trainingskurve der Konzentritätsprognose liegt nahe null, sodass ein Zustand eintreten könnte, der zu einem Übertrainieren der Methode durch zu viele Trainingsdaten führt und somit die Generalisierbarkeit abnimmt. Ob dies hier wirklich bereits eintritt, ist jedoch fraglich, da zuvor für die Geradheitsprognose auch ein deutlicher Anstieg der Differenzwerte für den Bereich von 180 bis 280 Trainingsdaten festzustellen ist, obwohl schließlich für 300 Trainingsdaten das Minimum erreicht wird. Gegen einen Trend mit nachhaltigem Anstieg spricht auch, dass lediglich ein Mehr von ca. 10 % an Trainingsdaten bereits ein Übertraining hervorrufen würde.

Festzuhalten ist, dass ein Trainingsdatensatz von ca. 300 Daten für die angestrebten Qualitätsprognosen in dem in dieser Arbeit betrachteten Anwendungsfall bereits zu sehr guten Prognosen führt. Zudem wird bei dieser Anzahl von Trainingsdaten ein Ende bzw. ein nahendes Ende des Trainings für die Geradheit, die Konzentrität und den Durchmesser erreicht. Potenzial besteht hingegen noch für die Rundheitsprognose, die eventuell mit mehr Trainingsdaten an Genauigkeit gewinnen kann. Es kann jedoch auch an fehlenden Informationen in den bereitgestellten Merkmalen liegen, die ein schnelleres Lernen bzw. eine genauere Prognose verhindern. Ein Grund ist z. B. die bereits zuvor erwähnte parallele Fertigung von zwei Ventilen, die nur die Erfassung des kombinierten Einflusses auf die Position der X- und Y-Achse ermöglicht.

Ein grundsätzliches Folgern, dass stets 300 Trainingsdaten ausreichend sind, um z. B. die Geradheit zu prognostizieren, ist etwas zu kurz gedacht, da die Anzahl lediglich eine von mehreren Stellgrößen darstellt. Weitere Stellgrößen sind in den Kapiteln 5.4 und 5.5 ausführlich betrachtet worden (z. B. Methode des maschinellen Lernens, Merkmalsgruppe, Selektionsverfahren, Datenquelle, Abtastfrequenz). Eine geeignete Kombination aus diesen Stellgrößen ist notwendig, um die in den Daten enthaltene Streuung zu bewältigen und eine Methode anzulernen, die für den speziellen Anwendungsfall und eine gewisse Breite an Messwerten (Messwertbreite, siehe Kapitel 5.3.2 und 5.6) an Gültigkeit besitzt.

5.5.5 Übersicht über die ermittelten Parameterkombinationen

Die Abbildung 5-37 zeigt die Zusammenfassung der in diesem Kapitel 5.5 ermittelten Parameterwerte. Mit dieser Kombination von Parameterwerten erfolgt die Validierung der Prognosegüte in dem Kapitel 5.6 sowie die anschließende Implementierung in die Fertigung. Jedes Qualitätsmerkmal hat seine individuelle Kombination von Parameterwerten, welche zu der genauesten Prognose führen. Für gewisse Parameter unterscheiden sich die erzielten Prognosewerte jedoch nur minimal, wenn ein anderer Parameterwert als der hier angegebene ausgewählt wird. Dies wurde bereits bei der Bestimmung der Parameterwerte deutlich. So sind die extrahierten Merkmale aus dem Zeitbereich für die Erzielung von genauen Prognosen ausreichend und die Hinzunahme von Merkmalen aus dem Frequenzbereich führt nur zu einer minimalen Prognoseverbesserung. Dies gilt in ähnlicher Form für die Parameter Selektionsverfahren (Transinformation oder Pearson Korrelation) und die Methode des maschinellen Lernens (GBR oder RFR). Ein Abweichen von den angegebenen Werten für die Parameter: Anzahl der Trainingsdaten, Abtastfrequenz und Datenquellen, führt hingegen zu einer niedrigeren Prognosegenauigkeit.

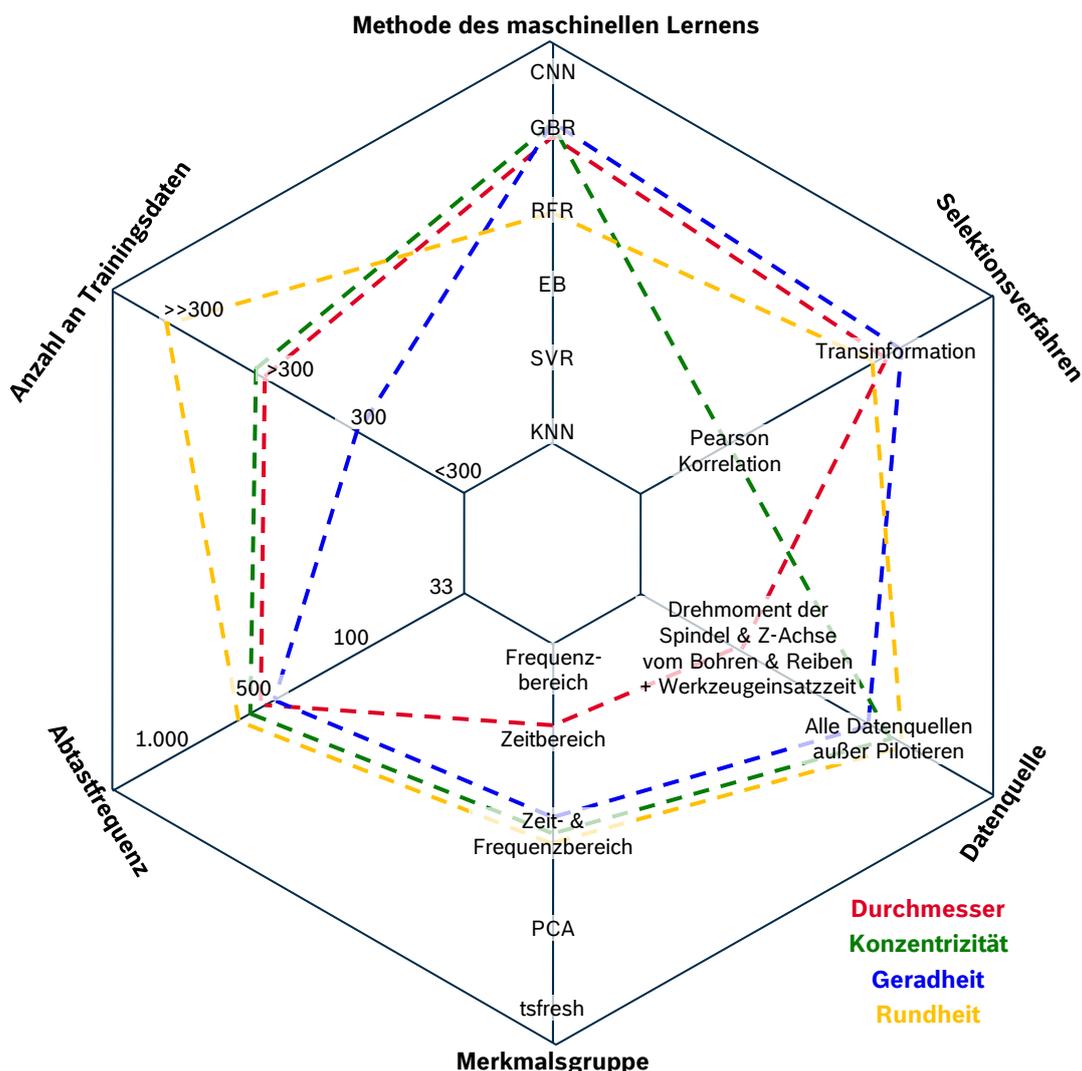


Abbildung 5-37: Ermittelte Parameterkombinationen zur Erzielung der besten Qualitätsprognosen

5.6 Validierung der Prognosegüte

Die Validierung der erzielten Prognosen wird auf zwei Arten durchgeführt. Zum einen werden von den Prognoseergebnissen die in Kapitel 2.4.5 eingeführten Kennzahlen berechnet, die üblich für die Bewertung der Prognosegüte von maschinellen Lernverfahren sind. Zum anderen werden die in der Fertigungsmesstechnik eingesetzten Verfahren zum Nachweis der Eignung eines Messmittels angewandt (siehe Kapitel 2.2.2). Die in Kapitel 2.5.1 vorgestellten Ansätze für die Integration von maschinellem Lernen in das Qualitätsmanagement werden hierbei berücksichtigt.

5.6.1 Validierung mittels Kennzahlen

In Kapitel 2.4.5 werden Kennzahlen beschrieben, die für die Bewertung bzw. Validierung von Prognosen häufig herangezogen werden. Sie eignen sich somit auch für die Validierung der Prognoseergebnisse, die mit den Methoden des maschinellen Lernens erzielt werden. Die verwendeten Kennzahlen MAE, MAX und R^2 werden bereits in den vorherigen Kapiteln genutzt, um unter anderem die besten Methoden und die notwendigen Datenquellen zu bestimmen. Sie werden hier erneut aufgegriffen, um die Prognosegüte des final konfigurierten Prognosemodells eines jeden Qualitätsmerkmals zu validieren. Die Kennzahlen werden zudem noch in Relation zu der Toleranz sowie der Messwertbreite eines jeden Qualitätsmerkmals gesetzt. Hierdurch lässt sich eine Art „Sicherheitsfaktor“ bestimmen, um abzuschätzen, ob eine Bohrung noch innerhalb der Toleranzgrenzen des jeweiligen Qualitätsmerkmals liegt und wie groß die Streuung der Prognosewerte ist. Zusätzlich erfolgt eine grafische Darstellung der Prognoseergebnisse in der Form von Verteilungskurven und Histogrammen sowie individuell für jede Bohrung (Ventil).

Die Verteilungen der Prognoseergebnisse sowie die berechneten Kennzahlen sind in der Abbildung 5-38 für die Durchmesserprognose dargestellt. In jedem der aufgeführten Diagramme wird die Verteilungskurve und die Histogramme von dem Datensatz, mit dem das Training durchgeführt wird, in der Farbe Blau dargestellt. Die Verteilungskurven der Daten, die für das Testing bzw. für die Validierung verwendet werden, werden in grün abgebildet und die Verteilungen, die die Prognosen widerspiegeln, erhalten die Farbe Rot. Die Durchmesserwerte folgen ursprünglich einer Normalverteilung, jedoch weist der hier eingesetzte Trainingsdatensatz zwei Gipfel auf. Diese Verteilung tritt per Zufall ein, da der Validierungsdatensatz, der die Durchmesserwerte zwischen den zwei Gipfeln hauptsächlich beinhaltet, aus der Grundgesamtheit der Durchmesserwerte für die Validierung entnommen wurde. Die Form der Verteilung des Testdatensatzes ist identisch zu der Verteilungsform des Trainingsdatensatzes, da der Testdatensatz durch zufälliges Ziehen aus dem Trainingsdatensatz gewonnen wird. Die Verteilung des Validierungsdatensatzes nimmt dagegen eher die Gestalt einer Normalverteilung an. Die roten Histogramme und Verteilungskurven stellen die für die Test- bzw. Validierungsdaten erhaltenen Prognosen dar. Es ist zu erkennen, dass die prognostizierten Durchmesser den Wertebereich des Test- bzw. Validierungsdatensatzes nicht überschreiten. Das Training erfolgt mit den Daten, die

die blaue Verteilungskurve repräsentieren, jedoch liegen die Prognosen nur innerhalb des Durchmesserbereiches der grünen Kurve. Dies ist insbesondere für den Validierungsdatensatz als sehr positiv zu werten, da die trainierte Methode auf der Basis der Fertigungsmerkmale den tatsächlich zugehörigen Durchmesserwert (Wertebereich) korrekt bestimmt und ausgibt. Durch die auftretende minimale Zentrierung der Durchmesserwerte innerhalb des Wertebereiches des Test- bzw. Validierungsdatensatzes steigt die Dichteverteilung der Prognosen gegenüber dem tatsächlichen Wert etwas an.

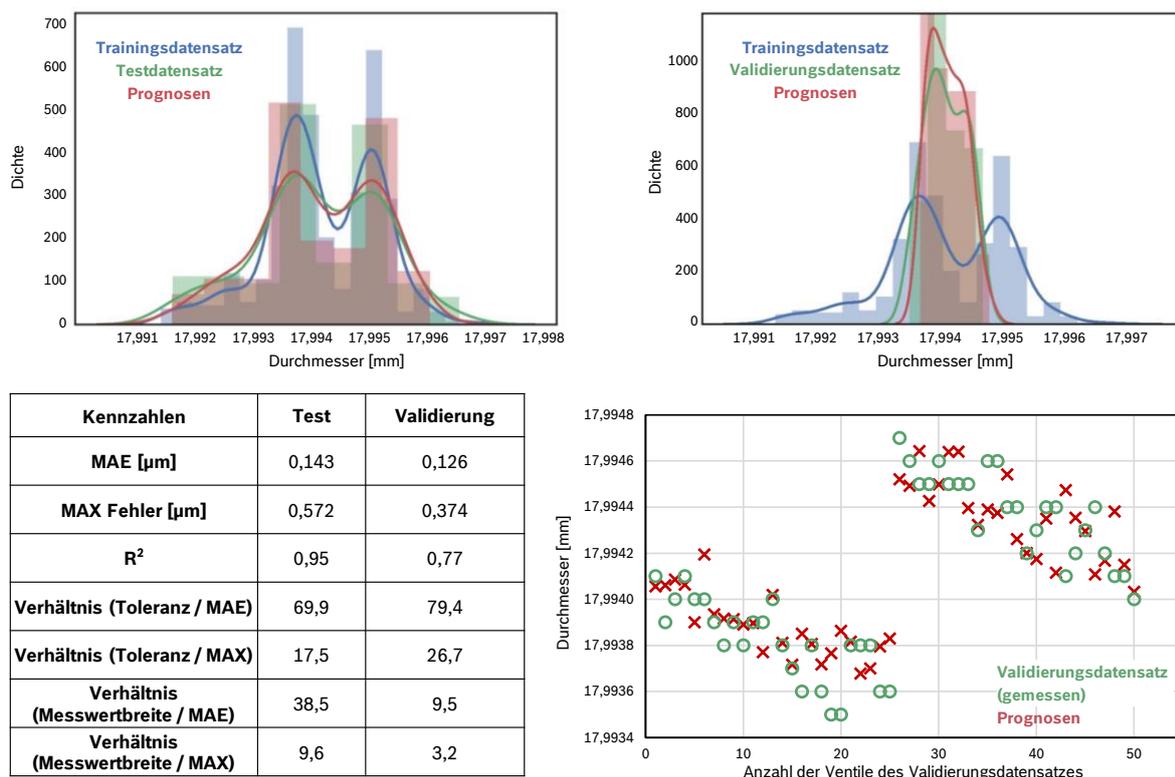


Abbildung 5-38: Ergebnisse der Durchmesserprognose für den Test- und Validierungsdatensatz

Im rechten unteren Diagramm sind die zu jeder Bohrung (Ventilgehäuse) individuell gehörenden Durchmessermessungen (grün) und die Prognosen (rot) dargestellt. Die ersten 25 Bohrungen wurden mit der ersten Spindel und die Bohrungen 26 bis 50 mit der zweiten Spindel gefertigt. Es ist eindeutig zu erkennen, dass der GBR den Trend einer Durchmesserreduktion mit der steigenden Anzahl von gefertigten Bohrungen, aufgrund des fortschreitenden Werkzeugverschleißes, erkennt und abbildet. Zudem werden die verschiedenen Durchmesserbereiche der beiden Spindeln richtig identifiziert. Die Prognosen zu den einzelnen Bohrungen sind von hoher Genauigkeit geprägt, sodass die maximal auftretende Abweichung lediglich 0,374 μm und die mittlere absolute Abweichung 0,126 μm beträgt. Werden diese Werte in Relation zu der Toleranz gesetzt, so zeigt sich, dass der MAE 79-mal und der MAX 26-mal kleiner als die Toleranz ist. Somit kann auf der Basis der Prognosewerte mit hoher Sicherheit (Sicherheitsfaktor) gesagt werden, ob eine Bohrung noch innerhalb der geforder-

ten Toleranz ist oder nicht mehr. Auch in Bezug auf die Messwertbreite, die sich in diesem Fall aus der Differenz des größten und des kleinsten gemessenen Durchmessers des Validierungsdatensatzes ergibt, nehmen die Prognosefehler nur einen niedrigen Bruchteil der Bandbreite ein. Das Bestimmtheitsmaß R^2 ist mit 77 % nicht ideal, jedoch vertretbar. Es zeigt auf, dass 77 % der in den Durchmesser messungen enthaltenen Varianz durch das Prognosemodell erklärt wird. Für den Testdatensatz beträgt R^2 95 % und zeigt mit diesem hohen Wert auf, dass ein Großteil der Varianz grundsätzlich erklärt werden kann. Der Wert von R^2 für den Validierungsdatensatz lässt sich eventuell durch eine größere Anzahl von Trainingsdaten in dem entsprechenden Durchmesserbereich erhöhen. Grundsätzlich lässt sich festhalten, dass der Durchmesser mit den erfassten Fertigungsmerkmalen sehr gut prognostiziert werden kann. Eine nahezu individuelle Prognose ist möglich, da hauptsächlich die Merkmale der Spindel und der Z-Achse für die Prognose relevant sind und diese auch bei der parallelen Bearbeitung mit zwei Spindeln einer Bohrung individuell zugeordnet werden können.

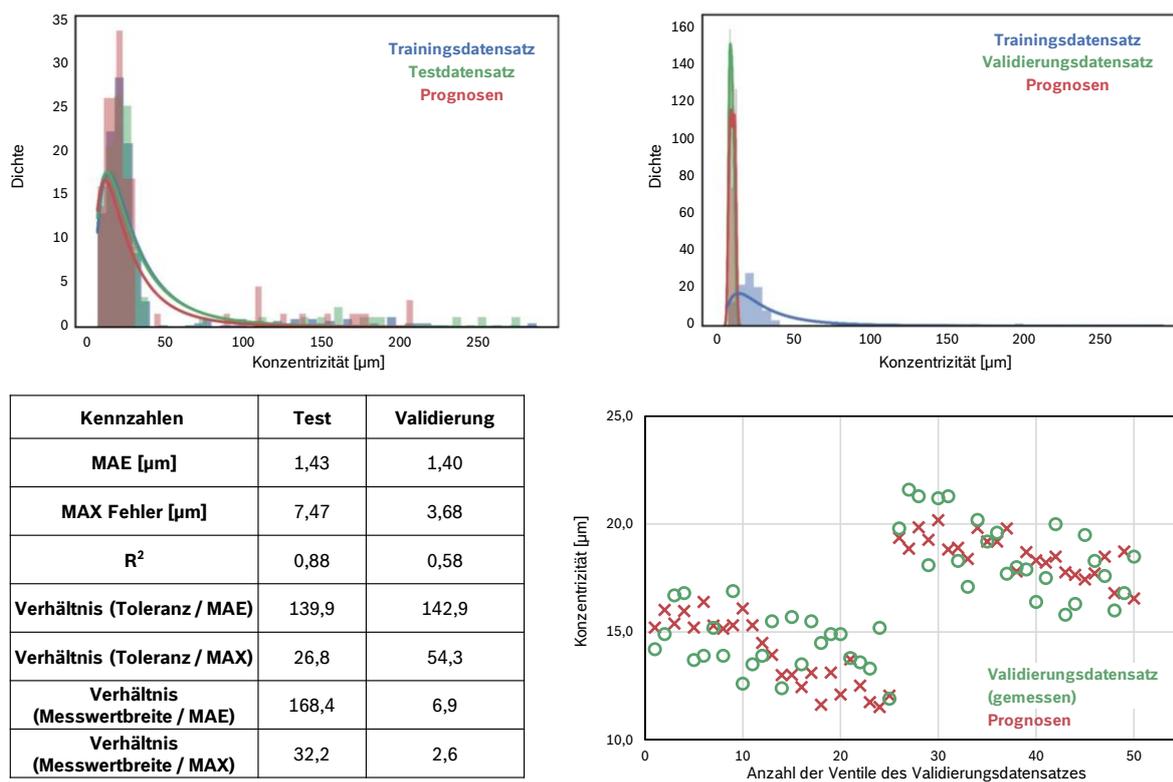


Abbildung 5-39: Ergebnisse der Konzentritätsprognose für den Test- und Validierungsdatensatz

Die Ergebnisse der Konzentritätsprognose sind in Abbildung 5-39 abgebildet. Die Konzentrität ist ein Qualitätsmerkmal, dessen natürliche Toleranzgrenze bei null liegt. Folglich können keine negativen Konzentritätswerte existieren und eine Log-Normalverteilung wurde als Verteilungsfunktion für den Trainings- und Testdatensatz sowie die erhaltenen Prognosen vom Testdatensatz gewählt. Der Validierungsdatensatz und die zugehörigen Prognosen werden durch eine Normalverteilung am besten

beschrieben. Die Verteilungsfunktionen (Dichtekurven) haben keine direkte Bedeutung für das Training oder das Prognostizieren, sondern dienen lediglich für die bessere Visualisierung. Die Verwendung von Histogrammen würde ebenso genügen, um die Verteilung der verschiedenen Datensätze und Prognosen zu visualisieren. Die Konzentritätswerte des Trainingsdatensatzes erstrecken sich über einen Wertebereich, der größer ist als die Toleranz von 200 μm . Die meisten Konzentritätswerte befinden sich jedoch in der Nähe der natürlichen Toleranzgrenze von null. Somit verfügt die Methode des maschinellen Lernens über ausreichend Trainingsdaten zu diesem Wertebereich der Konzentrität. Die Konzentritätswerte jenseits der Nähe zur Null werden bei dem Training jedoch trotzdem berücksichtigt, um zum Ersten auch die Prognose von Ausreißern zu ermöglichen und zum Zweiten die Wirkung eines heterogenen Trainingssatzes auf die Validierung zu bewerten. Im Gegensatz zum Trainingsdatensatz weist der Validierungsdatensatz ausschließlich Konzentritätswerte in der Nähe zur Null auf. Die Dichtekurven der Prognosen für den Test- als auch für den Validierungsdatensatz sind immer unterhalb der Dichtekurven der wahren Konzentritätswerte. Die Prognosen erstrecken sich somit über den kompletten Wertebereich der zugrundeliegenden bzw. wahren Messwerte. Eine Streuung der Prognosen über diesen Wertebereich hinaus findet nicht statt, sodass die große Breite der im Trainingsdatensatz enthaltenen Konzentritätswerte keinen negativen Einfluss auf die Prognoseerstellung hat. Aus dem Diagramm in Abbildung 5-39 (rechts unten), welches die einzelnen Konzentritätswerte abbildet, ist zu entnehmen, dass die Prognosen den einzelnen Spindeln eindeutig zuordenbar sind und auch der vorhandene Trend von dem GBR richtig prognostiziert wird. Ein MAE von 1,4 μm und ein MAX von 3,68 μm sind im Vergleich zu einer Toleranzbreite von 200 μm ausreichend klein, um mit einer hohen Sicherheit die Einhaltung der Toleranz auf der Basis der Prognosen zuzusichern. Werden diese Werte in Verhältnis zu der Messwertbreite gesetzt, so wird deutlich, dass ein größerer Anteil der Messwertbreite von den Prognosefehlern in Anspruch genommen wird (im Vergleich zu der Durchmesserprognose), dies lässt einen Rückschluss auf eine sinkende Prognosegenauigkeit je Bohrung zu. Dieser Sachverhalt spiegelt sich auch in dem Wert des R^2 von nur 58 % wieder. Für das Testing beträgt R^2 noch 88 % und deutet damit darauf hin, dass auch zu einer individuellen Bohrung präzise Prognosen erzielt werden. Der GBR erhält durch das Training ausreichend Informationen, um gute Prognosen für den aus dem Trainingsdatensatz gewonnenen Testdatensatz abgeben zu können. Ein Transfer der erkannten Zusammenhänge auf unbekannte Daten stellt sich jedoch als schwierig dar, sodass R^2 sinkt. Grundsätzlich scheinen dem GBR für eine generalisierbare und präzisere Konzentritätsprognose noch weitere Informationen zu fehlen. Die in den vorherigen Kapiteln durchgeführten Untersuchungen zeigen, dass alle Achsen für die Prognose der Konzentrität berücksichtigt werden müssen. Die Berücksichtigung der Positionswerte der X- und Y-Achse ist aufgrund der Bauweise der Maschine und der parallelen Bearbeitung nicht einer Bohrung (Spindel) ausschließlich zuordenbar. Die Positionsschwankungen sind das Ergebnis von Wechselwirkungen der parallelen Bearbeitung und sind auch nicht auf die Spindel (bzw. Werkzeug) mit der größten Unwucht zurückzuführen. Folglich stehen notwendige Informationen nicht

zur Verfügung. Die Drehmomente der Spindel und der Z-Achse dominieren die Konzentritätsprognose, sodass noch gute individuelle Prognosen erreicht werden. Für die Prognose der Rundheit und der Geradheit gilt dies hingegen nicht mehr.

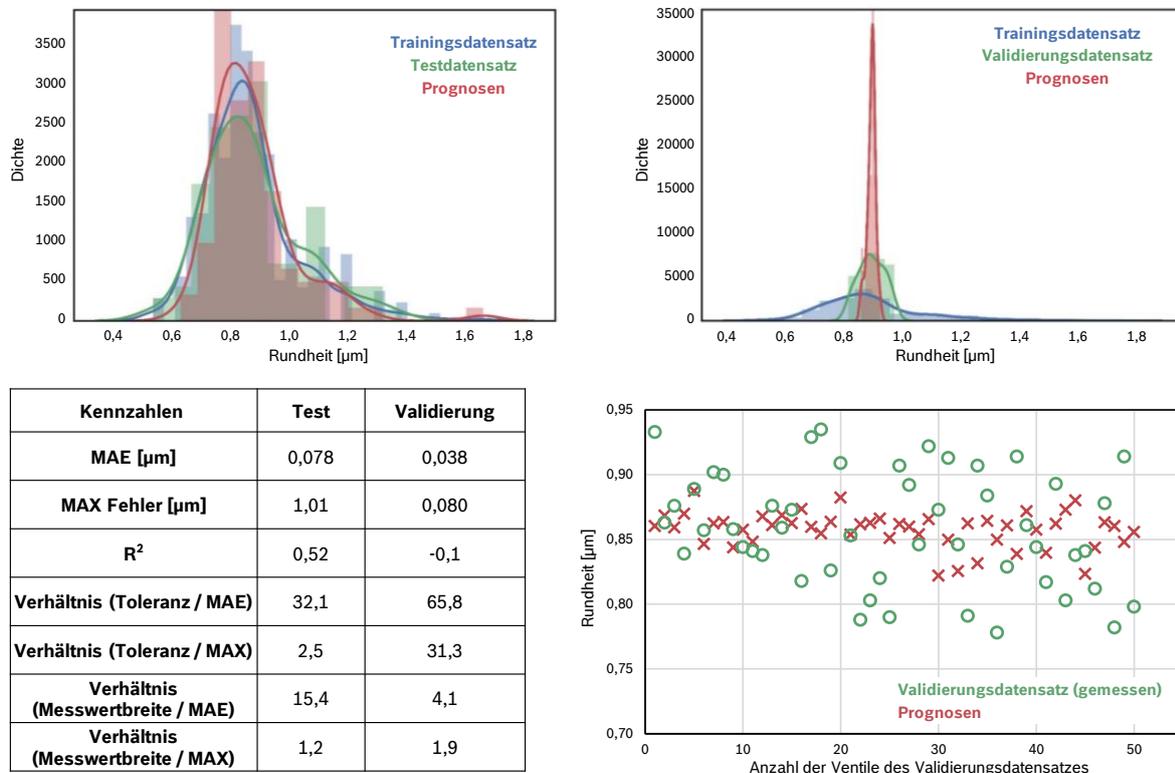


Abbildung 5-40: Ergebnisse der Rundheitsprognose für den Test- und Validierungsdatensatz

Bei der Prognose der Rundheit (siehe Abbildung 5-40) bildet das Testing noch ziemlich genau die realen Werte des Testdatensatzes ab. Der Gipfel der Dichtekurve übersteigt zwar die Gipfel des Test- und sogar des Trainingsdatensatzes, ansonsten gleichen sich die Verläufe der Kurven. Eine Konzentration bzw. Zentrierung der Prognosewerte in einem bestimmten Wertebereich bildet sich nicht besonders stark aus. Dies ist jedoch der Fall für die Prognosen, die für den Validierungsdatensatz erzielt werden. Es ist eindeutig zu erkennen, dass die Prognosen sich ziemlich genau in der Mitte des Wertebereiches des Validierungsdatensatzes konzentrieren und folglich eine extreme Dichte aufweisen. Die reale Verteilung der Rundheitswerte wird von den Prognosen nicht mehr erreicht. Dies ist auch eindeutig anhand der Messwerte und der Prognosen für die einzelnen Bohrungen zu erkennen. Es tritt eine Konzentration der Rundheitswerte bei ca. 0,86 µm ein, unabhängig von der gemessenen Rundheit einer Bohrung. Lediglich die leicht unterschiedliche Streuung der gemessenen Werte der beiden Spindeln äußert sich noch minimal in der Streuung der Prognosewerte. Die Prognosefehler MAE und MAX sind mit 0,038 µm und 0,08 µm sehr niedrig. Im Verhältnis zur Messwertbreite nehmen sie jedoch einen großen Anteil ein. Mit Blick auf die Toleranz lässt sich erneut mit einer hohen Sicherheit sagen, ob eine Bohrung sich innerhalb oder außerhalb der Rundheitstoleranz befindet. Ein R² von

nur 52 % für das Testing zeigt auf, dass das Prognosemodell den Zusammenhang zwischen den verfügbaren Fertigungsmerkmalen und der Rundheit nicht ausreichend abbilden kann. Lediglich 52 % der in den Messwerten enthaltenen Varianz lässt sich mit den Merkmalen erklären. Für den Validierungsdatensatz wird R^2 sogar negativ, was ein Zeichen für eine ausgesprochen schlechte Prognosegenauigkeit ist und dem Raten der Rundheitswerte gleichkommt. Der trainierte RFR, auf unbekannte Daten angewandt, liefert nur noch einen Wertebereich, in dem die Rundheitswerte liegen könnten, jedoch keine zuverlässigen individuellen Prognosen mehr. Die Informationen, die aus den verfügbaren Datenquellen gewonnen werden, sind für eine Rundheitsprognose nicht ausreichend. Insbesondere durch Kraft- oder Positionsschwankungen in radialer Richtung zur Bohrung lassen sich Rundheitsabweichungen detektieren. Eine Erfassung von radialen Positionsschwankungen, hervorgerufen durch radial wirkende Kräfte, würde sich bei der verwendeten Maschine in der X- und Y-Achse widerspiegeln. Wie bereits zuvor erwähnt, sind die Positionsschwankungen dieser Achsen aufgrund der parallelen Bearbeitung von zwei Bohrungen nicht einer Bohrung individuell zuzuordnen. Die für eine Rundheitsprognose wichtigste Informationsquelle steht somit nicht in der benötigten Form zur Verfügung. Die Methode des maschinellen Lernens ist somit nur in der Lage, einen ungefähren Rundheitswert für beide Spindeln zusammen anzugeben. Um das Zustandekommen des Prognosewertes besser nachzuvollziehen, ist eine Betrachtung des Funktionsprinzips des RFR hilfreich (siehe Kapitel 2.4.3). Jeder der Bäume des RFR prognostiziert einen Rundheitswert auf der Basis der verfügbaren Daten. Trotz verschiedener Rundheitswerte zwischen den beiden Spindeln sind die X- und Y-Merkmalwerte von jeweils zwei Bohrungen identisch. Es wird nun Bäume geben, die eher den Rundheitswert der Bohrungen der ersten Spindel prognostizieren und wiederum Bäume, die eher den Rundheitswert der Bohrungen der zweiten Spindel prognostizieren. Der nun aus allen Prognosen gemittelte Rundheitswert wird mit einer hohen statistischen Wahrscheinlichkeit in der Mitte der beiden gemessenen Rundheitswerte liegen. Hierdurch ist auch die starke Zentrierung der Prognosewerte in der Mitte der Dichtekurve des Validierungsdatensatzes zu erklären.

Die Geradheitsprognose (siehe Abbildung 5-41) verhält sich analog zu der Rundheitsprognose, da für die Bestimmung der Geradheit einer Bohrung u. a. die Mittelpunkte der bei der Rundheitsmessung bestimmten Kreise mit einfließen. Auch bei der Geradheitsprognose tritt der Effekt der Zentrierung der Prognosewerte auf. Die Gründe hierfür sind die zuvor erläuterten. Die MAE und MAX Werte sind zwar beide sehr klein, jedoch nehmen sie von allen Qualitätsmerkmalen den größten Anteil der zugrundeliegenden Messwertbreite des Validierungsdatensatzes ein. Das Verhältnis zwischen der Toleranzbreite und dem MAE bzw. MAX Fehler ist mit 32 und 12 nur halb so groß wie für die Rundheit. Dennoch sind die Werte immer noch groß genug, um mit hoher Sicherheit auf der Basis der Prognosen zu entscheiden, ob die Geradheitstoleranz eingehalten wird oder nicht. Bemerkenswert ist der hohe R^2 -Wert für das Testing, welcher jedoch für den Validierungsdatensatz dann auch negativ wird. Der für die Geradheitsprognose eingesetzte GBR scheint, im Unterschied zu dem

RFR bei der Rundheitsprognose, die Zusammenhänge zwischen Fertigungsmerkmalen und Geradheit aus dem Trainingsdatensatz gut zu erkennen und kann diese dann für die Prognose auf den Testdatensatz anwenden. Jedoch besitzt er in diesem Fall ebenso wenig die Fähigkeit, auf der Basis der verfügbaren Datenquellen, präzise Prognosen für einen unbekanntem Datensatz zu erstellen.

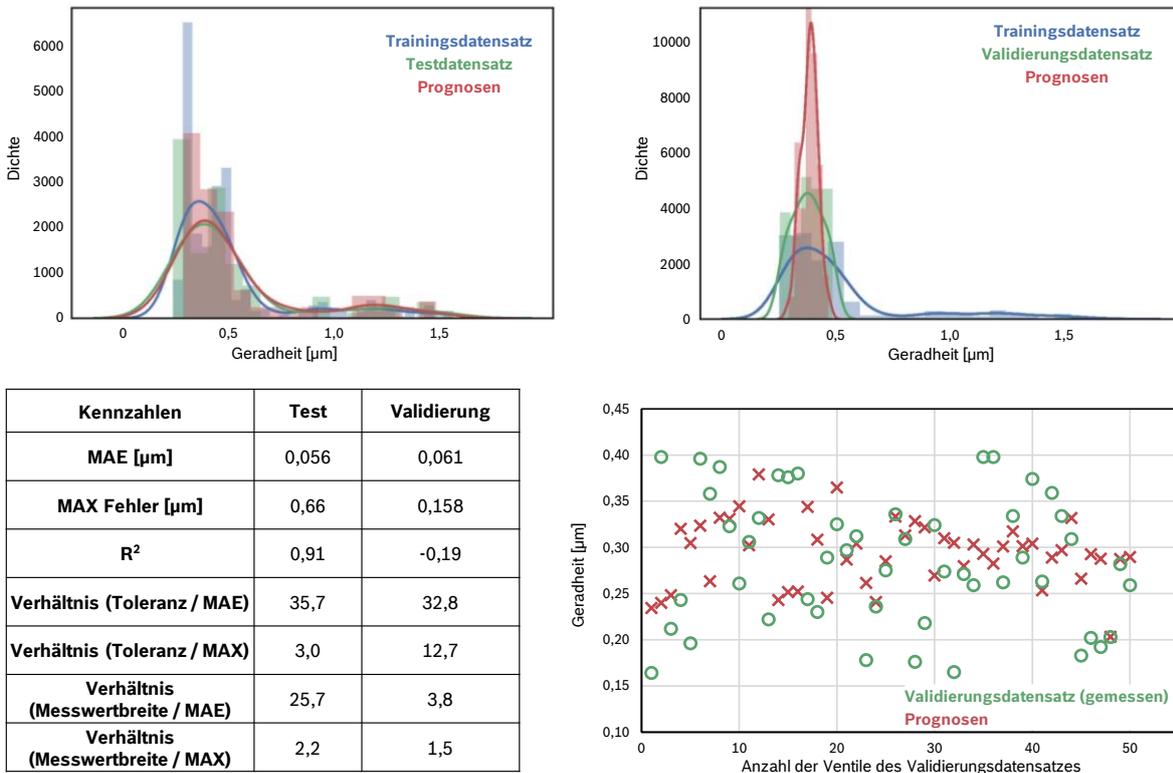


Abbildung 5-41: Ergebnisse der Geradheitsprognose für den Test- und Validierungsdatensatz

Festzuhalten ist, dass für alle vier Qualitätsmerkmale die erzielten Prognosen stets nur innerhalb des Wertebereiches des Validierungsdatensatzes sind. Es tritt somit keine zufällige, unerklärliche Streuung der Prognosen über den Wertebereich des Trainingsdatensatzes auf. Dies führt dazu, dass die Fehler MAE und MAX stets deutlich kleiner sind als die Toleranzen der Merkmale. Eine Aussage darüber, ob die Merkmale noch innerhalb ihrer jeweiligen Toleranz sind, lässt sich somit mit einer hohen Sicherheit treffen. Präzise, zu einer Bohrung individuell gehörende Qualitätsprognosen sind nur für die Merkmale verlässlich möglich, deren qualitätsbeeinflussende Effekte auch individuell erfasst und der Bohrung zugeordnet werden können.

5.6.2 Herleitung und Adaption einer fertigungstechnischen Validierung

Zusätzlich zu der Validierung der Prognoseergebnisse mit Kennzahlen, welche üblich für die Bewertung der Prognosegüte von Methoden des maschinellen Lernens sind, werden im Folgenden Verfahren angewendet, die sich in der fertigen Industrie für die Bewertung der Fähigkeit von Messmitteln und Messprozessen für die Qualitäts-

kontrolle etabliert haben. Durch die Anwendung dieser genormten, weit verbreiteten sowie dem Fertigungsingenieur bekannten Verfahren ist es möglich, die Prognosegüte mit geläufigen und vergleichbaren Kennzahlen auszudrücken. Hierdurch wird die Möglichkeit eines Vergleiches zwischen den Ergebnissen des maschinellen Lernens und der industriellen Messtechnik geschaffen. In Kapitel 2.2.2 werden die Verfahren eins und drei für die Bewertung der Fähigkeit des Messmittels und des Messprozesses detailliert beschrieben. In diesem Kapitel werden nun diese über Jahrzehnte entwickelten sowie genutzten Verfahren angewendet, und zwar zur Bewertung der Fähigkeit der trainierten Methoden für die Qualitätsprognose der verschiedenen Merkmale des Validierungsdatensatzes.

Das Grundprinzip des Verfahrens eins besteht darin, ein Normal mit einem Messmittel insgesamt 50-mal zu messen und aus den Messergebnissen die systematische Messabweichung und die Standardabweichung zu bestimmen. In Bezug auf die Merkmalstoleranz ergeben sich dann die Werte der Fähigkeitsindizes. Für die herkömmliche Durchführung des Verfahrens eins ist somit ein Messmittel sowie ein Normal mit bekanntem Referenzwert notwendig. In dem Kontext der Qualitätsprognose wird das Messmittel durch die trainierte Methode des maschinellen Lernens ersetzt und das Normal durch die aus den Fertigungsdaten extrahierten Merkmale eines Werkstückes (Ventilgehäuses) des Validierungsdatensatzes sowie den zu dem Werkstück gehörenden Messwert des jeweiligen Qualitätsmerkmals. Das Ersetzen des Messmittels durch die trainierte Methode ist leicht nachvollziehbar, da schließlich das Messen durch eine Prognose ersetzt werden soll. Die Verwendung eines Werkstückes als Normal bedarf hingegen tiefergehender Herleitung. Ein Werkstück kann grundsätzlich auch als ein Normal verwendet werden, wenn es einer entsprechenden Kalibrierung unterzogen wurde. Hier kommt schnell die Idee auf, ein Werkstück des Validierungsdatensatzes zu kalibrieren und den Referenzwert des Qualitätsmerkmals zu bestimmen, um dann die erzielte Prognose mit dem Referenzwert vergleichen zu können bzw. die Fähigkeit der Methode zu bestimmen. Gegen diese Idee spricht jedoch, dass die Methode des maschinellen Lernens für das Training nicht nur die Merkmale der Fertigungsdaten von vielen Werkstücken benötigt, sondern auch die zugehörigen Messwerte des jeweiligen Qualitätsmerkmals. Demnach ist es nicht ausreichend, nur ein kalibriertes Werkstück zu besitzen. Vielmehr müssten alle im Trainingsdatensatz enthaltenen Werkstücke kalibriert werden und die ermittelten Referenzwerte für das Training genutzt werden. Das Kalibrieren von einem Werkstück ließe sich aufwandstechnisch noch gut realisieren, die Kalibrierung von mehreren hundert Trainingsdaten ist hingegen wirtschaftlich nicht mehr realisierbar. Das Training hat somit in der industriellen Praxis mit Messwerten zu erfolgen, welche keine Referenzwerte repräsentieren. Um dennoch Messwerte zu erhalten, die jeweils nahe an dem wahren Wert des Qualitätsmerkmals liegen, sind fähige Messmittel sowie Messprozesse von essentieller Wichtigkeit (siehe Kapitel 5.3.2). Die Basis für das Training stellen somit nicht nur zuverlässig und sinnhaft erfasste Fertigungsdaten, sondern auch präzise gemessene Qualitätsmerkmale dar. Dass für das Training keine Referenzwerte genutzt werden können, sollte aufgrund der hohen Anzahl von

Trainingsdaten aus statistischer Sicht eine vernachlässigbare Rolle bzw. Wirkung haben. Denn nach dem Gesetz der Großen Zahlen konvergieren mit Wahrscheinlichkeiten behaftete Werte (Messwerte) mit steigender Anzahl gegen den arithmetischen Mittelwert und nach dem Grenzwertsatz der Statistik können die Mittelwerte von Stichproben, mit steigender Anzahl von Stichproben, als ausreichend Normalverteilt betrachtet werden [TILS 19b, S. 49]. Beide Aussagen sind hier zutreffend, da die Messwerte von Fertigungschargen (Stichproben) erfasst werden, die relativ homogen in ihrer Qualität sind und somit der wahre Wert (der Fertigungscharge) von dem Messmittel im Durchschnitt bestimmt wird. Eine Methode, die mit Daten trainiert wird, deren Werte von den wahren Werten abweichen, wird zwangsläufig auch fehlerhafte Zusammenhänge erlernen. Eine Art Fehlerfortpflanzung, die zu Fehlern führt, welche deutlich größer als die ursprünglichen Fehler der Trainingsdaten sind, ist aufgrund der erwähnten Gesetzmäßigkeiten nicht zu erwarten. Ein weiterer Effekt zur Fehlerreduzierung geht von den Methoden RFR und GBR selbst aus, die das finale Prognoseergebnis durch die Mittelung der von den Entscheidungsbäumen ausgegebenen Prognoseergebnisse berechnen.

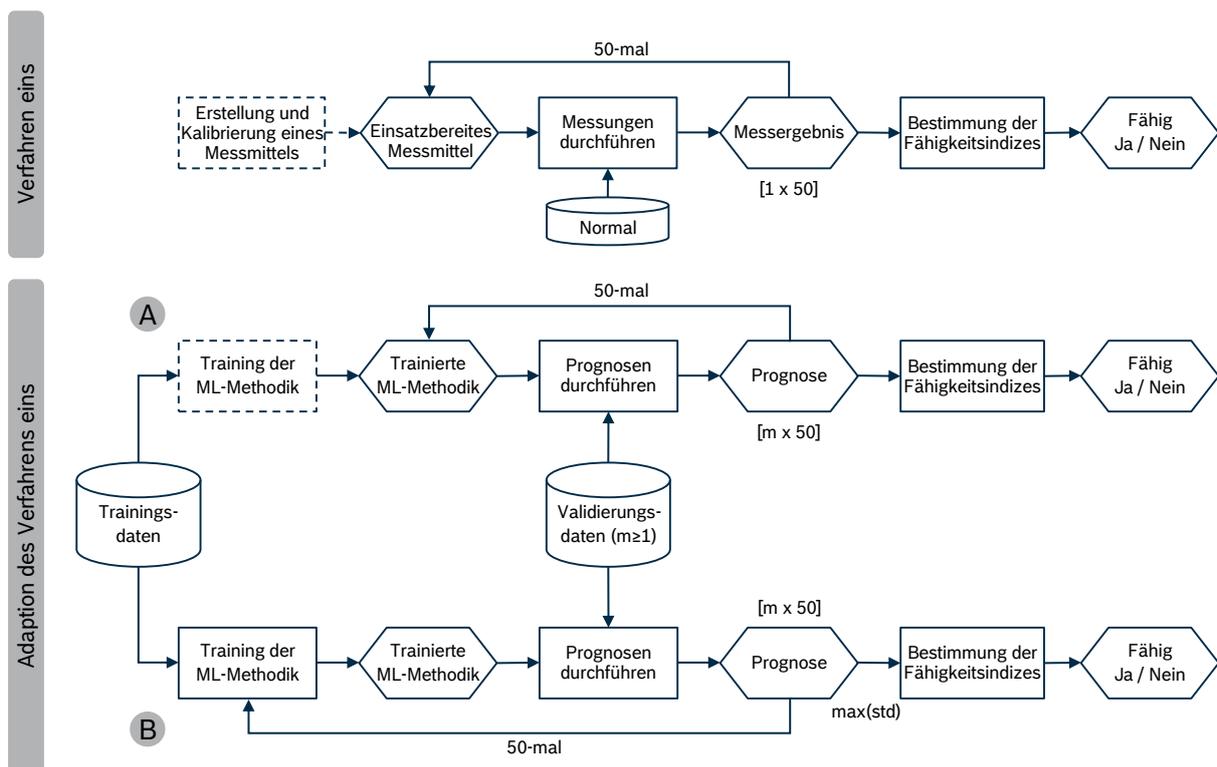


Abbildung 5-42: Ablauf des Verfahrens eins im herkömmlichen Sinne und seine Adaption für eine Qualitätsprognose mit Methoden des maschinellen Lernens

In Abbildung 5-42 ist das Vorgehen für die Durchführung des Verfahrens eins für den herkömmlichen sowie den adaptierten Einsatz aufgezeigt. In der herkömmlichen Anwendung ist von der Existenz eines einsatzbereiten Messmittels auszugehen, mit dem ein Normal 50-mal gemessen wird und im Anschluss die Fähigkeitsindizes berechnet werden (siehe Kapitel 2.2.2). Bei der Durchführung des Verfahrens eins, zum

Nachweis der Fähigkeit einer Methode des maschinellen Lernens für die Qualitätsprognose, kann darin unterschieden werden, ob das Training der Methode bei jedem Durchlauf in das Ergebnis mit einfließt oder nicht. In der Praxis wird eine Methode trainiert und diese dann solange für die Prognoseerstellung genutzt, bis ein erneutes Training erforderlich ist, aufgrund von sich z. B. ändernden Umständen bzw. Umwelteinflüssen, die bei der bereits trainierten Methode noch nicht berücksichtigt wurden. Wird eine trainierte Methode genutzt, um 50-mal eine Prognose für den gleichen Datensatz abzugeben, so werden 50 identische Prognoseergebnisse erzielt (Ast „A“ in Abbildung 5-42). Der Sachverhalt, dass eine trainierte Methode bei jedem Durchlauf für die gleichen Inputdaten auch dasselbe Ergebnis ausgibt, führt dazu, dass die Standardabweichung für die Prognosen null beträgt. Treten bei einem klassischen Messvorgang mit einem Messmittel bei jedem Messdurchlauf minimal verschiedene Messergebnisse auf, so ist dies bei den Methoden des maschinellen Lernens nicht der Fall. Folglich ist die mit dem Verfahren eins untersuchte Wiederholbarkeit des Messergebnisses bei der Qualitätsprognose exzellent, da stets dasselbe Ergebnis erzielt wird. Jedoch wird zur Berechnung der Fähigkeitsindizes der jeweilige Zähler durch ein Vielfaches der Standardabweichung dividiert, was in diesem Fall aus mathematischer Sicht nicht möglich ist, da die Standardabweichung den Wert Null annimmt (siehe Kapitel 2.2.2). Unter der Annahme, dass die Standardabweichung nicht null, sondern nur nahezu null wäre, würde der Quotient unendlich groß sein und somit immer über den vorgegebenen Mindestwerten liegen, was ein positiver Fähigkeitsnachweis wäre. Um die Fähigkeit einer Methode für die Qualitätsprognose mit Verfahren eins realistisch beurteilen zu können, muss somit eine Adaption des Verfahrens eins auf die neuartige Qualitätsbestimmung erfolgen. Eine solche Adaption bzw. Modifizierung ist durchaus üblich, setzt jedoch voraus, dass sie dokumentiert und kritisch hinterfragt wird [TILS 19a, S. 2]. Das Verfahren eins soll soweit modifiziert werden, dass es bei jedem Durchlauf der Prognose ein erneutes Training der Methode mit einbezieht (Ast „B“ in Abbildung 5-42). Die Methode lernt bei jedem Training dieselben Zusammenhänge zwischen Eingangsdaten und Zielgröße, jedoch ist die methodeninterne Parametrierung nach jedem Training individuell. Dies führt zu einer gewissen Streuung der Prognoseergebnisse, die auch in den vorherigen Kapiteln bei der Anwendung der Kreuzvalidierung zu erkennen ist. Je geringer die Streuung ist, desto valider sind die von der Methode erkannten und gelernten Zusammenhänge in den Trainingsdaten. Die Streuung ist somit auch ein Gütemaß für die Wiederholbarkeit des Erkennens der Zusammenhänge, was sich auf die Streuung der Prognoseergebnisse auswirkt. Folglich ist die Streuung (Standardabweichung) auch eine essentielle Größe bei der Berechnung der Fähigkeitsindizes. Bei der Durchführung der Messprozessfähigkeit mit Messmittel und Normal wird vorausgesetzt, dass alle Handhabungsschritte bei jedem Durchlauf vollständig ausgeführt werden. Dies bedeutet, dass das Normal für jede Messung ausgespannt und erneut eingespannt werden muss. Eine solche Fehlerquelle bzw. Einflüsse auf das Messergebnis treten bei der Durchführung einer Prognose nicht auf. Deswegen sollte daher das Trainieren der Methode als ein entscheidender Handhabungsschritt verstanden werden und somit bei jedem Durchlauf erneut ausgeführt werden. Dahingegen würde die erneute

Durchführung z. B. der Merkmalsextraktion oder die Parametrierung der Methode bei jedem Durchlauf zu weit gehen und wird deswegen nicht bei jedem Durchlauf vollzogen. Beim herkömmlichen Verfahren wird ein Normal insgesamt 50-mal gemessen, sodass am Ende 50 Messwerte vorliegen (*1x50-Matrix*). Für die Durchführung des adaptierten Verfahrens könnte die Prognose ebenfalls nur für ein Werkstück erfolgen. Jedoch bietet es sich an, für jedes der m Werkstücke des Validierungsdatensatzes 50-mal ein Qualitätswert zu prognostizieren, sodass eine *mx50-Matrix* an Prognosewerten vorliegt. Mit diesen Werten hat schließlich die Berechnung der Fähigkeitsindizes zu erfolgen. Ein einziges der m Werkstücke ist jedoch ausreichend für die Berechnung der Indizes und es bietet sich daher an, das Werkstück mit der größten Standardabweichung der 50 Prognosewerte auszuwählen. Eine hohe Standardabweichung führt zu kleineren Werten bei der Berechnung der Fähigkeitsindizes, was beim Unterschreiten des Fähigkeitskriteriums von 1,33 in einem negativen Fähigkeitsnachweis nach Verfahren eins enden würde. Wird eine Fähigkeit der Qualitätsprognose für das Werkstück mit der größten Standardabweichung erreicht, so erzielt die Methode auch für die restlichen Validierungsdaten einen positiven Fähigkeitsnachweis. Die Wahl der größten Standardabweichung für den Fähigkeitsnachweis kann als eine Art „Abschätzung zur sicheren Seite“ angesehen werden. Dieses Vorgehen macht es auch überflüssig, ein Werkstück für den Fähigkeitsnachweis zu kalibrieren, wobei die Notwendigkeit einer Kalibrierung bereits zuvor angezweifelt wurde. Erfolgen Änderungen an dem Fertigungsprozess, welche grundlegende Anpassungen der Methode notwendig machen, so kann mit jedem neu erhobenen Validierungsdatensatz ein effizienter und schneller Fähigkeitsnachweis durchgeführt werden.

Wird nach Verfahren eins ein Messprozess als fähig eingestuft, so hat mittels Verfahren drei auch die Überprüfung seiner Fähigkeit (Streuverhalten) für das Messen von Werkstücken aus der Serienfertigung zu erfolgen. Im Unterschied zu Verfahren eins wird bei der Durchführung des Verfahrens drei nicht ein Normal 50-mal vermessen, sondern mindestens 25 Werkstücke aus der Serienfertigung insgesamt zweimal (siehe Kapitel 2.2.2). Anhand der zwei Messreihen werden dann die Fähigkeitsindizes bestimmt. Der Ablauf der beiden Verfahren ist prinzipiell identisch, nur dass nun mehr Werkstücke benötigt werden, dafür aber weniger Wiederholmessungen pro Werkstück durchgeführt werden. Der Sachverhalt, dass mit derselben trainierten Methode für einen Datensatz stets identische Prognosewerte erzielt werden, macht eine Adaption des Verfahrens drei ebenfalls notwendig. Die Adaption besteht darin, auch das Training der Methode bei jedem Durchlauf erneut durchzuführen (Ast „D“ in Abbildung 5-43). Die so erhaltenen Prognosewerte weisen eine gewisse Streuung auf, die analog zu der Streuung eines Messmittels verstanden werden kann und die Anwendung der Berechnungsformeln zum Nachweis der Fähigkeit ermöglichen. Bei der Durchführung der zwei Messreihen sollen die Werkstücke für jede Messreihe in unterschiedlicher Reihenfolge gemessen werden und müssen somit auch zwangsweise zweimal eingespannt und ausgespannt werden. Diese sowie die vom Messmittel ausgehenden Unsicherheiten bei der Messung eines Qualitätsmerkmals treten in

dieser Form bei der Qualitätsprognose nicht auf. Lediglich durch das erneute Training der Methode können diese Unsicherheiten indirekt mit einfließen, da diese bei der Messung der Qualitätsmerkmale der Werkstücke des Trainingsdatensatzes ebenfalls aufgetreten sind und sich nun durch die Streuung der Prognosewerte äußern. Eine gesonderte Auswahl der Prognosen, welche für die Berechnung der Fähigkeitsindizes berücksichtigt werden, ist im Unterschied zu Verfahren eins nicht durchzuführen, da mindestens $m \geq 25$ Prognosen benötigt werden. Somit werden alle Prognosewerte der zwei Messreihen zum Nachweis der Fähigkeit verwendet.

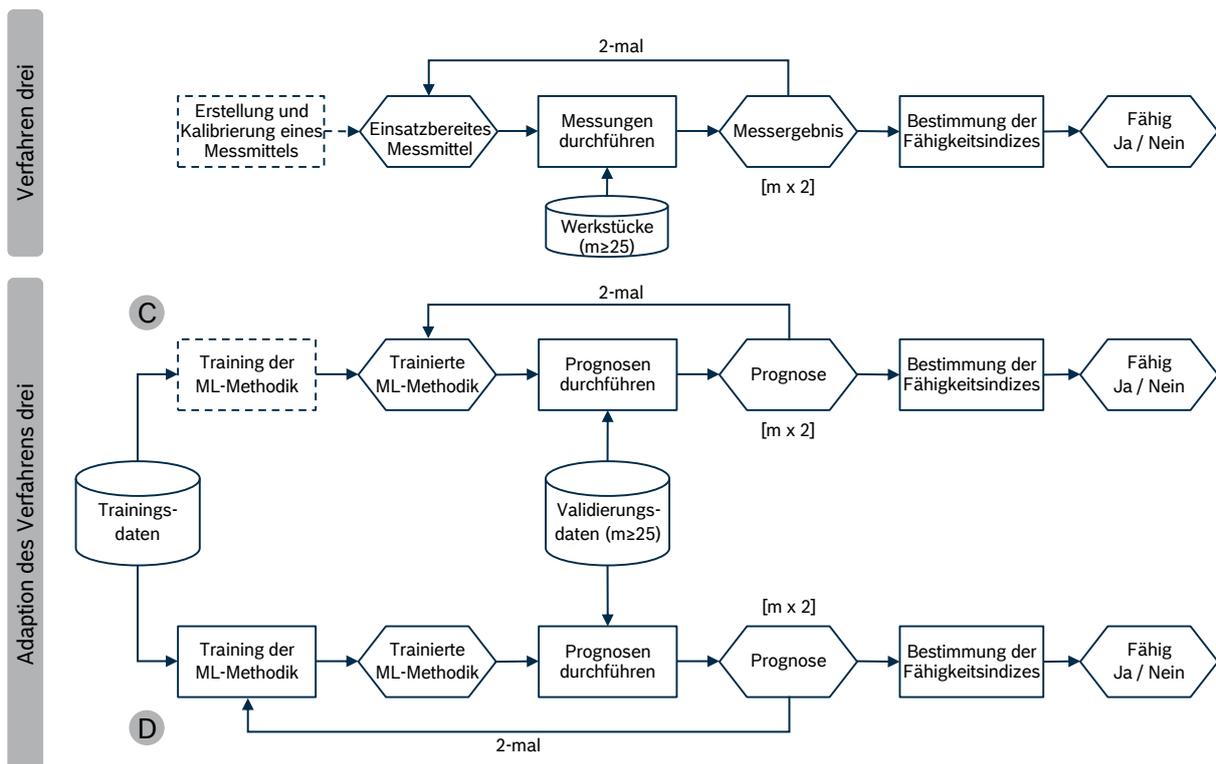


Abbildung 5-43: Ablauf des Verfahrens drei im herkömmlichen Sinne und seine Adaption für eine Qualitätsprognose mit Methoden des maschinellen Lernens

5.6.3 Durchführung der fertigungstechnischen Validierung

Für die Auswertung der Messreihen und die Berechnung der Fähigkeitsindizes wird die hierfür speziell ausgelegte Software Q-DAS solara.MP der Firma Hexagon verwendet. Die Bewertung der Fähigkeit der Qualitätsprognose mittels der Methoden des maschinellen Lernens erfolgt für jedes der vier Qualitätsmerkmale individuell. Die Ergebnisse werden in diesem Kapitel beschrieben und diskutiert. Die von Q-DAS solara.MP ausgegebenen Berichte sind im Anhang D und E aufgeführt. Die in den Abbildungen und den Berichten aufgeführten Begriffe „Messabweichung“, „gemessene Werte“ und „Messwertklasse“ müssten im Kontext des Untersuchungsvorhabens die Bezeichnungen „Prognoseabweichung“, „prognostizierte Werte“ und „Prognosewertklasse“ tragen. Jedoch haben sie in der Konfiguration von Q-DAS solara.MP die auf das Messen bezogenen Bezeichnungen. Mit der hier aufgeführten Erläuterung

sollte nun eindeutig sein, dass die mit den Begriffen angegebenen Werte einer Prognose entstammen und nicht einer Messung.

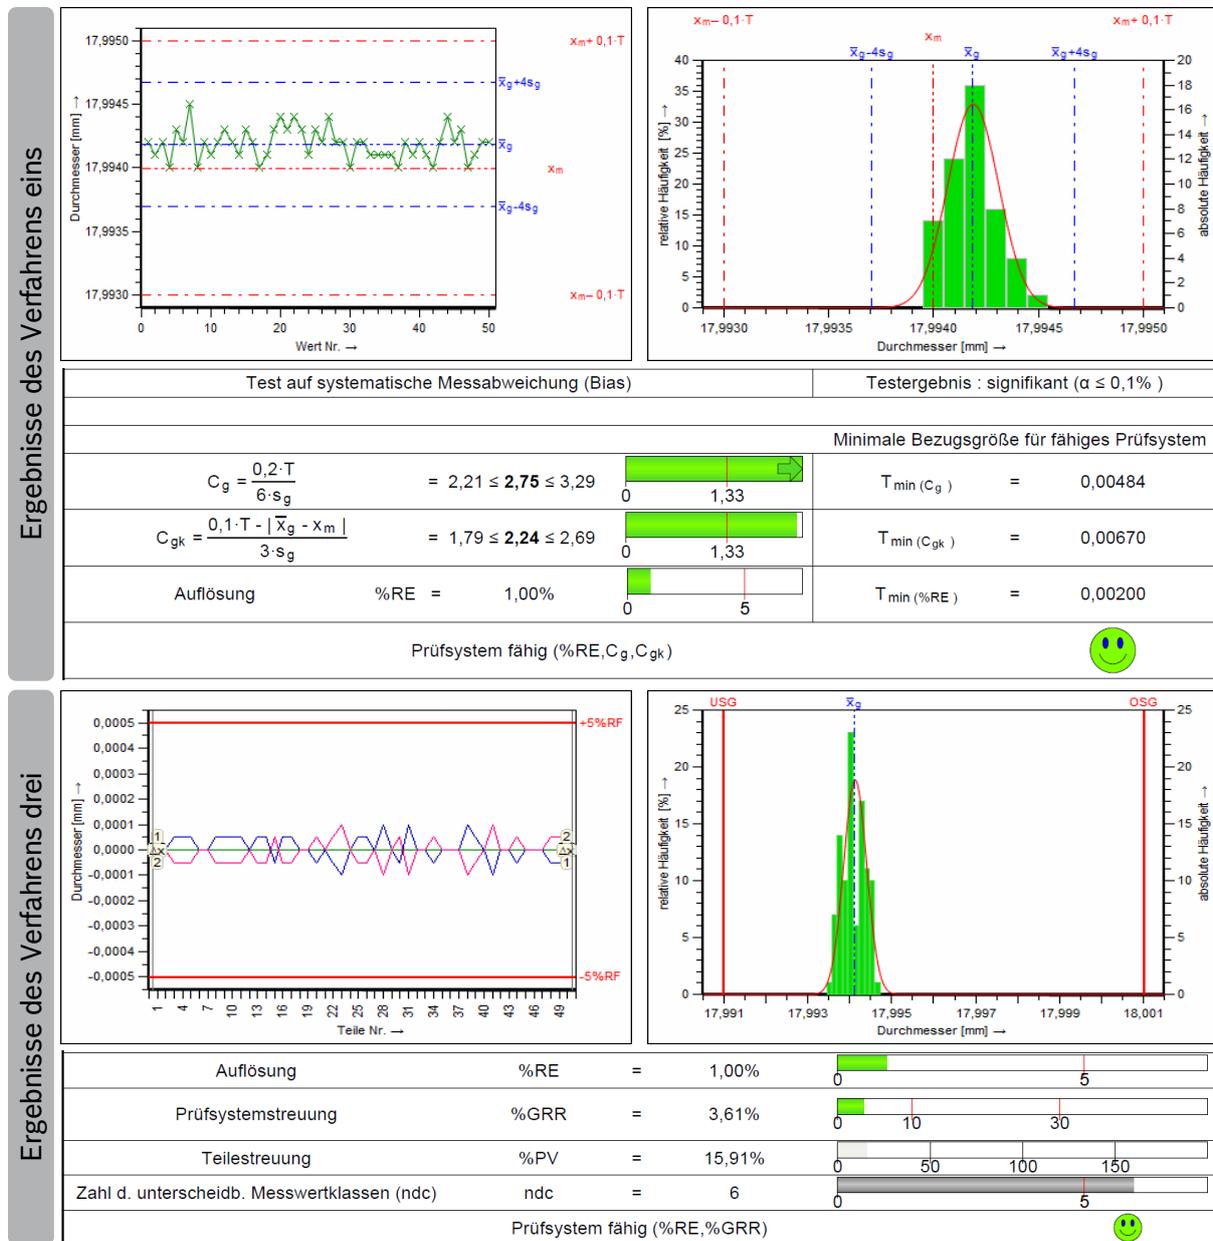


Abbildung 5-44: Ergebnisse des Verfahrens eins und drei für die Prognose des Durchmessers ausgewertet mit der Software Q-DAS solara.MP (vollständiger Bericht im Anhang D und E)

Die Ergebnisse des Verfahrens eins und drei für die Prognose des Durchmessers sind in Abbildung 5-44 aufgezeigt. Die C_g und C_{gk} -Werte des Verfahrens eins liegen jeweils deutlich über dem Grenzwert von 1,33. Dies bedeutet, dass der GBR (Messmittel) hinsichtlich Streuverhalten und systematische Prognoseabweichung für die Prognose des Durchmessers in Bezug auf die Toleranzbreite fähig ist und eingesetzt werden kann. Die oberen beiden Diagramme zeigen die Ergebnisse der 50 Wiederholprognosen für dieselbe Bohrung (Ventilgehäuse) auf. Es ist die Bohrung, für die die Standardabweichung s_g der Prognoseergebnisse am höchsten ist. Der Wert für s_g

beträgt $0,12 \mu\text{m}$ und führt in Bezug auf die Toleranz zu einem C_g -Wert von 2,75. Der Mittelwert \bar{x}_g der Prognosen liegt bei $17,9942 \text{ mm}$ und ist damit $0,2 \mu\text{m}$ über dem gemessenen Durchmesser $x_m=17,994 \text{ mm}$ der Bohrung. Der sich hieraus ergebene C_{gk} -Wert beträgt 2,24 und ist somit ebenfalls über dem Grenzwert. Es ist zu erkennen, dass die Prognosewerte teilweise exakt den Wert von x_m annehmen, jedoch mehrheitlich über diesem Wert liegen. Die Durchführung eines sogenannten Einstichproben-t-Tests mit einem Vertrauensniveau von 90 % führt zu dem Ergebnis, dass die Abweichung signifikant ist. In einem solchen Fall rät AIAG MSA entweder eine Korrektur an dem Messmittel vorzunehmen, was hier einem erneuten Training mit eventuell weiteren Trainingsdaten oder zusätzlichen Merkmalen gleichkäme, oder einen Korrekturfaktor bei jedem Messwert zu berücksichtigen [AIAG10, S. 95]. In diesem Fall wird das Ergreifen von Maßnahmen aus den folgenden Gründen jedoch als nicht notwendig angesehen. Die Abweichung liegt im Durchschnitt bei lediglich $0,2 \mu\text{m}$ und es kann nicht ausgeschlossen werden, dass die Trainingsdaten über eine ähnliche Streuung verfügen. Zudem könnte auch der Messwert x_m mit dieser Größe vom „wahren“, gemessenen Wert abweichen. Des Weiteren wird für sieben der 50 Wiederholprognosen exakt der Wert x_m erzielt. Ein weiterer Punkt ist die Lage von x_g . x_g liegt deutlich näher an x_m als etwa an $x_m+0,1*T$ oder gar darüber. Somit besteht aus fertigungstechnischer Sicht kein klarer Offset, der ein Ergreifen von Maßnahmen rechtfertigen würde. Im unteren Teil der Abbildung 5-44 sind die Ergebnisse des Verfahrens drei aufgeführt. Mit einem %GGR-Wert von 3,98 % wird der kritische Grenzwert von 10% deutlich unterschritten, was in diesem Fall die Fähigkeit des Prognosemodells bestätigt. Die Streuung der Ergebnisse des GBR liegt somit in einem vertretbaren Rahmen. Insgesamt wurde der Durchmesser von 50 Bohrungen jeweils zweimal prognostiziert. Die Abweichungen vom Mittelwert der zwei Prognoseergebnisse sind im linken Diagramm für jede Bohrung abgebildet. Es ist zu erkennen, dass die maximale Abweichung lediglich $0,1 \mu\text{m}$ beträgt und somit deutlich niedriger ist als der Grenzwert, welcher 5 % der Bohrungstoleranz beträgt. Die Auflösung, die mit dem GBR möglich ist, ist gleich der Auflösung des Messmittels (Koordinatenmessmaschine), mit dem die Qualitätsdaten des Trainingsdatensatzes bestimmt wurden. Die Auflösung %RE beträgt 1 % der Toleranz und ist somit deutlich unter den maximal zulässigen 5 %. Die Teilstreuung %PV ist selbst keine kritische Größe, sondern wird benötigt, um die Zahl der unterscheidbaren Messwertklassen (ndc) zu bestimmen. Mit einem ndc -Wert von sechs wird die kritische Grenze von fünf überschritten, was sicherstellt, dass der trainierte GBR unterschiedliche Teilequalitäten unterscheidbar prognostizieren kann. Die in Kapitel 5.6.1 gewonnene Erkenntnis, dass der Durchmesser mit dem GBR für eine Bohrung individuell bestimmt werden kann, und nicht nur der Bereich, in dem der Durchmesser liegt, wird hier erneut bekräftigt. Der ndc -Wert ist jedoch nur nach der Vorschrift von AIAG MSA verpflichtend zu prüfen. Da alle notwendigen Fähigkeitsindizes (C_g , C_{gk} , %GRR, %RE) innerhalb der geforderten Grenzwerten liegen, ist der GBR für die Prognose des Durchmessers sowohl nach Verfahren eins als auch nach Verfahren drei fähig, was von der Software auch anhand der beiden grünen Smileys zum Ausdruck gebracht wird.

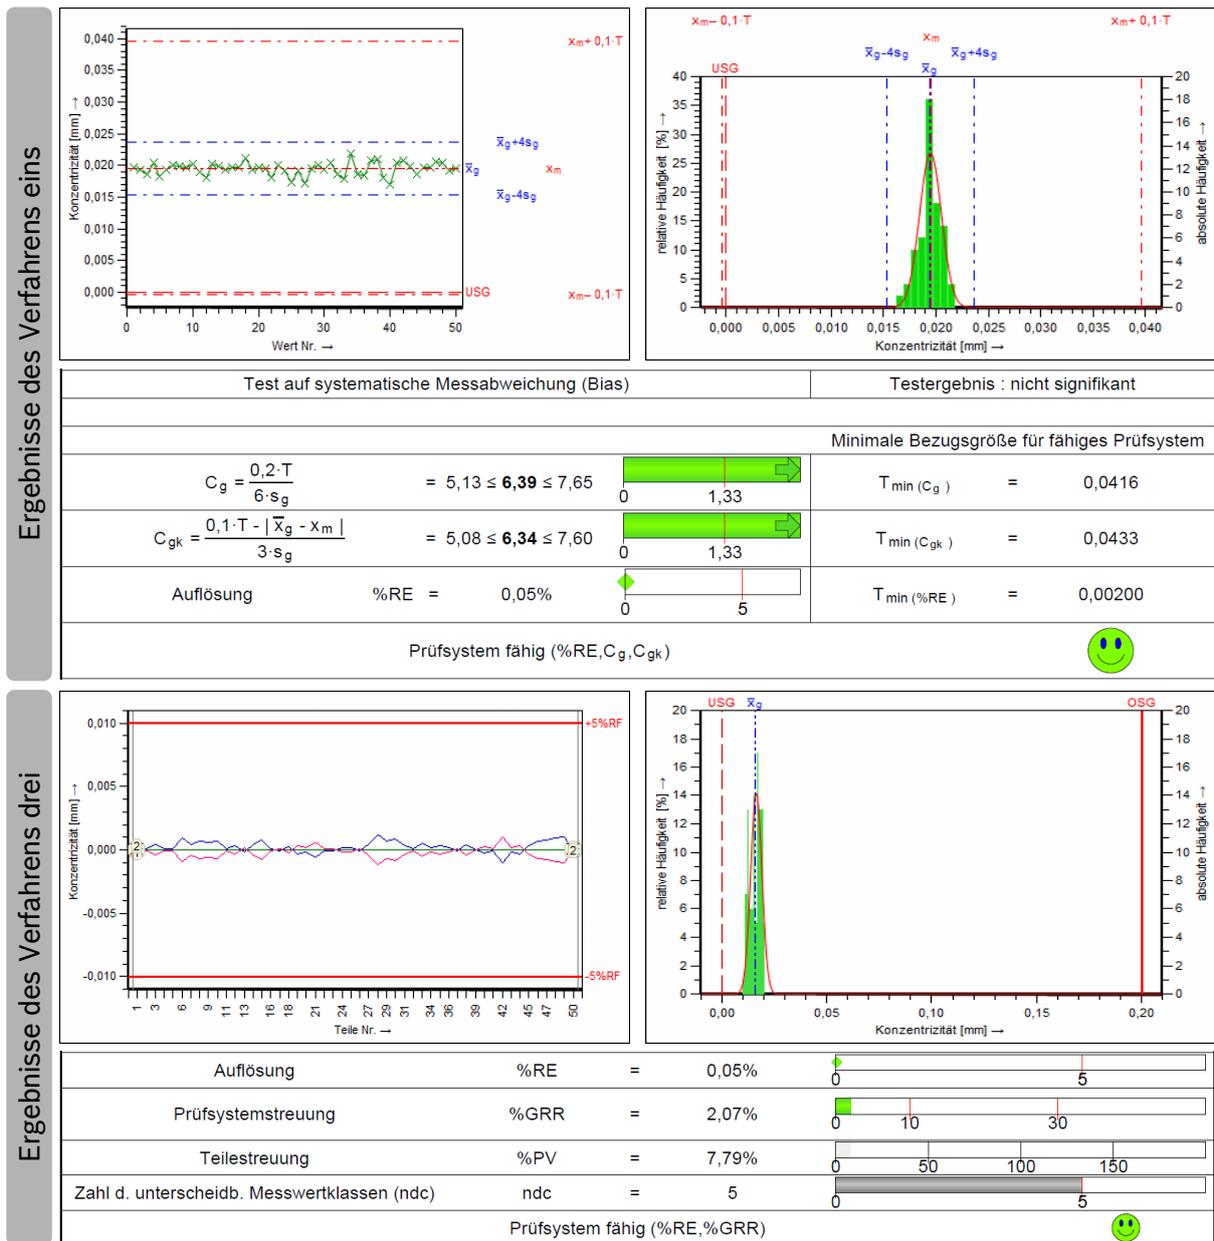


Abbildung 5-45: Ergebnisse des Verfahrens eins und drei für die Prognose der Konzentrität ausgewertet mit der Software Q-DAS solara.MP (vollständiger Bericht im Anhang D und E)

Die Ergebnisse der Fähigkeitsuntersuchung der Konzentritätsprognose sind in Abbildung 5-45 aufgezeigt. Die beiden grünen Smileys verraten auf den ersten Blick, dass der trainierte GBR fähig und somit geeignet ist, die Konzentrität zu prognostizieren. Ein C_g -Wert von 6,39 ist weit entfernt von den mindestens zu erreichenden 1,33 und gibt somit Rückschluss auf eine hohe Wiederholgenauigkeit der Prognosen. Das linke obere Diagramm visualisiert die niedrige Streuung der Prognosewerte. Gleichzeitig ist der Mittelwert \bar{x}_g der 50 Wiederholprognosen gleich dem gemessenen Konzentritätswert x_m . Die Prognosewerte sind gleichmäßig um x_m verteilt, sodass keine systematische Prognoseabweichung vorliegt. Der Ein-Stichproben-t-Test kann bei einem Vertrauensniveau von 90 % auch keine signifikante Prognoseabweichung feststellen. Der C_{gk} -Wert, welcher die systematische Prognoseabweichung ins Verhältnis zu der Standardabweichung setzt, ist mit 6,34 deutlich größer als der mindes-

tens geforderte Wert von 1,33. Die Prognoseauflösung $\%RE$ ist mit 0,05 % deutlich niedriger als die maximal zulässigen 5 %. Die mit Verfahren drei von 50 verschiedenen Bohrungen bei zweifacher Wiederholprognose bestimmten Werte führen zu einer Prüfsystemstreuung $\%GRR$ von 2,07 % und dieser Wert liegt hiermit deutlich unter den maximal zulässigen 10 %. Das linke Diagramm zeigt die Werte der Wiederholprognosen und es ist erkennbar, dass die maximale Differenz zwischen zwei Prognosewerten für dieselbe Bohrung bei maximal 2 μm liegt. Der ndc -Wert entspricht mit fünf genau dem mindestens zu erreichenden Grenzwert. Es lassen sich somit fünf unterscheidbare Messwertklassen (Prognosewertklassen) aus dem Validierungsdatensatz bestimmen. Dies ist ein Zeichen dafür, dass die Streuung der Prognosen (Streuung der Wiederholprognosen) im Vergleich zu der Streuung der Validierungsdaten (Breite des Wertebereiches, in dem die Prognosen liegen) ausreichend klein ist, um einen Konzentritätswert zu prognostizieren, der der Konzentrität der jeweiligen Bohrung entspricht. Der Wert ist zwar um eine Einheit niedriger als bei der Durchmesserprognose und somit sind die Prognosen etwas weniger spezifisch, jedoch ist der erreichte Wert zum Fähigkeitsnachweis vollkommen ausreichend.

Die Rundheit ist das einzige Qualitätsmerkmal, das mit einem RFR prognostiziert wird. Für diese Methode kann die Fähigkeit zur Qualitätsprognose ebenso nachgewiesen werden, wie es bereits für den GBR durchgeführt wurde. Die Indizes in Abbildung 5-46 zeigen auf, dass die Methode RFR für die Prognose der Rundheit als fähig betrachtet werden kann. Die Standardabweichung s_g der 50 Wiederholprognosen beträgt lediglich 0,019 μm , sodass sich hieraus ein hoher C_g -Wert von 4,34 ergibt. Auch die Differenz zwischen dem gemessenen Wert x_m und dem Mittelwert der Prognosen \bar{x}_g ist mit 0,02 μm ausgesprochen klein. Dies weist auf eine niedrige systematische Prognoseabweichung hin und ergibt schließlich einen C_{gk} -Wert von exakt 4,0. Beide Werte sind somit über dem mindestens zu erreichenden Wert von 1,33 und der Prognoseprozess kann hinsichtlich Wiederholbarkeit und systematischer Prognoseabweichung (Verfahren eins) als fähig eingestuft werden. Die systematische Prognoseabweichung wird nach dem Ein-Stichproben-t-Test bei einem Vertrauensniveau von 90 % zwar als signifikant eingestuft, jedoch wird aus fertigungstechnischer Sicht kein Bedarf zur Handlung gesehen. Die Auflösung $\%RE$ der Prognosen liegt zudem weit unter den maximal zulässigen 5 %. Die Gesamtstreuung $\%GRR$ liegt mit 2,34 % deutlich unter den zulässigen 10 %, was die Fähigkeit des Prognoseprozesses bestätigt. Die geringe Streuung der Prognosewerte lässt sich auch aus dem linken Diagramm ablesen. Lediglich für die ersten 10 Bohrungen, die mit der Spindel eins gefertigt werden, weichen die Wiederholmessungen etwas stärker voneinander ab. Lediglich zwei unterscheidbare Prognoseklassen (ndc -Wert) können bei der Rundheitsprognose aus dem Validierungsdatensatz ermittelt werden. Dies ist der gleiche Wert wie bei der Geradheitsprognose. Die Methode RFR kann die Rundheitswerte nur zwischen den beiden Spindeln unterscheiden, jedoch keine weiteren Klassen innerhalb einer dieser Klassen ausbilden. Dies bestätigt die vorherige Erkenntnis, dass die Anzahl der durch die Merkmale bereitgestellten Informatio-

nen nicht für eine präzisere Rundheits- und Geradheitsprognose ausreicht. Die Positionsschwankungen der X- und Y-Achse können aufgrund der parallelen Bearbeitung nicht einer Bohrung bzw. Spindel zugeschrieben werden. Somit ist auch nicht festzustellen, von welcher Spindel-Werkzeugkombination maßgeblich die Abweichungen verursacht und in das Maschinensystem eingeleitet werden. Dennoch kann die Rundheitsprognose auch nach Verfahren drei als fähig angesehen werden.

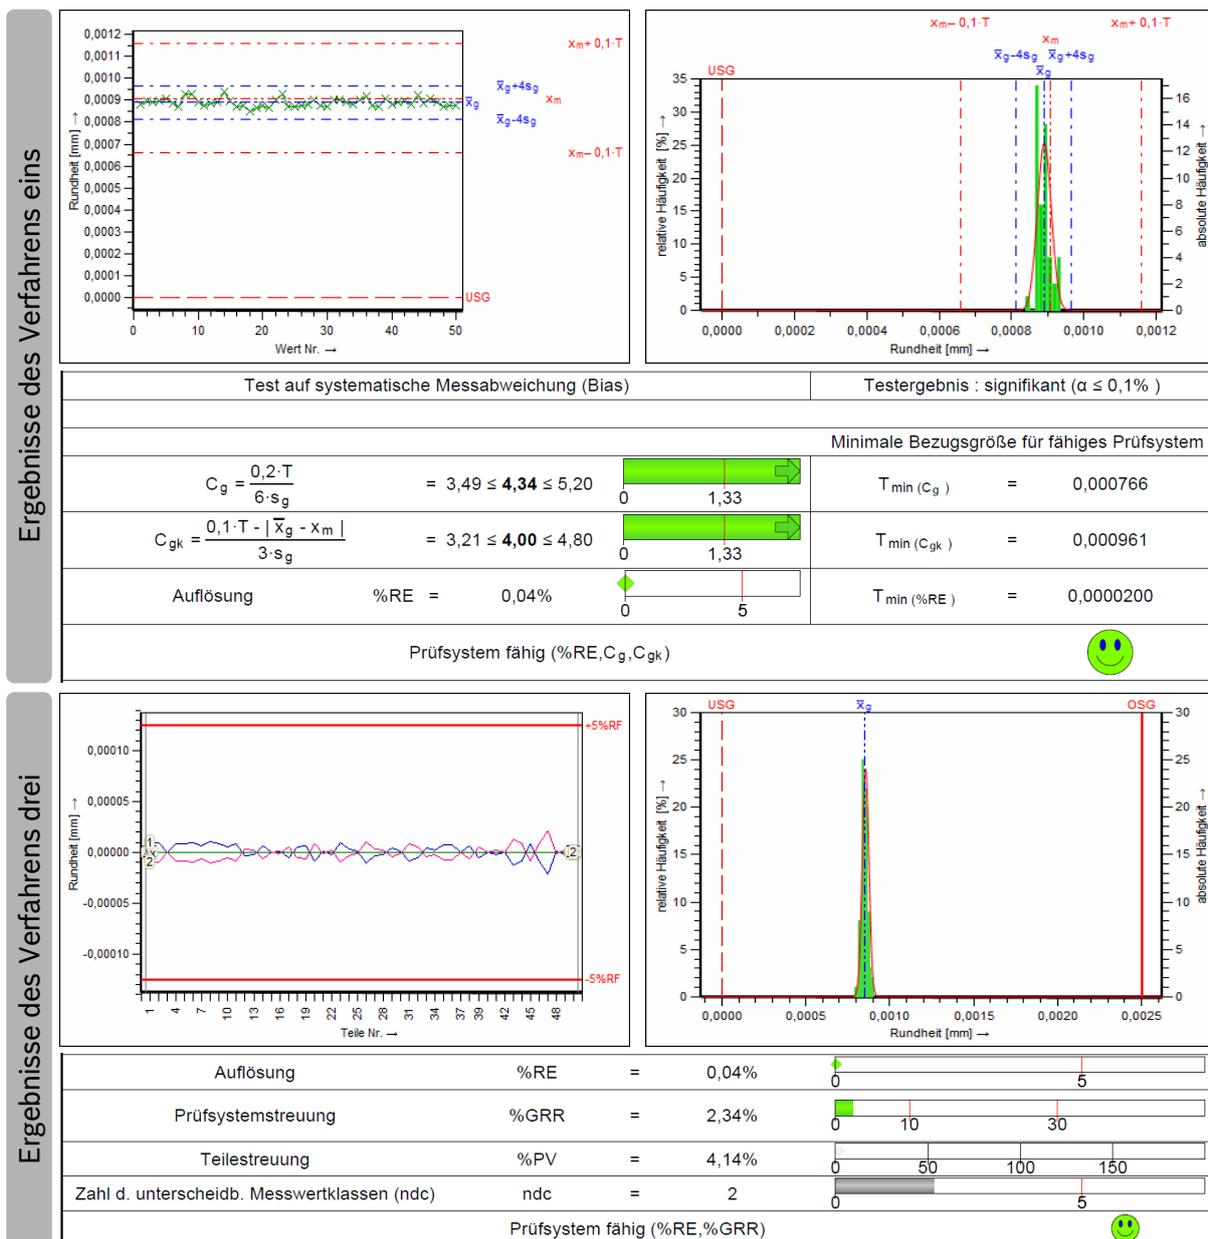
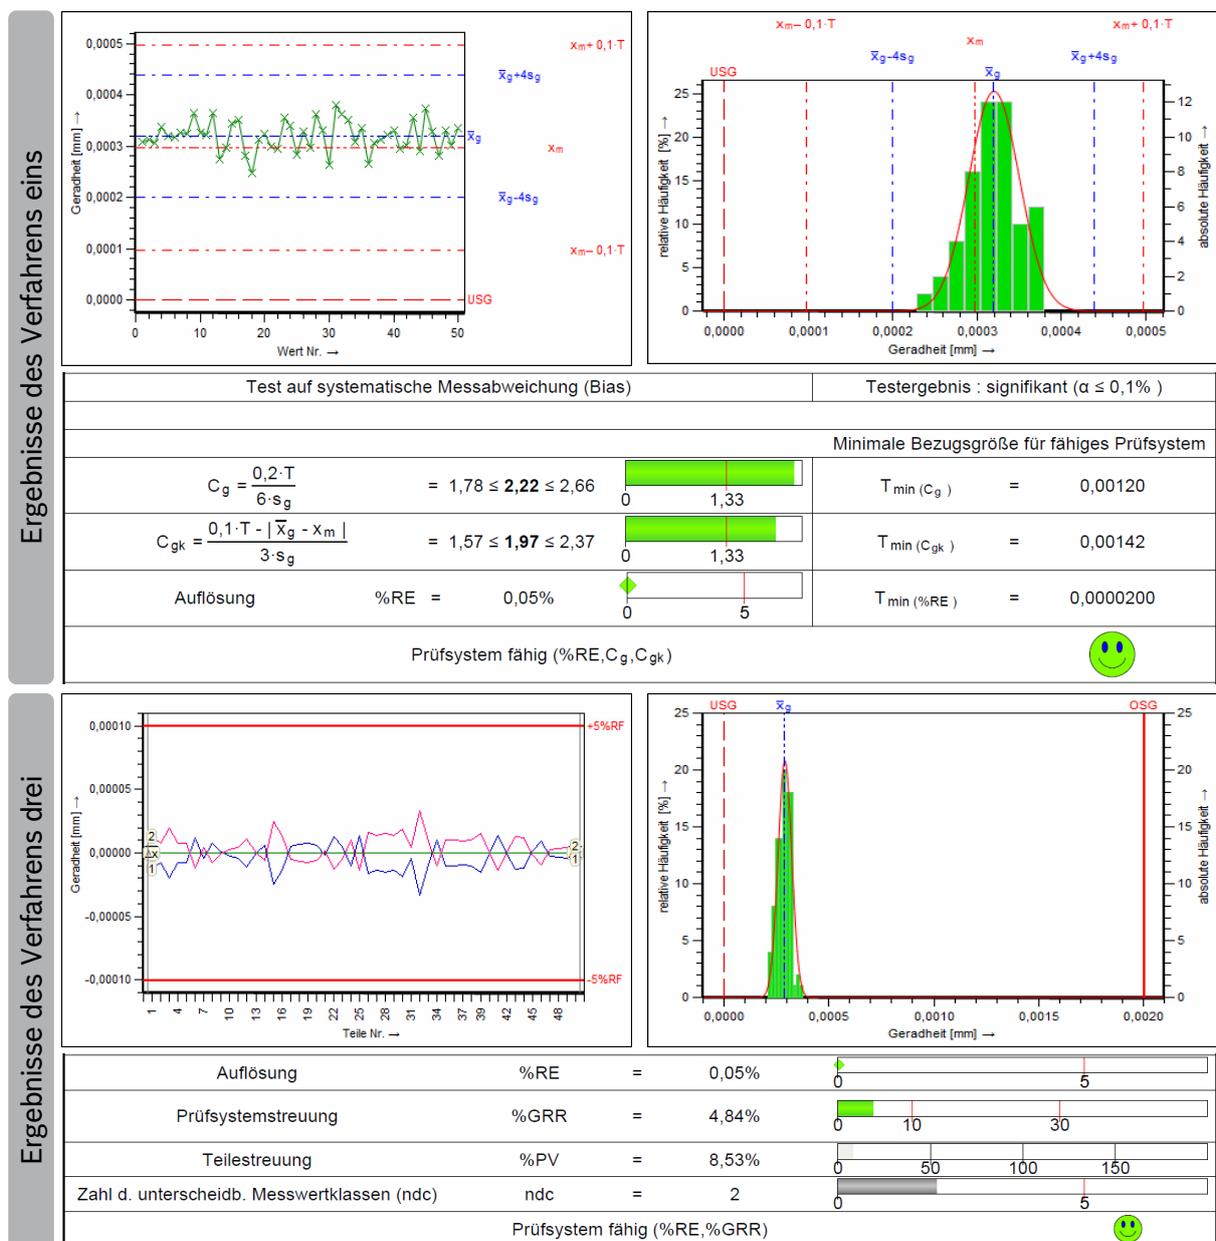


Abbildung 5-46: Ergebnisse des Verfahrens eins und drei für die Prognose der Rundheit ausgewertet mit der Software Q-DAS solara.MP (vollständiger Bericht im Anhang D und E)

Auch die Prognose der Geradheit mit der Methode GBR wird nach Verfahren eins und drei als Fähigkeit eingestuft, wie aus der Abbildung 5-47 zu entnehmen ist. Die Werte für C_g und C_{gk} betragen 2,22 sowie 1,97 und liegen damit über der minimal zu erreichenden Grenze von 1,33. Sie sind jedoch nicht, wie es für die anderen Quali-

tätsmerkmale der Fall ist, um ein Vielfaches von dieser entfernt. Dies deutet darauf hin, dass sich die Streuung der Prognosewerte im Verhältnis zu der Toleranz erhöht hat. Der Mittelwert \bar{x}_g der 50-fach wiederholten Prognose der Geradheit liegt $0,16 \mu\text{m}$ über dem gemessenen Geradheitswert der Bohrung. Auf der Basis eines Einstichproben-t-Tests mit einem Vertrauensniveau von 10 % wird diese Abweichung als signifikant eingestuft. Jedoch wird aufgrund der Lage von \bar{x}_g und dem Sachverhalt, dass auch sieben der 50 Wiederholprognosen identisch mit dem x_m -Wert sind, keine Notwendigkeit zur Maßnahmenergreifung gesehen. Weitere Gründe, die gegen das Einleiten von Maßnahmen bzw. einer Korrektur sprechen, sind für die Durchmesserprognose bereits erläutert worden.



Die Auflösung des GBR ist identisch mit der Auflösung des Formmessgerätes und unterschreitet vielfach die geforderte Auflösung von maximal 5 % der Merkmalstoleranz. Die Prüfsystemstreuung $\%GRR$ ist mit 4,84 % nur ca. halb so hoch wie der maximal zulässige Grenzwert, dennoch ist es der höchste Wert im Vergleich zu den anderen Qualitätsmerkmalen. In dem Diagramm, welches die Abweichungen der beiden Wiederholprognosen aufzeigt, bestehen die größten Abweichungen zwischen der 26. und der 32. Bohrung. Bei insgesamt 50 Bohrungen und zwei Spindeln entfallen die ersten 25 Bohrungen auf die erste Spindel und die letzten 25 Bohrungen auf die zweite Spindel. Die Prognosestreuung ist für die Daten des Validierungsdatensatzes bei der zweiten Spindel somit etwas größer. Ein Grund hierfür konnte jedoch nicht gefunden werden. Insgesamt beträgt die Standardabweichung bei den Wiederholpräzision jedoch nur 0,02 μm . Von größerem Interesse ist die Zahl der unterscheidbaren Messwertklassen (Prognosewertklassen) ndc , welche lediglich den Wert zwei annimmt und somit deutlich unter den mindestens geforderten fünf Klassen liegt. Wie bereits aus dem Kapitel 5.6.1 ersichtlich, lassen sich bei der Geradheits- und der Rundheitsprognose keine verlässlichen Prognosen für eine individuelle Bohrung erstellen. Vielmehr ist es nur möglich, einen Wertebereich verlässlich zu bestimmen, in dem die Geradheits- und Rundheitswerte liegen. Diese zuvor gewonnene Erkenntnis wird hier nun durch den ndc -Wert bestätigt. Der Validierungsdatensatz umfasst die Merkmale der Fertigungsdaten von zwei Spindeln für die parallele Fertigung der Bohrungen. Für jede Spindel und die zugehörigen Werkzeuge werden leicht verschiedene Bohrungsqualitäten erzielt. Für die Geradheitsprognose ist es nur möglich, anhand der zur Verfügung gestellten Daten zwischen den beiden Spindeln valide zu unterscheiden. Eine Klassifizierung der Qualität innerhalb des Wertebereiches einer Spindel wird hingegen nicht erreicht. Streng genommen wäre somit nach AIAG MSA der Prognoseprozess nach Verfahren drei nicht fähig. In den Richtlinien der BOSCH Group und der VDA 5 wird der ndc -Wert jedoch als kein kritisches Entscheidungsmerkmal geführt. Folglich erscheint in dem Auswertebereich das grüne Smiley und der Prognoseprozess gilt als fähig.

5.7 Implementierung in die Fertigung

Die letzte Stufe des in Kapitel 4.2 entworfenen Vorgehensmodells besteht aus der Implementierung der Qualitätsprognose in die Fertigung durch die Nutzung der gewonnenen Informationen aus den vorgelagerten Stufen. Die Implementierung hat auf zwei Weisen zu geschehen, zum einen durch die Integration in die Qualitätsregelkreise und zum anderen auf dem Shopfloor als Informationsquelle für den Maschinenbediener. Die Integration in die Qualitätsregelkreise ist nur theoretisch beschrieben, da für eine derartige Qualitätskontrolle noch jegliche Zertifizierung fehlt. Die Implementierung auf dem Shopfloor ist hingegen umgesetzt und informiert den Maschinenbediener über die aktuelle Qualität der gefertigten Werkstücke.

5.7.1 Integration der Qualitätsprognose in die Qualitätsregelkreise

Die Nutzung des maschinellen Lernens für die Qualitätsprognose bietet nicht nur neue Möglichkeiten der Qualitätskontrolle, sondern hat auch einen Einfluss auf die Gestaltung der Qualitätsregelkreise. In Kapitel 2.2.1 ist das Qualitätsmanagement und die zugehörige Struktur der Qualitätsregelkreise für die Fertigung bei der Verwendung von Mess- und Prüftechnik aufgezeigt. Es existiert jedoch noch keine Norm, die die Nutzung von maschinellem Lernen für die Qualitätssicherung in der Fertigung vorsieht. Folglich ist die Zertifizierung einer Qualitätsprognose auch noch nicht möglich. Erste vom VDE/VDI herausgegebene Richtlinien, die auf die Nutzung von Fertigungsdaten abzielen, befinden sich bisher lediglich im Entwurf, wie in Kapitel 2.5.1 beschrieben. Aus diesem Grund kann die hier entwickelte Qualitätsprognose, trotz der guten Prognoseergebnisse, die klassische Qualitätssicherung mittels Messtechnik nicht ablösen. Die Prognose der Werkstückqualität kann infolgedessen lediglich als eine zusätzliche, aber nicht zwingend notwendige Qualitätskontrolle angesehen werden. Im Folgenden sollen dennoch die strukturellen bzw. organisatorischen Auswirkungen auf die Qualitätsregelkreise, die von einer Qualitätssicherung mittels maschinellen Lernens ausgehen, dargestellt werden.

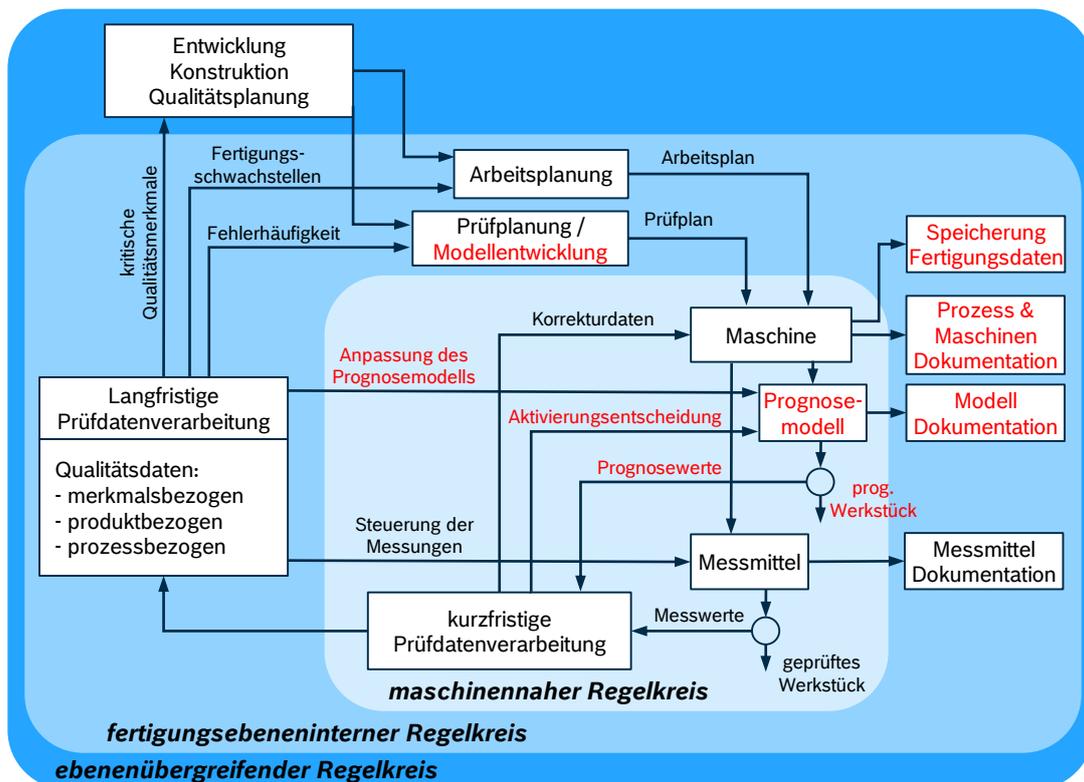


Abbildung 5-48: Qualitätsregelkreise bestehend aus Fertigungsmesstechnik und Prognosemodell

Die in Abbildung 5-48 dargestellten Regelkreise sind identisch mit den in Kapitel 2.2.1 präsentierten Regelkreisen und werden für die Qualitätsprognose um weitere Elemente ergänzt. Die hierdurch hinzukommenden Elemente bzw. Abhängigkeiten werden in roter Schrift in den Regelkreisen verdeutlicht. Ausgangspunkt ist die Ma-

schine, mit der die Bearbeitung der Werkstücke erfolgt. Mit einer im Prüfplan festgelegten Häufigkeit werden die Qualitätsmerkmale der Werkstücke mit den Messmitteln kontrolliert. Für die Stichprobenkontrolle müssen Werkstücke, physisch aus der Fertigung entnommen werden, um die Qualitätsmerkmale zu messen. Somit liegen am Ende geprüfte Werkstücke sowie die Messwerte vor. Parallel hierzu und unabhängig von einer Stichprobengröße kann ein trainiertes Prognosemodell basierend auf den Methoden des maschinellen Lernens, mittels der Fertigungsdaten die Qualitätsmerkmale eines jeden gefertigten Werkstückes prognostizieren. Die Ergebnisse sind Prognosewerte eines virtuell geprüften Werkstücks. Die auf beiden Arten erzielten Ergebnisse müssen für die weitere Datenverarbeitung unterscheidbar sein und separat geführt werden. Es muss also klar erkenntlich sein, ob die zu einem Werkstück gehörenden Qualitätsangaben gemessen oder prognostiziert wurden. Die Werte fließen schließlich in die kurzfristige Prüfdatenverarbeitung ein. Unabhängig von dem Wertesprung werden die Ergebnisse genutzt, um Korrekturen an der Maschine vorzunehmen, falls die Qualität nicht den Anforderungen entspricht. Dies kann z. B. der Wechsel eines Zerspanungswerkzeuges sein oder eine Nullpunktkorrektur. Liegen Mess- und Prognosewerte von demselben Werkstück vor, so kann ein Vergleich zwischen den beiden Werten die jeweils aktuelle Prognosegenauigkeit aufzeigen. In Abhängigkeit von der bestimmten Prognosegenauigkeit wird dann entschieden, ob das Prognosemodell weiterhin aktiv bleibt und die Qualität bestimmt oder ob es deaktiviert wird und entsprechende Anpassungen notwendig sind. Alle Mess- und Prognosedaten fließen in die langfristige Prüfdatenverarbeitung ein und werden u. a. für die Bewertung der Langzeitprognosegenauigkeit des Prognosemodells genutzt. Zum Beispiel lässt sich hierdurch ein Trend in den Prognoseabweichungen erkennen, der aufgrund von über die Zeit stattfindenden Maschinenveränderungen entsteht. Durch die gespeicherten Fertigungsdaten sowie die Messwerte ist dann ein erneutes Training der Methode des maschinellen Lernens durchführbar. Das Element des fertigungsebeneninternen Regelkreises, in dem die Prüfplanung festgelegt wird, übernimmt zusätzlich die Aufgabe der Modellentwicklung. Alle restlichen Elemente und Ebenen bleiben durch die Einführung einer Qualitätsprognose unverändert, können jedoch die Prognosewerte für die jeweilige Aufgabenerfüllung nutzen. Zu erwähnen ist, dass die Dokumentation der genutzten Mechanismen der Qualitätskontrolle insgesamt deutlich ausgeweitet werden muss. Eine Dokumentation der Maschinen-, Prozess- und Messmittelfähigkeit ist gegenwertiger Standard. Erfolgt nun die Qualitätskontrolle mittels maschinellen Lernens, so beruht diese auf den Fertigungsdaten und dem genutzten Algorithmus. Dies führt dazu, dass der Wechsel zu einem Werkzeug mit veränderter Geometrie und Schnittdaten das bis dahin verwendete Prognosemodell ungültig machen kann, da dieses mit Fertigungsdaten von dem früheren Werkzeugtyp trainiert wurde. Die Qualität am Werkstück mag sich durch eine solche Werkzeugumstellung nicht ändern und ruft daher auch kein Handeln bei der Qualitätskontrolle mit der Messtechnik hervor. Jedoch gilt dies nun nicht mehr für eine Qualitätsprognose. Dasselbe gilt z. B. auch, wenn bauliche Veränderungen an der Maschine durchgeführt werden oder eine Spindel getauscht wird. Aus diesem Grund muss eine strikte und konsequente Dokumentation zum Ersten von dem Sta-

tus Quo, mit dem das Training erfolgte, sowie zum Zweiten von allen auftretenden Veränderungen an Werkzeug, Maschine, Werkstück, Messmittel, etc. durchgeführt werden. Nur so kann eine plötzliche Prognoseabweichung nachvollzogen werden und zusammen mit den gespeicherten (somit auch dokumentierten) Fertigungsdaten ein angepasstes Prognosemodell erstellt werden. Wichtig ist auch die Dokumentation des Prognosemodells an sich sowie sein Entstehen. Einige Dokumentationspunkte sind z. B. der Zeitraum, aus dem die Trainingsdaten stammen, die verwendeten Datenquellen, die Abtastfrequenz, die berechneten Merkmale und die verwendeten Formeln, die Version des NC-Programms, das Messmittel, mit dem die Messwerte des Trainingsdatensatzes bestimmt wurden, die Größe des Trainingsdatensatzes, der Werkstücktyp, der Softwarestand, mit dem das Training durchgeführt wurde etc. Dies sind nur einige der möglichen Größen, die zu dokumentieren sind. Eine Hilfestellung bietet zudem die Auflistung in Kapitel 5.5.5. Ein geregeltes Vorgehen für die Dokumentation der verwendeten Hilfsmittel zur Qualitätssicherung ist in der ISO 9001:2015 festgehalten. Final soll festgehalten werden, dass die Qualitätskontrolle aus dem Fertigungsprozess heraus bestimmt wird und nicht anhand des vom Fertigungsprozess geschaffenen Werkstücks. Folglich muss auch der Fertigungsprozess eine Konstante aufweisen, die am besten dadurch erreicht wird, dass alle vom Anwender beeinflussbaren Parameter „eingefroren“ werden und es zu keiner ungeplanten Änderung von diesen kommt.

5.7.2 Implementierung auf dem Shopfloor bei der Bosch Rexroth AG

Die in dieser Arbeit entwickelte Qualitätsprognose erfolgt in enger Anlehnung an einen Bohr- und Reibprozess zur Fertigung von Hydraulikventilen. Für diesen Fertigungsprozess erfolgt schließlich eine Implementierung einer vollautomatischen Qualitätsprognose des Durchmessers inklusive Visualisierung mittels Dashboard auf dem Shopfloor. Die Implementierung beruht hierbei auf den in dieser Arbeit gewonnenen Erkenntnissen. Die Umsetzung ist als ein erster, jedoch bedeutender Schritt zu sehen, der zu mehr Transparenz über die Werkstückqualität in nahezu Echtzeit führt. Mittels Dashboard erfolgt die Visualisierung der Prognoseergebnisse und somit die Informationsübermittlung an den Maschinenbediener, welcher bei Qualitätsabweichungen regelnd in den Fertigungsprozess eingreifen kann. Zudem besteht die Möglichkeit, die Durchmesserprognosen an die Fertigungsplanung und in die Montage zu übermitteln. Hierdurch wird eine bessere Versorgung der Montagelinie mit den zu den einzelnen Ventilen passenden Komponenten ermöglicht.

In Abbildung 5-49 sind die Softwarekomponenten aufgeführt, die für die Verarbeitung der Fertigungsdaten sowie für die Prognoseerstellung und die Visualisierung notwendig sind. Die Implementierung baut auf der in dem Kapitel 5.3.1 eingeführten Datenerfassung bestehend aus NC-Steuerung, IOT Gateway und IPC auf. Da nun nur die Verarbeitung der Fertigungsdaten von Relevanz ist, ist die Betrachtung ausschließlich auf den IPC und die dort geschaffene Softwarearchitektur gerichtet. Die Fertigungsdaten liegen in der MongoDB in kontextualisierter Form vor und werden

von der Komponente „Merkmalsextraktion und Qualitätsprognose“ für die Prognosen herangezogen. Der hierfür ablaufende Prozess ist in der Abbildung 5-50 grob skizziert.

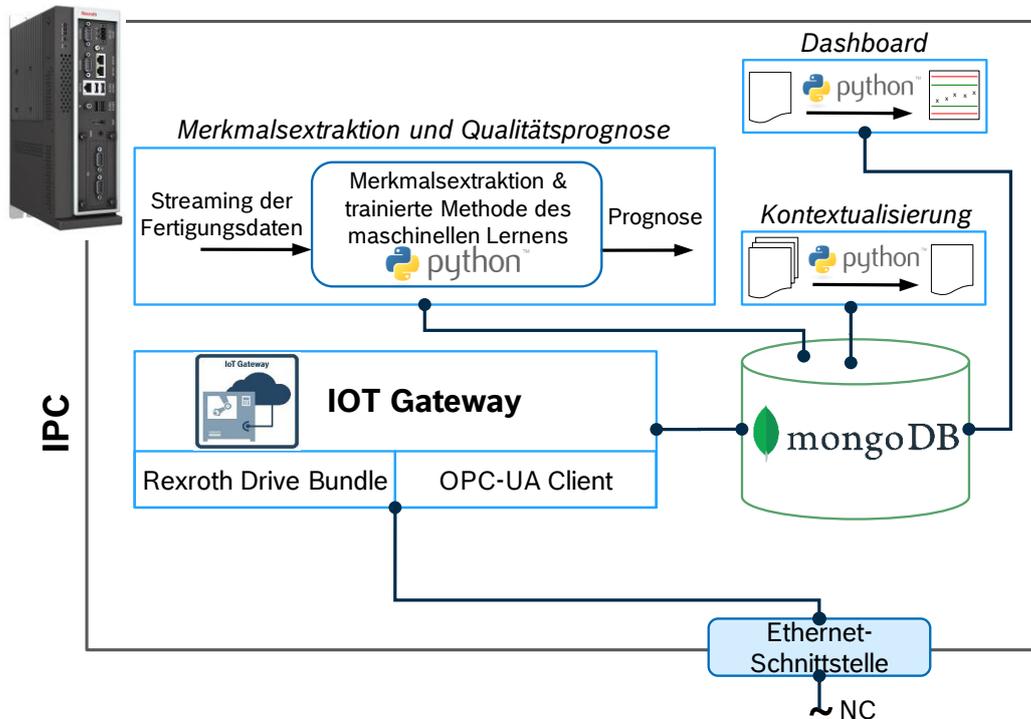


Abbildung 5-49: Verarbeitung der erfassten Fertigungsdaten für die Prognoseerstellung in Echtzeit

In Abhängigkeit von dem gefertigten Ventiltyp ist in dem in Python geschriebenen Code die für die Durchmesserprognose zu berücksichtigenden Werkzeuge, Datenquellen und die benötigten Merkmale hinterlegt. Nach der Berechnung der Merkmalswerte erfolgt eine Überprüfung mittels LDA (siehe Kapitel 5.4.2), ob der Fertigungsprozess sich im Normalzustand befindet. Als Normalzustand wird der Zustand verstanden, welcher von dem Trainingsdatensatz abgebildet wird und für den die Methode des maschinellen Lernens trainiert ist. Liegen die Werte für LD1 und LD2 außerhalb des definierten Wertebereiches, so kann keine zuverlässige Qualitätsprognose abgegeben werden und es wird ein Warnhinweis ausgegeben. Liegen die Werte jedoch innerhalb des Wertebereiches, dann wird die trainierte und gespeicherte Methode des maschinellen Lernens aufgerufen und die Qualitätsprognose durchgeführt. Die Prognoseergebnisse werden in der Datenbank gespeichert und stehen für den Abruf durch die Montage oder für die Anzeige auf dem Dashboard zur Verfügung. Der Prozess von der Datenerfassung über die Merkmalsextraktion und die Prognoseerstellung bis hin zu der Anzeige der Ergebnisse auf dem Dashboard ist vollkommen automatisiert und bedarf keines Eingriffes durch einen Mitarbeiter.

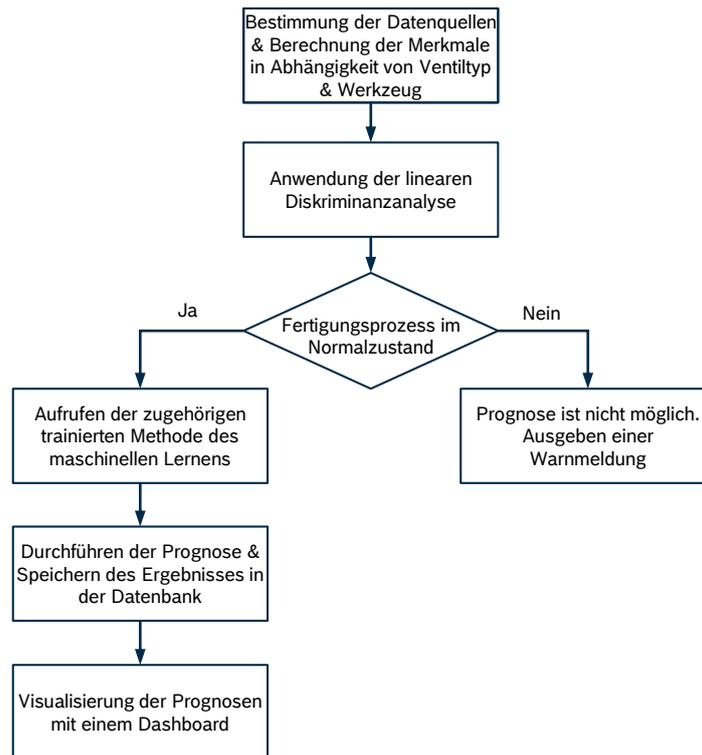


Abbildung 5-50: Ablaufdiagramm der Prognoseerstellung

In Abbildung 5-51 ist eine Ansicht des mit Python programmierten Dashboards dargestellt. Auf der linken Seite sind die Ventiltypen abgebildet, für die eine trainierte Methode für die Durchmesserprognose existiert. Durch klicken auf das Bild eines Ventiltyps erscheinen auf der rechten Seite die zugehörigen Durchmesserprognosen.

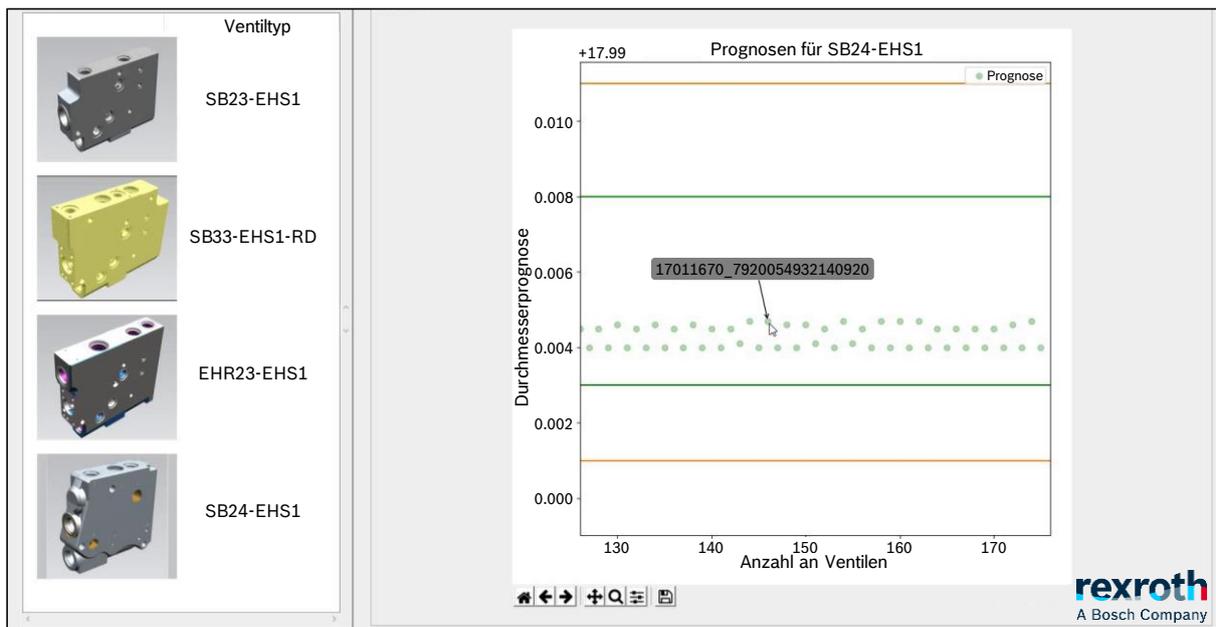


Abbildung 5-51: Dashboard mit der Ansicht: Verfügbare Ventiltypen und Prognosen für den Ventiltyp SB24-EHS1

Die Grafik enthält zwei orange horizontale Linien, die die Toleranzgrenzen markieren sowie zwei grüne Horizontale, welche den idealen Durchmesserbereich hervorheben. Die einzelnen Prognosen sind durch Punkte in der Grafik abgebildet und ein Trend bzw. die Lage der Durchmesserwerte in dem Toleranzbereich ist somit auf einen Blick erkennbar. Wird der Cursor über einen Punkt bewegt, so erscheint die zu der Prognose gehörende ID-Nummer des Ventils. Ausreißer lassen sich auf diese Weise schnell bestimmen und in der Produktionscharge finden. Zudem ist es möglich, die Prognosen zusammen mit den ID-Nummern als Liste anzuzeigen und zu exportieren.

6 Ableitung von ingenieurwissenschaftlichen Lehrsätzen

In Kapitel 4 erfolgte die Konzeption eines Vorgehensmodells für die Gestaltung einer prozessparallelen Qualitätsprognose mit Hilfe von Methoden des maschinellen Lernens. Die Detaillierung der einzelnen Stufen des Vorgehensmodells wurde in Kapitel 5 durchgeführt. Diese Detaillierung erfolgte für den konkreten Anwendungsfall des Bohrens und Reibens einer Bohrung. Der Anwendungsfall ermöglichte die Entwicklung von Erkenntnissen zu jeder einzelnen Stufe des Vorgehensmodells. Die einzelnen Stufen können auch als Phasen eines Projektes zur Einführung von maschinellem Lernen in der Fertigung verstanden werden. Die während der Detaillierung gewonnenen Erkenntnisse werden in diesem Kapitel für jede Stufe zusammengefasst und in möglichst generischer Form durch Lehrsätze wiedergegeben. Die Wahrscheinlichkeit einer Anwendung des Vorgehensmodells auf weitere Fertigungsverfahren und Qualitätsmerkmale kann hierdurch erhöht werden. Eine Diskussion der getroffenen Annahmen, der Vorgehensweise und der erzielten Ergebnisse erfolgt vor der Formulierung eines oder mehrerer Lehrsätze zu einer jeden Stufe.

Auf der ersten Stufe „Festlegung des Ordnungsrahmens & Definition des Zielzustandes“ wurde der Ordnungsrahmen, die Ventulfertigung sowie die Funktionsweise der betrachteten Ventilkomponente beschrieben und das Ziel definiert, welches in der Prognose von vier verschiedenen Qualitätsmerkmalen einer Bohrung besteht. Auf die Bohrungsqualität wirkende Einflussgrößen wurden ermittelt und in Abhängigkeit von ihrem Auftreten in drei verschiedene Systeme eingeteilt. Ein derartiges Vorgehen ist hilfreich, um die Komplexität zu durchdringen und ein erstes Modell für die Qualitätsprognose aufzustellen. In dieser Arbeit wurden nur die sich in kurzen Zyklen veränderten Komponenten (Werkzeuge, Gusscharge) berücksichtigt. Dies ist ein guter Schritt, um einen Nachweis zu erbringen, ob eine Prognose unter „Idealbedingungen“ überhaupt möglich ist. Um ein permanent zuverlässiges Prognosemodell zu erhalten, müssen auch die sich in längeren Zyklen verändernden Komponenten berücksichtigt werden. Diese lassen sich entweder durch die bereits erfassten Fertigungsdaten berücksichtigen, sodass das bestehende Modell nur kontinuierlich neu antrainiert werden muss, oder sie müssen durch zusätzliche Parameter in das Modell mit einfließen. Die Expertise des Fertigungsingenieurs ist zwingend notwendig, um die Komponenten, die Einflussgrößen und die Zusammenhänge auf die Qualität zu benennen. Auf dieser Basis lassen sich dann Systeme definieren und in Modelle überführen, indem Abbildungs-, Verkürzungs- und pragmatische Merkmale bestimmt werden. Für die Bewertung, ob maschinelles Lernen sich für den Anwendungsfall überhaupt eignet, ist etwas Fachwissen zu dem maschinellen Lernen hilfreich. Grundsätzlich folgt die erste Stufe einem Top-Down-Ansatz, bei dem bestmögliche Systeme in Abhängigkeit von einem Betrachtungshorizont zu definieren sind. Zu große oder zu kleine Systeme können die Prognosegüte negativ beeinflussen, sodass diese neu bestimmt werden müssen. Für die erste Stufe ergibt sich der Lehrsatz:

Die Definition von Subsystemen aus dem bestehenden System (Fertigungssystem) erfolgt, indem geeignete Systemgrenzen unter der Beachtung des Top-Down-Ansatzes und unter der Berücksichtigung von fachlicher (fertigungstechnischer) Expertise gewählt werden. Die anschließende Formulierung von Modellen geschieht durch das Festlegen von Abbildungs-, Verkürzungs- und pragmatischen Merkmalen.

Die Bezeichnung der zweiten Stufe „Herausstellung von Wirkzusammenhängen mittels fertigungstechnischen Wissens“ lässt bereits erahnen, dass die Expertise des Fertigungsingenieurs auf dieser Stufe von höchster Bedeutung ist. Ausgehend von den auf der ersten Stufe definierten Subsystemen, erfolgt nun die Bestimmung der zu erfassenden Größen (Daten), um die Subsysteme durch Modelle abzubilden. Die zu erfassenden Größen können am sinnvollsten bestimmt werden, indem die Ursachen-Wirkungs-Zusammenhänge weitestgehend bekannt sind. Für das in dieser Arbeit berücksichtigte und definierte Subsystem sind die System-, Stell-, Fertigungs- und Ergebnisgrößen für die Modellerstellung notwendig, wobei der Fokus hauptsächlich auf den Fertigungsgrößen liegt. Durch die Kenntnis der Ursachen-Wirkungs-Zusammenhänge zwischen Zerspanungsprozess und Werkstückqualität können die Fertigungsgrößen (Inputgrößen) abgeleitet werden, die die Kräfte widerspiegeln, welche einen Rückschluss auf die Qualität (Zielgröße) zulassen. Bei dieser Vorgehensweise wird jedoch unterstellt, dass alle Ursachen-Wirkungs-Zusammenhänge bekannt sind und diese auch über die Fertigungsgrößen erkennbar sind. Für einen Großteil der Zusammenhänge trifft dies sicher zu, jedoch hat das maschinelle Lernen den Charme, bisher noch unbekannte Zusammenhänge zu erkennen. Aus diesem Grund sollten auch die Fertigungsgrößen erfasst werden, die der Fertigungsingenieur nicht definitiv als irrelevant einstufen kann. Die finale Selektion der relevanten Fertigungsgrößen erfolgt auf der fünften Stufe. Wichtig ist hingegen, dass die erfassten Daten auch zu dem betrachteten Zerspanungsprozess gehören und den Moment der Bearbeitung abbilden. So sind z. B. die am Anfang und am Ende eines Zerspanungsprozesses auftretenden Peaks des Spindeldrehmomentes auf die Beschleunigung und das Bremsen der Spindel zurückzuführen und dürfen nicht für die Qualitätsprognose berücksichtigt werden. Zudem müssen Einflussgrößen bewertet und entsprechend erfasst werden, wenn diese die Fertigungsgrößen beeinflussen können. Der Einfluss der Werkzeugeinsatzzeit und der Gusscharge auf das Spindeldrehmoment wurde untersucht und es konnte nur ein Einfluss der Werkzeugeinsatzzeit festgestellt werden. Es kann jedoch vorkommen, dass der Guss einer Charge auch einmal außerhalb der üblichen Härte liegt und dass hierdurch die Prognosen verfälscht werden. Gegen einen solchen Fall bedarf es einer Absicherung im Regelbetrieb, die z. B. durch eine LDA erfolgen kann. Die zweite Stufe zeigt die Wirkzusammenhänge auf und beantwortet hierdurch die in Kapitel 3 aufgestellte erste Forschungsfrage. Zudem beantwortet sie teilweise die zweite Forschungsfrage, indem sie die für die Kontextualisierung notwendigen Daten nennt. Welche Daten und mit welcher Frequenz final aufgezeichnet werden müssen, kann auf der zweiten Stufe noch nicht beantwortet werden. Dies ist erst nach der Anwendung der Methoden des

maschinellen Lernens auf der fünften Stufe möglich. Dies zeigt den iterativen Charakter, der das maschinelle Lernen prägt. Der für die zweite Stufe abzuleitende Lehrsatz lautet:

Zur umfassenden Bestimmung von Ursachen-Wirkungs-Zusammenhängen und zur Festlegung von möglichen Inputgrößen für die Prognose der Zielgröße ist der Einsatz von fachspezifischem (fertigungstechnischem) Verständnis notwendig.

Die zu erfassenden Größen werden auf der Stufe „Datengewinnung, Datenspeicherung & Kontextualisierung“ des Vorgehensmodells mit verschiedenen Technologien erfasst. Die Erfassung der Fertigungsgrößen erfolgt mit der NC-Steuerung und den in der Maschine verbauten Sensoren. Die Datenerfassung sollte vorerst mit der maximal möglichen Abtastfrequenz erfolgen und erst nach den Analysen der fünften Stufe angepasst werden. Die bei modernen Bearbeitungszentren verbauten Sensoren sind hinsichtlich ihrer Auflösung und Sensitivität ausreichend, um ein Großteil der auftretenden Kräfte während der Zerspanung zu erfassen. Für sehr kleine Kräfte zwischen Werkzeug und Werkstück muss jedoch davon ausgegangen werden, dass diese nicht eindeutig in den Sensorwerten erkennbar sind bzw. im Rauschen untergehen. Der Grund hierfür kann in der Prozessdynamik sowie dem Trägheitsmoment und Dämpfungsverhalten der sich im Kraftfluss befindenden Maschinenkomponenten liegen. Sind die Sensoren der Maschine für den Anwendungsfall nicht ausreichend, so können zusätzliche Sensoren in die Maschine integriert werden, was jedoch den Aufwand deutlich erhöht. Die Auswahl der Datenquellen sollte zudem so erfolgen, dass die durch die Fertigungsgröße erfassten Effekte eindeutig der Zerspanung eines Werkstücks zugeschrieben werden können und keinen Einflüssen von parallelen Zerspanungsprozessen unterliegen. Aufgrund der zeitgleichen Zerspanung mit zwei Spindeln lässt sich diese Bedingung hier für manche Qualitätsmerkmale nicht erfüllen, worunter die Prognosegenauigkeit leidet. Bei der Durchführung der Qualitätsmessungen ist darauf zu achten, dass die Messmittel fähig sind und dass alle Trainings- sowie Validierungsdaten mit denselben Einstellungen bzw. Messprogrammen erzielt werden. Nur wenn die Input- und die Zielgrößen mit einer möglichst kleinen Abweichung vom „wahren“ Wert vorliegen, können die Zusammenhänge von der Methode des maschinellen Lernens bestmöglich abgebildet werden. Alle erfassten Daten müssen zudem über einen Zeitstempel verfügen, über den sie miteinander synchronisiert werden können. Zusammenfassend hat die Datenerfassung auf eine Art und Weise zu erfolgen, sodass die Daten für die weitere Verarbeitung und für den Einsatz der Methoden des maschinellen Lernens nutzbar sind. Für die Auswahl der Datenquellen und die Qualitätsmessung sind Kompetenzen aus dem Bereich der Fertigungstechnik notwendig. Für die Datenerfassung, die Datenspeicherung und die Kontextualisierung bedarf es Fachwissen zu der industriellen IT-Technik. Es lässt sich der Lehrsatz formulieren:

Bei der Auswahl der Datenquellen zur Erfassung der erforderlichen Größen ist auf eine realisierbare und wirtschaftliche Datenerfassung sowie auf eine Effekt-Eindeutige-Zuordnung zu achten. Die Datenerfassung setzt zudem eine umfassende Dokumentation und eine performante Speicherung voraus.

Die gespeicherten Daten werden auf der vierten Stufe „Merkmalsextraktion & Merkmalsselektion“ in eine Form gebracht, die von den Methoden des maschinellen Lernens verarbeitet werden kann. Die Extraktion und die Selektion mit der Hilfe von analytischen Methoden erfordert Fachwissen, welches eher dem maschinellen Lernen anstatt der Fertigungstechnik zuzuschreiben ist. Dieser Sachverhalt sowie die anfänglich nur schwer einzuschätzende Wichtigkeit eines Merkmales führen zu dem Lehrsatz:

Die Gewinnung und Verdichtung von Informationen aus den (Fertigungs-) Daten erfolgt mittels einer umfassenden Merkmalsextraktion und einer anschließenden Selektion der informativsten Merkmale. Dies wird durch den Einsatz von analytischen Berechnungsverfahren erzielt.

Die erhaltene Selektion von Merkmalen sollte dann zusätzlich von dem Fertigungsingenieur auf ihre Sinnhaftigkeit überprüft werden. Merkmale mit kausalen Beziehungen zur Zielgröße sollten dabei stets bevorzugt berücksichtigt werden. Grundsätzlich sollte das menschliche Urteilsvermögen nicht überschätzt werden, da oftmals die Komplexität und die Zusammenhänge nicht in voller Tiefe vom Menschen erkannt werden. Aus diesem Grund werden (in dieser Arbeit) die Methoden des maschinellen Lernens eingesetzt und kein analytisches, physikalisches Modell entwickelt, für das die Zusammenhänge eindeutig bestimmt und bekannt sein müssen. Der Lehrsatz, der sich hieraus ableitet, lautet:

Die selektierten Merkmale sollen hinsichtlich ihrer Sinnhaftigkeit für die Prognose der Zielgröße kritisch bewertet werden, indem der Unterschied zwischen Kausalität und Korrelation sowie das begrenzte menschliche Wissen beachtet werden.

Die dritte und die vierte Forschungsfrage lassen sich mit den Ergebnissen der vierten Stufe zum größten Teil beantworten. Eine vollständige Beantwortung ist jedoch erst nach der Anwendung des maschinellen Lernens möglich, da erst dann bekannt ist, welche Merkmale in Kombination mit den einzelnen Methoden die besten Prognosen erzielen.

Die extrahierten Merkmale werden schließlich auf der fünften Stufe „Einsatz der Methoden des maschinellen Lernens“ für das Training der Methoden sowie für die Prognoseerstellung genutzt. Das benötigte Fachwissen kommt hierfür hauptsächlich

aus dem Bereich des maschinellen Lernens. Fertigungstechnisches Wissen ist jedoch hilfreich für die Beurteilung der Prognosegenauigkeit und für die Bewertung der ausgewählten Datenquellen. Jede Methode muss individuell für die zu prognostizierende Zielgröße sowie für die verwendeten Merkmale parametrisiert werden. Diese Bedingung wird mit dem ersten von insgesamt vier Lehrsätzen der fünften Stufe wiedergegeben:

Für jede Methode des maschinellen Lernens sowie für jede Kombination aus Merkmalsgruppe und Zielgröße hat eine individuelle Parameteroptimierung zu erfolgen.

Die Bewertung der Prognosegenauigkeit und die damit verbundenen Entscheidungen sollten auf einer validen Basis getroffen werden, sodass nicht nur ein Kennwert, sondern mehrere Kennwerte (z. B. MAE, MAX, R^2 , Verteilung) berechnet werden sollten. Zudem sollte die Prognosegenauigkeit der ausgewählten Methode mit einem Validierungsdatensatz überprüft werden.

Die Beurteilung der Prognosegenauigkeit, der Vergleich der verschiedenen Methoden sowie die Auswahl der am besten geeigneten Methode sind auf mehrere berechnete Kennwerte zu stützen. Die Auswahl der Methode erfolgt anhand der Prognosen des Testdatensatzes und wird mit den Prognosen des Validierungsdatensatzes auf Generalisierbarkeit hin überprüft.

Die Feinabstimmung der Methode sowie eine Effizienzoptimierung der Qualitätsprognose, indem nur die notwendigen Eingangsgrößen, Abtastfrequenzen etc. berücksichtigt werden, kann mit Hilfe von Lernkurven erfolgen:

Die Bestimmung der bestmöglichen Kombination aus Datenquelle, Abtastfrequenz und Merkmalsgruppe erfolgt durch das Erstellen und das Studieren von Lernkurven.

Anhand der Steigung der Trainingskurve kann der Trainingsfortschritt abgelesen werden und z. B. bewertet werden, ob die Trainingsdatenmenge für das Erlernen der Zusammenhänge ausreicht oder noch weitere Trainingsdaten notwendig sind, jeweils bezogen auf den geforderten Geltungsbereich der Prognosen. Ist durch die Hinzugabe von weiteren Trainingsdaten keine Verbesserung der Prognosegenauigkeit zu erwarten, so sind die bis dahin getroffenen Entscheidungen zu überdenken. Der letzte Lehrsatz der fünften Stufe lautet somit:

Das Training einer Methode wird für einen gegebenen Datensatz als abgeschlossen angesehen, wenn die Steigung der Trainingskurve gleich null ist. Ist der Progno-

sefehler des Testdatensatzes für die trainierte Methode zu groß, so bedarf es einer sukzessiven Anpassung der bis dahin getroffenen Entscheidungen, beginnend bei der Wahl und Parametrierung der Methode des maschinellen Lernens bis hin zur Definition des Modells.

Die Lehrsätze der fünften Stufe führen zu Ergebnissen, die die in Kapitel 3 aufgestellten Forschungsfragen zwei bis sieben beantworten. Somit werden die meisten Fragen auf der Stufe beantwortet, welche den Einsatz des maschinellen Lernens adressiert. Dies ist nicht verwunderlich, da die meisten Forschungslücken hinsichtlich der Nutzung und Integration von maschinellem Lernen in der Fertigung existieren.

Die „Validierung der Prognosegüte“ ist die Aufgabe der sechsten Stufe des Vorgehensmodells. Die Validierung erfolgt mit den Kennwerten der fünften Stufe, indem diese in Bezug zu der Zielgröße bzw. der Fertigungstoleranz gesetzt werden. Somit kann eine Art Sicherheitsfaktor bestimmt werden, der angibt, wie viel Prozent der Qualitätstoleranz von dem Prognosefehler beansprucht wird. Zudem werden die in der Fertigung bekannten und etablierten Qualitätsbewertungsmethoden eingesetzt, sodass eine Vergleichbarkeit mit den Ergebnissen der Standardverfahren gegeben wird. Folglich erfolgt die Validierung auf zwei Weisen, was eine hohe Sicherheit sowie Akzeptanz schaffen soll. Die verbliebene, letzte Forschungsfrage aus Kapitel 3 wird hiermit beantwortet. Der abgeleitete Lehrsatz lautet:

Die Validierung der Prognosegüte erfolgt zum Ersten durch das Herstellen eines Bezuges der zuvor verwendeten Kennwerte zu der Toleranz der Zielgröße sowie zum Zweiten durch die in dem Anwendungsfall (Fertigungstechnik) etablierten Qualitätsbewertungsmethoden.

Mit der letzten Stufe erfolgt die „Implementierung in die Fertigung“. Hierfür sind die auf dem Shopfloor vorzufindenden Bedingungen zu beachten und die Hard- sowie Software entsprechend auszulegen. Zur Überwachung der Langzeitstabilität der Prognosegüte müssen Regelkreise initiiert werden. Zudem ist darauf zu achten, dass die Qualitätsprognose die Mitarbeiter bei ihrer Arbeit unterstützt und keinen zusätzlichen Mehraufwand bedeutet. Die Formulierung des letzten Lehrsatzes lautet somit:

Die Implementierung der Qualitätsprognose in die Fertigung erfolgt, indem die Bedingungen auf dem Shopfloor berücksichtigt werden, eine Integration in die Regelkreise des Qualitätsmanagements stattfindet und die Akzeptanz der involvierten Mitarbeiter erreicht wird.

7 Zusammenfassung und Ausblick

7.1 Zusammenfassung

Der stattfindende Trend einer Produktindividualisierung führt zu einem Anstieg an Produktvarianten, wodurch die zu fertigende Losgröße sinkt. Darauf hat die fertigende Industrie mit einer Flexibilisierung der Fertigungslinien reagiert, kann jedoch das erreichte Leistungsniveau mit der bisher eingesetzten Technologie kaum noch steigern. An dieser Stelle bietet der Einsatz von maschinellem Lernen neue Möglichkeiten, um die Fertigung hinsichtlich Qualität, Produktivität und Ressourcenverbrauch auf ein höheres Leistungsniveau zu heben.

In der vorliegenden Arbeit wurde das maschinelle Lernen zur Prognose der Qualität von geriebenen Bohrungen eingesetzt. Die Prognosen basierten hierbei auf den von der NC-Steuerung intern erfassten und bereitgestellten Fertigungsdaten. Die Qualitätsprognosen konnten hierdurch ohne die Integration von zusätzlichen Sensoren und parallel zum Fertigungsschritt erzielt werden. Die Entwicklung der Qualitätsprognosen erfolgte für die Fertigung von Hydraulikventilen bei der Bosch Rexroth AG und fokussierte sich auf die Fertigungsverfahren Bohren und Reiben. Das maschinelle Lernen stellt für die Fertigungstechnik eine noch weitgehend unbekannte Technologie dar. Aus diesem Grund wurde in dieser Arbeit das Funktionsprinzip dieser Technologie in der notwendigen Tiefe sowie verschiedene Methoden des maschinellen Lernens erläutert. Zudem wurde ein Vorgehensmodell vorgestellt, welches bei der Implementierung einer auf maschinellem Lernen beruhenden Qualitätsprognose unterstützen soll. Das Vorgehensmodell besteht aus sieben Stufen, welche von der Definition des Ausgangs- und Zielzustandes über die Anwendung von maschinellem Lernen bis zur Implementierung der Qualitätsprognose in die Fertigung unterstützen. Zudem werden die für jede Stufe notwendigen Kompetenzen aufgezeigt, die sich grob einteilen lassen in Fertigungstechnik, maschinelles Lernen und industrielle IT. Erst ihr Zusammenwirken ermöglicht das Erreichen eines höheren Leistungsniveaus in der Fertigung. Das Vorgehensmodell wurde auf der Basis der gesammelten Erfahrungen bei der Implementierung des maschinellen Lernens in die Fertigung von Bosch Rexroth erstellt und weist daher eine hohe Praxistauglichkeit auf. Die Detaillierung einer jeden Stufe führte zu Erkenntnissen, welche in Lehrsätze überführt wurden. Das generisch gestaltete Vorgehensmodell zusammen mit den Lehrsätzen soll die Einführung einer Qualitätsprognose auch für Fertigungsverfahren ermöglichen, welche in dieser Arbeit nicht betrachtet wurden.

Zu den Erkenntnissen, die durch die Detaillierung gewonnen werden konnten, zählt z. B. die Feststellung, dass das fertigungstechnische Wissen auf jeder Stufe des Vorgehensmodells einen hohen Stellenwert hat. Auch für die Stufen, die ausschließlich die Merkmalsextraktion und -selektion sowie das maschinelle Lernen umfassen, ist das fertigungstechnische Wissen für das Erreichen von genauen Prognosen von essentieller Wichtigkeit. Die in Bezug auf maschinelles Lernen oftmals vertretene Meinung, dass die geeignetsten Merkmale ausschließlich über eine Datenanalyse

bestimmt werden können bzw. dies ausreichend ist, konnte nicht bestätigt werden. So wurde von der Merkmalsselektion die Merkmale der Achsposition als besonders wichtig für die Durchmesserprognose eingestuft, obwohl der Durchmesser von der Achsposition aus fertigungstechnischer Sicht unabhängig ist. Das fertigungstechnische Verständnis hat dann aufgedeckt, dass nur ein zufälliger Zusammenhang zwischen gefertigtem Durchmesser und den Achspositionen, aufgrund der von der Maschine durchgeführten Temperaturkompensation, besteht. Das Ausgrenzen der Achspositionen führte für den Validierungsdatensatz zu deutlichen besseren Prognosewerten. Für den Trainings- und Testdatensatz blieben die Prognosewerte hingegen identisch. Dies zeigt, dass das Prognosemodell die tatsächlichen physikalischen Zusammenhänge zwischen den verbliebenen Fertigungsdaten und den Durchmesserwerten erlernen konnte, sobald es nicht mehr die Positionen mitgeteilt bekam. Eine werkstückindividuelle Prognose der Rundheit und Geradheit war hingegen nicht möglich. Dies lag sehr wahrscheinlich an dem Sachverhalt, dass die für die Qualitätsabweichung relevanten radial wirkenden Kräfte, aufgrund der parallelen Zerspannung mit zwei Spindeln, nicht individuell zu jedem Werkstück erfassbar waren. Es kann jedoch auch daran gelegen haben, dass die radialen Kräfte nicht groß genug waren, um entsprechende Positionsabweichungen der radial zur Vorschubsrichtung liegenden Achsen hervorzurufen. Dennoch wurden Ergebnisse erzielt, die in etwa dem Durchschnittswert der gemessenen Rundheit oder Geradheit von zwei parallel zerspannten Werkstücken entsprechen. Für alle Qualitätsmerkmale konnten Prognosen erzielt werden, die eine Abweichung von nur wenigen μm aufwiesen und somit für den betrachteten Anwendungsfall vollkommen zufriedenstellend waren. Die Trainingsdatenmenge sowie die Verteilung der Messwerte über den betrachteten Wertebereich beeinflusste jedoch die Prognosegenauigkeit. Ab einer Trainingsdatenmenge von ca. 300 Werkstücken nahm die Trainingskurve allmählich eine Steigung von null ein, was auf ein Ende des Lernens hindeutet. Weitere Trainingsdaten werden jedoch als positiv erachtet, um die Prognosefehler noch weiter zu reduzieren. Insbesondere, wenn sich der Messwertebereich vergrößert oder Veränderungen an der Maschine oder dem Prozess eintreten, bedarf es weiterer Trainingsdaten.

Eine Vielzahl von verschiedenen Methoden des maschinellen Lernens wurden auf ihre Eignung für den Anwendungsfall hin überprüft, doch nur die Methoden GBR und RFR aus der Gruppe der Ensemble Methoden brachten zufriedenstellende Prognosen hervor. Die Auswahl der Methoden erfolgte anhand von mehreren Kennzahlen und wurde mit einem Validierungsdatensatz überprüft. Für die Erfassung der Fertigungsdaten wurde eine Abtastfrequenz von 500 Hz als ausreichend befunden. Wird die Abtastfrequenz reduziert, so steigt der Prognosefehler in Abhängigkeit von dem Qualitätsmerkmal unterschiedlich stark an. Von den erfassten Fertigungsdaten wurden Merkmale aus dem Zeit- und Frequenzbereich extrahiert, welche die besten Prognosewerte hervorbrachten und zugleich die kürzeste Berechnungsdauer von allen getesteten Merkmalsextraktionsverfahren benötigten.

Die Validierung der Prognoseergebnisse erfolgte mit für das maschinelle Lernen üblichen Kennwerten sowie von dem Qualitätsmanagement eingesetzten Verfahren zur

Untersuchung der Messmittelfähigkeit. Beide Vorgehensweisen mussten leicht angepasst werden, damit sie für eine Validierung genutzt werden konnten. Die Kennzahlen wurden ins Verhältnis zu den Toleranzen der Qualitätsmerkmale gesetzt, um die Prognosegenauigkeit zu beurteilen. Die Verfahren zur Untersuchung der Messmittelfähigkeit mussten auf das maschinelle Lernen angepasst werden, um einen Fähigkeitsnachweis zu erhalten. Obwohl die Fähigkeit der Qualitätsprognose mit den Verfahren des Qualitätsmanagements bestätigt werden konnte, kann sie nicht als Ersatz für die Qualitätssicherung mit industrieller Messtechnik verwendet werden. Grund hierfür sind „noch“ fehlende Normen sowie Rechtssicherheit.

Dennoch wurde eine Implementierung auf dem Shopfloor durchgeführt. Die Durchmesserwerte der einzelnen Ventilgehäuse werden prognostiziert sowie auf einem Dashboard dem Maschinenbediener angezeigt. Diese Installation gilt als zusätzliche Informationsquelle und ersetzt keine bestehende Qualitätskontrolle.

7.2 Ausblick

Die entwickelte prozessparallele Qualitätsprognose kann als ein Beispiel verstanden werden, welches die Möglichkeiten des Einsatzes von maschinellem Lernen in dem Fertigungsumfeld aufzeigt. Die implementierte Qualitätsprognose liefert vollautomatisiert solide Durchmesserprognosen, dennoch kann die Stabilität der Prognosegenauigkeit erst durch eine Langzeitstudie bewertet werden. Denkbar ist eine Abweichung der Prognosen über die Zeit aufgrund stattfindender Abnutzungserscheinungen an der Maschine. Ein Prognosemodell, welches permanent an die sich ändernden Umstände angepasst wird, stellt eine Weiterentwicklung des bisher Erreichten dar. Möglich wäre dies, indem die aus der Stichprobenkontrolle anfallenden Messwerte den ursprünglichen Trainingsdatensatz ergänzen und somit die Aktualität des Prognosemodells sichern. Mit einem größeren Trainingsdatensatz sowie mit eventuell zusätzlich hinzukommenden Fertigungsgrößen kann auch der Einsatz von Methoden, die nicht zu den Ensemble Methoden zählen, möglich werden.

Grundsätzlich wird durch die Qualitätsprognose eine Transparenzsteigerung erreicht, die dazu führt, dass Informationen von einem ganz neuen Umfang sowie Aktualität zur Verfügung stehen. Diese Informationen können eine weitere Optimierung bewirken, indem z. B. die Einsatzzeit eines jeden Zerspanungswerkzeuges individuell bestimmt wird und nicht einem für alle Werkzeuge gleichen Vorgabewert folgt. Die Maschine könnte zudem automatisch einen Werkzeugwechsel durchführen, sobald eine Toleranzgrenze erreicht wird. Die Kenntnis der Qualität zu jedem einzelnen Werkstück in einem frühen Fertigungszeitpunkt ermöglicht zudem die bessere Planung der kompletten Fertigungskette sowie des Wertstroms. So ließe sich in dem Beispiel der Ventulfertigung der prognostizierte Durchmesserwert dazu nutzen, ein Ventil erst in die Montage einzuplanen, wenn auch alle benötigten Komponenten vorrätig sind, um die geforderte Passung zu erreichen. Das Messen des Durchmessers in der Montage könnte somit hinfällig werden und mögliche Bandstillstände aufgrund fehlender Komponenten würden verhindert werden. Die anfänglich erwähnte steigende

Produktindividualisierung führt auch zwangsläufig zu einer Vielzahl von zusätzlichen Komponenten in der Montage, die entweder selbst hergestellt oder zugekauft werden. Aufgrund der Vielzahl von unterschiedlichen Komponenten ist eine Bevorratung in der Nähe der Montage kaum noch wirtschaftlich, sodass die Prognoseergebnisse dazu genutzt werden können, die benötigten Komponenten zu fertigen oder zu bestellen und sie somit bei Montagebeginn vorliegen zu haben. Die Transparenzsteigerung könnte damit zu einer effizienteren Abstimmung der Wertströme führen.

Die Entwicklungen, die in dem Bereich des Transfer Learning stattfinden, lassen darauf hoffen, dass ein trainiertes Modell, welches bisher nur für die Prognose eines Qualitätsmerkmals eines bestimmten Ventiltyps an Gültigkeit besitzt, mit überschaubarem Aufwand auf weitere Ventiltypen übertragen werden kann.

Um auch das Potential zu realisieren, welches in der Einsparung der Stichprobenkontrolle mit industrieller Messtechnik liegt, bedarf es der rechtlichen Grundlage. Bis jetzt existiert noch keine Norm und keine Zertifizierung, um die Fertigungsqualität ausschließlich über maschinelles Lernen abzusichern. Es wird sehr wahrscheinlich noch Zeit und viel Forschungseinsatz benötigt, um eine valide Basis von Erkenntnissen zu schaffen, die eine Zertifizierung befürworten könnte. In diesem Punkt spielen die Forschungstätigkeiten zu der Thematik Explainable Artificial Intelligence (XAI) eine entscheidende Rolle. XAI versucht den Entscheidungsprozess und damit die Prognoseerzeugung von Black-Box-Modellen nachvollziehbar und transparent zu machen. Dies ist ein bedeutender Schritt, um die benötigte Akzeptanz für das maschinelle Lernen zu erreichen sowie den Prognosen zu vertrauen.

8 Literaturverzeichnis

- [AIAG10] AIAG Core Tools, Measurement System Analysis (MSA), 4. Aufl. 2010
- [BACK16] Backhaus, K.; Erichson, B.; Plinke, W.; Weiber, R.: Multivariate Analysemethoden. 14. Aufl. Berlin: Springer, 2016
- [BARA20] Barandas, M.; Folgado, D.; Fernandes, L.; Santos, S.; Abreu, M.; Bota, P.; Liu, H.; Schultz, T.; Gamboa, H.: TSFEL: Time Series Feature Extraction Library. In: SoftwareX. 11. Jg., 2020, Aufs. 100456, S.1-7
- [BERG20] Berg, A.: Industrie 4.0 - so digital sind Deutschlands Fabriken. URL: <https://www.bitkom-research.de/de/pressemitteilung/industrie-40-so-digital-sind-deutschlands-fabriken> [Stand: 12.01.2020]
- [BIAU12] Biau, G.: Analysis of a Random Forests Model. In: Journal of Machine Learning Research. 13. Jg., 2012, S. 1063–1095
- [BINS09] Binsaeida, S.; Asfoura, S.; Chob, S.; Onarc, A.: Machine ensemble approach for simultaneous detection of transient and gradual abnormalities in end milling using multisensor fusion. In: Journal of Materials Processing Technology. 209. Jg., 2009, S. 4728–4738
- [BOSC21] Bosch Rexroth AG
- [BOX09] Box, G. E. P.; Luceño, A.; Paniagua-Quiñones, M. d. C.: Statistical control by monitoring and feedback adjustment. 2. Aufl., Oxford: Wiley-Blackwell, 2009
- [BRAN19] Brandstätter, T. C.; Krauß, J.; Schmitt, R. H.: Certification of AI-Supported Production Processes. Zertifizierung von KI-gestützten Produktionsprozessen. In: Wulfsberg, J. P.; Hintze, W.; Behrens, B.-A. (Hrsg.): Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP). Berlin: Springer Vieweg, 2019, S. 553–562
- [BREC17] Brecher, C.; Broos, A.; Butz, F.; Epple, A.; Fey, M.; Kaefer, M.; Köhler, W.; Königs, M.; Lange, M.; Neus, S.; Queins, M.; Runde, S.; Weingold, M.; Wellmann, F.; Wille, H.; Zapf, B.: Nutzen und Potenziale modellbasierter Datenanalyse. In: Schuh, G. (Hrsg.): Internet of Production für agile Unternehmen. AWK Aachener Werkzeugmaschinen-Kolloquium 2017. 1. Aufl. Aachen: Apprimus Verlag, 2017, S. 163–195
- [BREC20] Brecher, C.; Biernat, B.; Fey, M.; Ochel, J.; Wiesch, M.: Analytics in der Produktion. In: Schuh, G. (Hrsg.): Internet of Production - Turning Data into Value. Statusberichte aus der Produktionstechnik 2020. Aachen: Fraunhofer-Gesellschaft, 2020, S. 186–208
- [BREC15] Brecher, C.; Daniels, M.; Wellmann, F.; Neus, S.; Epple, A.: Realisierung effizienter Zerspanprozesse. Ergebnisbericht des BMBF Verbundprojekts ReffiZ. Aachen: Shaker, 2015

- [BREC19] Brecher, C.; Wiesch, M.; Neus, S.: Prozessparallele Qualitätssicherung in der spanenden Fertigung. URL: <https://werkstoffzeitschrift.de/prozessparallele-qualitaetssicherung-in-der-spanenden-fertigung/> [Stand: 30.04.2020]
- [BREI01] Breiman, L.: Random Forests. In: Machine Learning. 45. Jg., 2001, S. 5–32
- [BRET18] Bretz, A.; Geßner, F.; Öztürk, T.; Rinn, C.; Abele, E.: Adjustment of Axis Offset Errors during Reaming. In: Applied Mechanics and Materials. 885. Jg., 2018, S. 267–275
- [BRIN09] Brinkhaus, J.-W.: Statistische Verfahren zur selbstlernenden Überwachung spanender Bearbeitungen in Werkzeugmaschinen. Dissertation, Gottfried Wilhelm Leibniz Universität, Hannover, 2009
- [BRUN91] Bruns, M.: Systemtechnik. Methoden zur interdisziplinären Systementwicklung. Berlin: Springer, 1991
- [BUND20] Strategie Künstliche Intelligenz der Bundesregierung. Fortschreibung 2020, 12/2020
- [BUXM19] Buxmann, P.; Schmidt, H.: Künstliche Intelligenz. Mit Algorithmen zum wirtschaftlichen Erfolg. 1. Aufl. Berlin: Springer Gabler, 2019
- [CHRI17] Christ, M.; Kempa-Liehr, A. W.; Feindt, M.: Distributed and parallel time series feature extraction for industrial big data applications. URL: <http://arxiv.org/pdf/1610.07717v3> [Stand: 23.05.2017]
- [CHRI18] Christ, M.; Braun, N.; Neuffer, J.; Kempa-Liehr, A. W.: Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package). In: Neurocomputing. 307. Jg., 2018, S. 72–77
- [CHRI20] Christ, M.: tsfresh. URL: <https://tsfresh.readthedocs.io/en/latest/> [Stand: 28.06.2020]
- [CLEV16] Cleve, J.; Lämmel, U.: Data mining. Berlin: De Gruyter Studium, 2016
- [CUTL12] Cutler, A.; Cutler, D. R.; Stevans, J. R.: Random Forests. In: Zhang, C.; Ma, Y. (Hrsg.): Ensemble machine learning. Methods and applications. New York: Springer, 2012, S. 157–175
- [DENK11] Denkena, B.; Tönshoff, H. K.: Spanen. Grundlagen. Berlin: Springer, 2011
- [DIET14] Dietrich, E.: Messmanagementsystem / Prüfmittelmanagement. In: Pfeifer, T.; Schmitt, R. (Hrsg.): Masing Handbuch Qualitätsmanagement. 6. Aufl. München: Hanser, 2014, S. 714–729
- [DIET17] Dietrich, E.; Schulze, A.: Eignungsnachweis von Prüfprozessen. Prüfmittelfähigkeit und Messunsicherheit im aktuellen Normenumfeld. 5. Aufl. München: Hanser, 2017

- [DIN 03a] DIN 8589-2 (September, 2003). Fertigungsverfahren Spanen – Teil 2: Bohren, Senken, Reiben – Einordnung, Unterteilung, Begriffe
- [DIN 03b] DIN 8580 (September, 2003). Fertigungsverfahren – Begriffe, Einteilung
- [DIN 03c] DIN EN ISO 10012 (2003). Messmanagementsysteme – Anforderungen an Messprozesse und Messmittel
- [DIN15] DIN EN ISO 9000 (2015). Qualitätsmanagementsysteme – Grundlagen und Begriffe
- [DIN19] DIN ISO 22514-2 (Juli, 2019). Statistische Verfahren im Prozessmanagement – Fähigkeit und Leistung – Teil 2: Prozessleistungs- und Prozessfähigkeitskenngrößen von zeitabhängigen Prozessmodellen
- [DIN88] DIN 44300 (1988). Informationsverarbeitung - Begriffe Verarbeitungsabläufe
- [DROZ83] Drozda, T.; Wick, C.; Benedict, J. T.; Veilleux, R. F.; Bakerjian, R.: Tool and manufacturing engineers handbook. A reference book for manufacturing engineers, managers, and technicians. 4. Aufl. Dearborn: Society of Manufacturing Engineers, 1983
- [DUDE21] Duden: Die Echtzeit. URL: <https://www.duden.de/rechtschreibung/Echtzeit> [Stand: 12.01.2021]
- [ENNE19] Ennen, P.; Pabisch, E.; Kupper, R.; Benmoussa, P.; Vossen, R.: Leitfaden Selbstlernende Produktionsprozesse. Einführungsstrategie für Reinforcement Learning in der industriellen Praxis. Frankfurt am Main: VDMA Forum Industrie 4.0, 2019
- [FAYY96] Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P.: Knowledge Discovery and Data Mining: Towards a Unifying Framework. In: Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, 1996, S. 82–88
- [GEVA06] Gevatter, H.-J.; Grünhaupt, U.: Mess- und Automatisierungstechnik in der Produktionstechnik. 2. Aufl. Berlin: Springer, 2006
- [GORE17] Gorecky, D.; Hennecke, A.; Schmitt, M.; Weyer, S.; Zühlke, D.: Wandelbare modulare Automatisierungssysteme. In: Reinhart, G. (Hrsg.): Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik. München: Hanser, 2017, S. 555–583
- [GROB20] Grob: G320 Modulares Bearbeitungszentrum. URL: <https://www.grobgroup.com/produkte/produktbereiche/systemloesungen/bearbeitungszentren/g320/> [Stand: 18.12.2020]
- [GÜNT17] Günther, S.; Salmen, M.; Jussen, P.; Riesener, M.; Zeller, V.; Hensen, T.; Be-govic, A.; Birkmeier, M.; Hocken, C.; Jordan, F.; Kantelberg, J.; Kelzenberg, C.; Kolz, D.; Maasem, C.; Siegers, J.; Stark, M.; Tönnies,

- C.: Geschäftsmodell-Innovation. In: Reinhart, G. (Hrsg.): Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik. München: Hanser, 2017, S. 3–29
- [GUYO06] Guyon, I.; Gunn, S.; Nikravesh, M.; Zadeh, L.: Feature extraction. Foundations and applications. Berlin: Springer, 2006
- [HABE12] Haberfellner, R.: Systems Engineering. Grundlagen und Anwendung. 12. Aufl. Zürich: Orell Füssli, 2012
- [HEHE20] Hehenberger, P.: Computerunterstützte Produktion. Eine kompakte Einführung. 2. Aufl. Berlin: Springer Vieweg, 2020
- [HEID19] Heidenhain: Längenmessgeräte für gesteuerte Werkzeugmaschinen. Traunreut, 06.2019
- [HELW17] Helwig, N.; Merten, P.; Schneider, T.; Schütze, A.: Integrated Sensor System for Condition Monitoring of Electromechanical Cylinders. In: Proceedings Eurosensors Paris 2017. 1. Jg., 2017, Aufs. 626, S. 1-4
- [HERI10] Hering, E.: Sensoren. Funktionsweise und Einsatzgebiete. 1. Aufl. Wiesbaden: Springer Vieweg, 2010
- [HESS14] Hesse, S.: Sensoren für die Prozess- und Fabrikautomation. 6. Aufl. Wiesbaden: Springer Vieweg, 2014
- [HOPP19] Hoppe, F.; Hohmann, J.; Knoll, M.; Kubik, C.; Groche, P.: Feature-based Supervision of Shear Cutting Processes on the Basis of Force Measurements: Evaluation of Feature Engineering and Feature Extraction. In: Procedia Manufacturing. 34. Jg., 2019, S. 847–856
- [INF120] infineon: TLI4971 high precision coreless current sensor for industrial applications in 8x8mm SMD package. München, 09.03.2020
- [JESC19] Jeschke, S.: Leitfaden Selbstlernende Produktionsprozesse. Einführungsstrategie für Reinforcement Learning in der industriellen Praxis. In: VDMA Forum Industrie 4.0 (Hrsg.): Leitfaden Selbstlernende Produktionsprozesse. Einführungsstrategie für Reinforcement Learning in der industriellen Praxis. Frankfurt am Main, 2019, S. 3
- [JOSH20] Joshi, A. V.: Machine Learning and Artificial Intelligence. Cham: Springer, 2020
- [KEFE17] Keferstein, C. P.; Marxer, M.; Bach, C.: Fertigungsmesstechnik. Alles zu Messunsicherheit, konventioneller Messtechnik und Multisensorik. 9. Aufl. Wiesbaden: Springer Vieweg, 2017
- [KESS07] Kessler, W.: Multivariate datenanalyse. Für die pharma-, bio- und prozessanalytik : Ein Lehrbuch. Weinheim: WILEY-VCH, 2007
- [KLOC18] Klocke, F.: Fertigungsverfahren 1. Zerspanung mit geometrisch bestimmter Schneide. 9. Aufl. Berlin: Springer Vieweg, 2018

- [KLOT10] Kloth, C.: Havariemanagement im Broadcast Engineering. Wiesbaden: Vieweg+Teubner, 2010
- [KOHNO5] Kohn, W.: Statistik. Datenanalyse und Wahrscheinlichkeitsrechnung. Berlin: Springer, 2005
- [KOLL18] Koller, V.: Machine Learning. In: VDMA Nachrichten: Machine Learning treibt Innovationen an. Frankfurt am Main, Dezember 2018, S. 8–11
- [KÖNI18] Königs, M.; Brecher, C.: Process-parallel virtual quality evaluation for metal cutting in series production. In: Procedia Manufacturing. 26. Jg., 2018, S. 1087–1093
- [KOPP08] Koppka, F.: A contribution to the maximization of productivity and workpiece quality of the reaming process by analyzing its static and dynamic behavior. An analysis with focus on automotive powertrain production. Dissertation, Technische Universität Darmstadt, Darmstadt, 2008
- [KRAS04] Kraskov, A.; Stögbauer, H.; Grassberger, P.: Estimating mutual information. In: Physical review. 69. Jg., 2004, Aufs. 66138, S. 1-16
- [KRAU18] Krauß, J. K.; Frye, M.; Teodoro, G.; Beck, D.; Schmitt, R. H.: Selection and Application of Machine Learning-Algorithms in Production Quality. In: Beyerer, J.; Kühnert, C.; Niggemann, O. (Hrsg.): Machine learning for cyber physical systems. New York: Springer, 2018, S. 46–57
- [KRAU19] Krauß, J.; Dorißen, J.; Mende, H.; Frye, M.; Schmitt, R. H.: Maschinelles Lernen und Künstliche Intelligenz in der Produktion: Anwendungsgebiete und öffentlich zugängliche Datensätze. In: Wulfsberg, J. P.; Hintze, W.; Behrens, B.-A. (Hrsg.): Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP). Berlin: Springer Vieweg, 2019, S. 493–501
- [KRÜG14] Krüger, M.: Modellbasierte Online-Bewertung von Fräsprozessen. Dissertation, Gottfried Wilhelm Leibniz Universität, Hannover, 2014
- [MAIM05] Maimon, O.; Rokach, L.: Data mining and knowledge discovery handbook. New York: Springer, 2005
- [MASI14] Masing, W.: Das Unternehmen im Wettbewerb. In: Pfeifer, T.; Schmitt, R. (Hrsg.): Masing Handbuch Qualitätsmanagement. 6. Aufl. München: Hanser, 2014, S. 4–14
- [MATH99] Mathews, P.G.; Shunmugam, M.S.: Neural-network approach for predicting hole quality in reaming. In: International Journal of Machine Tools and Manufacture. 39. Jg., 1999, Nr. 5, S. 723–730

- [MCCA55] McCarthy, J.; Minsky, M. L.; Rochester, N.; Shannon, C. E.: A proposal for the Dartmouth summer research project on artificial intelligence, 31. August 1955
- [MITC97] Mitchell, T. M.: Machine learning. New York: McGraw-Hill, 1997
- [MONG20] mongodb: mongodb. URL: <https://www.mongodb.com/> [Stand: 18.12.2020]
- [MUEL19] Mueller, T.; Kiesel, R.; Schmitt, R. H.: Automated and Predictive Risk Assessment in Modern Manufacturing Based on Machine Learning. In: Schmitt, R.; Schuh, G. (Hrsg.): Advances in Production Research. Proceedings of the 8th Congress of the German Academic Association for Production Technology (WGP). Cham: Springer, 2019, S. 91–100
- [MURP12] Murphy, K. P.: Machine learning. A probabilistic perspective. Cambridge: MIT Press, 2012
- [NETO13] Neto, F. C.; Gerônimo, T. M.; Cruz, C.E.D.; Aguiar, P. R.; Bianchi, E.E.C.: Neural Models for Predicting Hole Diameters in Drilling Processes. In: Procedia CIRP. 12. Jg., 2013, S. 49–54
- [NGO16] Ngo, Q. H.; Schmitt, R. H.: A Data-based Approach for Quality Regulation. In: Procedia CIRP. 57. Jg., 2016, S. 498–503
- [OETT18] Oetter, C.: Die Innovationstreiber im Maschinenbau. In: VDMA Software und Digitalisierung: Machine Learning im Maschinen- und Anlagenbau. Quick Guide. Frankfurt am Main, 2018, S. 3
- [PETE05] Petersohn, H.: Data Mining. München: Oldenbourg, 2005
- [PIME18] Pimenov, D. Y.; Bustillo, A.; Mikolajczyk, T.: Artificial intelligence for automatic prediction of required surface roughness by monitoring wear on face mill teeth. In: Journal of Intelligent Manufacturing. 29. Jg., 2018, Nr. 5, S. 1045–1061
- [PUHA20] Puhani, J.: Statistik. Einführung mit praktischen Beispielen. 13. Aufl. Wiesbaden: Springer, 2020
- [PYTH20] python: python. URL: <https://www.python.org/> [Stand: 18.12.2020]
- [QUIN11] Quintana, G.; Rudolf, T.; Ciurana, J.; Brecher, C.: Surface roughness prediction through internal kernel information and external accelerometers using artificial neural networks. In: Journal of Mechanical Science and Technology. 25. Jg., 2011, Nr. 11, S. 2877–2886
- [REIM18] Reimann, G.: Machine Learning im Maschinen- und Anlagenbau. Quick Guide. Frankfurt am Main: VDMA Software und Digitalisierung, 2018
- [REXR08] Rexroth: Rexroth IndraDrive. Firmware für Antriebsregelgeräte MPH-04, MPB-04, MPD-04. R911315484. Lohr am Main, 2008

- [REXR20] Rexroth AG: Automatisierungslösungen. URL: <https://www.boschrexroth.com/de/de/produkte/produktgruppen/elektrische-antriebe-und-steuerungen/elektrische-antriebs-und-steuerungstechnik> [Stand: 18.12.2020]
- [RICH19] Richter, S.: Statistisches und maschinelles Lernen. Gängige Verfahren im Überblick. 1. Aufl. Berlin: Springer Spektrum, 2019
- [ROSS14] Ross, B. C.: Mutual information between discrete and continuous data sets. In: PLOS one. 9. Jg., 2014, Nr. 2, Aufs. e87357, S.1–5
- [RUNK15] Runkler, T. A.: Data Mining. Modelle und Algorithmen intelligenter Datenanalyse. 2. Aufl. Wiesbaden: Springer Vieweg, 2015
- [SAND20] Sandvik Coromant: CoroDrill. URL: https://www.sandvik.coromant.com/en-us/products/corodrill_460/Pages/default.aspx [Stand: 18.09.2020]
- [SARC17] Sarcevic, P.; Pletl, S.; Kincses, Z.: Comparison of Time- and Frequency-domain Features for Movement Classification using Data from Wrist-worn Sensors. In: IEEE 15th International Symposium on Intelligent Systems and Informatics, Subotica, 2017, S. 261-265
- [SCHM20] Schmitt, R. H.; Kurzhals, R.; Ellerich, M.; Nilgen, G.; Schlegel, P.; Dietrich, E.; Krauß, J.; Latz, A.; Gregori, J.; Miller N.: Predictive Quality – Data Analytics in produzierenden Unternehmen. In: Schuh, G. (Hrsg.): Internet of Production - Turning Data into Value. Statusberichte aus der Produktionstechnik 2020. Aachen: Fraunhofer-Gesellschaft, 2020, S. 226–253
- [SCHN18] Schneider, T.; Helwig, N.; Schütze, A.: Industrial condition monitoring with smart sensors using automated feature extraction and selection. In: Measurement Science and Technology. 29. Jg., 2018, Nr. 9, Aufs. 94002, S. 1–15
- [SCIK 20a] scikit-learn: 3.2.4.3.6. sklearn.ensemble.GradientBoostingRegressor. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html> [Stand: 31.10.2020]
- [SCIK 20b] scikit-learn: 3.2.4.3.2. sklearn.ensemble.RandomForestRegressor. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html> [Stand: 31.10.2020]
- [SHEA00] Shearer, C.: The CRISP-DM Model: The New Blueprint for Data Mining. In: Journal of Data Warehousing. 5. Jg., 2000, Nr. 4, S. 13–22
- [STAC13] Stachowiak, H.: Allgemeine Modelltheorie. Wien: Springer, 2013

- [SWAM19] Swamynathan, M.: Mastering Machine Learning with Python in Six Steps. A Practical Implementation Guide to Predictive Data Analytics Using Python. 2. Aufl. New York: Apress, 2019
- [TETI10] Teti, R.; Jemielniak, K.; O'Donnell, G.; Dornfeld, D.: Advanced monitoring of machining operations. In: CIRP Annals. 59. Jg., 2010, Nr. 2, S. 717–739
- [TILS 19a] Tilsch, J.: 10. Fähigkeit von Mess- und Prüfprozessen. Qualitätsmanagement in der Bosch-Gruppe. Stuttgart, 2019
- [TILS 19b] Tilsch, J.: Maschinen- und Prozessfähigkeit. Qualitätsmanagement in der Bosch-Gruppe. Stuttgart, 2019
- [VDI19] VDI/VDE-Richtlinien VDI 3714 (2019). Implementierung und Betrieb von Big-Data-Anwendungen in der produzierenden Industrie
- [VESE12] Veselovac, D.: Process and product monitoring in the drilling of critical aero engine components. Dissertation, Rheinisch-Westfälische Technische Hochschule, Aachen, 2012
- [VOGE17] Vogel-Heuser, B.; Bauernhansl, T.; Hompel, M. t.: Handbuch Industrie 4.0 Bd.4: Allgemeine Grundlagen. Berlin: Springer Vieweg, 2017
- [WALT20] Walter AG: Reibahlen in Standard- und Sonderausführung. URL: https://www.walter-tools.com/de-de/tools/standard_products/holemaking/overview/reaming/single_flute/Pages/default.aspx#!#picture-carousel [Stand: 18.09.2020]
- [WANG18] Wang, J.; Ma, Y.; Zhang, L.; Gao, R. X.; Wu, D.: Deep learning for smart manufacturing: Methods and applications. In: Journal of Manufacturing Systems. 48. Jg., 2018, S. 144–156
- [WECK06] Weck, M.; Brecher, C.: Automatisierung von Maschinen und Anlagen. 6. Aufl. Berlin: Springer, 2006
- [WELC20] Welcker, C. M.: Die Chancen ergreifen - Neue Geschäftsmodelle gestalten. In: VDMA Volkswirtschaft und Statistik: Maschinenbau in Zahl und Bild 2020. Frankfurt am Main, 2020, S. 3
- [WELC67] Welch, P.: The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. In: IEEE Transactions on audio and electroacoustics. 15. Jg., 1967, Nr. 2, S. 70–73
- [WELS18] Welsch, A.; Eitle, V.; Buxmann, P.: Maschinelles Lernen. In: HMD Praxis der Wirtschaftsinformatik. 55. Jg., 2018, Nr. 2, S. 366–382
- [WIEC20] Wiechers, R.; Scholl, F.: Maschinenbau in Zahl und Bild 2020. Frankfurt am Main: VDMA Volkswirtschaft und Statistik, 2020
- [WIES17] Wiesch, M.: Entwicklung eines Kraftschätzmodells beim Fräsen. Anwendung eines modernen, hybriden Lernansatzes auf Basis künstlicher

- neuronaler Netze zur prozessparallelen Ermittlung der Prozesskraft anhand maschineninterner Daten. In: Zeitschrift für wirtschaftlichen Fabrikbetrieb. 112. Jg., 2017, Nr. 11, S. 792–796
- [WILL20] Willrett, M.: WZL-Direktor Prof. Thomas Bergs über die Zukunft der Fertigungstechnik. In: Industrieanzeiger. 142. Jg., 2020, Nr. 11, S. 20–23
- [WINZ16] Winzer, P.: Generic Systems Engineering. Ein methodischer Ansatz zur Komplexitätsbewältigung. 2. Aufl. Berlin: Springer Vieweg, 2016
- [WOLP97] Wolpert, D. H.; Macready, W. G.: No Free Lunch Theorems for Optimization. In: IEEE Transactions on evolutionary computation. 1. Jg., 1997, Nr. 1, S. 67–82
- [WROB12] Wrobel, S.; Joachims, T.; Morik, K.: Maschinelles Lernen und Data Mining. In: Görz, G.; Schneeberger, J.; Schmid, U. (Hrsg.): Handbuch der Künstlichen Intelligenz. 5. Aufl. München: Oldenbourg, 2012, S. 405–471
- [ZANG14] Zangemeister, C.: Nutzwertanalyse in der Systemtechnik. Eine Methodik zur multidimensionalen Bewertung und Auswahl von Projektalternativen. 5. Aufl. Winnemark: Zangemeister & Partner, 2014
- [ZIEG20] Ziegenbein, A.; Fertig, A.; Metternich, J.; Weigold, M.: Data-based process analysis in machining production: Case study for quality determination in a drilling process. In: Procedia CIRP. 93. Jg., 2020, S. 1472–1477
- [ZOLL14] Zollondz, H.-D.: Die Entwicklung des Qualitätsmanagements im 20. und 21. Jahrhundert. In: Pfeifer, T.; Schmitt, R. (Hrsg.): Masing Handbuch Qualitätsmanagement. 6. Aufl. München: Hanser, 2014, S. 16–37

Anhang A

Liste mit den Bezeichnungen der Antriebsparameter.

P-0-0038	Drehmomentbildender Strom, Sollwert
P-0-0039	Flussbildender Strom, Sollwert
P-0-0043	Drehmomentbildender Strom, Istwert
P-0-0044	Flussbildender Strom, Istwert
P-0-0048	Wirksamer Geschwindigkeits-Sollwert
P-0-0049	Wirksamer Momenten-/Kraft-Sollwert
P-0-0051	Drehmoment-/Kraft-Konstante
P-0-0059	Lagesollwert additiv, Regler
P-0-0063	Drehmomentbildende Spannung, Istwert
P-0-0064	Flussbildende Spannung, Istwert
P-0-0065	Spannungsbetrag, Istwert
P-0-0109	Spitzendrehmoment-/Kraft-Begrenzung
P-0-0434	Lagesollwert Regler
P-0-0453	Integralanteil Geschwindigkeitsregler
P-0-0454	Geschwindigkeitsvorsteuerungs-Istwert
P-0-0455	Beschleunigungsvorsteuerungs-Istwert
P-0-0533	Spannungsregler Proportionalverstärkung
P-0-0534	Spannungsregler Nachstellzeit
P-0-0536	Motormaximalspannung
P-0-0556	Achsregler-Konfiguration
P-0-0590	Motormodell Frequenzregler Proportionalverstärkung
P-0-0591	Motormodell Frequenzregler Nachstellzeit
P-0-0592	Motormodell Abgleichfaktor
P-0-0691	Lagesollwert additiv, Prozessregler
P-0-4005	Flussbildender Strom, Grenzwert
P-0-4045	Maximal möglicher Dauerstrom
P-0-4046	Wirksamer Spitzenstrom
S-0-0032	Hauptbetriebsart
S-0-0037	Geschwindigkeits-Sollwert additiv
S-0-0038	Geschwindigkeits-Grenzwert positiv
S-0-0039	Geschwindigkeits-Grenzwert negativ
S-0-0040	Geschwindigkeits-Istwert
S-0-0048	Lagesollwert additiv
S-0-0051	Lage-Istwert Geber 1
S-0-0053	Lage-Istwert Geber 2
S-0-0081	Drehmoment-/Kraft-Sollwert additiv
S-0-0091	Geschwindigkeits-Grenzwert bipolar
S-0-0092	Drehmoment/Kraft-Grenzwert bipolar
S-0-0100	Geschwindigkeitsregler-Proportionalverstärkung
S-0-0101	Geschwindigkeitsregler-Nachstellzeit
S-0-0104	Lageregler Kv-Faktor
S-0-0106	Stromregler-Proportionalverstärkung 1
S-0-0107	Stromregler-Nachstellzeit 1
S-0-0155	Reibungs-Kompensation
S-0-0189	Schleppabstand
S-0-0347	Geschwindigkeits-Regelabweichung
S-0-0386	Aktiver Lageistwert

Anhang B

Auflistung der mit einer Random Search bestimmten Parameterwerte der Methoden GBR und RFR (die Bedeutung der Parameter kann unter [SCIK 20b; SCIK 20a] abgerufen werden).

Parametrierung des GBR für die Prognose des Durchmessers (mit der Merkmalsselektion nach dem Transinformationswert):

```
{'alpha': 0.9, 'criterion': 'mae', 'init': None, 'learning_rate': 0.1, 'loss': 'ls', 'max_depth': 3, 'max_features': 'sqrt', 'max_leaf_nodes': None, 'min_impurity_decrease': 0.0, 'min_impurity_split': None, 'min_samples_leaf': 1, 'min_samples_split': 7, 'min_weight_fraction_leaf': 0.0, 'n_estimators': 217, 'n_iter_no_change': None, 'pre-sort': 'auto', 'random_state': None, 'subsample': 1.0, 'tol': 0.0001, 'validation_fraction': 0.1, 'verbose': 0, 'warm_start': False}
```

Parametrierung des GBR für die Prognose der Konzentrität (mit der Merkmalsselektion nach der Pearson Korrelation):

```
{'alpha': 0.9, 'criterion': 'mae', 'init': None, 'learning_rate': 0.1, 'loss': 'ls', 'max_depth': 3, 'max_features': 'log2', 'max_leaf_nodes': None, 'min_impurity_decrease': 0.0, 'min_impurity_split': None, 'min_samples_leaf': 1, 'min_samples_split': 19, 'min_weight_fraction_leaf': 0.0, 'n_estimators': 949, 'n_iter_no_change': None, 'pre-sort': 'auto', 'random_state': None, 'subsample': 1.0, 'tol': 0.0001, 'validation_fraction': 0.1, 'verbose': 0, 'warm_start': False}
```

Parametrierung des GBR für die Prognose der Geradheit (mit der Merkmalsselektion nach dem Transinformationswert):

```
{'alpha': 0.9, 'criterion': 'mae', 'init': None, 'learning_rate': 0.1, 'loss': 'ls', 'max_depth': 3, 'max_features': 'sqrt', 'max_leaf_nodes': None, 'min_impurity_decrease': 0.0, 'min_impurity_split': None, 'min_samples_leaf': 1, 'min_samples_split': 4, 'min_weight_fraction_leaf': 0.0, 'n_estimators': 586, 'n_iter_no_change': None, 'pre-sort': 'auto', 'random_state': None, 'subsample': 1.0, 'tol': 0.0001, 'validation_fraction': 0.1, 'verbose': 0, 'warm_start': False}
```

Parametrierung des RFR für die Prognose der Rundheit (mit Merkmalsselektion nach Pearson Korrelation):

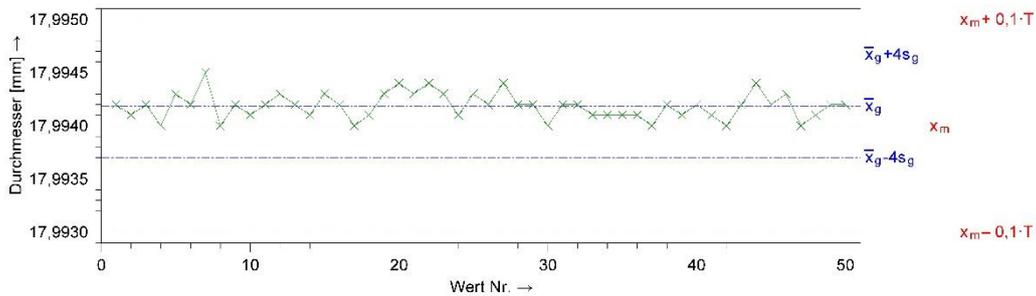
```
{'bootstrap': True, 'criterion': 'mae', 'max_depth': None, 'max_features': 'log2',  
'max_leaf_nodes': None, 'min_impurity_decrease': 0.0, 'min_impurity_split': None,  
'min_samples_leaf': 1, 'min_samples_split': 16, 'min_weight_fraction_leaf': 0.0,  
'n_estimators': 426, 'n_jobs': None, 'oob_score': False, 'random_state': None, 'ver-  
bose': 0, 'warm_start': False}
```


Anhang D

Protokoll von solara.MP zum Verfahren eins für den Durchmesser.

	<h2>Messsystemanalyse</h2>	Seite 1 / 4
---	----------------------------	----------------

Datum/Zeit	24.11.2020	Bearb.Name	Schorr Sebastian	Abt./Kst./Prod.	TEF2	Prüfart	
Prüfmittel		Normal		Merkmal			
Prfm.Bez.	Gradient Boosting Reg.	Normal Bez.	Gehäuse	Merkm.Bez. Durchmesser			
Prfm.Nr.		Normal Nr.	Nr. 12	Merkm.Nr. 1			
Prfm.Aufl.	0,0001	Normal-Istw.	17,994	Nennm. 17,9960 OSG 18,0010 $\Delta = 0,0050$			
Prüfgrnd.	Validierung	Einh.	mm	Einh. mm USG 17,9910 $\Delta = -0,0050$			
Bemerkung							



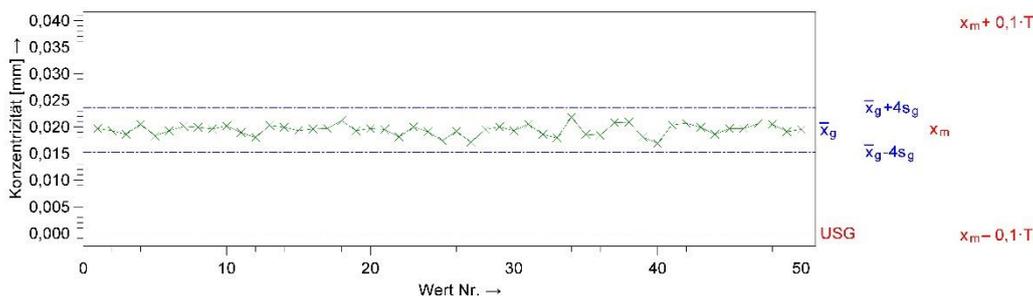
i	x _i								
1	17,9942	11	17,9942	21	17,9943	31	17,9942	41	17,9941
2	17,9941	12	17,9943	22	17,9944	32	17,9942	42	17,9940
3	17,9942	13	17,9942	23	17,9943	33	17,9941	43	17,9942
4	17,9940	14	17,9941	24	17,9941	34	17,9941	44	17,9944
5	17,9943	15	17,9943	25	17,9943	35	17,9941	45	17,9942
6	17,9942	16	17,9942	26	17,9942	36	17,9941	46	17,9943
7	17,9945	17	17,9940	27	17,9944	37	17,9940	47	17,9940
8	17,9940	18	17,9941	28	17,9942	38	17,9942	48	17,9941
9	17,9942	19	17,9943	29	17,9942	39	17,9941	49	17,9942
10	17,9941	20	17,9944	30	17,9940	40	17,9942	50	17,9942

Zeichnungswerte		Gemessene Werte		Statistische Werte	
$x_m + 0,1 \cdot T$	= 17,995000	$x_{max\ g}$	= 17,9945	$\bar{x}_g + 3s_g$	= 17,99455
x_m	= 17,994000	$ B $	= 0,00018600	\bar{x}_g	= 17,99419
$x_m - 0,1 \cdot T$	= 17,993000	$x_{min\ g}$	= 17,9940	$\bar{x}_g - 3s_g$	= 17,99382
$0,2 \cdot T$	= 0,002000	R_g	= 0,0005	$6s_g$	= 0,00073
T	= 0,0100	n_{ges}	= 50	s_g	= 0,000121
Einheit	= mm				

Test auf systematische Messabweichung (Bias)		Testergebnis : signifikant ($\alpha \leq 0,1\%$)	
$C_g = \frac{0,2 \cdot T}{6 \cdot s_g} = 2,21 \leq 2,75 \leq 3,29$		Minimale Bezugsgröße für fähiges Prüfsystem $T_{min}(C_g) = 0,00484$	
$C_{gk} = \frac{0,1 \cdot T - \bar{x}_g - x_m }{3 \cdot s_g} = 1,79 \leq 2,24 \leq 2,69$		$T_{min}(C_{gk}) = 0,00670$	
Auflösung	%RE = 1,00%	$T_{min}(\%RE) = 0,00200$	
Prüfsystem fähig (%RE, C _g , C _{gk}) 			
BOSCH 2012 - MSA: Type 1			

Protokoll von solara.MP zum Verfahren eins für die Konzentrizität.

		<h2>Messsystemanalyse</h2>			Seite 2 / 4	
Datum/Zeit 24.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfart			
Prüfmittel		Normal		Merkmal		
Prfm.Bez. Gradient Boosting Reg.	Normal Bez. Gehäuse	Merkm.Bez. Konzentrizität				
Prfm.Nr.	Normal Nr. Nr. 35	Merkm.Nr. 2				
Prfm.Aufl. 0,0001	Normal-Istw. 0,0196	Nennm. 0,0000		OSG 0,2000	$\hat{\Delta} = 0,2000$	
Prüfgrnd. Validierung	Einh. mm	Einh. mm		USG 0,0000	$\hat{\Delta} = 0,0000$	
Bemerkung						



i	x _i								
1	0,0197	11	0,0189	21	0,0195	31	0,0205	41	0,0204
2	0,0193	12	0,0180	22	0,0181	32	0,0186	42	0,0207
3	0,0186	13	0,0203	23	0,0200	33	0,0179	43	0,0199
4	0,0205	14	0,0199	24	0,0191	34	0,0218	44	0,0186
5	0,0183	15	0,0193	25	0,0174	35	0,0186	45	0,0197
6	0,0193	16	0,0196	26	0,0192	36	0,0184	46	0,0197
7	0,0201	17	0,0197	27	0,0171	37	0,0208	47	0,0206
8	0,0199	18	0,0212	28	0,0195	38	0,0209	48	0,0205
9	0,0196	19	0,0193	29	0,0200	39	0,0181	49	0,0191
10	0,0202	20	0,0197	30	0,0193	40	0,0169	50	0,0195

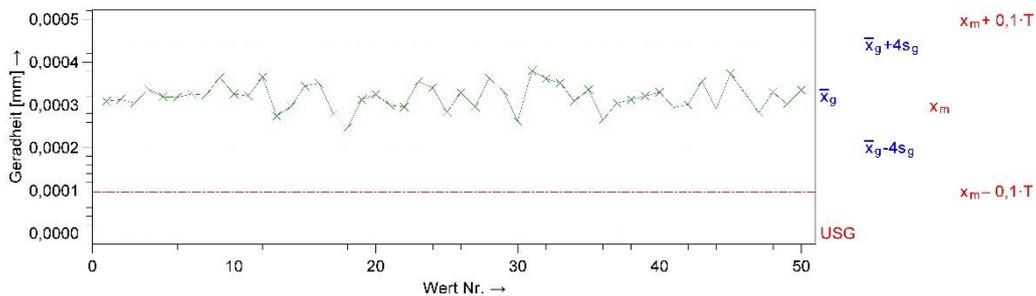
Zeichnungswerte		Gemessene Werte		Statistische Werte	
$x_m + 0,1 \cdot T$	= 0,039600	$x_{max\ g}$	= 0,0218	$\bar{x}_g + 3s_g$	= 0,02256
x_m	= 0,019600	$ B $	= 0,00016400	\bar{x}_g	= 0,01944
$x_m - 0,1 \cdot T$	= -0,000400	$x_{min\ g}$	= 0,0169	$\bar{x}_g - 3s_g$	= 0,01631
$0,2 \cdot T^*$	= 0,040000	R_g	= 0,0049	$6s_g$	= 0,00626
T^*	= 0,2000	n_{ges}	= 50	s_g	= 0,00104
Einheit	= mm				

Test auf systematische Messabweichung (Bias)			Testergebnis : nicht signifikant		
$C_g = \frac{0,2 \cdot T}{6 \cdot s_g} = 5,13 \leq 6,39 \leq 7,65$			Minimale Bezugsgröße für fähiges Prüfsystem		
$C_{gk} = \frac{0,1 \cdot T - \bar{x}_g - x_m }{3 \cdot s_g} = 5,08 \leq 6,34 \leq 7,60$			$T_{min}(C_g)$	=	0,0416
Auflösung %RE = 0,05%			$T_{min}(C_{gk})$	=	0,0433
			$T_{min}(\%RE)$	=	0,00200
Prüfsystem fähig (%RE, C _g , C _{gk})					
BOSCH 2012 - MSA: Type 1					

Datum _____ Unterschrift _____ Abteilung _____

Protokoll von solara.MP zum Verfahren eins für die Geradheit.

		<h2>Messsystemanalyse</h2>			Seite 3 / 4	
Datum/Zeit	24.11.2020	Bearb.Name	Schorr Sebastian	Abt./Kst./Prod.	TEF2	Prüfört
Prüfmittel		Normal			Merkmal	
Prfm.Bez.	Gradient Boosting Reg.	Normal Bez.	Gehäuse		Merkm.Bez. Geradheit	
Prfm.Nr.		Normal Nr.	Nr. 20		Merkm.Nr. 3	
Prfm.Aufl.	0,000001	Normal-Istw.	0,000297		Nennm. 0,000000 OSG 0,00200 $\hat{\Delta}$ 0,002000	
Prüfgrnd.	Validierung	Einh.	mm		Einh. mm USG 0,00000 $\hat{\Delta}$ 0,000000	
Bemerkung						



i	x_i								
1	0,000309	11	0,000321	21	0,000300	31	0,000380	41	0,000294
2	0,000313	12	0,000365	22	0,000295	32	0,000295	42	0,000301
3	0,000305	13	0,000274	23	0,000355	33	0,000351	43	0,000355
4	0,000337	14	0,000297	24	0,000340	34	0,000309	44	0,000291
5	0,000319	15	0,000344	25	0,000283	35	0,000336	45	0,000373
6	0,000318	16	0,000351	26	0,000329	36	0,000265	46	0,000329
7	0,000326	17	0,000280	27	0,000296	37	0,000305	47	0,000282
8	0,000323	18	0,000247	28	0,000363	38	0,000312	48	0,000330
9	0,000364	19	0,000313	29	0,000331	39	0,000321	49	0,000302
10	0,000326	20	0,000324	30	0,000262	40	0,000330	50	0,000335

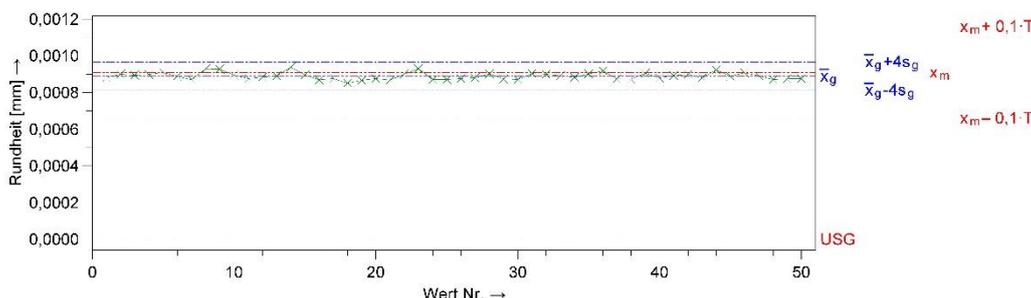
Zeichnungswerte		Gemessene Werte		Statistische Werte	
$x_m + 0,1 \cdot T$	= 0,00049700	$x_{max\ g}$	= 0,000380	$\bar{x}_g + 3s_g$	= 0,0004095
x_m	= 0,00029700	B	= 0,000022460	\bar{x}_g	= 0,0003195
$x_m - 0,1 \cdot T$	= 0,00009700	$x_{min\ g}$	= 0,000247	$\bar{x}_g - 3s_g$	= 0,0002295
$0,2 \cdot T^*$	= 0,00040000	R_g	= 0,000133	$6s_g$	= 0,0001800
T^*	= 0,002000	n_{ges}	= 50	s_g	= 0,0000300
Einheit	= mm				

Test auf systematische Messabweichung (Bias)			Testergebnis : signifikant ($\alpha \leq 0,1\%$)		
$C_g = \frac{0,2 \cdot T}{6 \cdot s_g} = 1,78 \leq 2,22 \leq 2,66$			Minimale Bezugsgröße für fähiges Prüfsystem		
$C_{gk} = \frac{0,1 \cdot T - \bar{x}_g - x_m }{3 \cdot s_g} = 1,57 \leq 1,97 \leq 2,37$			$T_{min}(C_g) = 0,00120$		
Auflösung %RE = 0,05%			$T_{min}(C_{gk}) = 0,00142$		
			$T_{min}(\%RE) = 0,0000200$		
Prüfsystem fähig (%RE, C_g, C_{gk})					
BOSCH 2012 - MSA: Type 1					

Datum _____ Unterschrift _____ Abteilung _____

Protokoll von solara.MP zum Verfahren eins für die Rundheit.

		<h2>Messsystemanalyse</h2>			Seite 4 / 4	
Datum/Zeit	24.11.2020	Bearb.Name	Schorr Sebastian	Abt./Kst./Prod.	TEF2	Prüfört
Prüfmittel		Normal			Merkmal	
Prfm.Bez.	Random Forest Reg.	Normal Bez.	Gehäuse	Merkm.Bez. Rundheit		
Prfm.Nr.		Normal Nr.	Nr. 19	Merkm.Nr. 4		
Prfm.Aufl.	0,000001	Normal-Istw.	0,000909	Nennm.	0,000000 OSG	0,00250 [^] 0,002500
Prüfgrnd.	Validierung	Einh.	mm	Einh.	mm USG	0,00000 ₀ 0,000000
Bemerkung						



i	x _i								
1	0,000882	11	0,000876	21	0,000868	31	0,000903	41	0,000891
2	0,000889	12	0,000884	22	0,000900	32	0,000900	42	0,000898
3	0,000894	13	0,000890	23	0,000930	33	0,000891	43	0,000880
4	0,000898	14	0,000938	24	0,000870	34	0,000882	44	0,000923
5	0,000909	15	0,000895	25	0,000871	35	0,000901	45	0,000887
6	0,000887	16	0,000869	26	0,000875	36	0,000918	46	0,000908
7	0,000869	17	0,000875	27	0,000881	37	0,000874	47	0,000890
8	0,000929	18	0,000852	28	0,000901	38	0,000873	48	0,000870
9	0,000928	19	0,000866	29	0,000874	39	0,000905	49	0,000874
10	0,000894	20	0,000876	30	0,000871	40	0,000879	50	0,000875

Zeichnungswerte		Gemessene Werte		Statistische Werte	
x _m +0,1-T	= 0,00115900	x _{max g}	= 0,000938	\bar{x}_g+3s_g	= 0,0009470
x _m	= 0,00090900	B	= 0,000019540	\bar{x}_g	= 0,0008895
x _m -0,1-T	= 0,00065900	x _{min g}	= 0,000852	\bar{x}_g-3s_g	= 0,0008319
0,2-T*	= 0,00050000	R _g	= 0,000086	6s _g	= 0,0001151
T*	= 0,002500	n _{ges}	= 50	s _g	= 0,0000192
Einheit	= mm				

Test auf systematische Messabweichung (Bias)			Testergebnis : signifikant (α ≤ 0,1%)		
$C_g = \frac{0,2 \cdot T}{6 \cdot s_g} = 3,49 \leq 4,34 \leq 5,20$			Minimale Bezugsgröße für fähiges Prüfsystem T _{min} (C _g) = 0,000766 T _{min} (C _{gk}) = 0,000961 T _{min} (%RE) = 0,0000200		
$C_{gk} = \frac{0,1 \cdot T - \bar{x}_g - x_m }{3 \cdot s_g} = 3,21 \leq 4,00 \leq 4,80$					
Auflösung	%RE =	0,04%			
Prüfsystem fähig (%RE, C _g , C _{gk})					
BOSCH 2012 - MSA: Type 1					

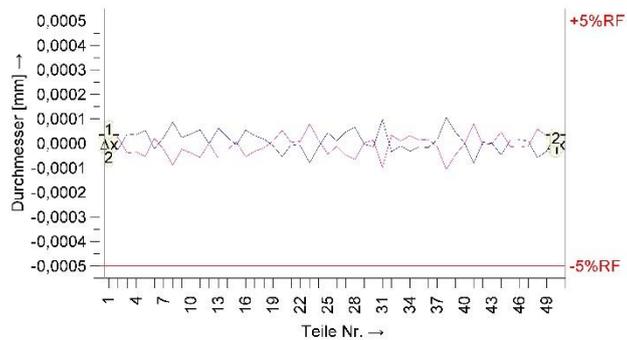
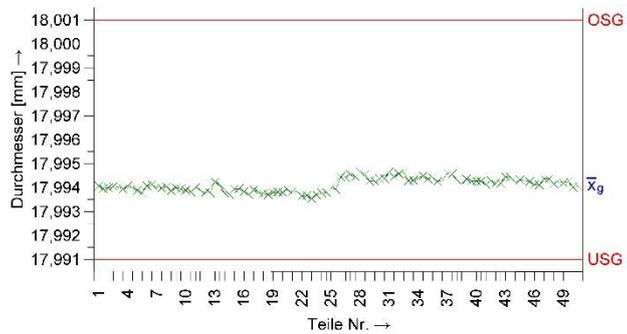
Anhang E

Protokoll von solara.MP zum Verfahren drei für den Durchmesser (1/2).

	<h2>Messsystemanalyse</h2>	Seite 1 / 8
---	----------------------------	----------------

Datum/Zeit 23.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfart
Prüfmittel		Teil	Merkmal
Prfm.Bez. Gradient Boosting Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Durchmesser	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 1	
Prfm.Aufl. 0,0001		Nennm. 17,9960 OSG 18,0010 $\Delta = 0,0050$	
Prüfgrnd. Validierung		Einh. mm USG 17,9910 $\Delta = -0,0050$	
Bemerkung			

n	X _{A,1}	X _{A,2}	\bar{x}_{gj}	s _{gj}
1	17,9941	17,9940	17,99401	0,00008
2	17,9940	17,9940	17,99402	0,00004
3	17,9940	17,9939	17,99398	0,00005
4	17,9941	17,9940	17,99403	0,00005
5	17,9939	17,9938	17,99383	0,00008
6	17,9941	17,9941	17,99409	0,00003
7	17,9940	17,9940	17,99400	0,00003
8	17,9940	17,9939	17,99396	0,00012
9	17,9940	17,9939	17,99397	0,00003
10	17,9939	17,9938	17,99385	0,00005
11	17,9940	17,9939	17,99395	0,00008
12	17,9938	17,9938	17,99379	0,00000
13	17,9942	17,9941	17,99418	0,00009
14	17,9938	17,9937	17,99374	0,00004
15	17,9939	17,9940	17,99394	0,00001
16	17,9938	17,9937	17,99377	0,00008
17	17,9939	17,9938	17,99387	0,00005
18	17,9937	17,9937	17,99373	0,00003
19	17,9938	17,9938	17,99380	0,00001
20	17,9938	17,9939	17,99386	0,00008
21	17,9938	17,9938	17,99382	0,00001
22	17,9936	17,9937	17,99366	0,00001
23	17,9935	17,9937	17,99361	0,00011
24	17,9938	17,9938	17,99379	0,00002
25	17,9940	17,9939	17,99395	0,00006



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung	Merkm.Nr. 1	Merkm.Bez. Durchmesser
Wiederholpräzision	EV = 0,000050368 ≤ 0,0000601	%EV = 3,61%	
Prüfsystemstreuung	GRR = 0,000050368 ≤ 0,0000601	%GRR = 3,61%	
Varianz 0,000000036237	Standardabw. 0,000060198		
Toleranz T = 0,0100	Vertrauensniveau 1-α = 95,000%		
Auflösung	%RE = 1,00%	0	5
Prüfsystemstreuung	%GRR = 3,61%	0	10 30
Teilstreuung	%PV = 15,91%	0	50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc)	ndc = 6	0	5
Prüfsystem fähig (%RE,%GRR)			
BOSCH 2012 - MSA: Type 3			
T _{min} (%GRR) = 0,00361	T _{min} (%GRR) = 0,00120		

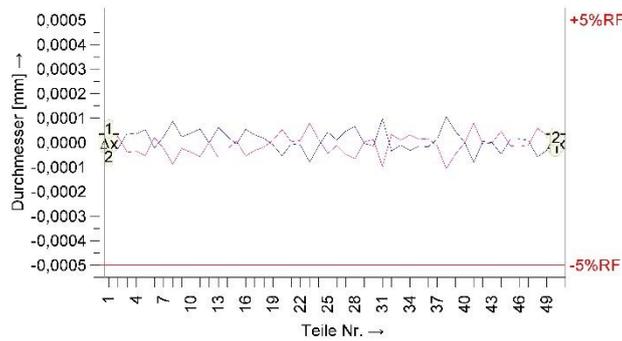
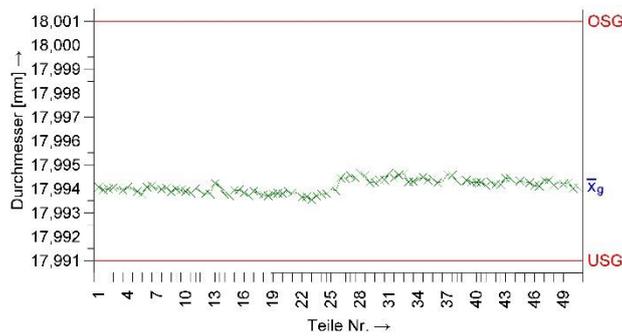
Datum 23.11.2020 Unterschrift 12 / 200503 GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3.dfg

Protokoll von solara.MP zum Verfahren drei für den Durchmesser (2/2).

	<h2>Messsystemanalyse</h2>	Seite 2 / 8
---	----------------------------	----------------

Datum/Zeit 23.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfört
Prüfmittel		Teil	Merkmal
Prfm.Bez. Gradient Boosting Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Durchmesser	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 1	
Prfm.Aufl. 0,0001		Nennm. 17,9960 OSG 18,0010 $\Delta = 0,0050$	
Prüfgrnd. Validierung		Einh. mm USG 17,9910 $\Delta = -0,0050$	
Bemerkung			

n	x _{A,1}	x _{A,2}	\bar{x}_{gj}	s _{gj}
26	17,9945	17,9944	17,99444	0,00002
27	17,9945	17,9945	17,99450	0,00007
28	17,9947	17,9945	17,99460	0,00009
29	17,9943	17,9943	17,99427	0,00000
30	17,9943	17,9944	17,99436	0,00002
31	17,9946	17,9944	17,99454	0,00014
32	17,9946	17,9946	17,99461	0,00005
33	17,9943	17,9943	17,99430	0,00001
34	17,9944	17,9945	17,99445	0,00005
35	17,9944	17,9944	17,99439	0,00002
36	17,9943	17,9943	17,99427	0,00002
37	17,9946	17,9946	17,99458	0,00002
38	17,9943	17,9941	17,99422	0,00015
39	17,9944	17,9943	17,99431	0,00006
40	17,9943	17,9943	17,99426	0,00000
41	17,9941	17,9943	17,99422	0,00011
42	17,9942	17,9942	17,99418	0,00001
43	17,9944	17,9944	17,99445	0,00000
44	17,9942	17,9943	17,99427	0,00007
45	17,9943	17,9943	17,99427	0,00002
46	17,9941	17,9941	17,99412	0,00002
47	17,9944	17,9944	17,99438	0,00001
48	17,9942	17,9943	17,99421	0,00008
49	17,9942	17,9943	17,99424	0,00004
50	17,9940	17,9941	17,99403	0,00003



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung	Merkm.Bez. Durchmesser
Wiederholpräzision 0,0000000036237	EV = 0,000050368 ≤ 0,0000601	%EV = 3,61%
Prüfsystemstreuung 0,0000000036237	GRR = 0,000050368 ≤ 0,0000601	%GRR = 3,61%
Toleranz T = 0,0100	Vertrauensniveau 1-α = 95,000%	
Auflösung %RE = 1,00%	0 5	
Prüfsystemstreuung %GRR = 3,61%	0 10 30	
Teilestreuung %PV = 15,91%	0 50 100 150	
Zahl d. unterscheidb. Messwertklassen (ndc) ndc = 6	0 5	
Prüfsystem fähig (%RE,%GRR)		
BOSCH 2012 - MSA: Type 3		
T _{min} (%GRR) = 0,00361	T _{min} (%GRR) = 0,00120	

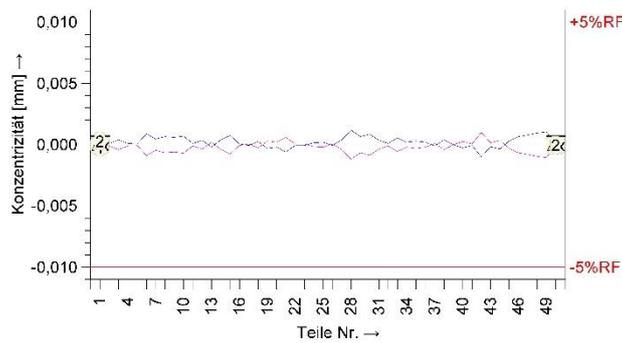
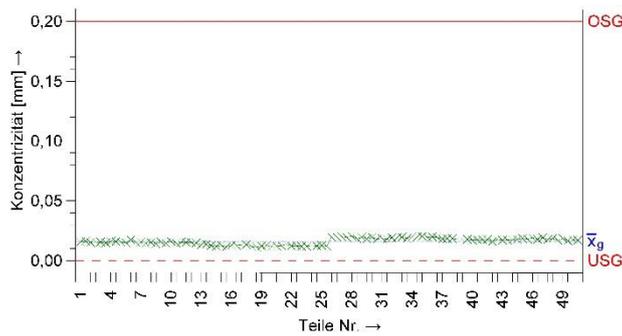
Datum 23.11.2020 Unterschrift 12 / 200503 GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3.dfg

Protokoll von solara.MP zum Verfahren drei für die Konzentrität (1/2).

	<h2>Messsystemanalyse</h2>	Seite 3 / 8
---	----------------------------	----------------

Datum/Zeit 24.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfört
Prüfmittel		Teil	Merkmal
Prfm.Bez. Gradient Boosting Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Konzentrität	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 2	
Prfm.Aufl. 0,0001		Nennm. 0,0000 OSG 0,2000 $\Delta = 0,2000$	
Prüfgrnd. Validierung		Einh. mm USG 0,0000 $\Delta = 0,0000$	
Bemerkung			

n	$x_{A,1}$	$x_{A,2}$	$\bar{x}_{g,j}$	$s_{g,j}$
1	0,0156	0,0161	0,01585	0,00035
2	0,0151	0,0149	0,01500	0,00014
3	0,0155	0,0147	0,01510	0,00057
4	0,0161	0,0159	0,01600	0,00014
5	0,0152	0,0151	0,01515	0,00007
6	0,0173	0,0155	0,01640	0,00127
7	0,0153	0,0144	0,01485	0,00064
8	0,0153	0,0140	0,01465	0,00092
9	0,0156	0,0144	0,01500	0,00085
10	0,0160	0,0146	0,01530	0,00099
11	0,0153	0,0151	0,01520	0,00014
12	0,0153	0,0146	0,01495	0,00049
13	0,0132	0,0136	0,01340	0,00028
14	0,0126	0,0118	0,01220	0,00057
15	0,0128	0,0113	0,01205	0,00106
16	0,0128	0,0127	0,01275	0,00007
17	0,0133	0,0134	0,01335	0,00007
18	0,0116	0,0111	0,01135	0,00035
19	0,0122	0,0128	0,01250	0,00042
20	0,0115	0,0119	0,01170	0,00028
21	0,0125	0,0137	0,01310	0,00085
22	0,0123	0,0124	0,01235	0,00007
23	0,0119	0,0120	0,01195	0,00007
24	0,0126	0,0123	0,01245	0,00021
25	0,0127	0,0123	0,01250	0,00028



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung
Merkm.Nr. 2	Merkm.Bez. Konzentrität
Wiederholpräzision 0,0000047770	EV = 0,00057830 ≤ 0,00069116 %EV = 2,07%
Prüfsystemstreuung 0,0000047770	GRR = 0,00057830 ≤ 0,00069116 %GRR = 2,07%
Standardabw. 0,00069116	
Toleranz T* = 0,2000	Vertrauensniveau 1-α = 95,000%
Auflösung %RE = 0,05%	0 5
Prüfsystemstreuung %GRR = 2,07%	0 10 30
Teilestreuung %PV = 7,79%	0 50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc) ndc = 5	0 5
Prüfsystem fähig (%RE,%GRR)	
BOSCH 2012 - MSA: Type 3	
T _{min} (%GRR) = 0,0415	T _{min} (%GRR) = 0,0138

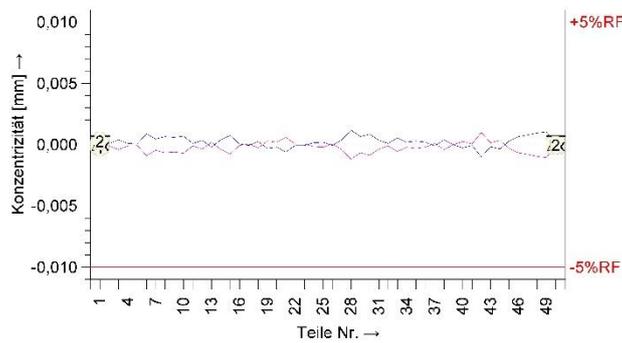
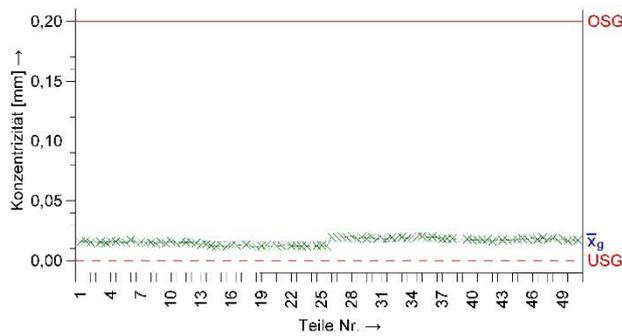
Datum 24.11.2020 Unterschrift 12 / 200503_GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3_Bearbeitet.dfg

Protokoll von solara.MP zum Verfahren drei für die Konzentritzität (2/2).

	<h2>Messsystemanalyse</h2>	Seite 4 / 8
---	----------------------------	----------------

Datum/Zeit 24.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfört
Prüfmittel		Teil	Merkmal
Prfm.Bez. Gradient Boosting Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Konzentritzität	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 2	
Prfm.Aufl. 0,0001		Nennm. 0,0000 OSG 0,2000 $\Delta = 0,2000$	
Prüfgrnd. Validierung		Einh. mm USG 0,0000 $\Delta = 0,0000$	
Bemerkung			

n	$x_{A,1}$	$x_{A,2}$	$\bar{x}_{g,j}$	$s_{g,j}$
26	0,0197	0,0198	0,01975	0,00007
27	0,0201	0,0193	0,01970	0,00057
28	0,0206	0,0182	0,01940	0,00170
29	0,0195	0,0182	0,01885	0,00092
30	0,0196	0,0179	0,01875	0,00120
31	0,0186	0,0179	0,01825	0,00049
32	0,0191	0,0189	0,01900	0,00014
33	0,0196	0,0185	0,01905	0,00078
34	0,0201	0,0197	0,01990	0,00028
35	0,0202	0,0196	0,01990	0,00042
36	0,0197	0,0193	0,01950	0,00028
37	0,0181	0,0183	0,01820	0,00014
38	0,0185	0,0177	0,01810	0,00057
39	0,0177	0,0177	0,01770	0,00000
40	0,0171	0,0176	0,01735	0,00035
41	0,0175	0,0176	0,01755	0,00007
42	0,0158	0,0178	0,01680	0,00141
43	0,0170	0,0173	0,01715	0,00021
44	0,0170	0,0177	0,01735	0,00049
45	0,0186	0,0180	0,01830	0,00042
46	0,0191	0,0178	0,01845	0,00092
47	0,0191	0,0175	0,01830	0,00113
48	0,0185	0,0166	0,01755	0,00134
49	0,0185	0,0164	0,01745	0,00148
50	0,0172	0,0171	0,01715	0,00007



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung
Merkm.Nr. 2	Merkm.Bez. Konzentritzität
Wiederholpräzision	EV = 0,00057830 ≤ 0,00069116 %EV = 2,07%
Prüfsystemstreuung	GRR = 0,00057830 ≤ 0,00069116 %GRR = 2,07%
Varianz 0,0000047770	
Standardabw. 0,00069116	
Toleranz T^* = 0,2000	Vertrauensniveau $1-\alpha$ = 95,000%
Auflösung %RE = 0,05%	0 5
Prüfsystemstreuung %GRR = 2,07%	0 10 30
Teilestreuung %PV = 7,79%	0 50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc) = 5	0 5
Prüfsystem fähig (%RE,%GRR)	
BOSCH 2012 - MSA: Type 3	
$T_{min}(\%GRR) = 0,0415$	$T'_{min}(\%GRR) = 0,0138$

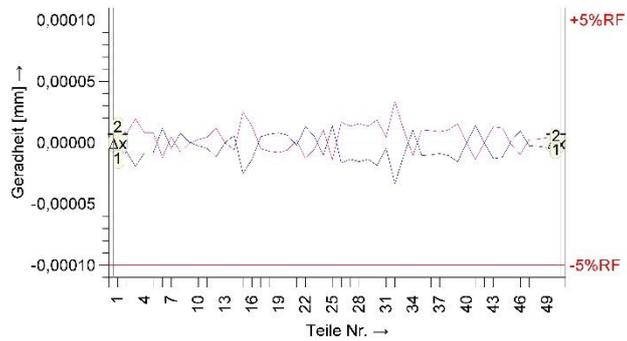
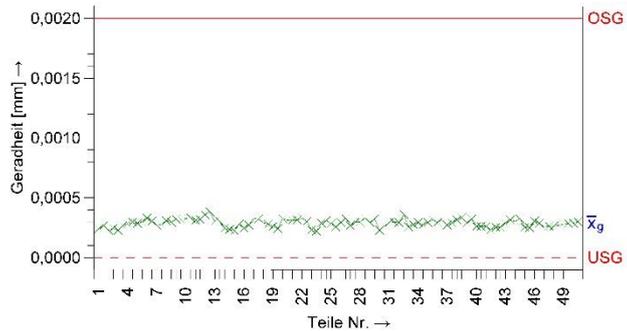
Datum 24.11.2020 Unterschrift 12 / 200503_GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3_Bearbeitet.dfg

Protokoll von solara.MP zum Verfahren drei für die Geradheit (1/2).

	<h2>Messsystemanalyse</h2>	Seite 5 / 8
---	----------------------------	----------------

Datum/Zeit	24.11.2020	Bearb.Name	Schorr Sebastian	Abt./Kst./Prod.	TEF2	Prüfart	
Prüfmittel		Teil			Merkmal		
Prfm.Bez.	Gradient Boosting Reg.	Teilebez.	Druckwaagenbohrung		Merkm.Bez. Geradheit		
Prfm.Nr.		Teilnr.	1 bis 50		Merkm.Nr. 3		
Prfm.Aufl.	0,000001				Nennm.	0,000000 OSG	0,00200 ^A 0,002000
Prüfgrnd.	Validierung				Einh.	mm USG	0,00000 ^B 0,000000
Bemerkung							

n	x _{A,1}	x _{A,2}	$\bar{x}_{g,j}$	s _{g,j}
1	0,000241	0,000267	0,0002540	0,0000184
2	0,000230	0,000245	0,0002375	0,0000106
3	0,000228	0,000267	0,0002475	0,0000276
4	0,000282	0,000298	0,0002900	0,0000113
5	0,000285	0,000301	0,0002930	0,0000113
6	0,000330	0,000306	0,0003180	0,0000170
7	0,000269	0,000278	0,0002735	0,0000064
8	0,000310	0,000295	0,0003025	0,0000106
9	0,000322	0,000321	0,0003215	0,0000007
10	0,000326	0,000331	0,0003285	0,0000035
11	0,000311	0,000320	0,0003155	0,0000064
12	0,000359	0,000382	0,0003705	0,0000163
13	0,000301	0,000301	0,0003010	0,0000000
14	0,000247	0,000235	0,0002410	0,0000085
15	0,000226	0,000276	0,0002510	0,0000354
16	0,000246	0,000273	0,0002595	0,0000191
17	0,000330	0,000320	0,0003250	0,0000071
18	0,000294	0,000280	0,0002870	0,0000099
19	0,000258	0,000242	0,0002500	0,0000113
20	0,000324	0,000312	0,0003180	0,0000085
21	0,000309	0,000313	0,0003110	0,0000028
22	0,000330	0,000304	0,0003170	0,0000184
23	0,000230	0,000220	0,0002250	0,0000071
24	0,000289	0,000310	0,0002995	0,0000148
25	0,000284	0,000256	0,0002700	0,0000198



Teilnr.	1 bis 50		Teilebez.	Druckwaagenbohrung	
Merkm.Nr.	3		Merkm.Bez.	Geradheit	
Wiederholpräzision	Varianz	Standardabw.	EV	%EV	<div style="width: 4.84%;"></div>
Prüfsystemstreuung	0,0000000026007	0,000016127	GRR = 0,000013493 ≤ 0,0000161	%GRR = 4,84%	<div style="width: 4.84%;"></div>
Toleranz		T* = 0,002000	Vertrauensniveau		1-α = 95,000%
Auflösung	%RE	= 0,05%	<div style="width: 0%;"></div>	0	5
Prüfsystemstreuung	%GRR	= 4,84%	<div style="width: 4.84%;"></div>	0	10 30
Teilestreuung	%PV	= 8,53%	<div style="width: 8.53%;"></div>	0	50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc)	ndc	= 2	<div style="width: 20%;"></div>	0	5
Prüfsystem fähig (%RE,%GRR)					
BOSCH 2012 - MSA: Type 3					
T _{min} (%GRR)		= 0,000968	T _{min} (%GRR)		= 0,000323

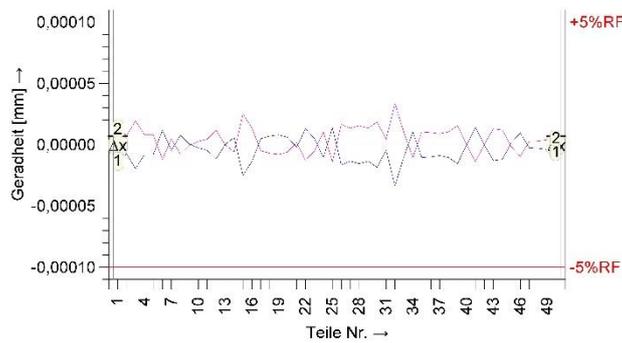
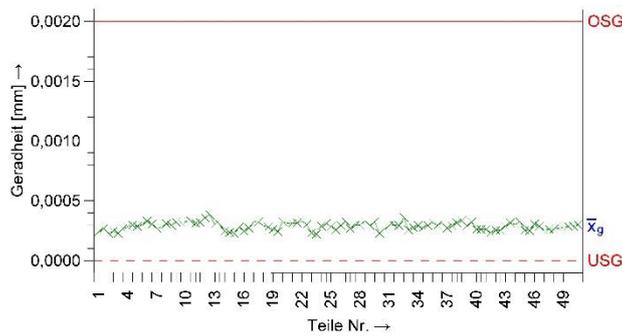
Datum _____ Unterschrift _____ Abteilung _____

Protokoll von solara.MP zum Verfahren drei für die Geradheit (2/2).

	<h2>Messsystemanalyse</h2>	Seite 6 / 8
---	----------------------------	----------------

Datum/Zeit 24.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfört
Prüfmittel		Teil	Merkm.
Prfm.Bez. Gradient Boosting Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Geradheit	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 3	
Prfm.Aufl. 0,000001		Nennm. 0,000000 OSG 0,00200 ^A 0,002000	
Prüfgrnd. Validierung		Einh. mm USG 0,00000 ^B 0,000000	
Bemerkung			

n	x _{A,1}	x _{A,2}	\bar{x}_{gj}	s _{gj}
26	0,000294	0,000327	0,0003105	0,0000233
27	0,000269	0,000296	0,0002825	0,0000191
28	0,000298	0,000329	0,0003135	0,0000219
29	0,000296	0,000323	0,0003095	0,0000191
30	0,000228	0,000265	0,0002465	0,0000262
31	0,000291	0,000300	0,0002955	0,0000064
32	0,000293	0,000360	0,0003265	0,0000474
33	0,000258	0,000277	0,0002675	0,0000134
34	0,000294	0,000273	0,0002835	0,0000148
35	0,000295	0,000316	0,0003055	0,0000148
36	0,000295	0,000315	0,0003050	0,0000141
37	0,000273	0,000291	0,0002820	0,0000127
38	0,000315	0,000336	0,0003255	0,0000148
39	0,000290	0,000321	0,0003055	0,0000219
40	0,000260	0,000260	0,0002600	0,0000000
41	0,000261	0,000233	0,0002470	0,0000198
42	0,000253	0,000254	0,0002535	0,0000007
43	0,000287	0,000313	0,0003000	0,0000184
44	0,000301	0,000325	0,0003130	0,0000170
45	0,000254	0,000251	0,0002525	0,0000021
46	0,000306	0,000287	0,0002965	0,0000134
47	0,000257	0,000262	0,0002595	0,0000035
48	0,000262	0,000268	0,0002650	0,0000042
49	0,000278	0,000286	0,0002820	0,0000057
50	0,000289	0,000300	0,0002945	0,0000078



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung
Merkm.Nr. 3	Merkm.Bez. Geradheit
Wiederholpräzision 0,0000000026007	EV = 0,000013493 ≤ 0,0000161 %EV = 4,84%
Prüfsystemstreuung 0,0000000026007	GRR = 0,000013493 ≤ 0,0000161 %GRR = 4,84%
Standardabw. 0,000016127	
Toleranz T* = 0,002000	Vertrauensniveau 1-α = 95,000%
Auflösung %RE = 0,05%	0 5
Prüfsystemstreuung %GRR = 4,84%	0 10 30
Teilestreuung %PV = 8,53%	0 50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc) ndc = 2	0 5
Prüfsystem fähig (%RE,%GRR)	
BOSCH 2012 - MSA: Type 3	
T _{min} (%GRR) = 0,000968	T _{min} (%GRR) = 0,000323

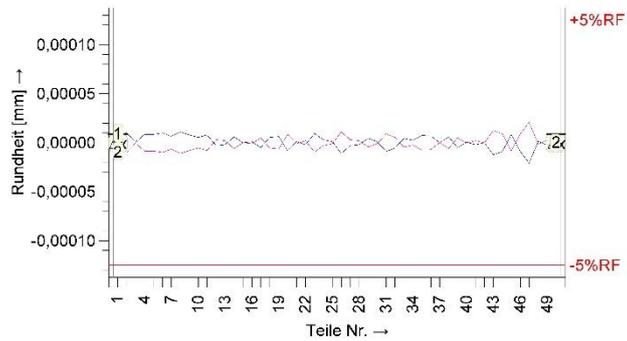
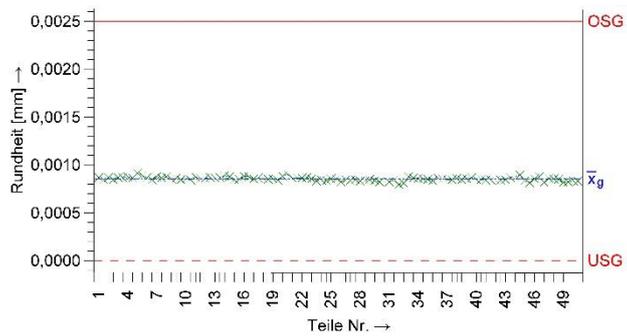
Datum 24.11.2020 Unterschrift 12 / 200503 GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3_Bearbeitet.dfg

Protokoll von solara.MP zum Verfahren drei für die Rundheit (1/2).

	Messsystemanalyse	Seite 7 / 8
---	-------------------	----------------

Datum/Zeit 24.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfört
Prüfmittel		Teil	
Prfm.Bez. Random Forest Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Rundheit	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 4	
Prfm.Aufl. 0,000001		Nennm. 0,000000 OSG 0,00250 ^A 0,002500	
Prüfgrnd. Validierung		Einh. mm USG 0,00000 ^B 0,000000	
Bemerkung			

n	X _{A,1}	X _{A,2}	\bar{x}_{gj}	s _{gj}
1	0,000865	0,000846	0,0008555	0,0000134
2	0,000865	0,000845	0,0008550	0,0000141
3	0,000867	0,000866	0,0008665	0,0000007
4	0,000877	0,000860	0,0008685	0,0000120
5	0,000909	0,000892	0,0009005	0,0000120
6	0,000862	0,000842	0,0008520	0,0000141
7	0,000877	0,000864	0,0008705	0,0000092
8	0,000873	0,000851	0,0008620	0,0000156
9	0,000861	0,000845	0,0008530	0,0000113
10	0,000854	0,000843	0,0008485	0,0000078
11	0,000874	0,000858	0,0008660	0,0000113
12	0,000861	0,000867	0,0008640	0,0000042
13	0,000865	0,000869	0,0008670	0,0000028
14	0,000887	0,000875	0,0008810	0,0000085
15	0,000848	0,000848	0,0008480	0,0000000
16	0,000880	0,000878	0,0008790	0,0000014
17	0,000854	0,000864	0,0008590	0,0000071
18	0,000859	0,000848	0,0008535	0,0000078
19	0,000855	0,000842	0,0008485	0,0000092
20	0,000882	0,000899	0,0008905	0,0000120
21	0,000865	0,000863	0,0008640	0,0000014
22	0,000864	0,000868	0,0008660	0,0000028
23	0,000852	0,000833	0,0008425	0,0000134
24	0,000842	0,000836	0,0008390	0,0000042
25	0,000856	0,000854	0,0008550	0,0000014



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung
Merkm.Nr. 4	Merkm.Bez. Rundheit
Wiederholpräzision 0,00000000095410	EV = 0,0000081728 ≤ 0,000005
Prüfsystemstreuung 0,00000000095410	GRR = 0,0000081728 ≤ 0,000005
Standardabw. 0,0000097678	%EV = 2,34%
	%GRR = 2,34%
Toleranz T* = 0,002500	Vertrauensniveau 1-α = 95,000%
Auflösung %RE = 0,04%	0 5
Prüfsystemstreuung %GRR = 2,34%	0 10 30
Teilestreuung %PV = 4,14%	0 50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc) ndc = 2	0 5
Prüfsystem fähig (%RE,%GRR)	
BOSCH 2012 - MSA: Type 3	
T _{min} (%GRR) = 0,000586	T _{min} (%GRR) = 0,000195

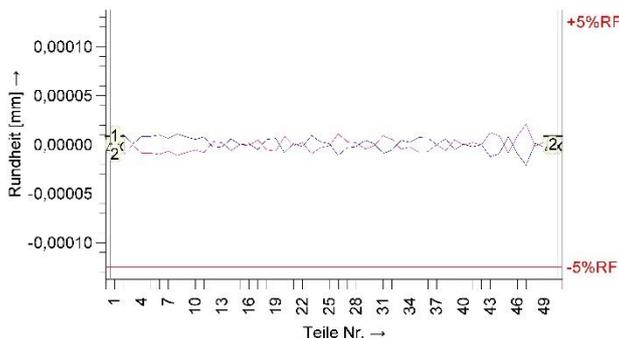
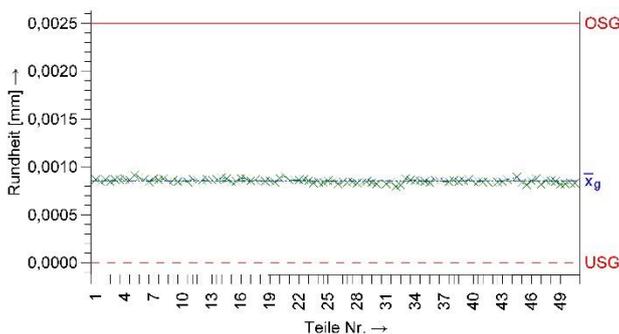
Datum 24.11.2020 Unterschrift 12 / 200503 GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3_Bearbeitet.dfg

Protokoll von solara.MP zum Verfahren drei für die Rundheit (2/2).

	<h2>Messsystemanalyse</h2>	Seite 8 / 8
---	----------------------------	----------------

Datum/Zeit 24.11.2020	Bearb.Name Schorr Sebastian	Abt./Kst./Prod. TEF2	Prüfört
Prüfmittel		Teil	Merkmal
Prfm.Bez. Random Forest Reg.	Teilebez. Druckwaagenbohrung	Merkm.Bez. Rundheit	
Prfm.Nr.	Teilnr. 1 bis 50	Merkm.Nr. 4	
Prfm.Aufl. 0,000001		Nennm. 0,000000 OSG 0,00250 ^A 0,002500	
Prüfgrnd. Validierung		Einh. mm USG 0,00000 ^B 0,000000	
Bemerkung			

n	X _{A,1}	X _{A,2}	\bar{x}_{gj}	s _{gj}
26	0,000821	0,000843	0,0008320	0,0000156
27	0,000838	0,000844	0,0008410	0,0000042
28	0,000829	0,000833	0,0008310	0,0000028
29	0,000845	0,000836	0,0008405	0,0000064
30	0,000823	0,000821	0,0008220	0,0000014
31	0,000822	0,000840	0,0008310	0,0000127
32	0,000798	0,000809	0,0008035	0,0000078
33	0,000872	0,000863	0,0008675	0,0000064
34	0,000860	0,000855	0,0008575	0,0000035
35	0,000850	0,000835	0,0008425	0,0000106
36	0,000864	0,000850	0,0008570	0,0000099
37	0,000846	0,000846	0,0008460	0,0000000
38	0,000858	0,000846	0,0008520	0,0000085
39	0,000855	0,000865	0,0008600	0,0000071
40	0,000848	0,000847	0,0008475	0,0000007
41	0,000839	0,000843	0,0008410	0,0000028
42	0,000839	0,000839	0,0008390	0,0000000
43	0,000846	0,000871	0,0008585	0,0000177
44	0,000876	0,000894	0,0008850	0,0000127
45	0,000832	0,000815	0,0008235	0,0000120
46	0,000856	0,000874	0,0008650	0,0000127
47	0,000818	0,000860	0,0008390	0,0000297
48	0,000853	0,000850	0,0008515	0,0000021
49	0,000816	0,000821	0,0008185	0,0000035
50	0,000832	0,000833	0,0008325	0,0000007



Teilnr. 1 bis 50	Teilebez. Druckwaagenbohrung
Merkm.Nr. 4	Merkm.Bez. Rundheit
Wiederholpräzision 0,00000000095410	EV = 0,0000081728 ≤ 0,000005
Prüfsystemstreuung 0,00000000095410	GRR = 0,0000081728 ≤ 0,000005
Standardabw. 0,0000097678	%EV = 2,34%
	%GRR = 2,34%
Toleranz T* = 0,002500	Vertrauensniveau 1-α = 95,000%
Auflösung %RE = 0,04%	0 5
Prüfsystemstreuung %GRR = 2,34%	0 10 30
Teilestreuung %PV = 4,14%	0 50 100 150
Zahl d. unterscheidb. Messwertklassen (ndc) ndc = 2	0 5
Prüfsystem fähig (%RE,%GRR)	
BOSCH 2012 - MSA: Type 3	
T _{min} (%GRR) = 0,000586	T _{min} (%GRR) = 0,000195

Datum 24.11.2020 Unterschrift 12 / 200503 GC_3_me.def Abteilung Bosch Rexroth AG HoP2 Vorlage_V3_Bearbeitet.dfg