

Maschinelles Lernen zur Überwachung semi-automatischer Bohrprozesse im Flugzeugbau

Vom Promotionsausschuss der
Technischen Universität Hamburg
zur Erlangung des akademischen Grades

Doktor-Ingenieur (Dr.-Ing.)

genehmigte Dissertation (Monografie)

von
Denys Romanenko

aus
Lugansk

2026

1. Gutachter: Prof. Dr.-Ing. Wolfgang Hintze
2. Gutachter: Prof. Dr.-Ing. habil. Prof. h. c. Dr. h. c. Dr. h. c. Bernhard Karpuschewski

Tag der mündlichen Prüfung: 03. November 2025

Wissen schafft Innovation

Herausgeber:

Prof. Dr.-Ing. Wolfgang Hintze
Prof. Dr.-Ing. habil. Hermann Lödding
Prof. Dr.-Ing. Jan Hendrik Dege
Prof. Dr.-Ing. Dr. h. c. Christian Nedeß

Anschrift:

Technische Universität Hamburg
Institut für Produktionsmanagement und -technik
Denickestraße 17
21073 Hamburg

Band 59:

Denys Romanenko
Maschinelles Lernen zur Überwachung semi-automatischer Bohrprozesse im Flugzeugbau
1. Auflage
Hamburg 2026

ISSN der Schriftenreihe: 1613-8244

DOI dieser Arbeit: <https://doi.org/10.15480/882.16351>

Creative Commons Lizenzvertrag

Der Text steht, soweit nicht anders gekennzeichnet, unter der Creative-Commons-Lizenz Namensnennung 4.0 (CC BY 4.0). Das bedeutet, dass er vervielfältigt, verbreitet und öffentlich zugänglich gemacht werden darf, auch kommerziell, sofern dabei stets der Urheber, die Quelle des Textes und o. g. Lizenz genannt werden. Die genaue Formulierung der Lizenz kann unter <https://creativecommons.org/licenses/by/4.0/legalcode.de> aufgerufen werden.

Zusammenfassung

Die aktuelle Lage der globalen Luftfahrtindustrie ist dadurch gekennzeichnet, dass einerseits hohe Auftragsbestände vorliegen und andererseits der Ausbau von Produktionslinien nicht ohne Weiteres möglich ist. Der Neuaufbau von Fertigungseinrichtungen ist mit einem hohen finanziellen Risiko verbunden, und die Ratensteigerung der Fertigung auf den bestehenden Betriebsstätten lässt sich oftmals nur durch Optimierung und Automatisierung aktueller Prozesse erreichen. Gleichzeitig ist durch die technologische Entwicklung der letzten Jahre eine immer bessere Eignung unterschiedlicher Sensortechnologien zur Fertigungsprozessdaten-Erfassung erreicht worden. Die aufgenommenen Daten stellen eine Grundlage für die sich aktuell rasant entwickelnden Methoden der künstlichen Intelligenz (KI) mit ihrem Teilgebiet des maschinellen Lernens (ML) dar. In der Luftfahrzeug-Strukturfertigung bietet das dabei wichtigste Fügeverfahren des Nietens ein potenziell sehr gut geeignetes Szenario zur Anwendung der datenbasierten Überwachungsmethoden, da ein Flugzeug eine äußerst große Anzahl an präzisen Nietbohrungen benötigt. Dies stellt die Grundlage zur Schaffung von Massendaten für das Training von ML-Modellen.

Mit dem Ziel, in der Industrie mithilfe der datenbasierten Methoden die manuellen Aufwände zur Prozessüberwachung zu reduzieren sowie die Werkzeug-Standzeitausnutzung zu steigern, wird in dieser Arbeit das Potential einer ML-basierten Überwachung bei semi-automatischen Bohrprozessen zur Herstellung von Durchgangsbohrungen mittels Vollbohren mit Wendelbohrern untersucht. Die semi-automatische Bohrprozessführung ist eine der dominanten Verfahrensgruppen in der Luftfahrzeug-Strukturmontage, bei der im Rahmen der ML-Anwendung eine Forschungslücke identifiziert wurde.

Im experimentellen Teil dieser Arbeit werden Bohrungen in 44 Prozessszenarien mit einer elektrischen semi-automatischen Bohrvorschubeinheit SmartADU gefertigt. Dabei werden Prozessdaten mithilfe interner Maschinensensorik und extern applizierter Messfühler aufgenommen. Darauf folgen eine ML-basierte Modellierung und eine dazugehörige holistische Abschätzung der Vorhersagegüten für folgende Zielgrößen: Anomaliedetektion, Prozesszustand, Werkstückqualität und Werkzeugverschleiß. Je nach Anwendungsfall werden unüberwachte (Clustering und Ausreißeridentifikation) und überwachte Methoden (Klassifikation und Regression) des maschinellen Lernens angewandt. Die Ergebnisse werden in Bezug auf die Sensorrelevanz sowie die Feature-Extraktion, Modell-Validierungsmethoden, ML-Algorithmen und Objektivfunktionen beim ML-Modelltraining evaluiert.

Die Resultate werden im Hinblick auf eine spätere industrielle Anwendung bewertet. Dabei erfolgt eine Einstufung, für welche Zielgrößen geeignete, bedingt geeignete und nicht geeignete Vorhersagegüten erreicht werden. Die trainierten ML-Modelle stellen sich zur Anomaliedetektion als ungeeignet heraus. Zur Überwachung der Werkstück-Qualität können zum Teil (d. h. in Abhängigkeit der Zielgrößen und der ML-Verfahrensgruppen) ML-Modelle mit bedingt geeigneter und geeigneter Vorhersagegüte aufgebaut werden. Bei dem Prozesszustand- und Werkzeugverschleiß-Monitoring können für die Mehrheit der Zielgrößen ML-Modelle mit geeigneter Vorhersagegüte trainiert werden. Grundsätzlich ist dabei ersichtlich, dass die überwachte Klassifikation die vorteilhafteste ML-Verfahrensgruppe ist.

Summary

The current situation in the global aviation industry is characterised by high order backlogs on the one hand and the fact that the expansion of production lines is not readily possible on the other. The setup of new production facilities is associated with a high financial risk and an increase in production rates at existing facilities can often only be achieved by optimising and automating current processes. At the same time, technological developments in recent years have made it possible to improve the suitability of various sensor technologies for recording production process data. The recorded data provides a basis for the methods of artificial intelligence (AI) with its sub-area of machine learning (ML), which has also developed rapidly in recent years. In aircraft structural manufacturing, the most important joining process of riveting offers a potentially very suitable scenario for the application of data-based monitoring methods, as an aircraft requires a large number of precise rivet holes. Thus, the basis for creating mass data for the training of ML models is provided.

With the aim of using data-based methods to reduce the manual effort required for process monitoring and to increase tool life utilisation, this thesis investigates the potential of ML-based monitoring in semi-automatic drilling processes to produce through holes by means of solid drilling with twist drills. Semi-automatic drilling is a dominant process type in aerospace structural assembly where a research gap has been identified in the context of ML application.

In the experimental part of this thesis, drill holes are produced in 44 process scenarios using an electric semi-automatic drilling unit called SmartADU. Process data is recorded using internal machine sensors and externally applied sensors. This is followed by the development of ML-based models and corresponding holistic determination of the modelling qualities for the target variables of anomaly detection, process status, workpiece quality and tool wear. Depending on the application, unsupervised (clustering and novelty detection) and supervised methods (classification and regression) of machine learning are applied. The results are evaluated with regard to sensor relevance as well as feature extraction, validation methods, ML algorithms and objective functions during ML model training.

The basic findings are assessed in relation to a later industrial application. The target variables with suitable, conditionally suitable and unsuitable prediction qualities are categorised. The trained ML models turn out to be unsuitable for anomaly detection. To monitor workpiece quality, ML models with conditionally suitable and suitable prediction quality can be built in some cases (i.e. depending on the target variables and the ML method groups). For process status and tool wear monitoring, ML models with suitable prediction quality can be trained for the majority of target variables. In principle, it can be seen that supervised classification is the most advantageous ML process group.

Vorwort

Dieses Werk entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Produktionsmanagement und -technik (IPMT) der Technischen Universität Hamburg (TUHH). Einen herzlichen Dank möchte ich zahlreichen Personen aussprechen, deren Unterstützung zur Fertigstellung dieser Dissertation beigetragen hat.

Insbesondere möchte ich Herrn Prof. Dr.-Ing. Wolfgang Hintze für die außerordentliche fördernde Unterstützung bei der Betreuung dieser Arbeit in fachlicher und menschlicher Sicht bedanken. Mit Ihrer technologisch-wissenschaftlichen Begeisterung, Elan, Beharrlichkeit, Ideenreichtum und Wohlwollen haben Sie mir hervorragende Forschungsbedingungen ermöglicht. Herrn Prof. Dr.-Ing. Bernhard Karpuschewski gilt mein Dank für die Übernahme des Korreferats und damit das Interesse an meiner Arbeit. Herrn Prof. Dr.-Ing. Jürgen Grabe danke ich für die Rolle als Vorsitzender des Prüfungsausschusses.

Ohne meine ehemaligen Kollegen am IPMT hätte ich meinen Weg in dieser Form nicht bestreiten können. Eure Hilfsbereitschaft, wohlwollenden kritischen Beiträge, Fachkompetenz und Humor brachten mich in den jeweiligen Arbeitssituationen weiter, sorgten bei diversen Institutsveranstaltungen für ordentliche Lacher, ließen mich als Person reifen und werden mir immer in Erinnerung bleiben. Dabei danke ich Jan Mehnen, Petter Ploog, Lars Köttner, Robert von Wenserski, Marco Hinrichs, Oliver Rosenthal, Melchior Blühm, Sebastian Junghans, Sebastian Schibsdatt, Lasse Evers, Hans-Otto Krause, Dirk Manning, Alexander Brouschkin, Malte Flehmke und Ganna Shchegel. Prof. Dr.-Ing. Jan Dege, Dr.-Ing. Carsten Möller und Dr.-Ing. Axel Friedewald danke ich ebenfalls für die vielfältige Unterstützung während meiner Tätigkeit am IPMT.

Zudem möchte ich den Beitrag der Studenten hervorheben, die innerhalb ihrer Anstellung am Institut oder ihrer studentischen Arbeiten durch ihr Engagement, ihre neuen Perspektiven und ihren geselligen Umgang einen Teil zu dieser Arbeit beigetragen haben. Neben denjenigen, die schon weiter oben als spätere Kollegen genannt wurden, möchte ich insbesondere Lukas Molkentin, Keno Volkmann, Cedric Lutz und Sarah Behr danken. Aus dem Bereich der Industrie gilt mein Dank Michael Schmid, Thomas Langhorst und Jan Stuhmann für ihre unterstützende Fachexpertise. Dem Bundeswirtschaftsministerium danke ich für die Projektförderung im Rahmen des Luftfahrt-Forschungsprogramms. Meinem Freundeskreis bin ich dankbar für die facettenreiche Unterstützung über die Jahre in Form von motivierender gemeinsamer Zeit oder kritischer Anmerkungen zu meinen Dissertationsentwürfen.

Meiner Familie gilt mein größter Dank, sie hat mich in vielfältiger Weise am längsten begleitet. Meine Eltern haben mir alle Voraussetzungen für meinen Bildungsweg ermöglicht. Meine Großeltern waren stets ein Vorbild in Zielstrebigkeit, Fleiß und Bodenständigkeit. Meiner lieben Ehefrau danke ich für die unendliche Geduld, den stabilen Halt und das riesige Verständnis. Und dabei habe ich nur den Bruchteil ihres Beistands nennen können.

Inhaltsverzeichnis

Inhaltsverzeichnis	VII
Abbildungsverzeichnis	XI
Tabellenverzeichnis	XV
Formelverzeichnis	XVII
Quellcodeverzeichnis	XIX
Glossar	XXI
Abkürzungen und Akronyme	XXV
Symbolverzeichnis	XXXIII
1 Einleitung	1
2 Wissenschaftliche und technische Grundlagen	3
2.1 Fertigungsverfahren Bohren	3
2.1.1 Verfahrenstechnische Grundlagen und Werkzeuge	3
2.1.2 Prozessgrößen	4
2.1.3 Kenngrößen der Werkstückqualität	5
2.1.4 Kenngrößen des Werkzeugverschleißes	10
2.2 Klassische Produktionsprozess-Überwachung	13
2.2.1 Zerspanprozess als System	14
2.2.2 Systematisierung der Überwachungsmethoden	14
2.3 Maschinelles Lernen	15
2.3.1 Maschinelles Lernen im Feld der künstlichen Intelligenz	16
2.3.2 Anwendung von maschinellem Lernen	18
2.3.3 Unüberwachtes Lernen	26
2.3.4 Überwachtes Lernen	28
3 Aktuelle Entwicklungen in der Forschung und Industrie	35
3.1 Luftfahrzeug-Strukturmontage	35
3.1.1 Eingesetzte Werkstoffe	36
3.1.2 Fügetechnologien	37
3.1.3 Bohrtechnologien	39
3.2 Maschinelles Lernen in der Produktion	46
3.2.1 Industrie 4.0 im Übergang zur Industrie 5.0	46
3.2.2 Einsatz in Produktionsprozessen	47
3.2.3 Einsatz in Bohrprozessen	51

4	Ableitung der Forschungsfrage, Zielsetzung und Vorgehensweise	55
4.1	Fazit zum Stand der Technik	55
4.2	Ableitung der Forschungsfrage	56
4.3	Zielsetzung	56
4.4	Vorgehensweise	57
5	Experimentelle Datengenerierung	59
5.1	Bohrversuche und online-Prozessdatengenerierung	59
5.1.1	Semi-automatische SmartADU mit interner Sensorik	59
5.1.2	Adaptiver Prüfstand mit externer Sensorik	61
5.1.3	Versuchswerkstoffe und -werkzeuge	68
5.1.4	Versuchsdurchführung und Datenbasis-Generierung	70
5.2	Überwachungs-Kenngrößen und deren offline-Messdatenaufnahme	73
5.2.1	Monitoring von Prozessanomalien	75
5.2.2	Monitoring des Prozesszustandes	75
5.2.3	Monitoring der Werkstückqualität	76
5.2.4	Monitoring des Werkzeugverschleißes	81
5.3	Zusammenfassung der Versuchsdurchführung und Zielgrößendefinition	86
6	Modellierung basierend auf dem maschinellen Lernen	87
6.1	Software- und hardwareseitige Implementierung	89
6.2	ML-Verfahren-unabhängige Verarbeitungsschritte	90
6.2.1	Messdatenimport und -aufbereitung	91
6.2.2	Sensordaten-Fusion	94
6.2.3	Feature-Extraktion	97
6.3	ML-Verfahren- und zielgruppenspezifische Modellierung	103
6.3.1	Monitoring von Prozessanomalien	104
6.3.2	Monitoring des Prozesszustandes	118
6.3.3	Monitoring der Werkstückqualität	120
6.3.4	Monitoring des Werkzeugverschleißes	122
6.4	Untersuchung zum Einfluss der Datensatzgröße	124
6.4.1	Motivation zur Betrachtung des Datensatzgröße-Einflusses	124
6.4.2	Vorgehen	124
6.5	Zusammenfassung zur ML-basierten Modellierung	126
7	Zielgrößenverläufe und Limitation grafischer Kennzahlenevaluation	127
7.1	Versuchsergebnisse der Zielgrößen	127
7.1.1	Anomaliezustand	127
7.1.2	Prozesszustand	128
7.1.3	Werkstückqualität	128
7.1.4	Werkzeugverschleiß	130
7.2	Limitation grafischer Kennzahlenevaluation	133
8	Anomaliedetektion	135
8.1	Unüberwachtes Clustering	135
8.1.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	135
8.1.2	Ranking der finalen Modelle	136
8.2	Unüberwachte Ausreißeridentifikation	137
8.2.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	137
8.2.2	Ranking der finalen Modelle	137

8.2.3	Analyse der Modellierungsstufen	141
8.3	Überwachte Klassifikation	142
8.3.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	142
8.3.2	Ranking der finalen Modelle	144
8.3.3	Analyse der Modellierungsstufen und der Überanpassung	147
8.4	Einfluss der Datensatzgröße	149
8.5	Zusammenfassung und Bewertung	150
9	Prozesszustand-Überwachung	151
9.1	Unüberwachtes Clustering	151
9.1.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	151
9.1.2	Ranking der finalen Modelle	151
9.1.3	Analyse der Modellierungsstufen	156
9.2	Überwachte Klassifikation	156
9.2.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	156
9.2.2	Ranking der finalen Modelle	160
9.2.3	Analyse der Modellierungsstufen und der Überanpassung	164
9.3	Einfluss der Datensatzgröße	166
9.4	Zusammenfassung und Bewertung	167
10	Werkstückqualität-Überwachung	171
10.1	Überwachte Klassifikation und Regression	171
10.1.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	171
10.1.2	Ranking der finalen Modelle	175
10.1.3	Analyse der Modellierungsstufen und der Überanpassung	184
10.2	Einfluss der Datensatzgröße	186
10.3	Zusammenfassung und Bewertung	187
11	Werkzeugverschleiß-Überwachung	191
11.1	Überwachte Klassifikation und Regression	191
11.1.1	Ergebnisse der Feature-Vorbereitung und Sensorrelevanz	191
11.1.2	Ranking der finalen Modelle	195
11.1.3	Analyse der Modellierungsstufen und der Überanpassung	201
11.2	Einfluss der Datensatzgröße	203
11.3	Zusammenfassung und Bewertung	203
12	Bewertung der Vorhersagegüten und industriebezogene Anwendungsempfehlung	207
12.1	Vorhersagegüte der Zielgrößen	207
12.1.1	Betrachtung der Zielgrößen-Vorhersagen im Kontext der industriellen Toleranzfelder	207
12.1.2	Betrachtung der Zielgrößen-Vorhersagen im Kontext des Standes der Technik	210
12.2	Feature-Extraktion	212
12.3	Methoden innerhalb der Modellierungsstufen	213
12.4	Einsatz künstlicher Daten	214
13	Zusammenfassung, Limitation und Ausblick	215
13.1	Zusammenfassung	215
13.2	Limitation	216

13.3 Ausblick	216
Literaturverzeichnis	i
Normen- und Datenblattverzeichnis	xxvii
A Anhang	xxix
A.1 Grundlagen und Stand der Technik	xxix
A.2 Bearbeitete Werkstoffe	xxxv
A.3 Eingesetzte Werkzeuge	xxxvii
A.4 Versuchspläne	xxxviii
A.5 Bohrungsanomalien	xli
A.6 Beispielprotokoll der Rauigkeitsmessung	xliii
A.7 ML-ADU-Monitor Umgebung	xlv
A.8 Import von Sensorgrößen	xlvi
A.9 Feature-Definition	xlix
A.10 Modell-Training	lix
A.11 Modell-Evaluation	lxiv
A.12 Aufbauschneiden-Bildung bei der Bearbeitung von Al2024	lxviii
A.13 Modellierungsergebnisse	lxviii

Abbildungsverzeichnis

1.1	Prognose des Flugzeugbedarfs	1
1.2	Wandlung der Industriedaten	2
2.1	Aufbau und Verfahrenskinetik des Wendelbohrers	4
2.2	Spanungsgrößen und Zerspankräfte an einem Wendelbohrer	5
2.3	Systematisierung der Qualitätseigenschaften von Bohrungen	6
2.4	Gratbildung	7
2.5	Rauigkeitskennwerte	8
2.6	Ausbildung der Delamination an der Werkstück-Austrittsseite	10
2.7	Verschleißprozess am Werkzeug	11
2.8	Verschleißmarke am Werkzeug	12
2.9	Schneidkantencharakterisierung	13
2.10	Verschleißkenngröße Hauptschneiden-Volumen	13
2.11	Zerspanprozess als System	14
2.12	Übersicht zu KI/ML/TL	17
2.13	Maschinelles Lernen - Systematisierung	17
2.14	ML-Modellierungs-Pipeline	19
2.15	Beispiele für unüberwachte Clustering-Algorithmen	27
2.16	Beispiele für unüberwachte Ausreißeridentifikatoren	28
2.17	Beispiele für überwachte ML-Algorithmen	30
2.18	Binäre und Multi-Klassen Klassifikation	32
3.1	Rumpfaufbau bei Luftfahrzeugen und Werkstoffeinsatz beim Airbus A350 .	35
3.2	CFK-Werkstoffaufbau	37
3.3	Nietprozess und -arten	39
3.4	Bohrprozesse in der Luftfahrzeug-Strukturmontage	40
3.5	Manuelle Bohrmaschinen in der Luftfahrzeug-Strukturmontage	40
3.6	Automatisches Bohren in der Luftfahrzeug-Strukturmontage	41
3.7	Semi-automatisches Bohren in der Luftfahrzeug-Strukturmontage	42
3.8	Kinematik des vibrationsunterstützten Bohrens	43
3.9	Schnittmoment und Decklagendelamination in Abhängigkeit der Einspannung	45
3.10	Vernetzte Fertigung für Nietbohrungen	45
3.11	Beispiel für die Güte der Anomaliedetektion im Fräsprozess	48
3.12	Transformation von Zeitreihen-Daten in die Bilddomäne	50
3.13	Beispiel für ML-basierte Prozesszustand-Überwachung im Bohrprozess . . .	53
3.14	Vorhersage der Werkstückqualität in Abhängigkeit der Feature-Vorbereitung beim Bohrprozess	54
4.1	Ableitung der Forschungsfrage	56
4.2	Schema zur Zielsetzung dieser Arbeit	57
4.3	Schema zur Vorgehensweise in dieser Arbeit	58

5.1	Semi-automatische elektrische Bohrvorschubeinheit SmartADU	60
5.2	SmartADU-Prüfstand mit externer Sensorik	62
5.3	Einspannbedingungen der SmartADU und des Werkstücks	63
5.4	Schema zur internen SmartADU- und externen Prüfstandssensorik	64
5.5	G-Sensor Dytran 3053B2	65
5.6	Freifeld-Mikrofon GRAS 146AE	65
5.7	Laser-Distanzsensor Micro-Epsilon ILD 2300-10	66
5.8	Dynamometer Kistler 9271A und 9272	67
5.9	Flussdiagramm zum Gesamtsystem des SmartADU-Versuchsstands	67
5.10	Untersuchte Leichtbauwerkstoffe und deren Abmessungen	68
5.11	CAD-Modell der Versuchswerkzeuge	69
5.12	Versuchswerkzeug-Typen	70
5.13	Gruppen der Überwachungs-Kenngrößen bei der Prozessüberwachung	73
5.14	Gratvermessung	77
5.15	Durchmesservermessung	77
5.16	Rauigkeitsvermessung	78
5.17	Ausgangs-Messgrößen für Bohrungsaustritt-Schädigung bei CFK	80
5.18	Verschleißmessung mittels 2D-Werkzeugvermessung	82
5.19	Verschleißmessung mittels 3D-Werkzeugvermessung	83
5.20	Automatisierte Bestimmung der Schneidkanten-Abflachung	84
5.21	3D-Hauptschneiden-Vermessung	84
5.22	Automatisierte Bestimmung des Hauptschneiden-Volumens	85
5.23	Zusammenfassung zur Zielgrößenaufnahme	86
6.1	ML-Modellierungsablauf	88
6.2	Ein- und Ausgangsdaten der entwickelten MATLAB-Software	89
6.3	ML-Verfahren-unabhängige Verarbeitungsschritte	90
6.4	Sensoren und Sensorgrößen	92
6.5	Beispiel für eine Bohrphasen-Identifikation	95
6.6	Gesamtpfade zur Feature-Extraktion	99
6.7	Beispiel Feature-Extraktion in der Zeit-Domäne	100
6.8	Beispiel-Transformation in die Frequenz-Domäne	101
6.9	Beispiel für die Bild-Domäne	102
6.10	Erstellung der Feature-Matrix aus den Feature-Vektoren	102
6.11	Training der Clustering-Modelle für die Prozessanomalie-Vorhersage	106
6.12	Datenset-Aufteilung bei der unüberwachten Ausreißeridentifikation	109
6.13	Modell-Evaluation bei der unüberwachten Ausreißeridentifikation	110
6.14	Anomaliedetektion: Modell-Ranking bei unüberwachter Ausreißeridentifikation	111
6.15	Anomaliedetektion: Datenset-Einteilung bei überwachter Klassifikation	113
6.16	Anomaliedetektion: Feature-Vorbereitung bei überwachter Klassifikation	114
6.17	Anomaliedetektion: Modellierungs-Pipeline bei überwachter Klassifikation	116
6.18	Anomaliedetektion: Hyperparameteroptimierung bei überwachter Klassifikation	117
7.1	Versuchsergebnisse der Anomaliezustand-Zielgrößen	127
7.2	Versuchsergebnisse zum Ein- und Austrittsgrat	128
7.3	Versuchsergebnisse zum Bohrungsdurchmesser	129
7.4	Versuchsergebnisse zur Rauigkeit	129
7.5	Versuchsergebnisse zur Delamination	130
7.6	Versuchsergebnisse zum Faserüberstand-Faktor	130
7.7	Versuchsergebnisse zur maximalen Verschleißmarkenbreite	131

7.8	Versuchsergebnisse zur Ausbruchsfläche an der Freifläche	131
7.9	Versuchsergebnisse zur Hauptschneiden-Abflachung	132
7.10	Versuchsergebnisse zur Querschneide-Abflachung	132
7.11	Versuchsergebnisse zum Hauptschneiden-Volumen	132
7.12	Repräsentative Verläufe des Spindelmotorstroms	133
7.13	Mittelwert des gefilterten Spindelmotorstroms im Vollschnitt	134
8.1	Anomaliedetektion: Feature-Vorbereitung beim unüberwachten Clustering .	135
8.2	Anomaliedetektion: Modellbewertung und -ranking beim unüberwachten Clustering	137
8.3	Unüberwachte Ausreißeridentifikation - Punktebewertung	138
8.4	Unüberwachte Ausreißeridentifikation - beste Modelle	140
8.5	Unüberwachte Ausreißeridentifikation - Konfusionsmatrix bestes Modell . .	141
8.6	Modellierungsstufen-Bewertung bei unüberwachter Ausreißeridentifikation .	141
8.7	Anomaliedetektion: Feature-Vorbereitung bei überwachter Klassifikation .	143
8.8	Anomaliedetektion: Feature-Signifikanz bei überwachter Klassifikation . . .	144
8.9	Anomaliedetektion: Modell-Performance bei überwachter Klassifikation . .	145
8.10	Anomaliedetektion: beste Modelle der überwachten Klassifikation	146
8.11	Anomaliedetektion: zielgrößenübergreifende Auswertung der überwachten Klassifikation	147
8.12	Anomaliedetektion: Analyse der Modellierungsstufen und der Überanpassung bei überwachter Klassifikation	148
9.1	Prozesszustand: Clustering-Qualität	152
9.2	Prozesszustand: Bewertung der Modellierungs-Pipelines	154
9.3	Prozesszustand: zielgrößenübergreifende Clustering-Bewertung	155
9.4	Prozesszustand: Modellierungsstufen-Bewertung beim unüberwachten Clus- tering	156
9.5	Prozesszustand: Feature-Vorbereitung bei überwachter Klassifikation	157
9.6	Prozesszustand: Feature-Signifikanz bei überwachter Klassifikation	159
9.7	Prozesszustand: Modell-Performance bei überwachter Klassifikation	161
9.8	Prozesszustand: beste Modelle der überwachten Klassifikation (1)	162
9.9	Prozesszustand: beste Modelle der überwachten Klassifikation (2)	163
9.10	Prozesszustand: zielgrößenübergreifende Auswertung der überwachten Klas- sifikation	163
9.11	Prozesszustand: Modellierungsstufen und Überanpassung bei überwachter Klassifikation	165
9.12	Prozesszustand: Einfluss der Datensatzgröße	167
10.1	Werkstückqualität: Feature-Vorbereitung	172
10.2	Werkstückqualität: Feature-Signifikanz bei überwachter Klassifikation	174
10.3	Werkstückqualität: Modell-Performance bei überwachter Klassifikation . . .	176
10.4	Werkstückqualität: Modell-Performance bei überwachter Regression	177
10.5	Beste Modelle zur Vorhersage des Eintrittsgrats	178
10.6	Beste Modelle zur Vorhersage des Austrittsgrats	179
10.7	Beste Modelle zur Vorhersage des Durchmessers	180
10.8	Beste Modelle zur Vorhersage des Mittenrauwerts	181
10.9	Beste Modelle zur Vorhersage des Delaminations-Faktors	181
10.10	Beste Modelle zur Vorhersage des Faserüberstand-Faktors	182
10.11	Beste Modelle zur Vorhersage des Delaminationsradius-Faktors	182

10.12	Werkstückqualität: zielgrößenübergreifende Auswertung	183
10.13	Werkstückqualität: Modellierungsstufen und Überanpassung bei überwachter Klassifikation	185
10.14	Werkstückqualität: Einfluss der Datensatzgröße	187
11.1	Werkzeugverschleiß: Feature-Vorbereitung	192
11.2	Werkzeugverschleiß: Feature-Signifikanz bei überwachter Klassifikation . .	194
11.3	Werkzeugverschleiß: Modell-Performance bei überwachter Klassifikation . .	196
11.4	Werkzeugverschleiß: Modell-Performance bei überwachter Regression . . .	197
11.5	Beste Modelle zur Vorhersage der maximalen Verschleißmarkenbreite . . .	198
11.6	Beste Modelle zur Vorhersage der Ausbruchfläche an der Freifläche	199
11.7	Beste Modelle zur Vorhersage der Hauptschneiden-Abflachung	199
11.8	Beste Modelle zur Vorhersage der Querschneide-Abflachung	200
11.9	Beste Modelle zur Vorhersage des Hauptschneiden-Volumens	200
11.10	Werkzeugverschleiß: Modellierungsstufen und Überanpassung bei überwach- ter Klassifikation	202
11.11	Werkzeugverschleiß: Einfluss der Datensatzgröße	203
A.1	Gratformen	xxx
A.2	Delaminationsarten und -mechanismen	xxx
A.3	Technologien für das vibrationsunterstützte Bohren	xxxix
A.4	CRISP-DM / CRISP-ML(Q)	xxxix
A.5	Varianz und Bias anhand eines Beispiel-Datensets	xxxv
A.6	Beispiel einer Wavelet-Transformation	xxxv
A.7	Erzeugte Bohranomalien	xlii
A.8	Beispielprotokoll Rauigkeitsmessung	xliv
A.9	Ordnerstruktur ML-ADU-Monitor Softwareumgebung	xlvi
A.10	Import interner Sensorgrößen	xlvi
A.11	Import externer Sensorgrößen	xlviii
A.12	Beispiel für eine anomale Bohrung ohne Bohrphasen-Identifikation	l
A.13	Transformation in die Spektral-Domäne (1)	liv
A.14	Transformation in die Spektral-Domäne (2)	lv
A.15	Statistik der Feature-Matrix	lix
A.16	Beispiel zur Erzeugung künstlicher Sensordaten	lxiv
A.17	Aufbauschneiden-Bildung am Werkstoff Al2024	lxviii
A.18	Unüberwachte Ausreißeridentifikation: Vorhersageergebnisse mit bester True Positive Rate	lxx
A.19	Anomaliedetektion: Modell mit bester True Positive Rate bei der überwachten Klassifikation	lxxii
A.20	Prozesszustand: Konfusionsmatrizen beim Clustering	lxxv
A.21	Werkstückqualität: Feature-Signifikanz bei überwachter Regression	lxxviii
A.22	Werkstückqualität: Modellierungsstufen bei überwachter Regression	lxxxiv
A.23	Werkzeugverschleiß: Feature-Signifikanz bei überwachter Regression	lxxxv
A.24	Werkzeugverschleiß: zielgrößenübergreifende Auswertung	lxxxix
A.25	Werkzeugverschleiß: Modellierungsstufen und Überanpassung bei überwach- ter Regression	xc

Tabellenverzeichnis

2.1	Synonyme und Übersetzungen beim maschinellen Lernen	20
3.1	Abgrenzung der Bohrprozesse in der Luftfahrzeug-Strukturmontage	39
3.2	ML-basierte Anomaliedetektion in Produktionsprozessen	47
3.3	ML-basierte Prozesszustand-Überwachung in Produktionsprozessen	49
3.4	ML-basierte Werkstückqualität-Vorhersage in Produktionsprozessen	49
3.5	ML-basierte Werkzeugverschleiß-Vorhersage in Produktionsprozessen	50
3.6	ML-basierte Anomaliedetektion in Bohrprozessen	51
3.7	ML-basierte Prozesszustand-Überwachung in Bohrprozessen	52
3.8	ML-basierte Werkstückqualität-Vorhersage in Bohrprozessen	52
3.9	ML-basierte Werkzeugverschleiß-Vorhersage in Bohrprozessen	54
5.1	Adaptive Prozessparameter der SmartADU	61
5.2	Übersicht zur internen SmartADU- und externen Prüfstandssensorik	64
5.3	Gruppierung der Versuchsreihen	71
5.4	Überwachungs-Kenngrößen	74
6.1	ML-Verfahrensgruppen in Abhängigkeit der Überwachungs-Kenngrößen	87
6.2	Sensoreinsatz in einzelnen Versuchsreihen	91
6.3	Filterung der Daten	94
6.4	Sensoreinsatz Wechsellpunktbestimmung	96
6.5	Datenrepräsentation der Sensorgrößen	97
6.6	Zuordnung zwischen ML-Modellierung und Überwachungs-Kenngrößen	104
6.7	Feature-Vorbereitung für das Clustering innerhalb der Anomaliedetektion	105
6.8	ML-Algorithmen für das Clustering der Prozessanomalie-Detektion	106
6.9	ML-Algorithmen der unüberwachten Ausreißeridentifikation	109
6.10	Anomaliedetektion: Zielgrößen der überwachten Klassifikation	112
6.11	Anomaliedetektion: Feature-Signifikanzanalyse der überwachten Klassifikation	115
6.12	Werkstückqualität: Klasseneinteilung bei überwachter Klassifikation	121
6.13	Werkzeugverschleiß: Klasseneinteilung bei überwachter Klassifikation	123
9.1	Prozesszustand: Zusammenfassung der Vorhersagegüten bester Modelle	169
10.1	Werkstückqualität: Zusammenfassung der Vorhersagegüten bester Modelle	189
11.1	Werkzeugverschleiß: Zusammenfassung der Vorhersagegüten bester Modelle	205
12.1	Fazit zu Vorhersagegüten mit unüberwachten ML-Verfahren	208
12.2	Fazit zu Vorhersagegüten mit überwachten ML-Verfahren	210
12.3	Fazit zur Feature-Extraktion mit überwachten ML-Verfahren	213
12.4	Fazit zu Modellierungsstufen mit überwachten ML-Verfahren	214
A.1	Übersicht über die dominanten Werkstoffe der Luftfahrt-Strukturen	xxix
A.2	Kraftanteile an einem Wendelbohrer	xxx

A.3	Evaluationskennzahlen der überwachten binären Klassifikation (1)	xxxii
A.4	Evaluationskennzahlen der überwachten binären Klassifikation (2)	xxxiii
A.5	Evaluationskennzahlen der überwachten Regression	xxxiv
A.6	Metallische Werkstoffe Al2024 und Ti64 (Ti-6Al-4V / Ti6Al4V / TiAl6V4)	xxxvi
A.7	Bearbeitete CFK-Werkstoffe	xxxvii
A.8	Eigenschaften verwendeter Bohrwerkzeuge	xxxviii
A.9	Versuchsplan Reihengruppe P	xxxix
A.10	Versuchsplan Reihengruppe Q-Ti64	xl
A.11	Versuchsplan Reihengruppe Q-CFK-D	xl
A.12	Versuchsplan Reihengruppe Q-Al2024	xli
A.13	Versuchsplan Reihengruppe A	xli
A.14	Hardware-Spezifikationen des eingesetzten Tower-PC	xlvi
A.15	Kombinationsstufen der Pfade zur Feature-Extraktion	xlix
A.16	Feature-Definition in der Zeit-Domäne	li
A.17	Feature-Definition in der Frequenz-Domäne	liii
A.18	Feature-Definition in der Spektral-Domäne	lvi
A.19	Feature-Definition in der Wavelet-Domäne	lvii
A.20	Feature-Definition in der Bild-Domäne	lviii
A.21	ML-Algorithmen bei überwachter Klassifikation (1)	lxi
A.22	ML-Algorithmen bei überwachter Klassifikation (2)	lxii
A.23	ML-Algorithmen bei überwachter Regression (1)	lxiii
A.24	ML-Algorithmen bei überwachter Regression (2)	lxiii
A.25	Evaluations-Kennzahlen für das unüberwachte Clustering	lxv
A.26	Evaluations-Kennzahlen für die unüberwachte Ausreißeridentifikation und überwachte Klassifikation	lxvi
A.27	Evaluations-Kennzahlen für die überwachte Regression	lxvii
A.28	Einstufung der Evaluationskennzahlen mit festem Wertebereich	lxviii
A.29	Anomaliedetektion: bestes allgemeines Modell der unüberwachten Ausreißer- identifikation	lxix
A.30	Anomaliedetektion: Modell mit der besten True Positive Rate bei der un- überwachten Ausreißeridentifikation	lxx
A.31	Anomaliedetektion: beste allgemeine Modelle der überwachten Klassifikation	lxxi
A.32	Anomaliedetektion: Modell mit der besten True Positive Rate bei der über- wachten Klassifikation	lxxii
A.33	Anomaliedetektion: Einfluss der Datensatzgröße	lxxiii
A.34	Prozesszustand: beste allgemeine Modelle beim unüberwachten Clustering .	lxxiv
A.35	Prozesszustand: beste Modelle der überwachten Klassifikation, Teil 1 . . .	lxxvi
A.36	Prozesszustand: beste Modelle der überwachten Klassifikation, Teil 2 . . .	lxxvii
A.37	Werkstückqualität: beste Modelle der überwachten Klassifikation, Teil 1 . .	lxxix
A.38	Werkstückqualität: beste Modelle der überwachten Klassifikation, Teil 2 . .	lxxx
A.39	Werkstückqualität: 2-Klassen-Modelle der überwachten Klassifikation mit der besten True Positive Rate	lxxxii
A.40	Werkstückqualität: beste Modelle der überwachten Regression, Teil 1 . . .	lxxxiii
A.41	Werkstückqualität: beste Modelle der überwachten Regression, Teil 2 . . .	lxxxiii
A.42	Werkzeugverschleiß: beste Modelle der überwachten Klassifikation	lxxxvi
A.43	Werkzeugverschleiß: 2-Klassen-Modelle der überwachten Klassifikation mit der besten True Positive Rate	lxxxvii
A.44	Werkzeugverschleiß: beste Modelle der überwachten Regression	lxxxviii

Formelverzeichnis

2.1	Zerspankraft beim Bohren	5
2.2	Schnittmoment beim Bohren	5
2.3	Feature-Standardisierung	24
2.4	Objektivfunktion	25
5.1	Delaminationsfaktor	79
5.2	Delaminations-Bezugsfläche	79
5.3	Faserüberstand-Faktor	80
5.4	Delaminationsradius-Faktor	81
5.5	Gewichtung der Einzel-Hauptschneidenverrundungen	83
5.6	Gewichtung der Einzel-Hauptschneidenvolumen	85
6.1	Ausreißererkenung mit dem 1,5-fachen Interquartilsabstand	93
6.2	Nyquist-Shannon-Theorem	94
6.3	Notwendige Abtastrate für die Sensorgrößen	94
6.4	Linear-proportionale Punktezuordnung	107
6.5	Umgekehrt linear-proportionale Punktezuordnung	107
6.6	Gewichtung der Punktwerte für die Evaluationskennzahlen	108
6.7	Gewichteter Gesamtpunktwert einer Modellierungs-Pipeline	108
6.8	Skalierung des Original-Datenpunkts	125
6.9	Verschiebung des Original-Datenpunkts	125
6.10	Generierung des künstlichen Datenpunkts	125
A.1	Matthews Correlation Coefficient	xxxiii
A.2	Cohen's Kappa	xxxiii

Quellcodeverzeichnis

A.1	Pseudo-Code zur Bestimmung der Wechsellpunkte an internen Sensordaten	1
A.2	Berechnung des Amplitudenspektrums	lii
A.3	Extraktion von Features in der Wavelet-Domäne	lvi
A.4	Extraktion von Features in der Bild-Domäne	lvii
A.5	Einbinden externer Bayes'scher Optimierung	lx

Glossar

Augmented Reality

Erweiterung der Realitätswahrnehmung mit digitalen Werkzeugen (dt. *erweiterte Realität*)

Beispiel (maschinelles Lernen)

Dateninstanz, die durch Features beschrieben wird

Bestärkendes Lernen (en. reinforcement learning)

Verfahrensgruppe des maschinellen Lernens, bei dem die Problemlösung durch das Trial-and-Error-Verfahren erarbeitet wird anstatt anhand von gesammelten Daten

Bias

Unterangepasste, zu einfache ML-Modelle weisen einen Vorhersagefehler (= Bias) auf, da sie die Komplexität der vorliegenden Datenstruktur nicht abbilden können

Concentric Collet

Druckluftbetriebene Klemmhülse zur Arretierung der SmartADU

CRISP-DM

Cross Industry Standard Process for Data Mining (dt. *industrieller Standardprozess fürs Data Mining*)

CRISP-ML(Q)

Cross-Industry Standard Process for the Development of Machine Learning Applications with Quality Assurance Methodology (dt. *industrieller Standardprozess zur Entwicklung von Anwendungen des maschinellen Lernens mit Methodik zur Qualitätssicherung*)

Ensemble Learner

Bildung eines machine learning Modells aus mehreren Algorithmen

Feature

Dateneigenschaft, die als Modell-Eingangsgröße dient

Fehlerquote

Anteil der falsch klassifizierten Beispiele

Glare

Glasfaserverstärktes Aluminium

Gramian Angular Field

Bildliche Darstellung von Zeitreihen-Daten durch deren Transformation in Polarkoordinaten und eine anschließende Matrixrepräsentation (in dt. keine gängige Bezeichnung vorhanden)

Industrie 4.0

Vernetzung von Maschinen und Prozessen während der industriellen Produktion mithilfe von Informations- und Kommunikationstechnologie

IPMT

Institut für Produktionsmanagement und -technik der Technischen Universität Hamburg

Kostenfunktion

Fehler zwischen den wahren und modellierten Zielgrößen am gesamten Datensatz

Kreuzvalidierung

Stichprobenverfahren zur Modell-Hyperparameteroptimierung und -Evaluation beim maschinellen Lernen

Markow-Übergangsmatrix

Diese Matrix enthält die Übergangswahrscheinlichkeit zwischen den Zuständen eines Daten-Zeitverlaufs

MATLAB®

Software des Herstellers *The MathWorks, Inc.* zur Programmierung, numerischer Berechnung, Datenanalyse, Modellierung und Visualisierung

ML-ADU-Monitor

Im Rahmen dieser Arbeit entwickeltes Software-Paket in der MATLAB-Softwareumgebung für das ganzheitliche machine learning-basierte Prozessmonitoring (Anomaliedetektion sowie Prozesszustand-, Werkstückqualität- und Werkzeugverschleiß-Überwachung) semi-automatischer Bohrprozesse mit der elektrischen SmartADU-Bohrvorschubeinheit; die Funktionalitäten umfassen Sensordatenimport und -vorbereitung, Featureextraktion sowie Modelltraining, -evaluation und -ranking

Modell-Hyperparameter (maschinelles Lernen)

externe Einstellparameter beim Training von Modellen im Bereich des maschinellen Lernens

Modell-Parameter (maschinelles Lernen)

Interne Modellparameter, die durch das Modelltraining basierend auf dem Dateninput angepasst werden

Objektivfunktion

Funktion, die den Fehler zwischen wahren und vorhergesagten Zielgrößen repräsentiert und während des Modelltrainings minimiert wird

Python

Höhere Programmiersprache

Rekkurenzplot

Zeitreihendaten-Visualisierung als Bild, bei der die Zeitpunkte markiert werden, an denen die Zeitreihenwerte zu einem bereits vorher eingenommenem Wert wiederkehren

RGB-Farbraum

Farbmodell basierend auf den Grundfarben Rot-Grün-Blau, die miteinander vermischt werden

Semi-überwachtes Lernen (en. semi-supervised learning)

Verfahrensgruppe des maschinellen Lernens, bei der im Datensatz neben den vollständig enthaltenen Dateneigenschaften die Zielgrößen nur zum Teil vorhanden sind

Sercos

Genormte digitale Schnittstelle zur Kommunikation zwischen Steuerungen und Feldbusteilnehmern

SmartADU

Elektrische semi-automatische Bohrvorschubeinheit mit variabler Prozessparametereinstellung und interner Sensorik

SmartADU2020

Öffentlich gefördertes Projekt vom Bundesministerium für Wirtschaft und Klimaschutz: Assistenzsysteme und Prozesse für smarte ADU-Bohrtechnologien zur Flugzeugmontage in 2020

Spektrogramm

Diagramm des Zeit-Frequenz-Verlaufs eines Signal-Amplitudenspektrums

Stratifikation

Sicherstellung gleicher Klassenanteile bei Klassifikationsproblemen in jedem Datensatz (Trainings-, Validierungs- und Testdatensatz)

Test-Set

Anteil der Daten zur unabhängigen Performance-Bewertung eines machine learning Modells

Trainings-Set

Anteil der Daten zum Trainieren eines machine learning Modells während der Hyperparameter-Optimierung

Überanpassung (en. overfitting)

Das Modell weist eine hohe Anpassung an das Trainings-Set auf und liefert bei dem Test-Set eine ungenaue Vorhersage

Überwachtes Lernen (en. supervised learning)

Verfahrensgruppe des maschinellen Lernens, bei dem der Datensatz neben den Dateneigenschaften auch die Zielgrößen enthält und das trainierte Modell einen Zusammenhang zwischen diesen herstellt

Unteranpassung (en. underfitting)

Das machine learning Modell ist zu einfach aufgebaut und kann die vorliegenden Datenstrukturen nicht abbilden

Unüberwachtes Lernen (en. unsupervised learning)

Verfahrensgruppe des maschinellen Lernens, bei dem der Datensatz nur die Dateneigenschaften enthält

Validierungs-Set

Anteil der Daten zur Abstimmung der Hyperparameter eines machine learning Modells

Varianz

Überanpassende machine learning Modelle weisen eine hohe Varianz vor, d. h. sie passen sich stark an die Trainingsdaten an

Verlustfunktion

Fehler zwischen der wahren und modellierten Zielgröße an einem einzelnen Datenbeispiel

Z-Standardisierung

Transformation einer Datenreihe in eine Verteilung mit dem Mittelwert $\bar{x} = 0$ und der Standardabweichung $s = 1$

Zielgröße

Vorherzusagende Größe, die von Interesse ist

Abkürzungen und Akronyme

AAM_{MR}

Allgemeines Additives Modell; machine learning Algorithmus zur überwachten Regression

AC_{MC}

Agglomerative Hierarchische Clusteranalyse; machine learning Algorithmus zum unüberwachten Clustering

ADU

Advanced Drilling Unit

AFP

Automated-Fiber-Placement-Prozess

AI

artificial intelligence (dt. *künstliche Intelligenz (KI)*)

Al

Aluminium

Al2024

Aluminiumlegierung (4,4 % Kupfer- und 1,6 % Magnesium-Gewichtsanteil)

AMS

Aerospace Material Specification

ANN

Artificial Neural Network (dt. *künstliches neuronales Netz*)

ANN_{MK}

künstliches neuronales Netz; machine learning Algorithmus zur überwachten Klassifikation

ANN_{MR}

künstliches neuronales Netz; machine learning Algorithmus zur überwachten Regression

ASTM

American Society for Testing and Materials

BS_V	Bootstrapping; Validierungsmethode
BT_{MK}	Boosted Tree (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zur überwachten Klassifikation
BT_{MR}	Boosted Tree (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zur überwachten Regression
BVE	Bohrvorschubeinheit
CC	Concentric Collet
CFK	kohlenstofffaserverstärkter Kunststoff
CFK-D	kohlenstofffaserverstärkter Kunststoff mit duroplastischer Matrix
CFK-T	kohlenstofffaserverstärkter Kunststoff mit thermoplastischer Matrix
Chi_{2F}	Chi-Quadrat-Ranking; Feature-Vorbereitungsmethode
CNC	Computerized Numerical Control, (dt. <i>rechnergestützte numerische Steuerung</i>)
CNN	Convolutional Neural Network (dt. <i>faltendes neuronales Netz</i>)
DA_{MK}	Diskriminanzanalyse; machine learning Algorithmus zur überwachten Klassifikation
DED	Directed Energy Deposition; 3D-Druck durch gerichtete Materialabscheidung
DL	deep learning (dt. <i>tiefes Lernen (TL)</i>)
DMS	Dehnmessstreifen

dt.

deutsch

DT_{MK}

Entscheidungsbaum; machine learning Algorithmus zur überwachten Klassifikation

DT_{MR}

Entscheidungsbaum; machine learning Algorithmus zur überwachten Regression

en.

englisch

ESV_{MA}

One-Class Support Vector Machine (dt. *Ein-Klassen-Stützvektormaschine*); machine learning Algorithmus zur unüberwachten Ausreißeridentifikation

FEM

Finite-Elemente-Methode

FFT

Fast Fourier Transform (dt. *schnelle Fourier-Transformation*)

FN

False Negative (dt.: *falsch negative Vorhersage*)

FP

False Positive (dt.: *falsch positive Vorhersage*)

FT_F

F-Test-Ranking; Feature-Vorbereitungsmethode

FVK

Faserverbund-Kunststoff

GAF

Gramian Angular Field (in dt. keine Bezeichnung vorhanden)

GPM_{MR}

Gauß-Prozess Modell; machine learning Algorithmus zur überwachten Regression

HO_V

Hold-Out-Validierung (in dt. keine gängige Bezeichnung vorhanden); Validierungsmethode

I4.0

Industrie 4.0

IF_{MA}

Isolation Forest (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zur unüberwachten Ausreißeridentifikation

IIoT

Industrial Internet of Things (dt. Internet der Dinge)

KF_V

K-Fold-Validierung (in dt. keine gängige Bezeichnung vorhanden); Validierungsmethode

KI

künstliche Intelligenz (en. *artificial intelligence (AI)*)

KMd_{MC}

K-Medoids (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zum unüberwachten Clustering

KMn_{MC}

K-Means (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zum unüberwachten Clustering

KNN_{MK}

K-Nearest Neighbour (dt. *K-Nächste-Nachbarn-Algorithmus*); machine learning Algorithmus zur überwachten Klassifikation

KPI

Key Performance Indicator (dt. *Schlüsselkennzahl*)

Lapl_F

Laplace-Punktwert; Feature-Vorbereitungsmethode

LOF_{MA}

Local Outlier Factor (dt. *lokaler Ausreißerfaktor*); machine learning Algorithmus zur unüberwachten Ausreißeridentifikation

LOOCV_V

Leave-One-Out Cross-Validation (in dt. keine gängige Bezeichnung vorhanden); Validierungsmethode

LPBF

Laser Powder Bed Fusion; 3D-Druck durch selektives Laserstrahlschmelzen im Materialpulver-Bett

LReg_{MK}	Logistische Regression; machine learning Algorithmus zur überwachten Klassifikation
LReg_{MR}	Lineare Regression; machine learning Algorithmus zur überwachten Regression
MD_{MA}	Mahalonobis-Distanz; machine learning Algorithmus zur unüberwachten Ausreißeridentifikation
ML	machine learning; (dt. <i>maschinelles Lernen (ML)</i>)
MMS	Minimalmengenschmierung
NB_{MK}	Naive-Bayes; machine learning Algorithmus zur überwachten Klassifikation
NC	Numerical Control, (dt. <i>numerische Steuerung von Maschinen-Arbeitsabläufen</i>)
NCA_F	Neighbourhood Component Analysis (in dt. keine gängige Bezeichnung vorhanden.); Feature-Vorbereitungsmethode
PCA_F	Principal Component Analysis (dt. <i>Hauptkomponentenanalyse</i>); Feature-Vorbereitungsmethode
Ph_A	Bohrungsphase Materialaustritt
Ph_E	Bohrungsphase Materialeintritt
Ph_g	Bohrungsphase Gesamtbohrung
Ph_M	Bohrungsphase Gesamtmessung
Ph_v	Bohrungsphase Vollschnitt

PPS

Polyphenylensulfid

RF_{MK}

Random Forest (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zur überwachten Klassifikation

RF_{MR}

Random Forest (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zur überwachten Regression

Rl_F

Relief-Algorithmus; Feature-Vorbereitungsmethode

RMSE

Root Mean Squared Error; (dt. *Quadratwurzel des mittleren quadratischen Fehlers*)

RRCF_{MA}

Robust Random Cut Forest (in dt. keine gängige Bezeichnung vorhanden); machine learning Algorithmus zur unüberwachten Ausreißeridentifikation

RS_V

Resubstitution-Validierung; Validierungsmethode

Stand_F

Z-Standardisierung

SVM_{MK}

Support Vector Machine (dt. *Stützvektormaschine*); machine learning Algorithmus zur überwachten Klassifikation

SVM_{MR}

Support Vector Machine (dt. *Stützvektormaschine*); machine learning Algorithmus zur überwachten Regression

teilw.

teilweise

TFR

Time-Frequency Representation (dt. *Zeit-Frequenz-Repräsentation*)

Ti

Titan

Ti64 (Ti-6Al-4V / Ti6Al4V / TiAl6V4)

$\alpha - \beta$ Titanlegierung mit 6% Aluminium und 4% Vanadium-Gewichtsanteil

TL

tiefes Lernen (en. *deep learning (DL)*)

TN

True Negative (dt. *richtig negative Vorhersage*)

TP

True Positive (dt. *richtig positive Vorhersage*)

VAD

Vibration assisted drilling (dt. *vibrationsunterstütztes Bohren*)

Symbolverzeichnis

Griechische Symbole

α_f	Seitenfreiwinkel Bohrwerkzeug	°
β	Gewichtungsfaktor beim F-Score (FSc_E)	-
β_f	Seitenkeilwinkel Bohrwerkzeug	°
Δr	Schneidkanten-Abflachung	μm
Δ	Wertebereich	-
δ	Drallwinkel Bohrwerkzeug	°
η_c	relativer Anteil der Schnittleistung; umgesetzt an der Hauptschneide	-
η_{el}	elektrischer Wirkungsgrad	-
η_{mech}	mechanischer Wirkungsgrad	-
γ_0	Spanwinkel d. Hauptschneide am Übergang zur Querschneide (Bohrwerkzeug)	°
γ_f	Seitenspanwinkel Bohrwerkzeug	°
λ	Wärmeleitfähigkeit	$W (m K)^{-1}$
λ_g	Grenzwellenlänge	μm
π	Kreiszahl als mathematische Konstante ($\pi = 3,14159\dots$)	-
ν	Poisson-Zahl	-
ψ_i	Modellparameter i eines ML-Modells	-
ρ	Massendichte	$g cm^{-3}$
ρ_A	Flächengewicht	$kg cm^{-2}$
σ	Spitzenwinkel Bohrwerkzeug	°
$\Sigma_{F,i}$	Summe normierter Feature-Signifikanzwerte für Feature i	-
$\Sigma_{PF,wn,ij}$	gewichtete Summe der normierten Feature-Signifikanzwerte des Feature-Extraktionspfads ij	-

θ	Fasertrennwinkel	◦
φ	Verschiebung der Schneidenspitze	◦
φ_F	Faservolumengehalt	%
Lateinische Symbole		
A_{An}	Anomaliezustand Bohrprozess	—
A_B	Bruchdehnung	%
A_c	Spanungsquerschnitt	mm ²
$A_{D,Bez}$	Bezugsfläche Bohrungsaustritt-Delamination	mm ²
A_D	Fläche Bohrungsaustritt-Delamination	mm ²
a_e	Arbeitseingriff	mm
A_F	Fläche Bohrungsaustritt-Faserüberstand	mm ²
A_{nom}	Bohrungsfläche	mm ²
A_{PF}	Peck-Feed Amplitude SmartADU	μm
a_p	Eingriffsbreite	mm
$A_{Si,A}$	Profilfläche der Hauptschneide i, äußeres Segment	mm ²
$A_{Si,I}$	Profilfläche der Hauptschneide i, inneres Segment	mm ²
A_{Si}	Profilfläche eines Segments der Hauptschneide i	mm ²
$a_{x,ADU}$	x-Beschleunigung interner G-Sensor SmartADU	m s ⁻²
$a_{x,ext}$	x-Beschleunigung externer G-Sensor	m s ⁻²
$a_{x/y/z}$	Beschleunigung in x/y/z-Richtung	m s ⁻²
$a_{y,ADU}$	y-Beschleunigung interner G-Sensor SmartADU	m s ⁻²
$a_{y,ext}$	y-Beschleunigung externer G-Sensor	m s ⁻²
$a_{z,ADU}$	z-Beschleunigung interner G-Sensor SmartADU	m s ⁻²
$a_{z,ext}$	z-Beschleunigung externer G-Sensor	m s ⁻²
b	Probenbreite	mm
b_c	Spanungsbreite	mm
B_{AccE}	Balanced Accuracy	—

C	Konzentrizität	mm
c_{CC}	Kontaktzustand Bohrmaschinen-Spannhülse / Werkstück	–
CK_E	Cohen's Kappa	–
D	Durchmesser	mm
d	Distanz-Messung zur Werkstückoberfläche am SmartADU-Versuchsstand	mm
D_f	Durchmesser Kohlenstoffaser in CFK-Werkstoffen	μm
d_M	Distanz Mikrofon/Bearbeitungsstelle	mm
d_B	Abstand der Bohrungen auf den Werkstoffproben	mm
d_c	Distanz der Spannelemente im SmartADU-Versuchsstand	mm
D_{nom}	Nominal-Durchmesser Bohrwerkzeug	mm
E	E-Modul	GPa
e	Evaluationskennzahl zur Bewertung eines machine learning Algorithmus	–
\bar{e}_j	Durschnittswert der Evaluationskennzahl j über Modellierungspipelines	–
e_j	Evaluationskennzahl j	–
$e_{i,j}$	Wert der Evaluationskennzahl j zur Bewertung der Modellierungspipeline i	–
f	(Werkzeug-)Vorschub pro Werkzeugumdrehung	mm
\mathcal{F}	Fourier-Transformierte	–
f_0	Eigenfrequenz	Hz
F_c	Schnittkraft	N
F_f	Vorschubkraft	N
F_M	Feature-Matrix	–
F_p	Passivkraft	N
f_s	Abtastrate	Hz
f_z	(Werkzeug-)Vorschub pro Werkzeugumdrehung und Zahn	mm
f_{Hz}	Frequenz	Hz
f_{PF}	Peck-Feed-Frequenz der SmartADU	Hz
$f_{s,ADU}$	Abtastrate der internen SmartADU-Sensorik	Hz

$f_{s,ext}$	Abtastrate der externen Prüfstand-Sensorik	Hz
$f_{s,notw.}$	nach dem Nyquist-Shannon-Abtasttheorem notwendige Abtastrate	Hz
F_{zer}	Zerspankraft	N
FDR_E	False Discovery Rate (dt. <i>Falsch-Entdeckungs-Rate</i>)	–
FM_E	Fowlkes-Mallows-Index	–
FN	False Negative, Anzahl falsch negativ vorhergesagter Beispiele	–
$FNRE$	False Negative Rate (dt. <i>Falsch-Negativ-Rate</i>)	–
FOR_E	False Omission Rate (dt. <i>Falsch-Auslassungs-Rate</i>)	–
FP	False Positive, Anzahl falsch positiv vorhergesagter Beispiele	–
$FPRE$	False Positive Rate (dt. <i>Falsch-Positiv-Rate</i>)	–
FS_{cE}	F-Score	–
g_j	Gewichtung der Evaluationskennzahl j	–
GM_E	Geometric Mean	–
H	Modell-Speichergröße	Byte
h	Probendicke Werkstoff	mm
HB	Brinell-Härte	HBW
H_c	Abstand zwischen Bohrachse und Kraftangriffspunkt	mm
h_c	Spanungsdicke	mm
h_P	Lagendicke CFK-Prepreg	mm
$h_{c,0}$	Bezugs-Spanungsdicke	mm
i	Index i	–
I_{SM}	Stromstärke Spindelmotor SmartADU (Spindelmotorstrom)	A
I_{VM}	Stromstärke Vorschubmotor SmartADU (Vorschubmotorstrom)	A
Inf_E	Informedness	–
IQR	Interquartilabstand (en. <i>interquartile range</i>)	variabel
J	Objektivfunktion beim Training eines machine learning Modells	variabel
K	Kostenfunktion beim Training eines machine learning Modells	variabel

k	Anzahl der Partitionen bei der k-Fold-Validierung	—
$k_{c1,1}$	spezifischer Schnittkraftkoeffizient	N mm^{-2}
L	Schmierungszustand SmartADU	%
l	Probenlänge	mm
l_1	Gesamtlänge Bohrer	mm
l_2	Spannutlänge Bohrer	mm
l_3	Schneidlänge Bohrer	mm
L_P	Schalldruck	Pa
$L_{E,K}$	maximale klassenbezogene Fehlerquote	—
L_E	Fehlerquote	—
$l_{Si,A}$	Bezugslänge der Hauptschneide i außen vom Spanteiler	mm
$l_{Si,I}$	Bezugslänge der Hauptschneide i innen vom Spanteiler	mm
l_{Si}	Bezugslänge der Hauptschneide i	mm
m	gewichteter Gesamt-Punktwert (äquivalente Darstellung zu $m_{i,gew}$)	—
\bar{m}	Durchschnitt des gewichteten Gesamt-Punktwerts	—
$\bar{m}_{j,gew}$	Durchschnitt des gewichteten Punktwerts der Evaluationskennzahl j	—
$m_{j,gew}$	gewichteter Punktwert der Evaluationskennzahl j	—
M_c	Schnittmoment	Nm
m_c	Werkstoffkonstante der Schnittkraft	—
$m_{i,gew}$	gewichteter Gesamt-Punktwert der Modellierungspipeline i	—
$m_{i,j,gew}$	gewichteter Punktwert d. Evaluationskennzahl j zur Modellierungspipeline i	—
$m_{i,j}$	Punktwert der Evaluationskennzahl j zur Modellierungspipeline i	—
MAE_E	mittlerer absoluter Fehler	variabel
$Mark_E$	Markedness (dt. <i>Deutlichkeit</i>)	—
MCC_E	Matthews Correlation Coefficient	—
$MedA_E$	Median der absoluten Abweichung	variabel
MSE_E	mittlere quadratische Abweichung	variabel

N	Gesamtanzahl	–
n	Drehzahl	min^{-1}
$N_{F,i}$	Anzahl der Vorkommnisse des Features i in der Feature-Matrix	–
$N_{PF,w,ij}$	gewichtete Anzahl der Vorkommnisse eines Feature-Extraktionspfads bei der Feature-Signifikanzanalyse	–
NMI_E	Normalized Mutual Information	–
NPV_E	Negative Predictive Value	–
O	Landau-Operator	–
\bar{O}_F	gemittelter Bewertungsfaktor für Überanpassung	–
O_F	Bewertungsfaktor für Überanpassung	–
$p_{B,j}$	Datenbeispiel j	–
p_B	Gesamtanzahl der Datenbeispiele	–
P_c	Schnittleistung	W
P_{el}	elektrische Leistung	W
$p_{F,j}$	Feature j	–
p_F	Gesamtanzahl Features	–
$p_{i,j}$	(standardisiertes) Feature j des Datenbeispiels i	–
$P_{SM,N}$	elektrische Nennleistung SmartADU-Spindelmotor	W
$P_{VM,N}$	elektrische Nennleistung SmartADU-Vorschubmotor	W
$PF_{i,j}$	Gesamtpfad zur Feature-Extraktion ($j = \text{Einzelpfad} / \text{Einflussgröße } i$)	–
PPV_E	Positive Predictive Value (dt. <i>positiver Vorhersagewert</i>)	–
Q_{DF}	Delaminationsfaktor	–
Q_{DR}	Delaminationsradius-Faktor	–
Q_D	Bohrungsdurchmesser	mm
Q_{FF}	Faserüberstand-Faktor	–
Q_{GA}	maximale Grathöhe am Bohrungsaustritt	μm
Q_{GE}	maximale Grathöhe am Bohrungseintritt	μm

Q_{Ra}	Mittenrauwert an der Bohrungswand	μm
q_s	Skalierungsfaktor bei der Generierung künstlicher Daten	—
q_v	Verschiebungsfaktor bei der Generierung künstlicher Daten	—
Q_x	x-Quantil	variabel
R_E^2	Bestimmtheitsmaß	—
r_β	Schneidkantenradius	μm
R_a	Mittenrauwert nach DIN ISO 1302	μm
$R_{D,max,zul}$	maximal zulässiger Delaminationsradius am Bohrungsaustritt	mm
$R_{D,max}$	maximaler Delaminationsradius am Bohrungsaustritt	mm
R_m	Zugfestigkeit	MPa
R_{nom}	nomineller Bohrungsradius	mm
$R_{p0,2}$	Dehngrenze	MPa
R_p	Höhe der größten Profilspitze	μm
R_s	spezifische Festigkeit	N m g^{-1}
R_t	maximale Rautiefe	μm
R_v	Tiefe des tiefsten Profiltales	μm
R_z	gemittelte Rautiefe nach DIN ISO 1302	μm
RAE_E	relativer absoluter Fehler	—
$RMSE_E$	Wurzel des mittleren quadratischen Fehlers	variabel
$RRMSE_E$	Wurzel des relativen mittleren quadratischen Fehlers	—
RSE_E	relativer quadratischer Fehler	—
s	Standardabweichung	variabel
$S1,A$	Schneide 1 - Profilschnitt außen	—
$S1,I$	Schneide 1 - Profilschnitt innen	—
$S2,A$	Schneide 2 - Profilschnitt außen	—
$S2,I$	Schneide 2 - Profilschnitt innen	—
S_α	Formparameter Schneidkantenverrundung an der Freifläche	μm

Symbolverzeichnis

S_γ	Formparameter Schneidkantenverrundung an der Spanfläche	μm
$S_{e,i}$	Sensor i (extern am Prüfstand)	–
$S_{i,i}$	Sensor i (intern in der SmartADU)	–
t	Zeit	s
t_F	Dauer der Feature-Vorbereitung	s
T_G	Glasübergangstemperatur	$^\circ\text{C}$
t_H	Dauer der Hyperparameteroptimierung	s
t_M	Dauer des Modell-Trainings	s
t_V	Vorhersagezeit	s
TN	True Negative, Anzahl richtig vorhergesagter negativer Klassen	–
TNR_E	True Negative Rate (dt. <i>richtig-negativ-Rate</i>)	–
TP	True Positive, Anzahl richtig vorhergesagter positiver Klassen	–
TPR_E	True Positive Rate (dt. <i>richtig-positiv-Rate</i>)	–
TS_E	Threat Score	–
U_{SM}	Spannung Spindelmotor SmartADU	V
V_{BA}	Ausbruchsfläche an der Hauptschneiden-Freifläche	mm^2
v_c	Schnittgeschwindigkeit	m min^{-1}
$V_{HA,Si,A}$	Schneidenabflachung der Hauptschneide i , äußeres Segment	μm
$V_{HA,Si,I}$	Schneidenabflachung der Hauptschneide i , inneres Segment	μm
V_{HA}	Schneidenabflachung der Hauptschneiden	μm
$V_{HV,Si,A}$	Schneidenvolumen an der Hauptschneide i , äußeres Segment	mm^3
$V_{HV,Si,I}$	Schneidenvolumen an der Hauptschneide i , inneres Segment	mm^3
V_{HV_i}	Schneidenvolumen an der Hauptschneide i , inneres Segment	mm^3
V_{HV}	Hauptschneiden-Volumen	mm^3
V_{QA}	Schneidenabflachung der Querschneide	μm
V_{VB}	max. Verschleißmarkenbreite an der Hauptschneiden-Freifläche	μm
W	Werkstoff	–

\bar{x}	Mittelwert	variabel
x_W	Werkzeugschneide-Dickenkoordinate	μm
$x_{i,j}$	Feature j des Datenbeispiels i	variabel
x_j	Feature-Vektor j	—
\hat{y}	vorhergesagter Wert Zielgröße	variabel
y	wahrer Wert Zielgröße	variabel
z	Schneidenanzahl	—
z_W	Werkzeugschneide-Höhenkoordinate	μm

1 Einleitung

Der weltweite zivile Luftverkehr und damit auch der Bedarf nach neuen treibstoffsparenden und leiseren Flugzeugen trotz den globalen Krisen und ist gemäß diverser Studien auf einem Wachstumspfad. In den nächsten 20 Jahren wird mit einer Nachfrage an etwa 42.000 - 44.000 neuen Auslieferungen und einem damit verbundenen Anstieg des Flugzeugbestands, bezogen auf Passagiermaschinen mit mehr als 100 Sitzplätzen und Frachtmaschinen mit mehr als 10 t Zuladung, um 75 - 100 % gerechnet, siehe dazu eine der Beispielprognosen in der Abbildung 1.1. Dementsprechend sind die Auftragsbücher großer Flugzeughersteller auf Jahre hinweg gefüllt, was mit einer hoher Wartezeit für Airlines verbunden ist [Air24], [Hul24].

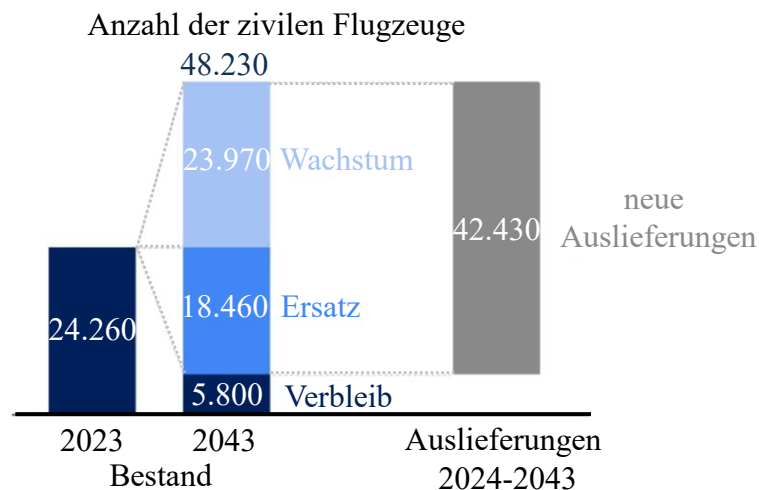


Abbildung 1.1: Prognose des Flugzeugbedarfs für Passagiermaschinen mit > 100 Sitzplätzen und Frachtmaschinen mit > 10 t Zuladung nach [Air24]

Das dominante Fügeverfahren bei der Montage von Luftfahrzeug-Strukturen ist das Nieten [Ray06]. Die Anzahl notwendiger Nietbohrungen schwankt je nach Flugzeugtyp und Quelle in dem Bereich von 230.000 - 750.000 für Mittel- und Langstreckenflugzeuge [Air15], [Dom+22]. Aktuell findet bei der Bohrungsherstellung eine Transition von manuellen Bohrverfahren hin zu semi-automatischen und automatischen Prozessen mit sensorintegrierten elektrischen Maschinen statt [Hin+19a]. In der Zukunft wird von einer dominierenden Koexistenz beider letztgenannten Verfahren ausgegangen [SGR23]. Aktuell wird unabhängig vom Bohrprozess der Werkzeugwechsel oftmals nach einem festen Zyklus vorgenommen, und die Qualitätskontrolle ist mit einem hohen manuellen Aufwand verbunden [Hin+19a].

Die künstliche Intelligenz (KI) und deren Subkategorie maschinelles Lernen (ML) haben in den letzten Jahren im täglichen Berufs- und Privatleben vieler Menschen Einzug gehalten. In der Produktion ist ebenfalls ein Wachstum der KI-Anwendungen zu beobachten. Diese finden beispielsweise in den Bereichen der Kundenbetreuung, Performanceoptimierung, automatischer Entscheidungsfindung, Nachfrageprognose, vorausschauender Wartung, Maschinenüberwachung und Qualitätskontrolle ihren Einsatz [MS24]. Als Anwendungstechniken sind hierbei das maschinelle Lernen zur Sensordatenverarbeitung, die Sprachverarbeitung,

das maschinelle Sehen oder die generative KI zur Erzeugung einer angeforderten Information zu nennen [FD24]. Die Prognosen diverser Beratungs- und Technologieakteure sagen aufgrund der KI-Potentiale einen rasanten Anstieg der KI-basierten Anwendungen in der Industrie voraus. Je nach Quelle wird ein Gesamtwachstum zwischen 600 % und 1400 % in den nächsten 5 Jahren prognostiziert [Bus25], [Pol24]. Der Einsatz des maschinellen Lernens wird durch die immer größeren Datenmengen (= Big Data) ermöglicht. Dies erfordert jedoch die Weiterentwicklung der etablierten Strategien zur Datenverarbeitung, da sich die Big Data Eigenschaften von denen der traditionellen Daten unterscheiden, siehe Abbildung 1.2.

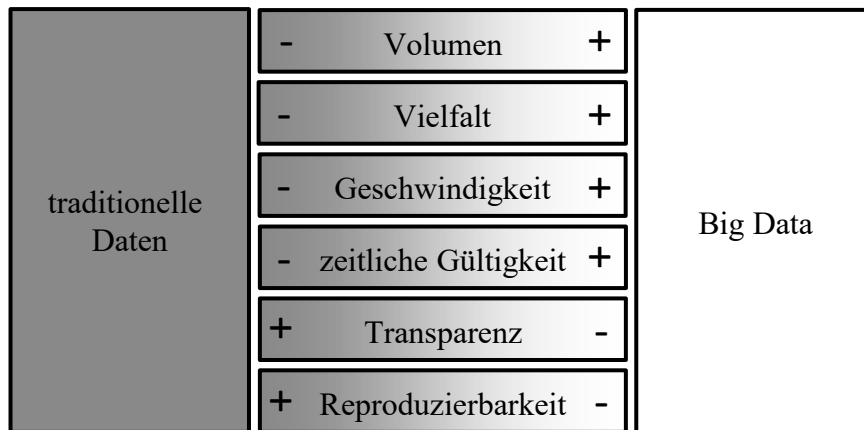


Abbildung 1.2: Wandlung der Industriedaten nach [MS24, S. 125]

Die Motivation dieser Arbeit entspringt aus dem Potential der Massendaten bei der Bohrungsfertigung in der Luftfahrzeug-Strukturmontage. Durch eine Sensorintegration und damit verbundene Datenerfassung in diesem häufig wiederholten Prozess bietet sich die Anwendung der ML-Methoden innerhalb der Prozessüberwachung an. Trotz des teilweise erfolgten Einsatzes maschineller Lernverfahren in Produktionsprozessen besteht eine Forschungslücke bei deren Anwendung im Bereich des semi-automatischen Bohrens. Daher wird in dieser Dissertation die Vorhersagegüte unüberwachter und überwachter ML-Algorithmen bei den Zielgrößen der Anomaliedetektion, Prozesszustand-, Werkstückqualität- und Werkzeugverschleiß-Überwachung semi-automatischer Bohrprozesse zur Herstellung von Durchgangsbohrungen beim Bohren ins Volle mit Wendelbohrern untersucht. Als Grundlage dienen dazu eigenständig aufgenommene Versuchsdaten mit einer hohen Prozessvariation mithilfe der elektrischen semi-automatischen Bohrvorschubeinheit SmartADU. Innerhalb der durchgeführten ML-basierten Modellierung werden vielfältige Einflussfaktoren auf die Vorhersagegüte, wie beispielsweise Sensorart, Feature-Vorbereitung oder ML-Algorithmus, untersucht. Als Ergebnis werden Zielgrößen mit geeigneter, bedingt geeigneter und nicht geeigneter Vorhersagegüte identifiziert.

Bei Zielgrößen mit hohen Vorhersagegüten wird mit den entwickelten Methoden der Weg zur automatischen Prozessüberwachung sowie optimaler Werkzeugstandzeit-Ausnutzung geebnet. Dies verspricht hohe Kosten- sowie Ressourceneinsparungen. Die frei gewordenen Kapazitäten können zum Abarbeiten des anfangs erwähnten Auftragsbestandes in der Luftfahrtindustrie genutzt werden, was zu einem globalen Wettbewerbsvorteil bzw. Produktionssicherung in bestehenden Luftfahrtindustrie-Clustern beiträgt.

Diese Arbeit ist am Institut für Produktionsmanagement und -technik der Technischen Universität Hamburg aufbauend auf dem öffentlich geförderten Projekt des Luftfahrtforschungsprogramms V-2 mit dem Akronym *SmartADU2020* (Förderkennzeichen 20Q11522) entstanden.

2 Wissenschaftliche und technische Grundlagen

In diesem Kapitel werden die Grundlagen dieser Arbeit erklärt, bei denen davon auszugehen ist, dass diese ausreichend erforscht sind. Dies betrifft die Grundmechanismen des Fertigungsverfahrens Bohren, die in der Industrie etablierte klassische Produktionsprozess-Überwachung sowie die Grundlagen des maschinellen Lernens (ML).

2.1 Fertigungsverfahren Bohren

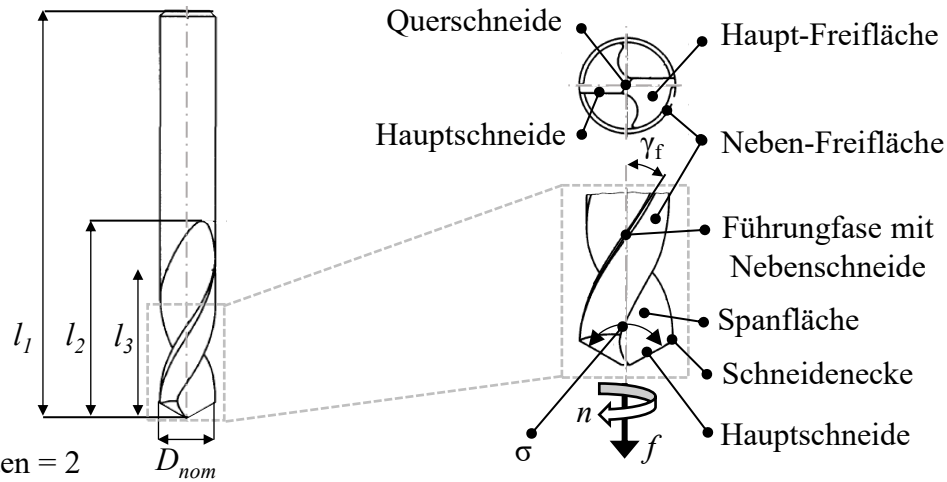
In den nächsten Abschnitten wird auf die Verfahrensgrundlagen der Bohrbearbeitung und die dabei eingesetzten Werkzeuge eingegangen. Anschließend erfolgt die Einführung in die Prozessgrößen, die Qualitätskennzahlen und die Verschleißformen der Werkzeuge.

2.1.1 Verfahrenstechnische Grundlagen und Werkzeuge

Das Bohren zeichnet sich als ein spanabhebendes Fertigungsverfahren mit einer rotatorischen Schnittbewegung und einer Vorschubbewegung in Richtung der Drehachse aus. Es wird in die Gruppe der trennenden Fertigungsverfahren mit bestimmter Schneide eingeordnet. Die Drehung kann vom Werkzeug oder dem Werkstück erzeugt werden. In dieser Arbeit wird die Verfahrensgruppe Bohren ins Volle zur Herstellung von Durchgangsbohrungen mit einem Wendelbohrer (auch als „Spiralbohrer“ bezeichnet), welcher die am meisten verwendete Bohrwerkzeugart repräsentiert, untersucht. Daher konzentrieren sich die kommenden Inhalte ausschließlich auf diese Domäne. Der Aufbau eines Wendelbohrers mit der Skizze der Verfahrenskinematik ist in der Abbildung 2.1 zu sehen [DIN 8589-2], [DIN 8580], [Pau08, S. 134–143], [KT93], [Hei14].

Der Wendelbohrer setzt sich aus einem Schaft, dem Schneidteil mit Spannuten und Führungsfasen inklusive Nebenschneiden sowie der Spitze mit der Haupt- und Querschneide(n) zusammen. Der größte Teil der Zerspanarbeit wird an den Hauptschneiden umgesetzt. Die Führungsfasen dienen der Stabilisation des Bohrers, die Spannuten gewährleisten die Spanabfuhr, und die Nebenschneiden beeinflussen die Qualität der Bohrungswand. Die Geometrie und der Schneidstoff können anforderungsgerecht gestaltet werden [Pau08, S. 134–143], [Klo18, S. 568–576].

Der Spanwinkel an den Hauptschneiden hat einen variablen Verlauf und sinkt vom höchsten Wert an den Schneidenecken (γ_f) hin zum niedrigsten Wert am Übergang zur Querschneide (γ_0) ab. In gleicher Weise erfolgt die Definition des Seitenfreiwinkels α_f und des Seitenkeilwinkels β_f ausgehend von der Schneidenecke. Der Spitzenwinkel σ entspricht dem doppelten Werkzeug-Einstellwinkel κ und weist einen Gestaltungsbereich von etwa 90° bei harten Kunststoffen bis etwa 140° bei langspanenden Leichtmetallen auf [Klo18, S. 568–576].



Anzahl Schneiden = 2


Abbildung 2.1: Aufbau und Verfahrenskinetik des Wendelbohrers nach [DIN 1412], [DIN 6581] (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, D_{nom} = Nenn-Durchmesser, l_1 = Gesamtlänge, l_2 = Spannutlänge, l_3 = Schneidlänge, γ_f = Seitenspanwinkel, σ = Spitzwinkel)

Bei der Anschliffform der Bohrer Spitze hat sich primär der Kegelmantelschliff durchgesetzt [DIN 1412]. Als Schneidstoff werden vorwiegend Schnellarbeitsstahl und Vollhartmetall eingesetzt. Letzterer ermöglicht höhere Schnittgeschwindigkeiten (z. B. bis $v_c = 1000$ m/min bei Aluminiumlegierungen) und Vorschübe pro Werkzeugumdrehung f bei besserer Verschleißfestigkeit, dabei werden jedoch höhere Anforderungen an Positioniergenauigkeit, Kühlung und Maschinensteifigkeit gestellt. Bei Bedarf kann die Kühlmittelzufuhr über die Spannuten oder integrierte Kühlkanäle erfolgen [Pau08, S. 134–143], [Die16, S. 134–138], [Hei14].

2.1.2 Prozessgrößen

Die Schnittgrößen Vorschub pro Werkzeugumdrehung f und Drehzahl n werden durch die Prozesseinstellungen vorgegeben. Daraus leiten sich mit dem Nenn-Durchmesser D_{nom} und der Zähnezahl z die Schnittgeschwindigkeit v_c und der Vorschub pro Schneide f_z ab, siehe Abbildung 2.2. Durch die Überlagerung einer translatorischen und rotatorischen Bewegung folgen die Hauptschneiden einer schraubenförmigen Bahn. Als Wert der Schnittgeschwindigkeit v_c wird die Größe an den Schneidenecken definiert, da v_c zur Bohrermitte abnimmt und an der Spitze $v_c = 0$ beträgt. Daher ist während des Zerspanprozesses in der Mitte an der Querschneide nur eine Druck- und keine Schnittbewegung vorhanden, was hohe Vorschubkräfte F_{f1}/F_{f2} zur Folge hat. Des Weiteren sind in der Abbildung 2.2 die Spannungsgrößen Spannungsdicke h_c , Spannungsbreite b_c und Spannungsquerschnitt A_c skizziert.

Die Zerspankraft F_{zer} an einer Schneide setzt sich aus den orthogonalen Komponenten Vorschubkraft F_f , Schnittkraft F_c und Passivkraft F_p gemäß der Gleichung 2.1 zusammen. Bei einem zweiseidigen Wendelbohrer mit einem symmetrischen Anschliff gleichen sich die Passivkräfte F_{pi} und die Schnittkräfte F_{ci} an den beiden Schneiden aus und die Vorschubkraft addiert sich aus den einzelnen Anteilen zusammen. Die Kraftresultierenden greifen in einem ungefähren Abstand H_c von der Bohrerachse an jeder Schneide an. Mit H_c lässt sich das wirkende Schnittmoment M_c gemäß Gleichung 2.2 berechnen. Als abgeschätzter Wertebereich für H_c ist das Intervall $H_c = [0,15 \cdot D_{nom}; 0,32 \cdot D_{nom}]$ in einschlägiger Literatur angegeben. In der Tabelle A.2 im Anhang A.1.2 sind die Kraft- und Drehmomentanteile an einem Wendelbohrer verglichen. Das Schnittmoment M_c wird mehrheitlich an den Hauptschneiden und die Vorschubkraft F_f an der Querschneide übertragen.



Anzahl Schneiden = 2

Abbildung 2.2: Spannungsrößen und Zerspankräfte an einem Wendelbohrer nach [Klo18, S. 577–580] (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, D_{nom} = Nenndurchmesser, σ = Spitzwinkel, f_z = Vorschub pro Zahn und Werkzeugumdrehung, h_c = Spannungsstärke, b_c = Spannungsweite, A_c = Spannungsquerschnitt, a_p = Schnitttiefe, F_{pi} = Passivkraft an der Schneide i , F_{ci} = Schnittkraft an der Schneide i , F_{fi} = Vorschubkraft an der Schneide i , H_c = Abstand zwischen Bohrachse und Kraftangriffspunkt)

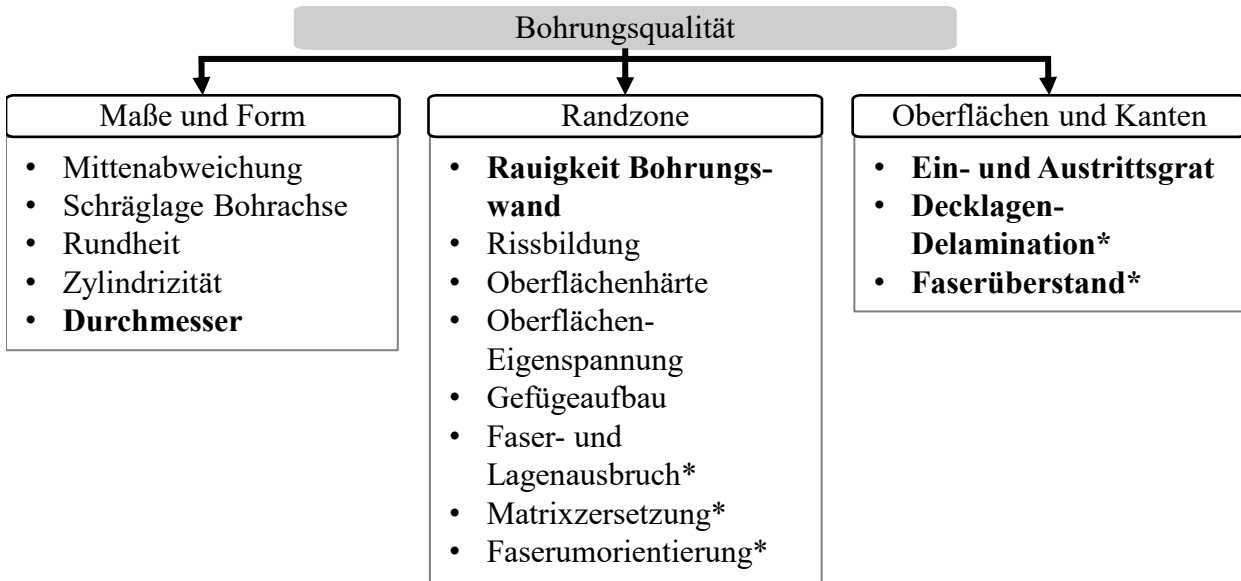
$$F_{zer} = \sqrt{F_f^2 + F_c^2 + F_p^2} \quad (2.1)$$

$$M_c = F_c \cdot H_c \cdot z \quad (2.2)$$

Die Abschätzung der Schnittkraft an der Hauptschneide lässt sich beispielsweise mittels des (empirischen) Schnittkraftgesetzes nach KIENZLE durchführen [Kie52], [Klo18, S. 578], [Pau08, S. 145], [DT11, S. 59]. Dabei sind unterschiedliche Korrekturfaktoren für die Schnittparameter, Spannungsgrößen und Werkzeuggeometrie zu verwenden. Bei Wendelbohrern mit Kegelmantelschliff entstand die experimentell ermittelte Abschätzung, dass die Vorschub- und Schnittkraft (als Summe über die Schneiden) sich in einem ähnlichen Bereich bewegen ($F_f \approx F_c$). Zusätzlich zu der Zerspankraft F_{zer} wirken zwischen den Fasen des Bohrwerkzeugs und der Bohrungswand Reibungskräfte. Die in diesem Abschnitt dargestellten Grundlagen basieren auf den Werken [Pau08, S. 144–188], [Klo18, S. 577–580], [Die16, S. 136–146].

2.1.3 Kenngrößen der Werkstückqualität

Das Einhalten der Qualitätsanforderungen innerhalb der vorgegebenen Wirtschaftlichkeits- und Technologiegrenzen ist das primäre Ziel eines Fertigungsprozesses. In der Abbildung 2.3 erfolgt eine eigens erstellte Systematisierung unterschiedlicher Qualitätseigenschaften orientiert auf den Ausführungen in [Hin21a], [Pau08], [Die16], [Dos15]. Zum Teil sind die quantitativen Bewertungskennzahlen für einzelne Qualitätskriterien offenkundig (z. B. beim Durchmesser). Bei einigen anderen Qualitätskriterien (z. B. Decklagen-Delamination) sind unterschiedliche Bewertungskennzahlen anwendbar. Nachfolgend wird nur auf die als am relevantesten eingeschätzten und damit in dieser Arbeit untersuchten Qualitätseigenschaften eingegangen.



Fett: in dieser Arbeit untersucht; *: nur bei FVK-Werkstoffen

Abbildung 2.3: Systematisierung der Qualitätseigenschaften von Bohrungen aufbauend auf [Hin21a], [Pau08], [Die16], [Dos15]

2.1.3.1 Grat am Bohrungsein- und -austritt

Gratbildung am Bohrungsein- und -austritt entsteht durch eine Werkstoffausfransung des plastisch verformten Restmaterials bei der Bearbeitung von metallischen Werkstoffen. Bei FVK-Werkstoffen besteht der Grat aus Resten der Matrix [Pau08], [Pfe14], [Aur+09]. Grundsätzlich ist der Austrittsgrat kritischer, da dieser meist größer und die Austrittsseite der Bohrung schwieriger zugänglich ist. In [MKD01] wird folgende Gratformen-Klassifikation vorgeschlagen (siehe weiterführend Abbildung A.1 im Anhang A.1.2):

- *gleichmäßiger Grat*: Dieser entsteht bei geringen Vorschüben und Drehzahlen und zeichnet sich durch eine niedrige und gleichmäßige Grathöhe sowie eine Gratkappe aus.
- *Kronengrat*: Die Grathöhe ist unregelmäßig und entsteht infolge hoher Vorschübe.
- *transienter Grat*: = Übergangsform zwischen dem gleichmäßigem Grat / Kronengrat

Zur Quantifizierung der Gratbildung sind unterschiedliche Kennzahlen möglich, siehe dazu die Abbildung 2.4. Im Rahmen dieser Arbeit wird die Messung der in Industrie häufig verwendeten maximalen Grathöhe umgesetzt. Die Betrachtung der Gratbildung ist essentiell, da überstehender Grat einen Einfluss auf das Absinken der Vorspannung bei Nietverbindungen und damit deren Betriebsfestigkeit hat [Bu+16], [Hin21a, S. 238]. Zudem bildet überstehender Grat ein Verletzungsrisiko für Menschen und ein Schädigungsrisiko für Bauteile. Beim Überschreiten von entsprechenden Grenzwerten ist in der Luftfahrt-Produktion daher eine (oftmals manuelle) aufwendige Nacharbeit notwendig [Hin+19a].

Die Erhöhung des Vorschubs pro Werkzeugumdrehung f und damit der Vorschubkraft F_f lässt auch die Grathöhe ansteigen [PR86]. Steigender Werkzeugverschleiß führt bei der Bearbeitung von Aluminium- und Titanlegierungen ebenfalls zu erhöhter Gratbildung [EDW17], [MJX21]. Mit steigender Schnittgeschwindigkeit v_c erhöht sich auch die Grathöhe beim Bohren der am häufigsten verwendeten Titanlegierung Ti6Al4V, da hierbei das plastische Umformvermögen bei höheren Temperaturen ansteigt [Jan03]. Daraus lässt sich ableiten, dass die Grathöhe durch Kühlung gesenkt werden kann. Zudem wird in [Hin21a, S. 239] beschrieben, dass die

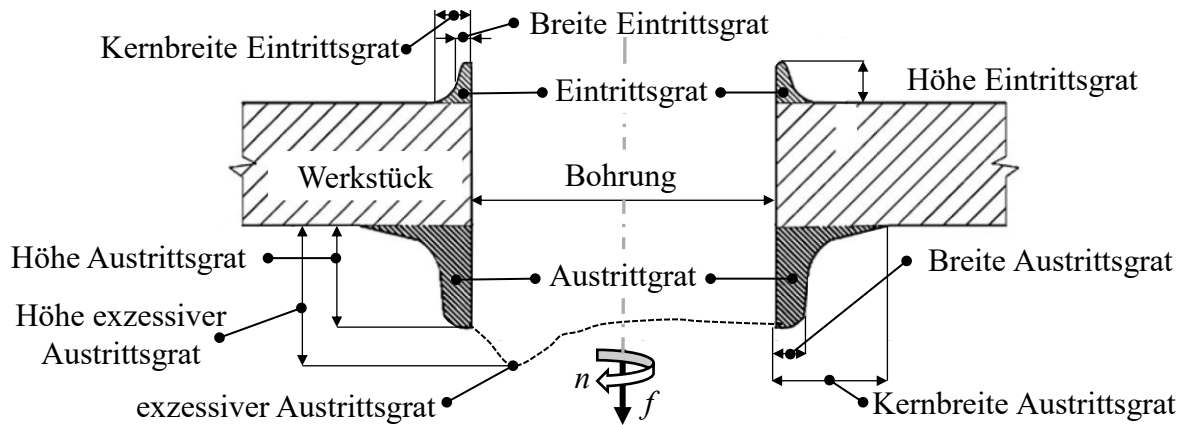


Abbildung 2.4: Gratbildung nach [Pil+12] (f = Vorschub pro Werkzeugumdrehung, n = Drehzahl)

Gratbildung eine Abhängigkeit vom Umformvermögen des Werkstoffs aufweist. In [Pil+12] wird beim Bohren von Aluminium (Legierung Al99.7Mg0.5Cu-H24) festgestellt, dass eine Austrittsgrat-Senkung durch die Reduktion des Vorschubs pro Werkzeugumdrehung f , die Erhöhung der Schnittgeschwindigkeit v_c und eine steifere Aufspannung des Werkstücks erreicht wird. Die Autoren von [Abd+15] stellen dazu im Gegensatz fest, dass die Austrittsgrat-Höhe bei Titan (Ti6Al4V)- und Aluminiumlegierungen (Al7010-T7451 und Al2024-T351) am niedrigsten im mittleren Bereich des jeweiligen werkstoffspezifischen Vorschub-Parameterraums ist.

Die Gratvermessung ist durch taktile Messsysteme oder optische Mikroskope möglich. Dabei werden jedoch häufig nur einzelne Kennzahlen, wie z. B. die Grathöhe erfasst. Mit einer 3D-Vermessung (z. B. Erfassung mittels eines 3D-Laserscanning-Mikroskops oder Fokusvariation) ist eine ganzheitliche Graterfassung und -auswertung möglich.

2.1.3.2 Bohrungsdurchmesser

Der Bohrungsdurchmesser ist als Maßtoleranz an die Formtoleranzen Rundheit und Zylindrizität gekoppelt. In Summe sind diese Qualitätsmerkmale bedeutend zur Herstellung der Passung von Nietverbindungen bei der Flugzeug-Strukturmontage. Eine gute Zentrierung, unverschlissener Bohrer sowie ein möglichst ideal-symmetrischer Anschliff des Bohrers sind die Voraussetzung zur Vermeidung von Überweite und Konizität und damit Einhaltung der Durchmesser-toleranz. Im Falle von unsymmetrischen Werkzeugen läuft die Radialkraft des Bohrers um und sorgt für die Aufweitung des Bohrlochs [Pau08, S. 152], [Klo18, S. 575], [BNN11], [KHS12]. Des Weiteren kann auch das Werkstück für eine mangelhafte Zentrierung des Bohrers sorgen. Werkstoffinhomogenitäten oder geringe bzw. variierende Steifigkeit gelten dabei als mögliche Ursachen [Pau08, S. 151]. Insbesondere beim Bohren im unidirektionalen CFK tritt eine z. T. hohe radiale Deformation in Abhängigkeit der Faserorientierung auf. Aufgrund des orthotropen Elastizitätsverhaltens wird hierbei die Problematik von unrun- den Bohrungen verschärft [Hin21a, S. 203], [Hin+07]. Zudem wird in [Hin21a, S. 203] ein steigender Bohrungsdurchmesser Q_D bei schnellerer Schnittgeschwindigkeit v_c durch die thermische Ausdehnung des Werkzeugs begründet und auf die „mögliche Adhäsion und Kaltverschweißung von Werkstoffmaterial an den Führungsfasen“ als Ursache für Abweichungen des Bohrungsmaßes bei metallischen Werkstoffen hingewiesen.

Nach [KHS12] entstehen in Inconel 718 Aufweitungen des Bohrdurchmessers Q_D durch prozessbedingte Schwingungen, Verformung des Werkzeugs sowie Erhöhung von Vorschub

pro Werkzeugumdrehung f und Schnittgeschwindigkeit v_c . Die Autoren von [BNN11] stellen dazu teilweise gegensätzlich fest, dass die genauesten Durchmesser Q_D beim Bohren in Stahl mit hohen Schnittgeschwindigkeiten v_c und Überflutungsschmierung erreicht werden. Laut [Cel14] sorgt die Erhöhung des Vorschubs pro Werkzeugumdrehung f und des Werkzeug-Spitzenwinkels σ beim Bohren von TiAl6V4 für ein Ansteigen des Bohrungsdurchmessers Q_D . Beim Bohren von Luftfahrt-Aluminiumlegierungen brachten weitere Untersuchungen gegensätzliche Ergebnisse zum Einfluss des Vorschubs pro Werkzeugumdrehung f und der Schnittgeschwindigkeit v_c auf den Durchmesser Q_D hervor [KBK09], [KKB08], [Gia+16].

2.1.3.3 Rauigkeit der Bohrungswand

Bei der Randzonenbetrachtung von Bohrungen ist die Rauigkeit an der Bohrungswand von Bedeutung, da sie einen signifikanten Einfluss auf die Betriebsfestigkeit der Fügeverbindung hat [Hin21a, S. 238]. Als Kennzahlen werden hierbei meist eindimensionale Werte wie der Mittenrauwert R_a (in dieser Arbeit als Q_{Ra} bezeichnet) aus aufgenommenen 2D-Verläufen berechnet, siehe Abbildung 2.5. Auch bei dieser Qualitätskenngröße hat fortschreitender Werkzeugverschleiß beim Bohren von Stahl- und Titanlegierungen negative Auswirkungen, die durch höheren Schmiermitteleinsatz abgemildert werden können [BNN11], [Osm+18], [EDW17]. Dazu im Gegensatz wird von den Autoren in [Zed+13] während der Bearbeitung der Aluminiumlegierung 6061-T6 festgestellt, dass ohne Schmierung oder mit Minimalmengenschmierung bessere Rauigkeitskennwerte erreicht werden als bei Überflutungsschmierung.




Abbildung 2.5: Rauigkeitskennwerte nach [Klo18] ($x =$ Längsordinate, $z =$ Höhenkoordinate, $R_t =$ maximale Rautiefe, $R_v =$ Tiefe des größten Profiltales, $R_p =$ Höhe der größten Profilspitze)

Werkstoffverfestigungen an dem Werkzeug aufgrund von Adhäsion sowie Press- oder Kaltverschweißung beeinflussen die Oberflächenrauigkeit metallischer Werkstoffe negativ. Ausreichende Kühlschmierung sowie eine zuverlässige Spanabfuhr wirken sich dagegen positiv auf die Rauigkeitskennwerte aus [Hin21a, S. 237], [Klo18, S. 290]. Laut [Waq+16] und [CYO16] ist die Kombination von hoher Schnittgeschwindigkeit v_c und niedrigem Vorschub pro Werkzeugumdrehung f vorteilhaft im Hinblick auf die Oberflächenrauigkeit beim Bohren der Titanlegierung Ti6Al4V. Während der Bearbeitung unterschiedlicher Aluminiumlegierungen stellen die Autoren in [Aam+20] und [Gia+16] dagegen fest, dass mit der Erhöhung der Schnittgeschwindigkeit v_c auch die Rauigkeit steigt. Bei FVK-Werkstoffen mit unidirektionalem Gelege ist die Rauigkeit an der Bohrungswand abhängig von Fasertrennwinkel θ [RHV12]. Hohe Schnittgeschwindigkeiten v_c sorgen beim Bohren von CFK für eine Verbesserung der Rauigkeitskennwerte aufgrund der Matrixverschmierung [VS18], [Mel+16], wohingegen hohe Vorschübe nachteilig sind [VS18], [Vos+17].

Als entsprechende Untersuchungsmethoden haben sich zum einen das taktile Tastschnittverfahren etabliert. Dabei wird ein 2D-Profil der Oberfläche erstellt. Zum anderen ist die 3D-Erfassung der Oberfläche mit optischen Verfahren, analog der Gratmessung, möglich.

2.1.3.4 Delamination am Bohrungsaustritt bei FVK-Werkstoffen

Als Delamination wird bei FVK-Werkstoffen das Ablösen von Laminatschichten am Bohrungsein- oder -austritt bezeichnet, siehe Abbildung 2.6. In der Literatur wird zwischen der *peel-up-Delamination* am Bohrungseintritt und der *push-out-Delamination* am Bohrungsaustritt unterschieden. Die Abbildung A.2 im Anhang A.1.2 stellt die Delaminationsarten und -mechanismen weiterführend dar [Gen+19]. Der Entstehungsmechanismus beruht auf mechanischen Spannungen zwischen den Laminatschichten infolge der Vorschubkraft F_f , die höher als die Zwischenlagen-Festigkeit sind, was zu Brüchen in der Matrix und den Fasern führt [Hin21a, S. 214]. Nach [Sch14] ist vor allem die Faserorientierung der Decklage von Bedeutung für die Delaminationsbildung. Da die Austritt-Delamination einen höheren Schweregrad aufweist, liegt der Fokus in der Literatur oft auf dieser Schädigungsform [Hin21a, S. 97]. Daher wird in dieser Arbeit ausschließlich diese Schädigungsform behandelt, die in weiterer Ausführung vereinfacht als „Delamination“ bezeichnet wird.

Es existieren unterschiedliche Kennzahlen zur quantitativen Erfassung der Delamination. Dabei erfolgt oftmals das Berechnen einer dimensionslosen Kennzahl durch das Beziehen einer Delaminations-Messgröße auf die Bohrungsgröße. So kann z. B. der maximale Radius der Delamination auf den Bohrungsdurchmesser oder der Flächeninhalt der Delamination auf den Flächeninhalt der Bohrung bezogen werden [Che97], [MRS92], [DCA07]. Die Delamination wird durch die Werkzeuggeometrie, den Werkzeug-Verschleißzustand und die Prozessbedingungen bestehend aus Schnittparametern und Randbedingungen beeinflusst. Mit zunehmendem Werkzeugverschleiß, beispielsweise in Form der Schneidkantenverrundung, kann ein Anstieg der Delamination beobachtet werden [Fer+21]. Der Einsatz von alternativen Bohrergeometrien, wie z. B. Mehrpunkt- oder Fischeschwanzbohrer oder die Anwendung des Stufenbohrers bewirkt eine Delamination-Senkung [Klo18, S. 404], [Ahm09].

In [Gen+19], [Ahm09] wird zusammenfassend festgestellt, dass die Delamination in einem hohen Maße von der Vorschubkraft F_f abhängt und folglich über die Vorschub-Einstellung die Delaminationseffekte beeinflusst werden. So bewirkt eine adaptive Vorschubreduktion im Austrittsbereich eine Verminderung der Delamination. Des Weiteren wirken sich hohe Schnittgeschwindigkeiten v_c als vorteilhaft aus. An der Bohrung-Austrittsseite ist die Delamination unabhängig von dem Werkzeug-Spitzenwinkel σ und kann durch den Einsatz scharfer Werkzeuge mit geringer Hauptschneiden-Abflachung V_{HA} signifikant gesenkt bzw. vermieden werden [Sch14]. Des Weiteren wird Delamination durch die Anwendung adaptiver Spannsysteme, bei denen die Abstützung der Materiallagen am Bohrungseintritt erfolgt, reduziert [Klo17]. In der Abbildung 2.6 ist die Abhängigkeit der Delaminationsbereiche vom Fasertrennwinkel θ an der Werkstück-Austrittsseite dargestellt. Die größte Delamination entsteht bei $\theta = 90^\circ$, da hierbei die Fasern der Schneide ausweichen, was ein Einreißen der Decklage zur Folge hat [Hin21a, S. 97].

Am meisten verbreitete Verfahren zur Aufnahme der Delamination sind Computertomographie, Ultraschall- und optische Prüfung [Hae+16], [BDG08], [DCA07].

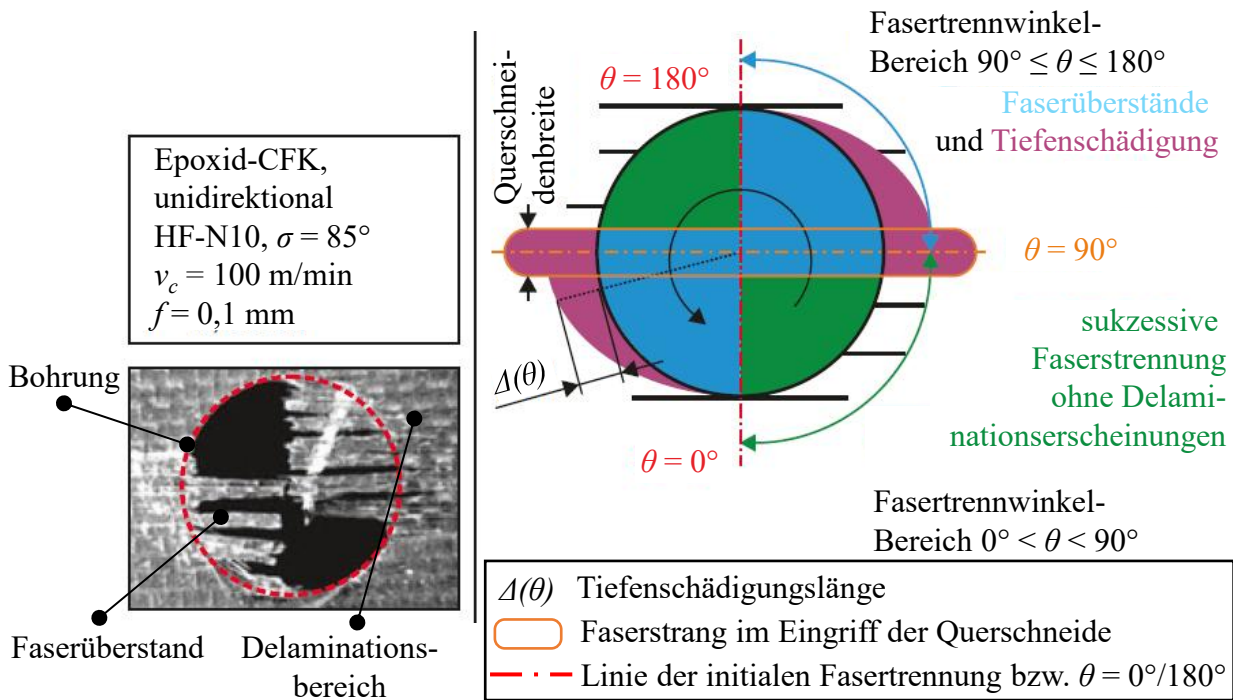


Abbildung 2.6: Ausbildung der Delamination an der Werkstück-Austrittsseite nach [Hin21a, S. 97] ($\sigma =$ Spitzenwinkel, $f =$ Vorschub pro Werkzeugumdrehung, $v_c =$ Schnittgeschwindigkeit)

2.1.3.5 Faserüberstand am Bohrungsaustritt bei FVK-Werkstoffen

Die Entstehung von Faserüberständen bei FVK-Werkstoffen kann an der Austrittsseite des Werkstücks beobachtet werden. Diese ist gekoppelt an die beschriebene Delamination [Hin21a, S. 93], [Klo18, S. 403], siehe Abbildung 2.6. Aus diesem Grund kann bei der Erklärung der Schädigungsmechanismen, Einflussgrößen, Kennzahlen und Messmethoden auf die Ausführung zu der Delamination am Bohrungsaustritt verwiesen werden. Nach [Hin21a, S. 98] kann das Auftreten von Faserüberständen im Fasertrennwinkel-Bereich $90^\circ < \theta < 180^\circ$ damit erklärt werden, dass hierbei die Fasern den Schneiden ausweichen können. Im Bereich des Fasertrennwinkels $\theta = 90^\circ$ werden die Faserüberstände senkrecht zur Decklagen-Laminebene belastet, was zu hohen Delaminations-Schädigungen führt [HH13]. Faserüberstände sind durch Nachbearbeitung korrigierbar.

2.1.4 Kenngrößen des Werkzeugverschleißes

Die Veränderung des Werkzeugs und damit die Ausbildung diverser Verschleißformen ist das Ergebnis der Beanspruchung während des Zerspanprozesses und dabei wirkender Verschleißmechanismen, siehe dazu der Ablauf in der Abbildung 2.7. Als Verschleißform werden stoffliche und geometrische Veränderungen der Schneide bezeichnet [Hin21a, S. 80]. Oftmals entsteht eine Verschleißform als Folge mehrerer Verschleißmechanismen. Umgekehrt kann ein Verschleißmechanismus mehrere Verschleißformen erzeugen. Im Folgenden werden die Verschleißmechanismen mit ihren Entstehungsursachen gemäß einschlägiger Literatur erläutert [Hin21b], [Klo18, S. 84], [Pau08, S. 47], [Fri18, S. 257].

Der Verschleißmechanismus *Abrasion* entsteht, wenn harte Körper den Schneidstoff in dessen Oberflächenbereichen abtragen oder es zu einer hohen tribologischen Beanspruchung

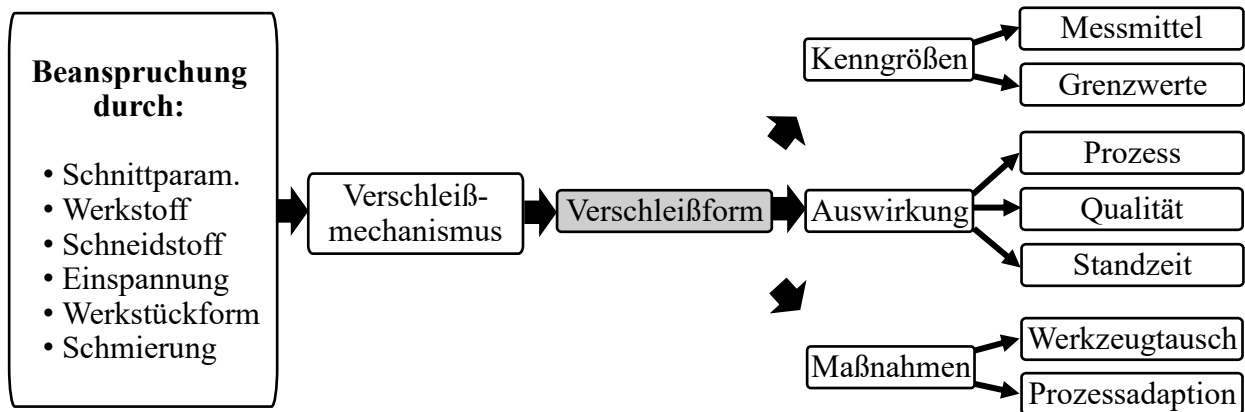


Abbildung 2.7: Verschleißprozess am Werkzeug (eigene Darstellung nach [Hin21b], [Klo18], [Die16])

des Schneidstoffs kommt [Klo18, S. 83]. Die *Oberflächenzerrüttung* wird durch eine schwelende thermo-mechanische Beanspruchung des Schneidstoffs hervorgerufen. Dies ist beim unterbrochenen Schnitt und dem Einsatz von Kühlschmierstoffen der Fall. Bei der *thermomechanischen Überbeanspruchung* kommt es zur plastischen Verformung oder dem Ausbruch des Schneidstoffs, wenn die Steifigkeit der Werkzeuggeometrie bei hohen Schnittkräften nicht ausreichend oder der Schneidstoff zu spröde ist. *Adhäsion* lässt sich mit der Affinität von Werkstoff und Schneidstoff, was zur Ausbildung atomarer Bindungen zwischen den Reibpartnern führt, erklären. Dieser Effekt ist in einem starken Maße von der Temperatur und damit der Schnittgeschwindigkeit abhängig. Die entstandenen Verschweißungen des abgetragenen Werkstoffs an der Schneidstoffoberfläche sorgen bei ihrer Abtrennung für Ausbröckelungen. Bei einer *tribochemischen Reaktion* kommt es bei hohen Temperaturen zu Diffusions- und Oxidationsvorgängen des Schneidstoffs. Dieser Effekt wird durch bestimmte Werkstoff- und Schneidstoffpaarungen sowie hohe Schnittgeschwindigkeiten begünstigt.

Die Erklärung jeglicher auftretender Verschleißformen würden den Rahmen dieser Arbeit sprengen. Bevor in folgenden Abschnitten die in dieser Arbeit betrachteten Verschleißformen analysiert werden, erfolgt der Übersicht halber die Nennung der gängigsten Verschleißformen beim Bohren: Kolkverschleiß, Freiflächenverschleiß, Eckenverschleiß, Schneiden- und Eckenausbruch, Querrisse, Kammrisse, plastische Verformung, Aufbauschneide, Oxidationszonen (Verzunderung), Schneidkantenverrundung, Ausbruch durch Pressverschweißung, Ausbröckelung durch Aufbauschneide.

Als Standzeit wird die „Schnittzeit, die ein Werkzeug im Eingriff bleiben kann, bis es nachgeschliffen oder seine Schneide gewechselt werden muss“ [Pau08, S. 50] bezeichnet. Das Standzeitende wird an einem bestimmten Kriterium festgelegt, welches nicht überschritten werden darf. Zwischen der Schnittgeschwindigkeit v_c und den Standzeitkriterien Verschleißmarkenbreite oder Kolktiefe kann ein exponentieller Zusammenhang mit der daraus abgeleiteten TAYLOR-Geraden festgestellt werden. Im Allgemeinen (Ausnahme: Verschleißform Aufbauschneide) kann gesagt werden, dass die Erhöhung der Schnittgeschwindigkeit v_c und des Vorschubs pro Werkzeugumdrehung f zum Anstieg des Werkzeugverschleißes führen. Zur spezifischen Erklärung sei auf einschlägige Fachliteratur verwiesen [Pau08], [Klo18], [Hin21a], [CYO16], [DAB16].

Bei der Zerspanung von Titanlegierungen hat die thermische Belastung einen wesentlichen Effekt aufgrund der niedrigen Wärmeleitfähigkeit des Werkstoffs [Wes07]. Während der Bohrbearbeitung von FVK-Werkstoffen stellt der abrasive Verschleiß die dominierende Verschleißgröße bei Hartmetallbohrern dar [Far11]. Diesem Effekt kann durch den Einsatz beschichteter Werkzeuge begegnet werden [Hin21a, S. 201]. In [Aam+20] wird zusammenfassend

festgestellt, dass die Adhäsion und die daraus resultierende Aufbauschneidenbildung ein signifikanter Verschleißmechanismus beim Bohren von Aluminium ist. Diese Verschleißform kann durch das Setzen passender Schnittgeschwindigkeiten bedeutend reduziert werden [Klo18]. In den kommenden Abschnitten wird auf die in dieser Arbeit untersuchten Verschleißformen näher eingegangen.

2.1.4.1 Freiflächenverschleiß an der Hauptschneide mit der Kenngröße maximale Verschleißmarkenbreite

Diese Art der Verschleißform wird hauptsächlich abrasiv verursacht [Pau08, S. 45]. Die Quantifizierung erfolgt durch die meist optische Vermessung der charakteristischen Verschleißmarken, siehe Abbildung 2.8. Es ist möglich, z. B. den mittleren oder maximalen Kennwert der Verschleißmarkenbreite zu extrahieren. Die Verschleißmarkenbreite nimmt zu den Schneidenecken hin aufgrund der dort höheren Schnittgeschwindigkeiten zu [Pau08]. Nachfolgend wird in diesem Werk die maximale Verschleißmarkenbreite als V_{VB} definiert und ausschließlich diese Größe genutzt.




Abbildung 2.8: Verschleißmarke am Werkzeug nach [Pau08] (V_{VB} = maximale Verschleißmarkenbreite)

2.1.4.2 Schneidenausbruch an der Freifläche der Hauptschneide mit der Kenngröße Ausbruchsfläche

Als Ursache für Schneidenausbrüche werden zu hohe Vorschübe, zu große Freiwinkel, zu hohe Schneidstoffhärte oder Spiel in dem Spindelvorschub genannt [Pau08, S. 148], [Die16, S. 28]. In [Jun22b] wird die Quantifizierung des Ausbruchs durch die Aufnahme der Ausbruchsfläche V_{HA} aus der Freifläche vorgeschlagen und im Prozess überwacht. Die Erscheinung und Quantifizierung von V_{HA} kann im späteren Abschnitt 5.2.4 zu den experimentellen Methoden in der Abbildung 5.18 eingesehen werden.

2.1.4.3 Schneidkantenverrundung mit der Kenngröße Schneiden-Abflachung

Der Schneidstoffabtrag an der Schneidkante kann außer durch die Verrundung der Schneide ebenfalls mithilfe der Abflachung der Schneidenspitze Δr charakterisiert werden, siehe Abbildung 2.9 [Hin21a, S. 80], [DT11, S. 163], [Die16, S. 27]. Bei Bohrwerkzeugen mit einem Kegelmantelschliff ist die Aufnahme der Schneiden-Abflachung auch für die Querschneide möglich. Die in dieser Arbeit betrachteten Haupt- und Querschneidenabflachung (V_{HA} und V_{QA}) stellen die Distanz zwischen der Spitze einer ideal scharfer Schneide und dem nächsten Punkt des realen Schneidenprofils dar.

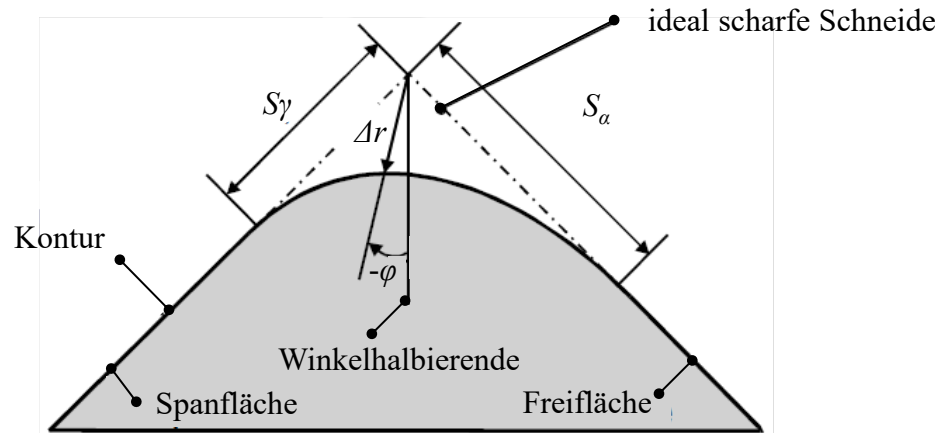


Abbildung 2.9: Schneidkantencharakterisierung nach [Hin21a, S. 80], [DT11, S. 163] (Δr = Schneidkanten-Abflachung, φ = Verschiebung der Schneidenspitze, S_γ und S_α = Formparameter)

2.1.4.4 Kombination der Verschleißformen-Kenngrößen mit der Kenngröße Hauptschneiden-Volumen

Verschleißformen wie Kolkbildung, Schneidenausbruch und -verrundung, oder auch Aufbauschneide führen zur Volumenänderung der Schneiden. Die Idee der Verschleißkenngröße Hauptschneiden-Volumen V_{HV} ist, mehrere Verschleißformen der Hauptschneide in einer Kennzahl zusammenfassend zu beschreiben [Jun22b]. Die Bestimmung des Hauptschneiden-Volumens V_{HV} ist in der Abbildung 2.10 zu sehen. Basierend auf der 3D-Topografie wird das gemittelte Schneidenprofil erstellt. Nach einer Segmentierung des Profils bzw. des Flächeninhalts ab einer festgelegten Bezugsdicke der Schneide wird der Rest-Flächeninhalt mit der Länge des betrachteten Schneiden-Körpers multipliziert.

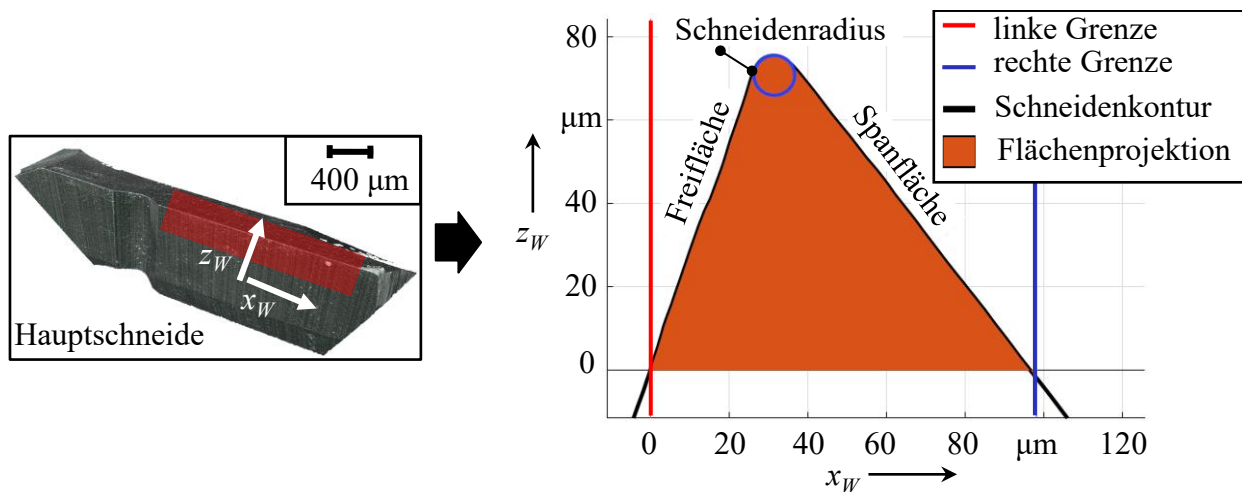


Abbildung 2.10: Verschleißkenngröße Hauptschneiden-Volumen V_{HV} nach [Jun22b] (x_W = Hauptschneiden-Dickenkoordinate, z_W = Hauptschneiden-Höhenkoordinate)

2.2 Klassische Produktionsprozess-Überwachung

Mit dem Ziel einer produktiven und wirtschaftlichen Fertigung ist die Überwachung des Produktionsprozesses elementar, um bedarfsgerechte Eingriffe im Ablauf möglichst zeitnah

durchführen zu können. Die Notwendigkeit entsteht aufgrund schleichender Abweichungen vom Sollprozess oder plötzlicher Störungen, die das Bearbeitungsergebnis negativ beeinflussen oder Schäden an der Werkzeugmaschine hervorrufen können. In den folgenden Abschnitten 2.2.1 und 2.2.2 wird ein Überblick über die Größen eines Zerspanprozesses sowie die Grundsystematik und die etablierten Vorgehensweisen der Überwachungsmethoden gegeben.

2.2.1 Zerspanprozess als System

Die Eingangsoperanden eines Zerspanprozesses werden nach DENKENA in *System-* und *Stellgrößen* eingeteilt, siehe Abbildung 2.11. Die *Systemgrößen* stellen die Randbedingungen dar und sind während des Zerspanprozesses im Allgemeinen gleichbleibend. Die *Stellgrößen* sind dagegen veränderlich. Mit dem Einfluss der Eingangsoperanden entstehen die Ausgangsoperanden in Form von *Prozess-* und *Wirkgrößen*. Diese sind veränderlich und können zur Überwachung des Zerspanprozesses genutzt werden [DT11, S. 8], [Kar01].

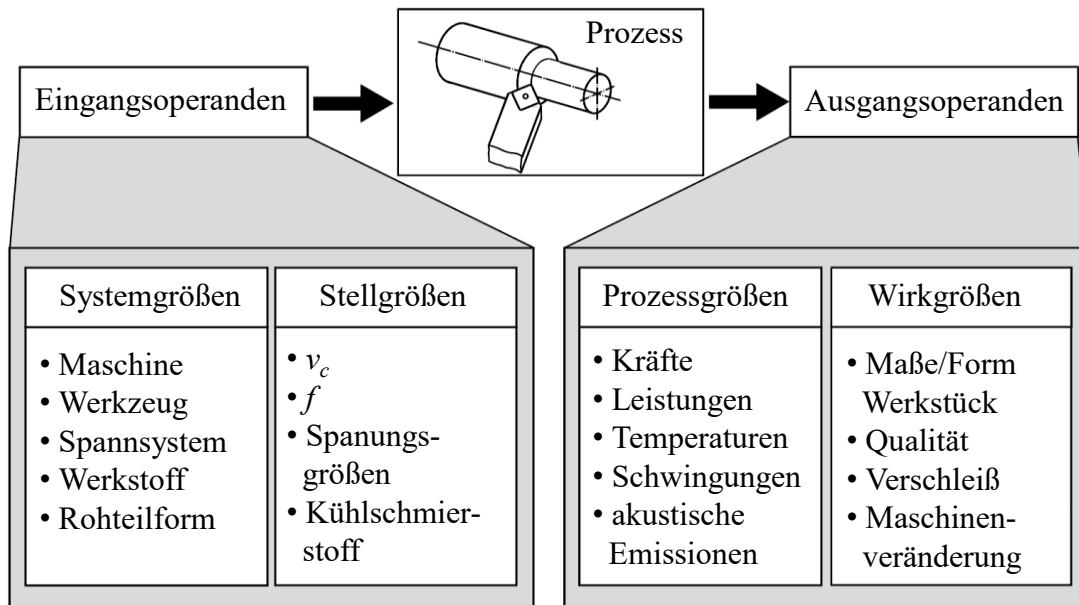


Abbildung 2.11: Zerspanprozess als System nach [DT11] (v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung)

2.2.2 Systematisierung der Überwachungsmethoden

Grundsätzlich können die Überwachungsmethoden in *direkte* und *indirekte* Verfahren eingeteilt werden. Bei den direkten Verfahren werden Überwachungs-Kenngrößen, z. B. in Form von Werkstückqualität oder Werkzeugverschleiß unmittelbar erfasst. Diese Herangehensweise ist in der Produktionsumgebung jedoch nur eingeschränkt anwendbar (z. B. beim Werkzeugverschleiß), da die direkte Ermittlung vieler Kenngrößen sehr aufwendig ist oder zu Prozessunterbrechungen führt (= offline-Überwachung in den Fertigungs-Nebenzeiten) [Tet+10], [BW21, S. 193]. Daher ist die direkte Kontrolle nach jedem hergestellten Artikel bzw. nach jedem Prozessdurchlauf z. B. nur bei sicherheitskritischen Komponenten vertretbar. Im Laborbereich oder in der Methoden-Entwicklungsphase ist die Anwendung dieser Methoden jedoch aufgrund der hohen Genauigkeit weit verbreitet. Beispiele für direkte Überwachung sind optische Aufnahmen oder Widerstandsmessungen [Tet+10], [AS10].

Mit den indirekten Überwachungsmethoden werden im Prozess Signale erfasst, die mit den Überwachungs-Kenngrößen im Zusammenhang stehen und gleichzeitig aufwandsarm und kontinuierlich prozessbegleitend aufgenommen werden können. Deren Verknüpfung mit den Überwachungs-Kenngrößen wird oft durch die Domänenexperten festgestellt (= *Expertensysteme*). Die notwendigen Sensoren können in den Werkzeugmaschinen bereits installiert sein oder nachgerüstet werden. Nach der Aufnahme der Sensordaten ist eine Verarbeitung der Zeitverläufe mit der Extraktion charakteristischer Kennzahlen notwendig. Die Bewertung der Kennzahlen und damit des Prozesses erfolgt oftmals mithilfe von Qualitätsregelkarten, Toleranzbändern oder Trendauswertung. Die Änderung eines Signals oder eines daraus extrahierten Kennwerts ist ein Hinweis auf Änderungen im Prozess. Des Weiteren ist die Beschreibung der Überwachungs-Kenngrößen mithilfe von Prozessmodellen, bei denen ausgewählte Sensordaten als Input agieren, möglich. Die Modellierung kann entweder auf Basis von physikalischen Zusammenhängen (*White-Box-Modell*) oder rein auf Grundlage von Versuchsdaten erfolgen (*Black-Box-Modell*). In den sogenannten *Grey-Box-Modellen* erfolgt die Kombination dieser Herangehensweisen. Zusammenfassend muss gesagt werden, dass im Vergleich zu den direkten Methoden die indirekten Verfahren im Allgemeinen weniger akkurat sind. Die einsetzbaren Sensoren lassen sich beispielsweise nach dem basis-physikalischen Funktionsprinzip oder der gemessenen Sensorgröße einteilen [Tet+10], [BW21, S. 193], [Pau08], [Klo18, S. 479].

Eine verbreitete Technik sind die Qualitätsregelkarten. Das Ziel ist dabei zu erkennen, ob der aktuelle Prozesszustand Abweichungen zum eingelaufenen Zustand bzw. Sollprozess aufweist. Dabei wird bewertet, ob sich das aktuelle Merkmal innerhalb statistisch festgelegter Normgrenzen befindet. Sollte dies nicht der Fall sein, könnte dies auf Prozessanomalien oder außerhalb der Toleranz liegende Qualitäts- oder Verschleißmerkmale hindeuten [Jak19, S. 84]. Im Folgenden werden die etabliertesten Ansätze zur indirekten, sensorbasierten Überwachung der Zielgrößen in einem Zerspanprozess aufgelistet [AS10], [Rod+02], [EKT03], [CC19], [CB03]:

- *Werkzeugverschleiß*: Schnittkraft und -moment, Schallemission, Motorstrom, Temperatur
- *Maße und Form Werkstück*: Schnittkraft und -moment
- *Oberflächengüte*: Schnittkraft, Vibration, Temperatur, Lichtreflexion
- *Rattern*: Schallemission
- *Werkzeugbruch*: Vibration, Schallemission

Im Hinblick auf den Bohrprozess mit einem zweiseitigen Bohrer mit einem annähernd symmetrischen Anschliff gleichen sich die Schnitt- und Passivkraft (F_c und F_p) aus. In diesem Fall sind die Vorschubkraft F_f und das Schnittmoment M_c als Überwachungsgrößen bedeutend [Hin21a, S. 123]. Zur Erfassung von hochdynamischen Vorgängen bieten sich auf dem piezoelektrischen Effekt basierende Kraftaufnehmer aufgrund ihrer hohen Steifigkeit an. Obwohl Stromsensoren aufgrund ihrer einfachen Integration und geringer Kosten häufig eingesetzt werden, eignen sich diese nicht zur Erfassung hochdynamischer Vorgänge, da durch die Trägheiten der Antriebe eine Tiefpassfilterung erfolgt [Klo18, S. 473].

2.3 Maschinelles Lernen

Der in den letzten Jahren stattgefundenen technologischen Fortschritt in der Datenerfassung, -speicherung und -verarbeitung in Form von immer leistungsfähigerer und günstigerer Rechen-

maschinen ermöglichte die disziplinübergreifende Anwendung vieler bereits früher entwickelter mathematisch-stochastischer Methoden. Damit entwickelte sich das *maschinelle Lernen* (ML, en. *Machine Learning*) mit dem Ziel, aktuelle und zukünftige Zustände mithilfe der Modellbildung basierend auf früherer Erfahrung vorherzusagen [Han+19], [Bad+20], [GS21, S. 5]. Im Abschnitt 2.3.1 erfolgt die Begriffsklärung und Systematisierung des maschinellen Lernens. Auf den dazugehörigen Modellierungsablauf wird im Abschnitt 2.3.2 eingegangen. In den Abschnitten 2.3.3 und 2.3.4 werden die in dieser Arbeit verwendeten unüberwachten sowie überwachten ML-Algorithmen und deren Performance-Bewertung näher erklärt.

2.3.1 Maschinelles Lernen im Feld der künstlichen Intelligenz

Zur Erklärung von maschinellem Lernen (ML) existieren unterschiedliche Definitionen, deren ungefährer Wortlaut im Folgenden wiedergegeben ist: „Algorithmen des maschinellen Lernens befähigen einen Computer von Daten zu lernen und sich zu verbessern, ohne dafür explizit programmiert zu sein.“ [Sam59]. Es wird deutlich, dass gesammelte Daten im ML-Bereich eine zentrale Rolle einnehmen. Entscheidungen werden anhand mathematisch-stochastischer Modelle getroffen, die an vorhandene Daten angepasst sind. Während der Modellbildung (= Modell-Training) werden unterschiedliche Modell-Konfigurationen anhand eines Fehler-Bewertungsmaßes überprüft. Bis auf wenige Ausnahmen kann gesagt werden, dass je mehr Beispiele beim Lernen verfügbar sind, desto besser entwickelt sich die Modellperformance [Mat20], [GBC16], [Jo21, S. 17].

Gemäß der Abbildung 2.12 kann der Zusammenhang zwischen den Begriffen *künstliche Intelligenz* (KI, en. *artificial intelligence (AI)*), *maschinelles Lernen* (ML, en. *machine learning*) und *tiefes Lernen* (TL, en. *deep learning (DL)*) spezifiziert werden. Im Verlauf dieser Arbeit wird aufgrund derer vorwiegenden Nutzung im deutschen Sprachraum und Konsistenzgründen teilweise auf die englischen Begriffe zurückgegriffen. Der Bereich KI umfasst die Techniken zur Automatisierung von Aufgaben. Die Regeln können dabei fest programmiert, an menschlichem Handeln orientiert oder mithilfe datenbasierter Erfahrung entwickelt sein. Das Letztere beschreibt das eingangs erwähnte maschinelle Lernen. Als ein Teilgebiet von ML entwickelte sich in den letzten Jahren das *tiefe Lernen* (TL). Hierbei erfolgt die Nutzung von künstlichen neuronalen Netzen (ANN) zur Modellierung. Als Startpunkt der KI-Entwicklung werden oftmals die 1950er Jahre bezeichnet, da hier die notwendigen mathematischen Grundlagen formuliert wurden [Bad+20]. Die Entwicklung verläuft seither zyklisch mit Entwicklungsschüben für maschinelles Lernen in den 1990er und wieder ab den 2010er Jahren (in Kombination mit DL) [Wit19], [GBC16], [Ert09], [Jo21, S. 17], [Jos19, S. 4].

Im Zusammenhang mit KI, ML, und TL sollten folgende Begriffe erwähnt werden. Als *Data Mining* wird der Vorgang der Wissensextraktion aus den Daten bezeichnet [Fay+96], [GS21, S. 270]. Der Begriff *Datenanalytik* beschreibt die Anwendung von Computersystemen zur Analyse von großen Datensets, um damit Entscheidungen zu unterstützen [Run16, S. 2], [Swa19, S. 76]. Mit *Big Data* werden Datensätze bezeichnet, deren Größe weit außerhalb gewöhnlichen Umfangs und deren Quellen sehr vielfältig sind [DD22, S. 10], [Jo21, S. 275]. Die ML-Verfahren werden in unterschiedliche Gruppen eingeteilt, siehe Abbildung 2.13.

Unüberwachtes Lernen (en. *unsupervised learning*): Die Daten sind ungelabelt, d. h. es liegen nur die Merkmale (= Eingangsgrößen) und keine Zielgrößen vor. Das Modelltraining findet an dem gesamten Datenset statt. Dabei werden die Datenstruktur und -muster zum Zwecke der Datensortierung (= Clustering) analysiert [GS21, S. 11], [RRC19, S. 21], [Jo21,

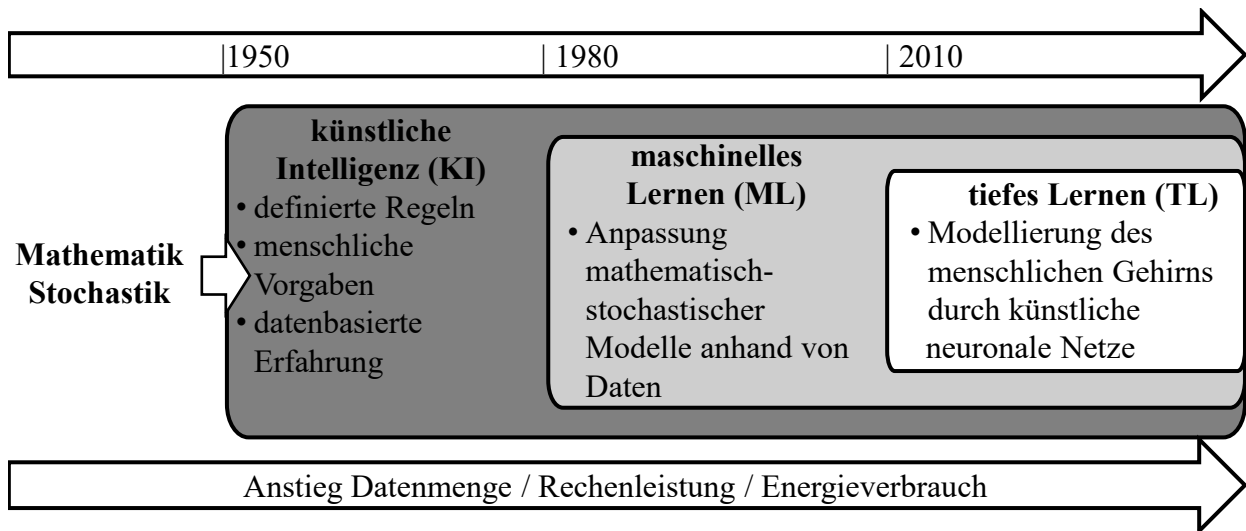


Abbildung 2.12: Übersicht zu AI/ML/TL nach [Wit19], [GBC16]

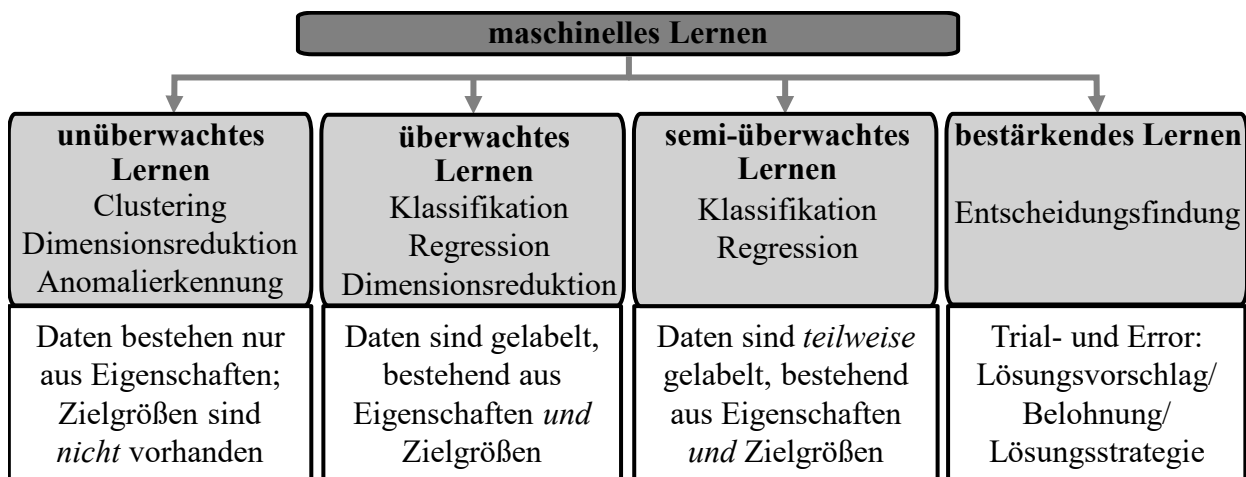


Abbildung 2.13: Maschinelles Lernen - Systematisierung nach [PT17], [Swa19], [Jo21]

S. 14]. Die Dimensionsreduktion und Anomalieerkennung werden in der Literatur teilweise dem unüberwachten Lernen zugeordnet [McL16, S. 54], [Jam+13, S. 373], [Jun22a, S. 173]. Bei der Anomalieerkennung wird ein Modell meist auf den Daten der normalen Klasse trainiert, da deren Anzahl die der Anomalien gewöhnlich übersteigt. Bei der Anwendung des Modells auf neue Daten werden diese bei starker Abweichung von den gelernten Dateneigenschaften als Anomalien markiert. Dieses Vorgehen wird als *Novelty Detection* oder *Ein-Klassen-Klassifikation* bezeichnet [RRC19, S. 153], [SZK21], [Sug16, S. 457].

Überwachtes Lernen (en. supervised learning): Hierbei liegen zu jedem Datensatz neben den Merkmalen (= Features) auch die dazugehörigen Zielgrößen (= Labels) vor. Mit dem Modelltraining werden Regeln gelernt, um zwischen den Merkmalen (= Modell-Input) und den Zielgrößen die korrekte Beziehung durch die richtige Kombination und Gewichtung des Modell-Inputs herzustellen. Das Ziel dabei ist, die richtige Vorhersage von diskreten (= Klassifikation) oder quantitativen (= Regression) Zielgrößen bei neuen Daten durchzuführen [MP18, S. 5], [Alp14, S. 21]. In dieser Arbeit werden die überwachte Klassifikation und die überwachte Regression immer mit dem Zusatz „überwacht“ aufgeführt, um deren Zugehörigkeit zu den überwachten ML-Methoden zu verdeutlichen.

Semi-überwachtes Lernen (en. semi-supervised learning): In diesem Falle ist nur ein

Teil der Daten mit Labels versehen. Die Information der Daten mit den vorhandenen Labels dient dazu, die restlichen Daten wiederum mit Labels zu versehen. Dies geschieht mithilfe des unüberwachten Lernens, indem die Gesamtdaten anhand der Merkmale in ähnliche Cluster eingeteilt werden. Daraufhin werden die ungelabelten Daten mit den Labels der gelabelten Daten im gleichen Cluster versehen. Damit entsteht ein vollständig gelabelter Datensatz für ein erneutes Modelltraining gemäß dem überwachten Lernen [RRC19, S. 22], [Jun22a, S. 173], [Jo21, S. 14].

Bestärkendes Lernen (en. reinforcement learning): Beim bestärkenden Lernen werden die Lösungen nicht anhand von gesammelten Daten, sondern durch das Trial-and-Error-Verfahren erarbeitet. Nach dem Probieren unterschiedlicher Ansätze werden die Lösungen durch ein Belohnungssystem bewertet. Das Ziel der Lösungssuche ist, die Belohnung zu maximieren. Durch das Ausführen und Bewerten aufeinanderfolgender Iterationen entsteht eine mögliche Lösungsstrategie. Der Vorteil dabei ist, dass keine aufwendig vorbereiteten Daten für den Trainings-Prozess notwendig sind [Alp14, S. 517], [Kub17, S. 331], [Jun22a, S. 14].

Die Anwendung von maschinellem Lernen kann in folgende Hauptbereiche eingeordnet werden: Kategorisierung, Vorhersage von Werten und Zuständen (= Zielgrößen), Anomaliedetektion, Dimensionsreduktion und Entscheidungsfindung [Mat20], [Han+19], [Lee19], [Jos19]. Der Einsatz von maschinellem Lernen findet heutzutage in allen Bereichen des täglichen Lebens statt, wobei viele klassische Vorhersagemethoden nicht ersetzt, sondern erweitert werden. Als Beispiele werden hierbei die Medizin, chemische Analysen, Finanzwesen, vorausschauende Wartung, Marketing, Sprachverarbeitung und auch Fertigungsprozesse genannt [Vab+19], [Mal+20], [Han+19], [Bad+20], [Han+13], [Krs+14], [XLD04], [Had+13], [Mat20], [DD22]. Folgende Gründe zur Nutzung von ML-Methoden ergeben sich dabei: sehr hohe Komplexität der Fragestellung, fortlaufende Änderung der Aufgaben, fortlaufende Änderung und hohe Komplexität der Datenstruktur und nicht umsetzbare physikalisch-mathematische Modellbildung [Mat20], [Jos19], [GS21].

2.3.2 Anwendung von maschinellem Lernen

In diesem Abschnitt wird die Anwendung des maschinellen Lernens in einem weitestgehend allgemeinen Rahmen, der für das unüberwachte und überwachte Lernen gilt, dargestellt. Bei Notwendigkeit wird auf die Unterschiede eingegangen. Das semi-überwachte Lernen wird nicht näher erläutert, da dies eine Symbiose der beiden erwähnten Methoden ist. Nach dem Kurzüberblick über den Modellierungsablauf und die Terminologie werden die Schritte der Datenvorbereitung, des Modelltrainings und der Ergebnisbewertung näher beleuchtet.

2.3.2.1 Modellierungsablauf

Die bereits dargestellten Ziele des maschinellen Lernens lassen sich im mathematischen Sinne damit beschreiben, dass eine gewählte Fehler-Bewertungsfunktion minimiert wird. Beim unüberwachten Lernen kann dies ein Unterschiedsmaß der Datenpunkte in einem Cluster sein und bei den überwachten Methoden der Unterschied zwischen den wahren y_i und vorhergesagten Zielgrößen \hat{y}_i [MP18]. In der Abbildung 2.14 ist ein möglicher ML-Workflow auf Basis unterschiedlicher Quellen dargestellt. Für eingehende Daten erfolgt beim überwachten Lernen die Einteilung des Datensatzes in ein Trainings-, Validierungs- und Test-Set. Anhand des Trainings-Sets erfolgt das Modelltraining, dessen Ergebnisse an dem Validierungs-Set

bewertet werden. In mehreren Iterationen erfolgt danach eine Hyperparameter-Optimierung, bei der die Konfiguration des Modells variiert wird. Als Resultat entsteht das beste Modell mit dem optimalen Hyperparameter-Satz. Für eine unabhängige Bewertung erfolgt die Vorhersage an dem anfangs separierten Test-Set, wobei das ML-Modell dafür an dem verbundenen Trainings- und Validierungsset trainiert wird. Anhand der Ergebnisse kann die Entscheidung erfolgen, ob das ermittelte ML-Modell, nachdem es z. B. nochmal an dem gesamten anfangs zur Verfügung stehenden Datensatz trainiert wird, im Feld eingesetzt wird [Ste20], [Mat20], [Wit19], [Jos19], [Jo21].

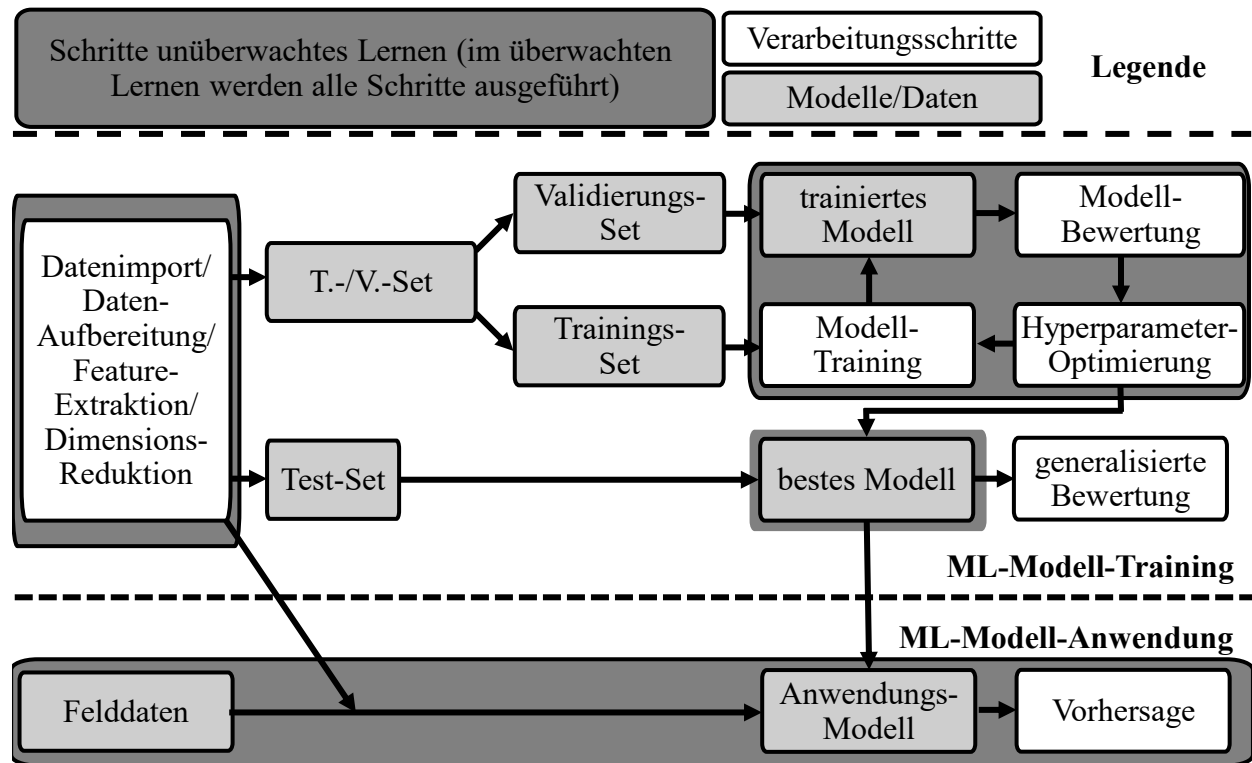


Abbildung 2.14: ML-Modellierungs-Pipeline nach [Ste20], [Schi23], [Mat20], [Wit19] (“T.-Set,, = Trainings-Set, „V.-Set“ = Validierungs-Set)

2.3.2.2 Terminologie

Nach der erfolgten Einführung in das maschinelle Lernen ist eine eindeutige Begriffsklärung für den weiteren Verlauf dieser Arbeit essentiell, da in der Praxis gleichbedeutende Komponenten teilweise unterschiedlich benannt werden. Zu diesem Zwecke sind die wichtigsten Synonyme und Übersetzungen in der Tabelle 2.1 zusammengefasst. Daran schließt sich die Erklärung weiterer ML-Begriffe an.

Der *Datensatz* besteht aus der Gesamtheit zur Verfügung stehender Beispiele. Gemäß der Abbildung 2.14 ist sichtbar, dass das *Trainings-Set* ausschließlich zum Trainieren des Modells während der Hyperparameter-Optimierung eingesetzt wird. Das *Validierungs-Set* dient zur Abstimmung der Hyperparameter. Für die unabhängige Performance-Bewertung wird das *Test-Set* eingesetzt. Als *Stratifkation* wird das Verfahren bei der überwachten Klassifikation bezeichnet, wenn die Klassenanteile in jedem Set in etwa gleich verteilt sind.

Als *Überanpassung* wird der Effekt genannt, wenn das ML-Modell sehr viele Freiheitsgrade hat und sich deswegen an das Trainings-Set inklusive seines Datenrauschens sehr stark anpasst.

Tabelle 2.1: Synonyme und Übersetzungen beim maschinellen Lernen nach [Jun22a], [Ric19], [MP18] (in dieser Arbeit vorwiegend verwendete Bezeichnung ist kursiv dargestellt)

Begriff (Synonyme)	Erklärung	englische Begriffe
<i>Feature</i> (Deskriptor, Merkmal, unabhängige Variable)	Dateneigenschaft, die als Modell-Einganggröße dient	feature, variable, predictor, descriptor, independent variable
<i>Zielgröße</i> (Zielvariable, abhängige Variable, Antwortvariable)	vorherzusagende Größe, die von Interesse ist	label, response variable, target, dependent variable, outcome, output
<i>Beispiel</i>	Dateninstanz, die durch Features beschrieben wird	observation, example, instance, sample, case

Beim Test-Set liefert es jedoch eine schwache Performance und ist daher nicht *generalisierend*. Folglich ist das Modell mit einer hohen Varianz und einem niedrigen *Bias* behaftet. Bei der *Unteranpassung* passiert das Gegenteil, wenn ein sehr einfaches Modell die Datenstrukturen nicht abbilden kann und als Folge eine schlechte Modell-Performance bei allen Datensätzen festgestellt wird (siehe Beispiel in der Abbildung A.5 im Anhang A.1.3).

Die *Modell-Hyperparameter* werden als externe Einstellparameter durch den Anwender vorgegeben. Diese kontrollieren den Trainings-Prozess, sind unabhängig von den Daten und verändern sich nicht während des Trainings. Die *Modell-Parameter* als innere Modell-Kenngrößen werden dagegen während des Modell-Trainings in Abhängigkeit der Daten iterativ ausgebildet und sind von den Hyperparameter-Einstellungen abhängig.

Mithilfe der Verlustfunktion wird der Fehler zwischen der wahren und modellierten Zielgröße an einem einzelnen Beispiel bezeichnet. Das Pendant dazu ist die *Kostenfunktion* zur Gesamtbewertung des Fehlers an dem gesamten Datensatz. In der Literatur werden diese Größen teilweise gleichgesetzt. Als *Objektivfunktion* wird die Funktion bezeichnet, welche während der Modelloptimierung minimiert wird. Die genannten Funktionen können mathematisch gleich sein. Die Ausführungen in diesem Abschnitt zur Terminologie basieren auf [DD22], [Jam+13], [Jo21], [Jun22a], [MP18], [Ber19].

2.3.2.3 Datenvorbereitung

Dieser Abschnitt behandelt die Datenvorbereitung, die als unabhängig von den später verwendeten Algorithmen betrachtet wird.

Datenimport und -aufarbeitung

Zu Anfang besteht die Notwendigkeit, die eingehenden Daten in ein verarbeitbares und einheitliches Format zu bringen und deren Qualität für die weitere Verarbeitung zu erhöhen. Dazu gehören die Synchronisation, der Datenzuschnitt sowie das Eliminieren von Fehlstellen, Aufnahme Fehlern und offensichtlichen Ausreißern. Bei stark verrauschten Messwerten kann eine Filterung vonnöten sein. Dieser Bearbeitungsschritt benötigt oftmals den größten Zeitanteil [GS21, S. 115], [Mat20], [RRC19, S. 186], [Run16, S. 23].

Feature-Extraktion

Die extrahierten Features müssen die Signalcharakteristika repräsentieren, und gleichzeitig hat deren Ableitung einen signifikanten Einfluss auf die Modellperformance. Dem Anwender sind bei der Methodik keine Limits gesetzt, daher werden in diesem Abschnitt ausschließlich die in dieser Arbeit gewählten Vorgehensweisen erläutert.

Die Features können aus den kontinuierlichen Verläufen des Daten-*Zeitbereichs* mit einer Vielzahl von Methoden extrahiert werden. Als Beispiel können statistische Merkmale wie Mittelwert, Peak-Abstand, Minima, Maxima, etc. genannt werden [DD22, S. 32], [Guy+06]. Mit der Überführung eines Zeitsignals in den *Frequenzbereich* z. B. mittels der schnellen Fourier-Transformation (en. fast Fourier transform (FFT)), werden Zeitsignale in ihr Frequenzspektrum zerlegt [DV90]. In einem Spektrogramm erfolgt die zeitliche Darstellung der Frequenz und Amplitude. Daraus lassen sich ebenfalls statistische Features ermitteln.

Des Weiteren ist es z. B. bei akustischen Messungen möglich, die Form des Schalls mathematisch zu beschreiben. Dies erfolgt mithilfe von *spektralen Eigenschaften*, die wiederum einen zeitlichen Verlauf haben. Daraus lassen sich analog zu der beschriebenen Feature-Extraktion im Zeitbereich charakteristische Kennwerte ableiten. Als spektrale Eigenschaften lassen sich nach [Pee04] und [Mat24e] z. B. *Centroid, Spread, Flux, Roll Off Point, Skewness, Kurtosis, Flatness, Crest, Slope, Decrease, Entropy* nennen (aufgrund von teilweise fehlenden deutschen Begriffen wird die Bezeichnung im englischen belassen). Dazu sei als Vorgriff auf die Abbildungen A.13 und A.14 im Anhang A.9.5 verwiesen.

Eine zusätzliche Option zur Feature-Generierung ist der Einsatz der *Wavelet-Transformation*. Das Wavelet kann als ein Referenzsignal bestimmter Länge beschrieben werden, wovon unterschiedliche Formen existieren. Die Grundidee der Wavelet-Transformation ist, die Ähnlichkeit zwischen einem Eingangssignal und dem Wavelet zu bestimmen, indem diese miteinander gefaltet werden (siehe weiterführende Abbildung A.6 im Anhang A.1.3). Es wird zwischen der kontinuierlichen und der diskreten Transformation unterschieden. Der Vorteil gegenüber der Fourier-Transformation ist die vorhandene zeitliche Auflösung. Die Ergebnisse können als Features oder als Werte zur weiteren Verarbeitung verwendet werden [Ami+15], [Sam+99].

Zudem kann die Feature-Extraktion durch *Bildcodierung* umgesetzt werden. Die Grundidee besteht darin, die Eingangssignale in Bilddarstellungen mit einer definierten Größe umzuwandeln. Die Farbe jedes Pixels entspricht in einer gängigen Farbcodierung wiederum numerischen Werten. Diese können als Features eingesetzt werden [WO15], [SSA23], [MTR19]. In dem späteren Abschnitt 6.2.3.5 ist ein Beispiel für ein decodiertes Zeitsignal dargestellt. Eine naheliegende Bildcodierung ist das bereits beschriebene (*Wavelet-*) *Spektrogramm*. Mithilfe des *Gramian Angular Field (GAF)* entsteht eine weitere Möglichkeit der Farbcodierung. Die Zeitreihendaten werden hierbei zuerst in Polarkoordinaten transformiert. Daraus wird die Matrix des Gramian Angular Fields entwickelt. Die Matrixwerte sind als Features oder Werte zur Bilddarstellung der Zeitreihe nutzbar [WO15]. Die *Markov-Übergangsmatrix* repräsentiert die Übergangswahrscheinlichkeiten zwischen den Zuständen eines Daten-Verlaufs [WO15]. Der *Rekurrenzplot* stellt visuell die Zeitpunkte eines Systems oder eines Sensordaten-Verlaufs dar, an denen das System zu einem vorherigen Zustand zurückkehrt [EKR87].

Nach der Feature-Extraktion kann im Allgemeinen davon ausgegangen werden, dass sich hochdimensionale Feature-Räume ergeben. Jedes Feature repräsentiert eine Dimension des Feature-raums. Zudem ist anzunehmen, dass die Signifikanz der Features variiert und diese z. T. redundant sind. Aus diesem Grunde ist eine Feature-Vorbereitung, z. B. in Form einer Dimensionsreduktion empfohlen [Alp14].

Datenset-Einteilung zur Hyperparameteroptimierung und zum Modellvergleich

Die Einteilung der Datensets ist nur für überwachte ML-Verfahren möglich, da hierbei die Zielgrößen vorhanden sind. Zum Zwecke der finalen Modell-Bewertung wird anfangs ein Test-Set aus dem Datensatz entnommen, um die wahre Modell-Performance des finalen ML-Modells an unbekanntem Daten zu testen. Der restliche Datensatz wird in ein Trainings- und Validierungs-Set für die Modell-Hyperparameteroptimierung aufgeteilt, siehe Abbildung 2.14. Für das Vorgehen bei der Aufteilung existieren unterschiedliche Möglichkeiten. Gemein haben alle Methoden, dass sich die *Stratifkation* und eine nicht nach der Zeit geordnete Aufstellung der Daten vor deren Aufteilung in die Datensets für eine realistischere Modell-Bewertung als vorteilhaft erweist [Jun22a, Kap. 6], [Krs+14] [Ber19], [Alp14], [HTF09, S. 220 ff.]. Die Methoden der Datenset-Einteilung werden oftmals als (*Kreuz-*) *Validierung* bezeichnet. Dazu existiert eine Vielzahl an möglichen Verfahren, zu denen auf folgende Literatur verwiesen wird: [Gro19], [Kum20], [Mal+20], [HTF09, S.220 ff.], [Sug16, Kap. 14], [SV10, Kap. 2], [Ric19, Kap. 1], [Sha93], [XLD04], [Zha93], [Kub17], [Pat21], [XL01], [Had+13]. In dieser Arbeit eingesetzte Methoden werden in den kommenden Ausführungen näher erklärt. Diese sind ebenfalls in dem späteren Kapitel zur aufgebauten ML-Modellierung in der Abbildung 6.15 visualisiert.

Re-Substitution: Hierbei werden die Daten nicht aufgeteilt, zum Training und zur Validierung bzw. Modell-Bewertung werden sämtliche Beispiele verwendet, siehe Abbildung 6.15. Dieses Vorgehen neigt zu fälschlich optimistischen Modellevaluationen und sollte nur verwendet werden, wenn anderweitige Validierungsmethoden nicht umgesetzt werden können, der Datensatz ausreichend viele Beispiele enthält oder mögliche neue Daten durch den vorhandenen Datensatz repräsentiert werden [Mat22], [Kum18].

Hold-Out-Validierung: Bei der *Hold-Out-Validierung* wird das Datenset zur Modellauswahl in ein Trainings- und Validierungsset, zur Modellevaluation zusätzlich in ein Test-Set aufgesplittet, siehe dazu die Abbildung 6.15. Das Modell wird an dem Trainingsset trainiert und an dem Validierungs-Set wird die Qualität des Hyperparametersatzes geprüft. Oftmals verwendete Aufteilung ist 60 % - 20 % - 20 % (Trainings-/Validierungs-/Test-Set). Die Hold-Out-Validierung benötigt weniger Rechenkapazität als die *K-Fold-Validierung*. Des Weiteren wird sie bei großen Datensätzen sowie zur rechenarmen und zeitsparenden Aufstellung von (Test-) Modellen empfohlen. Bei kleinen Datensätzen hängen deren Ergebnisse in einem hohen Maße von dem Datensplit ab [Ric19], [Kum21], [Mal+20], [All18], [Lak21], [All18], [Kum21].

K-Fold-Validierung: Charakteristisch für diese Art der Validierung ist die wiederholte Neueinteilung des Trainings- und Validierungs-Sets und die damit wiederholten Modelltraining und -validierung. Bei der k-Fold Kreuzvalidierung wird das Datenset in k Teile eingeteilt und es werden $k - 1$ Partitionen als Training-Set und eine Partition als Validierungs-Set eingesetzt. Diese Arbeitsabfolge wird k Mal wiederholt, wobei die Zuordnung der Partitionen sequenziell weitergetrieben wird. Der Vorgang ist in der Abbildung 6.15 visualisiert. Die Gesamtbewertung der Modell-Hyperparameter erfolgt über die Mittelung von k verfügbaren Modellbewertungen. Das anhand der Hyperparameter-Optimierung beste ermittelte Modell wird am verbundenen Trainings- und Validierungs-Set trainiert und an dem Test-Set bewertet.

Es wird bei der Anwendung ein k von 5-10 empfohlen. In der Mehrheit der Literatur wird mittels der K-Fold-Validierung die Auswahl ausbalancierter Vorhersagen hinsichtlich Bias und Varianz erwartet. Im Folgenden sind die Vorteile der K-Fold-Validierung zusammengefasst: mehrfache Verwendung von Daten als Trainings- und Validierungs-Set und damit eine größere Anzahl an Trainingsdaten; weniger streuende Abschätzung der Modellqualität im

Vergleich zur Hold-Out-Validierung; durch die gemittelten Bewertungen eine nicht durch eine Überanpassung gekennzeichnete Beurteilung; robustere Abschätzung der Modellqualität bei variierenden Daten. Als Nachteile sind der vermehrte Rechenaufwand und die damit hohe Rechenzeit zu nennen. Diese Methode wird bei tendenziell kleinen Datensätzen als notwendig angesehen.

Bei der vorgestellten K-Fold-Validierung ist die Modell-Bewertung ebenso in mehrmaliger Durchführung möglich. Dazu ist der Einsatz der *verschachtelten K-Fold-Validierung* notwendig. Der gesamte Datensatz wird in k Sets unterteilt. In der *äußeren* Schleife wird *ein* Set als Test-Set verwendet, und $k - 1$ Sets werden dem *äußeren* Trainings-Set zugewiesen. Das *äußere* Trainings-Set wird wiederum in l Sets unterteilt, wobei *ein* Set als Validierungs- und $l - 1$ Sets als *inneres* Trainings-Set dienen. Es entstehen k Hyperparametersätze. Diese können durch wiederholtes Training an den k äußeren Trainings-Sets untereinander verglichen werden. Adaptierte Vorgehensweisen sind hierbei auch denkbar [All18], [Pra20], [Ric19], [Vab+19], [Kum21], [Ber19], [Sug16, Kap. 14], [SV10, Kap. 2], [Mal+20], [Lak21].

Bootstrapping: Bei dieser Methode wird eine zufällige Stichprobe mit möglicher Datenwiederholung (*en. Bootstrapping*) erzeugt. Das heißt, in der Stichprobe können gleiche Datenpunkte mehrmals vorkommen. In der Literatur werden mehrere Abwandlungen als Validierungsmethode vorgestellt. Für das Trainings-Set können damit $p \leq p_B$ Beispiele entnommen werden. Das Validierungs-Set kann aus den Beispielen des bereitgestellten Trainings- und Validierungs-Sets, die nicht im Training verwendet wurden, bestehen. Genauso ist es möglich, die gesamten Daten des Trainings- und Validierungssets als Validierungs-Set zu nutzen. Das finale Modell wird an den Trainings- und Validierungsdaten trainiert und an den zu Beginn separierten Test-Daten final bewertet. Diese Methode wird bei kleinen Datensets empfohlen. Zu beachten ist, dass aufgrund der Überlappung des Trainings- und des Validierungssets eine Tendenz zur überoptimistischen Modellperformance-Abschätzung gegeben ist [HTF09, S. 561 ff.], [LPS21], [Alp14, S. 249 ff.], [Koh95], [Kum18].

Im allgemeinen wird in den referenzierten Quellen ausgesagt, dass bei ausreichend großen Datensätzen die Evaluationsmethoden an Bedeutung verlieren und sich die Ergebnisse der vorgestellten Verfahren annähern. Zudem ist die Wiederholung des Validierungsprozesses aufgrund der Abhängigkeit des Lernprozesses von Zufallsfaktoren (z. B. Initial-Modellparameterwerte beim Trainingsstart) anzustreben. Dabei wird anhand der ggf. resultierenden Streuung der Modellperformance-Abschätzung deren Vertrauensbereich robust abgeschätzt.

Feature-Vorbereitung und Dimensionsreduktion

Die Anwendung der im folgenden beschriebenen Skalierungs- und Dimensionsreduktions-Methoden muss separat beim Trainings-, Validierungs- und Test-Set erfolgen, da es ansonsten zur „Daten-Leckage“ kommt. Dies bedeutet, dass zuerst die Anwendung auf das Trainings-Set stattfindet und mit den ermittelten Projektions- oder Selektionsparametern die Dimension der Features im Validierungs- und Test-Set reduziert wird. Andernfalls fließen die Eigenschaften des Test-Datensatzes in die Reduktionsparameter ein. Dadurch wäre eine objektive Modellbewertung des trainierten Modells nicht gegeben [Krs+14].

Nach der Feature-Extraktion weisen die Deskriptoren im Allgemeinen unterschiedliche Wertebereiche auf. Dies führt im Modelltraining zu einer verfälschten Wichtigkeitsbewertung einzelner Features und einer erschwerten Optimierung beim Training der Modell-Parameter. Durch *Z-Standardisierung* kann eine Skalierung der Daten auf ein einheitliches Maß vorgenommen werden, ohne die Unterschiede innerhalb des Datensatzes eines einzelnen Features zu

verfälschen. Mit der Z-Standardisierung werden die Werte eines Features $p_{i,j}$ für jedes Beispiel mit den ursprünglichen Feature-Werten $x_{i,j}$ sowie dem Mittelwert des Feature-Vektors $\bar{x}(x_j)$ und deren Standardabweichung $s(x_j)$ gemäß Gleichung 2.3 berechnet. Als Ergebnis wird der Datensatz eines einzelnen Features auf einen dimensionslosen Wertebereich mit dem Mittelwert $\bar{x}(x_j) = 0$ und der Standardabweichung $s(x_j) = 1$ über alle Beispiele hinweg transformiert [Guy+06, S. 3], [Alp14, S. 97], [GS21, S. 123].

$$p_{i,j} = \frac{x_{i,j} - \bar{x}(x_j)}{s(x_j)} \quad (2.3)$$

Im nächsten Schritt wird die Durchführung einer Dimensionsreduktion empfohlen, um nicht relevante Feature-Information zu entfernen. Dies ist im Hinblick auf die Rechenressourcen-Senkung, die Vermeidung der Modell-Überanpassung und die Modell-Interpretierbarkeit sinnvoll. Bei der Feature-Selektion werden unwichtige Features entfernt. Bei der Feature-Projektion werden neue Features durch die Kombination der Original-Features erstellt [Alp14, S. 114], [GS21, S. 130], [Jun22a, S. 174].

Bei der *Principal Component Analysis* erfolgt eine Feature-Projektion, indem mithilfe der Singulärwertzerlegung konsekutiv die Dimensionen identifiziert werden, bei denen die Verschiedenheit der Datenprojektion am höchsten ist. Die Vektoren des neu aufgespannten Raums sind orthogonal, und deren Anzahl (= neue Dimensionen) ist von der darzustellenden Datenvarianz abhängig [Jos19, S. 26], [Alp14, S. 120].

Durch das Ranking der Features gemäß ihrem *Laplace-Punktwert* werden die relevantesten Features ermittelt. Die Features werden hierbei durch deren Lokalität zueinander bewertet. Die Kenntnis der Zielgrößen ist nicht notwendig [HCN05].

Bei der *Neighbourhood Component Analysis* wird basierend auf dem K-Nearest-Neighbour Algorithmus eine Reduktion des Ausgangs-Featureraums in einen Featureraum mit geringerer Dimension durch Feature-Selektion entwickelt. Die Beziehungen zwischen den Datenpunkten bleiben jedoch erhalten. Hier wird eine Gewichtung der Features vorgenommen, bei der die Kenntnis der Zielgrößen notwendig ist [Gol+04].

Mit dem *Relief-Algorithmus* werden Features nach ihrer Wichtigkeit bewertet. Dazu ist die Kenntnis der Zielgröße notwendig. Bei einer Klassifikationsaufgabe werden die Features als wichtig bewertet, die bei nächsten Datenpunkt-Nachbarn unterschiedlicher Klassen auch selber unterschiedlich sind. Bei der Regression wird die Größe des Zielwerts zur Wichtigkeitsbewertung der Features verwendet [RK03], [Mat25a].

Beim *Chi-Quadrat-Ranking* erfolgt das Ranking der Features basierend auf dem Chi-Quadrat-Test, welcher einen Hypothesentest darstellt. Die Grundlage des Tests sind dabei die zwei Hypothesen (Nullhypothese und Alternativhypothese), ob zwischen zwei Grundgesamtheiten ein Zusammenhang besteht oder nicht. Dementsprechend kann mit dem p-Wert, der die Wahrscheinlichkeit zur Beibehaltung der Nullhypothese repräsentiert, eine Beurteilung der aufgestellten Nullhypothese vorgenommen werden. Es wird daher mithilfe des p-Werts die Prüfung zur Feststellung der Abhängigkeit zwischen einem Feature und der Zielvariable durchgeführt [HS17, S. 333, 445]. Dieses Verfahren ist innerhalb der genutzten *MATLAB*-Umgebung nur für die überwachte Klassifikation bei Kenntnis der Zielgrößen anwendbar [Mat25b].

Ähnlich dem Chi-Quadrat-Ranking wird beim *F-Test-Ranking* die Wichtigkeit der Features basierend auf dem F-Test gerankt. Dabei wird ein Hypothesentest zum Mittelwert der

gezogenen Populationen in Abhängigkeit der Features durchgeführt. Als Nullhypothese dient die Annahme, dass die nach Featurewerten gruppierten Zielgrößen aus der Grundgesamtheit mit gleichem Mittelwert stammen. Mithilfe des p-Werts kann die Signifikanz des Features eingeschätzt werden. Dieses Verfahren wird für die überwachte Regression bei Kenntnis der Zielgrößen eingesetzt [Mat25d].

2.3.2.4 Modelltraining mit Hyperparameteroptimierung

Die Prozesse des Modell-Trainings und der Hyperparameter-Optimierung sind miteinander gekoppelt, was im Folgenden näher erläutert wird.

Modelltraining

Beim Modelltraining unüberwachter Modelle wird eine iterative Anpassung der Modellparameter umgesetzt. Parallel erfolgt eine Bewertung der abgebildeten Datenstruktur oder darin enthaltener Assoziationen. Nach einem vorgegebenem Abbruchkriterium werden die optimalen Modellparameter identifiziert [Jo21, S. 191], [HTF09, S. 487].

Das Ziel beim Modelltraining überwachter ML-Verfahren ist, die Modellparameter bei gesetzten Hyperparametergrenzen dahingehend anzupassen, dass der Unterschied zwischen vorhergesagten \hat{y}_i und wahren Zielgrößen y_i minimiert wird. Dies erfolgt durch die Definition einer Objektivfunktion J , die während der iterativen Anpassung der Modellparameter $\psi_{1..k}$ minimiert wird, siehe Gleichung 2.4 (p_B = Anzahl an Trainingsdaten-Beispiele; K = Kostenfunktion; y_i = wahre Zielgrößen; \hat{y}_i = vorhergesagte Zielgrößen). Mathematisch ergibt dieses Vorgehen eine Optimierungsaufgabe für J [Alp14], [Jun22a, S. 6], [Bad+20], [Mat22].

$$J(\psi_{1..k}) = \sum_{i=1}^{p_B} K(y_i, \hat{y}_i) \quad (2.4)$$

Ein zentrales Ziel der Optimierungsaufgabe ist das Auffinden des optimalen Bias-Varianz-Gleichgewichts in Abhängigkeit der ML-Modellkomplexität, siehe Abbildung A.5 im Anhang A.1.3. Darin wird ebenfalls die Abhängigkeit der Modellierungs-Ergebnisse von der Numerik deutlich, da die zufälligen initialen Startwerte des Trainings-Zyklus einen Einfluss auf das finale Ergebnis haben [HTF09], [SLA12], [Jos19, S. 163], [Swa19, S. 312].

Beim *Ensemble Learning* werden die Ergebnisse unterschiedlicher Modelle nach festgelegten Methoden miteinander verrechnet, um eine ausgewogene Vorhersage zu erhalten. Damit kann von kombinierten Modellen gesprochen werden. Die Ermittlung des Ergebnisses ist mithilfe vielfältiger Methoden, die auf paralleler oder serieller Kombination basieren können, möglich (z. B. *Boosting*, *Bootstrapping*, *Bagging*, ...) und ist in der referenzierten Literatur näher erklärt [GS21, S. 54], [Jos19, S. 60], [Guy+06, S. 191].

Hyperparameteroptimierung

Zum Testen unterschiedlicher Hyperparameter-Kombinationen ist ein möglichst effizientes Suchverfahren auszuwählen. In einer systematischen und damit genauen, jedoch rechenaufwendigen *Rastersuche* wird jede Hyperparameter-Kombination getestet. Bei einer *Zufallssuche* werden die Kombinationen zufällig ausgewählt. Zudem existieren kombinierte Suchalgorithmen, die bereits ermittelte Information zum Hyperparameter-Einfluss bei ihrer Suche nach

neuen Kombinationen nutzen. So werden bei der *Bayes'schen Optimierung* Hyperparameter-Sets guter Performance mit neuen zufälligen Einstellungen kombiniert [WHG16].

2.3.2.5 Bewertung der Modellierungs-Güte

Nach dem Trainings-Vorgang müssen die Modelle auf ihre Modellierungs-Güte bewertet werden, siehe Abbildung 2.14. Beim überwachten Lernen geschieht dies zweistufig zum Zwecke der Hyperparameter-Bewertung (anhand des Validierungs-Sets) und der generellen Performance-Bewertung (anhand des Test-Sets) durch den Abgleich der vorhergesagten und wahren Zielgrößen. Da beim unüberwachten Lernen keine Zielgrößen vorhanden sind, erfolgt die Bewertung basierend auf den verarbeiteten Features [Jos19], [HTF09], [Jun22a].

2.3.2.6 Implementierung in der Serienanwendung

Sollten die aufgebauten ML-Modelle sich zur Anwendung auf die vorliegende Aufgabe eignen, ist deren Implementierung in automatisierten Systemen anzustreben, bei denen die Datenquellen, die Datenverarbeitung sowie der Ergebnisoutput aneinander gekoppelt sind und auch in der Cloud laufen können. Neben den zu definierenden Schnittstellen sind auch die zu verwendenden Hardware-Geräte, Software-Bibliotheken und ggf. Cloud-Lösungen auszuwählen. Zudem ist ein kontinuierliches Monitoring der ML-Modelle notwendig, um deren Anwendbarkeit bei neuen Daten zu überprüfen und diese ggf. durch neu trainierte Modelle zu ersetzen. Dabei ist der Einsatz von *online*-lernenden Modellen denkbar, die neu einkommende Daten dem Trainings-Prozess zukommen lassen [Alp14, S. 285], [Jos19, S. 207], [RRC19, S. 243] [Lee19, S. 269].

2.3.3 Unüberwachtes Lernen

In diesem Abschnitt wird auf die Besonderheiten der unüberwachten ML-Algorithmen sowie auf deren Evaluationsmethoden und Herausforderungen eingegangen.

2.3.3.1 Algorithmen

Die ML-Algorithmen können in folgende Gruppen eingeteilt werden: Clustering-Algorithmen, Komponenteanalyse, Anomalieidentifikatoren und neuronale Netze [Jos19, S. 136], [DD22, S. 16]. In dieser Arbeit eingesetzte unüberwachte Algorithmen sind im Folgenden erklärt.

Clustering-Algorithmen

Der *K-Means*-Algorithmus ordnet die vorliegenden Datenpunkte k Clustern zu, siehe Abbildung 2.15. Dabei besteht das Ziel, die Abstände zwischen den Punkten und dem dazugehörigen Cluster-Mittelpunkt zu minimieren. Die Anzahl k der Cluster wird vom Anwender vorgegeben. Nach einer zufälligen Festlegung der Cluster-Mittelpunkte werden die Datenpunkte diesen zugeordnet. Basierend auf den Datenpunkten jedes Clusters werden die Cluster-Mittelpunkte neu berechnet, woraufhin die Zuordnung der Datenpunkte neu beginnt. Das Vorgehen wird solange fortgeführt, bis sich die Lage der Cluster-Mittelpunkte nicht mehr signifikant ändert

[Jos19, S. 134], [GS21, S. 61]. Eine Abwandlung des K-Means-Algorithmus ist der *K-Medoids*-Algorithmus. Bei diesem müssen die Cluster-Mittelpunkte einem Datenpunkt entsprechen [HTF09, S. 516]. Die *hierarchische Clusteranalyse* ordnet die Daten mithilfe deren Abstände in einer Baumstruktur an, anhand deren Aufbau die Daten in Clustern zusammengefasst werden können, siehe Abbildung 2.15 [Alp14, S. 177], [Bad+20].




Abbildung 2.15: Beispiele für unüberwachte Clustering-Algorithmen nach [Mat20]

Ausreißeridentifikatoren

Mit der Anwendung der *One-Class Support Vector Machine* wird anhand der eingelesenen Gut-Daten eine Grenze konstruiert, mit deren Hilfe neue Beispiele als Gut- oder Schlecht-Daten (Ausreißer) identifiziert werden, siehe Abbildung 2.16 [RR07]. Ebenfalls in der Abbildung 2.16 ist die Funktionsweise des *Local Outlier Factor* skizziert. Bei diesem Verfahren werden die Datenpunkte als Anomalien identifiziert, deren lokale Dichte niedriger ist als die ihrer Nachbarn. Bildlich gesprochen werden einzeln liegende Beispiele als Ausreißer identifiziert [Bre+00]. Bei dem Verfahren des *Isolation Forest* werden Anomalien aufgrund ihres Unterschieds von den normalen Datenpunkten mithilfe von Entscheidungsbäumen isoliert. Eine Anomalie benötigt weniger Entscheidungen, um von den normalen Datenpunkten isoliert zu werden, siehe Abbildung 2.16 [LTZ08]. Das Verfahren des *Robust Random Cut Forest* als Erweiterung des Isolation Forest basiert darauf, dass ein anomaliebehaftetes Beispiel im Gegensatz zu normalen Daten die Komplexität des Modells erhöht [Guh+16]. Des Weiteren können Anomalien mithilfe der *Mahalanobis*-Distanzmetrik identifiziert werden. Bei normalverteilten Daten folgen die quadratischen Mahalanobis-Abstände der Beispiele zu der Normalverteilung wiederum einer Chi-Quadrat-Verteilung. Mit der Definition eines kritischen Schwellwerts können Anomalien bei Abweichungen festgestellt werden [HTF09, S. 441], [Run16, S. 13], [Mat25c].

2.3.3.2 Evaluationskennzahlen

Zur Beurteilung eignen sich z. B. der *Silhouettenkoeffizient*, der *Calinski-Harabasz-Index* oder der *Davies-Bouldin Index*. Die entstehenden Bewertungen basieren auf Distanzmessungen unter den Daten innerhalb eines Clusters sowie zwischen den Clustern [Liu+10], [Nai23], [Wij23]. In [AJ03] wird die *Normalized Mutual Information* zur Bewertung der Cluster-Qualität vorgeschlagen. Dabei wird die Ähnlichkeit zweier Clusterzuordnungen verglichen. Dies bedeutet, dass zur Prüfung des finalen Clusterings der Abgleich mit dem wahren Cluster notwendig ist (jedoch sind die wahren Cluster nicht für das Modell-Training notwendig). Die




Abbildung 2.16: Beispiele für unüberwachte Ausreißeridentifikatoren nach [RR07], [Bre+00], [LTZ08], [Mat25c]

Punktebewertung reicht von 0 (= keine Übereinstimmungen) bis 1 (= perfekte Korrelation).

2.3.3.3 Herausforderungen

Eine Herausforderung ist die oftmals notwendige Vorgabe der Clusteranzahl, wovon das finale Ergebnis im hohen Maße abhängt. Da die wahren Zielgrößen der Daten nicht vorhanden sind, stellt sich zudem die Frage, auf welche Art die Ergebnisse bewertet werden und welche Schwelle zur Beurteilung der Evaluationskennzahlen herangezogen wird [Jam+13, S. 373].

2.3.4 Überwachtes Lernen

In diesem Abschnitt werden die Eigenschaften der überwachten Klassifikations- und Regressionsalgorithmen sowie deren Bewertung analysiert.

2.3.4.1 Algorithmen

Die Algorithmen werden je nach der Art der Zielgrößen in Klassifikations- und Regressionsmethoden unterteilt. Teilweise lassen sich in diesen Parallelen finden, wodurch eine Gruppeneinteilung möglich ist: Bei den *instanzbasierten Algorithmen* entstehen die Vorhersagen durch Vergleiche mit Trainings-Beispielen. Innerhalb der *Regressionsalgorithmen* erfolgt das iterative Lernen der Modellparameter durch die Minimierung der Objektivfunktion. Für *Entscheidungsbaum-basierte Algorithmen* werden Entscheidungsregeln basierend auf den Trainings-Daten entwickelt. *Bayes'sche Algorithmen* nutzen Bayes'sche Statistik zur Entscheidungsfindung. Innerhalb der *künstlichen neuronalen Netze* werden netzartige, teilweise an biologischen Prozessen orientierte, Entscheidungsstrukturen aufgebaut [Bro23].

Klassifikation

Der *K-Nearest-Neighbour* Algorithmus weist einem neuen Beispiel die mehrheitliche Klasse der k nächsten Nachbarn zu, die mit den Abständen der Features identifiziert werden, siehe Abbildung 2.17. Es erfolgt keine Trainingsphase, sondern nur der Featureabgleich der Trainings- und neuer Daten. Dieses Verfahren ist vor allem bei niedrigen Feature-Dimensionen empfohlen. Bei hoher Anzahl verwendeter Nachbarn entsteht eine Neigung zur Überanpassung. Zudem

ist der hohe Speicherbedarf nachteilig [Jos19, S. 38]. Die *logistische Regression* berechnet die Wahrscheinlichkeit der Klassenzugehörigkeit als Funktion linearer Kombination der Features. Die finale Klassenzuteilung erfolgt mit der Sigmoidfunktion ausgehend von einer vorgegebenen Wahrscheinlichkeitsschwelle, siehe Abbildung 2.17. Dies ist ein binärer, leicht interpretierbarer Klassifizierer, welcher durch den Aufbau mehrerer binärer Teilprobleme zu einem Multiklassen-Klassifizierer erweitert werden kann [Jun22a, S. 64], [Jos19, S. 38]. Bei der *Support Vector Machine* werden die Trainings-Daten als Vektoren definiert, die durch eine Hyperebene in unterschiedliche Klassen separiert werden, siehe Abbildung 2.17. Der Abstand der Hyperebene zu den Vektoren, die der Ebene am nächsten sind, wird beim Trainings-Prozess maximiert. Dies ist ein binärer Klassifikationsalgorithmus, der wie die logistische Regression auf Mehrklassen-Probleme erweitert werden kann. Vorteilhaft ist hierbei die vergleichsweise geringe Neigung zu Überanpassung [RRC19, S. 63], [GS21, S. 46].

Der *Naive-Bayes* Algorithmus gehört zu den probabilistischen Methoden. Die Klassenzugehörigkeit der Beispiele wird nicht eindeutig, sondern wahrscheinlichkeitsbasiert definiert, siehe Abbildung 2.17. Jedes Merkmal bedingt die Wahrscheinlichkeit einer Klassenzugehörigkeit. Dieser Algorithmus wird bei einfachen Problemstellungen und kleinen Datensätzen empfohlen, da er in diesem Fall vergleichsweise wenig Rechenressourcen und Trainingszeit benötigt [GS21, S. 42], [RRC19, S. 42]. Bei der *Diskriminanzanalyse* wird der Aufbau des Trainings-Datensatzes als mehrdimensionale Normalverteilung angenommen. Zur Separation der Klassen werden deren Grenzen durch die Punkte ermittelt, an denen die Verteilungen die gleiche Wahrscheinlichkeit annehmen. Diese Methode ist robust gegenüber Ausreißern und Datenrauschen [Alp14, S. 55], [Jam+13, S. 138].

Künstliche neuronale Netze (en. *artificial neural network*) bestehen aus vernetzten Neuronen, die in mehreren Schichten angeordnet sind, siehe Abbildung 2.17. Die Neuronenanzahl der Eingabeschicht entspricht der Feature-Anzahl. In der Ausgabeschicht wird die Zielgröße, z. B. in Form der Sigmoid-Funktion für die Klassifikation, generiert. Dazwischen sind die verdeckten Schichten aufgebaut, deren Anzahl und Größe je nach Netzwerkarchitektur variiert. In den Neuronen wird die eingehende Information mithilfe trainierter Gewichte verarbeitet. Daraus wird durch eine Aktivierungs-Funktion ein Ausgabewert berechnet, der wiederum als Eingabewert für die Neuronen der nächsten Schicht fungiert. Die beschriebenen Netze eignen sich zur Abbildung hochkomplexer nichtlinearer Zusammenhänge. Als Nachteil ist der hohe Rechenaufwand sowie die schwierige Interpretierbarkeit zu nennen. Künstliche neuronale Netze stellen die Grundlage des heutigen deep learnings dar. Es existiert eine Vielzahl an Architekturen für gesonderte Anwendungen [GS21, S. 63, 84], [Jo21, S. 18], [Jos19, S. 43].

In einem *Entscheidungsbaum* wird eine Entscheidungsstruktur in Abhängigkeit der Dateneigenschaften aufgebaut, siehe Abbildung 2.17. Ausgehend von einem Wurzelknoten wird an jedem darunter liegenden Knoten eine Entscheidungsregel eingesetzt, um die Daten in Zweige zu separieren. Die Klasse wird am Ende eines Baums ermittelt. Der Vorteil der Entscheidungsbäume ist die leichtere Interpretierbarkeit. Als Nachteil ist die Neigung zur Überanpassung zu nennen [GS21, S. 49], [Jo21, S. 41]. Zur Überwindung der Nachteile von Entscheidungsbäumen lassen sich mit dem *Ensemble Learning* mehrere Bäume in einen *Boosted Tree* oder *Random Forest* kombinieren. Das Vorhersageergebnis entsteht aus den untereinander verrechneten Outputs der einzelnen Bäume. Beim Boosted Tree werden einzelne Bäume sukzessive dem gesamten Modell hinzugefügt und deren Ergebnisse anhand der Trainingsfehler gewichtet. Die Methode Random Forest trainiert ebenfalls mehrere Entscheidungsbäume, wobei diese auf unterschiedliche Teil-Datensätze angepasst werden. Zudem werden die Entscheidungsregeln an den einzelnen Knoten hierbei zufällig ausgewählt [GS21, S. 49, 55], [Alp14, S. 213], [Jo21, S. 141, 160], [Jam+13], [Jos19, S. 53], [HTF09, S. 587].

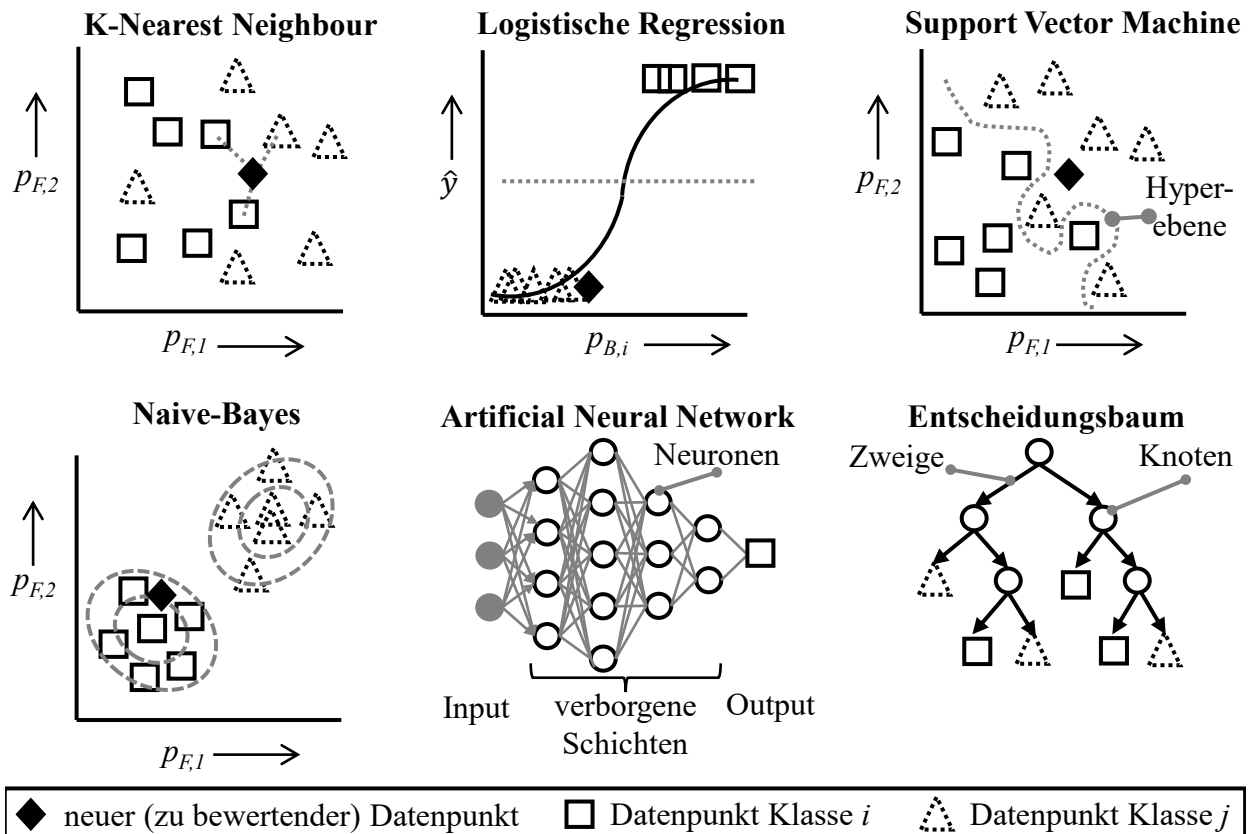


Abbildung 2.17: Beispiele für überwachte ML-Algorithmen [Mat20], [Jos19], [Jun22a], [Jun22b], [RRC19], [GS21], [Alp14], [Jam+13] ($p_{F,i}$ = Feature i ; \hat{y} = Vorhersage; $p_{B,i}$ = Datenbeispiel i)

Regression

Die Anwendung der *linearen Regression* erfolgt durch das Bilden einer Regressionsgleichung aus den Features. Einzelne Features und deren mathematische Abbildungen (z. B. Feature-Produkte, -Potenzen, -Logarithmen, etc.) werden zu einer Gesamtgleichung der Zielgröße addiert. Das Gewicht jedes Summands wird durch die Minimierung der Objektivfunktion im Modell-Training optimiert. Durch die Regularisierung der Kostenfunktion wird die Modell-Überanpassung reduziert. Dabei wird bei der Objektivfunktion während des Modelltrainings den für die Überanpassung verantwortlichen Gliedern im mathematischem Sinne ein Strafmaß hinzugefügt, welches beispielsweise die Summe der Koeffizienten in einer linearen Regressionsgleichung sein kann [GS21, S. 133], [Alp14, S. 14], [Jos19, S. 36]. Die Modellierung erfordert keine hohen Rechenressourcen und ist leicht interpretierbar. Damit können jedoch komplexe Zusammenhänge schlecht abgebildet werden [GS21, S. 30], [Jam+13, S. 59]. Die Anwendung des *Support Vector Machine* Algorithmus ist auch bei der Regression möglich. Dabei wird im Gegensatz zur Klassifikation eine Hyperebene modelliert, auf der möglichst viele Datenpunkte liegen [SC08]. Der Einsatz *künstlicher neuronaler Netze* kann für die Regression analog wie bei der Klassifikation erfolgen, indem die Gewichte und Aktivierungsfunktionen angepasst werden [GS21, S. 63, 84], [Jo21, S. 18]. Die ML-Algorithmen *Entscheidungsbaum*, *Boosted Tree* und *Random Forest* eignen sich ebenfalls für Regressionsaufgaben. Statt der Klassenzuordnung wird der kontinuierliche Wert der Zielgröße vorhergesagt. Dies kann jedoch zu hoher Überanpassung führen, wenn noch nicht gesehene Zielgrößen-Werte vorhergesagt werden sollen [Alp14, S. 214], [DD22, S. 15]. Das *Allgemeine Additive Modell* ist eine Erweiterung von linearen Modellen, wobei vordefinierte nicht-lineare Basisfunktionen mithilfe statistischer Methoden vorgegeben werden [HTF09, S. 295].

2.3.4.2 Evaluationskennzahlen

In diesem Abschnitt werden die Evaluationskennzahlen der Modellierungs-Güte vorgestellt. Als Benchmark-Größen der Modellierungsgüte können die probabilistische Fehlerabschätzung, andere ML-Methoden oder der Vergleich mit der Vorhersagegüte durch einen Menschen dienen [Jun22a, Kap. 6]. Da für die Kennzahlen auch im deutschen Sprachraum häufig deren englischer Begriff verwendet wird, wird dies auch im Folgenden so umgesetzt.

Klassifikation

Die Evaluation der Modellierungs-Güte bei Klassifikationsaufgaben basiert vorwiegend auf der Gegenüberstellung der wahren und vorhergesagten Klassen, siehe die dazugehörige Visualisierung in den Konfusionsmatrizen in der Abbildung 2.18. Im binären Fall wird eine richtig vorhergesagte wahre Klasse als *true positive* (TP , dt. *richtig positiv*) bezeichnet. In Falle der negativen Klassen wird die analoge Zuordnung als *true negative* (TN , dt. *richtig negativ*) bezeichnet. Auf der Matrix-Diagonalen sind die Anzahlen der richtigen Zuordnungen (TP und TN) verzeichnet. Innerhalb dieser Arbeit werden dabei höhere Zahlen richtiger Zuordnungen mit einem stärkeren Grünton markiert. Sollte ein wahres positives Beispiel als negativ vorhergesagt werden, so wird diese Vorhersage *false negative* (FN , dt. *falsch negativ*) genannt. Falls ein wahr negatives Beispiel als positiv vorhergesagt wird, entsteht eine *false positive* (FP , dt. *falsch positiv*) Klassifizierung. In den einzelnen Feldern wird die Anzahl der entsprechenden Falsch-Klassifikationen folgerichtig außerhalb der Matrix-Diagonalen (FN und FP) eingetragen. Innerhalb dieser Arbeit werden dabei höhere Zahlen falscher Zuordnungen mit einem stärkeren Rotton markiert. Im Falle einer Multiklassen-Klassifikation (Anzahl der Klassen > 2) wird für jede Klasse die $TP/TN/FP/FN$ -Zuordnung umgesetzt [Lee19, S. 166].

Im Folgenden wird auf bedeutende Evaluationskennzahlen eingegangen. Deren mathematische Definition inklusive Wertebereich ist in den Tabellen A.3 und A.4 sowie den Gleichungen A.1 und A.2 im Anhang A.1.3 spezifiziert. Die Berechnungen basieren auf der Konfusionsmatrix eines binären Klassifizierers (Abbildung 2.18). Die notwendige Erweiterung auf ein multi-Klassen-Modell wird im Anschluss erläutert.

Die *Fehlerquote* (L_E) entspricht dem Anteil falsch klassifizierter Beispiele. Die *True Positive Rate* (TPR_E) gibt den Anteil an positiven Klassen, die auch als solche erkannt wurden, wider [Alp14, S. 562]. Für die negativen Klassen ist die analoge Kennzahl die *True Negative Rate* (TNR_E) [Run16, S. 93]. Der *Positive Predictive Value* (PPV_E) repräsentiert den Anteil der als positiv korrekt identifizierten Beispiele bezogen auf die Gesamtzahl der als positiv klassifizierten Beispiele [Alp14, S. 562]. Das Komplement dazu ist die *False Discovery Rate* (FDR_E) [BH95]. Der *Negative Predictive Value* (NPV_E) sagt aus, welcher Anteil der als negativ eingestuften Klassen wirklich negativ ist [Run16, S. 93]. Das Komplement dazu ist die *False Omission Rate* (FOR_E) [TVS10]. Mithilfe der *False Positive Rate* (FPR_E) wird der Anteil der falschen Alarme identifiziert. Anhand der *False Negative Rate* (FNR_E) wird der gleiche Effekt für die negative Klasse gemessen [Alp14, S. 562].

Des Weiteren finden Evaluations-Kennzahlen Anwendung, mit denen eine umfassendere Bewertung vorgenommen wird. Mit dem *F-Score* (FSc_E) wird die Beurteilung durch die True Positive Rate TPR_E und den Positive Predictive Value PPV_E kombiniert [GS21, S. 69]. In dieser Arbeit wird der darin enthaltenen Gewichtungsfaktor zu $\beta = 1$ gesetzt, was den F-Score zu einem harmonischen Mittel aus der True Positive Rate TPR_E und dem Positive Predictive

Binäre Klassifikation				Multi-Klassen-Klassifikation					
wahrer Zustand	positiv	298 TP	22 FN	wahrer Zustand	1	718 TP₁	40 FN₁	2 FN₁	
	negativ	17 FP	31 TN		2	101 FP₁	76 TN₁	7 TN₁	
		positiv	negativ	Auswertung für Klasse 1		1	2	3	
		Vorhersage				Vorhersage			
wahrer Zustand	1	718 TN₂	40 FP₂	2 TN₂	wahrer Zustand	1	718 TN₃	40 TN₃	2 FP₃
	2	101 FN₂	76 TP₂	7 FN₂		2	101 TN₃	76 TN₃	7 FP₃
	3	11 TN₂	20 FP₂	9 TN₂		3	11 FN₃	20 FN₃	9 TP₃
Auswertung für Klasse 2		1	2	3	Auswertung für Klasse 3		1	2	3
		Vorhersage				Vorhersage			

Abbildung 2.18: Binäre und multi-Klassen Klassifikation nach [Lee19] (TP/TN/FP/FN = true positive/true negative/false positive/false negative-Vorhersage bei einer binären Klassifikation; TP_i/TN_i/FP_i/FN_i = o. g. Kennzahlen bei der Betrachtung der Klasse i innerhalb einer multi-Klassen-Klassifikation; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

Value PPV_E macht. Bei der Beschreibung mit dem *Threat Score* (TSc_E) werden ebenfalls falsche Alarme und falsch negative Vorhersagen mit in die Bewertung einbezogen [Sch90]. Die Kennzahl *Informedness* (Inf_E) beschreibt, wie gut der Klassifizierer über die positiven und negativen Beispiele informiert ist [Pow20]. Mit der *Markedness* ($Mark_E$) wird die Sicherheit positiver und negativer Vorhersagen bewertet [Pow20].

Die Nutzung der *Balanced Accuracy* ($BAcc_E$) wird bei unbalancierten Datensets empfohlen. Diese ist der Durchschnitt der True Positive und True Negative Rate [Guy+06, S. 112]. Der *Geometric Mean* (GM_E) beurteilt die Performance des Klassifizierers bei positiven und negativen Klassen [Kub17, S. 220]. Mithilfe des *Fowlkes-Mallows-Index* (FM_E) wird die Vorhersagegüte anhand der Konfusionsmatrix bewertet [FM83]. Der *Matthews Correlation Coefficient* (MCC_E) kann als eine Art Korrelationskoeffizient der Klassifikation angesehen werden [Mat75], [Pow20] (siehe Gleichung A.1 im Anhang A.1.3). Mit dem *Cohen's Kappa* (CK_E) wird die Übereinstimmung von zwei Schätzern evaluiert, siehe Gleichung A.2 im Anhang A.1.3 [Coh60]. Die beiden letztgenannten Kennzahlen werden für den Einsatz bei unbalancierten Daten empfohlen.

Bei Mehrklassen-Klassifikatoren werden verschiedene Techniken empfohlen, mit denen die bisher genannten Bewertungskennzahlen verarbeitet werden. Dazu zählen die folgenden häufig verwendeten Methoden: *Macro-*, *Weighted-Macro-* und *Micro-Averaging*. Beim *Macro-Averaging* werden die Evaluationskennzahlen für jede Klasse gemäß der Aufstellung von true positive, true negative, false positive und false negative Werten (siehe Abbildung 2.18) separat berechnet. Abschließend ergibt sich die finale Kennzahl durch das Mitteln der Kennzahlen jeder Klasse. Ähnlich dazu verläuft das *Macro-Weighted-Averaging*, bei dem die Kennzahlen jeder Klasse zusätzlich vor dem Mitteln entsprechend den Klassenanteilen

an dem Datensatz gewichtet werden. Diese Technik ist bei nicht balancierten Datensätzen empfohlen. Mit dem Einsatz des Micro-Averaging werden beim Betrachten jeder Klasse binäre Konfusionsmatrizen abgeleitet, in denen die betrachtete Klasse als positive und der Rest als negative Klasse eingestuft sind. Diese Konfusionsmatrizen werden zu einer gesamten binären Konfusionsmatrix addiert, woraus die Kennwerte der Vorhersagegüte berechnet werden [Kub17, S. 265], [Shm19].

Regression

Die Kennzahlen der Regressions-Vorhersagegüte können dimensionslos oder dimensionsbehaftet sein. Die dimensionslosen Kennzahlen lassen sich in Kennzahlen mit definiertem und variablem Wertebereich einteilen. Die mathematische Definition und der Wertebereich folgender Kennzahlen sind in der Tabelle A.5 im Anhang A.1.3 aufgelistet.

Das *Bestimmtheitsmaß* R_E^2 bewertet den linearen Zusammenhang zwischen zwei Variablen. Dies lässt sich auf die wahre (y_i) und vorhergesagte Zielgröße (\hat{y}_i) anwenden [GS21, S. 72]. Ähnlich verhält sich der *Korrelationskoeffizient* $R_{XY,E}$ [Jos19, S. 145]. Bei diesen beiden Kennzahlen ist der Wertebereich vorgegeben und repräsentiert bei hohen Werten einen sehr starken Zusammenhang. Beim *relativen absoluten Fehler* (RAE_E) wird die Summe der absoluten Fehler auf die absolute Summe der Differenz zwischen Zielgröße und deren Durchschnitt bezogen. Hier sind geringe Fehlerwerte anzustreben [JPJ22]. Die *Wurzel des mittleren quadratischen Fehlers* ($RMSE_E$) beschreibt, wie nah die Vorhersage an der wahren Zielgröße liegt. Dieser Kennwert ist dimensionsbehaftet und repräsentiert bei dem Wert $RMSE_E = 0$ eine fehlerlose Vorhersage [Swa19, S. 170]. Die daraus abgeleitete dimensionslose Kennzahl wird durch die *Wurzel des relativen mittleren quadratischen Fehlers* ($RRMSE_E$) abgebildet [JPJ22]. Die *mittlere quadratische Abweichung* (MSE_E) ist eine dimensionsbehaftete Kennzahl, bei der die Ausreißer ein größeres Gewicht aufgrund der Quadrierung in der Bewertung haben. Je höher die Kennzahl, desto schlechter ist die Vorhersage [Jos19, S. 170]. Beim *mittleren absoluten Fehler* (MAE_E) handelt es sich um eine Metrik, die wenig sensitiv auf Ausreißer reagiert [JPJ22], [Jos19, S. 170]. Der *Median der absoluten Abweichung* ($MedA_E$) ist in einem geringen Maße abhängig von Ausreißern [Att25].

In der Tabelle A.28 im Anhang A.11.4 sind die Stufen zur Interpretation der Evaluationskennzahlen mit einem festen Wertebereich anhand der in diesem Abschnitt verwendeten Quellen dargestellt. Die Stufen sind eine Näherung im Rahmen dieser Arbeit, um eine Vergleichsgrundlage zu schaffen.

3 Aktuelle Entwicklungen in der Forschung und Industrie

Dieses Kapitel stellt die aktuellen Entwicklungen in den relevanten Technologiebereichen dieser wissenschaftlichen Arbeit dar. In dem Abschnitt 3.1 wird auf die Luftfahrzeug-Strukturmontage eingegangen. Dabei werden die eingesetzten Werkstoffe (Abschnitt 3.1.1) und die genutzten Füge-technologien (Abschnitt 3.1.2) präsentiert. Im Abschnitt 3.1.3 erfolgt die Analyse der durchgeführten Bohrprozesse in der Luftfahrzeug-Strukturmontage mit einem speziellen Fokus auf die neuesten Entwicklungen. Abschließend wird die Digitalisierung der Produktionsprozesse und der Einsatz von maschinellem Lernen beim Produktionsprozess-Monitoring (Abschnitt 3.2) mit einem Fokus auf Bohrverfahren erläutert.

3.1 Luftfahrzeug-Strukturmontage

In diesem Abschnitt erfolgt die Einführung in den Aufbau von Luftfahrzeug-Strukturen und die dabei eingesetzten Werkstoffe. Daraufhin werden die aktuell angewandten Füge-technologien vorgestellt. Anschließend findet die Darstellung unterschiedlicher Bohrverfahren, die zur Herstellung der Nietverbindungen vonnöten sind, statt. Die Rümpfe heutiger industriell hergestellter Passagier- und Frachtmaschinen werden aus Schalen aufgebaut, die zu Sektionen zusammengefügt werden. In dieser Sektionsbauweise werden als volumengebendes Element vorgefertigte Schalen durch quer angeordnete Spanten und längs laufende Stringer verbunden und damit versteift, siehe dazu die Abbildung 3.1. Neben den Strukturelementen wird Dicht- und Ausgleichsmasse beim Fügen eingebracht. Der Werkstoffeinsatz und die dafür notwendigen Füge-technologien werden dabei bauteilspezifisch gestaltet [Ray06], [Air13].




Abbildung 3.1: Rumpfaufbau bei Luftfahrzeugen und Werkstoffeinsatz beim Airbus A350 nach [Ray06], [BHB17], [Air13] (FVK = Faserverbund-Kunststoffe)

3.1.1 Eingesetzte Werkstoffe

Bei der Betrachtung moderner Luftfahrt kann ab der Hälfte des 20. Jahrhunderts der Einsatz neuartiger Titanlegierungen festgestellt werden, welche die bis dahin eingesetzten Stahl- und Aluminiumwerkstoffe teilweise ersetzen. Ab den 1960er Jahren kamen erstmals glas- und kohlenstofffaserverstärkte Kunststoffe im Militärbereich zum Einsatz. Seit den 1990ern laufende Entwicklungsprogramme der großen Flugzeughersteller führten zum Einsatz von Verbundwerkstoffen in der zivilen Luftfahrt. Im Airbus A380 ist der Gewichtsanteil an Aluminiumwerkstoffen mithilfe von Glare (= glasfaserverstärktes Aluminium) und kohlenstofffaserverstärkter Kunststoffe (CFK) auf $\approx 60\%$ gesenkt worden [Mra13]. Mit dem wichtigen Ziel der Gewichtseinsparung wurde der Anteil an CFK in den neuesten Langstreckenflugzeugen Airbus A350 und Boeing 787 auf über 50% gesteigert [Bre16]. Metallische Werkstoffe haben trotz aufkommender Verbundwerkstoffe weiterhin über alle Flugzeugtypen hinweg eine dominierende Bedeutung. Titan-Legierungen finden ihren Einsatz vor allem als versteifende Strukturelemente sowie im Fahrwerks- und Triebwerksbereich [Pet+03]. Die Struktur der heute am meisten verkauften Flugzeugfamilien Airbus A320 und Boeing 737 besteht zu einem großen Teil aus Aluminium-Legierungen [Ram+17].

3.1.1.1 Aluminium-Legierungen

Das Leichtmetall Aluminium bringt die Vorteile geringer Dichte, hoher Korrosions- und UV-Beständigkeit, hoher Ermüdungs- und spezifischer Festigkeit, vergleichsweise niedriger Kosten sowie guter Verarbeitbarkeit (z. B. durch Umformen, Zerspanen und teilweise Schweißen) mit sich. Weitere mechanische Eigenschaften lassen sich in der Tabelle A.1 im Anhang A.1.1 finden. Häufig eingesetzte Legierungen sind Al2024, Al7075, Al6061 oder Al3003. Die wichtigsten Legierungselemente sind dabei Silizium, Kupfer, Magnesium und Zink. So zeichnet sich die Al7075-Legierung durch eine hohe Festigkeit und schlechte Schweißbarkeit auf, lässt sich jedoch gut spanend bearbeiten. Der Einsatz von Aluminium in der Flugzeug-Struktur erfolgt bei Spanten, Stringern, Flügelholmen, Bodenabschnitten, Rumpfschalen, Treibstofftanks sowie bei der Tragflächenverkleidung [Li+23a], [ZL23], [Ram+17].

3.1.1.2 Titan-Legierungen

In der Luftfahrt eingesetzte Titan-Legierungen zählen ebenfalls zu den Leichtmetallen und zeichnen sich durch eine niedrige Dichte, hohe Duktilität und hohe (spezifische) Festigkeit aus, was zu hohen Gewichts- oder Volumeneinsparungen bei gleicher Belastbarkeit der Bauteile führt, siehe Tabelle A.1 im Anhang A.1.1. Als weitere Vorteile sind die hohe Korrosions- und Temperaturbeständigkeit, chemische Verträglichkeit mit CFK sowie die hohe Ermüdungsbeständigkeit zu nennen. Der Einsatz erfolgt bei speziellen mechanischen und thermischen Belastungsszenarien als Bestandteil von Triebwerks-, Struktur-, Verbindungs-, Rohr-, Tür- und Fahrwerkskomponenten. Die am häufigsten verwendete Legierung in der Luftfahrt ist die Ti6Al4V-Legierung (mit 6% Massenprozent Aluminium und 4% Massenprozent Vanadium) aufgrund ihrer ausgewogenen Eigenschaften. Titanwerkstoffe zählen zu den schwer zerspanbaren Materialien aufgrund ihrer niedrigen Wärmeleitfähigkeit und daraus resultierender hoher thermischer Werkzeugbelastung. Zudem entsteht aufgrund deren hoher Zähigkeit eine hohe mechanische Belastung der Schneiden [LW07], [Pet+03], [Ina+14], [VDL12], [BRS03], [HSS21].

3.1.1.3 Kohlenstofffaserverstärkte Kunststoffe (CFK)

Kohlenstofffaserverstärkter Kunststoff (CFK) ist ein Leicht-Verbundmaterial, dessen Struktur durch das Einbetten von Kohlenstofffasern unterschiedlicher Länge in ein Matrixmaterial aus Kunststoff beschrieben werden kann, siehe Abbildung 3.2. Diverse Faser- und Matrixausführungen bestimmen das Verhalten des Werkstoffs, siehe Tabelle A.1 im Anhang A.1.1.




Abbildung 3.2: CFK-Werkstoffaufbau nach [Sho07]

Als Vorteile von CFK-Werkstoffen lassen sich die geringe Dichte, hohe (spezifische) Zugfestigkeit bei Belastung in Faserrichtung, Korrosionsbeständigkeit, höhere Ermüdungsfestigkeit im Vergleich zu Aluminium-Legierungen und die Möglichkeit der belastungsabhängigen Gestaltung nennen. Dabei haben die Kohlenstofffasern die Funktion der Kräfteübertragung in Faserrichtung. Die Matrix dient der geometrischen Stabilisierung der Fasern, deren Schutz sowie der Kraftübertragung quer zur Faserrichtung. Als Matrix werden überwiegend Duroplaste und im geringeren Maße Thermoplaste eingesetzt. Bei den Duroplasten sind als Vorteil die mechanischen Eigenschaften, thermische Beständigkeit sowie geringere Rohstoffkosten zu nennen. Thermoplaste weisen günstige Eigenschaften hinsichtlich des einfacheren Urformprozesses für kleine Bauteile, der höheren Schadenstoleranz, der möglichen Schweißbarkeit, der chemischen Beständigkeit sowie des einfacheren Recyclings auf. Als Nachteil sind die höheren Materialkosten als bei Duroplasten sowie schwieriges Urformen von Bauteilen mit großen Abmessungen (z. B. Tragflächen) zu nennen.

Zur Herstellung eines funktionsfähigen CFK-Bauteils ist oftmals eine spanende Präzisionsbearbeitung, z. B. in Form der Kanten- oder Bohrbearbeitung notwendig, um die vorgegebenen Toleranzen zu erreichen. Dabei entstehen materialspezifische Herausforderungen wie Bauteilschädigungen in Form von Decklagendelamination oder abrasiver Werkzeugverschleiß, siehe Abschnitt 2.1.3 und 2.1.4. Die Anwendung von CFK erfolgt als Rumpfschalen, Tragflächen- und Leitwerkskomponenten, Triebwerksverkleidung und Clips. Ein Herausforderung stellen dabei die technisch aufwendige gesundheits- und umweltgerechte Entsorgung und Recycling von CFK-Werkstoffen dar [Hin21a, S. 61], [Lae+12], [Sho07], [Wu24], [Bre16].

3.1.2 Fügetechnologien

Beim Fügen von einzelnen Luftfahrzeug-Strukturelementen finden hauptsächlich folgende Technologien ihren Einsatz: *Kleben*, *Schweißen*, *Schrauben* und *Nieten* [Ray06]. Innerhalb der Schweißtechnologie sind das etablierte Laserstrahlschweißen sowie das aktuell im Forschungsfokus stehende Rührreibschweißen hervorzuheben. Das dominierende Fügeverfahren ist das Nieten, auf welches in diesem Abschnitt verstärkt eingegangen wird [Ray06]. Die restlichen

Verfahren werden zum Zwecke der Abgrenzung skizziert.

Das *Kleben* von Strukturkomponenten wird vor allem beim Verbinden der Außenschalen mit Stringern angewandt. Als Vorteil erweist sich dabei, dass das Werkstoffgefüge weniger als bei anderen Fügeverfahren beeinflusst wird. Die zusätzliche Gewichtsaufnahme ist dabei gering und die Lasteinbringung gleichmäßig. Als Nachteil ist die geringe Temperaturbeständigkeit, Empfindlichkeit gegenüber der Schwingungsbelastung und die hochgradige Abhängigkeit der Tragfähigkeit von der Belastungsrichtung zu nennen [Hig00], [Cav+21].

Das *Laserstrahlschweißen* wurde bisher in wenigen Szenarien beim Fügen von Aluminium-Werkstoffen eingesetzt, um Stringer mit Rumpfschalen zu verbinden. Als Potentiale sind hierbei die Automatisierbarkeit, hohe Prozessgeschwindigkeit, niedrigere Korrosionsanfälligkeit gegenüber der Nietverbindung und die Gewichtseinsparung aufgrund fehlender Verbindungselemente sowie nicht notwendiger Werkstoffüberlappung und Dichtmasse zu nennen. Die Nachteile sind in Form von leichterem Ermüdungsrisso-Ausbreitung, höherer Heißbrissneigung, fehlender Schweißbarkeit mancher Werkstoffe sowie herausfordernder Prozessführung und Bauteileinspannung zu nennen [Bla12], [Gru08]. In jüngster Zeit konnte auch die Eignung des Verfahrens für das Fügen von Thermoplast-Rumpfschalen im Forschungsbereich nachgewiesen werden [Fra25]. Zudem konnte in den letzten Jahren das *Rührreibschweißen* zum Fügen nicht mittels Laserstrahl schweißbarer Werkstoffe weiterentwickelt werden, wobei für diese Technologie ansonsten ähnliche Vorteile wie beim Laserstrahlschweißen zu nennen sind. Das Fügen erfolgt in einem Festphasen-Prozess, welcher aufgrund der hohen mechanischen Belastung spezielle Fertigungseinrichtungen zur Abstützung der Wirkzone erfordert. Der Übertrag in die industrielle Großanwendung der Luftfahrzeug-Strukturmontage fand bisher jedoch noch nicht statt [Fra14], [WZH18], [GLS19].

Schraubverbindungen bringen den Vorteil der einfachen Demontierbarkeit, Anwendbarkeit bei unterschiedlichen Werkstoffen sowie der hohen Festigkeit in Zug- und Scherrichtung. Als Nachteil sind die chemische Anfälligkeit, verschiedene thermische Eigenschaften beim Fügen unterschiedlicher Werkstoffe und hohe Kosten zu nennen. Der Einsatz erfolgt beim Fügen großer Elemente wie z. B. der Tragflächen mit dem Rumpf. Bei Boeing 747 machen Schraubverbindungen etwa 22 % der Verbindungselemente aus [Ray06], [YKG24], [Mel19].

Das *Nieten* ist die dominante Füge-technologie in der Flugzeug-Strukturmontage. Die erreichte Prozessstabilität und -wiederholbarkeit, die Scherfestigkeit, die Ermüdungsbeständigkeit, die hohe Prozessvariabilität in Bezug auf Werkstoffart und -dicke sowie die einfache Inspektion und Wartung übertreffen dieselben Eigenschaften bereits beschriebener Fügemethoden. Demgegenüber stehen die aufwendige Prozessführung, das zusätzliche Gewicht, der notwendige Korrosionsschutz sowie die schlechtere Verträglichkeit des Nietmaterials mit CFK aufgrund unterschiedlicher thermischer Eigenschaften als Nachteile. Als Merkmal jeglicher Nietarten in der Strukturmontage kann die Notwendigkeit des wiederholten präzisen Ausrichtens und Fixierens der Bauteile genannt werden, wonach das Einbringen der Nietbohrungen erfolgt, siehe Abbildung 3.3. Dabei müssen enge Toleranzfelder eingehalten und die Umgebung nach dem Bohren, Aufbohren, Reiben und Senken der Löcher von Schmiermitteln und Spänen befreit werden [Zha+20], [Mel19], [Ray06]. Die dafür notwendige Abfolge ist in [Sto07] und [Goe20] skizziert.

Grundsätzliche Ausführungsvarianten der Niettechnologie in Form des Voll- und Blindnietens sind in der Abbildung 3.3 dargestellt. Beim Vollnieten ist die Fügestelle beidseitig zugänglich, wobei während des Nietvorgangs die Kraftaufbringung in Form von z. B. eines Niethammers und eines Gegenkörpers geschieht. Beim Setzen eines Blindnietens ist nur eine Bohrungsseite zugänglich. Dabei wird der Blindniet in die Bohrung eingeschoben und durch gleichzeitiges

Rausziehen und Gegenhalten erfolgt die plastische Verformung des Nietmaterials zur Herstellung eines Formschlusses. Im speziellen Kontext des Flugzeugbaus sind zudem der Passniet und der Schraubpassniet zu erwähnen. Diese Nietarten enthalten z. B. Gewindeelemente und müssen mithilfe eines Schließrings teilweise durch das Aufbringen eines Anzugsmoments gesetzt werden. Je nach Nietverfahren muss eine Spielpassung (bei Voll- und Blindnieten) oder eine Presspassung (bei Passnieten und Schraubpassnieten) hergestellt werden. Diese Umstände stellen spezifische Qualitätsanforderungen an die Nietbohrungen. Zudem können Nieten anhand ihrer Form unterschieden werden. Der Rundkopf-Niet steht an der Bauteiloberfläche ab. Zur Reduktion des Luftwiderstands erfolgt die Verwendung von Senknieten an der Flugzeug-Außenhaut, siehe Abbildung 3.3 [Ray06], [Mei07].




Abbildung 3.3: Nietprozess (Vollnieten und Blindnieten) und -arten (Rundkopfniet und Senkkopfniet) nach [Ray06]

Für die dominanten Füge-technologien Nieten und Verschrauben ist eine hohe Anzahl an Bohrungen in einem Flugzeugrumpf notwendig. Bei einem Langstreckenflugzeug sind dies mindestens 230.000 Bohrungen [Air15]. Daher hat die Optimierung des Bohrprozesses einen hohen Einfluss auf die Kosten, Prozesszeiten und Qualität.

3.1.3 Bohrtechnologien

In diesem Abschnitt wird auf die Prozesseigenschaften und Herausforderungen der Bohrtechnologien in der Luftfahrzeug-Strukturmontage eingegangen. Diese lassen sich gemäß Tabelle 3.1 in 3 Arten einteilen: manuelles, semi-automatisches und automatisches Bohren.

Tabelle 3.1: Abgrenzung der Bohrprozesse in der Luftfahrzeug-Strukturmontage nach [SGR23]

Bohrprozess	Vorschubbewegung	Positionierung
manuell	Bediener	Bediener / Positionier-Hilfsmittel
semi-automatisch	automatisch	Bediener / Schablone
automatisch	automatisch	automatisch

Mithilfe neuartiger Automatisierungs-Lösungen konnte in den letzten Jahren der Anteil manuell gefertigter Bohrungen gesenkt werden [SGR23], siehe Abbildung 3.4. Eine Automatisierung kann nur bei guter Zugänglichkeit ohne Weiteres umgesetzt werden, was im Umkehrschluss

bedeutet, dass auch in der Zukunft aufgrund unterschiedlicher Prozessszenarien weiterhin von einer Koexistenz der 3 genannten Verfahrensgruppen auszugehen ist [Hin+19a], [HMR19].




Abbildung 3.4: Bohrprozesse in der Luftfahrzeug-Strukturmontage nach [SGR23]

3.1.3.1 Manuelle Bohrprozesse

Bei manuellen Bohrprozessen finden kompakte, händisch geführte Bohrmaschinen Anwendung, siehe Abbildung 3.5. Diese werden manuell platziert, z. B. auch mithilfe von Bohrbuchsen oder -böcken, die mit integrierten Vorschubbremsen ausgestattet sein können [Hin+04]. Der Antrieb der Maschinen erfolgte bis vor wenigen Jahren überwiegend pneumatisch, da diese Antriebsart eine hohe Leistung und Verlässlichkeit bei niedriger Masse und Abmessungen bietet. Die Nachteile dabei sind die notwendige Energiezufuhr über einen Versorgungsschlauch und der niedrige Wirkungsgrad. Die Einstellung der Prozessparameter und die Prozessüberwachung sind dabei mit Herausforderungen verbunden. Daher ist die resultierende Bohrungsqualität und die Entscheidung zum Werkzeugtausch von der Bedienererfahrung abhängig [Hin+19a], [Atl23].



Abbildung 3.5: Manuelle Bohrmaschinen in der Luftfahrzeug-Strukturmontage mit Angabe zum Hersteller nach [Des25a], [Des25b] [Atl25a], [Atl25b], [HMR19]

Mit der Elektronik-Entwicklung der letzten Jahre werden zunehmend elektrisch angetriebene Handbohrmaschinen im Flugzeugbau eingesetzt, um die Nachteile der pneumatischen Geräte hinsichtlich Handling, Stabilität der Prozessparameter und Prozessüberwachung zu umgehen. Damit entstehen Potentiale hinsichtlich einer werkerunabhängigen Prozessführung [Hin+19a], [Hin+19b], [Des25c]. Als Nachteile sind die Prozessunterbrechung aufgrund des notwendigen Akku-Nachladens sowie die Entzündungsgefahr bei reaktiven Umgebungsgasen zu nennen [Atl23]. Das Nutzen der Prozessdaten elektrischer manueller Handbohrmaschinen ist aktueller Forschungsgegenstand. In [HMR19] wird der Prototyp einer smarten Handbohrmaschine vorgestellt, deren Sensordaten in Form von Spindelmotorstrom und Gyroskop-Messwerten

in einem Web-Interface ausgewertet werden können. Um den Nachteil der fehlenden Vorschubinformation zu überwinden, stellen die Autoren in [FD23] die zusätzliche Integration einer Wägezelle vor, mit deren Hilfe das Erreichen eines kritischen Vorschubkraftwerts erfasst wird. In [FS24] und [FJJ24] werden die Potentiale weiterer Sensorarten und ML-basierter Datenverarbeitung zum Werkzeug-Verschleißmonitoring untersucht.

3.1.3.2 Automatische Bohrprozesse

Bei automatischen Bohrprozessen werden die Positionierung und der Vorschub werkerunabhängig, basierend auf einer CNC-Steuerung, vorgenommen. Dies ist aufgrund von Zugänglichkeits-Restriktionen meist nur in Form von *Industrierobotern* oder eines *Flex Track* Systems umsetzbar, siehe Abbildung 3.6.

Ein Flex Track System lässt sich als eine Bohrspindel auf einer 4-Achs-Kinematik beschreiben, bei dem das System eine entsprechend der Rumpfschalen-Krümmung flexible Linearachse entlang der gesamten Montagelänge abfährt. Die Installation der Vorrichtung kann mithilfe von Vakuumspannern erfolgen und ist somit an die Form der Rumpfschalen anpassbar. Die Vorteile liegen in einem wiederholbaren Bohrprozess, einer signifikanten Reduktion manueller Arbeit und der möglichen Integration weiterer Systeme wie z. B. machine vision. Als Nachteil sind die variierende Systemsteifigkeit in Abhängigkeit der Bohrungsposition und die daraus resultierenden Qualitätsabweichungen zu nennen. Zudem muss die Positionierungs-Güte des Gesamtsystems sichergestellt werden [Li+23b], [AIT25], [Tho+05].



Flex Track



robotisches Bohren

Abbildung 3.6: Automatisches Bohren in der Luftfahrzeug-Strukturmontage nach [AIT25], [Kip19]

Mithilfe von Industrierobotern wird das Einbringen von Nietbohrungen in Rumpfschalen an Orten mit guter Zugänglichkeit übernommen. Zudem können auch weitere Tätigkeiten wie Entgraten, Nieten, Versiegeln oder Beschichten ausgeführt werden. Als Nachteile sind die fehlende Systemsteifigkeit und damit eine Einschränkung der bearbeitbaren Werkstoffe, hohe Anschaffungskosten und teilweise schlechtere Genauigkeit im Vergleich zu den semi-automatischen Systemen zu nennen [Eis19], [Kip19], [Cor19]. In [Mar+16] wird ein System zur Anwendung von Standard-Industrierobotern mit integriertem Kraftsensor zwecks Kostensenkung vorgeschlagen. Zur Steigerung der Bohrungs-Qualität wird in [Zhe+16] ein Endeffektor vorgestellt, welcher sich mithilfe von 3 Laser-Distanzsensoren vor der Bohroperation normal zur Bohrfläche ausrichtet. In [Per+22] wird ein Posen-Überwachungssystem zur Optimierung der Bohrungsqualität von Aluminium eingerichtet.

3.1.3.3 Semi-automatische Bohrprozesse

Das semi-automatische Bohren mit Bohrvorschubeinheiten (BVE, en. *Advanced Drilling Unit (ADU)*) erfordert manuelles Positionieren der Maschinen in Bohrschablonen, die an den zu bohrenden Strukturen befestigt sind, siehe Abbildung 3.7. Das Fixieren der Maschinen innerhalb der Schablone erfolgt beispielsweise mithilfe von Spreizhülsen. Nach dem Auslösen des Bohrvorgangs durch den Bediener läuft die Prozessparameter-Einstellung inklusive des Vorschubs automatisch ab. Bisher werden die Maschinen überwiegend pneumatisch angetrieben, wobei sich bei dieser Antriebsart ähnliche Vor- und Nachteile wie bei den beschriebenen manuellen Bohrprozessen mit pneumatischem Antrieb ergeben. Die aktuell fortschreitende Einführung elektrischer semi-automatischer BVEs ermöglicht ein lagenabhängiges Bearbeiten von Multi-Material-Stacks sowie eine vielfältige Sensorintegration und verspricht eine präzisere Steuerung und Überwachung der Bohrprozesse. Gegenüber dem manuellen und automatischen Bohren wird beim semi-automatischen Bohren die gleiche Bohrungsqualität beim geringeren Aufwand erreicht [Hin+19a], [HMR19], [Koe+20], [Hin+22], [Fle+23].



Fixierung in Bohrschablonen



semi-automatische Bohrvorschub-Einheiten

Abbildung 3.7: Semi-automatisches Bohren in der Luftfahrzeug-Strukturmontage nach [Hin+22], [Des25d], [Lue25]

3.1.3.4 Vibrationsunterstütztes Bohren

Zur Erzeugung leicht abtransportierbarer metallischer Wendelspäne hat sich der Einsatz des *vibrationsunterstützten Bohrens* (en. *vibration assisted drilling (VAD)* oder *peck drilling*) in den letzten Jahren immer mehr durchgesetzt. Dabei wird die lineare Vorschubbewegung des Bohrers mit einer Oszillation überlagert, siehe Abbildung 3.8. Die Schwingungsbewegung wird durch die Peck-Feed-Amplitude A_{PF} und die Peck-Feed-Frequenz f_{PF} beschrieben. Der dadurch entstehende kurzzeitige Austritt der Schneiden aus dem Material führt zur Schnittunterbrechung und damit zu einem kontrollierten Spanbruch, was in der Erzeugung leicht abtransportierbarer Wendelspäne und der Vermeidung von Spänestau resultiert. Folglich wird der Reibungskontakt zwischen den Spänen und der Bohrungswand reduziert und der Schmiermitteleinsatz zum Spänetransport kann gesenkt werden [Jal+13], [Hin+19a], [Hin21a, S. 258].

Die Erzeugung der oszillierenden Schneidenbewegung lässt sich mit unterschiedlichen Systemen erreichen, die wiederum charakteristische Eigenschaften aufweisen, siehe Abbildung A.3 im Anhang A.1.2. Niederfrequente Systeme erzeugen höhere Amplituden ($f_{PF} \leq 100$ Hz; $A_{PF} \geq 100 \mu\text{m}$) basierend auf mechanischer oder pneumatischer Wirkungsweise. Hierbei kann von einem Spanbruch ausgegangen werden. Hochfrequentes vibrationsunterstütztes




Abbildung 3.8: Kinematik des vibrationsunterstützten Bohrens nach [Hin13] ($S1/2 = \text{Schneide } 1/2$; $A_{PF} = \text{Peck-Feed-Amplitude}$; $\Delta\varphi = \text{Phasenverschiebung}$; $f_{PF} = \text{Peck-Feed-Frequenz}$; $f_z = \text{Zahnvorschub pro Werkzeugumdrehung}$; $h_{max} = \text{maximale Spannungsstärke}$)

Bohren ($10^3 \text{ Hz} \leq f_{PF} \leq 10^5 \text{ Hz}$; $2 \mu\text{m} \leq A_{PF} \leq 15 \mu\text{m}$) ist mit Piezo-Aktuatoren möglich, hier ist bei duktilen Materialien der Spanbruch aufgrund der niedrigen Peck-Feed-Amplitude A_{PF} jedoch nicht garantiert. Der zwischen den beschriebenen Prozessarten liegende Frequenzbereich wird durch elektro-mechanische Aktuatoren abgedeckt. Semi-automatische Bohrmaschinen können den niederfrequenten Systemen zugeordnet werden. Nachteilig kann sich beim vibrationsunterstützten Bohren die Systemanregung durch eine ungünstige Wahl der Schwingungsparameter auswirken, was zu Prozessinstabilitäten und erhöhten Bearbeitungskräften führen kann [Sad+13].

Beim Bohren von CFK/Ti6Al4V Schichtverbunden können lt. [Xu+19] mit dem niederfrequenten vibrationsunterstützten Bohren Verbesserungen bei den Qualitätskenngrößen Rauheit der Bohrungswand, Delaminationsfaktor am Bohrungsaustritt von CFK-Werkstoffen, Austrittsgrat, Durchmesser und Zylindrizität der Bohrung gegenüber dem konventionellen Bohren erreicht werden. Nach [PB14] wird beim Einsatz des vibrationsunterstützten Bohrens eine Verdreifachung der Werkzeug-Standzeit beim Bohren von CFK/Ti6Al4V Schichtverbunden erreicht, da die thermische Werkzeugbelastung signifikant reduziert wird. Die mechanische Belastung steigt dazu im Gegensatz jedoch an. Um diese Herausforderung zu beherrschen, wird in [Pau+17] die Variation der Werkzeugschwingung durch Überlappung unterschiedlicher Sinusformen untersucht, was zu einer Senkung der maximalen Schnittkräfte führt. Die dargestellten Ergebnisse werden in [Pec18] zusammen mit der Aussage, dass vibrationsunterstütztes Bohren zu besseren Qualitätseigenschaften der Bohrungen führt, bestätigt. Zudem stellt der Autor in [Pec18] für das vibrationsunterstützte Bohren ein Modell zur Beschreibung der Spanabfuhr-Qualität, der Prozesskräfte und der Spanungsgrößen vor. In [Pau+20], [Pau21] wird der Zusammenhang zwischen den Eigenschaften metallischer Werkstoffe und der Spanabfuhr-Qualität hergestellt, welcher zum Einstellen optimaler Prozessparameter genutzt werden kann. Für CFK werden in [Sad+13] Prozessparametersätze für das niederfrequente Vibrationsbohren entwickelt, mit denen eine deutliche Reduktion der thermischen und mechanischen Werkzeugbelastung sowie Qualitätsverbesserungen gegenüber dem konventionellem Bohren erreicht werden.

In [Sch+21], [Sch+24a] erfolgt die Aufstellung und Validierung eines FEM-Modells, mit dem die Prozesskräfte beim vibrationsunterstützten Bohren abgeschätzt und das Potential zur Beschreibung der Spanbildung untersucht wird. Die Untersuchung des Verhaltens der Minimalmengen-Schmierung (MMS) beim VAD-Bohren ergibt lt. [Bus+23] eine ungünstige Aufteilung des Schmierstoffs in den Kühlkanälen des Werkzeugs, da die Schmierpartikel sich größtenteils an dem Kühlkanalumfang absetzen. Mit den Ergebnissen aus [Sch+24b] erfolgt eine Beschreibung der Schmiermittel-Versorgung in Abhängigkeit der Parameter wie Werkzeuggeometrie und Versorgungsdruck mithilfe von schattengrafischer Darstellung. Diese Visualisierungs-Form macht Unregelmäßigkeiten in strömenden Fluiden, z. B. in Form

von Dichteschwankungen, basierend auf der entstehenden Lichtstrahl-Brechung, kenntlich [Men81].

3.1.3.5 Weitere luftfahrtbezogene Bohrprozess-Entwicklung

Ein stetige Weiterentwicklung der Bohrprozesse in der Luftfahrzeug-Strukturmontage wird aufgrund des Einsatzes neuartiger Werkstoffe, Schneidstoffe, Schneidstoffbeschichtungen, der Automatisierung, Digitalisierung und Vernetzung der Maschinen sowie der Weiterentwicklung von Simulationsmethoden vorangetrieben.

In [Sto07] werden die Prozessgrößen, die erreichbaren Qualitätsmerkmale und das Verschleißverhalten beim Bearbeiten von Glare als Einzellage sowie als Schichtverbund mit Titan, Aluminium und CFK mithilfe von Vollhartmetall-Bohrern untersucht. Die Zerspanung und im Speziellen die Bohrbearbeitung moderner CFK-Werkstoffe wird in [Sch14], [See21], [Hin21a], [Sau+22] und [Meh23] grundlagenorientiert untersucht. In [Sch14], [See21] wird der räumliche Trennmechanismus beim Bohrvorgang analysiert und die Abhängigkeit der Prozesskräfte vom Fasertrennwinkel beschrieben. Der Fasertrennwinkel ist zusammen mit dem Schneidkantenradius entscheidend für die Bohrungsqualität. In [Hin21a, S. 194] wird der Bohrprozess innerhalb der CFK-Zerspanung grundlagenorientiert betrachtet und im Hinblick auf die Industrieanforderungen erklärt. Die Analyse des Temperaturfeldes bei der CFK-Zerspanung resultierend aus den richtungsabhängigen Materialeigenschaften wird in [Meh23] aufgestellt. Dabei erfolgt eine analytische und simulative Modellbildung, die experimentell validiert wird. In [Sau+22] wird die Prozessgestaltung zur Bohrungsherstellung in flächigen CFK-Werkstoffen untersucht. In [Hen15] wird eine einzelne allumfassende Kennzahl zur Erfassung des Verschleißzustandes beim Bohren von CFK vorgestellt. Ein Werkzeug-Verschleißmodell für das Bohren von CFK oder auch potentiell von metallischen Werkstoffen wird in [See21] vorgestellt, welches als Input-Parameter die initiale Werkzeuggeometrie, die elastischen Rückfederungshöhen und 4 Fitting-Parameter benötigt. Des Weiteren wird in [See21] als Alternative zum vibrationsunterstützten Bohren die „sekundäre Materialtrennung“ zur Erzeugung leicht abtransportierbarer kleiner Späne untersucht. Dies geschieht durch das Erwirken eines „radialen Trennrisses“ während der kontrollierten Umleitung des Spans in die Spannut.

Der Einfluss der Werkstückeinspannung und -nachgiebigkeit auf die Bohrungsqualität von CFK wird in [Klo17] und [Lis21] analysiert. Die Schädigung nimmt bei wachsendem Abstand zur Einspannung zu, und es wird eine dynamische Anpassung des Vorschubs in Abhängigkeit des Biegeverhaltens des Werkstücks und der Bohrungstiefe empfohlen [Klo17]. In [Lis21] wird die Werkstückverformung in Abhängigkeit zur Nachgiebigkeit untersucht, um eine Aussage zum resultierenden Spannungsquerschnitt und zur Austrittsdelamination zu formulieren. Ein dazugehöriges exemplarisches Untersuchungsergebnis ist in der Abbildung 3.9 zu sehen. Die Resultate münden dabei in der Aufstellung von Simulationsmodellen, um Maßabweichungen, Prozesskraftverläufe und Schädigungen vorherzusagen.

Mit fortschreitender Digitalisierung entstehen große Potentiale in der Bohrprozessoptimierung in Form von Prozesssteuerung und -überwachung. Eins der Basiselemente dafür ist der Aufbau von Wissensdatenbanken, um auch neue Prozesse zu entwickeln. In [Dos15] wird dafür eine Methodik zur Anwendung bei Bohrprozessen in CFK vorgestellt. Die Autoren von [Hin+19a] stellen ein vernetztes Fertigungssystem für das Einbringen von Nietbohrungen vor, welches eine Bohrungsposition-individuelle Ansteuerung der Fertigungsmaschinen (Positioniereinheit, Bohrmaschinen, Bohrungsvermessung-Vorrichtung) ermöglicht und eine ganzheitliche Prozessüberwachung sicherstellt. Die Systemarchitektur ist in einer industriellen

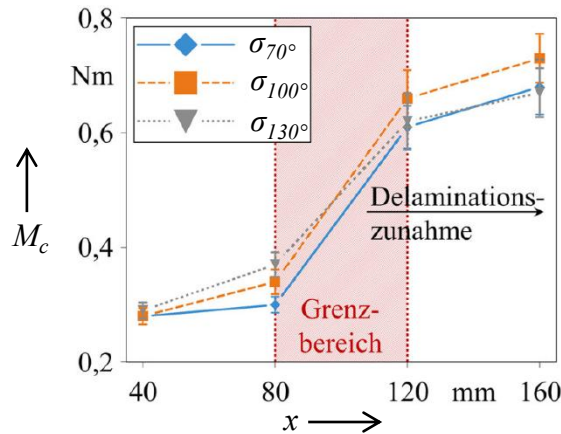


Abbildung 3.9: Schnittmoment und Decklagendelamination in Abhängigkeit der Einspannung nach [Lis21] (M_c = Schnittmoment; x = Abstand zur Einspannung; σ = Spitzenwinkel Werkzeug)

Versuchsumgebung im Rahmen des Forschungsprojekts *SmartADU2020* erprobt und patentiert, siehe Abbildung 3.10 [Hin+19a], [HMR19], [Lue+19]. Ähnliche Systeme werden aktuell eingeführt und durch weitere Operationen wie Nieten und Schrauben erweitert [SK23]. Zur Senkung des CO₂-Abdrucks der Flugzeug-Fertigung werden in [Fle+24] Upcycling-Methoden für Vollhartmetall-Werkzeuge untersucht. Damit lassen sich die CO₂-Emissionen um etwa die Hälfte durch folgende Maßnahmen reduzieren: Schleifen verschlissener Werkzeuge auf kleinere Durchmesser, Beschichten von initial unbeschichteten Werkzeugen zur Kompensation der Maßabweichung und Wiederherstellung abgetragener Beschichtungen.

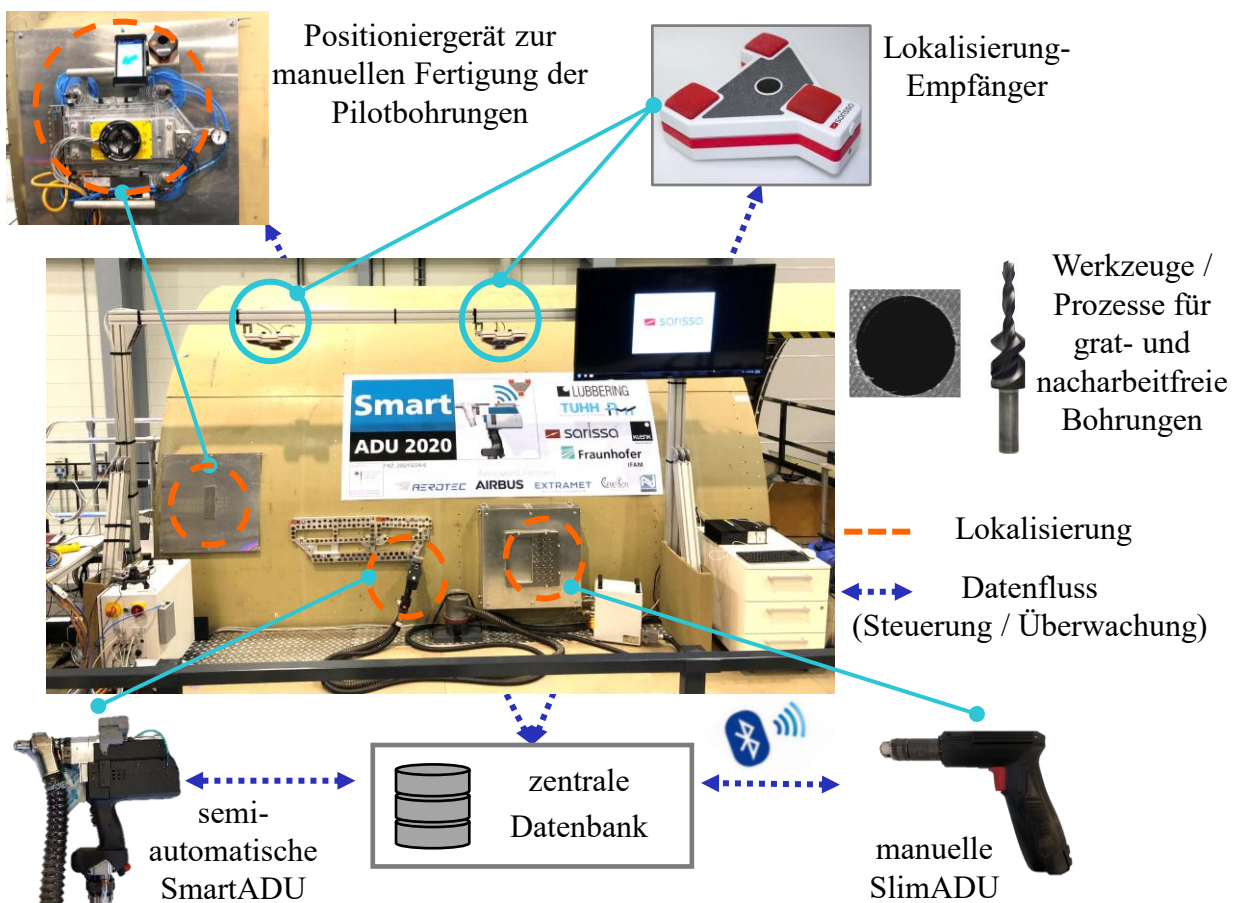


Abbildung 3.10: Vernetzte Fertigung für Nietbohrungen nach [Hin+19a], [HMR19], [Lue+19]

3.2 Maschinelles Lernen in der Produktion

Der Einsatz des maschinellen Lernens in der Überwachung von Produktionsprozessen wurde in der Forschung und Industrie als Zukunftstechnologie erkannt und ist Gegenstand aktueller Untersuchungen [Gao+24], [Fon+21]. Unabhängig von der spezifischen Anwendung erweist sich der Aufbau einer standardisierten Datenverarbeitungs-Infrastruktur als essentiell, um ML-Methoden zu etablieren. Ein Konzept für dieses Vorgehen wird in z. B. [Hin+23] vorgeschlagen. In diesem Abschnitt erfolgt die systematische Darstellung der exemplarischen Ergebnisse aus der Forschungslandschaft in tabellarischer Form, um den Fokus auf die Quintessenzen zu legen. Die Recherche ist in Bohrprozesse und sonstige Luftfahrt-relevante Produktionsprozesse aufgeteilt. Die angegebenen Evaluations-Kennzahlen gelten für die jeweils besten Ergebnisse in den referenzierten Quellen und die verwendeten ML-Algorithmen werden weitestgehend in der Notation dieser Arbeit referenziert.

3.2.1 Industrie 4.0 im Übergang zur Industrie 5.0

Die im 21. Jahrhundert ablaufende digitale Transformation der Industrie wird als die 4. industrielle Revolution bezeichnet (= Industrie 4.0 / I4.0). Diese umfasst die digitale Vernetzung an der Produktion beteiligter intelligenter Maschinen inklusive deren Sensorik im Internet der Dinge. Dabei wird die gesamte Fertigung inklusive deren Peripheriekomponenten und -prozessen und externer Partner mit einbezogen, um die Produktion, Beschaffung, Logistik, Qualitätskontrolle und Anlagenwartung zu koppeln, weiter zu automatisieren und aufeinander abzustimmen [Boy+18], [XXL18], [Fol+24].

Zur Verarbeitung der unterschiedlichsten Sensordaten sowie für die Gerätekommunikation ist die Implementierung robust arbeitender, sicherer und universeller Schnittstellen notwendig. Neben den Sensordaten sind die Metadaten an der Produktion beteiligter Glieder essentiell. Die Verarbeitung großer Datenmengen (Big Data) kann zentral in einer Cloud-Lösung oder lokal (Edge Computing) erfolgen. Dazu wird im industriellen Kontext das Konzept *CRISP-ML(Q)* (*Cross-Industry Standard Process for the Development of Machine Learning Applications with Quality Assurance Methodology*) eingesetzt, falls Techniken des maschinellen Lernens verwendet werden (siehe dazugehörige Visualisierung in der Abbildung A.4 im Anhang A.1.3). Mit der Verarbeitung der Zustandsinformation können beispielsweise folgende Szenarien umgesetzt werden: Anomaliedetektion im Fertigungsprozess, Triggern des nächsten Fertigungsschritts und damit Steigerung der Prozesseffizienz, Einleitung einer Maschinenwartung, Training und Einsatz von machine learning Modellen, Flexibilisierung der Produktion oder Anforderung von Rohmaterial.

Die vernetzten Teilsysteme müssen als cyber-physische Systeme implementiert sein, d. h. innerhalb dieser ist die Verbindung der softwaretechnischen, elektronischen und mechanischen Komponenten vorhanden. I4.0-Systeme grenzen sich von den klassischen Automatisierungslösungen durch das Vorhandensein einer Intelligenz ab, welche einen eigenständigen Entscheidungsprozess ausführen kann [JSB16]. In diesem Zusammenhang muss der Begriff *Digitaler Zwilling*, welcher als eine digitale Repräsentation eines physischen Guts verstanden werden kann, als ein signifikantes Tool erwähnt werden [SD19a]. Als Herausforderungen des Industrie 4.0 - Konzepts sind der Umgang mit heterogenen Datenquellen, hohe Datenvolumina sowie das Sicherstellen der Datensicherheit zu nennen [LWH16], [XXL18].

Im Jahre 2021 veröffentlichte die Europäische Union die Grundsätze der *Industrie 5.0*, die

eher als eine Erweiterung der Industrie 4.0 anzusehen ist. Die darin verfassten wesentlichen Ziele sind: Eine ökologisch nachhaltige, menschenorientierte (Fach- und Führungskräfte, Konsument, Investor) und anpassungsfähige Industrie. Demnach hat die Produktion dem Wohlbefinden der Gesellschaft und der Ökologie zu dienen [BDP21].

3.2.2 Einsatz in Produktionsprozessen

Im weiteren Verlauf werden aktuelle Ergebnisse der ML-Anwendung bei Produktionsverfahren, mit Ausnahme des Bohrens, vorgestellt.

3.2.2.1 Anomaliedetektion

In der Tabelle 3.2 sind beispielhafte Ergebnisse für ML-basierte Anomalieerkennung dargestellt. Oftmals kommen künstliche neuronale Netze als Klassifikatoren (ANN_{MK}) mit hoher Vorhersagegüte zum Einsatz. In einzelnen Szenarien sinkt die Qualität der Anomalie-Identifikation jedoch deutlich ab, siehe dazu die Fräsprozess-Beispielanwendung in der Abbildung 3.11. Darin wird die Güte der Gutteile-Identifikation im Fräsprozess mithilfe der Evaluationskennzahl Positive Predictive Value PPV_E , welche sich mehrheitlich im Bereich $PPV_E \geq 0,9$ (äußere Segmente des Netzdiagramms) befindet und damit für eine hohe Erkennungsquote steht, bewertet. Bei einer relativen Betrachtung einiger Geometrielemente, ohne auf die spezifischen Eigenschaften dieser Komponenten einzugehen, ist die Vorhersagegüte in einzelnen Fällen dabei weniger genau. Als Komplement der Gutteil-Erkennung können Ausschussteile und damit Anomalien identifiziert werden [Fer23].

Tabelle 3.2: ML-basierte Anomaliedetektion in Produktionsprozessen (ANN_{MK} = künstliches neuronales Netz zur Klassifikation, L_E = Fehlerquote, TPR_E = True Positive Rate, FSc_E = F-Score, PPV_E = Positive Predictive Value, $BAcc_E$ = Balanced Accuracy)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[Bau20]	Klassifikation von Gutteilen mithilfe von Spindelmotorstrom und -leistung beim Drehen	ANN_{MK}	$L_E = 0$
[Hoc20]	Erkennung von Fertigungsfehlern mithilfe thermischer Prozessbilder beim AFP-Prozess	ANN_{MK}	$TPR_E \geq 0,95$
[Chu23]	bildbasierte Erkennung von Anomalien bei additiver Fertigung	ANN_{MK}	$FSc_E \approx 0,9$
[Fer23]	Anomalieerkennung beim Fräsen mithilfe von NC-Signaldaten und Werkstück-Metadaten	diverse (Abb. 3.11)	$PPV_E \geq 0,93$
[KSS22]	bildbasierte Anomaliedetektion von Oberflächen bei Flugzeugen	ANN_{MK}	$BAcc_E \approx 0,75$ $TPR_E = 1$

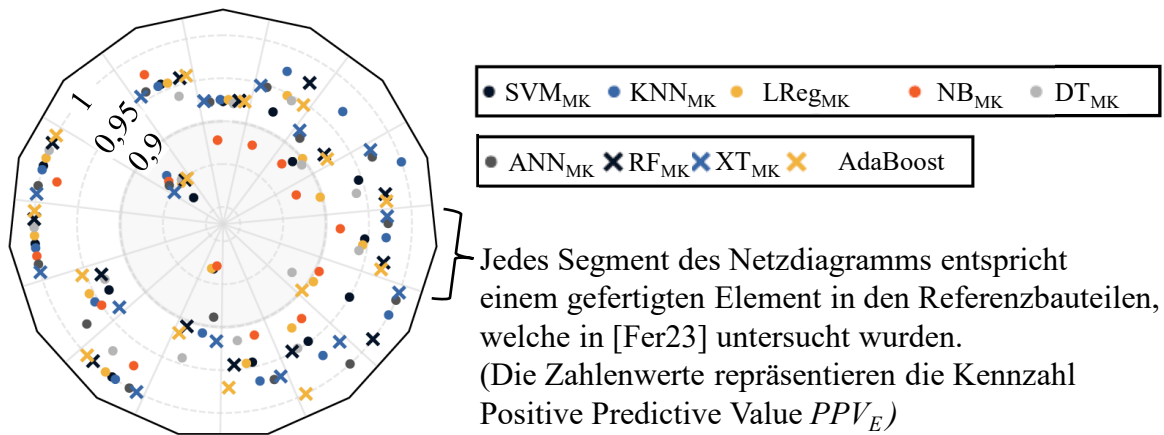


Abbildung 3.11: Beispiel für die Güte der Anomaliendetektion im Fräsprozess [Fer23] (tiefgestelltes „MK“ = Klassifikations-Modell, SVM = Support Vector Machine, KNN = K-Nearest Neighbour, LReg = Logistische Regression, NB = Naive-Bayes, DT = Entscheidungsbaum, ANN = künstliches neuronales Netz, RF = Random Forest, XT = Extra Trees, AdaBoost = Ada Boost Klassifizierer)

3.2.2.2 Prozesszustand

Anhand der Tabelle 3.3 wird sichtbar, dass die Vorhersageergebnisse im hohen Maße von der betrachteten Domäne abhängig sein können. So befindet sich die Spannweite der maximalen klassenbezogenen Fehlerquote bei der Werkstoffbestimmung während des Außenlängsdrehens mithilfe von Kraft- und Beschleunigungssensoren zwischen $L_{E,K} = 0\%$ und $L_{E,K} = 97\%$ [DBW19]. Bei der Bestimmung geometrischer Eigenschaften (wie z. B. Dicke der Erzeugnisse) werden unterschiedliche mittlere absolute Fehler MAE_E erreicht, welche sich vom Mikrometer bis zum Zentimeterbereich bewegen [Kub24], [EW21]. Dies zeigt, dass bei der Betrachtung dimensionsbehafteter Evaluationskennzahlen die Größenordnungen der Wertebereiche der Zielgrößen mit beachtet werden müssen.

3.2.2.3 Werkstückqualität

In der Literatur ist die Dominanz der künstlichen neuronalen Netze (ANN_{MK}) bei der Werkstückqualität-Überwachung deutlich, da laut Tabelle 3.4 diese ML-Algorithmengruppe mehrheitlich die besten Vorhersagen bietet. So können laut [Wag+22], [Tch+23] und [CBS24] Defekte bei geschweißten, tiefgezogenen und mittels Spritzguss hergestellten Produkten mithilfe einer optischen Erfassung fast fehlerlos klassifiziert werden. Insgesamt deutet sich eine gute Eignung optischer Überwachungs-Systeme bei der Werkstückqualität an.

3.2.2.4 Werkzeugverschleiß

Bei der Werkzeugverschleiß-Überwachung eignen sich vor allem Spindelmotorströme und Beschleunigungsdaten zur ML-Verarbeitung, siehe Tabelle 3.5. Zudem konnten Methoden zur Bildverarbeitung auf Sensordaten-Zeitverläufe erfolgreich angewendet werden, siehe Abbildung 3.12 [Jun+23]. Die Grundidee dabei ist, Zeitreihendaten in eine zweidimensionale grafische Repräsentation überzuführen und aus dieser relevante Features zum Training von ML-Vorhersagemodellen zu extrahieren. Zur weiterführenden Erklärung der Methodik sei als Vorgriff auf den Abschnitt 6.2.3.5 hingewiesen.

Tabelle 3.3: ML-basierte Prozesszustand-Überwachung in Produktionsprozessen (tiefgestelltes „MK“ = Klassifikations-Modell, tiefgestelltes „MR“ = Regressions-Modell, PCA = Principal Component Analysis, ANN = künstliches neuronales Netz, KNN = K-Nearest Neighbour, SVM = Support Vector Machine, DT = Entscheidungsbaum, RF = Random Forest, L_E = Fehlerquote, TPR_E = True Positive Rate, MAE_E = mittlerer absoluter Fehler)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[Man+18]	Klassifikation von Spaltmaßen in der Luftfahrzeug-Montage mit einer um 97 % reduzierten Lasersensor-Anzahl	PCA_F	$L_E = 0,13$
[DBW19]	Klassifikation von Werkstoffen beim Außenlängsdrehen mithilfe von Kraft- und Beschleunigungssensoren	ANN_{MK} KNN_{MK} SVM_{MK}	$L_{E,K} = 0 \dots 0,97$ (werkstoffabh.)
[Kub24]	Dickenbestimmung von Stanz-erzeugnissen mithilfe von Kraftsensoren	RF_{MR}	$MAE_E = 5,67 \mu m$
[EW21]	Ermittlung der Geometrie gefräster Turbinenschaufeln basierend auf NC-Daten und Spindelmotorstrom	RF_{MR}	$MAE_E = 0,02 \dots 0,13 \text{ mm}$
[Miz+22]	visuelle Spanerkennung in der Werkstückaufnahme mit mobilem Roboter	ANN_{MK}	$TPR_E \approx 0,9$

Tabelle 3.4: ML-basierte Werkstückqualität-Vorhersage in Produktionsprozessen (tiefgestelltes „MK“ = Klassifikations-Modell, tiefgestelltes „MR“ = Regressions-Modell, ANN = künstliches neuronales Netz, BT = Boosted Tree, L_E = Fehlerquote, TPR_E = True Positive Rate, PPV_E = Positive Predictive Value, MAE_E = mittlerer absoluter Fehler)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[Ger22]	Oberflächenrauheit-Vorhersage beim LPBF-Druck mit Hyperspektralkamera	ANN_{MR}	$MAE_E = 14,3 \mu m$
[VV22]	Identifikation von Schlechtteilen im DED-Prozess mit Kamera-, Pyrometer- und NC-Größen	BT_{MK}	$PPV_E = 0,74$
[Wag+22]	Klassifikation von Defekten beim Laserstrahlschweißen mit optischen und akustischen Sensoren	ANN_{MK}	$L_E = 0,04$
[Tch+23]	Riss- und Beulenerkennung bei Tiefzieherzeugnissen mit Bildaufnahmen aus unterschiedlichen Winkeln	ANN_{MK}	$L_E = 0,03$
[CBS24]	optische Erkennung von Oberflächenschäden beim Aluminium-Druckguss	ANN_{MK}	$TPR_E = 0,98$

Tabelle 3.5: ML-basierte Werkzeugverschleiß-Vorhersage in Produktionsprozessen (V_{VB} = Verschleißmarkenbreite, tiefgestelltes „MK“ = Klassifikations-Modell, tiefgestelltes „MR“ = Regressions-Modell, ANN = künstliches neuronales Netz, SVM = Support Vector Machine, RF = Random Forest, KNN = K-Nearest Neighbour, GPM = Gauss-Prozess-Modell, FSc_E = F-Score, L_E = Fehlerquote, $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers, R_E^2 = Bestimmtheitsmaß)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[Jun+23]	Werkzeugzustand-Klassifikation beim Fräsen durch das Überführen der Prozessdaten in die Bilddomäne	ANN_{MK}	$FSc \approx 0,9$
[GEM21]	Klassifikation von V_{VB} beim Sägen der 42CrMo4-Legierung unter Nutzung von Motorstrom-, Positions- und Beschleunigungssignalen	ANN_{MK}	$L_E \approx 0$
[Fer+21b]	Klassifikation von Werkzeugabweichungen beim Fräsen von Ti6Al4V mithilfe von Motorstrom-, Positions- und G-Sensor-Signalen	KNN_{MK} , SVM_{MK} , RF_{MK}	$L_E \approx 0,05...0,61$
[HMA24]	Vorhersage von V_{VB} beim Fräsen von Ti6Al4V unter Nutzung von Motorstrom- und Beschleunigungs-Signalen mit automatischer Feature-Auswahl	GPM_{MR}	$RMSE_E \approx 0,1 \mu m$
[AZB24]	Vorhersage von V_{VB} bei Open-Source-Fräsdaten mithilfe von Motorstrom-, Körperschall- und G-Sensor-Signalen	ANN_{MR}	$R_E^2 \approx 1$




Abbildung 3.12: Transformation von Zeitreihen-Daten in die Bilddomäne bei ML-basierter Werkzeugverschleiß-Überwachung im Fräsprozess [Jun+23] ((A)/(B)/(C) = Phase Werkzeugeingriff (Eintritt/Vollschnitt/Austritt); I_{SM} = Spindelmotorstrom, t = Zeit, WT = Wavelet-Spektrogramm, STFT = Spektrogramm, RP = Rekurrenzplot, MTF = Markov-Übergangsmatrix, GAF = Gramian Angular Field, v_c = Schnittgeschwindigkeit, f_z = Vorschub pro Zahn pro Werkzeugumdrehung, a_p = Eingriffsbreite, a_e = Arbeitseingriff, z = Zähnezahl, γ_f = Seitenspanwinkel der Hauptschneiden, D = Werkzeugdurchmesser)

3.2.3 Einsatz in Bohrprozessen

3.2.3.1 Anomaliedetektion

Beispiele aktueller Forschungsergebnisse zur Anomaliedetektion bei Bohrprozessen sind in der Tabelle 3.6 präsentiert. Hierbei wird die große Bandbreite der Methoden, die teils aus anderen Technologiebereichen stammen, deutlich.

Tabelle 3.6: *ML-basierte Anomaliedetektion in Bohrprozessen (tiefgestelltes „MK“ = Klassifikations-Modell, ANN = künstliches neuronales Netz, BT = Boosted Tree, KNN = K-Nearest Neighbour, FSc_E = F-Score, L_E = Fehlerquote)*

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[TPL22]	schallbasierte Vorhersage des Bohrerbruchs mit Störlärm	ANN_{MK}	$FSc_E = 0,91$
[Glo19]	schallbasierte Schadenserkennung innerhalb manueller Bohrmaschinen	KNN_{MK}	$L_E \leq 0,04$
[Pap+20]	Erkennung fehlerhafter Werkstücke mit Kraft-, G-Sensor- und Temperaturprozessdaten	Fuzzy C-Means	Reduktion manueller Tests um bis zu 94 %
[LL24]	Werkzeugbruch-Identifikation beim automatisiertem Bohren mithilfe der Spindelleistung und Prozessparameter	BT_{MK}	$L_E \approx 0$
[Pan+22]	Bohrfehler-Identifikation in Turbinenschaufeln mithilfe von Röntgenbildern	ANN_{MK}	$L_E = 0,06$

3.2.3.2 Prozesszustand

Anhand der Tabelle 3.7 wird deutlich, dass mithilfe von ML und KI vielfältige Überwachungssysteme implementiert sind. Durch die immer schnellere Datenverarbeitung ist ebenfalls eine schnelle und damit prozessparallele Auswertung von hochaufgelösten optischen Aufnahmen möglich. In der Abbildung 3.13 werden Ergebnisse zur visuellen Kontrolle der Elemente im Arbeitsfeld vorgestellt [Rui+20]. Dabei wird mithilfe künstlicher neuronaler Netze z. B. zwischen einer vorliegenden Bohrung, einer Senkung oder einem gesetzten Niet unterschieden. Die mittlere Klassifikations-Vorhersagegüte je Element liegt, gemessen am F-Score, im ungefähren Bereich $FSc = 0,75 \dots 0,99$. Diese Anwendung ist als Grundlage für eine automatische Arbeitsschritt-Überwachung denkbar.

3.2.3.3 Werkstückqualität

Bei der Vorhersage der Werkstückqualität ist, wie schon mehrmals festgestellt, der Fokus auf automatische (meist robotische) Prozesse zu sehen (siehe Tabelle 3.8). Es konnten dabei nicht jedes Mal hochpräzise Vorhersagen erreicht werden. In der Abbildung 3.14 wird ein exemplarisches Ergebnis in Form der Durchmesser- und Konzentritätsvorhersage einer Bohrung mithilfe eines auf Entscheidungsbäumen basierten Ensemble-Algorithmus (Extra

Tabelle 3.7: ML-basierte Prozesszustand-Überwachung in Bohrprozessen (tiefgestelltes „MK“ = Klassifikations-Modell, ANN = künstliches neuronales Netz, SVM = Support Vector Machine, L_E = Fehlerquote)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[Rui+20]	robotischer bildbasierter Check der Bohrungen und Verbindungselemente	ANN _{MK}	siehe Abb. 3.13
[DD23]	Ratterndetektion beim manuellen Bohren in Metallen mithilfe von Beschleunigungs-Signalen	SVM _{MK}	$L_E \leq 0,016$
[Zha+24]	Erkennung der Bohrungsphasen sowie der Werkstoffübergänge und -art beim automatischen Bohren	ANN _{MK}	$L_E \leq 0,02$
[Zub+21]	Einfluss der Feature-Extraktion bei der Überwachung von Bohrprozessen	diverse	-

Tree Regression) nach [SMB20] präsentiert. Dabei erfolgen unterschiedliche Modellierungen in Abhängigkeit der Feature-Vorbereitungsmethode. Bei dieser überwachten Regression führt die manuelle Feature-Extraktion mit einem Bestimmtheitsmaß zwischen wahren und vorhergesagtem Wert von $R_E^2 \geq 0,93$ zu ähnlich hohen Vorhersagegüten wie automatisierte Extraktionsmethoden.

Tabelle 3.8: ML-basierte Werkstückqualität-Vorhersage in Bohrprozessen (tiefgestelltes „MK“ = Klassifikation, tiefgestelltes „MR“ = Regression, ANN = künstliches neuronales Netz, BT = Boosted Tree, LReg = Lineare Regression, RF = Random Forest, MCC_E = Matthews Correlation Coefficient, R_E^2 = Bestimmtheitsmaß, MAE_E = mittlerer absoluter Fehler, $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers, L_E = Fehlerquote)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[Zie22]	Klassifikation von Geradheit/Rundheit/Durchmesser automatisch gefertigter Bohrungen in Stahl	RF _{MK}	$MCC_E \approx 1$
[SMB20]	Einfluss der Feature-Vorbereitung auf die Durchmesser- und Konzentritätsvorhersage von automatisch gefertigten Bohrungen	RF _{MR}	$R_E^2 \leq 0,92$ $MAE_E = 0,24$... $27\mu\text{m}$
[Sch21]	Durchmesser-Vorhersage automatisch gefertigter Bohrungen in Grauguss unter Nutzung von Spindelmoment, -position und -drehzahl	BT _{MR}	$R_E^2 = 0,77$
[HW23]	Vorhersage von Rundheit/Geradheit beim automatischen Bohren mithilfe von G-Sensor- und NC-Steuersignalen	LReg _{MR}	$RMSE_E = 5 \dots 7\mu\text{m}$
[Lee+25]	optische Delaminations-Erkennung beim robotischen Bohren	ANN _{MR}	$L_E = 0,17$

(a) Werkstoffoberfläche (b) Nietbohrung (c) Senkung (d) Niet (e) hervorstehender Niet
 (f) temporäres Element 1 (g) temporäres Element 2 (h) hexagonales Element (i) Schraube

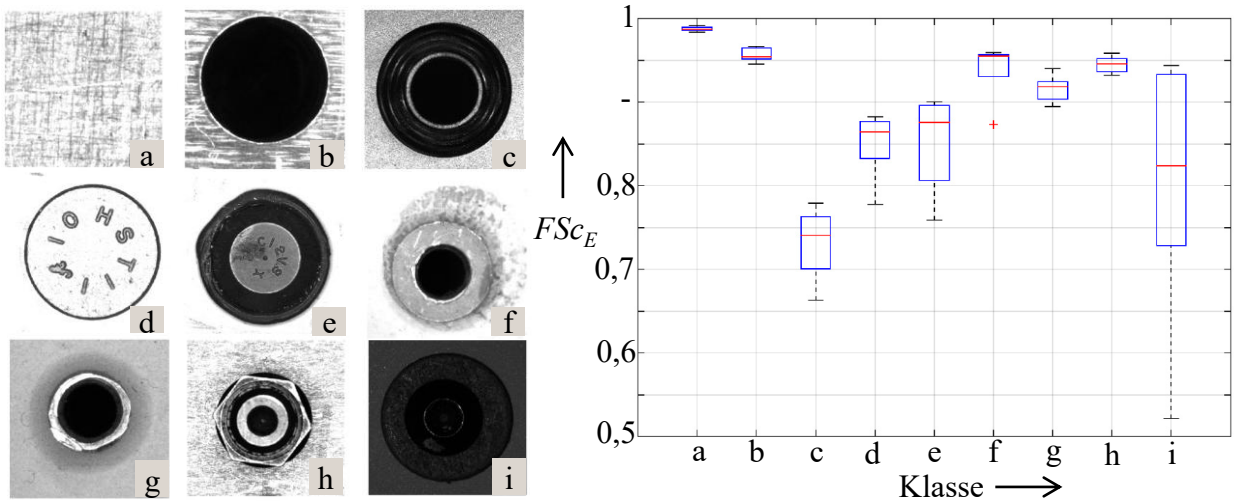


Abbildung 3.13: Beispiel für ML-basierte visuelle Prozesszustand-Überwachung beim Bohrvorgang durch Erkennung der Elemente im Arbeitsfeld nach [Rui+20] ($FSc_E = F\text{-Score}$; die Streuung für FSc_E ergibt sich aufgrund wiederholter Trainingsvorgänge; ML-Algorithmus: künstliches neuronales Netz als Klassifikator (ANN_{MK}))

3.2.3.4 Werkzeugverschleiß

In der Tabelle 3.9 sind exemplarische Ergebnisse zur ML-basierten Werkzeugverschleiß-Vorhersage dargestellt. Auffällig ist die häufige Verwendung auf Entscheidungsbäumen basierter Algorithmen und der Fokus auf das automatisierte Bohren.

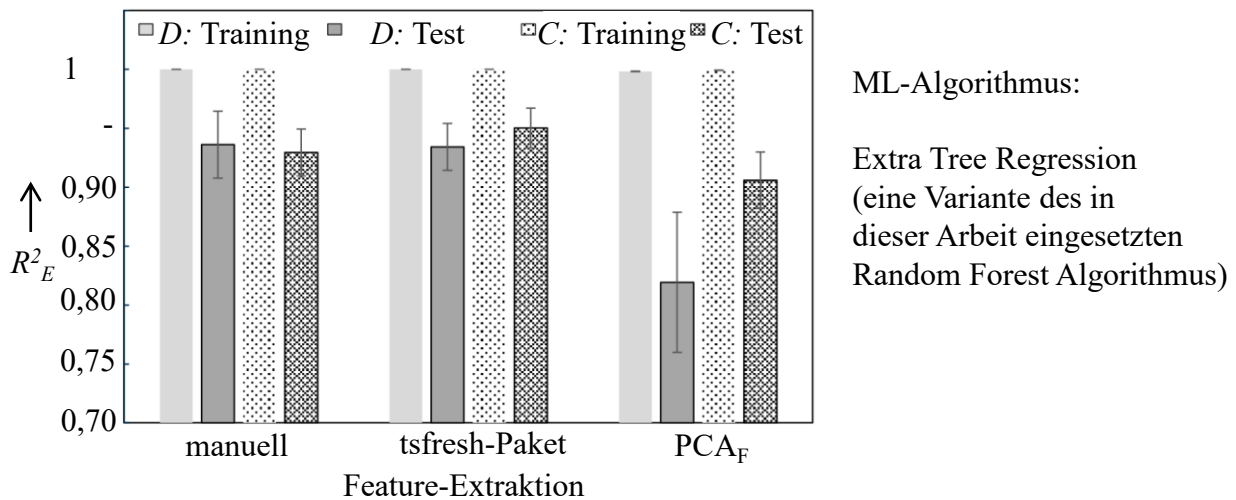


Abbildung 3.14: Vorhersage der Werkstückqualität in Abhängigkeit der Feature-Vorbereitung beim Bohrprozess nach [SMB20] (D = Durchmesser, C = Konzentrität, R_E^2 = Bestimmtheitsmaß zwischen wahren und vorhergesagtem Wert, PCA_F = Principal Component Analysis)

Tabelle 3.9: ML-basierte Werkzeugverschleiß-Vorhersage in Bohrprozessen (V_{VB} = Verschleißmarkenbreite, tiefgestelltes „MK“ = Klassifikations-Modell, tiefgestelltes „MR“ = Regressions-Modell, BT = Boosted Tree, RF = Random Forest, SVM = Support Vector Machine, DT = Entscheidungsbaum, $LReg$ = lineare Regression, KNN = K-Nearest Neighbour, R_E^2 = Bestimmtheitsmaß, $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers, L_E = Fehlerquote, FSc_E = F-Score)

Quelle	Einsatz/Zielgröße	Modell	Vorhersagegüte
[AA20]	Vorhersage von V_{VB} beim Bohren von Kupfer- und Stahllegierungen	RF_{MR}	$R_E^2 \geq 0,975$
[SD19b]	Klassifikation von V_{VB} beim Bohren von Stahllegierungen unter Nutzung von Beschleunigungsmessungen	RF_{MR}	$L_E \leq 0,21$
[Ree+24]	Klassifikation verschlissener Werkzeuge beim Bohren von Stahl mithilfe von Motorströmen der Werkzeugmaschine	BT_{MK}	$FSc_E \approx 1$
[Koc+22]	Klassifikation verschlissener Werkzeuge beim robotischen Bohren von CFK mit Schall- und G-Sensor-Signalen	SVM_{MK} DT_{MK}	$L_E = 0,13 \dots 0,22$
[Dom+22]	Werkzeugzustand-Überwachung beim automatisierten CFK-Bohren in der Luftfahrt-Produktion mithilfe der Spindelleistung und NC-Steuersignale	$LReg_{MR}$ KNN_{MR} RF_{MR}	$RMSE_E \leq 0,23$ (Zustandsskala = [1; 5])

4 Ableitung der Forschungsfrage, Zielsetzung und Vorgehensweise

In diesem Kapitel wird die Forschungsfrage, die aus dem Fazit des vorherigen Kapitels 3 abgeleitet ist, aufgezeigt. Die daraus resultierenden Ziele werden im Anschluss dargestellt. Abschließend wird die Vorgehensweise dieser wissenschaftlichen Arbeit skizziert.

4.1 Fazit zum Stand der Technik

Anhand der Abschnitte 3.1.1 und 3.1.2 wird die elementare Bedeutung der Bohrprozesse bei der Fertigung der Luftfahrzeuge deutlich, da Niet- und Schraubverbindungen den größten Anteil der Fügeverbindungen darstellen. Dabei weisen die semi-automatischen Bohrprozesse eine hohe und immer noch steigende Relevanz auf, siehe Abschnitt 3.1.3. Die Implementierung des vibrationsunterstützten Bohrens erweist sich dabei als vorteilhaft, um die Spanabfuhr und damit die Werkstückqualität sowie den Werkzeugverschleiß zu reduzieren (Abschnitt 3.1.3.4). Die Prozesse werden durch die fortschreitende Digitalisierung und damit einhergehende Vernetzung und Kommunikation zwischen den beteiligten Maschinen und Bedienern unterstützt (Abschnitt 3.1.3.5). Mit heutigen Sensortechnologien und der immer leichter verfügbaren und schnelleren Rechenkapazität lässt sich eine wachsende Datenbasis zur ML-basierten Überwachung der Produktionsprozesse aufbauen und verarbeiten. In ausgewählten Anwendungsfällen werden beim Einsatz des maschinellen Lernens hohe Vorhersagegüten erreicht, was den Gebrauch dieser Verfahren rechtfertigt, siehe Abschnitt 3.2. Anhand der aktuellen Forschungsergebnisse lassen sich jedoch folgende Lücken erkennen, die eine weitere wissenschaftliche Untersuchung zur Anwendung von ML-basierten Methoden erfordern:

- **Vergleich der ML-Algorithmen:** Oftmals liegt der Fokus auf einzelnen ML-Algorithmen. Dies führt dazu, dass der Performance-Vergleich zwischen unterschiedlichen Algorithmen-Gruppen nicht gegeben ist.
- **Generalisierbarkeit der Randbedingungen:** Die bisherigen Untersuchungen weisen meist einen engen Fokus, z. B. auf bestimmte Werkstoffe oder Prozessparameter, auf.
- **Semi-automatische Bohrprozesse:** Es erfolgt meist eine Betrachtung der automatischen Prozesse, bei denen die Sensordaten-Güte aufgrund fest vorgeschriebener Arbeitsschritte meist hochwertig ist. Es konnten sehr wenige Untersuchungen zu nicht-automatischen Bohrprozessen identifiziert werden.
- **Objektiv-Funktion:** Die Definition der Objektivfunktion und der Validierungsmethode beim Modelltraining ist häufig nicht vorhanden bzw. lückenhaft dokumentiert.
- **Anomaliezustände beim Bohren:** In der Literatur werden mehrheitlich werkzeugbezogene Prozessfehler, z. B. Bohrerbrüche, untersucht. Analysen zu fälschlich angesetzten Bohrungen ließen sich nicht feststellen.

- **Verschleiß-Kenngrößen:** Es sind größtenteils Untersuchungen zu der Verschleißmarkenbreite an der Schneiden-Freifläche vorhanden. Dieser Parameter ist jedoch nicht für jedes Prozessszenario die aussagekräftigste Kennzahl des Werkzeugverschleißes.
- **Benchmark-Bezug:** Oftmals ist die Herkunft und Verteilung der wahren Zielgrößen als Benchmark zur Modell-Bewertung intransparent. Damit ist auch die Einschätzung der Vorhersagegüte kritisch zu betrachten, wenn z. B. zum Modell-Training verwendete Zielgrößen annähernd konstant oder deren Toleranz-Grenzwerte unbekannt sind.

4.2 Ableitung der Forschungsfrage

Die Analyse der aktuellen Forschung ergibt, dass die ML-Anwendung bei semi-automatischen Bohrprozessen wenig untersucht ist. Der Status Quo der Industrie ist, dass die Fertigungskapazitäten aufgrund sehr hoher Auftragsbestände auf Jahre hinweg ausgelastet sind und die Niettechnologie als wichtigstes Fügeverfahren sehr viele Bohrungen pro Flugzeug benötigt. Dieser Zustand verspricht ein großes Potential an Massendaten, um darauf basierend zuverlässige ML-Modelle zu trainieren. Diese wiederum können zur Automatisierung und Genauigkeitssteigerung der Prozessüberwachung eingesetzt werden, womit manuelle Ressourcen zur Ratensteigerung in der Produktion entstehen. Die Ausgangslage mündet in der Forschungsfrage gemäß Abbildung 4.1:

Inwieweit sind ML-Algorithmen zur automatischen sensordatenbasierten Prozessüberwachung beim semi-automatischen Bohren gewinnbringend einsetzbar?

Dabei sind die Fragen zu relevanten Datenfeatures, den einzusetzenden Methoden in den ML-Modellierungs-Pipelines und zu den erreichbaren Vorhersagegüten zu beantworten.

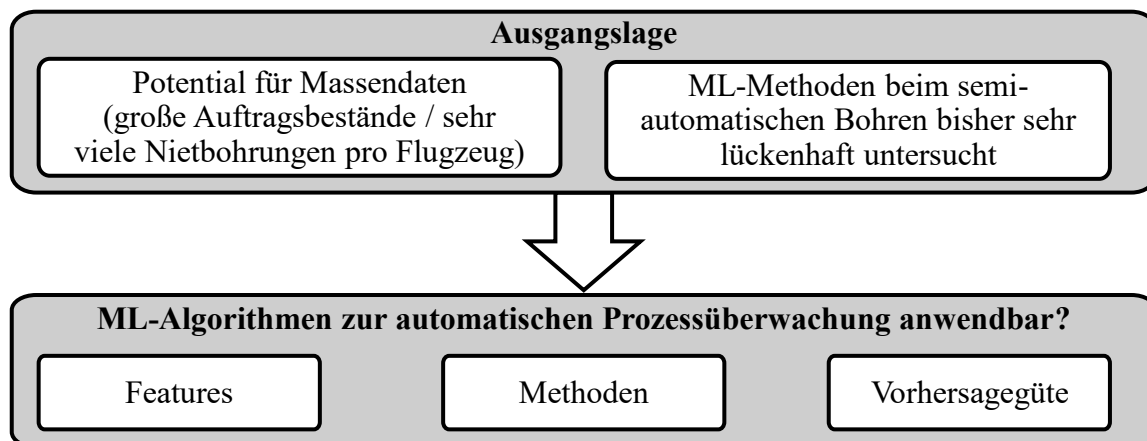


Abbildung 4.1: Ableitung der Forschungsfrage

4.3 Zielsetzung

Die Abbildung 4.2 fasst die Zielsetzung dieser Arbeit zusammen. Als Grundziel ist die Erstellung einer Datenbasis der Prozessgrößen (= Sensordaten) und der Zielgrößen (=

Anomaliezustände, Prozesszustände, Werkstückqualität und Werkzeugverschleiß) zu nennen. Dies ist durch experimentelles Vorgehen zur Herstellung von Bohrungen unter möglichst industrienahen Bedingungen umzusetzen. Wichtig ist dabei, die mögliche Breite der Prozess-Stellgrößen, wie z. B. Schnittparameter, abzubilden.

Das zentrale Ziel der Forschungsfrage wird folgendermaßen formuliert:

In dieser Forschungsarbeit ist das zentrale Ziel die Ermittlung der möglichen Vorhersagegüte eines auf maschinellem Lernen basierenden Prozessmonitorings für das semi-automatische Bohren bei der Herstellung von Durchgangsbohrungen beim Bohren ins Volle mit Wendelbohrern. Dabei liegt der Fokus auf der Bestimmung von möglichen Prozessanomalien, des Prozesszustands, der Werkstückqualität und des Werkzeugverschleißes.

In den aufzubauenden Modellierungs-Pipelines soll der Einfluss der Feature-Vorbereitung, der Validierungs-Methode, des ML-Algorithmus sowie der bei der Modell-Hyperparameteroptimierung verwendeten Objektiv-Funktion analysiert werden. Die einzelnen Methoden dieser Teilschritte sind in den folgenden Kapiteln ausführlich erklärt. Dabei soll auch erkannt werden, welche Art des maschinellen Lernens am vorteilhaftesten ist. Als weiterer Einflussparameter ist zudem das Vorgehen bei der Feature-Extraktion zu bewerten, um z. B. die Wichtigkeit der eingesetzten Sensoren und die Domänen der Features (z. B. Domäne der Zeit, Frequenz, etc.) zu vergleichen. Des Weiteren besteht das Ziel, den Einsatz von künstlichen Daten beim Modell-Training im Hinblick auf die Vorhersagegüte zu bewerten. Daraus lässt sich beispielsweise schließen, ob die erzeugte Datenbasis ausreichend groß ist.

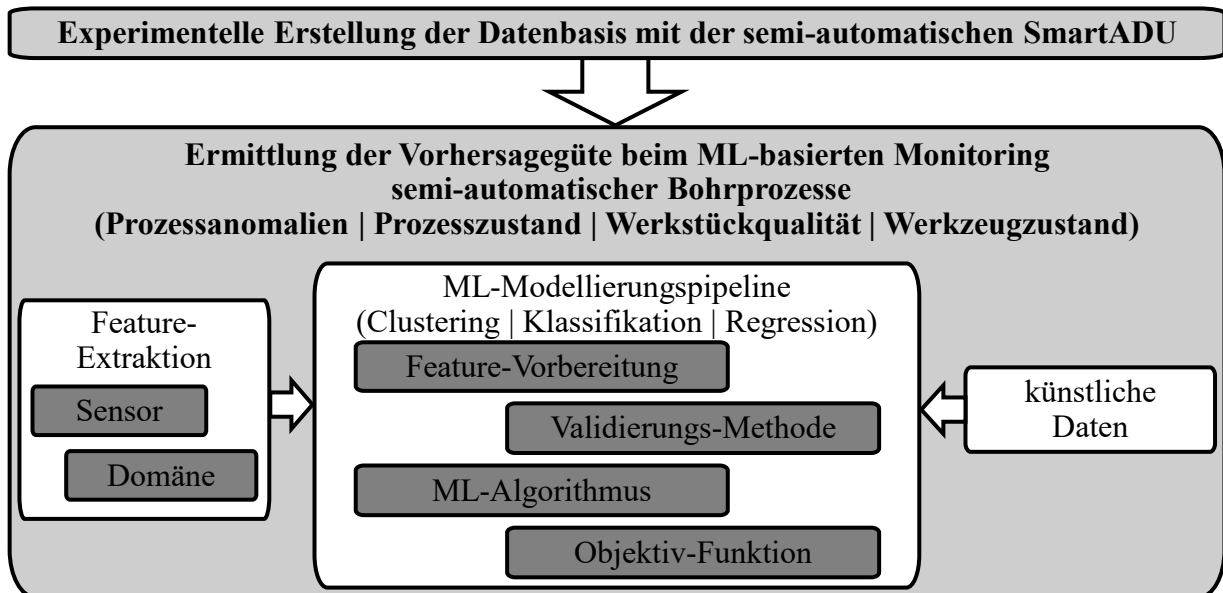


Abbildung 4.2: Schema zur Zielsetzung dieser Arbeit

4.4 Vorgehensweise

Zur Zielerreichung wird die in der Abbildung 4.3 sichtbare Vorgehensweise entworfen. Nach der Einleitung im Kapitel 1 werden die etablierten technischen Grundlagen dieser Arbeit im Kapitel 2 dargestellt. Diese umfassen das Fertigungsverfahren Bohren, die Techniken

der klassischen Produktionsprozess-Überwachung sowie das maschinelle Lernen. Im Kapitel 3 werden die aktuellen Entwicklungen in der Luftfahrzeug-Strukturmontage und in der Anwendung des maschinellen Lernens in der Produktion zusammengefasst. Bei diesen Inhalten ist eine Weiterentwicklung mit neuen Forschungs- und Entwicklungsergebnissen in den nächsten Jahren denkbar. Daraus erfolgt im Kapitel 4 die Ableitung der Forschungsfrage, des Forschungsziels sowie der Vorgehensweise dieser Arbeit.



Abbildung 4.3: Schema zur Vorgehensweise in dieser Arbeit

Im Kapitel 5 wird die Versuchsmethodik zur Datengenerierung vorgestellt. Dabei wird der Prüfstand mit externer Sensorik und der elektrischen semi-automatischen Bohrvorschubeinheit SmartADU beschrieben. Der Versuchsplan und die Beschreibung der Zielgrößen-Vermessung ist darin ebenfalls zu finden. Im Kapitel 6 schließt sich der Aufbau einer ML-basierten Modellierungs-Pipeline mit der dafür notwendigen Programmierung an. Das Kapitel 7 dient zur Darstellung der erfassten Zielgrößen-Verläufe, woraus die Ableitung der Limitation grafischer Kennzahlenevaluation zur Prozessüberwachung erfolgt.

Die Kapitel 8 - 11 beinhalten die Analyse der Ergebnisse bei der Anomaliedetektion, Prozesszustand-, Werkstückqualität- und Werkstückverschleiß-Überwachung. Darin werden die Einflussparameter laut der Abbildung 4.2 untersucht. Im Kapitel 12 werden die Ergebnisse im Hinblick auf eine mögliche industrielle Anwendung bewertet. Abschließend wird im Kapitel 13 diese Arbeit zusammengefasst, die Limitation der Ergebnisse diskutiert und mögliche weiterführende Forschungsansätze abgeleitet.

5 Experimentelle Datengenerierung

Dieses Kapitel stellt das experimentelle Vorgehen zur Prozessdaten- sowie Zielgrößenerfassung vor. Für eine ML-basierte Prozessüberwachung ist ein ausreichend großer Prozessdatensatz mit hinreichend breiter Varianz für das Training der Modelle notwendig. Dazu werden in dieser Arbeit zum einen während des Bohrvorgangs Sensordaten online aufgenommen. Zum anderen erfolgt die Erfassung der Zielgrößen in Abhängigkeit ihrer Eigenschaft entweder prozessparallel oder in einer nachgelagerten Vermessung. Die Basis für die online-Sensordatenaufnahme stellt die semi-automatische Bohrvorschubeinheit *SmartADU* mit dem dazugehörigen adaptiven Bohrversuchsstand dar. Beide sind mit Sensorik für eine prozessbegleitende Sensordatenaufnahme ausgestattet und werden in den Abschnitten 5.1.1 und 5.1.2 vorgestellt. Der Abschnitt 5.1.3 enthält Angaben zu den verwendeten Werkstoffen und Werkzeugen. Die Vorgaben des Versuchsplans sind sehr vielfältig gestaltet, um eine möglichst breite Variation industrierelevanter Prozessbedingungen darzustellen, siehe Abschnitt 5.1.4. Das Vorgehen zur Zielgrößendefinition und dazu notwendiger offline-Messdatenaufnahme ist im Abschnitt 5.2 dargestellt.

5.1 Bohrversuche und online-Prozessdatengenerierung

Bei der Datengenerierung wird das Ziel verfolgt, eine möglichst breite Datenbasis zum Training der ML-Modelle herzustellen. Daneben sollen die Potentiale interner Sensorik der *SmartADU* sowie weiterer externer Messaufnehmer am adaptiven Versuchsstand hinsichtlich ihrer Eignung zur Prozessüberwachung untersucht und bewertet werden. Im Folgenden werden die semi-automatische Bohrvorschubeinheit *SmartADU*, der adaptive Prüfstand sowie die bearbeiteten Werkstoffe und eingesetzten Werkzeuge im Rahmen der Versuchsplangruppen vorgestellt.

5.1.1 Semi-automatische *SmartADU* mit interner Sensorik

Im Abschnitt 3.1.3 wird der dominierende Anteil von Bohrungen in der Luftfahrtindustrie, die mit semi-automatischen Bohrvorschubeinheiten hergestellt werden und der technologische Wandel hin zu elektrisch angetriebenen Maschinen dargestellt. Die in der Abbildung 5.1 gezeigte *SmartADU* des Herstellers *Johannes Lübbering GmbH* ist eine elektrische semi-automatische Bohrvorschubeinheit, mit der die Versuche in dieser Arbeit durchgeführt werden. Die *SmartADU* wurde als Prototyp in dem Forschungsprojekt *SmartADU2020* unter Mitwirkung des IPMT entwickelt und getestet. Die Beschreibung der *SmartADU* in diesem Abschnitt basiert auf dem dazugehörigen Projektabschlussbericht [HMR19] sowie auf den am IPMT entstandenen Veröffentlichungen [Hin+19a], [Koe+20], [Hin+22].

Die Bohrmaschine muss zur Bohrungsherstellung in eine passende Halterung oder Schablone eingesetzt werden, die gemäß den Positionen der notwendigen Nietbohrungen passende

zylinderförmige Aussparungen zur Aufnahme der Maschinen-Klemmhülse besitzen. Mithilfe der druckluftbetriebenen Klemmhülse, auch als *Concentric Collet (CC)* bezeichnet, wird die Maschine arretiert, und nach Freigabe wird der Bohrvorgang automatisch durchgeführt. Aktuell geschieht die Freigabe in der Industriepaxis sowie am IPMT manuell durch einen Bediener. Anhand der SmartADU ist für diese Arbeit das ebenfalls in Abbildung 5.1 sichtbare kartesische Koordinatensystem definiert, auf welches, sofern nicht anders erwähnt, sich die Ausführungen und Analysen beziehen.

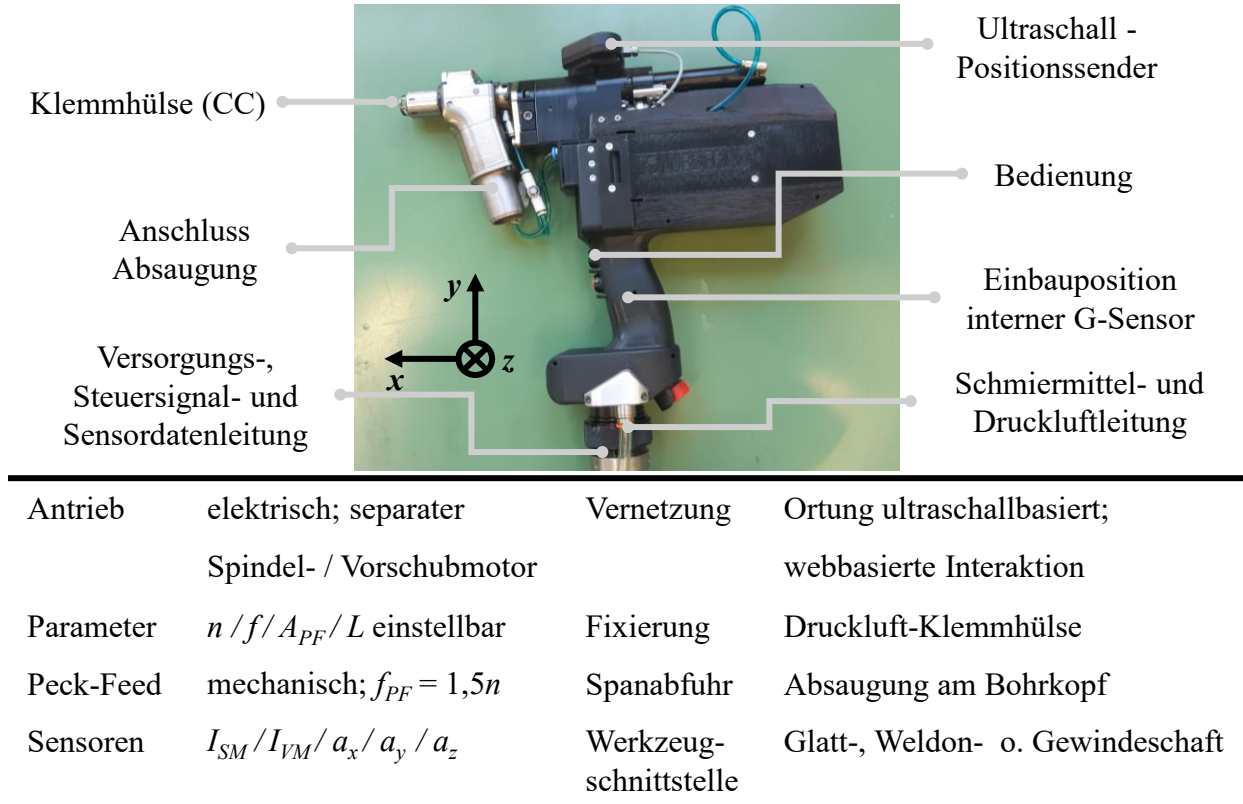


Abbildung 5.1: Semi-automatische elektrische Bohrvorschubeinheit SmartADU des Herstellers Johannes Lübbering GmbH (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, A_{PF} = Peck-Feed-Amplitude, L = Schmierzustand, f_{PF} = Peck-Feed-Frequenz, I_{SM} = Spindelmotorstrom, I_{VM} = Vorschubmotorstrom, $a_{X/Y/Z}$ = Beschleunigung in $x/y/z$ -Richtung)

Die SmartADU ist mit jeweils einem separaten elektrischen Spindelmotor (Nennleistung $P_{SM,N} = 2\text{kW}$) für die Erzeugung der Spindel-Rotation und einem Vorschubmotor (Nennleistung $P_{VM,N} = 180\text{W}$) für die Erzeugung des (Werkzeug-)Vorschubs ausgestattet. Die Maschine erlaubt eine vorschubwegabhängige Definition der Prozessparameter *Drehzahl* n , (*Werkzeug-)*Vorschub pro *Werkzeugumdrehung* f , *Schmierung* L und *Peck-Feed-Amplitude* A_{PF} , siehe Tabelle 5.1. Innerhalb eines Abschnitts ist die Maschine drehzahl geregelt.

Als *Peck-Feed* wird bei der SmartADU das System des vibrationsunterstützten Bohrens bezeichnet, siehe dazugehörige technischen Grundlagen und Auswirkungen im Abschnitt 3.1.3.4. Das Peck-Feed-System des Herstellers *MITIS* basiert auf dem konstruktiven Prinzip, bei dem die Laufflächen der Spindelaxiallagerung ein teilweise sinusförmiges Profil aufweisen, was dementsprechend eine sinusförmige axiale Bewegung der Spindel infolge ihrer Rotationsbewegung hervorruft [Jal+13]. Mittels eines Servomotors erfolgt eine Verstellung der Lagerung, wodurch die Peck-Feed-Amplitude A_{PF} in einem theoretischen Bereich zwischen $0\ \mu\text{m}$ und $125\ \mu\text{m}$ eingestellt werden kann. Diese Amplitudenangabe bezieht sich auf den

Tabelle 5.1: Adaptive Prozessparameter der SmartADU

Einstellbare Prozessparameter		Spezifikation
Drehzahl n	$[\text{min}^{-1}]$	in Al: max. 12000 min^{-1} in Ti: max. 3000 min^{-1}
Vorschub pro Werkzeugumdrehung f	$[\text{mm}]$	variabel
Schmierung L	$[\%]$	0 % $\hat{=}$ Schmierung: nein / Druckluft: nein 1 % $\hat{=}$ Schmierung: nein / Druckluft: ja 100 % $\hat{=}$ Schmierung: ja / Druckluft: ja
Peck-Feed- Amplitude A_{PF}	$[\mu\text{m}]$	max. 125 μm

Abstand zwischen Nulllage und Wellenberg oder -tal. Die Amplituden A_{PF} der Hübe weichen steifigkeits- und prozessbedingt von den theoretischen Herstellerangaben ab [HMR19; Dob19]. Da eine prozessindividuelle Überprüfung der realen Peck-Feed-Amplitude bei dem breit angelegten Versuchsplan nicht umsetzbar ist, wird sich bei der Einstellung von A_{PF} an den Herstellerangaben orientiert. Die Peck-Feed-Frequenz f_{PF} ist mit dem Faktor 1,5 zur Spindeldrehzahl vorgegeben ($f_{PF} = 1,5 \cdot n$).

In die Bohrvorschubeinheit sind, je nach eingebauter Spindel, Werkzeuge mit einem glatten Zylinder-, Gewinde- oder Weldon-Schaft einsetzbar. Das Schmiermittel wird in Form einer *Minimalmengenschmierung (MMS)* neben der Druckluft durch das Versorgungskabel zur Maschine und im Anschluss weiter in die Kühlkanäle des Werkzeugs gefördert. Hierbei sei drauf hingewiesen, dass auch bei ausgeschalteter Schmierung niedriger MMS-Austritt an den Kühlkanälen des Werkzeugs beobachtet wird. Möglicherweise werden dabei Reste aus vorherigen Prozessen befördert. An den Anschlussadapter hinter dem Concentric Collet lässt sich ein Sauger zum Abtransport der Späne und des CFK-Staubes anschließen.

Zur Prozessdatenüberwachung verfügt die SmartADU über interne Sensorik, deren Signale mit einer Abtastrate $f_{s,ADU} = 100$ Hz erfasst werden. Dabei werden als physikalische Größen der Spindel- und Vorschubmotorstrom I_{SM} und I_{VM} (Sensoren $S_{i,1}$ und $S_{i,2}$ in der Abbildung 5.4) sowie die Linear-Beschleunigungen in 3 Achsrichtungen $a_{x/y/z,ADU}$ (Sensor $S_{i,3}$) zeitabhängig aufgezeichnet. Die Lage des G-Sensors ist in der Abbildung 5.1 verzeichnet. Weitere Beschreibung der Sensorik ist in der Tabelle 5.2 aufgelistet.

Die Sensordaten werden auf der *Control Box* der SmartADU, die mittels eines Versorgungskabels mit der Maschine verbunden ist, neben den eingestellten Schnittparametern und den internen Steuergrößen zeitabhängig als .xlsx-Dateien abgelegt. Über eine WLAN-Verbindung zu der Control Box können die Daten in einem PC-Web-Interface visuell eingesehen und heruntergeladen werden, wie auch in dieser Arbeit geschehen ist. Die Control Box enthält einen Schmiermitteltank und ist an externe Druckluft- und Stromzufuhr angeschlossen.

5.1.2 Adaptiver Prüfstand mit externer Sensorik

Die Untersuchungen finden an einem adaptiven Prüfstand für semi-automatische Bohrmaschinen statt, welcher in Abbildungen 5.2 dargestellt ist. Dieser wurde bereits im Zuge des

SmartADU2020-Forschungsprojekts konzipiert und für Untersuchungen angewendet [HMR19]. Im Zuge dieser Arbeit finden notwendige spezifische Anpassungen, Erweiterungen sowie eine Koordinatenachsen-Definition statt. Diese beinhaltet die Ausrichtung des global verwendeten Koordinatensystems an den Achsen $x/y/z$ (siehe Abbildung 5.1 und 5.4) des internen SmartADU-G-Sensors $S_{i,3}$, welcher bereits im Abschnitt 5.1.1 vorgestellt wurde. Dabei fällt die x -Achse mit der Vorschubrichtung zusammen. Während der Positionierung der Bohrmaschine ist die Winkelorientierung um die x -Achse irrelevant für das Bearbeitungsergebnis, zudem ist diese durch die manuelle Positionierung einer Varianz unterworfen. Ferner ist die Winkelorientierung in der Industrie ebenfalls nicht festgelegt. Daher wird in dieser Arbeit zur bildlichen Erklärung von Aufbauten, Qualitätsvermessung, etc. eine idealisierte Positionierung der SmartADU angenommen, bei der ihre x -, y -, z -Achsen mit denen des Prüfstandes und des eingespannten Werkstücks (x' -, y' -, z' -Achsen) identisch sind, siehe Abbildung 5.2. Im weiteren Verlauf wird sich aus diesem Grund nur auf die x -, y -, z -Achsen bezogen.

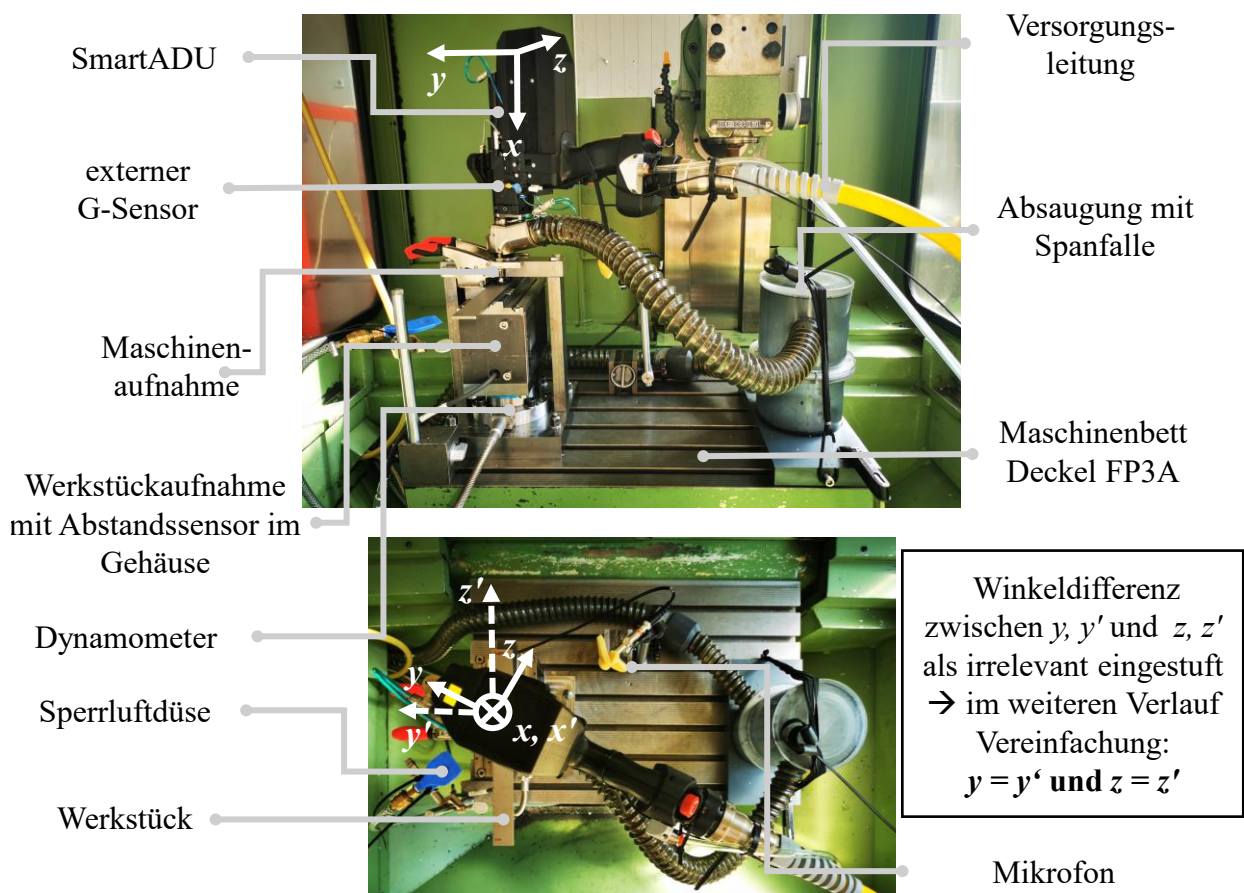


Abbildung 5.2: SmartADU-Prüfstand mit externer Sensorik

Der Prüfstand ist auf dem Maschinenbett der 3-Achs-Fräsmaschine *Deckel FP3A* befestigt. Das Fräsmaschinenbett dient lediglich der Prüfstandfixierung als Arbeitsraumfundament und ist nicht aktiv in den Versuchsprozess integriert. Bei dem Prüfstand sind Anpassungsmöglichkeiten gegeben in der:

- maschinenseitigen Anbindung
- werkstückseitigen Anbindung (Abmaße sowie Einspannbedingungen)
- Sensorintegration

Die Hauptelemente hinsichtlich des mechanischen Aufbaus und der Steifigkeit sind das Portal mit der Maschinenaufnahme, die Grundplatte mit einem integrierten Dynamometer und die Werkstückaufnahme mit einem integrierten Laser-Abstandssensor, welcher den Abstand von seinem Referenzpunkt zur Werkstückunterseite und damit effektiv die Werkstückbewegung aufnimmt. Die Maschinenaufnahme wird in Form einer Bohrschablone, worin sich der CC der SmartADU vertikal variabel einspannen lässt, realisiert. Die Werkstückhalterung ist von der Maschinenhalterung mechanisch entkoppelt und ist schematisch inklusive der variablen Einspannbedingungen in der Abbildung 5.3 dargestellt. Durch zwei integrierte Niederhalter lassen sich streifenförmige Werkstücke unterschiedlicher Abmessungen auf Lagerzylindern einspannen und nach einer erfolgten Bohrung (in z -Richtung) verschieben. Die Einspannung kann als Festlagerung angesehen und in vier Festlager-Abständen umgesetzt werden. Alternativ ist ein Spannen der Werkstücke gegen eine Stahlplatte möglich, welche zentral eine Bohrung mit einem Durchmesser D von 12 mm aufweist. Damit wird eine idealisierte Lagerentfernung von $d_c = 0$ mm erreicht. Demgegenüber ist bei einer Nutzung von Lagerzylindern (unten: Auflagezylinder; oben: Niederhalter) die Distanz d_c zwischen den Lagern stufenweise ([57,5; 81,5; 105,5] mm) verstellbar, was das Abbilden unterschiedlicher Werkstück-Steifigkeitsbedingungen in der Industriefertigung ermöglicht. Durch die vertikal variable Platzierung der Maschine kann entweder eine Verspannung der Maschine mit dem Werkstück umgesetzt oder vermieden werden.

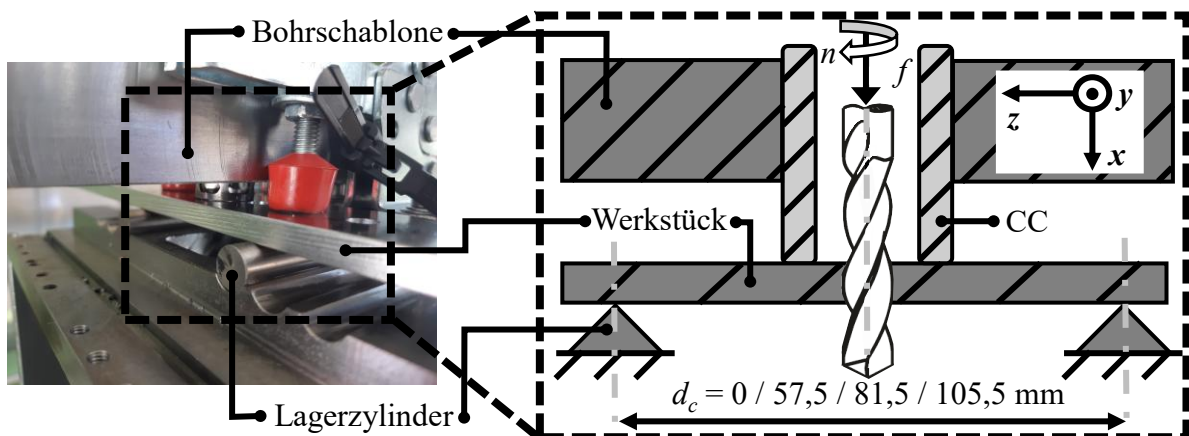


Abbildung 5.3: Einspannbedingungen der SmartADU und des Werkstücks [Hin+22] (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufs Spannweite)

Die Span- und CFK-Staub-Absaugung ist durch den Anschluss an einen Industriesauger *RUWAC DS 1400* der Staubklasse H sichergestellt. Mittels einer Spanfalle werden die bei den Bohrungen erzeugten Metallspäne aufgefangen und vom möglicherweise anfallenden CFK-Staub getrennt.

Die genutzte externe Sensorik mit ihren physikalischen Wirkprinzipien sollte bei dem vorliegenden Prozess zuverlässig funktionieren und das Potential für eine spätere Integration in eine semi-automatische Bohrmaschine aufweisen. Unter diesen Gesichtspunkten ist eine Auswahl der externen Sensorik, welche das Potential für einen späteren Industrieinsatz vorweist, erfolgt. Daher werden neben der bereits im Abschnitt 5.1.1 beschriebenen SmartADU-internen Sensorik weitere Sensoren am Prüfstand und in der unmittelbaren Umgebung appliziert. Ein dazugehöriges Schema ist in Abbildung 5.4 erstellt und in Tabelle 5.2 spezifiziert.

Ein signifikanter Unterschied ist die Abtastrate f_s der internen und externen Messtechnik. Während diese bei der SmartADU-Sensorik herstellerbedingt $f_s = 100$ Hz beträgt, ist diese bei der externen Sensorik auf $f_s = 5120$ Hz eingestellt. Damit wird bei hochfrequenten Signalen

gemäß dem *Nyquist-Shannon-Abtasttheorem* eine vollständige Messgrößenrekonstruktion nur bei den externen Sensoren gewährleistet. Für die dazugehörige rechnerische Begründung sei auf den Abschnitt 6.2 verwiesen. Insgesamt ergibt sich eine Anzahl von 7 Messgeräten, die 12 Messgrößen aufnehmen. Im Folgenden wird die am Prüfstand installierte externe Sensorik näher dargestellt.

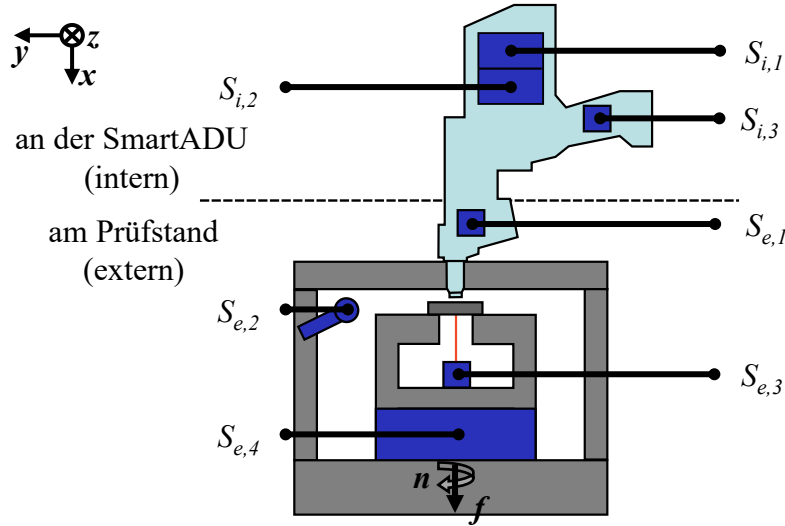


Abbildung 5.4: Schema zur internen SmartADU- und externen Prüfstandssensorik nach [Jun22b], [Hin+19a] (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, die Sensoren $S_{i,1-3}$ und $S_{e,1-4}$ sind in der Tabelle 5.2 erläutert)

Tabelle 5.2: Übersicht zur internen SmartADU- und externen Prüfstandssensorik (f_s = Abtastrate)

Sensor	physikalische Messgröße		f_s [Hz]	Anordnung
$S_{i,1}$	Vorschubmotorstrom I_{VM}	[A]	100	intern
$S_{i,2}$	Spindelmotorstrom I_{SM}	[A]		
$S_{i,3}$	Beschleunigungen $a_{x/y/z,ADU}$	[m s ⁻²]		
$S_{e,1}$	Beschleunigungen $a_{x/y/z,ext}$	[m s ⁻²]	5120	extern
$S_{e,2}$	Schalldruck L_P	[Pa]		
$S_{e,3}$	Distanz d	[m]		
$S_{e,4}$	Vorschubkraft F_z Schnittmoment M_z	[N] [Nm]		

Externer G-Sensor $S_{e,1}$ zur Messung der Beschleunigungen $a_{x/y/z,ext}$

Der G-Sensor *3053B2* des Herstellers *Dytran* ist ortsdefiniert an dem Gehäuse der Bohrmaschine mit einem Befestigungswachs, wie in der Abbildung 5.5 sichtbar, angebracht. Es wird fortlaufend sichergestellt, dass dessen Achsen parallel zu denen der SmartADU (Abbildung 5.1) stehen. Eine Koordinatentransformation der Beschleunigungssignale auf die Koordinatenachsen der SmartADU wird nach jeder Versuchsreihe vorgenommen. Die Kalibrierung des Sensors wird vor jedem Versuchsdurchlauf mit dem handbetriebenen Shaker *394C06* des

Herstellers *PCB Piezotronics* überprüft.

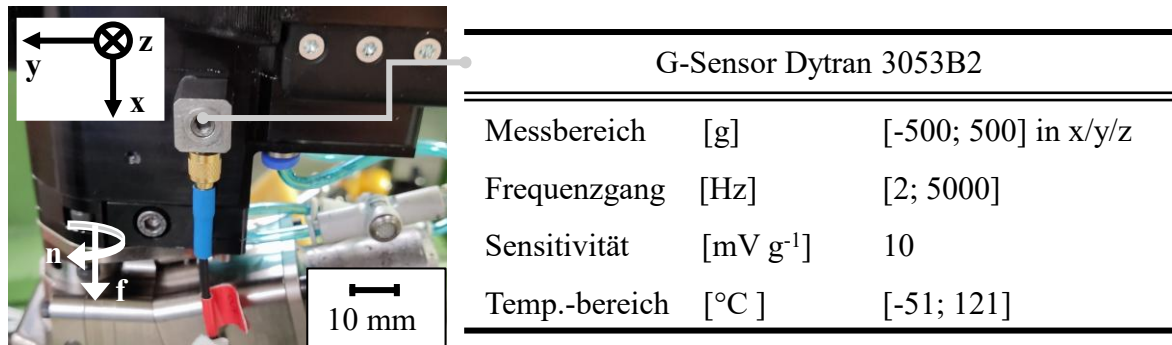


Abbildung 5.5: Sensor $S_{e,1}$: externer G-Sensor zur Aufnahme der Beschleunigungen in $x/y/z$ -Richtung (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung)

Mikrofon $S_{e,2}$ zur Messung des Schalldrucks L_P

Im Arbeitsraum ist auf einem Stativ das Freifeld-Mikrofon *146AE* (Hersteller: *GRAS Sound & Vibration*) zur Messung des Schalldrucks im Bohrprozess angebracht. In der Abbildung 5.2 ist die Positionierung und in der Abbildung 5.6 sind die technischen Details dargestellt. Das Mikrofon ist in einem horizontalen Abstand $d_M = 160$ mm zu der Bohrstelle installiert.

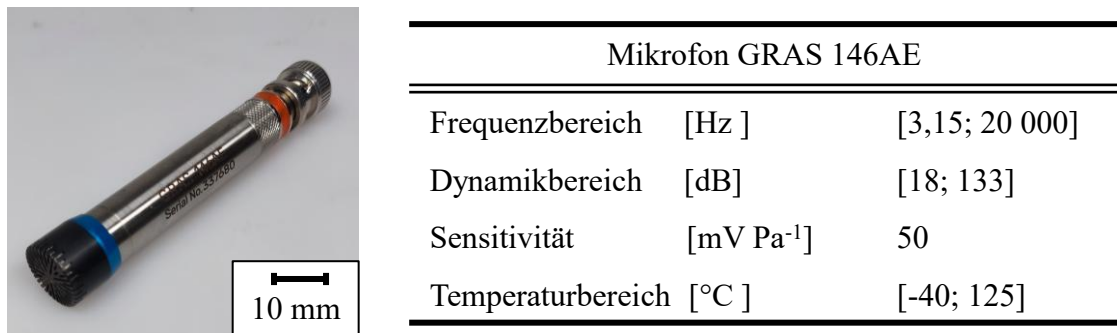


Abbildung 5.6: Sensor $S_{e,2}$: externes Freifeld-Mikrofon zur Aufnahme des Schalldrucks L_P

Laserbasierte Distanzmessung $S_{e,3}$ der Werkstückbewegung d

Die Werkstückbewegung wird mit einem optischen Lasertriangulation-Abstandssensor *ILD 2300-10* des Herstellers *Micro-Epsilon* erfasst, welcher im Gehäuse der Werkstückaufnahme installiert ist, siehe Abbildungen 5.4 und 5.7. Dabei wird der Zeitverlauf des Abstands zwischen der Sensorlinse und der Werkstückunterseite aufgenommen.

Der Messpunkt liegt dabei auf der Bohrerachse, wodurch die Werkstückbewegung während der Messung bei metallischen Materialien zuverlässig aufgenommen wird. Bei CFK-Materialien ist eine zuverlässige Messung aufgrund zum Teil reflektierender Oberflächeneigenschaften nicht möglich. Nach dem Bohrerdurchtritt ist die Messung infolge der Gratbildung und der Bohrerbewegung verfälscht und fließt nicht mehr in die Auswertung ein. Eine Sperrluftdüse ist zum Schutz der Laserlinse vor Spänen und Schmiermittel angebracht. Die Sensordaten werden über die herstellereigene Hardware (*C-Box*) als .csv-Datei an einen Rechner übermittelt. Gleichwohl ist der Anschluss der C-Box an das Messmodul *NI cDAQ-9184* möglich, womit die



Laser-Distanzsensor ILD 2300-10		
Messbereich	[mm]	[0; 10]
Auflösung	[µm]	0,15
Genauigkeit	[µm]	± 2
Lichtquelle		Halbleiterlaser

Abbildung 5.7: Sensor $S_{e,3}$: externer Laser-Distanzsensor zur Aufnahme der Werkstückbewegung d


Lasersensor-Distanzdaten mithilfe der Software *DIAdem*[®] des Herstellers *National Instruments* als .TDM-Dateien verarbeitet werden können. Die Kalibrierung des Lasersensors wird durch ein definiertes Anheben des Bohrstreifens mithilfe von Distanzplättchen überprüft.

Dynamometer $S_{e,4}$ zur Messung von Vorschubkraft F_f und Schnittmoment M_c

Die Vorschubkraft F_f und das Schnittmoment M_c werden je nach Verfügbarkeit mit einem *piezoelektrischen Dynamometer 9271A* oder *9272* der Firma *Kistler* gemessen. Es ist kein Einfluss eines Gerätewechsels auf die Messergebnisse vorhanden. Daher wird sich im Folgenden nur auf ein Dynamometer bezogen. Der Sensor ist mit der Grundplatte des Versuchsstands verschraubt. Die Kraftmessung zeichnet sich durch eine hohe Empfindlichkeit und schnelle Reaktionszeit aus. Im Zusammenhang mit dem restlichen Versuchsaufbau ist aufgrund der Steifigkeitsverhältnisse die minimale Dynamometer-Eigenfrequenz von $f_0 = 3$ kHz als obere Grenze anzusehen, was deutlich oberhalb der durch das Vibrationsbohren erzeugten Frequenzen liegt (für die dazugehörige Abschätzung sei hiermit auf den Abschnitt 6.2.2 verwiesen). Das Dynamometer ist an einen Ladungsverstärker *5070A* des Herstellers *Kistler* für eine Umwandlung der Ladungs- in Spannungssignale angebunden. Die Kalibrierung der Messkette wird vor jedem Versuchsdurchlauf mit dem Handkraftmessgerät *FG 500* des Herstellers *PCE Instruments* kontrolliert. Als Vorgriff auf die nähere Ausführung in dem Abschnitt 5.1.4.1 wird die Versuchsbeobachtung erwähnt, dass im Falle des Verspannens der Bohrmaschine mit dem Werkstück eine Verfälschung der Messdaten erfolgt. Daher sind die Dynamometer-Sensordaten theoretisch nur aus den Versuchsreihen verwendbar, in denen es zu keinem Kontakt des CC mit dem Werkstück kommt. Aus diesem Grund wird auf die Verwendung dieses Messgeräts ab der später beschriebenen Versuchsreihe Q3 verzichtet.

Digitalisierung der Zeitreihendaten

Die externen Sensoren $S_{e,1} \dots S_{e,4}$ des Prüfstandes sind bei einem Großteil der Versuchsreihen über I/O-Module der *C-Serie* an ein Ethernet-Chassis *cDAQ-9184* (beides vom Hersteller *National Instruments*) angeschlossen. Eine Ausnahme bildet die bereits beschriebene direkte Erfassung der Distanzmessung mit dem ILD 2300-10 Lasersensor. Das Gesamtsystem des Prüfstandes ergibt sich somit in der Abbildung 5.9. Als Output werden synchronisierte Zeitverläufe mit der NI *DIAdem*[®]-Software als .TDM-Dateien erzeugt, welche für eine weitere Verarbeitung z. B. in der später beschriebenen Software *MATLAB* (Abschnitt 6.2.2) geeignet sind. Der Versuchsaufbau wurde zum Teil oder in abgewandelter Form bei anderweitigen Untersuchungen am IPMT ebenfalls verwendet [Hin+19a], [Hin+19b], [Koe+20], [Hin+21], [Hin+22], [JRH23], [Fle+23].



Kistler 9271A



Kistler 9272

Dynamometer	9271A	9272
Messbereich	F_f [kN]	[-5; 20]
	M_c [Nm]	[-100; 100] [-200; 200]
Eigenfrequenz	f_0 [kHz]	> 3 in alle Messrichtungen

Abbildung 5.8: Sensor $S_{e,4}$: externe Dynamometer zur Aufnahme der Vorschubkraft F_f und des Schnittmoments F_c (n = Drehzahl, f = Vorschub pro Werkzeugumdrehung)

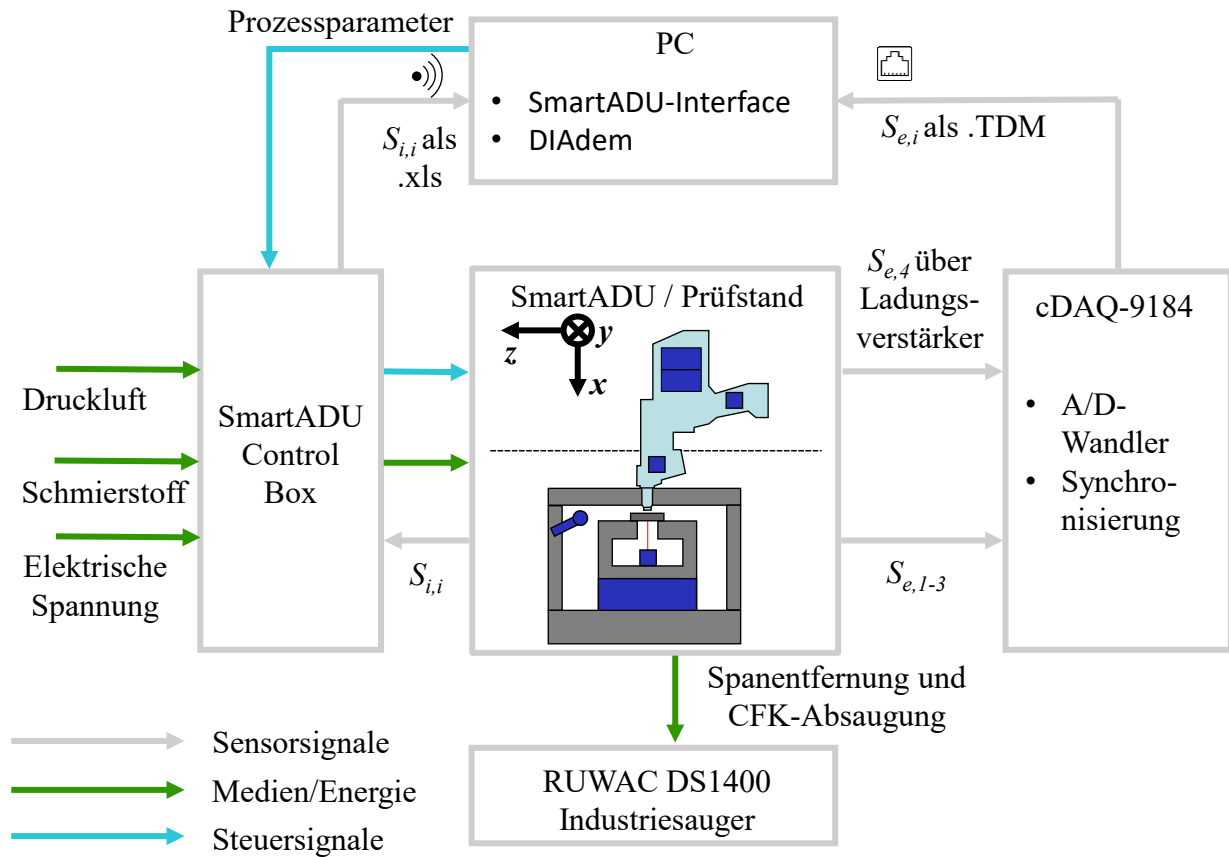


Abbildung 5.9: Flussdiagramm zum Gesamtsystem des SmartADU-Versuchsstands ($S_{i,i}$ = interner SmartADU-Sensor i , $S_{e,i}$ = externer Sensor i)

5.1.3 Versuchswerkstoffe und -werkzeuge

Im Folgenden werden die eingesetzten Versuchswerkstoffe und -werkzeuge näher spezifiziert.

5.1.3.1 Versuchswerkstoffe

Zur Erstellung der Datenbasis werden vier luftfahrttypische Leichtbauwerkstoffe gemäß Abschnitt 3.1.1 bearbeitet. Dabei handelt es sich um die Titanlegierung *Alternativbezeichnungen Ti64 (Ti-6Al-4V / Ti6Al4V / TiAl6V4)*, die Aluminiumlegierung *Al2024*, sowie jeweils einen kohlenstofffaserverstärkten Kunststoff *CFK* mit einer duroplastischen (bezeichnet als *CFK-D*) und thermoplastischen Matrix (bezeichnet als *CFK-T*). Diese Werkstoffe sind in der Abbildung 5.10 visualisiert und im Folgenden näher spezifiziert. Pro Materialprobe werden im Versuchsbetrieb bis auf wenige Ausnahmen 20 Durchgangsbohrungen in einem Abstand von etwa $d_B \approx 14$ mm eingebracht. Bedingt durch die manuelle Verschiebung der Proben ergibt sich zwar eine Varianz von d_B , die jedoch zur Überprüfung der Robustheit der entwickelten ML-Algorithmen gegenüber variierender Bauteilsteifigkeit beiträgt.

Die Versuchsträger werden als Materialstreifen mit den in der Abbildung 5.10 aufgezeigten Dimensionen präpariert. Während die Probenlänge l und -breite b bei allen (streifenförmigen) Proben annähernd gleiche Werte annehmen, variiert die Probendicke h materialspezifisch.




Abbildung 5.10: Untersuchte Leichtbauwerkstoffe und deren Abmessungen [Hin+22]

Al2024 ist eine Aluminiumlegierung mit den Hauptzusätzen Kupfer und Magnesium (auch bezeichnet: AlCuMg2; nach AMS-Norm: 4165; Werkstoffnummer: 3.1354 - T4) und ist eine der am meisten universell verwendeten Aluminiumlegierungen im Flugzeugbau [Eng18]. Die Bohrstreifen haben eine Dicke $h = 6$ mm. Materialspezifische Kennzahlen sind in der Tabelle A.6 im Anhang A.2.1 aufgelistet.

Ti64 ist eine Titan-Aluminium-Vanadium-Legierung (auch bezeichnet: TiAl6V4; nach AMS-Norm: 4911; Werkstoffnummer: 3.7164.1), die aufgrund der bereits im Abschnitt 3.1.1 beschriebenen Eigenschaften die am häufigsten verwendete Titanlegierung, insbesondere im Luftfahrtbereich, ist [LW07, S. 250], [Eng18]. Deren Eigenschaften sind in der Tabelle A.6 im Anhang A.2.1 zusammengefasst. Die Bohrstreifen haben eine Dicke $h = 4,1$ mm.

In modernen Flugzeugen werden je nach Modell komplette Rumpfschalen aus CFK mit duromerer Matrix hergestellt, zudem stellt diese Matrixart den dominierenden Marktanteil bei CFK-Werkstoffen dar [Hin21a, S. 10]. Daher wird das Endlosfaser-Verbundmaterial mit

der Herstellerbezeichnung *HexPly® M21E-IMA-34-194* in die Untersuchungen einbezogen, welches im Autoklavverfahren hergestellt wurde. Die CFK-Bohrproben haben eine multiaxiale Faserorientierung bestehend aus 22 Prepreg-Schichten. Der exakte Materialaufbau und die dazugehörigen Materialeigenschaften sind in Tabelle A.7 im Anhang A.2.2 aufgelistet.

CFK-Bauteile mit thermoplastischer Matrix werden beispielsweise für das Fügen der Außenschalen mit den inneren Strukturelementen im Flugzeugbau verwendet. Ein geringer Anteil der Versuchsbohrungen ist in dieser Materialgruppe gefertigt, da der Anteil thermoplastbasierter FVK im Vergleich zu den duromerbasierten Materialien signifikant niedriger ist, siehe Abschnitt 3.1.1. Trotz lückenhafter herstellereitiger Materialspezifikation ist eine Bearbeitung dieses Werkstoffs ebenfalls zur Vergrößerung der Datenbasis erkenntnisbringend (siehe Tabelle A.7 im Anhang A.2.2).

5.1.3.2 Versuchswerkzeuge

Fast alle Durchgangsbohrungen ($\approx 99\%$) werden mit dem unbeschichteten, zweischneidigen Hartmetall-Wendelbohrer *KS-HB-04937-01* des Herstellers *CERATIZIT* ausgeführt. Der restliche Bohrungsanteil wird mit der diamantbeschichteten, jedoch geometrisch gleichen Bohrervariante *KS-HB-04937-02* ausgeführt. Diese beschichtete Bohrervariante ist aufgrund einer Verwendung in früheren Versuchsreihen bereits zum Teil verschlissen. Die rechtsschneidenden Wendelbohrer (nach [DIN 6539]) verfügen über eine ausgespitzte Querschneide mit korrigierter Hauptschneide (*Kegelmantelanschliff Form B* nach [DIN 1412]). Auf beiden Hauptschneiden sind asymmetrisch Spanteiler eingebracht. Beide Varianten, welche als Modell in der Abbildung 5.11 und als Fotoaufnahme in der Abbildung 5.12 dargestellt sind, repräsentieren industrierelevante Werkzeuge in der Luftfahrtproduktion. Die Bohrwerkzeuge sind aus der Schneidstoffsorte *EMT210* des Herstellers *EXTRAMET* hergestellt. Sie sind laut dem Hersteller für den Einsatz in Titan/CFK-Werkstoffpaketen primär vorgesehen, jedoch ist deren Anwendungsgebiet innerhalb dieser Arbeit auf den Werkstoff Aluminium erweitert. Der Schneidstoff besteht aus einem Feinstkornhartmetall der Schneidstoffgruppe *HF*, welcher eine Korngröße von $\approx 0,8\ \mu\text{m}$ aufweist. Dieser setzt sich chemisch aus 89% Wolframcarbid, 10% Cobalt und 1% weiterer Zusatzcarbide zusammen [Ext22].

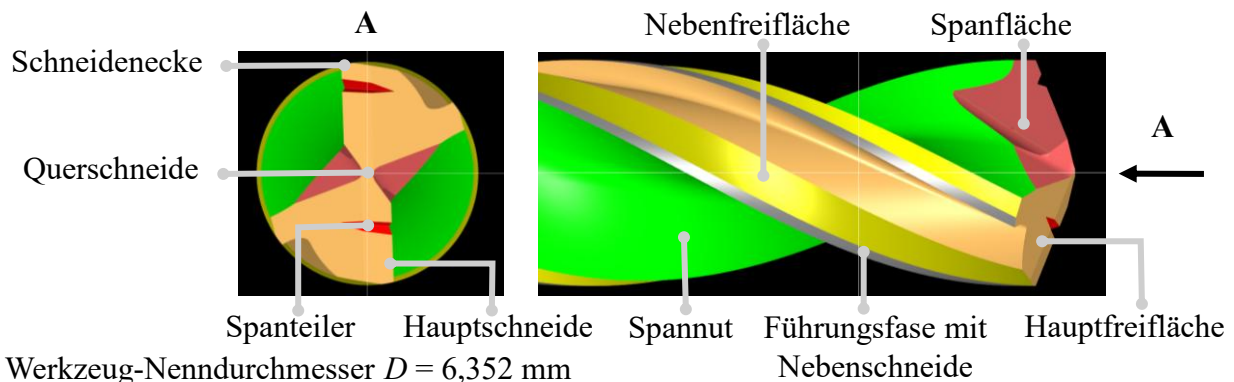




Abbildung 5.11: CAD-Modell der geometrisch identischen Versuchswerkzeuge *KS-HB-04937-01* und *KS-HB-04937-02* [Sch19]

Zur Aufnahme in die Maschine verfügen die Bohrwerkzeuge über einen glatten Zylinderschaft. Zudem sind Kanäle zur Innenkühlung vorhanden. In den Versuchen werden 9 Exemplare des Werkzeugtyps *KS-HB-04937-01* und ein Exemplar des Werkzeugtyps *KS-HB-04937-02* eingesetzt. Deren Verwendung innerhalb des Versuchsplans ist im Abschnitt 5.1.4 erläutert. Die



(a) Bohrertyp KS-HB-04937-01



(b) Bohrertyp KS-HB-04937-02

Abbildung 5.12: Versuchswerkzeug-Typen

spezifischen Eigenschaften der Bohrwerkzeuge sind ausführlich in der Tabelle A.8 im Anhang A.3 zusammengetragen. Aufgrund mehrerer Werkzeugexemplare gleichen Typs werden darin die Längenangaben (Gesamtlänge l und Schneidlänge l_3) und die Schneidkanten-Abflachung Δr in einem Intervall angegeben. Die Durchmesserermessung in dieser Untersuchung ist nicht von Interesse, da die Bestimmung des finalen Bohrlochdurchmessers mittels ML-basierter Überwachung erfolgen soll. Da der Nominal-Durchmesser D_{nom} der Bohrungen 6,352 mm beträgt, bezieht sich die spätere Qualitätsauswertung auf diesen Wert.

5.1.4 Versuchsdurchführung und Datenbasis-Generierung

Die Schaffung einer Datenbasis, deren Eigenschaften im Idealfall denen der zukünftigen Daten entsprechen, stellt die Grundlage für das ML-Modelltraining und damit für die Erstellung eines zuverlässigen Monitoringsystems dar. Zu diesem Zwecke werden 1722 Durchgangsbohrungen in 5 Versuchsreihengruppen, die 44 Versuchsreihen umfassen, ausschließlich mittels Vollbohren gefertigt. Da die zugrunde liegenden Ergebnisse der Versuchsreihen aus unterschiedlichen Zeitpunkten resultieren, erhöht die unsystematische Versuchsreihengestaltung die Schwierigkeit für die ML-Algorithmen, den Zusammenhang zwischen Sensordaten und Zielgrößen herzustellen. Damit werden mögliche reale variable Produktionsumgebungen simuliert.

5.1.4.1 Versuchsreihen und deren Gruppierung

Die Einzelversuchsreihen sind zu 5 Gruppen in der Tabelle 5.3 zusammengefasst. Obwohl jede Versuchsreihengruppe sich in ihrem Fokus, Werkstoff und ggf. Sensoreinsatz unterscheidet, sei hiermit betont, dass die Daten jeder Versuchsreihe zu der Gesamtdatenbasis fusioniert werden und die Zielgrößenbestimmung, sofern nicht anders definiert, grundsätzlich auf allen Daten basiert. Zur Eindeutigkeit der Begriffsdefinitionen *Schnittparameter*, *Prozessbedingung* und *Prozesszustand* wird folgende Unterscheidung eingeführt:

- *Schnittparameter* = Parameter des mechanischen Zerspanprozesses: Schnittgeschwindigkeit v_c , Vorschub pro Werkzeugumdrehung f und Peck-Feed-Amplitude A_{PF}
- *Prozessbedingung* = Randbedingung des Zerspanprozesses: Werkstoff W , Schmierungs-zustand L , Kontakt Bohrmaschinen-Spannhülse (CC) mit der Materialprobe ja / nein (dazugehörige Logikvariable c_{CC}) und Aufspannweite der Materialprobe d_c
- *Prozesszustand*: Oberbegriff für Schnittparameter und Prozessbedingungen

In den weiterführenden Abschnitten werden die Versuchsreihengruppen mit den eingeschlossenen Versuchsreihen näher erläutert. Die Reihenfolge der Erläuterung entspricht dem zeitlichen Ablauf der Untersuchungen.

Tabelle 5.3: Gruppierung der Versuchsreihen

Fokus (Gruppe)	Kürzel	Bohrungen	Kurzerklärung
Prozesszustand-Variation (P)	P1a - P9c	401	vielfältige Schnittparameter- und Prozessbedingungen-Variation; sämtliche Werkstoffe
Ti64 (Q-Ti64)	Q1 - Q1e	330	} Bearbeitung des jeweiligen Materials bei Variation des Prozesszustandes
CFK-D (Q-CFK-D)	Q2 - Q2e	326	
Al2024 (Q-Al2024)	Q3 - Q3e	325	
Bohranomalien (A)	A1 - A5	340	Einbringung regelmäßiger Anomalien; sämtliche Werkstoffe

Versuchsreihengruppe P: Breite Variation des Prozesszustands

In der Versuchsreihengruppe P liegt der Fokus auf einer breiten Variation des Prozesszustands, siehe die dazugehörige Zusammenfassung des Versuchsplans in der Tabelle A.9 des Anhangs A.4.1. Die Prozesszustände variieren teilweise systematisch oder zufällig. Die Durchgangsbohrungen werden mit dem Bohrertyp KS-HB-04937-01, von dem die Exemplare am Anfang im Neuzustand vorliegen, hergestellt. Für die Versuchsreihen P1a-P1e wird jeweils ein eigenes Exemplar pro Reihe verwendet, wohingegen die restlichen Versuchsreihen P2a - P9c ausschließlich mit dem gleichen Bohrerexemplar durchgeführt werden. Als externe Sensoren sind der Laser-Distanzsensor (außer in P1c und P1d aufgrund des CFK-Materials), das Mikrofon und das Dynamometer eingesetzt. Der Versuchsplan wurde in der Masterarbeit von MOLKENTIN [Mol21] ausgeführt und in [Hin+21] veröffentlicht.

Versuchsreihengruppe Q-Ti64: 6 Variationen der Prozesszustände beim Bearbeiten von Ti64

Innerhalb dieser Versuchsreihengruppe wird ausschließlich der Werkstoff Ti64 bearbeitet. Der verwendete Versuchsplan, welcher zum Teil in der Masterarbeit von JUNGHANS [Jun22b] ausgeführt und [JRH23] veröffentlicht wurde, ist in der Tabelle A.10 im Anhang A.4.2 dargestellt. Die verwendeten Bohrwerkzeuge des Typs KS-HB-04937-01 sind zu Beginn der Nutzung im nachgeschliffenen Zustand. Die Tabelle A.10 im Anhang A.4.2 zeigt den großen Anteil der Durchgangsbohrungen mit den industrierelevanten Schnittparametern und Prozessbedingungen der Versuchsreihe Q1 im Gegensatz zu den anderen Versuchsreihen Q1a-Q1e, die teilweise Schnittparameter anderer Werkstoffe enthalten. Im Vergleich zu der Versuchsreihengruppe P wird in der Gruppe Q zusätzlich der G-Sensor als externes Messgerät verwendet.

Versuchsreihengruppe Q-CFK-D: 6 Variationen der Prozesszustände beim Bearbeiten von CFK-D

In dieser Versuchsreihengruppe wird der Werkstoff CFK-D (CFK-Material mit duromerer Matrix) bearbeitet. Ähnlich der Gruppe Q-Ti64 wird ein großer Teil der Durchgangsbohrungen zu der Basis-Versuchsreihe Q2 und ein geringerer Teil zu den Variationen Q2a-Q2e zugeordnet, siehe der Versuchsplan in der Tabelle A.11 des Anhangs A.4.3. Der Versuchsplan wurde zum Teil in der Masterarbeit von JUNGHANS [Jun22b] ausgeführt und in [JRH23] veröffentlicht. Hierbei wird das CFK-Material zum Teil mit den Prozessparametern anderer Werkstoffe bearbeitet. Der verwendete Bohrwerkzeug-Typ ist ausschließlich KS-HB-04937-01, wobei jegliche Durchgangsbohrungen mit dem gleichen zum Anfang nachgeschliffenen Exemplar ausgeführt werden. Aufgrund der Oberflächeneigenschaften des vorliegenden CFK-Werkstoffs ist eine Laser-Distanzmessung zur Bestimmung der Werkstückbewegung nicht möglich.

Versuchsreihengruppe Q-Al2024: 6 Variationen der Prozesszustände beim Bearbeiten von Al2024

In dieser Versuchsreihengruppe wird der Aluminiumwerkstoff Al2024 mit einem Exemplar des Bohrertyps KS-HB-04937-01 bearbeitet. Auch in dieser Versuchsreihe entsteht der Großteil der Durchgangsbohrungen mit Schnittparametern und Prozessbedingungen aus der Industriepaxis sowie ein kleinerer Teil unter abweichenden Bedingungen, die sich an der Bearbeitung von Titan- und CFK-Werkstoffen orientieren, siehe der entsprechende Versuchsplan in der Tabelle A.12 im Anhang A.4.4. Der Versuchsplan wurde zum Teil in der Bachelorarbeit von VOLKMANN [Vol22] ausgeführt. Ab dieser Versuchsreihe wird das Dynamometer nicht mehr als externer Sensor eingesetzt. Basierend auf den Ergebnissen in [Dob19], worin eine verlässliche Korrelation zwischen dem Vorschubmotorstrom der SmartADU I_{VM} und der Vorschubkraft F_f sowie dem Spindelmotorstrom der SmartADU I_{SM} und dem Schnittmoment M_c nachgewiesen wurde, wird ab der Versuchsreihengruppe Q-Al2024 aus Gründen der Redundanzvermeidung und Datenvolumenreduktion auf die Dynamometeraufnahmen verzichtet.

Versuchsreihengruppe A: Gezielte Einbringung von Anomalien bei Bearbeitung aller Werkstoffe

Innerhalb dieser Versuchsreihengruppe wird in jedem Werkstoff ein definierter Satz an Bohranomalien, auf die im Folgenden eingegangen wird, mit dem Bohrertyp KS-HB-04937-01 (Versuchsreihen A1-A4) oder mit dem Bohrertyp KS-HB-04937-02 (Versuchsreihe A5) eingebracht. Der Versuchsplan, welcher in der Masterarbeit von SCHIBSDAT [Schi23] abgearbeitet und in [SR23] veröffentlicht wurde, ist in Tabelle A.13 im Anhang A.4.5 dargestellt. Der Einsatz des diamantbeschichteten Bohrers KS-HB-04937-02 für vergleichsweise wenige Bohrungen ist in dem Abschnitt 5.1.3.2 begründet. Sämtliche verwendeten Bohrerexemplare sind zum Anfang der Versuchsreihen bereits benutzt.

Neben den in der Abbildung A.7 des Anhangs A.5 für die Versuchsreihen-Gruppe A beispielhaft dargestellten, in regelmäßigen Abständen während der Versuchsdurchführung innerhalb der Versuchsreihen-Gruppe A erzeugten Fehlbohrungen, (deren Summe und Anteil in der Versuchsreihen-Gruppe A ist: 37 ($\approx 11\%$)) sind ebenfalls in den restlichen Versuchsreihen-Gruppen wenige unbeabsichtigte Anomalien dokumentiert, die damit ebenfalls der Gesamtdaten-Basis zugeflossen sind. In der Summe über alle Durchgangsbohrungen hinweg ergeben sich damit 50 Anomalien.

5.2 Überwachungs-Kenngrößen und deren offline-Messdatenaufnahme

Zur Erzeugung anforderungsgerechter Bohrungen wird in dieser Arbeit eine mehrstufige Prozessüberwachung verfolgt, deren Bestandteile und Abfolge in der Abbildung 5.13 dargestellt und in der Tabelle 5.4 näher spezifiziert sind.

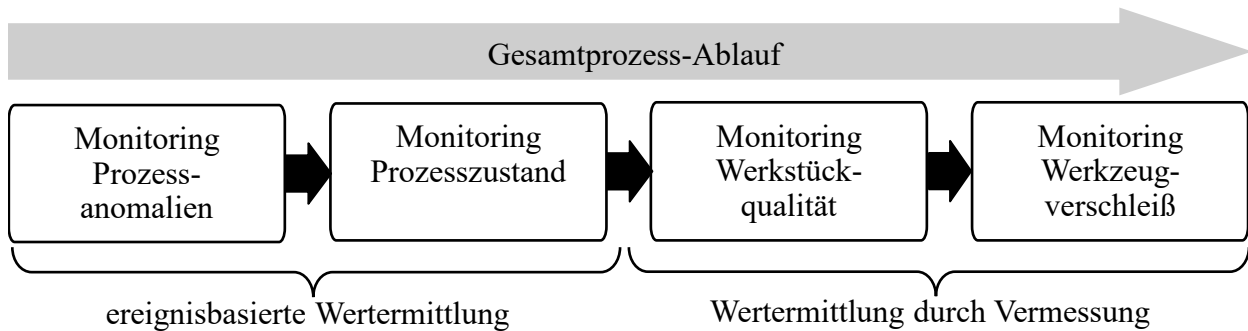


Abbildung 5.13: Gruppen der Überwachungs-Kenngrößen bei der Prozessüberwachung (zur spezifischen Auflistung einzelner Zielgrößen jeder Gruppe sei auf die Tabelle 5.4 verwiesen)

Die Erkennung einer *Prozessanomalie* wird hierbei als primäres Ziel angesehen, da hierbei die Gefahr von Schäden an der Maschine, dem Werkzeug oder dem Werkstück auftritt [Klo18]. Bei der Erkennung einer Anomalie muss der Prozess sofort unterbrochen und das System auf mögliche Schäden überprüft werden. Sollte keine Anomalie auftreten, ist die Kenntnis über den *Prozesszustand* im nächsten Schritt essentiell. Dabei soll sichergestellt werden, ob z. B. die Schnittparameter richtig eingestellt und die Prozessbedingungen (z. B. wird der vorgesehene Werkstoff bearbeitet?) korrekt sind. Bei einem ordnungsgemäßen Prozess ist die Kenntnis der *Werkstückqualität* notwendig. Abschließend ist die Beurteilung des *Werkzeugverschleißes* von Interesse, um möglicherweise einen Werkzeugwechsel oder eine Prozessparameteranpassung vor dem nächsten Arbeitsschritt durchzuführen.

Die Zielgrößen der Gruppen Prozessanomalie und Prozesszustand werden durch ein Ereignis ermittelt. Bei den Versuchen werden das Auftreten einer Anomalie und die Kennwerte des Prozesszustandes eindeutig dokumentiert, wodurch diese Kenngrößen keine gesonderte Vermessung benötigen. Die möglichen diskreten Zustände sind in der Tabelle 5.4 aufgelistet, wobei die Angabe „n. d.“ beim Monitoring des Prozesszustands im Falle eine Anomalie erfolgt. Die Kenngrößen der Werkstückqualität und des Werkzeugverschleißes werden durch eine offline-Vermessung nach dem Bohrprozess als numerische Messwerte identifiziert. Die Unterscheidung zwischen einer numerischen Vorhersage oder einer diskreten Klasseneinteilung durch ML-Algorithmen wird in dem Kapitel 6 vorgestellt.

Die einzelnen Überwachungs-Kenngrößen, ihre Messverfahren sowie die dabei eingesetzten Messgeräte werden im Folgenden näher erläutert. Dazu erfolgt der Hinweis, dass die Überwachungs-Kenngrößen bei allen Versuchsreihen aufgenommen werden und die Reihenfolge der nachfolgenden Erläuterung nicht im Zusammenhang mit der Abfolge der einzelnen Versuchsreihen steht, sondern sich an dem in der Abbildung 5.13 definierten Ablauf der Prozessmonitoring-Stufen orientiert. Die Überwachungs-Kenngrößen der Werkstückqualität und des Werkzeugverschleißes werden nach einer in dieser Arbeit gesondert definierten Systematik benannt, die sich u. U. von der Systematik der Fachliteratur unterscheidet. Der Grund dafür ist eine bessere Übersichtlichkeit innerhalb dieser Arbeit.

Tabelle 5.4: Überwachungs-Kenngrößen (bei den Gruppen Prozessanomalie und Prozesszustand findet die Zuordnung bei allen Werkstoffen statt, ansonsten siehe nähere Erklärung; *: „n. d.“ $\hat{=}$ „nicht definiert“; CC = Concentric Collet)

Gruppe	Kenngröße		mögliche diskrete Zustände / Anmerkungen
Prozessanomalie	Anomaliezustand A_{An}	[–]	keine; doppelt; angebohrt; schräg; nicht durch
Prozesszustand	Werkstoff W	[–]	Ti64; Al2024; CFK-D; CFK-T; n. d.*
	Drehzahl n	[min ⁻¹]	600; 750; 1000; 2000; 3000; 4000; 4500; 6000; n. d.*
	Vorschub pro Werkzeugumdrehung f	[mm]	0,03; 0,05; 0,06; 0,07; 0,08; 0,1; n. d.*
	Aufspannweite d_c	[mm]	0; 57,5; 81,5; 105,5; n. d.*
	Kontakt CC / Werkstück c_{CC}	[–]	ja; nein; n. d.*
	Schmierung L	[%]	0; 1; 100; n. d.*
	Peck-Feed-Amplitude A_{PF}	[μ m]	0; 62,5; 125; n. d.*
Werkstückqualität	Grat Eintritt Q_{GE}	[μ m]	} kontinuierlicher Messwert (Ti64/Al2024)
	Grat Austritt Q_{GA}	[μ m]	
	Bohrungsdurchmesser Q_D	[mm]	} kontinuierlicher Messwert (alle Werkstoffe)
	Mittenrauwert Q_{Ra}	[μ m]	
	Delaminationsfaktor Q_{DF}	[–]	} kontinuierlicher Messwert (nur am Austritt bei CFK-D/CFK-T)
	Faserüberstand-Faktor Q_{FF}	[–]	
	Delaminationsradius-Faktor Q_{DR}	[–]	
Werkzeugverschleiß	max. Verschleißmarkenbreite V_{VB}	[μ m]	} kontinuierlicher Messwert (Ti64/CFK-D/CFK-T)
	Ausbruch Freifläche V_{BA}	[mm ²]	
	Hauptschneiden-Abflachung V_{HA}	[μ m]	} kontinuierlicher Messwert (alle Werkstoffe)
	Querschneiden-Abflachung V_{QA}	[μ m]	
	Hauptschneiden-Volumen V_{HV}	[mm ³]	

5.2.1 Monitoring von Prozessanomalien

Mit Prozessanomalien werden in dieser Arbeit grobe fehlerhafte Vorkommnisse bezeichnet, die eine sofortige Überprüfung nicht nur des Werkstücks, sondern auch des gesamten Systems (Werkzeug, Maschine, Peripherie) erfordern. Die Erzeugung der experimentellen Daten sowie die Methodenentwicklung im Bereich der Prozessanomalien wurden unter anderem in der Masterarbeit von SCHIBSDAT durchgeführt [Schi23] sowie in [SR23] veröffentlicht. Die Bestimmung des Anomaliezustandes erfolgt durch eine ereignisbasierte Ermittlung ohne Messgeräte-Einsatz.

Die Erläuterung zu den 4 erzeugten Bohranomalien *doppelt*, *angebohrt*, *schräg* und *nicht durch* ist in der Abbildung A.7 im Anhang A.5 dargestellt. Deren Auswahl basiert auf Erfahrung in der Industrie und in der Forschungspraxis am IPMT:

- *doppelt*: Eine neue Bohrung wird genau auf einer bereits fertigen Durchgangsbohrung ausgeführt. Diese Anomalie wird in der Versuchsumgebung simuliert, indem die Materialprobe nach einer durchgeführten Bohrung nicht weitergeschoben wird.
- *angebohrt*: Die neue Bohrung überlagert sich teilweise mit der vorherigen. Dies wird realisiert, indem die Materialprobe nicht ausreichend weitergeschoben wird.
- *schräg*: Die Bohrerachse steht nicht orthogonal zu der Werkstückoberfläche. Dazu wird das Werkstück durch das einseitige Einspannen von definierten Abstandsplättchen um $\approx 3^\circ$ zur z-Achse geneigt (siehe Koordinatenachsen in der Abbildung A.7 im Anhang A.5)
- *nicht durch*: Bei dieser Anomalie durchdringt der Bohrer den Werkstoff nicht, was als Ergebnis zu einer ungewollten Sacklochbohrung führt. Diese Anomalieart kann zudem beim Rausdrücken der Maschine aus der Aufnahme (z. B. Spreizkraft des CC reicht bei zu hohen Vorschubkräften infolge eines sehr fortgeschrittenen Bohrerverschleißes nicht aus; Bohrfutter hat sich gelöst) oder durch falsche Kenntnis der Materialdicke entstehen. In der Versuchsreihengruppe A wird diese Anomalie geplant durch ein Bohrprogramm mit zu geringem Vorschubweg hervorgerufen.

Jede durchgeführte Bohrung erhält als Ergebnis ein Label mit dem Anomaliezustand, der 5 mögliche diskrete Werte, wie in Tabelle 5.4 verzeichnet, annehmen kann. Damit werden 1722 Monitoring-Werte ermittelt.

5.2.2 Monitoring des Prozesszustandes

Bei der Überwachung des Prozesszustandes soll sichergestellt werden, ob ein bereits grundsätzlich funktionierender Bohrprozess gemäß den Vorgaben abläuft. Im Abschnitt 5.1.4.1 erfolgt die Definition der Schnittparameter und der Prozessbedingungen. Das Monitoring der Schnittparameter ist beispielsweise zur Einhaltung der spezifizierten Schnittbedingungen sicherzustellen. Mit der Kenntnis der Prozessbedingungen wird eine ordnungsgemäße Einstellung der Peripherie und des Fertigungsablaufs sichergestellt. Beispielhaft können hierzu folgende Szenarien überprüft werden:

- gebohrter Werkstoff \rightarrow bei Abweichung: Prüfung des Bohrorts
- Status der Schmierung \rightarrow bei Abweichung: Prüfung der Schmiermittelvorrats

- Kontakt der Bohrmaschinen-Spannhülse (CC) mit dem Werkstück \rightarrow bei Abweichung: Werkerhinweis, das diese Vorgabe möglicherweise für die nächste Bohrung beachtet werden soll und die aktuelle Bohrung gesondert auf Qualität überprüft werden muss

In der Tabelle 5.4 sind die Kenngrößen der Prozesszustand-Überwachung mit ihren möglichen diskreten Zuständen zusammengetragen. Neben den Schnittparametern Drehzahl n (äquivalenter Parameter zur Schnittgeschwindigkeit v_c), Vorschub pro Werkzeugumdrehung f und Peck-Feed-Amplitude A_{PF} sind dies die Prozessbedingungen Werkstoff W , Aufspannweite d_c , Schmierungszustand L und Verspannungszustand zwischen Spannhülse der SmartADU und dem Werkstück c_{CC} . Zur ausführlicheren Erklärung dieser Prozessbedingungen sei auf die Abschnitte 5.1.1 und 5.1.2 verwiesen. Die Methodenentwicklung fand zum Teil in der Masterarbeit MOLKENTIN [Mol21] statt und wurde in [Hin+21] veröffentlicht.

Bei jeder der 1722 erstellten Bohrungen kann für jede Kennzahl des Prozesszustandes ein Wert zugeordnet werden. Da während der Versuchsdurchführung 50 anomaliebehaftete Bohrungen entstanden sind, werden jegliche Prozessmonitoring-Kenngrößen bei diesen Bohrungen als „nicht definiert“ (n. d.) markiert, was einen weiteren diskreten Zustand darstellt. Damit wird die Möglichkeit einer alternativen, integrierten Anomalie-Überwachung untersucht.

5.2.3 Monitoring der Werkstückqualität

In dieser Zielgrößen-Gruppe liegt der Fokus auf den relevantesten Qualitätseigenschaften von Durchgangsbohrungen gemäß Abschnitt 2.1.3. Die experimentelle Datenaufnahme sowie die Methodenentwicklung fand zum Teil im Rahmen der studentischen Arbeiten von JUNGHANS und VOLKMANN [Jun22b], [Vol22] statt und wurde in [JRH23] veröffentlicht. In diesem Abschnitt wird auf die Vermessungsroutinen der Kenngrößen eingegangen.

5.2.3.1 Grat am Bohrungsein- und Austritt Q_{GE} und Q_{GA}

Die Messung der Grathöhen am Bohrungsein- und -austritt (Q_{GE} / Q_{GA}) folgt dem gleichen Prinzip und wird mit der mechanischen Feinmessuhr *2046F* des Herstellers *Mitutoyo* ausgeführt. Der Feinzeiger ist auf einer dreibeinigen Auflagevorrichtung montiert, worin der zentrierte Messtaster mit dem Auflagestempel vertikal frei beweglich ist, siehe Abbildung 5.14. Die Vermessung findet nur an nicht anomaliebehafteten Bohrungen in metallischen Werkstoffen statt, da nur hierbei ein Einfluss auf die Qualität der Nietverbindung bei zu hohem Grat entsteht.

Die Kalibrierung der Null-Grat-Lage erfolgt an einer glatten und schmutzfreien Werkstückoberfläche, da die Positionierung während des eigentlichen Messvorgangs ebenso erfolgt. Nach jeder Bohrung wird der Bohrstreifen aus der Einspannung entnommen und beidseitig vermessen. Jede Messung wird an 3 unterschiedlichen um etwa 120° verdrehten Positionen des Bohrungsumfangs wiederholt, da jede Vermessung den Grat etwas zusammendrückt. Als Messergebnis wird der Maximalwert der Messungen genommen. Die Handhabung des Bauteils erfolgt so, dass es zu keiner Berührung des Bohrungsumfangs vor der Messung kommt. Daher erfolgt das Ablegen des Werkstücks an dessen Rändern auf erhöhten Positioniereinheiten.




Abbildung 5.14: Gratvermessung (Messung an jeder nicht anomaliebehafteter Bohrung metallischer Werkstoffe; Gesamtanzahl: 1233)

5.2.3.2 Bohrungsdurchmesser Q_D

Die Vermessung des Bohrungsdurchmessers erfolgt mit dem induktiven Feinzeiger *Extramess 2001* des Herstellers *Mahr*, siehe Abbildung 5.15. Dieser wird manuell durch den Bediener in die Bohrung gesetzt.

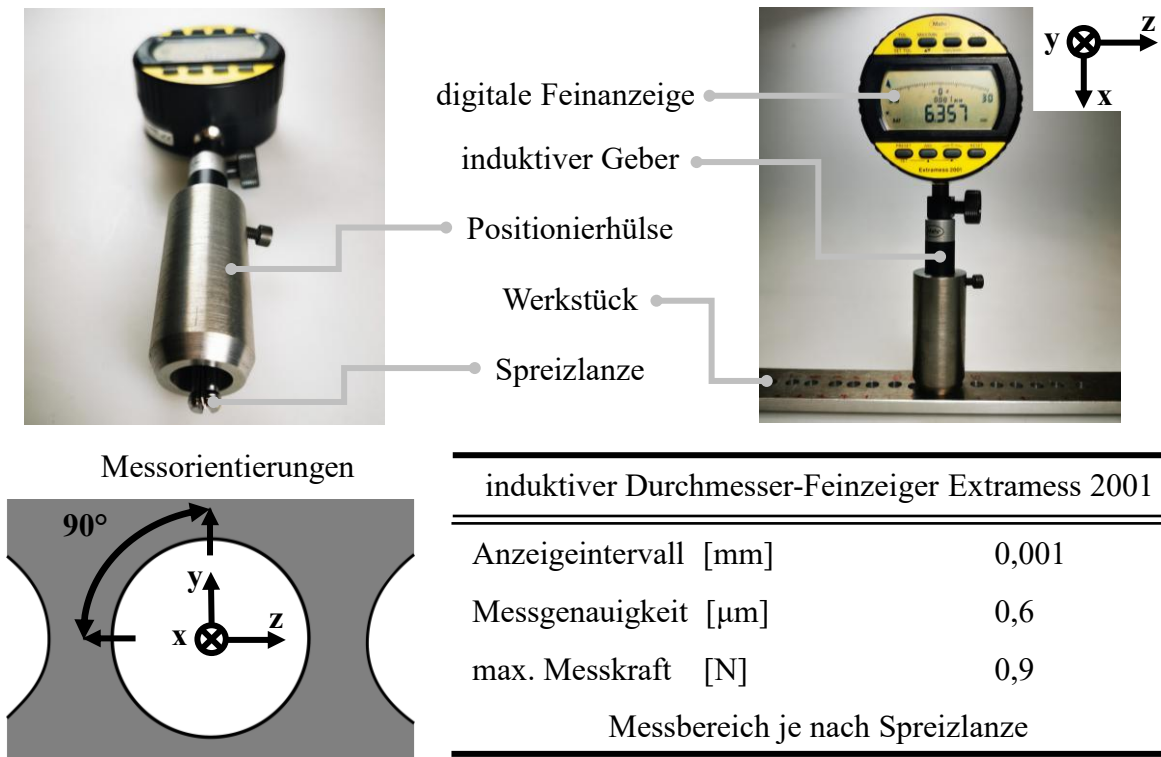


Abbildung 5.15: Durchmesserermessung nach [Jun22b]; Vermessung an jeder nicht anomaliebehafteter Bohrung (Gesamtanzahl: 1672)

Die Aufnahme der Messwerte erfolgt nach dem Reinigen der Durchgangsbohrungen mit Druckluft, um mögliche Spanrückstände und Schmutz zu entfernen. Der Durchmesser Q_D wird durch eine zweiteilige Spreizlanze aufgenommen, indem diese nach dem Einführen in die Bohrung zusammengedrückt und diese Verformung an den induktiven Geber der digitalen Messuhr weitergeleitet wird. Aufgrund der Selbstzentrierung der Messlanze und

einer Positionierhülse wird ein wiederholgenaues axiales Einsetzen des Messgeräts zwischen der Werkstoffeintritts- und -austrittsseite erreicht. Die Messfunktion wird durch den Abgleich mit einem Messnormal regelmäßig kalibriert bzw. validiert.

Die Vermessung erfolgt an jeder nicht anomaliebehafteten Bohrung 2 Mal. Dabei wird das Messgerät, wie in der Abbildung 5.15 gezeigt, um 90° bezogen auf die x -Achse gedreht. Der Messort liegt axial auf der Mitte zwischen den Bohrungsein- und austrittsflächen, was der halben Werkstückdicke entspricht. Die Einzelmesswerte werden zu einer finalen Kennzahl gemittelt.

5.2.3.3 Mittenrauwert an der Bohrungswand Q_{Ra}

Die Aufnahme des Mittenrauerts Q_{Ra} erfolgt mit dem Tastschnittgerät *MarSurfGD 120* des Herstellers *Mahr*. Die Messgröße entspricht dem nach [DIN 1302] definierten Mittenrauwert Ra . Das Messgerät und -vorgehen sind in der Abbildung 5.16 sichtbar.

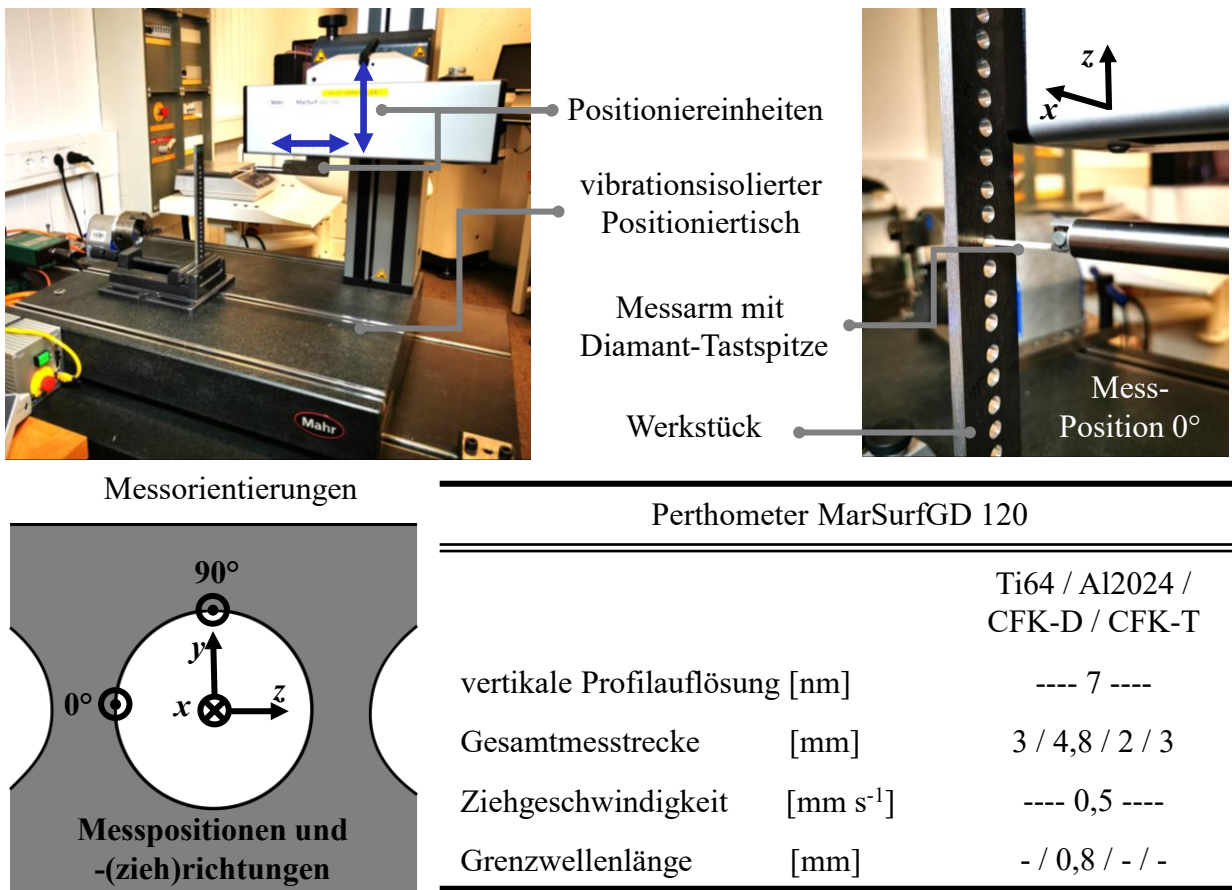


Abbildung 5.16: Rauigkeitsvermessung nach [Jun22b]; Vermessung an jeder nicht anomaliebehafteter Bohrung (Gesamtanzahl: 1672)

In dem horizontal und vertikal positionierbaren Messarm wird die Tastnadel A 4-45-2/90° mit einem Spitzenradius von $r = 2 \mu\text{m}$ und Öffnungswinkel $\alpha = 90^\circ$ eingesetzt, mit der durch das Abfahren der Oberfläche das dazugehörige Profil gemäß dem Ausschlag der Tastnadel, bezogen auf eine Nullposition, detektiert wird. Das Messprofil lässt sich mit der Firmware des Geräteherstellers als Datenscrib oder Protokoll inklusive diverser Kennzahlen exportieren.

Die Vermessung erfolgt an jeder Bohrung, nachdem diese mit Druckluft gesäubert wird. Jede

Durchgangsbohrung wird an 2 Positionen jeweils 2 Mal vermessen, indem die Tastnadel auf einer Mantellinie axial an der Bohrungsfläche entlanggezogen wird. Die Messparameter (siehe Abbildung 5.16) orientieren sich an der [DIN 4288]. Jedoch kann aufgrund der zu geringen Materialdicken t bei Ti64, CFK-D und CFK-T keine vollständig normgerechte Vermessung durchgeführt werden. Die finale Qualitätskennzahl Q_{Ra} einer Bohrung wird durch das Mittel der insgesamt 4 aus dem Messprotokoll entnommenen Rauigkeitskennzahlen Ra gebildet. Ein Beispiel-Messprotokoll ist dazu als Abbildung A.8 im Anhang A.6 eingefügt. Zu Beginn jeder Messreihe wird die Messfunktion durch den Abgleich mit einem Mess-Rauigkeitsnormal validiert.

5.2.3.4 Delaminationsfaktor am Bohrungsaustritt Q_{DF}

Die Vermessung jeglicher Bohrungsaustritt-Schädigungen (Q_{DF}, Q_{FF}, Q_{DR}) an den CFK-Werkstoffen erfolgt mithilfe der Stereolupe *SZX10* des Herstellers *Olympus*. Dabei wird eine Fotoaufnahme des Bohrungsaustritts erstellt, in dem mithilfe der Messgerät-Software *Stream Motion* aus relevanten Features im Bild wie z. B. Spline- oder Trapezflächen die notwendigen Kennzahlen (z. B. Umfang, Flächeninhalt, ...) extrahiert werden, siehe das dazugehörige Messprinzip in der Abbildung 5.17. Dabei werden am Bohrungsaustritt zuerst die Ausgangs-Messgrößen Fläche der Delamination A_D , Fläche des Faserüberstands A_F und der maximale Radius der Delamination $R_{D,max}$ ausgelesen. Der Delaminationsfaktor Q_{DF} wird schließlich als dimensionslose Größe durch das Beziehen der Delaminations-Fläche A_D auf die Bezugsfläche $A_{D,Bez}$ nach Gleichung 5.1 gebildet.

$$Q_{DF} = \frac{A_D}{A_{D,Bez}} \quad (5.1)$$

Die Delaminations-Bezugsfläche $A_{D,Bez}$ wird in Anlehnung an industrierelevante Vorgaben definiert. Bei einem Nominal-Bohrungsdurchmesser von $D_{nom} = 6,352$ mm ist der maximal zulässige Radius der Delaminationsfläche 2,5 mm höher als der Nominal-Bohrungsradius r_{nom} . Damit wird die Delaminations-Bezugsfläche $A_{D,Bez}$ als die Kreisring-Fläche entstehend aus folgender Differenz bestimmt: entstehende Kreisfläche aus dem maximal zulässigen Delaminationsradius abzüglich der Nominal-Bohrungsfläche A_{nom} nach Gleichung 5.2.



$$A_{D,Bez} = \pi \left((r_{nom} + 2,5 \text{ mm})^2 - r_{nom}^2 \right) \quad (5.2)$$

Die Nominal-Bohrungsfläche A_{nom} wird aus dem vorgegebenen Nominal-Durchmesser D_{nom} errechnet. Der Delaminationsfaktor Q_{DF} kann für 464 nicht anomaliebehaftete Bohrungen in CFK-Werkstoffen ermittelt und daraufhin in der ML-Modellierung als numerischer Wert verwendet werden. Je höher Q_{DF} , desto stärkere Decklagenschädigung liegt vor.

5.2.3.5 Faserüberstand-Faktor am Bohrungsaustritt Q_{FF}

Die Vermessungsroutine des Faserüberstand-Faktors am Bohrungsaustritt Q_{FF} erfolgt analog der vom Delaminationsfaktor Q_{DF} . Die Ausgangs-Messgrößen sind in der Abbildung 5.17 aufgezeigt. Für die Berechnung von der dimensionslosen Kennzahl Q_{FF} wird die Fläche des Faserüberstands A_F auf die Nominal-Bohrungsfläche A_{nom} bezogen, siehe Gleichung 5.3.

Versuchsreihe = Q2; Werkstoff = CFK-D; $v_c = 120 \text{ m min}^{-1}$; $f = 0,06 \text{ mm}$; $d_c = 0 \text{ mm}$;
 $c_{CC} = \text{nein}$; $L = 1 \%$; $A_{PF} = 0 \text{ }\mu\text{m}$; Werkzeug = KS-HB-04937-01



Stereolupe SZX10		Ausgangs-Messgrößen	
Vergrößerung	6,3x	Nominal-Bohrungsfläche A_{nom}	[mm ²]
Belichtung	automatisch	Fläche Delamination A_D	[mm ²]
Auflösung	1920 x 2448	Fläche Faserüberstand A_F	[mm ²]
Weißabgleich	ja	max. Radius Delamination $R_{D,max}$	[mm]

Abbildung 5.17: Ausgangs-Messgrößen für Bohrungsaustritt-Schädigung bei CFK-Werkstoffen nach [Jun22b] ($v_c =$ Schnittgeschwindigkeit, $f =$ Vorschub pro Werkzeugumdrehung, $d_c =$ Aufspannweite Werkstück, $c_{CC} =$ Kontaktzustand Maschine/Werkstück, $L =$ Schmierungszustand, $A_{PF} =$ Peck-Feed-Amplitude)

$$Q_{FF} = \frac{A_F}{A_{nom}} \quad (5.3)$$

Auch hier kann das Ergebnis für Q_{FF} direkt in der ML-Modellierung als numerischer Wert verwendet werden. Bei $Q_{FF} = 0$ liegt kein Faserüberstand vor, beim Wert $Q_{FF} = 1$ ist dieser maximal.

5.2.3.6 Delaminationsradius-Faktor am Bohrungsaustritt Q_{DR}

Die Vermessung und Berechnung des Delaminationsradius-Faktors am Bohrungsaustritt Q_{DR} wird analog den bereits beschriebenen Größen Q_{DF} und Q_{FF} durchgeführt. Zuerst wird gemäß Abbildung 5.17 der maximale Radius der Delamination $R_{D,max}$ ausgelesen. Der Delaminationsradius-Faktor Q_{DR} entsteht durch den Bezug von $R_{D,max}$ auf den maximal zulässigen Delaminationsradius $R_{D,max,zul}$ gemäß Gleichung 5.4. Für den vorliegenden nominellen Bohrungsdurchmesser D_{nom} wird ein industriebezogener maximaler Delaminationsradius von $R_{D,max,zul} = R_{nom} + 2,5 \text{ mm}$ festgelegt. Das Ergebnis kann als numerische Überwachungs-Kennzahl für 464 nicht anomaliebehaftete Bohrungen direkt in der ML-Modellierung verwendet werden.

$$Q_{DR} = \frac{R_{D,max}}{R_{D,max,zul}} \quad (5.4)$$

5.2.4 Monitoring des Werkzeugverschleißes

In diesem Teil wird auf die Vermessung des Werkzeugverschleißes eingegangen. Die wichtigsten Verschleißkennzahlen sind gemäß Tabelle 5.4 ausgewählt. Die Vermessung wird durchschnittlich nach etwa jeder 8. Bohrung durchgeführt. Beim Einsatz eines frisch geschliffenen Bohrers sind die Vermessungsintervalle enger (\approx jede 3. Bohrung) als bei einem Werkzeug mit einem höheren Standweg (\approx jede 15. Bohrung). Die experimentelle Datenaufnahme sowie die Methodenentwicklung fanden zum Teil im Rahmen der studentischen Arbeiten von JUNGHANS und VOLKMANN [Jun22b], [Vol22] statt und wurden in [JRH23] veröffentlicht.

5.2.4.1 Maximale Verschleißmarkenbreite V_{VB}

Zur Bestimmung der maximalen Verschleißmarkenbreite V_{VB} an der Bohrer-Freifläche wird eine Bildaufnahme des Werkzeugs mit der bereits im Abschnitt 5.2.3.4 beschriebenen Stereolupe SZX10 durchgeführt, siehe Abbildung 5.18. Dabei steht die Sichtachse senkrecht auf der Freifläche, um eine verzerrungsarme Vermessung zu gewährleisten.

Die Vermessung erfolgt an den Bohrerexemplaren des unbeschichteten Werkzeugtyps KS-HB-04937-01, die bei den Werkstoffen Ti64, CFK-D und CFK-T eingesetzt werden. Beim Al2024 eingesetzte Werkzeuge ermöglichen mit dem verwendeten Messgerät keine eindeutige Verschleißmarken-Identifikation. Als finaler Wert für V_{VB} wird der Mittelwert aus den maximalen Verschleißmarkenbreiten der beiden Hauptschneiden gebildet. Dieser kann als numerischer Wert in der weiteren ML-Modellierung direkt verwendet werden.

5.2.4.2 Ausbruch Freifläche V_{BA}

Die ausgebrochene Fläche V_{BA} an den Werkzeug-Freiflächen wird ebenfalls aus den Bildaufnahmen der bereits beschriebenen Stereolupe SZX10 ermittelt, siehe Abbildung 5.18. Vor allem bei der Bearbeitung von Ti64 ist diese Verschleißform präsent. An den Freiflächen werden die Ausbruchflächen an beiden Hauptschneiden-Freiflächen mittels Spline-Interpolation segmentiert und zu einer Gesamt-Ausbruchfläche V_{BA} addiert. Als Ergebnis stehen 1457 Beispiele zur Verfügung, die als numerische Werte direkt in der weiteren ML-Modellierung verwendet werden. Hierbei kommt die Besonderheit zum Tragen, dass falls sich der Wert für V_{BA} zwischen zwei Vermessungen nicht ändert, jegliche Werte für V_{BA} zwischen diesen Bearbeitungsdurchgängen gleichgesetzt werden können.

5.2.4.3 Hauptschneiden-Abflachung V_{HA}

Die Vermessung der Kennzahlen zur Ermittlung der Hauptschneiden-Abflachung V_{HA} erfolgt mit dem optischem 3D-Messgerät *InfiniteFocus G4* des Herstellers *Alicona*. Hierbei werden die Schneiden der Werkzeuge mittels Fokusvariation und vertikalem Abscannen erfasst. Als Ergebnis entsteht eine 3D-Topografie, die an der Hersteller-Gerätesoftware *MeasureSuite* ausgewertet wird. Das Vorgehen dazu ist im Bild 5.19 aufgezeigt.

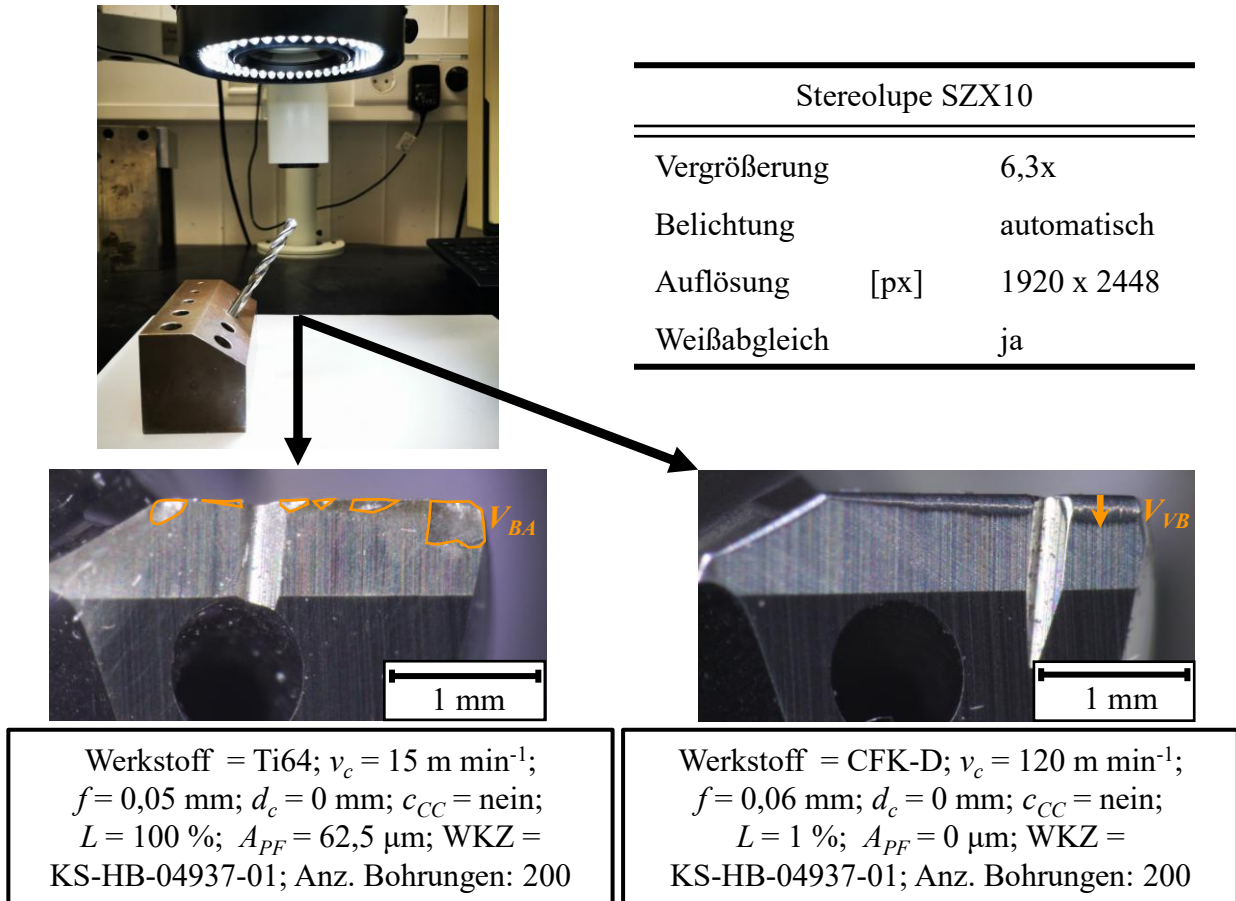


Abbildung 5.18: Verschleißmessung mittels 2D-Werkzeugvermessung an der Stereolupe SZX10 (V_{BA} = Ausbruchfläche an der Freifläche, V_{VB} = maximale Verschleißmarkenbreite, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

Die Ermittlung eines untersuchten Schneidenprofils erfolgt durch das Anlegen aneinandergereihter Schnittebenen orthogonal zum Schneidkanten-Längenverlauf x_W . Durch das Mitteln der erzeugten Profile ergibt sich der finale charakteristische Schneidkantenschnitt, siehe Abbildung 5.20, dessen Koordinaten als Tabellenwerte für eine softwareunabhängige Bearbeitung ausgegeben werden. Aus diesen wird die Hauptschneiden-Abflachung V_{HA} mit MATLAB berechnet. In diesem Zuge erfolgt die Definition der Werkzeugschneiden-Dicken- und Höhenkoordinate x_W und z_W , siehe Abbildung 5.19.

Die Verschleißkenngröße V_{HA} entspricht der Schneidenabflachung Δr aus der Formfaktormethode [Hin21a, S. 29], [Den+02], siehe Abschnitt 2.1.4.3. Diese Größe stellt die Distanz zwischen der Spitze einer ideal scharfer Schneide und dem nächsten Punkt des realen Schneidenprofils dar. In der Abbildung 5.20 ist das in MATLAB automatisierte Verfahren zur Bestimmung von V_{HA} skizziert. Dieses umfasst folgende Schritte:

- Die Profilkurve wird mit dem gleitenden Mittelwert Filter geglättet. Damit wird der Einfluss vom Messrauschen oder von Fehlstellen im Profil eliminiert.
- An beide Profil-Seitenflächen, die der Span- und Freifläche entsprechen, wird eine Tangente angelegt. Die exakte Seitenzuordnung der Span- und Freifläche ist nicht notwendig, da V_{HA} davon unabhängig ist. Der kleinste z_W -Wert der linken Tangente ist der erste Datenpunkt und der kleinste z_W -Wert der rechten Tangente ist der letzte Datenpunkt des Profils. Der größte z_W -Wert der linken Tangente und der größte z_W -Wert

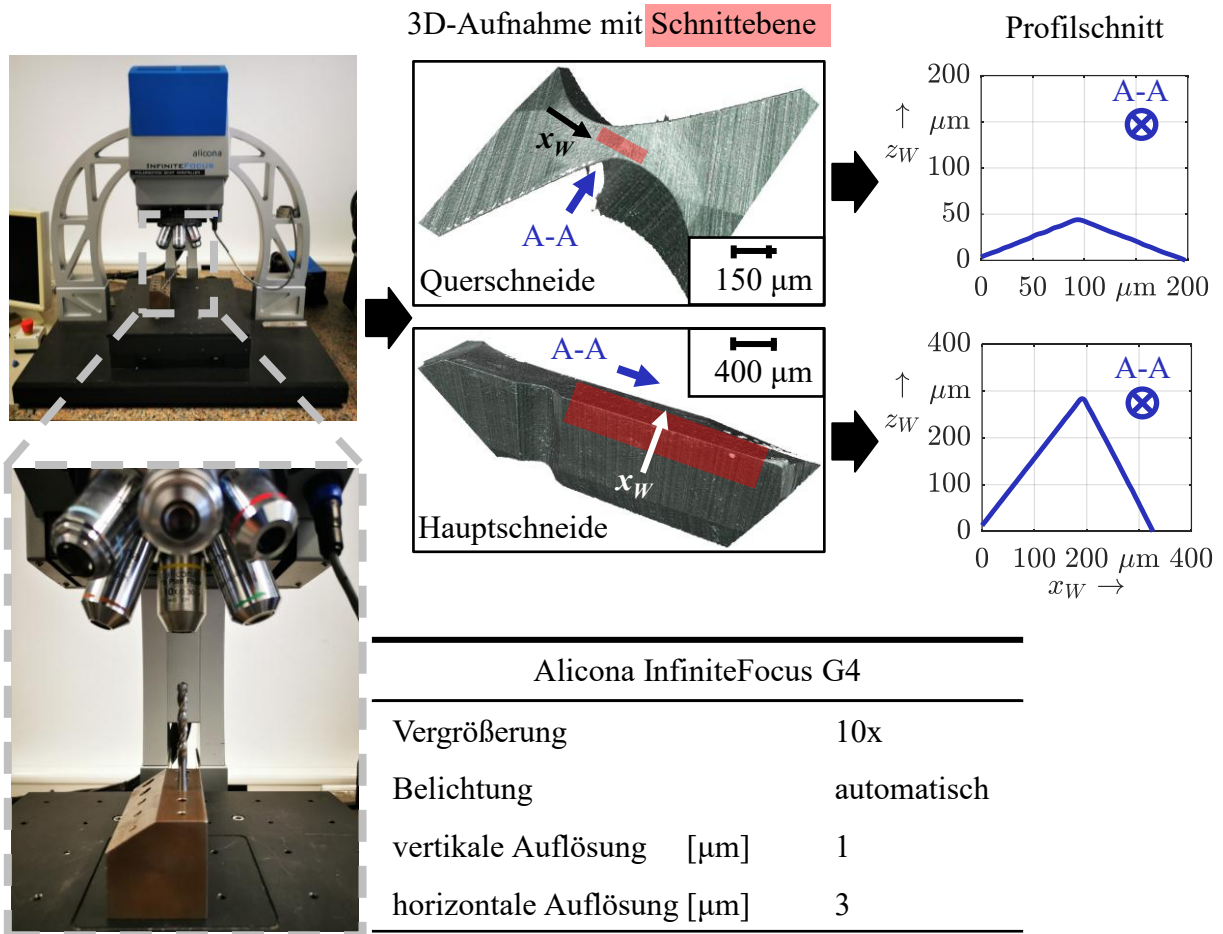



Abbildung 5.19: Verschleißmessung mittels 3D-Werkzeugvermessung am Alicona InfiniteFocus 4G (x_W = Werkzeugschneide-Dickenkoordinate, z_W = Werkzeugschneide-Höhenkoordinate)

der rechten Tangente wird durch die *findchangepts*-Funktion in MATLAB bestimmt. Hierbei wird eine Signalveränderung anhand einer Änderung der Standardabweichung nach der *Maximum-Likelihood-Methode* detektiert [Mat24a].

- Anschließend erfolgt die Berechnung des Tangenten-Schnittpunkts.
- Zwischen jedem Profilmittel und dem Tangenten-Schnittpunkt wird der euklidische Abstand berechnet. Der kleinste Wert entspricht V_{HA} .


Aufgrund der Spanteiler in den Hauptschnitten entsteht eine Besonderheit beim Setzen der Profilschnitte und dem folgenden Berechnen des mittleren Profils. Wie in der Abbildung 5.21 aufgezeigt, müssen in jeder Hauptschnitte jeweils zwei separate Profilschnitte (im Einzelnen: $S_{1,I}$; $S_{1,A}$; $S_{2,I}$ und $S_{2,A}$) unterschiedlicher Bezugslängen, die durch den Spanteiler getrennt sind, gesetzt werden. Die in der Abbildung 5.21 definierten Bezugslängen $l_{S_{1,A}} = l_{S_{2,I}} = 1,324$ mm und $l_{S_{1,I}} = l_{S_{2,A}} = 0,54$ mm fließen in die Gewichtung der aus den 4 Schneidprofilen ermittelten Abflachungen der Hauptschnitte $V_{HA,i}$ ein, aus denen der finale Wert für V_{HA} mittels gewichtetem arithmetischem Mittel (Gleichung 5.5) errechnet wird.

$$V_{HA} = \frac{V_{HA,S_{1,I}} \cdot l_{S_{1,I}} + V_{HA,S_{1,A}} \cdot l_{S_{1,A}} + V_{HA,S_{2,I}} \cdot l_{S_{2,I}} + V_{HA,S_{2,A}} \cdot l_{S_{2,A}}}{l_{S_{1,I}} + l_{S_{1,A}} + l_{S_{2,I}} + l_{S_{2,A}}} \quad (5.5)$$



Werkstoff = Al2024; $v_c = 120 \text{ m min}^{-1}$; $f = 0,03 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 1 \%$; $A_{PF} = 0 \text{ μm}$; WKZ = KS-HB-04937-01; Bohrungs-ID: Q2c_3; Bohrungsanzahl WKZ : 180

Abbildung 5.20: Automatisierte Bestimmung der Schneidkanten-Abflachung V_{HA} für Hauptschneide 1 im äußeren Segment (x_W = Schneiden-Dickenkoordinate, z_W = Schneiden-Höhenkoordinate, $V_{HV,S1,A}$ = Hauptschneiden-Abflachung der Hauptschneide 1 im äußeren Segment, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, „WKZ“ = Werkzeug)



Werkstoff = Al2024; $v_c = 60 \text{ m min}^{-1}$; $f = 0,1 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{ja}$; $L = 100 \%$; $A_{PF} = 125 \text{ μm}$; WKZ = KS-HB-04937-01; Bohrungs-ID: Q3_180; Bohrungsanzahl WKZ: 180

Abbildung 5.21: 3D-Hauptschneiden-Vermessung (x_W = Schneiden-Dickenkoordinate, $l_{S1,I}/l_{S1,A}/l_{S2,I}/l_{S2,A}$ = definierte Bezugslängen der Schneiden 1/2, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, „WKZ“ = Werkzeug)

5.2.4.4 Querschneide-Abflachung V_{QA}

Die Querschneide-Abflachung V_{QA} wird mit dem gleichen Verfahren wie bei den Hauptschneiden ermittelt. Für jede Querschneide liegt ein einziger durchgängiger Profilschnitt vor. Folglich wird aus diesem der Wert für V_{QA} direkt ermittelt.


5.2.4.5 Hauptschneiden-Volumen V_{HV}

Zur Verschleißbestimmung der Hauptschneiden wird des Weiteren eine verschleißformübergreifende Kennzahl in Form des Hauptschneiden-Volumens V_{HA} ausgewertet [Jun22b]. Basierend auf den in der Abbildung 5.21 definierten Schneidensegmenten wird das segmentweise Rest-Schneidenvolumen $V_{HV,i}$ berechnet und gemäß der Gleichung 5.6 zu dem Volumen der Hauptschneide V_{HV} addiert. Es handelt sich dabei um das Gesamtvolumen der beiden Hauptschneiden. Ein sinkendes V_{HV} ist ein Indiz für Schneidstoffabtrag und damit Werkzeugverschleiß z. B. in Form von Verrundung oder Ausbruch.

$$V_{HV} = V_{HV,S1,I} + V_{HV,S1,A} + V_{HV,S2,I} + V_{HV,S2,A} \quad (5.6)$$

Die Berechnung eines einzelnen Schneiden-Segmentvolumens $V_{HV,i}$ erfolgt automatisiert in MATLAB auf Basis der bereits definierten Schneidensegment-Profile. In folgenden Schritten, die in der Abbildung 5.22 visualisiert sind, wird die Auswertung durchgeführt:

- Das Schneidenprofil wird in der x_W - z_W -Ebene ausgerichtet. Dazu wird das Profil so gedreht, dass die Winkelhalbierende des Keilwinkels parallel zu der z_W -Achse ist.
- Für eine Vergleichbarkeit der Einzelprofile wird ein Referenz-Flächensegment extrahiert, indem das Profil der Schneidkante an der Stelle getrennt wird, wo die Schneidkante eine Breite von $150 \mu\text{m}$ aufweist. Der obere Teil ergibt das Referenz-Flächensegment.
- Das Flächensegment wird genullt und dessen Flächeninhalt $A_{HV,i}$ berechnet.
- die Berechnung von $V_{HV,i} = A_{HV,i} \cdot l_{Si}$ erfolgt mithilfe der Segmentlänge l_{Si} .



Werkstoff = CFK-D; $v_c = 120 \text{ m min}^{-1}$; $f = 0,03 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 100 \%$;
 $A_{PF} = 0 \mu\text{m}$; WKZ = KS-HB-04937-01; Bohrungs-ID: Q2c_3; Bohrungsanzahl WKZ: 268

Abbildung 5.22: Automatisierte Bestimmung des Hauptschneiden-Volumens V_{HV} (x_W = Schneiden-Dickenkoordinate, z_W = Schneiden-Höhenkoordinate, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, $V_{HV,S1,A}$ = Volumen der Hauptschneide 1 im äußeren Segment, „WKZ“ = Werkzeug)

5.3 Zusammenfassung der Versuchsdurchführung und Zielgrößendefinition

In diesem Kapitel wird das experimentelle Vorgehen zur Schaffung der Datenbasis und der Definition der Prozessüberwachungs-Kenngrößen beschrieben. Die Versuchsdurchführung erfolgt bei sehr breiter Prozessparameter- und Prozessbedingungsvariation, was in der Herstellung von 1722 Durchgangsbohrungen resultiert. Die Unterteilung der Prozessüberwachungs-Kenngrößen erfolgt in 4 Gruppen, die in der Abbildung 5.23 farblich dargestellt sind. Des Weiteren wird darin die Anzahl der ermittelten Werte für jede Kenngröße aufgezeigt. Diese variiert, da die Kenngrößengruppen Anomaliezustand und Prozesszustand *ereignisbasiert und prozessparallel* für jede Bohrung ermittelt werden und keine Vermessung erfordern. Die Kenngrößengruppen Werkstückqualität und Werkzeugverschleiß erfolgen *prozessnachgelagert* und erfordern eine gesonderte Vermessung der Werkstücke und Werkzeuge. Die Kenngrößen dieser Gruppen können nicht ausnahmslos bei jedem Werkstoff gleichermaßen ermittelt werden, was zu fallabhängigen Vermessungsintervallen führt. Die aufgenommenen Sensordaten dienen als Datengrundlage für die Trainings-Daten der ML-Modelle. Die experimentell aufgenommenen Prozessüberwachungs-Kenngrößen dienen als Antwort- bzw. Zielgrößen für die ML-basierte Prozessüberwachung.

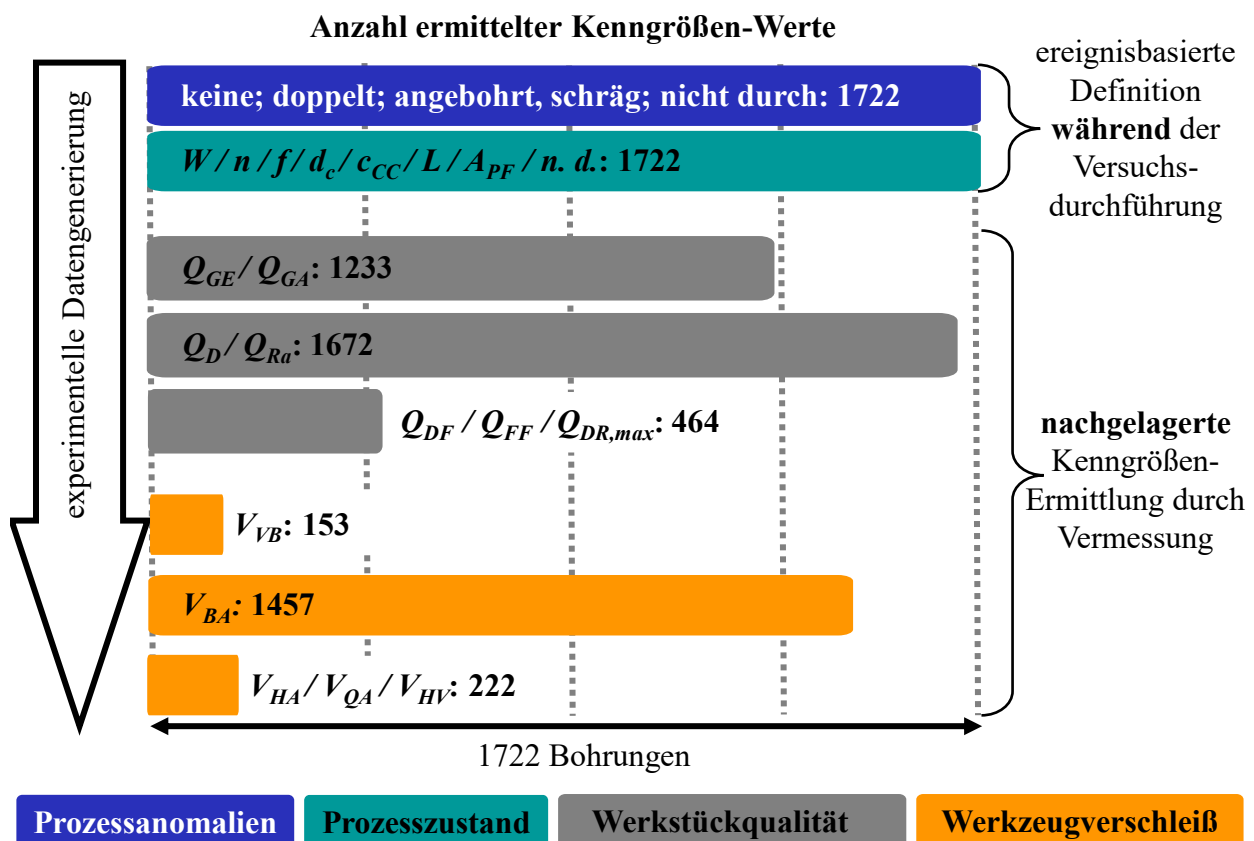


Abbildung 5.23: Zusammenfassung zur Zielgrößenaufnahme (W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierzustand, A_{PF} = Peck-Feed-Amplitude, Q_{GE}/Q_{GA} = Grat Eintritt/Austritt, Q_D = Bohrungsdurchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor, V_{VB} = max. Verschleißmarkenbreite, V_{BA} = Ausbruchsfläche Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen)

6 Modellierung basierend auf dem maschinellen Lernen

Nach der experimentellen Datenerhebung wird mithilfe ML-basierter Methoden eine Auswertepipeline für die Bestimmung der im Abschnitt 5.2 definierten Überwachungs-Kenngrößen implementiert. Hierfür werden 4 unterschiedliche ML-Verfahrensgruppen eingesetzt, siehe dazu die Aufteilung in der Tabelle 6.1. Es sei hierbei erwähnt, dass in diesem Kapitel die nicht selbst ergründeten wissenschaftlichen und technischen Aussagen nicht referenziert werden, falls dies bereits in dem Kapitel 2 erfolgt ist.

Tabelle 6.1: ML-Verfahrensgruppen in Abhängigkeit der Überwachungs-Kenngrößen

ML-Verfahrensgruppe	Gruppe der Überwachungs-Kenngrößen			
	Anomalie	Prozesszustand	Werkstückqualität	Werkzeugverschleiß
unüberwachtes Clustering	ja	ja	nein	nein
unüberwachte Ausreißeridentifikation	ja	nein	nein	nein
überwachte Klassifikation	ja	ja	ja	ja
überwachte Regression	nein	nein	ja	ja

Das *unüberwachte Clustering* wird bei den Überwachungs-Kenngrößen eingesetzt, die ausschließlich durch diskrete Klassen beschrieben werden. Dies ist bei der Anomalie- und Prozesszustand-Bestimmung der Fall.

Die *unüberwachte Ausreißeridentifikation* wird zur Anomaliedetektion eingesetzt. Im Allgemeinen ist bei dieser Verfahrensgruppe eins der Ziele, das Modell anhand der fehlerlosen Daten zu trainieren und die fehlerhaften Beispiele in neuen Daten zu identifizieren.

Die *überwachte Klassifikation* wird zur Einteilung der Überwachungs-Kenngrößen in diskrete Gruppen verwendet. Diese sind bei den Zielgrößen der Anomalien und der Prozesszustände naturgemäß gegeben. Für die Werkstückqualität und den Werkzeugverschleiß ist eine Klasseneinteilung nach festgelegten Grenzen im Hinblick auf Qualitätsanforderungen oder Werkzeugwechselfvorgaben sinnvoll.

Die *überwachte Regression* findet ihren Einsatz zur Vorhersage numerischer Zielgrößen der Werkstückqualität und des Werkzeugverschleißes.

Die Zusatzangaben „unüberwacht/überwacht“ werden durchgängig beibehalten, um die ML-Verfahrensgruppe zu verdeutlichen. Die Klassenverteilungen der Zielgrößen (= Überwachungs-Kenngrößen) dieser Arbeit sind zum Teil ausgeglichen (Prozesszustand, z. T. Werkstückqualität und Werkzeugverschleiß) und zum Teil nicht ausgeglichen (Anomalien, z. T. Werkstückqualität und Werkzeugverschleiß). Daher erfolgt der Einsatz unterschiedlicher ML-Verfahren fürs Monitoring einer Zielgrößengruppe, um die Wirksamkeit verschiedener ML-Verfahrensgruppen zu untersuchen.

In der Abbildung 6.1 sind die Einzelschritte des allgemeinen ML-Modellierungsablaufs dieser Arbeit abgebildet. In den nächsten Abschnitten werden die ML - *verfahrensunabhängigen* Arbeitsschritte Messdatenimport und -aufbereitung, Sensordatenfusion und Feature-Extraktion (Abschnitt 6.2) sowie die ML - *verfahrensspezifischen* Arbeitsschritte Datenset-Einteilung, Feature-Vorbereitung, Feature-Signifikanzanalyse, Modell-Training mit ggf. integrierter Hyperparameteroptimierung, Modell-Evaluation und Modell-Ranking vorgestellt (Abschnitt 6.3). Das Vorgehen spiegelt den im Kapitel 2 vorgestellten ML-Modellierungsablauf, welcher an die Aufgabe dieser Arbeit angepasst ist, wider. Die dabei verwendeten Methodiken wurden zum Teil im Rahmen dieser Dissertation betreuter studentischer Arbeiten untersucht [Mol21], [Jun22b], [Vol22], [Schi23]. Der Abschnitt 6.4 beschreibt den Einfluss der Datensatzgröße auf die Modellierungsergebnisse. Dies geschieht durch die Erzeugung künstlicher Sensordaten und deren Aufnahme in die Gesamt-Datenbasis.

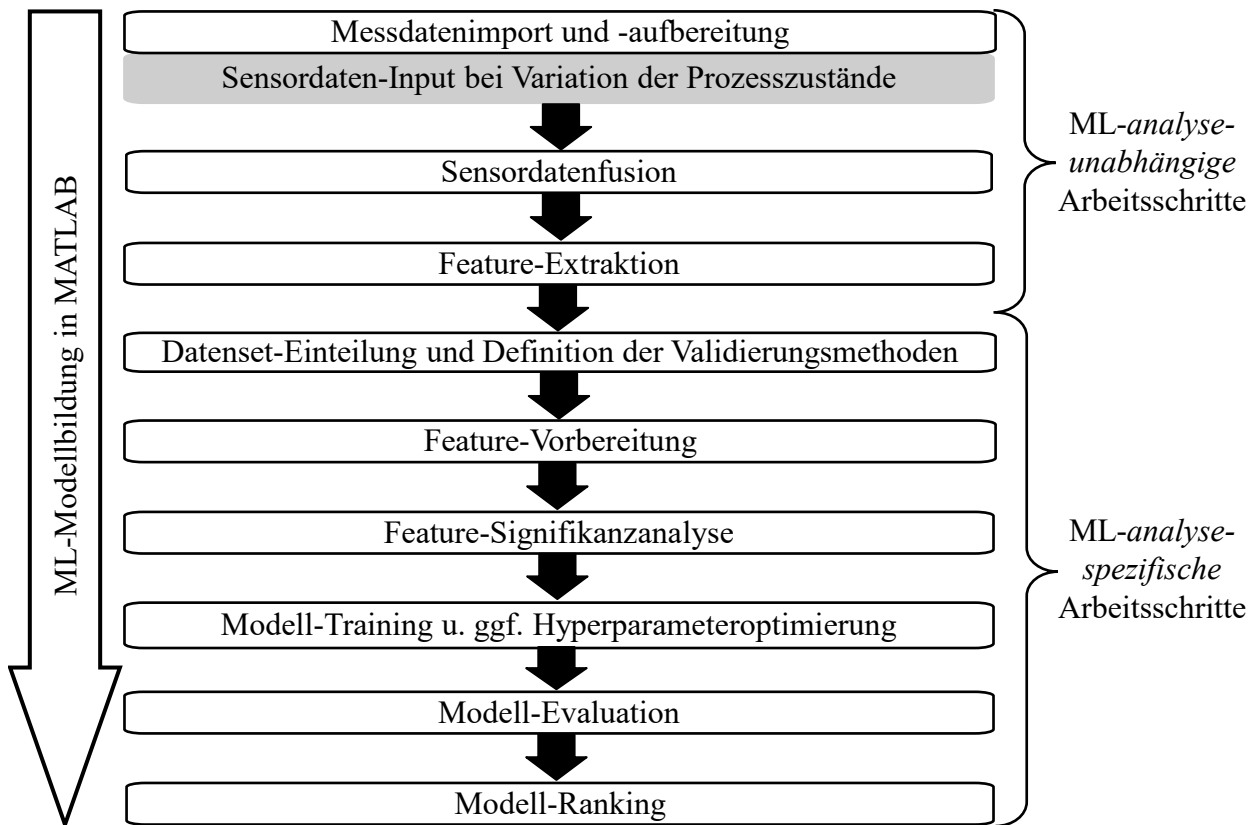


Abbildung 6.1: ML-Modellierungsablauf

6.1 Software- und hardwareseitige Implementierung

Die Datenverarbeitung sowie Implementierung der ML-Algorithmen ist in der Software *MATLAB* des Herstellers *The MathWorks* ausgeführt. Durch die Vielseitigkeit dieser Softwareumgebung, die enthaltenen Bibliotheken für ML-Algorithmen und die Möglichkeit zum parallelen Rechnen können die gesamten daten- und modellierungsbezogenen Arbeitsschritte auf dieser Plattform umgesetzt werden. Das entwickelte Gesamt-Softwarepaket trägt den Namen *ML-ADU-Monitor* und wird in dieser Arbeit fortlaufend so bezeichnet. Neben der Nutzung von *MATLAB*-Bibliotheken und -Funktionen werden auch Routinen eigenständig programmiert. Daher wird bei Anwendung der *MATLAB*-spezifischen Inhalte auf [Mat24a] verwiesen. Diese Referenz gilt stellvertretend auch an anderen Stellen mit *MATLAB*-Bezug, sofern nicht anders ausgewiesen. Bedarfsgerecht werden Inhalte der *Python-Scikit-learn*-Bibliothek eingebunden, falls *MATLAB*-Funktionalitäten nicht ausreichend sind [Sci11].

In der Abbildung 6.2 sind die wesentlichen Ein- und Ausgangsdaten der entwickelten Software skizziert. Als Input dienen folgende Nutzereingaben:

- *.mat config-Datei*: Einstellungen der Datenverarbeitung und ML-Modellierung
- *.xlsx Bohrungs-Metadaten-Datei*: Übergabe der Metadaten jeder Bohrung (individuelle ID, Schnittparameter, Prozessbedingungen, Speicherort der Sensordaten, ...)
- *.xlsx Zielgrößen-Tabelle*: Werte der Überwachungs-Kennzahlen (siehe Tabelle 5.4; diese dienen als Zielgrößen während des Trainings- und Testprozesses)

Der Output der entwickelten Modellierungsroutinen umfasst:

- bearbeitete Datenreihen der Sensoraufnahmen, die z. B. geglättet, zugeschnitten oder durch Einhüllende erweitert werden; eine Erklärung folgt in kommenden Abschnitten
- verarbeitete Sensordaten, aus denen Features und die Trainings-, Validierung- und Test-Sets erzeugt werden; Hyperparameter der erzeugten ML-Modelle
- Ergebnisdokumentation in Form von Plots sowie Tabellendateien zu Evaluation der Einzelmodelle und modellumfassendes Ranking

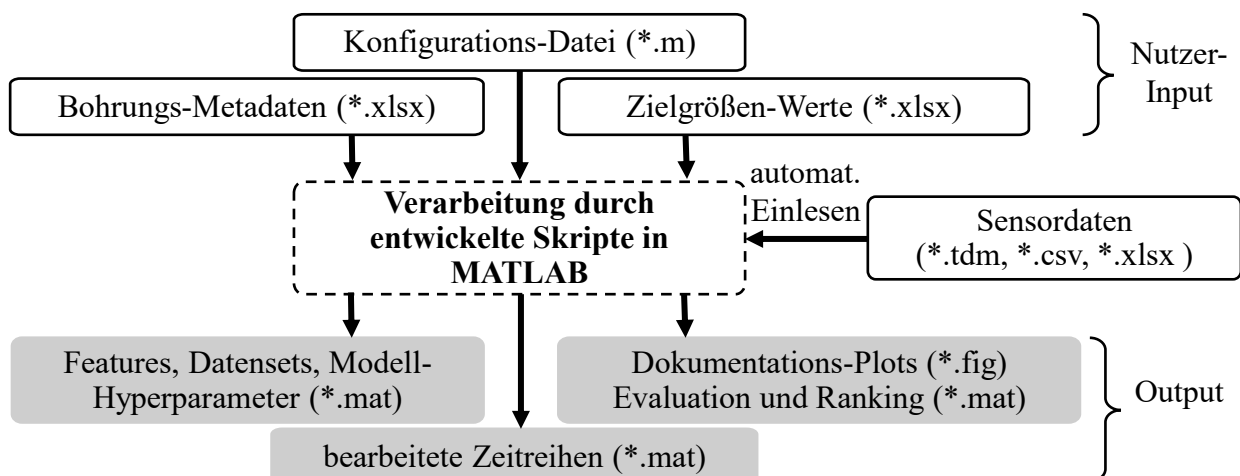


Abbildung 6.2: Ein- und Ausgangsdaten der entwickelten *MATLAB*-Software

Im Anhang A.7 ist die Ordnerstruktur der *ML-ADU-Monitor* Softwareumgebung dargestellt.

Die Datenverarbeitung, das Modelltraining und die nachgelagerte Auswertung werden unter gleichbleibenden Bedingungen an einem Desktop-PC mit den in der Tabelle A.14 im Anhang A.7.2 aufgelisteten Hardware-Spezifikationen durchgeführt. Mit dem vorhandenen 4-Kerne CPU ist der Einsatz von entsprechend 4 parallelen Prozessen, z. B. in Form von for-Schleifen, möglich. Dabei werden die einzelnen Schleifendurchläufe unabhängig voneinander durchgeführt.

6.2 ML-Verfahren-unabhängige Verarbeitungsschritte

Dieser Abschnitt beschreibt die Datenvorbereitung, die Sensorfusion und die Feature-Extraktion, deren Ergebnis als Input für die zu trainierenden machine learning Modelle fungiert. Die folgenden Teilschritte *Messdatenimport und -aufbereitung* (Abschnitt 6.2.1), *Sensordaten-Fusion* (Abschnitt 6.2.2) und *Feature-Extraktion* (Abschnitt 6.2.3) sind unabhängig von der späteren ML-Modellierung. Dies liegt an der umgesetzten universellen Feature-Extraktion, deren Ergebnisse für alle ML-Verfahrensgruppen nutzbar sind.

In der Abbildung 6.3 sind die ML-Verfahren-unabhängigen Schritte in einem höheren Detailgrad als Ausschnitt der Abbildung 6.1 präsentiert. Die implementierte Software ist modular aufgebaut, was die separate Durchführung der Teilschritte erlaubt.

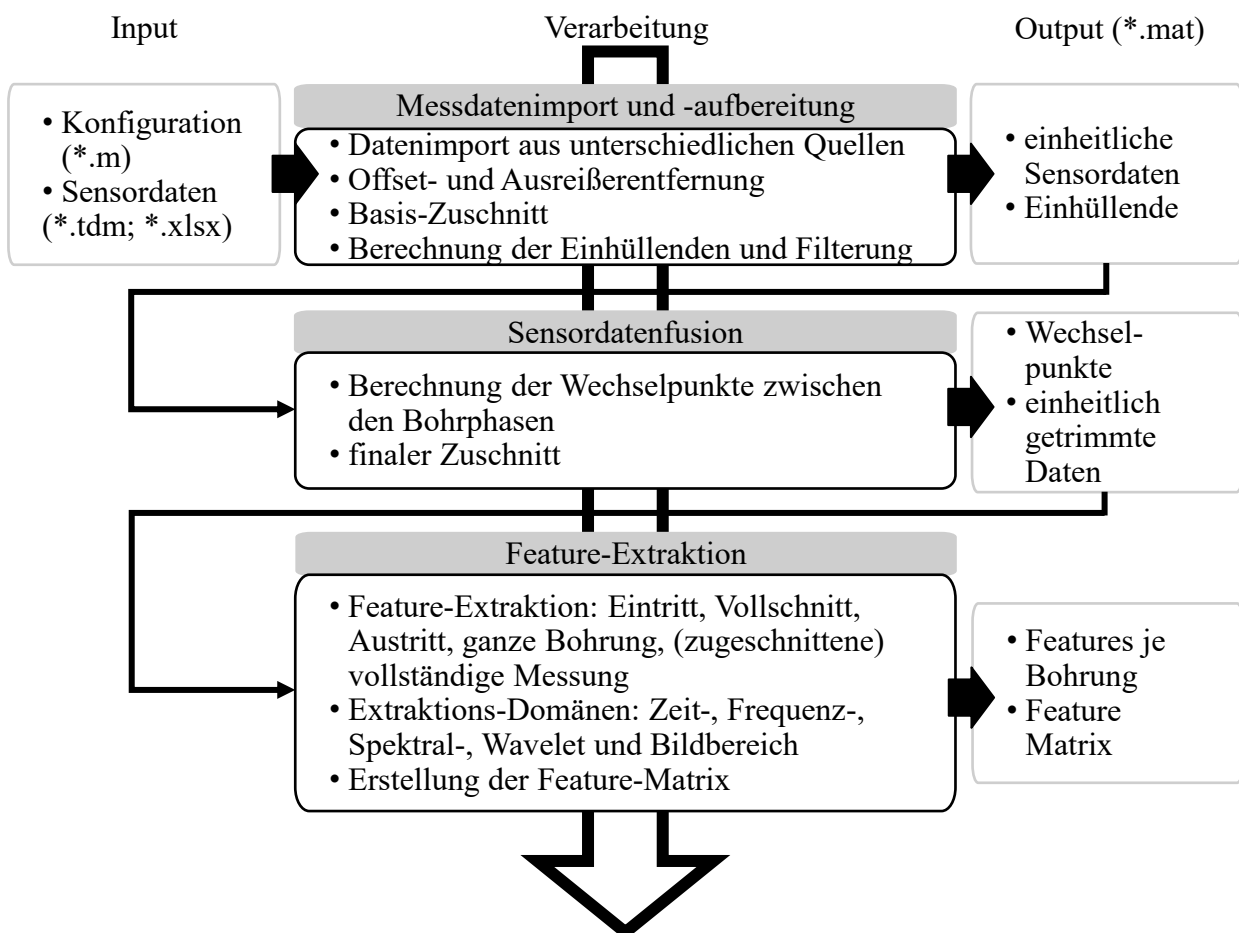


Abbildung 6.3: ML-Verfahren-unabhängige Verarbeitungsschritte

6.2.1 Messdatenimport und -aufbereitung

Die Basis für die gesamte Datenverarbeitung ist der Import und die Vereinheitlichung der Sensordaten, die in den Versuchen (siehe Kapitel 5) bei 1722 gültigen Bohrungen aufgenommen werden. Die Schritte des Messdatenimports und -aufbereitung gemäß der Abbildung 6.3 werden in diesem Abschnitt näher beleuchtet.

6.2.1.1 Datenimport aus unterschiedlichen Quellen

Anfangs werden die Sensordaten, die in spezifischen Formaten vorliegen (*.tdm, *.xlsx und teilweise *.csv), in MATLAB eingelesen und auf das einheitliche *.mat-Format gebracht. Hierbei ist zu beachten, dass nicht in jeder Versuchsreihe alle Sensoren eingesetzt werden. Der Sensoreinsatz pro Versuchsreihe ist in der Tabelle 6.2 zusammengefasst. Der wechselnde Einsatz der externen Sensorik ist in der Weiterentwicklung der Versuchssystematik ($S_{e,1}$), der Nichteignung aufgrund des Werkstoffs ($S_{e,3}$) und der Verfälschung von Messdaten beim CC/Werkstück Kontakt ($S_{e,4}$) begründet.

Tabelle 6.2: Sensoreinsatz in einzelnen Versuchsreihen (eingesetzte Sensorik: $S_{i,1}$ = Vorschubmotorstrom, $S_{i,2}$ = Spindelmotorstrom, $S_{i,3}$ = SmartADU-interner G-Sensor in x/y/z-Richtung, $S_{e,1}$ externer G-Sensor in x/y/z-Richtung, $S_{e,2}$ = Schalldruck, $S_{e,3}$ = Werkstückbewegung, $S_{e,4}$ = Dynamometer zur Messung der Vorschubkraft und des Schnittmoments)

Versuchsreihe	interne Sensoren			externe Sensoren			
	$S_{i,1}$	$S_{i,2}$	$S_{i,3}$	$S_{e,1}$	$S_{e,2}$	$S_{e,3}$	$S_{e,4}$
P1a, P1e, P2a-P9c	✓	✓	✓	x	✓	✓	✓
P1c, P1d	✓	✓	✓	x	✓	x	✓
Q1-Q1e	✓	✓	✓	✓	✓	✓	✓
Q2-Q2e	✓	✓	✓	✓	✓	x	✓
Q3-Q3e	✓	✓	✓	✓	✓	✓	x
A1, A3, A5	✓	✓	✓	✓	✓	✓	x
A2, A4	✓	✓	✓	✓	✓	x	x

Zu erwähnen ist, dass sich aus den 7 Sensoren 12 Sensorgrößen ergeben, da die G-Sensoren jeweils in x/y/z-Richtung Beschleunigungen messen und das Dynamometer die Vorschubkraft F_f und das Schnittmoment M_c aufnimmt, siehe Abbildung 6.4. Als Vorgriff auf den nächsten Abschnitt muss gesagt werden, dass 12 Sensorgrößen für die Datenvorbereitung und 10 für das Modelltraining gemäß Abbildung 6.4 verwendet werden.

6.2.1.2 Ausreißer- und Offsetentfernung

Dokumentierte Fehlmessungen einer Sensorgröße werden als „nicht definiert“ verzeichnet, um bei der Feature-Extraktion die entsprechenden Features als Nullwerte zu definieren.

Eine klassische Ausreißeranalyse der als solches aufgenommenen kontinuierlichen Zeitreihendaten wird nur in spezifischen Fällen basierend auf den Erfahrungswerten und Voruntersuchungen

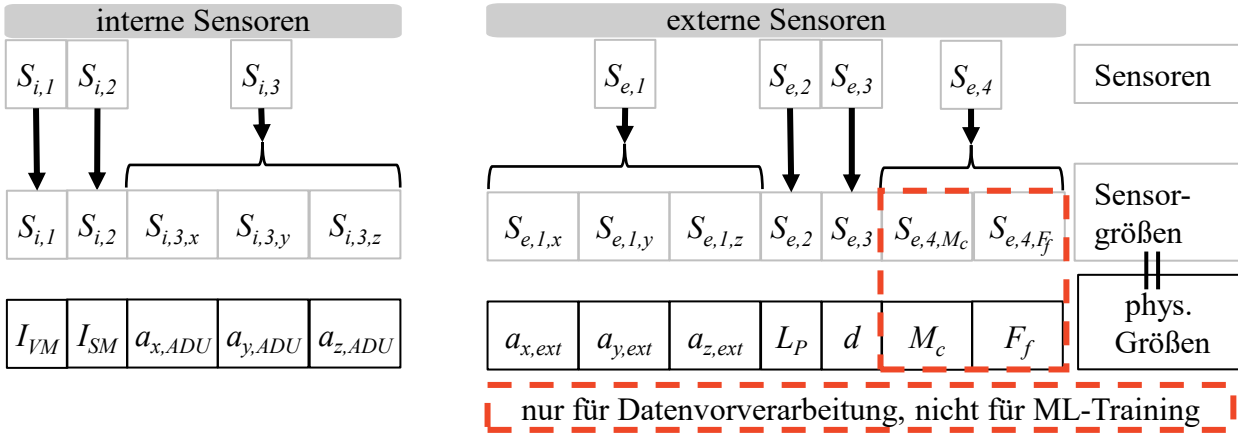


Abbildung 6.4: Sensoren und Sensorgrößen (Sensoren: $S_{i,1}$ = Vorschubmotorstrom, $S_{i,2}$ = Spindelmotorstrom, $S_{i,3}$ = SmartADU-interner G-Sensor in x/y/z-Richtung, $S_{e,1}$ = externer G-Sensor in x/y/z-Richtung, $S_{e,2}$ = Schalldruck, $S_{e,3}$ = Werkstückbewegung, $S_{e,4}$ = Dynamometer zur Messung von Vorschubkraft/Schnittmoment; gemessene physikalische Größen: I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung, L_P = Schalldruck, d = Werkstückbewegung als Distanzmessung zur Werkstückunterseite, M_c = Schnittmoment, F_f = Vorschubkraft)

vorgenommen. Mithilfe der MATLAB-Funktion `filloutliers()` werden nur eindeutig identifizierbare Ausreißer aufgrund von Sensorfehlern in den internen Sensordaten $S_{i,1-3}$ sowie in den Daten des Lasersensors $S_{e,3}$ ersetzt. Die Identifikation der Ausreißer erfolgt durch den Abstand des 3-fachen Medians von dem lokalen Durchschnittswert in einem Datenfenster von 20 Datenpunkten. In diesem Datenfenster ist der Datenverlauf mit dem gleitenden Mittelwert gefiltert. Der Ausreißer wird durch eine lineare Interpolation zwischen den Nachbarpunkten ersetzt [Mat24a]. Zudem werden beim Laser-Abstandssensor $S_{e,3}$ am Ende der Bohrung außerhalb des Wertebereichs liegende Werte entfernt, da diese nach dem Durchstoßen des Werkstoffmaterials durch den Bohrer entstehen. Bei den restlichen Sensoren findet keine Ausreißer-Elimination statt, da deren Vorhandensein nicht eindeutig festgestellt werden kann. Zudem ist es möglich, dass nicht sicher identifizierbare Sensordaten-Anomalien aufgrund von Bohrungsanomalien auftreten.

Die Offset-Entfernung in den Zeitverläufen wird in 2 Fällen durchgeführt:

- Die internen Beschleunigung-Sensorwerte $S_{i,1,x/y/z}$ enthalten auch im Ruhezustand der SmartADU einen Offset entsprechend den Anteilsrichtungen der Erdbeschleunigung. So beträgt der Offset bei $S_{i,1,x}$ etwa 1 g. Für eine orientierungsunabhängige spätere Feature-Extraktion wird daher der Offset entfernt. Dies geschieht durch die Subtraktion des Sensorgröße-Durchschnittswerts über den Start-Zeitraum von $\Delta t = 1$ s.
- Falls andere Sensoren einen (z. T. unregelmäßigen) Offset aufweisen, wird dieser ebenfalls mit der bei $S_{i,1,x/y/z}$ angewandten Methodik entfernt.

Während der Aufnahme numerischer Zielgrößen erfolgt eine Ausreißeridentifikation innerhalb einer Versuchsreihe mithilfe des 1,5-fachen Interquartilsabstandes IQR unter dem 25 %-Quantil $Q_{25\%}$ und über dem 75 %-Quantil $Q_{75\%}$. Der IQR ist als der Abstand zwischen dem 75 %-Quantil $Q_{75\%}$ und dem 25 %-Quantil $Q_{25\%}$ festgelegt. Eine Größe wird damit als Ausreißer markiert, falls sie außerhalb des folgenden, in Gleichung 6.1 definierten, Intervalls liegt [SS17, S. 40].

$$[Q_{25\%} - 1,5 \cdot IQR; Q_{75\%} + 1,5 \cdot IQR] \quad (6.1)$$

Die Ausreißeranalyse der Zielgrößen wird innerhalb der Einzel-Versuchsreihen bei nicht anomaliebehafteten Bohrungen durchgeführt. Als Ausreißer identifizierte Zielgrößen werden 3 Mal nachgemessen.

6.2.1.3 Basis-Zuschnitt

In diesem Schritt erfolgt das Entfernen eines kurzen Zeitabschnitts am Anfang und am Ende der Sensordaten, um Peaks in den Zeitverläufen zu entfernen, die aufgrund des Ein- oder Ausschaltens der Messkette oder reglerbedingt in der SmartADU auftreten. Die Länge des entfernten Abschnitt ist sensorindividuell und beträgt max. 0,5 s.

6.2.1.4 Einhüllende der ungefilterten Daten

Aus den ungefilterten Daten wird jeweils die obere und untere Einhüllende berechnet, um aus dieser ebenfalls Features zu extrahieren. Die Motivation hierfür liegt in dem Umstand, dass z. B. bei einer Tiefpassfilterung der G-Sensor-Daten ein ungefähres Nullsignal entsteht. Um eine Feature-Extraktion aus niederfrequenten Eigenschaften der Beschleunigungssignale durchzuführen, werden daher die Einhüllenden der Signale gebildet, was im gleichen Zuge auch für die anderen Sensorgrößen geschieht. Die Abbildungen A.10 und A.11 im Anhang A.8 zeigen u. a. die Einhüllenden neben den Rohsignalen.

6.2.1.5 Filterung der Daten

Die Filtermethoden sind in der Tabelle 6.3 eingetragen. Deren Auswahl erfolgt gemäß der Datenbeschaffenheit. Der *gleitende Mittelwert*-Filter wird bei einer Fensterbreite von 5 % des Datenvektors berechnet, was in einer Tiefpassfilterung resultiert. Bei den Rohdaten der Beschleunigungen wird keine Filterung vorgenommen, um die periodischen Eigenschaften der Daten nicht zu eliminieren und die Auslöschung des Signals zu vermeiden. Der eingesetzte *lowess*-Filter basiert auf einer lokal gewichteten Daten-Regression mit einem Polynom 1. Ordnung [Cle79]. Bei der Messung des Schalldrucks L_P wird ein spektraler Subtraktionsalgorithmus eingesetzt, welcher die Umgebungsrausch-Beseitigung durch die Subtraktion des Spektrums der Störgeräusche vom Spektrum der verrauschten Daten erzielt [Bol79]. Zur softwareseitigen Umsetzung wird auf [Zav05] zurückgegriffen.

Tabelle 6.3: Filterung der Daten (I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, L_P = Schalldruck, d = Werkstückbewegung als Distanzmessung zur Werkstückunterseite, M_c = Schnittmoment, F_f = Vorschubkraft)

Messgröße	Filter Rohdaten	Filter Einhüllende
I_{VM}	—— gleitender Mittelwert ——	
I_{SM}	—— gleitender Mittelwert ——	
$a_{x/y/z,ADU}$	keine Filterung	gleitender Mittelwert
$a_{x/y/z,ext}$	keine Filterung	lowess-Filter
L_P	spektrale Subtraktion	lowess-Filter
d	—— lowess-Filter ——	
M_c	—— lowess-Filter ——	
F_f	—— lowess-Filter ——	

6.2.2 Sensordaten-Fusion

Nach der Daten-Vorverarbeitung muss für jede Sensorgröße der relevante Abschnitt des Zeitverlaufs, der dem Bohrprozess entspricht, extrahiert werden. Dies ist notwendig, da die Messdatenaufnahme im Regelfall jeweils einige Sekunden vor dem Bohrvorgang gestartet und nach diesem beendet wird.

6.2.2.1 Betrachtungen zu der Signal-Abtastrate

Im Hinblick auf die Qualität der Erfassung frequenzabhängiger Sensordaten-Eigenschaften muss zudem die Erfüllung des *Nyquist-Shannon-Abtasttheorems* gemäß Gleichung 6.2 untersucht werden [Ber17, S. 40]. Dabei wird geprüft, ob die Abtastraten f_s der internen SmartADU-Sensorik ($f_{s,ADU}$) und der externen Prüfstands-Sensorik ($f_{s,ext}$) mindestens das doppelte der maximal vorhandenen Signalfrequenz f_{max} betragen. Im Falle der Erfüllung werden die frequenzabhängigen Signaleigenschaften bewahrt und eine Rekonstruktion des Signals ermöglicht. Hochfrequente Signalanteile werden durch den Spanbruch im Falle eines aktiven Peck-Feed-Systems erzeugt.

$$f_s > 2 f_{max} \quad (6.2)$$

Da für die Peck-Feed-Frequenz f_{PF} der SmartADU gemäß Abschnitt 5.1.1 $f_{PF} = 1,5 n$ gilt, ergibt sich bei einer maximal vorhandenen Drehzahl $n_{max} = 6000 \text{ min}^{-1}$ (siehe Tabelle 5.4) für die notwendige Abtastrate gemäß der Gleichung 6.3 der Wert $f_{s,notw.} > 300 \text{ Hz}$. Umgekehrt wird damit festgestellt, dass eine vollständige Erfassung der frequenzabhängigen Eigenschaften bis zu einer Drehzahl $n_{max} \approx 2000 \text{ min}^{-1}$ erfolgt.

$$f_{s,notw.} > 3 n_{max} \quad (6.3)$$

Die Abtastrate der internen SmartADU-Sensorik $f_{s,ADU}$ ist baubedingt vorgegeben. Die

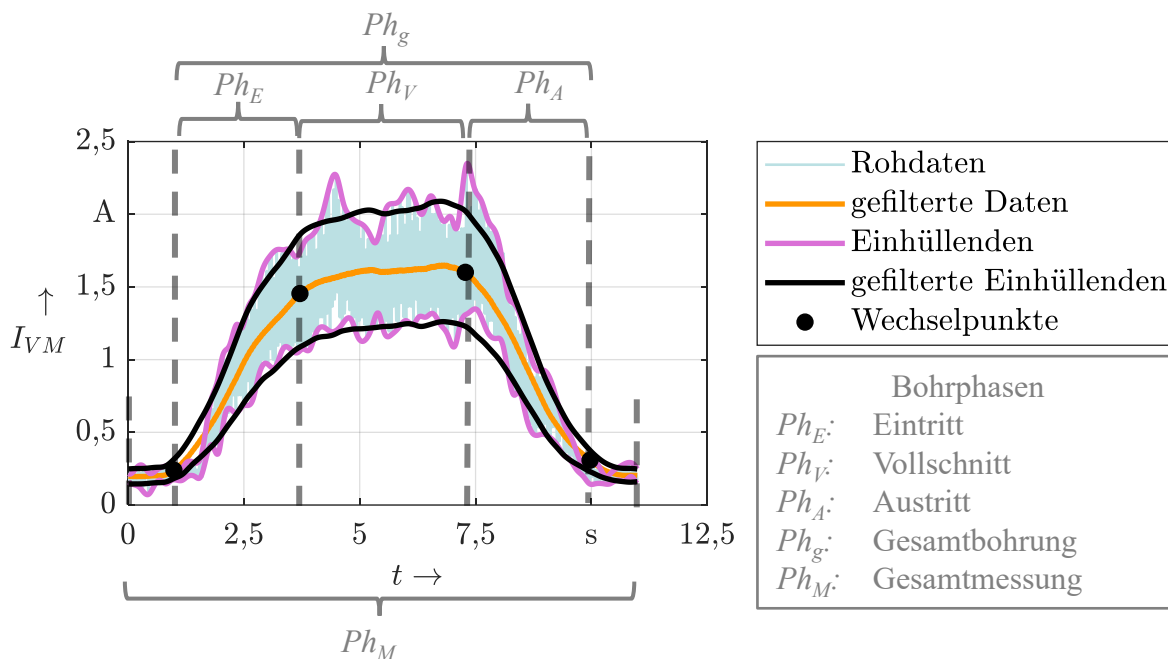
Abtastrate externer Sensorik $f_{s,ext} = 5120 \text{ Hz}$ erfüllt das Nyquist-Shannon-Theorem.

6.2.2.2 Berechnung der Wechsellpunkte zwischen den Bohrphasen

Die Bohrprozess-Phasen zur Erstellung von Durchgangsbohrungen sind in der Abbildung 6.5 dargestellt und lassen sich unterteilen in:

- *Eintrittsphase Ph_E* : Die Phase beginnt mit dem Materialeintritt des Bohrers. Die Hauptschneiden sind noch nicht im vollen Eingriff, und die Spannungsbreite b_c nimmt mit steigendem Vorschubweg zu.
- *Vollschnittphase Ph_V* : Die Phase beginnt, sobald die Hauptschneiden im vollen Eingriff sind und die Führungsfasen anfangen, an der Bohrungswand zu reiben. Bei ausgeschaltetem Peck-Feed sind die Spannungsbreite b_c und Spannungsdicke h_c konstant.
- *Austrittsphase Ph_A* : Die Phase beginnt, sobald die Bohrerspitze aus dem Material austritt. Die Spannungsbreite b_c nimmt mit steigendem Vorschubweg ab. Die Führungsfasen reiben an der Bohrungswand. Die Phase endet, nachdem die Schneidenecken aus dem Material ausgetreten sind.

In der Abbildung 6.5 sind die beschriebenen Bohrphasen anhand des Vorschubmotorstroms I_{VM} dargestellt. Charakteristisch sind bei I_{VM} die Steigung während des Eintritts, der annähernd konstante Verlauf im Vollschnitt und der Abfall während des Austritts, was mit der Vorschubkraft [Dob19] korreliert.



Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 100 \%$;
 $A_{PF} = 62,5 \text{ }\mu\text{m}$; Werkzeug = KS-HB-04937-01; Bohrungs-ID: Q1_200;
 Bohrungsanzahl Werkzeug: 200

Abbildung 6.5: Beispiel für eine Bohrphasen-Identifikation (I_{VM} = Spindelmotorstrom, t = Zeit, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, c_{CC} = Kontaktzustand zwischen Werkstück und Concentric Collet, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

Für die Aufteilung der Sensordaten in Bohrphasen ist die zuverlässige Bestimmung von 4

Wechselpunkten (siehe Abbildungen 6.5 und A.11 im Anhang A.8) zwischen den einzelnen Phasen essentiell. Die damit entstehende Bohrphasen-Identifikation basiert auf der Vorgabe eines einheitlichen Kurventyps für eine normale Durchgangsbohrung in einer Einzelschicht. Die Identifikation der Wechselpunkte erfolgt durch die MATLAB-Funktion *findchangepts()*. Das Grundprinzip dieser Funktion ist die Identifikation von Signaländerungen, sobald sich bestimmte Kennwerte (z. B. Mittelwert, Standardabweichung, ...) eines Zeitfensters ändern [Mat24a]. Geeignete Sensorgrößen, die beim Übergang zwischen den Bohrphasen eine Tendenz zu charakteristischen Änderungen aufweisen, werden nach Voruntersuchungen für die Wechselpunkteidentifikation ausgewählt. Der Vorgang besteht aus dem iterativen Ablaufen geeigneter Sensorverläufe und Identifikationsverfahren der *findchangepts()*-Funktion. Die dabei möglichen Identifikationsverfahren basieren beispielsweise auf der Detektion von Änderungen im Mittelwert oder der Standardabweichung des Signals in einem durchgelaufenen Zeitfenster. Zur näheren Erklärung sei auf die Dokumentation der erwähnten Funktion verwiesen [Mat24a]. Für das Auffinden geeigneter Wechselpunkte und damit Abbruch der Iteration wird eine eigens entwickelte Validierungsabfrage festgelegt.

Für die internen Sensordaten erfolgt die Wechselpunkt-Bestimmung über die gefilterten Daten des Vorschubmotorstroms I_{VM} . Sollten die Methoden der Wechselpunkt-Bestimmung mittels der *findchangepts()*-Funktion nicht erfolgreich sein, erfolgt in der nächsten Schleife der Versuch über die obere Einhüllende der Beschleunigung in x-Richtung $a_{x,ADU}$. Sollte jeder Iterationsversuch an der internen Validierung scheitern, wird diese Information für den nächsten Verarbeitungsschritt (Feature-Extraktion) abgelegt. Vor allem bei anomaliebehafteten Bohrungen ist eine ganzheitliche Bohrphasen-Identifikation (= 4 identifizierte Wechselpunkte) oftmals nicht möglich. In der Abbildung A.12 im Anhang A.9.2 ist ein Beispiel für eine anomale Bohrung ohne Bohrphasen-Identifikation visualisiert. Anhand des Pseudo-Codes A.1 im Anhang A.9.2 ist die Wechselpunkt-Bestimmung für die internen Sensordaten zusätzlich erklärt.

Die Systematik zur Bestimmung der Wechselpunkte für die externen Sensordaten ist die gleiche wie in dem Pseudo-Code A.1 im Anhang A.9.2 für interne Sensordaten. Als Sensordaten dienen jedoch je nach Versuchsreihe das Schnittmoment M_c des Sensors $S_{e,4}$ oder die Beschleunigungen in alle 3 Raumrichtungen des Sensors $S_{e,1}$. Die Auswahl der Sensoren erfolgt einerseits nach Verfügbarkeit (siehe Tabelle 6.2) und andererseits danach, ob bei einem Sensor eine erfolgreiche Wechselpunktbestimmung durchgeführt werden kann oder dies im nächsten Iterationsschritt bei einem weiteren versucht wird. In der Tabelle 6.4 sind die verwendeten Sensorgrößen für die Wechselpunktbestimmung in der Reihenfolge gemäß ihrer Nutzung dargestellt. Die wechselnde Methodik bei den externen Sensoren ist darin begründet, dass der Sensor $S_{e,4}$ (Dynamometer) ab der Versuchsreihengruppe Q-Al2024 aus Gründen der Redundanz mit den internen Motorstromsensoren $S_{i,1}$ und $S_{i,2}$ nicht mehr verwendet wird.

Tabelle 6.4: Sensoreinsatz Wechselpunktbestimmung (zur Erläuterung der Sensorgrößen siehe Abschnitt 5.1)

Sensorgrößen zur Wechselpunktbestimmung		
Versuchsreihengruppe	intern	extern
P, Q-Ti64, Q-CFK-D	} $I_{VM}; a_{x,ADU}$	$M_c; a_{x,ext}; a_{y,ext}; a_{z,ext}$
Q-Al2024, A		$a_{x,ext}; a_{y,ext}; a_{z,ext}$

Nach der Identifikation der Wechsellpunkte erfolgt ein Zuschnitt der Sensorgrößen auf eine Sekunde vor dem 1. und nach dem 4. Wechsellpunkt, siehe dazu die Abbildungen A.10 und A.11 im Anhang A.8. Die Synchronisation der internen und externen Sensorgrößen ist nicht notwendig, da die spätere Feature-Extraktion separat für jede Sensorgröße ausgeführt wird. Zudem würde die Synchronisation auch eine näherungsweise Anpassung der Abtastfrequenz erfordern, was zu einer Datenverfälschung führt.

Für jede Versuchsreihengruppe stehen individuell vorhandene Sensordaten gemäß Tabelle 6.2 zur Verfügung, woraus nach der Bohrphasen-Identifikation die endgültigen zugeschnittenen Sensordaten gemäß Abbildung 6.4 an die Feature-Extraktion weitergegeben werden. Hierbei sei angemerkt, dass die Daten des Schnittmoments M_c und der Vorschubkraft F_f nur zur Bohrphasen-Identifikation und nicht zur Feature-Extraktion genutzt werden.

Für jede bisher aufbereitete Sensorgröße sind mit dem bisherigen Vorgehen unterschiedliche Arten der *Datenrepräsentation* vorhanden, die in der Tabelle 6.5 zusammengefasst sind. Es werden keine gefilterten Beschleunigungsdaten $a_{x/y/z}$ für die weitere Verarbeitung gespeichert, da durch die Filterung die hochfrequenten Anteile dieser Sensorgrößen entfernt werden. Des Weiteren ist in der Tabelle 6.5 die Anzahl der Datenvektoren jeder Versuchsreihe für eine Bohrung zusammengefasst. Die Anzahl ergibt sich mit der bisher erläuterten Datenverarbeitung in Abhängigkeit der eingesetzten Sensoren und der Datenrepräsentation.

Tabelle 6.5: Datenrepräsentation der Sensorgrößen ($S_{i,1}$ = Vorschubmotorstrom, $S_{i,2}$ = Spindelmotorstrom, $S_{i,3}$ = SmartADU-interner G-Sensor in x/y/z-Richtung, $S_{e,1}$ = externer G-Sensor in x/y/z-Richtung, $S_{e,2}$ = Schalldruck, $S_{e,3}$ = Werkstückbewegung)

Datenrepräsentation nach Zuschnitt	interne Sensoren			externe Sensoren		
	$S_{i,1}$	$S_{i,2}$	$S_{i,3}$	$S_{e,1}$	$S_{e,2}$	$S_{e,3}$
Rohdaten	✓	✓	✓	✓	✓	✓
gefilterte Daten	✓	✓	x	x	✓	✓
obere Einhüllende	✓	✓	✓	✓	✓	✓
untere Einhüllende	✓	✓	✓	✓	✓	✓
obere Einhüllende gefiltert	✓	✓	x	x	✓	✓
untere Einhüllende gefiltert	✓	✓	x	x	✓	✓
Versuchsreihen	Summe der Datenvektoren pro Bohrung					
P1a, P1e, P2a-P9c	33					
P1c, P1d	27					
Q1-Q1e, Q3-Q3e, A1, A3, A5	42					
Q2-Q2e, A2, A4	36					

6.2.3 Feature-Extraktion

Aus den vorbereiteten Sensorgrößen werden im nächsten Schritt Kennzahlen (= Features) entnommen, die als Eingangsgrößen für die ML-Algorithmen des Prozessmonitorings dienen. Die Features werden in 5 Domänen extrahiert: *Zeit*, *Frequenz*, *Spektrum*, *Wavelet* und *Bild*.

Dies bedeutet, dass die Sensorgrößen aus der bereits vorliegenden Zeit-Domäne in 4 weitere Domänen transformiert werden. Das Extrahieren eines Features $p_{i,j}$ wird in dieser Arbeit als das Anwenden mathematischer Operationen auf kontinuierliche Datenvektoren definiert, was als Ergebnis eine skalare Größe zur Beschreibung einer Eigenschaft des ursprünglichen Datenvektors erzeugt. Bei der Extraktion wird darauf Wert gelegt, auf „triviale“ Features, wie z. B. Dauer des Bohrvorgangs, zu verzichten. Bei enger Prozessvariation würden diese Features mit einer hohen Wahrscheinlichkeit zu einer korrekten Vorhersage führen, wären jedoch bei hoher Prozessvariation wertlos. Das Verwenden einzelner Datenpunkte als Features wird aus mehreren Gründen nicht als zielführend eingeschätzt. Der Informationsgehalt eines einzelnen Datenpunktes ist nur in Verbindung mit weiteren Angaben wie z. B. dem Zeitpunkt verwendbar. Zudem würde eine bohrungsabhängige unterschiedliche Feature-Vektorlänge ein Verfahren zur Erzeugung einer bohrungsübergreifenden gleichen Featureanzahl erfordern. Mathematisch-physikalische Eigenschaften, die durch Kennzahlen ausgedrückt werden wie z. B. den Mittelwert, würden nicht in die ML-Modellierung einfließen. Zudem würde mit der deutlich höheren Anzahl an Features der Rechenaufwand enorm steigen.

Als Eingang für die Feature-Extraktion dient jede Kombination von *Sensorgröße*, *Datenrepräsentation*, *Bohrphase* und *Domäne*. Die bisher definierten Bohrphasen (Eintritt Ph_E , Vollschnitt Ph_V und Austritt Ph_A) werden zudem noch um folgende Variationen erweitert:

- *Gesamtbohrung* Ph_g : Diese Phase umfasst den Bohrprozess ab dem Anfang der Eintrittsphase Ph_E bis zum Ende der Austrittsphase Ph_A .
- *Gesamtmessung* Ph_M : Diese Phase umfasst den gesamten vorbereiteten Datenvektor.

Zusammenfassend ergibt die in der Abbildung 6.6 dargestellte Gesamtheit an Pfaden eine Generierung von $p_F = 23560$ Features pro Bohrung. In der Tabelle A.15 im Anhang A.9.1 sind die einzelnen Möglichkeiten der Kombinationsstufen aufgelistet. Hierbei sei erwähnt, dass gemäß der Sensordatenfusion im Abschnitt 6.2.2 nicht jede Möglichkeit der Kombinationsstufen umgesetzt wird, beispielsweise werden keine Features aus den gefilterten Beschleunigungsdaten entnommen. Die theoretische Feature-Anzahl würde sich aus dem Produkt der einzelnen Möglichkeiten der Kombinationsstufen ($= 10 \cdot 6 \cdot 5 = 300$) und einzelner Features aus den Extraktions-Domänen ($= 31 + 25 + 19 + 15 + 95 = 185$) zu einer weitaus höheren Zahl von 55500 ergeben, siehe Abbildung 6.6. Aufgrund der oben genannten Einschränkung ist die Anzahl der Features mit $p_F = 23560$ jedoch geringer. Bohrungsübergreifend werden die Features zu der *Feature Matrix* F_M zusammengesetzt, was im weiteren Verlauf näher beleuchtet wird.

6.2.3.1 Feature-Extraktion in der Zeit-Domäne

Im Zeitbereich werden statistische und physikalisch begründete Kenngrößen extrahiert. Die Features werden aus allen erzeugten Datenvektoren im Zeitbereich gebildet. Ausgewählte Feature-Beispiele der gefilterten Daten des Vorschubmotorstrom I_{VM} sind in der Abbildung 6.7 dargestellt. Die einzelnen Kennzahlen sind im Anhang A.9.3 spezifiziert.

6.2.3.2 Feature-Extraktion in der Frequenz-Domäne

Zur Extraktion frequenzabhängiger Kennzahlen erfolgt die Transformation der Datenvektoren in den Frequenzbereich mittels einer diskreten *Schnellen Fourier-Transformation* (en. *Fast Fourier Transform (FFT)*), siehe technische Grundlagen im Abschnitt 2.3.2.3. Nach

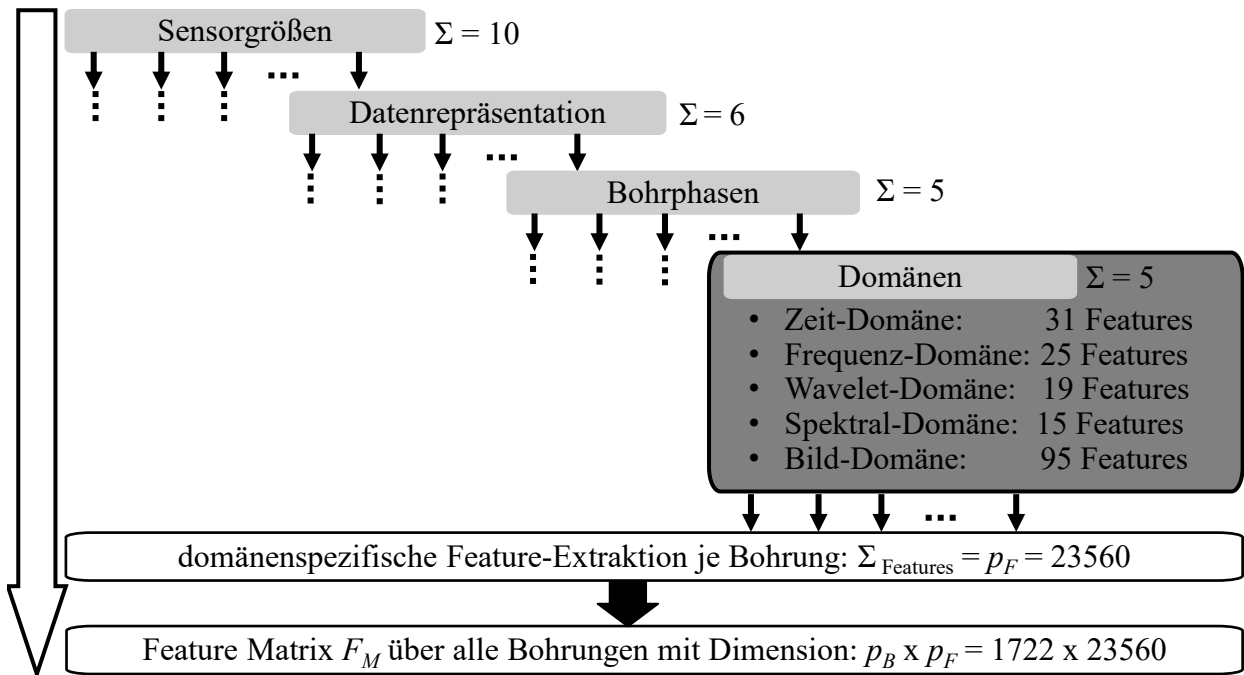



Abbildung 6.6: Gesamtpfade $PF_{i,j}$ zur Feature-Extraktion ($i = \text{Pfadabzweigung}$, $j = \text{Ausprägung der Pfadabzweigung}$, $p_F = \text{Gesamtanzahl Features}$, $p_B = \text{Gesamtanzahl Bohrungen}$)

der Ermittlung der Fourier-Transformierten \mathcal{F} wird aus dieser das Amplitudenspektrum berechnet, woraus im nächsten Schritt die Features extrahiert werden. Der Quellcode A.2 im Anhang A.9.4 stellt die Berechnungsschritte dar. Die Feature-Extraktion in der Frequenz-Domäne wird ausschließlich für ungefilterte Sensorgrößen sowie für die gefilterten Daten des Schalldrucks L_P durchgeführt.

Die Abbildung 6.8 zeigt Beispiele, bei denen die Frequenzcharakteristik der Signale nur teilweise mit den Prozessparametern in Verbindung gebracht werden kann. Zum Teil lassen sich die Peck-Feed-Frequenzen in den Amplitudenspektren wiederfinden (f_{PF} bei $a_{x,ADU}$ der Bohrung Q1_200 und $a_{x,ext}$ der Bohrung Q3_200). Gleichzeitig können nicht alle markanten Charakteristika in der internen Beschleunigung $a_{x,ADU}$ aufgrund der zu geringen Abtastrate bei höheren Drehzahlen in Aluminium-Bohrungen entnommen werden. Zudem entstehen in dem externen Beschleunigungssignal $a_{x,ext}$ Peaks, die nicht sofort mit der Signaleigenschaft in Verbindung gebracht werden können. Diese Beobachtungen unterstreichen die Notwendigkeit des Einsatzes von ML-Algorithmen zum Auffinden versteckter Strukturen, da auch die Datenerfassung durch den Applikationsort der Sensoren, z. B. aufgrund der Maschinensteifigkeit, beeinflusst ist. Die einzelnen Features sind im Anhang A.9.4 spezifiziert.

6.2.3.3 Feature-Extraktion in der Spektral-Domäne

Unter der Spektral-Domäne wird die Berechnung von zeitabhängigen Audio-Kennwerten aus den Datenvektoren bezeichnet, siehe dazu die Grundlagen-Ausführungen im Abschnitt 2.3.2.3. Die Berechnung wird ausschließlich für ungefilterte Sensorgrößen sowie für die gefilterten Daten des Schalldrucks L_P durchgeführt. Eine Anwendung bei nicht-Audiodaten wird hiermit auf die Sinnhaftigkeit in der Feature-Extraktion getestet. In den Abbildungen A.13 und A.14 des Anhangs A.9.5 sind die 11 durchgeführten Transformationen in die Spektral-Domäne, die in der MATLAB *Audio Toolbox* implementiert sind, beispielhaft aufgezeigt [Mat24c]. Aufgrund der teilweise nicht vorhandenen deutschen Bezeichnungen sind die Beschriftungen



Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$;
 $L = 100 \%$; $A_{PF} = 62,5 \text{ }\mu\text{m}$; Werkzeug = KS-HB-04937-01; Bohrungs-ID: Q1_200;
 Bohrungsanzahl Werkzeug: 200

Abbildung 6.7: Beispiel Feature-Extraktion in der Zeit-Domäne anhand des gefilterten Vorschubmotor-Stroms I_{VM} ($t = \text{Zeit}$; $I_{VM} = \text{Vorschubmotor-Strom}$, $v_c = \text{Schnittgeschwindigkeit}$, $f = \text{Vorschub pro Werkzeugumdrehung}$, $c_{CC} = \text{Kontaktzustand zwischen Werkstück und Concentric Collet}$, $L = \text{Schmierungszustand}$, $d_c = \text{Aufspannweite}$, $A_{PF} = \text{Peck-Feed-Amplitude}$)

darin in den englischen Originalbezeichnungen gelassen. Da die Berechnung dieser spektralen Kennwerte als Ergebnis wiederum Verläufe über Zeit ergibt, werden aus diesen jeweils 15 statische Kennzahlen extrahiert, die in der Tabelle A.18 des Anhangs A.9.5 aufgelistet sind.

6.2.3.4 Feature-Extraktion in der Wavelet-Domäne

Die Berechnung dieser Kennwerte wird ausschließlich für ungefilterte Sensorgrößen sowie für die gefilterten Daten des Schalldrucks L_P durchgeführt. Es wird auf eine bestehende MATLAB-Funktionalität, deren Bestandteile im Quellcode A.3 im Anhang A.9.6 zu sehen sind, zurückgegriffen. Zuerst wird in Abhängigkeit der Inputvektor-Länge und der Abtastrate ein Netzwerk zur automatisierten Berechnung der Wavelet-Koeffizienten mithilfe von Gabor-Wavelets erzeugt. Beim Basis-Gabor-Wavelet ist die Energie im Bereich $x = 0$ konzentriert und dessen Betrag entspricht dem Wert 1. Zu möglichen Ausprägungen dieser Wavelet-Familie sei auf entsprechende Fachliteratur verwiesen [Man92], [Bar11]. Anschließend berechnet das erzeugte Wavelet-Netzwerk eine Matrix mit Wavelet-Koeffizienten, was der diskreten Wavelet-Transformation entspricht [Mat24d]. Die Ergebnis-Matrix entspricht den eigentlichen Wavelet-Features. Die Größe des Wavelet-Netzwerks und der Wavelet-Feature-Matrix sind wegen der automatischen Erzeugung abhängig von der Datenlänge. Um die Anzahl der Features in der Wavelet-Domäne für jede Bohrung anzugleichen, werden die im Anhang A.9.6 niedergeschriebenen statistischen Operationen auf die Wavelet-Feature-Matrix angewandt.

6.2.3.5 Feature-Extraktion in der Bild-Domäne

In der Bild-Domäne wird die Berechnung der Kennwerte ebenfalls ausschließlich für ungefilterte Sensorgrößen sowie für die gefilterten Daten des Schalldrucks L_P durchgeführt. Die Grundidee ist, Zeitverläufe in eine 2D-Bilddarstellung zu überführen und aus den numerischen Farbeigenschaften mittels statistischer Methoden die Features zu extrahieren.

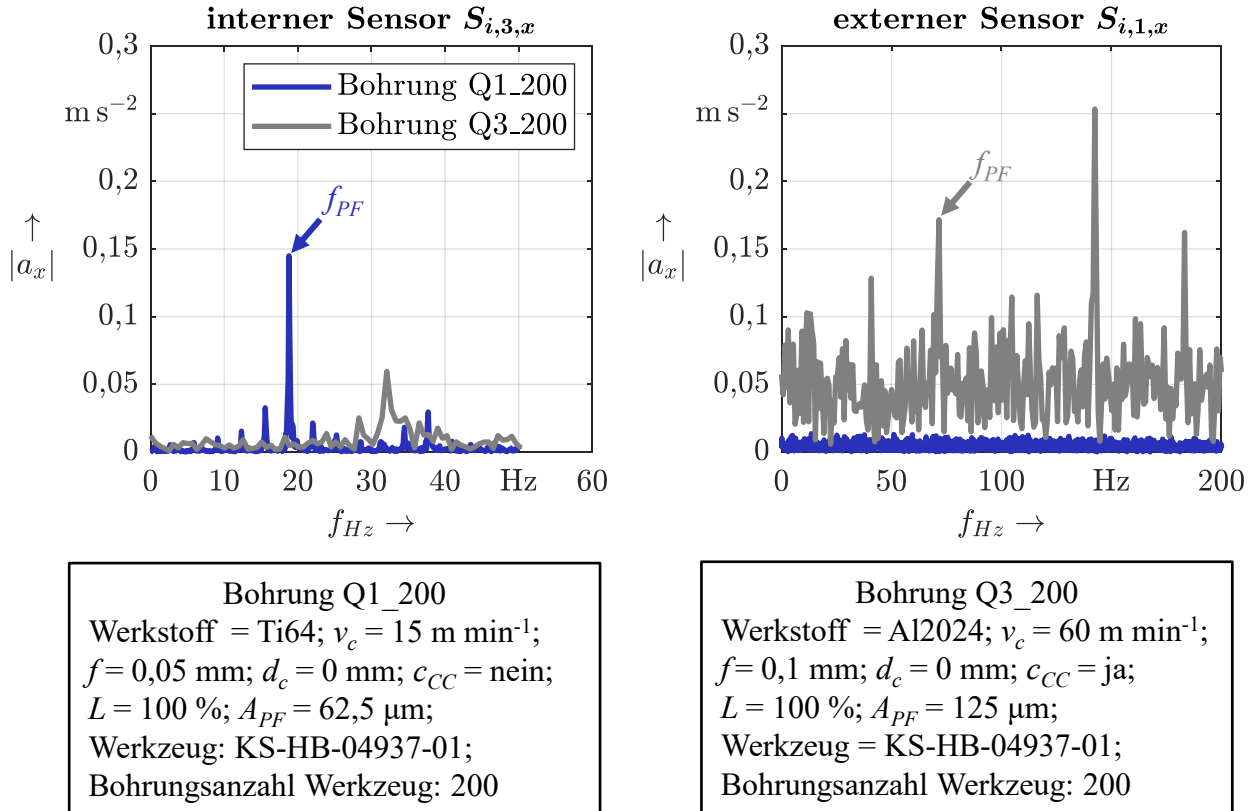
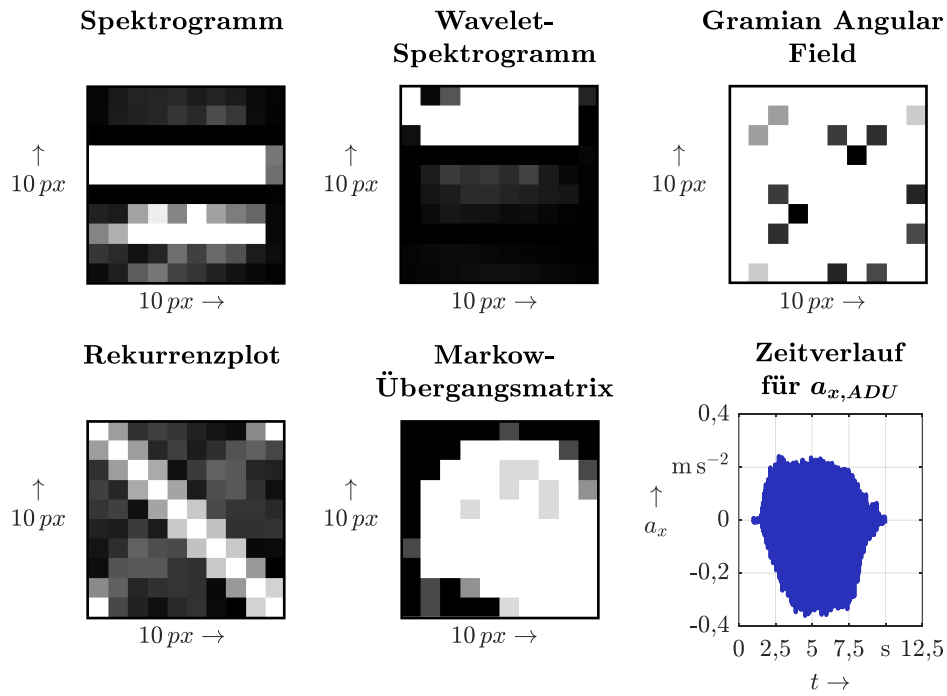


Abbildung 6.8: Beispiel-Transformation in die Frequenz-Domäne anhand der Beschleunigungsdaten in x -Richtung für die Phase Gesamtbohrung Ph_g (f_{Hz} = Signalfrequenz,; $|a_x|$ = Betrag der Amplitude, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, c_{CC} = Kontaktzustand zwischen Maschine und Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

Die Erstellung der Bildrepräsentation wird anhand des vereinfachten MATLAB-Codes A.4 im Anhang A.9.7 methodisch erklärt. Zuerst erfolgt eine Frequenzabsenkung und damit Vektorkürzung des Eingangsvektors, um einen Speicherüberlauf während der späteren Bilderstellung auszuschließen. Danach werden die Daten für die Bildrepräsentation mit folgenden Methoden, die in [Jun+23] erfolgreich zur Fräswerkzeug-Verschleißvorhersage und z. T. in [Schi23] zur Anomaliedetektion angewendet wurden, erzeugt: *Spektrogramm*, *Wavelet-Spektrogramm*, *Gramian Angular Field*, *Rekurrenzplot* und *Markov-Übergangsmatrix*.

In dieser Arbeit werden als Bildrepräsentation schwarz-grau-weiße Pixel (d. h. Werte zwischen 0 und 255) umgesetzt. Nach der Berechnung der jeweiligen numerischen, matrixförmigen Bildrepräsentations-Werte erfolgt die Konvertierung der Zahlen auf eine Skala von [0; 1], was eine mögliche Graubild-Darstellung ist. Zudem erfolgt die Faltung der Matrix auf eine Größe von 10×10 und eine Skalierung auf die Standard-Graustufenskala im Bereich [0; 255]. Zur finalen Feature-Extraktion werden aus der jeweiligen Graustufen-Bildmatrix mittels statistischer Methoden (deren spezifische Auflistung ist in der Tabelle A.20 im Anhang A.9.7 zu finden) die finalen Features extrahiert. Damit werden aus 5 Graustufen-Bildmatrizen jeweils 19 Features entnommen. In der Abbildung 6.9 ist eine Signalrepräsentation in der Bild-Domäne beispielhaft dargestellt.



Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 100 \%$;
 $A_{PF} = 62,5 \text{ } \mu\text{m}$; Werkzeug = KS-HB-04937-01; Bohrungs-ID: Q1_200;
 Bohrungsanzahl Werkzeug: 200

Abbildung 6.9: Beispiel für die Bild-Domäne der Phase Gesamtbohrung Ph_g für die Sensorgröße $a_{x,ADU}$ (Verwendung von teilweise englischen Größenbezeichnungen aufgrund nicht vorhandener deutscher Übersetzung; $px = \text{Pixel}$, $a_x = \text{Beschleunigung in } x\text{-Richtung}$, $t = \text{Zeit}$, $v_c = \text{Schnittgeschwindigkeit}$, $f = \text{Vorschub pro Werkzeugumdrehung}$, $c_{CC} = \text{Kontakzustand zwischen Werkstück und Concentric Collet}$, $L = \text{Schmierungszustand}$, $A_{PF} = \text{Peck-Feed-Amplitude}$)

6.2.3.6 Erstellung der Feature-Matrix

Die Features aus den beschriebenen Domänen werden für jede Bohrung zu einem Zeilenvektor zusammengesetzt. Aus diesen wird durch vertikales Zusammenfügen die *Feature-Matrix* des gesamten Datensets mit der Dimension 1722×23560 gebildet. Aufbauend auf der Abbildung 6.6 ist die Struktur der Feature-Matrix in der Abbildung 6.10 dargestellt und im Folgenden näher beschrieben.

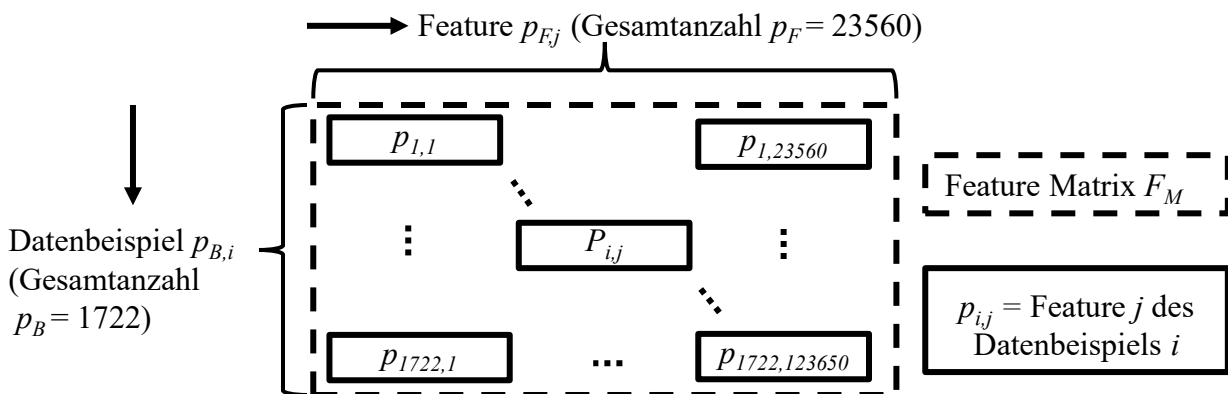


Abbildung 6.10: Erstellung der Feature-Matrix aus den Feature-Vektoren

Feature-Vektor für eine Bohrung

In der Abbildung 6.6 sind die kaskadierten Pfade zur Feature-Extraktion aufgezeigt. Es sei hierzu erwähnt, dass die finale Feature-Anzahl von $p_B = 23560$ für jede Bohrung gleich ist und dass nicht jede Kombination der einzelnen Pfade (z. B. erfolgt keine Feature-Extraktion für die Datenrepräsentation *gefiltert* der Beschleunigungs-Sensorgrößen) zur Feature-Extraktion herangezogen wird. Daher ist die theoretische Anzahl der möglichen Features höher. In einzelnen Situationen ist eine Bestimmung von Features nicht möglich. Da die finale Feature Matrix voll besetzt sein muss, wird in folgenden Fällen der Feature-Wert auf „0“ gesetzt:

- Fehlen von Daten bestimmter Sensorgrößen (z. B. bei CFK-Werkstoffen ist keine gültige Messung mit dem Laser-Distanzsensor $S_{e,3}$ möglich)
- bei einzelnen Datenvektoren der Sensorgrößen sind bestimmte mathematische Operationen nicht möglich (z. B. Division durch 0)
- Es können keine Wechsellpunkte bestimmt und damit keine Identifikation von Bohrphasen vorgenommen werden. In diesem Fall erfolgt die ordnungsgemäße Feature-Extraktion nur für die Phase der Gesamtmessung Ph_M , die Features der anderen Phasen sind „0“.

Erstellung der Feature-Matrix aus den Feature-Vektoren

Nach dem horizontalen Zusammenfügen der Feature-Vektoren zur Feature-Matrix gemäß Abbildung 6.10 wird diese in folgenden Schritten bereinigt:

- Entfernen jeder Spalte $p_{F,j}$, die mindestens einen ∞ - Wert enthält, aus einem Nullvektor besteht oder identisch zu einer anderen Spalte ist
- Entfernen der Zeilen $p_{B,i}$ (= Datenbeispiele), für die Zielgrößen nicht existieren (z. B. Löschen aller Bohrungen in CFK-Materialien beim Monitoring des Austrittsgrats Q_{GE})

Die Bereinigung der Feature-Matrix ist notwendig für eine fehlerfreie weitere Datenverarbeitung, da z. B. Nullspalten die Standardisierung nicht ermöglichen würden. Die erzeugte Feature-Anzahl ist sehr hoch, was aber damit gerechtfertigt wird, dass in den nächsten Schritten eine Dimensionsreduktion durchgeführt wird. Durch diese Methodik wird sichergestellt, dass jegliche bzw. möglichst viele relevante Features aus den Daten extrahiert sind und im Nachgang die Datenmenge zur ML-Modellierung reduziert und damit die Gefahr der Modell-Überanpassung gesenkt wird. In der Abbildung A.15 im Anhang A.9.8 kann die statistische Zusammensetzung der Feature Matrix eingesehen werden.

6.3 ML-Verfahren- und zielgruppenspezifische Modellierung

In diesem Abschnitt werden die Datenverarbeitungs- und Modellierungsschritte vorgestellt, die im Gegensatz zum vorherigen Abschnitt 6.2 individuell in Abhängigkeit der Zielgrößen und der ML-Verfahrensgruppe gestaltet sind. Die Auswahl der Verfahrensgruppe erfolgt in Abhängigkeit der Zielgrößen und wird in der Tabelle 6.6 als einleitende Übersicht dargestellt. Es wird fortlaufend der Zusatz „unüberwacht/überwacht“ zur Verdeutlichung der ML-Verfahrensgruppe aufgeführt.

Die Abbildung 6.1 aus dem Abschnitt 6 stellt u. a. die *ML-analysespezifischen* Arbeitsschritte

Tabelle 6.6: Zuordnung zwischen ML-Verfahrensgruppe und Überwachungs-Kenngrößen

Überwachungs-Kenngrößen	ML-Verfahrensgruppe			
	unüberwachtes Clustering	unüberwachte Ausreißeridentifikation	überwachte Klassifikation	überwachte Regression
Prozessanomalien	✓	✓	✓	x
Prozesszustand	✓	x	✓	x
Werkstückqualität	x	x	✓	✓
Werkzeugverschleiß	x	x	✓	✓

dar. Diese variieren zwar in Abhängigkeit der ML-Verfahrensgruppe, repräsentieren jedoch die generellen Phasen. Im Folgenden wird auf diese spezifisch eingegangen. Jeder Teilschritt in der entwickelten MATLAB-Routine ist separat ausführbar.

6.3.1 Monitoring von Prozessanomalien

Für die Identifikation der Anomalien wird das *unüberwachte Clustering*, die *unüberwachte Ausreißeridentifikation* und die *überwachte Klassifikation* untersucht.

Das *unüberwachte Clustering* hat das Potential, Daten ohne bekannte Klassenzuordnung in Gruppen mit ähnlichen Eigenschaften einzuordnen. Datenausreißer infolge von Prozessanomalien unterscheiden sich in ihren Merkmalen von den Clustern normaler Daten [Ric19, S. 289], [Kub17, S. 273]. Innerhalb dieser Arbeit wird die These geprüft, ob durch das unüberwachte Datenclustering die Anomalien im optimalen Fall in eine eigene Klasse aufgrund ihrer stark abweichenden Eigenschaften einsortiert werden.

Die *unüberwachte Ausreißeridentifikation* ist eine typische Anwendung zur Anomaliedetektion. Folgende Definitionsunterscheidung ist innerhalb dieser Arbeit zu beachten: Der Begriff „Anomaliedetektion“ steht für das globale Ziel der Fehlererkennung beim Bohrprozess, während der Begriff „unüberwachte Ausreißeridentifikation“ für die ML-Verfahrensgruppe steht. Innerhalb dieser Arbeit wird bei der unüberwachten Ausreißeridentifikation die Vorgehensweise der *Novelty Detection* ausgewählt, siehe Abschnitt 2.3.1 [Bar10], [MS03], [Mil10]. Bei der Zuweisung neuer Daten werden als Ergebnis die Daten als Anomalien markiert, die nicht zu den bisher gelernten Dateneigenschaften passen [Alp14, S. 199], [Sug16, S. 457]. Die Vorgehensweise der unüberwachten Ausreißeridentifikation bietet sich in der Produktion an, falls ein Datensatz vorliegt, dessen Bohrungen als gesichert ordnungsgemäß eingestuft sind und neu gefertigte Bohrungen auf Anomalien überprüft werden müssen.

Zudem wird die *überwachte Klassifikation* zur Anomalieerkennung genutzt. Dieser Einsatz entspricht dem Szenario, falls eine breite Datenbasis mit markierten Daten vorhanden ist oder die Anomalieart klassifiziert werden muss.

6.3.1.1 Unüberwachtes Clustering

Die Grundidee der Anomaliedetektion mittels unüberwachtem Clustering besteht in dieser Arbeit darin, dass die ungelabelten Daten mittels der ML-Modelle automatisch in 2 Cluster mit normalen und anomalen Daten eingeteilt werden. Nach der Clustereinteilung wird zwecks Untersuchung anhand der in Wahrheit vorhandenen Labels „Anomalie ja/nein“ die Qualität der Zuordnung überprüft und damit das Potential dieser Vorgehensweise für den realen Fall der Anomaliedetektion bewertet. Die Teilschritte für das unüberwachte Clustering zur Anomaliedetektion sind im Folgenden beschrieben.

Datenset-Aufteilung und Definition der Validierungsmethoden

Im Falle des unüberwachten Clusterings ist eine Set-Einteilung oder Auswahl der Validierungsmethode nicht notwendig, da bei dieser ML-Verfahrensgruppe die Daten nicht in ein Trainings- und z. B. Validierungsset eingeteilt werden.

Feature-Vorbereitung

Die generell empfohlene Daten-Skalierung erfolgt in Form der Standardisierung (siehe Abschnitt 2.3.2.3). Die Standardisierung wird gewählt, da diese die Ausreißer in den Feature-Vektoren nicht ausgleicht, was innerhalb der Anomaliedetektion von Bedeutung sein könnte [GS21, S. 123]. Das Ergebnis hieraus ist zum einen die erste Feature-Vorbereitungsmethode und zum anderen der Input für die weiteren beiden Vorgehensweisen zur Feature-Vorbereitung. Das Vorgehen mit den Einstellparametern ist systematisch in der Tabelle 6.7 zusammengefasst. Hierbei sei erwähnt, dass in dieser Arbeit unter dem Begriff Feature-Vorbereitung die Operationen der Transformation der Feature-Matrix oder der Feature-Selektion aus der Feature-Matrix zusammengefasst werden. Diese Prozeduren können einer Dimensionsreduktion (z. B. Principal Component Analysis) oder einer Anpassung ohne Dimensionsreduktion (z. B. Z-Standardisierung) zwecks einer höheren ML-Modellgüte dienen.

Tabelle 6.7: Feature-Vorbereitung für das Clustering innerhalb der Anomaliedetektion

Methode	Eigenschaften
Z-Standardisierung (Stand _F)	Transformation der Spalten $p_{F,i}$ der Feature-Matrix auf einen Datenvektor mit Mittelwert $\bar{x} = 0$ und Standardabweichung $s = 1$ (in der jeweiligen Feature-Einheit)
Principal Component Analysis (PCA _F)	Auswahl der Hauptkomponenten als Features, die in Summe mind. 95% der Datenvariation beschreiben
Laplace-Punktwert (Lapl _F)	Auswahl der Features, deren Lapl _F größer als der Durchschnittswert aller Lapl _F + dessen 3-fache Standardabweichung ist; falls keine Features die Bedingung erfüllen, dann Auswahl der Features, deren Lapl _F mindestens das 0,95-fache des maximalen Lapl _F der Datenreihe beträgt

Feature-Signifikanzanalyse

Basierend auf den Ergebnissen der Feature-Vorbereitung für das Clustering ist eine Feature-Signifikanzanalyse in dieser Arbeit nicht möglich. Dies liegt zum einen daran, dass die eingesetzte Z-Standardisierung und Principal Component Analysis eine Feature-Selektion nicht durchführen. Für weitere Begründung sei auf den Ergebnisabschnitt 8.1.1 verwiesen.

Modell-Training

Es erfolgt eine Anwendung der Modelle, bei denen eine feste Clusteranzahl vorgegeben wird, da diese für die beiden Fälle der binären Anomaliedetektion (Zustände: Anomalie ja/nein; Cluster-Vorgabe: 2) und der spezifischen Anomaliedetektion (Zustände: keine Anomalie / doppelt / schräg / nicht durch / angebohrt; Cluster-Vorgabe: 5) eindeutig ist. Es entstehen, wie in Abbildung 6.11 verzeichnet, 9 Modellierungs-Pipelines. Die verwendeten ML-Algorithmen sind in der Tabelle 6.8 aufgelistet.

Es werden diejenigen Algorithmen für die finale Modellierung ausgewählt, deren Ergebnisqualität bei einer Wiederholung ähnlich ist. Bei der Agglomerativen Hierarchischen Clusteranalyse AC_{MC} wurde in Voruntersuchungen bei Wiederholungsmodellierungen ein gleichbleibendes Cluster-Ergebnis erreicht. Bei K-Means $KM_{n_{MC}}$ und K-Medoids $KM_{d_{MC}}$ ist eine identische Clustering-Ergebnisqualität des besten Modells bei 100 Clustering-Wiederholungen beobachtet worden. Das beste Modell während der Trainings-Iterationen wird clusterintern anhand der niedrigsten Datenpunktabstände zum Clustermittelpunkt ermittelt [Mat24a]. Dieses wiederholte Vorgehen ist für die K-Means und K-Medoids-Algorithmen sinnvoll, da deren Clustervorgang in Abhängigkeit der (zufällig) gewählten Start-Clusterkoordinaten konvergiert [Kub17, S. 280].

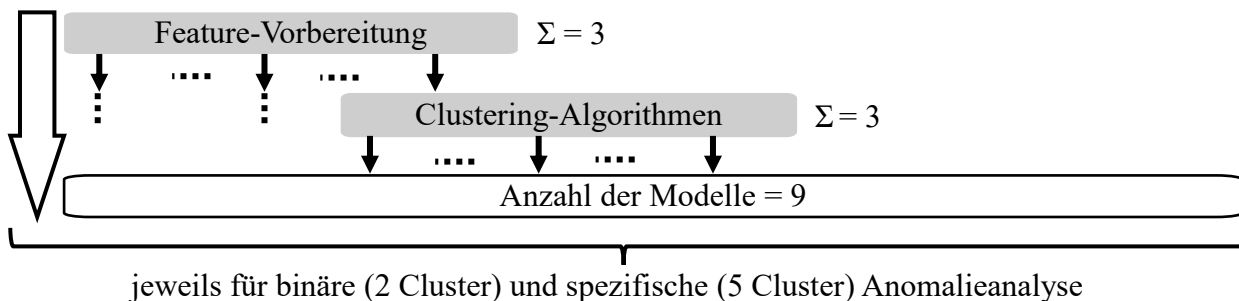


Abbildung 6.11: Training der Clustering-Modelle (= Modellierungs-Pipelines bestehend aus Feature-Vorbereitung und Clustering-Algorithmus) für die Prozessanomalie-Detektion

Tabelle 6.8: ML-Algorithmen beim unüberwachten Clustering zur Prozessanomalie-Detektion

ML-Algorithmus	spezifische Einstellungen
K-Means ($KM_{n_{MC}}$)	$\left. \begin{array}{l} \text{max. Anzahl Iterationen = Anzahl der} \\ \text{Trainings-Beispiele;} \\ \text{Anzahl Wiederholungen = 100} \end{array} \right\}$
K-Medoids ($KM_{d_{MC}}$)	
Agglomerative Hierarchische Clusteranalyse (AC_{MC})	Standardeinstellungen

Modell-Evaluation

Bei der Evaluation der Modelle wird die Feature-Vorbereitungs- und Modell-Trainingszeit sowie die Qualität der Cluster-Zuordnung mithilfe der Normalisierten Gegenseitigen Information (en. Normalized Mutual Information (NMI_E)) bewertet. Die Nutzung von NMI_E erfolgt, da die wahren Labels der Daten vorhanden sind und mit dieser Metrik neben der Ähnlichkeit der Daten innerhalb eines Clusters auch die Separation zwischen den Clustern bewertet wird [AJ03]. Im Anhang A.11.1 sind die Evaluationskennzahlen e_j zusammengefasst.

Modell-Ranking

Die Identifikation der besten Modellierungs-Pipeline (Kombination aus Feature-Vorbereitung und ML-Algorithmus) für eine bestimmte Analyse erfolgt in folgenden Schritten.

1. Zuerst erfolgt eine Skalenfestlegung, bei welchem Wert einer Evaluationskennzahl die maximale Punktezahl $m_{i,j} = 1$ und die minimale Punktezahl $m_{i,j} = 0$ zugewiesen wird: Falls ein hoher Wert einer Evaluationskennzahl vorteilhaft ist (z. B. bei NMI_E), entspricht der Maximalwert der erreichten Werte für eine bestimmte Evaluationskennzahl e_j (Laufvariable j bei $m_{i,j}$) über die Modellierungs-Pipelines (Laufvariable i bei $m_{i,j}$) hinweg dem Punktwert $m_{i,j} = 1$. Dem Minimalwert wird die Punktezahl $m_{i,j} = 0$ zugeordnet. Falls ein hoher Wert einer Evaluationskennzahl nachteilig ist (z. B. bei der Modell-Trainingszeit t_M), erfolgt die Zuordnung umgekehrt. Damit können nur Punktwerte $m_{i,j}$ im Intervall $[0; 1]$ zugeteilt werden.
2. Daraufhin wird dem Wert jeder Evaluationskennzahl $e_{i,j}$ (Laufvariable i entspricht der Modellierungs-Pipeline und j der eigentlichen Evaluationskennzahl) gemäß der beschriebenen Skalenfestlegung ein Punktwert zugewiesen. Dieser wird fallabhängig nach der Skalenart vergeben: Falls ein hoher Wert einer Evaluationskennzahl vorteilhaft ist, erfolgt die Berechnung des Punktwerts $m_{i,j}$ durch eine linear-proportionale Zuordnung gemäß dem Skalenbereich nach Gleichung 6.4. Dabei repräsentiert e_{min} den minimal erreichten Wert bei der Evaluationskennzahl e_j und e_{max} steht umgekehrt für den maximal erreichten Wert bei der Evaluationskennzahl e_j .

$$m_{i,j} = \frac{e_{i,j} - e_{min}}{e_{max} - e_{min}}, m_{i,j} \in [0, 1] \quad (6.4)$$

Falls ein niedriger Wert einer Evaluationskennzahl vorteilhaft ist, erfolgt die Berechnung des Punktwerts $m_{i,j}$ durch eine umgekehrte linear-proportionale Zuordnung gemäß dem Skalenbereich nach Gleichung 6.5.

$$m_{i,j} = \frac{e_{max} - e_{i,j}}{e_{max} - e_{min}}, m_{i,j} \in [0, 1] \quad (6.5)$$

Für den Fall, dass eine Modellierungspipeline nicht umgesetzt werden kann, erhalten jegliche Evaluationskennzahlen dieser Modellierungs-Pipeline den Punktwert $m_{i,j} = 0$.

3. Im Anschluss erfolgt eine Gewichtung der berechneten Punktwerte $m_{i,j}$ jeder Modellierungspipeline gemäß den in der Tabelle A.25 im Anhang A.11.1 definierten Gewichten g_j für jede Evaluationskennzahl e_j . Die Berechnungsvorschrift für die gewichteten Punktwerte $m_{i,j,gew}$ ist in der Gleichung 6.6 definiert.

$$m_{i,j,gew} = g_j \cdot m_{i,j}, m_{i,j,gew} \in [0, g_j] \quad (6.6)$$

Die Gewichtung erfolgt nach einer Eigeneinschätzung und die Summe der Gewichtungsfaktoren g_j ist 1.

- Die gewichteten Punktwerte $m_{i,j,gew}$ werden zu einem gewichteten Gesamtpunktwert $m_{i,gew}$ für jede Modellierungspipeline i addiert, siehe Gleichung 6.7. Dabei wird über N Evaluationskennzahlen anhand der Laufvariable j (= Evaluations-Kennzahl j) addiert. Der Maximalwert für $m_{i,gew}$ beträgt 1.

$$m_{i,gew} = \sum_{j=1}^N m_{i,j,gew}, m_{i,gew} \in [0, 1] \quad (6.7)$$

Anhand von $m_{i,gew}$ werden die Modellierungspipelines sortiert, wodurch eine *Rangliste* entsteht. Im weiteren Verlauf wird zwecks einer besseren Lesbarkeit die Variable $m = m_{i,gew}$ definiert und als solche verwendet. Während der Herleitung von $m_{i,gew}$ ist die Betonung der Gewichtung mit dem Zusatz „*gew*“ von Bedeutung. Im späteren Verlauf erfolgt jedoch ausschließlich die Betrachtung des gewichteten Gesamtpunktwerts für mehr als eine Modellierungs-Pipeline, wodurch die vorgestellte Vereinfachung als sinnvoll angesehen wird.

- Abschließend besteht die Möglichkeit, die Performance der Optimierungsschritt-Varianten der Modellierungspipelines gemäß der Abbildung 6.11 zu bewerten. Dazu wird der Mittelwert aus den gewichteten Punktwerten \bar{m} für jedes mögliche Verfahren der Optimierungsschritte gebildet. Um beispielsweise die beste Methode des Optimierungsschritts *ML-Algorithmus* zu ermitteln, muss somit über alle gewichteten Gesamtpunktwerte \bar{m} der Modellierungs-Pipelines, die als ML-Algorithmus den K-Means-Algorithmus enthalten, gemittelt werden. Dies geschieht hierbei ebenfalls für die Modellierungs-Pipelines mit den ML-Algorithmen K-Medoids und Agglomerative Hierarchische Clusteranalyse. Durch den Vergleich von sich 3 ergebenden mittleren gewichteten Gesamtpunktwerten \bar{m} kann der im Durchschnitt am präzisesten arbeitende Algorithmus bestimmt werden.

Das vorgestellte Evaluierungs- und Ranking-Vorgehen wird mit dem Ziel entwickelt, eine von den numerischen Werten der Evaluationskennzahlen abhängige, objektive Bewertungsmethode zwischen den einzelnen Modellierungspipelines sowie deren Optimierungsschritt-Varianten zu gewährleisten. Die gewichtete Gesamtpunktzahl $\bar{m} = m_{i,gew}$ wird im Folgenden nur noch als „Gesamtpunktzahl“ bezeichnet. Sie dient zum Vergleich der Modellierungspipelines untereinander und spiegelt nicht direkt deren Performance wider (dazu dienen die Evaluationskennzahlen $e_{i,j}$).

6.3.1.2 Unüberwachte Ausreißeridentifikation

Mithilfe der unüberwachten Ausreißeridentifikation wird das Ziel verfolgt, eingehende Daten mit Anomalie „ja“ oder „nein“ zu markieren. Zur Modellerstellung wird das Vorgehen der *Novelty Detection* (siehe Abschnitt 2.3.1) umgesetzt, bei dem das Training der Daten ausschließlich mit nicht anomaliebehafteten Bohrungen erfolgt. Bei der Anwendung des Modells auf neue Daten werden anomale von den normalen Bohrungen optimalerweise

separiert. Dabei ist eine Einteilung nach der Anomalieart nicht möglich.

Datenset-Aufteilung und Definition der Validierungsmethoden

Die Aufteilung zwischen dem Trainings- und Test-Set erfolgt im Verhältnis 80/20 %, siehe Abbildung 6.12. Der Trainings-Datensatz besteht ausschließlich aus normalen Bohrungen. Die Test-Set-Daten sind in etwa zu einem Fünftel aus anomalen Bohrungen zusammengesetzt. Diese Erstellung wird 4 Mal wiederholt, wodurch 4 Datensätze mit zufälliger Aufteilung der normalen Bohrungsdaten entstehen. Dies ist notwendig, um die optimalen Verfahren bei variierenden Daten zu identifizieren.




Abbildung 6.12: Datenset-Aufteilung bei der unüberwachten Ausreißeridentifikation

Feature-Vorbereitung und -Signifikanzanalyse

Diese beiden Schritte mit den dazugehörigen Begründungen entsprechen denen des unüberwachten Clusterings (siehe Abschnitt 6.3.1.1). Dies liegt daran, dass ein Labeln der Daten mit den Zielgrößen im Anwendungsfall der unüberwachten Ausreißeridentifikation nicht durchgeführt wird.

Modell-Training

Es werden die etabliertesten ML-Algorithmen der unüberwachten Ausreißeridentifikation eingesetzt, siehe deren Auflistung in der Tabelle 6.9. Die Grundlagen der ML-Algorithmen sind in dem Abschnitt 2.3.3.1 beschreiben.

Tabelle 6.9: ML-Algorithmen der unüberwachten Ausreißeridentifikation

ML-Algorithmus	Einstellungen
One-Class Support Vector Machine (ESV _{MA})	} MATLAB-StandardEinstellungen
Isolation Forest (IF _{MA})	
Local Outlier Factor (LOF _{MA})	
Robust Random Cut Forest (RRCF _{MA})	
Mahalanobis-Distanz (MD _{MA})	

Aus der Kombination von Feature-Vorbereitungsmethoden und den ML-Algorithmen entsteht eine kaskadierte Variation möglicher Modellierungs-Pipelines, die strukturell der Methodik aus dem unüberwachten Clustering in der Abbildung 6.11 entspricht. Mit 4 Datenset-Variationen, 3 Feature-Vorbereitungsmethoden und 5 ML-Algorithmen entstehen 60 Modelle.

Modell-Evaluation

Die Ermittlung der Performance-Kennzahlen wird bei den finalen Modellen, die auf der Kombination einer Feature-Vorbereitungsmethode und dem Training eines ML-Algorithmus basieren, durchgeführt. Jedes Modell wird an jedem der 4 vorhandenen Test-Datensätze getestet, siehe Abbildungen 6.12 und 6.13. Es findet eine Vorhersage des Anomaliezustandes mit dem Modell $i \in [1; 4]$ an dem Datensatz $j \in [1; 4]$ statt. Anhand des Abgleichs zwischen der Vorhersage und der wahren Zielgröße erfolgt die Berechnung der Evaluationskennzahlen e , welche in der Tabelle A.26 im Anhang A.11.2 zusammengefasst sind.

Bei der Auswertung eines Modells i an einem Test-Datensatz j , an dessen zugehörigem Trainings-Datensatz das Modell nicht trainiert wurde (d. h. $i \neq j$), kommt es i. A. zu einer Daten-Leckage. Dies bedeutet, dass im Test-Datensatz zum Teil Daten aus dem Trainings-Datensatz vorhanden sind. Der Umstand ist jedoch akzeptabel, da die Auswertung jedes Modells gleichermaßen an einem Test-Datensatz mit unbekanntem Daten und an 3 Test-Datensätzen mit wenigen bekannten Daten erfolgt. Andernfalls wäre nur ein Vergleich zwischen 4 Modellen, die an unterschiedlichen Trainings-Datensätzen trainiert und an jeweils verschiedenen Test-Datensätzen ausgewertet werden, möglich.

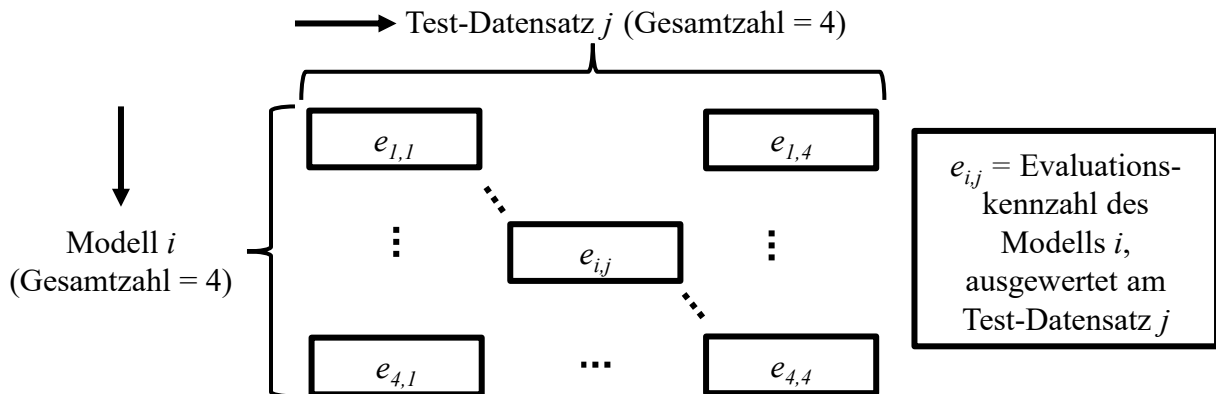


Abbildung 6.13: Modell-Evaluation bei der unüberwachten Ausreißeridentifikation

Modell-Ranking

Aufgrund des wiederholten Modelltrainings an unterschiedlichen Datensätzen bei sonst gleich bleibender Modellierungs-Pipeline (Feature-Vorbereitung und ML-Algorithmus) ist vor dem finalen *globalen* Ranking die Auswahl des besten *lokalen* Modells durchzuführen. Im Folgenden wird das in Abbildung 6.14 zusammengefasste Vorgehen erläutert.

Auswahl des besten (lokalen) Modells innerhalb einer Modellierungs-Pipeline

Für jede Modellierungs-Pipeline sind 4 Modelle an unterschiedlichen Trainings-Daten trainiert, von denen jedes an 4 verschiedenen Test-Datensätzen ausgewertet ist (siehe das Vorgehen in Abbildung 6.13). Bevor das finale Ranking zwischen den Modellierungs-Pipelines erstellt werden kann, muss innerhalb jeder Pipeline das beste Modell bestimmt werden. Gemäß der Tabelle A.26 im Anhang A.11.2 werden innerhalb jeder Modellierungs-Pipeline der Durchschnitt und die Standardabweichung der Evaluationskennzahlen an jedem Test-Set j für jedes Modell i berechnet. Durch den Durchschnitt wird die Güte der Modellierung und durch die Standardabweichung die Streuung der lokalen Modellergebnisse bewertet.

Im Anschluss erfolgt das Ranking der lokalen Modelle gemäß dem im Abschnitt 6.3.1.1

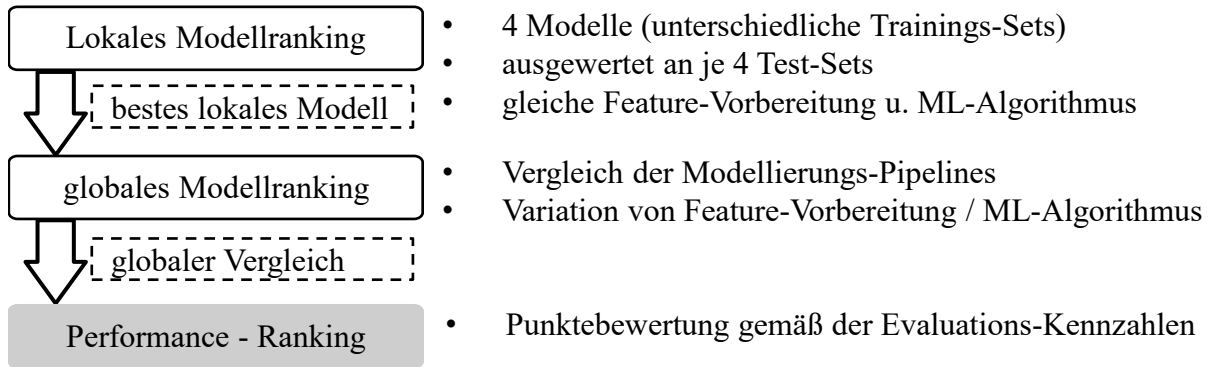


Abbildung 6.14: Anomaliedetektion: Modell-Ranking bei unüberwachter Ausreißeridentifikation

beschriebenen Vorgehen beim unüberwachten Clustering mit folgenden Anpassungen:

- Es erfolgt kein Ranking der Modellierungs-Pipelines sondern der lokalen Modelle innerhalb einer Modellierungs-Pipeline.
- Folglich wird der Schritt 5 des Ranking-Vorgehens aufgrund des lokalen Modellvergleichs und damit identischer Optimierungsschritt-Varianten nicht ausgeführt.

Die Gewichtungen g_j der einzelnen Evaluationskennzahlen e_j sind in der Tabelle A.26 im Anhang A.11.2 eingetragen. Diese sind gemäß der eingeschätzten Wichtigkeit einzelner Evaluationskennzahlen definiert. Deren Verarbeitung innerhalb der Berechnung des gewichteten Gesamtpunktwerts $m_{i,gew}$ ist in den Gleichungen 6.6 und 6.7 dargestellt. Die Summe aller Gewichtungsfaktoren beträgt 1, wodurch eine Gesamtpunktzahl von max. 1 bei der Modellbewertung erreicht werden kann.

Auswahl des besten (globalen) Modells zwischen den Modellierungs-Pipelines

In diesem Schritt werden die besten lokalen Modelle jeder Modellierungs-Pipeline untereinander verglichen und gerankt. Das Vorgehen ist analog der im Abschnitt 6.3.1.1 beim unüberwachten Clustering vorgestellten Methodik. Dabei erfolgt die Nutzung der festgelegten Evaluationskennzahlen in der Tabelle A.26 im Anhang A.11.2.

Basierend auf den Evaluationskennzahlen ist es möglich, die Ergebnisse innerhalb einer Modellierungsstufe zu vergleichen. Die geschieht durch das Mitteln der Punktwerte. So wird z. B. ausgewertet, welcher ML-Algorithmus die durchschnittlich besten Ergebnisse liefert.

6.3.1.3 Überwachte Klassifikation

Bei diskreten Anomaliezuständen eignet sich die überwachte Klassifikation zum Monitoring, falls historische gelabelte Daten von normalen und anomalen Bohrungen vorhanden sind. Im Vergleich zu den unüberwachten ML-Methoden ist es zudem von Interesse, ob der Mehraufwand der überwachten Klassifikation mit dem Daten-Labeling und dem aufwendigeren Modelltraining signifikante Vorteile bei der Vorhersagegüte bringt. Die ML-Modellierung erfolgt gemäß Tabelle 6.10. Zum einen erfolgt die Vorhersage, ob grundsätzlich ein Anomaliezustand vorliegt, ohne diesen näher zu spezifizieren. Zum anderen werden die Modelle zur Bestimmung des spezifischen Anomaliezustandes trainiert.

Tabelle 6.10: Zielgrößen der überwachten Klassifikation

Zielgröße	Klassen (Anzahl)
allgemeiner Anomaliezustand	ja/nein (2)
spezifischer Anomaliezustand	nein / doppelt / angebohrt / schräg / nicht durch (5)

Datenset-Aufteilung und Definition der Validierungsmethoden

Zum Training der ML-Modelle erfolgt die Erstellung von 4 Datensätzen durch Permutation des Originaldatensatzes, um die Robustheit der Modelle nach dem Training an einem bestimmten Trainings-Set durch die Nutzung von 4 Test-Sets präzise abzuschätzen und damit die resilienteste Modellierungs-Pipeline bestimmen zu können.

Für jeden Datensatz erfolgt die Set-Aufteilung ins Trainings-, Validierungs- und Test-Set nach 4 Methoden: *Hold-Out*-, *K-Fold*-, *Resubstitution*- und *Bootstrapping-Validierung*. Diese Validierungsarten unterscheiden sich in ihrer Güte der Modellevaluation, ihren Anforderungen zur notwendigen Varianz der Daten für eine präzise Modellbeurteilung und ihrem Rechenaufwand. Tendenziell verschlechtern sich die ersten beiden Eigenschaften bei einer Validierungsmethode mit geringeren Rechenkosten (siehe Abschnitt 2.3.2.3). Eine höhere Güte der Modellevaluation führt zur Auswahl genauer arbeitender Modelle während der später beschriebenen Hyperparameteroptimierung, vor allem bei Datensätzen mit wenigen Beispielen. Die Aufteilung in den Trainings-, Validierungs- und Testdatensatz ist aufgrund der durchgeführten (siehe spätere Beschreibung) Hyperparameteroptimierung notwendig.

Das Gesamtverfahren ist in der Abbildung 6.15 aufgezeichnet. Anfangs wird dem Gesamtdatensatz ein 20 %-iger Anteil als Test-Set entnommen, welcher erst wieder zur finalen Modellevaluation der fertig trainierten und in ihren Hyperparametern optimierten ML-Algorithmen verwendet wird. Damit ist eine verlässliche Evaluation der Modelle an unbekanntem Daten sichergestellt. Der Restanteil von 80 % verbleibt als verbundener Trainings- und Validierungsdatensatz und wird für das spätere Modelltraining inklusive Hyperparameteroptimierung verwendet. Die Datensätze sind stratifiziert und zufällig entnommen.

Das verbundene Trainings- und Validierungs-Set wird nach den in der Abbildung 6.15 aufgelisteten Validierungs-Methoden aufgeteilt. Diese Segmentierung ist notwendig, da beim Modell-Training nicht nur eine *Modellparameter*-Optimierung anhand der Trainings-Daten, sondern auch zusätzlich eine *Hyperparameter*-Optimierung gemäß externer Konfiguration stattfindet:

- *Hold-Out-Validierung* HO_V : Aus dem bisher verbundenen Trainings- und Validierungsset wird das Validierungsset als ein 20 %-iger Anteil zufällig, jedoch stratifiziert entnommen.
- *Resubstitution* RS_V : Das verbundene Trainings- und Validierungsset wird jeweils als Ganzes als Trainings- und Validierungs-Set genutzt.
- *K-Fold* KF_V : Das bisher verbundene Trainings- und Validierungsset wird in 5 Teile stratifiziert und zufällig aufgeteilt. Gemäß der Methodik der K-Fold-Validierung (siehe Abschnitt 2.3.2.3) entstehen daraus 5 Instanzen, von denen in der 1. Instanz das Validierungs-Set der 1. Teil ist und der Rest dient als Trainingsset. In der 2. Instanz ist der 2. Teil das Validierungsset und der Rest das Trainingsset, usw. .

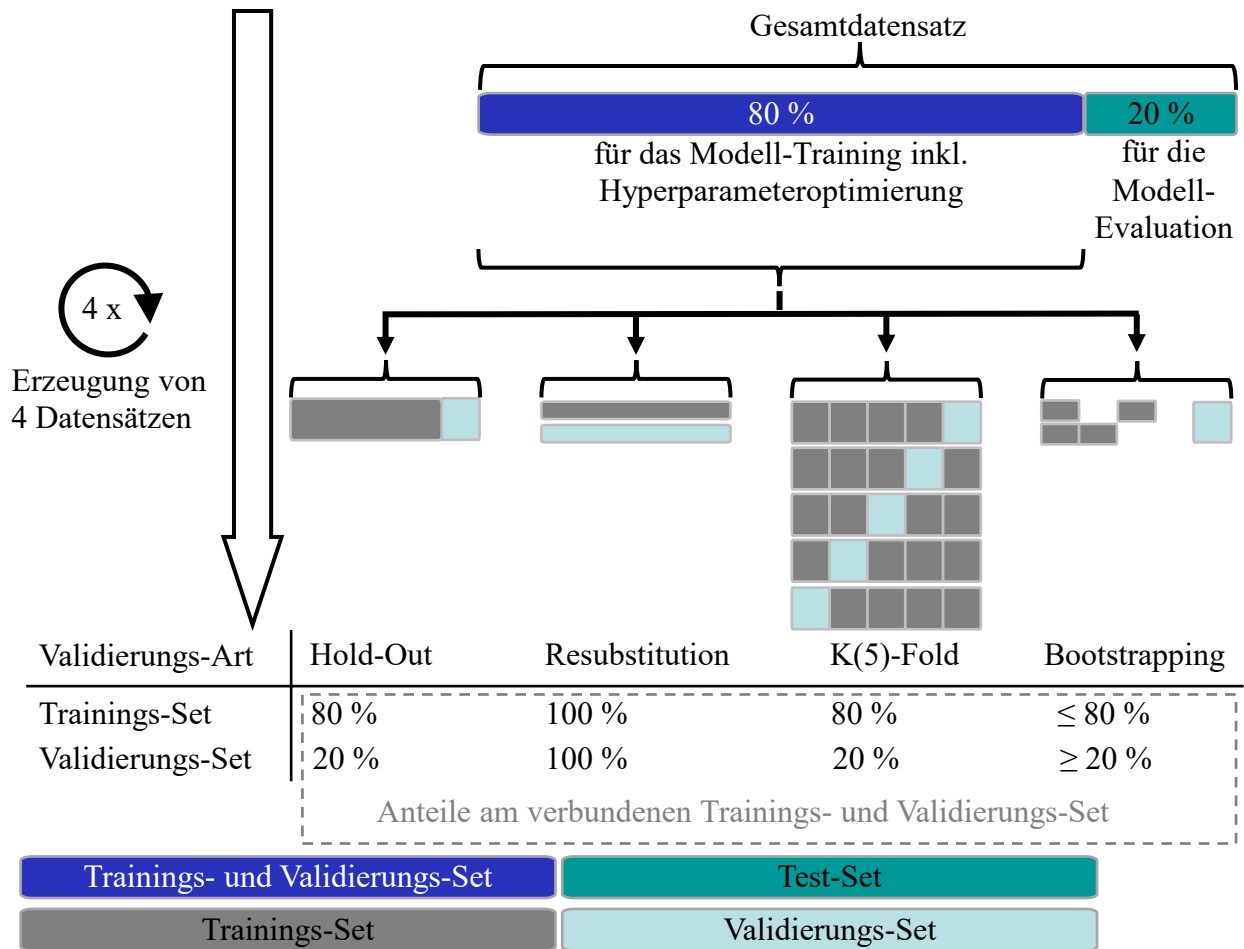


Abbildung 6.15: Anomaliendetektion: Datenset-Einteilung bei überwachter Klassifikation

- *Bootstrapping* BS_V : Zu Erzeugung des Trainings-Sets wird aus dem bisher verbundenen Trainings- und Validierungsset eine absolute Zahl an Datenbeispielen zufällig entnommen, die 80 % der Gesamtanzahl der Daten im verbundenen Trainings- und Validierungsset entspricht. Dies geschieht bei einer möglichen Datenwiederholung, d. h. nach der Entnahme des Datenbeispiels i wird der verbundene Trainings- und Validierungs-Datensatz mit diesem Datenbeispiel wieder aufgefüllt. Folglich kann in dem Trainings-Set derselbe Datenpunkt mehrmals vorhanden sein. Das Validierungsset besteht aus den nicht gezogenen Datenpunkten.

Durch die 4-fache Wiederholung der Validierungsset-Erzeugung wird eine Form der verschachtelten Validierung umgesetzt (siehe vergleichend Abschnitt 2.3.2.3).

Feature-Vorbereitung

Die Feature-Vorbereitung wird separat bei dem verbundenen Trainings- und Validierungs-Set sowie dem Test-Set vorgenommen. Der Ablauf dazu ist in der Abbildung 6.16 dargestellt. Die getrennte Durchführung ist notwendig, um den Zufluss der Dateneigenschaften des Test-Sets in das Trainings- und Validierungs-Set zu unterbinden. Die getrennte Feature-Vorbereitung in dem Trainings- und Validierungs-Set wird aufgrund fehlender Funktionalitäten in MATLAB nicht umgesetzt, da diese Datensets zusammen in den Prozess des Modelltrainings eingehen.

Gemäß der Abbildung 6.16 besteht die Feature-Vorbereitung aus den Teilschritten *Normalisierung* und *Dimensionsreduktion*:

- *Normalisierung*: Mittels Z-Standardisierung werden im ersten Schritt die Feature-Matrix-Einträge des verbundenen Trainings- und Validierungs-Sets mittels der Z-Standardisierung (siehe Abschnitt 2.3.2.3) auf die gleiche relative Skala transformiert. Die sich ergebenden Skalierungsfaktoren werden ausgelesen und als Einstellparameter für die separate Z-Standardisierung des Test-Sets verwendet.
- *Dimensionsreduktion*: Die normalisierten Datensets werden einer Dimensionsreduktion unterzogen. Dies ist notwendig, um die ML-Algorithmen nur anhand der relevanten Daten zu trainieren sowie die Modell-Überanpassung und Trainings-Zeit zu reduzieren. Die geschieht entweder durch eine Feature-Transformation in Abhängigkeit der Daten-Varianz oder durch eine Feature-Selektion in Abhängigkeit der Feature-Signifikanz bezogen auf die Zielgröße. Die Auswahl der im Folgenden erklärten Methoden basiert auf dem Stand der Technik lt. Abschnitt 2.3.2.3 und deren Rechenzeit:

Bei der *Principal Component Analysis* (PCA_F) erfolgt die Dimensionsreduktion durch die Auswahl der nach Wichtigkeit sortierten Hauptkomponenten, deren kumulierte Summe mindestens 95% der Datenvarianz erklärt.

Bei den *Feature-Selektionsalgorithmen* (*Relief-Algorithmus* Rlf_F , *Neighbourhood Component Analysis* NCA_F und *Chi-Quadrat-Ranking* $Chi2_F$) erfolgt die Dimensionsreduktion nach folgender Methodik: Auswahl der Features, deren Signifikanzwert höher ist als folgende Summe: durchschnittlicher Signifikanzwert + dreifache Standardabweichung der Signifikanzwerte. Sollte kein Feature diese Bedingung erfüllen, werden Features ausgewählt, deren Signifikanzwert größer gleich 95 % des maximalen Signifikanzwertes aller Features ist.

Die sich ergebenden Eigenschaften der Feature-Transformation (z. B. berechnete Hauptkomponenten) oder Feature-Selektion (z. B. die Zuordnungs-ID der ausgewählten Features) des verbundenen Trainings- und Validierungs-Sets werden als Einstellparameter für die Anwendung beim Test-Set genutzt.

- *ggf. wiederholte Normalisierung*: Nach dem Einsatz der Principal Component Analysis PCA_F erfolgt wiederholt die Z-Standardisierung, um die resultierenden Hauptkomponenten auf die gleiche Skala zu transformieren. Dies gilt für alle Datensets.

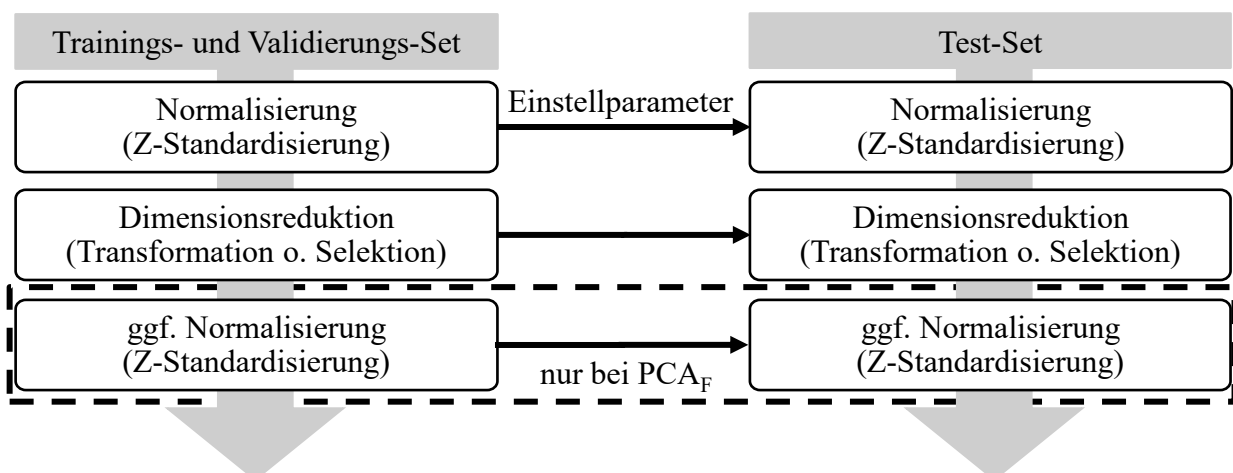


Abbildung 6.16: Anomaliedetektion: Feature-Vorbereitung bei überwachter Klassifikation (PCA_F = Principal Component Analysis)

Feature-Signifikanzanalyse

Das Ziel der Feature-Signifikanzanalyse ist die Bestimmung wichtigster Einflüsse auf die gemäß der Dimensionsreduktion selektierten Features in Bezug auf die vorliegende Zielgröße. Als Einflüsse auf die extrahierten Features werden die Varianten innerhalb der Pfade für die Feature-Extraktion (siehe Abbildung 6.6) in Form von *Sensorgroße*, *Datenrepräsentation*, *Bohrphase* und *Domäne* bezeichnet. So ist beispielsweise von Interesse, welcher Sensor die relevantesten Features hervorbringt. Entsprechend kann die Frage gestellt werden, ob z. B. Rohdaten oder die Einhüllenden, ob z. B. die Bohrphase des Eintritts oder des Austritts sowie die Zeit- oder Frequenzdomäne die signifikantesten Features in Bezug auf die Vorhersagen beinhalten. Die Signifikanzanalyse erfolgt auf Basis der in Dimension reduzierten, verbundenen Trainings- und Validierungssets und ist dabei nur für die Feature-Selektionsmethoden möglich, da bei den Feature-Transformationsmethoden die Features als solche aufgelöst werden. Die relevantesten Features weisen die höchsten Signifikanzwerte bei den Ergebnissen der jeweiligen Feature-Selektionsmethoden innerhalb der Feature-Vorbereitung vor. Aufgrund des identischen verbundenen Trainings- und Validierungssets kann die Auswertung an dem Datenset resultierend aus einer beliebigen Validierungsmethode erfolgen.

Im ersten Schritt erfolgt die Aufstellung der Statistik zur Signifikanzbewertung für jedes in der Feature-Vorbereitung selektierte Feature über jede Datenset-Variation (Anzahl = 4) und jede Feature-Vorbereitungsmethode (Anzahl = 4) hinweg, wodurch 16 Feature-Matrizen ausgewertet werden. Die dazugehörige Schrittfolge ist in den nächsten Absätzen erklärt. Das Ergebnisschema ist in der Tabelle 6.11 zu sehen. Als wichtigste Feature-Signifikanzkennzahlen werden die Summe der normierten Feature-Signifikanzwerte $\Sigma_{F,i}$ und die Anzahl der Vorkommnisse $N_{F,i}$ eines Features $p_{F,i}$ betrachtet. Der Wert für $\Sigma_{F,i}$ entsteht nach Division der Signifikanzwerte durch den maximalen vorkommenden Signifikanzwert bei den ausgeführten Feature-Selektionsverfahren.

Tabelle 6.11: Anomaliedetektion: Feature-Signifikanzanalyse der überwachten Klassifikation. Die statistischen Kennwerte werden aus allen 16 Feature-Matrizen, die aus den Datenset-Variationen und Feature-Vorbereitungsmethoden entstehen, kumuliert.

Feature $p_{F,i}$	statistische Kennwerte	
	Summe normierter Signifikanzwerte $\Sigma_{F,i}$	Anzahl Vorkommnisse $N_{F,i}$
$p_{F,1}$	$\Sigma_{F,1}$	$N_{F,1}$
\vdots	\vdots	\vdots

Im zweiten Schritt wird eine Signifikanzanalyse der Sensorgrößen, Datenrepräsentationen, Bohrphasen und Domänen vorgenommen, über deren Variation (= Pfadabzweigungen der Feature-Extraktion) die Features extrahiert und zur Feature-Matrix gemäß dem Vorgehen in der Abbildung 6.6 zusammengesetzt werden. Als Ausgangspunkt dient hierfür die Tabelle 6.11. Für jede Ausprägung von Sensorgroße, Datenrepräsentation, Bohrphase und Domäne werden anhand deren Vorkommnisse in der Feature-Bildung die *gewichtete* Summe der normierten Feature-Signifikanzwerte $\Sigma_{PF,wn,ij}$ und die *gewichtete* Anzahl der Vorkommnisse $N_{PF,w,ij}$ bestimmt. Die Gewichtung ist notwendig aufgrund der Summierung der Signifikanz-Kennzahlen $\Sigma_{F,i}$ und $N_{F,i}$ bei gleichzeitig inhomogenen Anteilen der Ausprägungen von Sensorgrößen, Datenrepräsentationen, Bohrphasen und Domänen bei der Feature-Extraktion.

Als Ergebnis entsteht eine Übersicht, welche gleich derjenigen in der Tabelle 6.11 ist. Darin sind die Varianten der Feature-Extraktionspfade PF_{ij} (Sensorgrößen, Datenrepräsentation, Bohrphasen und Domäne) mit der gewichteten Summe der normierten Feature-Signifikanzwerte $\Sigma_{PF,wn,ij}$ und den normierten Anzahlen der Vorkommnisse $N_{PF,n,ij}$ enthalten.

Modell-Training

Beim Modell-Training werden die Modellparameter berechnet sowie die Modell-Hyperparameter optimiert. Die Hyperparameteroptimierung ist eine zentrale Strategie zur Bestimmung der optimalen Modellkonfiguration, siehe Abschnitt 2.3.2.4. Zusammen mit den bereits beschriebenen Variationen der Modell-Validierungsarten sowie den Feature-Vorbereitungsmethoden ergibt sich eine kaskadierte Bildung von 720 Modellierungs-Pipelines für jeden der 4 permutierten Datensätze gemäß Abbildung 6.17.

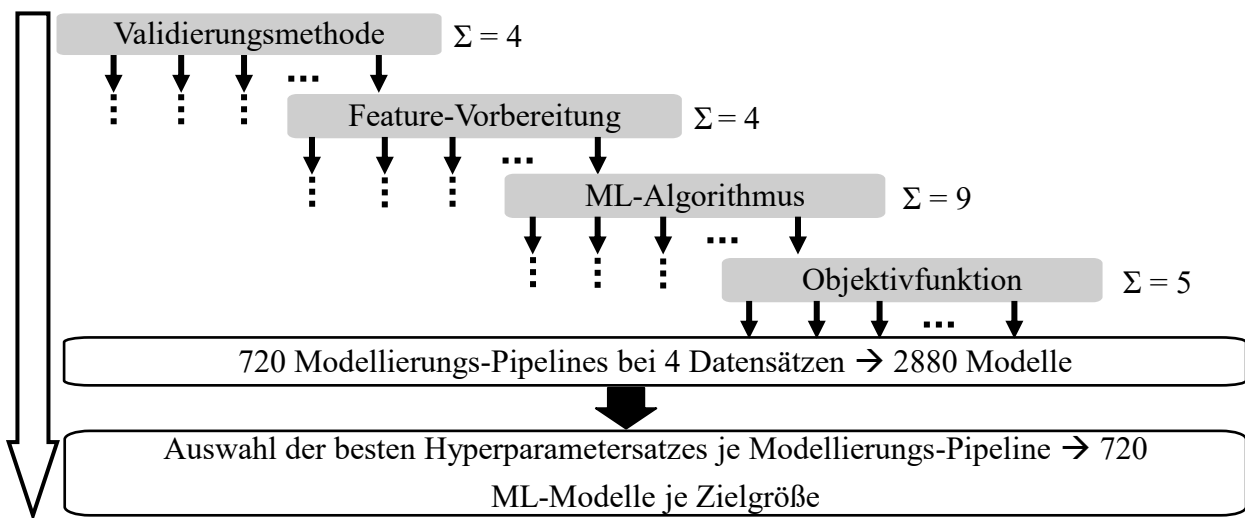


Abbildung 6.17: Anomaliedetektion: Modellierungs-Pipeline bei überwachter Klassifikation

Die eingesetzten ML-Klassifikationsalgorithmen sind im Folgenden aufgelistet: *K-Nearest Neighbour* (KNN_{MK}) / *Logistische Regression* ($LReg_{MK}$) / *Support Vector Machine* (SVM_{MK}) / *Naive-Bayes* (NB_{MK}) / *Diskriminanzanalyse* (DA_{MK}) / *künstliches neuronales Netz* (ANN_{MK}) / *Entscheidungsbaum* (DT_{MK}) / *Boosted Tree* (BT_{MK}) / *Random Forest* (RF_{MK})

Damit werden ML-Algorithmen unterschiedlicher Charakteristika auf ihre Eignung zur Anomaliedetektion untersucht. Die Wertebereich, innerhalb dessen die Hyperparameter optimiert werden, ist in den Tabellen A.21 und A.22 des Anhangs A.10.1 verzeichnet. In dieser Arbeit werden die ML-Algorithmen nur in dem Fall auf deutsch bezeichnet, falls gebräuchliche deutsche Begriffe vorhanden sind.

Zur Auswahl der besten Hyperparameter wird die *Bayessche Hyperparameteroptimierung* eingesetzt, siehe dazu das Vorgehen in der Abbildung 6.18. Nach dem Modelltraining mit einem bestimmten Hyperparametersatz erfolgt die Evaluation an dem Validierungs-Set (= eine Iteration). Aus 30 Iterationen wird die optimale Hyperparameter-Kombination gemäß der besten Modellperformance am Validierungs-Set ausgewählt. Der Einsatz der Bayesschen Optimierung erfolgt aufgrund ihrer Eigenschaft, die Kenntnisse über bekannte sowie die Exploration unbekannter Hyperparameter-Bereiche zum Auffinden der optimalen Hyperparameter-Kombinationen zu nutzen. In der Forschung wurde die Überlegenheit dieser Methode gegenüber der Zufalls- oder Rastersuche nachgewiesen [Moc82], [SLA12].

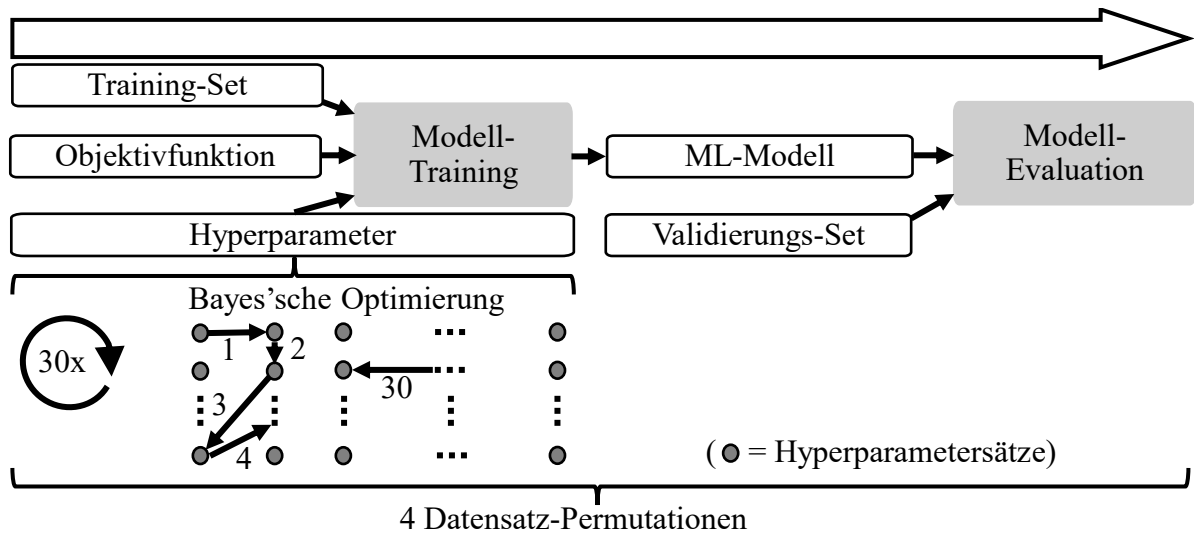


Abbildung 6.18: Anomaliendetektion: Hyperparameteroptimierung bei überwachter Klassifikation

Die Implementierung der Hyperparameter-Optimierung erfolgt mittels einer extern eingebundenen Bibliothek für Bayessche Optimierung, da hiermit eine höhere Flexibilität bzgl. der eingesetzten Objektivfunktionen erreicht wird, siehe dazu der Beispielcode A.5 im Anhang A.10.

Als Objektivfunktion werden 5 Evaluationskennzahlen für ML-Klassifikations-Algorithmen ausgewählt, die sich durch eine ganzheitliche Betrachtung der Klasseneinteilung auszeichnen. Es werden folgende, bereits früher in diesem Abschnitt bei den Ausführungen zur unüberwachten Ausreißeridentifikation und in den Tabellen A.3 und A.4 im Anhang A.1.3 definierte Evaluationskennzahlen als Objektivfunktionen eingesetzt: F1-Score FSc_E , Geometric Mean GM_E , Matthews Correlation Coefficient MCC_E , Markedness $Mark_E$, Balanced Accuracy $BAcc_E$. Hiermit wird die Vorgehensweise bei dem Modell-Training transparent definiert.

Die Kostenfunktion, die beim Lernen der internen Modellparameter minimiert wird, wird gemäß den Standardeinstellungen der MATLAB-Bibliothek des jeweiligen ML-Algorithmus übernommen [Mat24a]. Dies bringt den Vorteil mit sich, dass algorithmusabhängige Kostenfunktionen eingesetzt werden.

Es sei angemerkt, dass bei der Bildung der Modellierungs-Pipelines die Validierungsmethode und die Objektivfunktion in Bezug auf die Hyperparameter-Optimierung relevant sind. Dies bedeutet, dass mit den optimalen Methoden dieser Modellierungsstufen der Modell-Optimierungsprozess inklusive der Hyperparameter-Auswahl vorteilhaft gestaltet werden kann. Hierbei kann in abstrakter Weise von der Strategie bzw. Rahmenbedingungen des Gesamtprozesses gesprochen werden. Die Feature-Vorbereitung und der ML-Algorithmus sind für das Modelltraining und damit den eigentlichen Aufbau der Vorhersagemodelle von Bedeutung. Im übertragendem Sinne können diese beiden Modellierungsschritte als technischen Methoden des Gesamtprozesses bezeichnet werden.

Modell-Evaluation

Das Vorgehen zur Modell-Evaluation ist analog dem in der unüberwachten Ausreißeridentifikation im Abschnitt 6.3.1.2. Es werden die gleichen Evaluationskennzahlen e wie in der Tabelle A.26 im Anhang A.11.2 verwendet, zusätzlich mit der Bewertung der Dauer für die Hyperparameteroptimierung t_H .

Als Ergebnis entstehen Modellbewertungen z. B. auch für klassenbezogene Evaluationskennzahlen e wie die True Positive Rate TPR_E , womit auch die Modellperformance bei Evaluationskennzahlen getestet werden kann, auf die das Modell nicht hin optimiert wird. Für den Fall, dass die Klassenanzahl > 2 ist, wird zur Berechnung der finalen Evaluationskennzahl \bar{e}_j die Methode des *Weighted Macro-Averaging* verwendet (siehe dazu die Grundlagen im Abschnitt 2.3.4.2). Diese wird für unbalancierte Datensets empfohlen, bei denen die korrekte Bestimmung jeder Klasse gleichermaßen von Interesse ist [Opi24], [GBV20].

Modell-Ranking

Das Vorgehen zum Ranking der Modellierungs-Pipelines sowie zum Vergleich der Verfahren innerhalb einzelner Modellierungsstufen (= Validierungsmethode/Feature-Vorbereitung/ML-Algorithmus/Objektivfunktion) erfolgt wie bei der unüberwachten Ausreißeridentifikation im Abschnitt 6.3.1.2. Pro Modellierungs-Pipeline werden 4 Hyperparametersätze infolge der 4 vorhandenen Datenset-Permutationen erzeugt. Damit wird jeweils ein lokal bestes Modell aus jeder Modellierungs-Pipeline bestimmt, welches daraufhin in einem globalen Vergleich zwischen den erstellten Modellierungs-Pipelines gerankt wird.

Diese Auswertung wird durch die Bewertung der Überanpassung erweitert. Dabei werden die Ergebnisse der Objektivfunktion der Hyperparameteroptimierung (ausgewertet am Validierungs-Set) mit den Ergebnissen der dazugehörigen Evaluationskennzahl (ausgewertet am Test-Set) abgeglichen. Vor dem Abgleich werden die jeweiligen numerischen Werte auf das Intervall $[0; 1]$ normiert. Die Differenz zwischen der Evaluationskennzahl am Test-Set und dem Ergebnis der Objektivfunktion nach der Hyperparameteroptimierung ist ein Indikator für die Überanpassung des Modells. Die Ergebnisse für den Überanpassung-Faktor O_F liegen theoretisch im Intervall $[-1; 1]$, wobei -1 den denkbar schlechtesten Wert mit einer sehr großen Überanpassung repräsentiert und umgekehrt. Die Auswertung der Überanpassung ist bei der Betrachtung der Objektivfunktionen als Modellierungsstufe nicht praktikabel, da diese während der Hyperparameter-Optimierung die zu minimierende Größe ist und somit ein objektiver Vergleich dieser Größe als Evaluationskennzahl beim Validierungs- und Test-Set nicht gegeben ist.

6.3.2 Monitoring des Prozesszustandes

Die Überwachung des Prozesszustandes erfolgt mit den ML-Methoden des unüberwachten Clusterings und der überwachten Klassifikation. Diese Verfahrensauswahl ist in den diskreten, oftmals nicht-numerischen Prozesszuständen begründet.

6.3.2.1 Unüberwachtes Clustering

Die Intention der Clustering-Anwendung entsteht aus dem Szenario, bei dem Prozessspezifikationen (z. B. Drehzahl n) vorgegeben sind, jedoch ein Trainings-Datensatz mit nachweislich richtig zugeordneten Prozess-Zielgrößen nicht vorhanden ist. In der Produktion könnten die Mitgliederzahlen jedes Clusters mit den Soll-Zahlen verglichen werden. Damit entsteht ein Hinweis, ob die vorgegeben Prozesszustände eingehalten werden

Datenset-Aufteilung und Definition der Validierungsmethoden / Feature-Vorbereitung / Feature-Signifikanzanalyse

Diese Schritte erfolgen analog dem entsprechenden Vorgehen beim unüberwachten Clustering während der Anomaliedetektion in dem Abschnitt 6.3.1.1

Modell-Training

Für jede Zielgröße erfolgt eine Clusteraufteilung der Daten mit den in der Tabelle 6.8 verzeichneten ML-Algorithmen. Dabei erfolgt die Vorgabe der Clusteranzahl gemäß der möglichen Anzahl der Prozesszustände, die in der Tabelle 5.4 aufgelistet sind. Zusätzlich wird die Clusteranzahl um eins erhöht, um den Zustand *n. d.*, der für eine anomale Bohrung steht, in die Betrachtung mit einzubeziehen.

Mit den jeweils 3 beschriebenen Feature-Vorbereitungsmethoden und ML-Clusteralgorithmen ergeben sich 9 Modelle je Zielgröße und bei 7 Zielgrößen eine Gesamtheit von 63 Modellen. Zur Begründung der Modellauswahl und der dazugehörigen Spezifikationen sei auf die Ausführung der Clustering-basierten Anomaliedetektion im Abschnitt 6.3.1.1 verwiesen.

Modell-Evaluation

Die Modell-Evaluation erfolgt analog dem Vorgehen für die Clustering-basierte Anomaliedetektion im Abschnitt 6.3.1.1.

Modell-Ranking

Das Vorgehen zum Modell-Ranking für die Modellierungspipelines innerhalb einer Zielgröße entspricht ebenfalls der bereits beschriebenen Methodik zum Monitoring von Prozessanomalien mittels unüberwachtem Clustering in dem Abschnitt 6.3.1.1. Die globale Bewertung der Modellierungs-Pipelines erfolgt über die Bildung der Durchschnittswerte der Evaluationskennzahlen e_j und gewichteter Punktwerte m für jede Modellierungs-Pipeline über die Zielgrößen hinweg.

6.3.2.2 Überwachte Klassifikation

Die Anwendung der überwachten Klassifikation bietet sich aufgrund der diskret vorliegenden Prozesszustände an, siehe dazu die Tabelle 5.4. Innerhalb einzelner Zielgrößen wird zusätzlich der Zustand „n. d.“ betrachtet, der für eine Anomalie steht. Somit erfolgt bei der Prozesszustand-Überwachung eine integrierte Anomaliedetektion für den Fall, falls Fehlbohrungen in der separaten Anomaliedetektion nicht entdeckt werden.

Für die Methodik gilt, dass sich diese mit dem Vorgehen zur Anomaliedetektion mittels überwachter Klassifikation (siehe Abschnitt 6.3.1.3) deckt, da die ML-Verfahrensgruppen gemäß Tabelle 6.6 identisch sind. Daher werden die einzelnen Analyseschritte für die überwachte Klassifikation des Prozesszustandes nicht weiter ausgeführt. Es ergeben sich gemäß der Tabelle 5.4 insgesamt 7 Prozesszustandsgrößen, deren Vorhersage mittels ML-Modellen untersucht wird. Die diskreten Klassen für die Zielgrößen Werkstoff W , Drehzahl n , Vorschub pro Werkzeugumdrehung f , Aufspannweite d_c , Kontakt zwischen dem Concentric Collet der Maschine und dem Werkstück c_{CC} , Schmierung L sowie Peck-Feed-Amplitude A_{PF} sind darin ebenfalls verzeichnet.

6.3.3 Monitoring der Werkstückqualität

In der gemäß Abbildung 5.13 definierten Vorgehensweise zur ganzheitlichen Prozessüberwachung wird nach dem Prozesszustand die Werkstückqualität kontrolliert. Für diese liegen experimentelle Ergebnisse (siehe Abschnitt 5.2.3) als numerische Messwerte vor. Jedoch besteht in der Industrie auch die Möglichkeit, dass diese als diskrete Klassen vorliegen, z. B. nach einer Prüfung mit einer Gut- oder Ausschusslehre. Aus diesem Grund werden die numerischen Qualitätskennzahlen zusätzlich in diskrete Gruppen anhand industrieorientierter Toleranzfelder eingeteilt. Damit ergeben sich Zielgrößen für die Regression und Klassifikation gemäß der Tabelle 6.12. Mit dieser zweigleisigen Strategie soll zudem überprüft werden, ob sich eine Diskretisierung von kontinuierlichen Messwerten hinsichtlich der Vorhersagegüte als vorteilhaft erweist, falls nur von Interesse ist, ob ein Qualitätsmerkmal sich unter-, inner- oder oberhalb der Toleranz befindet.

Im Gegensatz zu den Analysen der Anomaliedetektion und des Prozesszustandes werden bei der Modellierung der Werkstückqualität anomaliebehaftete Bohrungen aus dem Gesamtdatensatz entnommen, welcher damit auf 1672 Bohrungen schrumpft. Bei Bohrungsfehlern ist die Vermessung der Werkstückqualität oftmals nicht möglich.

6.3.3.1 Überwachte Klassifikation

Die Ermittlung der Qualitäts-Kenngrößen ist bereits im Abschnitt 5.2.3 beschrieben. In der Tabelle 6.12 ist deren Klasseneinteilung für die überwachte Klassifikation dargestellt. Für alle Kenngrößen mit Ausnahme des Faserüberstand-Faktors Q_{FF} liegen industrierelevante Erfahrungswerte vor, die auch in die Erstellung der Klassengrenzen einfließen. Für Q_{FF} wird die Klassengrenze in etwa der Hälfte der Wertebereich-Spannweite erstellt, um die Funktionalität einer ML-basierten Klassifizierung zu testen. In der Toleranz liegende Werte werden der negativen (bei 2-Klassen-Klassifikation) bzw. der Klasse „0“ (bei Klassifikation mit mehr als 2 Klassen) zugeordnet.

Für die Methodik der überwachten Klassifikation für die Werkstückqualität gilt, dass sich diese größtenteils mit dem Vorgehen zur Anomaliedetektion und zum Prozesszustand-Monitoring mittels überwachter Klassifikation deckt (Abschnitte 6.3.1.3 und 6.3.2.2). Daher werden die einzelnen Analyseschritte für die überwachte Klassifikation des Prozesszustandes nicht weiter ausgeführt.

6.3.3.2 Überwachte Regression

Die exakte Vorhersage einer numerischen Qualitäts-Kenngröße würde neben einer Qualitätsakzeptanz-Beurteilung des vorliegenden Werkstücks auch eine Lageabschätzung der erreichten Qualität innerhalb vorgegebener Toleranzen ermöglichen. Mit dieser Kenntnis können Trends festgestellt sowie eine nähere Beobachtung des Prozesses angeordnet werden, falls sich die Qualitäts-Kennzahlen den Toleranzgrenzen nähern. Die Zielgrößen der überwachten Regression sind die gleichen wie in der überwachten Klassifikation (siehe Tabelle 6.12), diese werden jedoch in numerischer Form anstatt in diskreten Klassen aufgestellt.

Tabelle 6.12: Werkstückqualität: Klasseneinteilung bei überwachter Klassifikation

Zielgröße		diskrete Klassen inkl. Akzeptanzaussage
Grat Eintritt Q_{GE}	$[\mu\text{m}]$	$Q_{GE} < 100$ (in der Toleranz); $100 \leq Q_{GE} \leq 200$ (teilweise akzeptiert); $200 < Q_{GE}$ (oberhalb der Toleranz)
Grat Austritt Q_{GA}	$[\mu\text{m}]$	$Q_{GA} < 100$ (in der Toleranz); $100 \leq Q_{GA} \leq 200$ (teilweise akzeptiert); $200 < Q_{GA}$ (oberhalb der Toleranz)
Bohrungsdurchmesser Q_D	$[\text{mm}]$	$Q_D < 6,34$ (unterhalb der Toleranz); $6,34 \leq Q_D \leq 6,39$ (in der Toleranz); $6,39 < Q_D$ (oberhalb der Toleranz)
Mittenrauwert Q_{Ra}	$[\mu\text{m}]$	$Q_{Ra} \leq 1,6$ (in der Toleranz); $1,6 < Q_{Ra}$ (oberhalb der Toleranz)
Delaminations-Faktor Q_{DF}	$[-]$	$Q_{DF} \leq 1$ (in der Toleranz); $1 < Q_{DF}$ (oberhalb der Toleranz)
Faserüberstand-Faktor Q_{FF}	$[-]$	$Q_{FF} \leq 0,5$ (in der Toleranz); $0,5 < Q_{FF}$ (oberhalb der Toleranz)
Delaminationsradius-Faktor Q_{DR}	$[-]$	$Q_{DR} \leq 1$ (in der Toleranz); $1 < Q_{DR}$ (oberhalb der Toleranz)

Datenset-Aufteilung und Definition der Validierungsmethoden

Die Datenset-Aufteilung entspricht dem Vorgehen in der bereits beschriebenen überwachten Klassifikation der anderen Zielgrößen, siehe Abbildung 6.15 mit den dazugehörigen Beschreibungen. Somit wird der Gesamt-Datensatz gemäß 4 Validierungsmethoden (Hold-Out, Resubstitution, K(5)-Fold und Bootstrapping) bei 4 permutierten Datensätzen in Trainings-, Validierungs- und Test-Set aufgeteilt. Die Datenbeispiele werden dabei zufällig entnommen.

Feature-Vorbereitung

Das Vorgehen gleicht strukturell dem aus der bisher beschriebenen überwachten Klassifikation, was in den Ausführungen zur Anomaliedetektion beschrieben ist, siehe Abschnitt 6.3.1.3. Der einzige Unterschied besteht in der Nutzung der Feature-Selektionsmethode F-Test-Ranking FT_F statt des Chi-Quadrat-Rankings $Chi2_F$. Das F-Test-Ranking (siehe Abschnitt 2.3.2.3) wird mit den Standard-MATLAB-Einstellungen durchgeführt. Damit unterteilt sich die Feature-Vorbereitung in Feature-Transformation und -Selektion (siehe Abbildung 6.16).

Feature-Signifikanzanalyse

Die Feature-Signifikanzanalyse gleicht dem Vorgehen in der bereits beschriebenen überwachten Klassifikation der Anomaliedetektion (siehe vergleichend Abschnitt 6.3.1.3).

Modell-Training

Das Modell-Training inklusive Hyperparameter-Optimierung ist ebenfalls strukturell gleich dem Vorgehen in der bisher beschriebenen überwachten Klassifikation bei der Anomaliede-

tektion (siehe Abbildungen 6.17 und 6.18). Es werden jedoch für eine Regressionsaufgabe geeignete ML-Algorithmen und Objektivfunktionen eingesetzt. Dabei werden folgende ML-Algorithmen untersucht: *Lineare Regression* $LReg_{MR}$ / *Support Vector Machine* SVM_{MR} / *Allgemeines Additives Modell* AAM_{MR} / *Entscheidungsbaum* DT_{MR} / *Random Forest* RF_{MR} / *Boosted Tree* BT_{MR} / *künstliches neuronales Netz* ANN_{MR} .

Der Wertebereich der mittels Bayesscher Optimierung zu findenden besten Hyperparameter-sätze ist in den Tabellen A.23 und A.24 des Anhangs A.10.2 zu finden.

Als Objektivfunktionen werden die Wurzel des mittleren quadratischen Fehlers $RMSE_E$, die Wurzel des relativen mittleren quadratischen Fehlers $RRMSE_E$, das Bestimmtheitsmaß R_E^2 , der Pearson-Korrelationskoeffizient $R_{XY,E}$ sowie der relative absolute Fehler RAE_E beim Modell-Training vorgegeben. Dazu sei auf die technischen Grundlagen im Abschnitt 2.3.4.2 und die Tabelle A.27 im Anhang A.11.3 verwiesen. Die Auswahl dieser Objektivfunktionen erfolgt aufgrund deren etablierter Anwendung in der ML-Modellierung sowie deren unterschiedlicher Evaluationsmethodik (damit wird eine Sichtweise aus unterschiedlichen Perspektiven auf die Modellierungsgüten geboten). Die Kostenfunktion wird gemäß den Standardeinstellungen der MATLAB-Bibliothek des jeweiligen ML-Algorithmus übernommen [Mat24a].

Modell-Evaluation

Auch die Modell-Evaluation gleicht dem bereits eingeführten Verfahren in der überwachten Klassifikation, welches ausführlich in dem Abschnitt 6.3.1.2 zur Anomaliedetektion beschrieben ist. Es müssen lediglich die Evaluationskennzahlen e für die ML-Regression angepasst werden. Deren Auflistung samt Gewichtung ist in der Tabelle A.27 im Anhang A.11.3 zu finden.

Modell-Ranking

Das Vorgehen beim Modell-Ranking entspricht ebenfalls der für die überwachte Klassifikation entwickelten und in dem Abschnitt 6.3.1.3 erläuterten Vorgehensweise. Dabei erfolgt der Einsatz der für die Regression geeigneten und in der Tabelle A.27 des Anhangs A.11.3 verzeichneten Evaluationskennzahlen. Als Ergebnis wird für jede Zielgröße die optimale Modellierungs-Pipeline und innerhalb jeder Modellierungsstufe die beste Methode identifiziert. Im Gegensatz zu der überwachten Klassifikation ist eine allgemeine Bewertung der Überanpassung nicht möglich, da die Ergebnisse der Objektivfunktionen und Evaluationskennzahlen unterschiedlicher Zielgrößen bei der Regression i. A. nicht auf eine gemeinsame Skala normiert werden können.

6.3.4 Monitoring des Werkzeugverschleißes

Nach einer Aussage zur erzeugten Bohrungsqualität einer erstellten Bohrung ist im Hinblick auf die nächste zu fertigende Bohrung die Einschätzung von Interesse, ob ein Werkzeugwechsel empfohlen ist oder nicht. Wie in der Abbildung 5.13 aufgezeigt, erfolgt in dieser Arbeit die Werkzeugverschleiß-Vorhersage als letzter Schritt der ganzheitlichen Prozessüberwachung. Wie beim Monitoring der Werkstückqualität kann diese mittels einer überwachten Klassifikation oder Regression umgesetzt werden. Auch hier besteht die Forschungsfrage, welche der beiden ML-Verfahrensgruppen in der Industrieanwendung aufgrund ihrer Vorhersagegüte vorteilhaft ist. In dem Werkzeug-Monitoring ist das präzise Wissen des quantitativen Verschleißzustandes in Bezug auf die Reststandzeit von Interesse, womit die Relevanz der Regressionsergebnisse bei

dieser Zielgröße höher als die der Klassifikation eingeschätzt wird. Die Aufnahme des Werkzeugverschleißzustandes ist nicht in der Häufigkeit möglich wie bei der Werkstückqualität. Zudem variiert die Häufigkeit in Abhängigkeit der Zielgröße, siehe dazugehörige Erklärungen im Abschnitt 5.2.4 und 5.3 sowie in der Abbildung 5.23.

6.3.4.1 Überwachte Klassifikation

Innerhalb der überwachten Klassifikation bei der Werkzeugverschleiß-Vorhersage wird genau eine Klassengrenze (Verschleißgrenze überschritten ja/nein) gesetzt. Bei der max. Verschleißmarkenbreite V_{VB} wird als Klassengrenze eine für alle Werkstoffe gültige, grob angenäherte Größe von $V_{VB} = 0,1$ mm definiert. Für die Ausbruchsfläche an der Schneiden-Freifläche ist der Wert $V_{BA} = 0$ mm² als Grenze festgelegt. Die Haupt- und Querschneidenabflachung V_{HA} und V_{QA} und das Volumen der Hauptschneiden V_{HV} sind in ihrem Ausgangszustand von der Präparation abhängig. Daher lässt sich hierbei keine allgemeingültige Klassengrenze für die vorliegenden Werkzeuge definieren. Infolgedessen müssen für diese Zielgrößen eigene empirische Grenzen festgelegt werden. Diese entsprechen der ungefähren Hälfte der Messwertespannweite von den jeweiligen Verschleiß-Kennwerten ohne Berücksichtigung der starken Ausreißer, siehe Tabelle 6.13.

Die in der Toleranz liegenden Werte werden der negativen Klasse zugeordnet. Für die Methodik der überwachten Klassifikation für die Werkzeugverschleiß-Klassifikation gilt, dass sich diese mit dem bisherigen Vorgehen überwachter Klassifikation aus den vorherigen Abschnitten 6.3.1.3 - 6.3.3 zur Anomaliedetektion, Prozesszustand-Bestimmung und Werkstückqualität-Vorhersage deckt. Daher werden die einzelnen Analyseschritte für die überwachte Klassifikation der Werkstückqualität nicht weiter erklärt.

Tabelle 6.13: Werkzeugverschleiß: Klasseneinteilung bei überwachter Klassifikation

Zielgröße		diskrete Klassen inkl. Akzeptanzaussage
max. Verschleißmarkenbreite V_{VB}	[μm]	$V_{VB} \leq 100$ (in Toleranz); $100 < V_{VB}$ (oberhalb der Toleranz)
Ausbruch Freifläche V_{BA}	[mm ²]	$V_{BA} = 0$ (in Toleranz); $0 < V_{BA}$ (oberhalb der Toleranz)
Hauptschneiden-Abflachung V_{HA}	[μm]	$V_{HA} \leq 40$ (in Toleranz); $40 < V_{HA}$ (oberhalb der Toleranz)
Querschneide-Abflachung V_{QA}	[μm]	$V_{QA} \leq 5$ (in Toleranz); $5 < V_{QA}$ (oberhalb der Toleranz)
Hauptschneiden-Volumen V_{HV}	[mm ³]	$V_{HV} \geq 0,01$ (in Toleranz); $V_{HV} < 0,01$ (unterhalb der Toleranz)

6.3.4.2 Überwachte Regression

Ein präzises Regressionsmodell liefert eine quantitative Aussage zum Verschleißzustand des vorliegenden Werkzeugs. Anhand dessen kann der Zustand des Werkzeugs im Hinblick auf festgelegte Grenzen festgestellt werden. Kostspielige Qualitätseinbußen oder das Auftreten

eines plötzlichen Werkzeugbruchs aufgrund eines zu späten Werkzeugwechsels könnten damit gemindert werden. Die in dieser Arbeit überwachten Zielgrößen des Werkzeugverschleißes gleichen denen der überwachten Klassifikation, die bereits beschrieben und in der Tabelle 6.13 dargestellt sind. Diese werden jedoch mit ihren numerischen Werten der Modellierungs-Pipeline zugeführt.

Für die Methodik der überwachten Regression gilt, dass sich diese strukturell mit dem Vorgehen der Werkstückqualität-Überwachung mittels überwachter Regression deckt, siehe Abschnitt 6.3.3.2. Daher werden die einzelnen Analyseschritte für die überwachte Regression des Werkzeug-Verschleißes nicht weiter erklärt.

6.4 Untersuchung zum Einfluss der Datensatzgröße

Zu jeder beschriebenen Untersuchung basierend auf den experimentell gewonnenen Daten, wird der Einfluss eines künstlich vergrößerten Datensatzes ermittelt. Die Motivation und das Vorgehen mit der notwendigen Generierung künstlicher Datensätze werden in den kommenden Abschnitten 6.4.1 und 6.4.2 erläutert.

6.4.1 Motivation zur Betrachtung des Datensatzgröße-Einflusses

Eine allgemeine, jedoch sehr häufig zutreffende Annahme im maschinellen Lernen ist, dass mit größerer Datenbasis präziser arbeitende Modelle entstehen. Nur im Falle von zu wenig angepassten („zu einfachen“) Modellen mit einem hohen Bias würde eine breitere Datenbasis keine Vorteile bringen. In diesem Szenario sind zur Modellperformance-Verbesserung ML-Algorithmen mit mehr Freiheitsgraden notwendig [Ng23], [Alp14, S. 32], [Jam+13, S. 24]. Weitere, zusätzlich zu den bereits beschriebenen, Bohrungsdaten sind im Rahmen dieser Arbeit nicht vorhanden. Daher wird die Strategie verfolgt, den Datensatz mittels künstlich erzeugter Daten zu erweitern. Durch die Datenset-Erweiterung werden folgende Fragestellungen untersucht:

1. *Ist der vorliegende experimentelle Datensatz tendenziell zu klein, falls sich die Vorhersagegüte mit der Hinzunahme weiterer Daten verbessert?*
2. *Sind die ermittelten optimalen ML-Modellierungspipelines ausreichend generalisierend, um auch bei neuen Daten eine hohe Vorhersagegüte zu bieten?*

6.4.2 Vorgehen

In den weiteren Unterabschnitten werden die Modellierungsschritte erläutert. Dabei weicht das Vorgehen teilweise von der Modellierung mit den realen Daten ab. Die Durchführung jedes Modellierungsschritts gemäß der Abbildung 6.1 ist nicht notwendig. Dies liegt an der Forschungsfrage, die darin besteht, ob die optimalen identifizierten Modellierungspipelines bei höheren Datenmengen präziser arbeiten. Daher werden aus der Abbildung 6.1 nur folgende Modellierungsschritte ausgeführt: Sensordatenfusion, Feature-Extraktion, Datenset-Einteilung und Definition der Validierungsmethoden, Feature-Vorbereitung, Modelltraining (ohne Hyperparameter-Optimierung) und Modell-Evaluation. Die Durchführung der Hyperparameter-Optimierung ist nicht notwendig, da der Einfluss des künstlich erweiterten

Datensatzes am bereits zuvor optimierten Modell getestet wird. Die Modellierungsschritte werden in den folgenden Abschnitten näher erklärt.

Das bereits im Abschnitt 6.2.2 beschriebene Vorgehen der Sensordatenfusion wird im Kern beibehalten und zusätzlich um den Vorgang der künstlichen Datengenerierung erweitert. Die Variation der Daten geschieht innerhalb eines zweistufigen Prozesses, bestehend aus einer Skalierung und Verschiebung. Zuerst erfolgt die Multiplikation jedes Sensorgrößen-Datenvektors mit einem für jeden Datenpunkt individuellen, zufälligen Wert q_s aus dem Intervall $[0,95; 1,05]$, siehe Gleichung 6.8. Damit wird ein skaliertes Signal erzeugt.

$$\text{Datenpunkt}_{skaliert} = \text{Datenpunkt}_{original} \cdot q_s; q_s \in [0,95; 1,05] \quad (6.8)$$

Im nächsten Schritt wird gemäß der Gleichung 6.9 für jeden skalierten Datenpunkt ein zufälliger Verschiebungs-Wert erzeugt, welcher den skalierten Datenpunkt zufällig im Intervall $[-10\%; 10\%]$ seines Betrags vermindert oder erhöht. Die finale Berechnung eines Datenpunktes künstlich erzeugter Sensordaten durch Skalierung und Verschiebung ist in der Gleichung 6.10 verdeutlicht.

$$\text{Verschiebungswert} = \text{Datenpunkt}_{skaliert} \cdot q_v; q_v \in [-0,1; 0,1] \quad (6.9)$$

$$\text{generierter Wert} = \text{Datenpunkt}_{skaliert} + \text{Verschiebungswert} \quad (6.10)$$

Die stochastische Skalierung und Verschiebung der Rohdaten bewirkt auch eine Variation der gefilterten Zeitverläufe und Einhüllenden. Je realen Datensatz werden 4 zusätzliche künstliche Datensätze erzeugt, deren Sensordaten die oben beschriebene Verfremdung erfahren. Damit vergrößert sich der Datensatz um den Faktor 5. Die Zielgrößen der künstlichen Datensätze werden unverändert aus dem Originaldatensatz übernommen. In der Abbildung A.16 im Anhang A.10.3 ist zusätzlich ein Beispielergebnis zur Erzeugung künstlicher Daten zu sehen.

Die Feature-Extraktion erfolgt in Abhängigkeit des ML-Verfahrens (siehe dazu Tabelle 6.1) gemäß der bereits beschriebenen Methodik in den vorherigen Abschnitten für die Gesamtheit der Daten bestehend aus den realen und künstlichen Zeitverläufen.

Es werden 80 % der Daten als Trainings- und 20 % der Daten als Test-Set genutzt. Es wird auf das Testen an 4 Datensätzen aus derselben Grundgesamtheit verzichtet. Diese Vereinfachung kann damit begründet werden, dass bei einem größeren Datenset generell performantere Modelle erzeugt werden. Bei einem deutlichen Performance-Anstieg beim Test an einem beliebigen einzelnen Datenset würde sich ein starkes Indiz für diese Annahme ergeben. Eine Ausnahme besteht für die ML-Verfahrensgruppe Clustering. Hierbei erfolgt wie bereits früher beschrieben keine Datenset-Aufteilung.

Die Features werden gemäß der Methode vorbereitet, welche ein Bestandteil der optimalen Modellierungspipeline der jeweiligen Zielgröße ist.

Das Modell-Training erfolgt unter dem Einsatz der als optimal identifizierten Hyperparameter, wobei hierbei die Datenset-Erweiterung zum Tragen kommt. Somit wird für jede Zielgröße nur ein ML-Modell auf den künstlich erweiterten Trainings-Daten trainiert.

Das Ziel der Modell-Evaluation ist die Abschätzung, ob die Vorhersagegüte bei gleichen Modellierungspipelines mit einer größeren Datenbasis besser ist. Daher werden nur folgende

Performance-Kennzahlen des besten ML-Modells basierend auf dem realen Datenset und seinem Pendant, welches auf dem künstlich erweiterten Datenset trainiert ist, verglichen: Dauer des Modell-Trainings t_M und der Vorhersage t_V (entfällt bei der Verfahrensgruppe unüberwachtes Clustering) sowie ein Merkmal der Vorhersagegüte gemäß der ML-Verfahrensgruppe: Normalized Mutual Information NMI_E (beim unüberwachten Clustering), Matthew Correlation Coefficient MCC_E (bei unüberwachter Ausreißeridentifikation und überwachter Klassifikation) und Wurzel des mittleren quadratischen Fehlers $RMSE_E$ (bei überwachter Regression). Der Vergleich einer einzelnen Evaluationskennzahl der Vorhersagegüte ist ausreichend, da mit verbesserter Modellperformance jegliche generalisierende Kennzahlen tendenziell auch eine bessere Vorhersagegüte bestätigen.

6.5 Zusammenfassung zur ML-basierten Modellierung

In dem Kapitel 6 werden die Bestandteile der entwickelten ML-basierten Modellierung erklärt und systematisch verknüpft. Zuerst werden jeder Überwachungs-Zielgrößengruppe (Bohranomalie, Prozesszustand, Werkstückqualität und Werkzeugverschleiß) technisch sinnvolle ML-Verfahren (unüberwachtes Clustering, unüberwachte Ausreißeridentifikation, überwachte Klassifikation und Regression) zugeordnet, siehe Tabelle 6.1. Der Abschnitt 6.1 beschreibt die entwickelte MATLAB-Softwarearchitektur mit den einzelnen Verarbeitungsschritten und der Nutzerinteraktion.

Der erste Teil der implementierten Modellierungsschritte ist vom ML-Verfahren unabhängig. Dieser Part wird in dem Abschnitt 6.2 erklärt und umfasst die Schritte Messdatenimport und -aufbereitung, Sensordaten-Fusion und Feature-Extraktion. Im Abschnitt 6.3 werden die konsekutiven Modellierungsschritte, die jedoch vom genutzten ML-Verfahren abhängen, näher beleuchtet: Datenset-Aufteilung und Definition der Validierungsmethoden, Feature-Vorbereitung, Feature-Signifikanzanalyse, Modell-Training (ggf. inklusive Hyperparameteroptimierung), Modell-Evaluation und Modell-Ranking. Hierbei werden die Unterschiede und Gemeinsamkeiten der einzelnen Modellierungsschritte gemäß den ML-Verfahrensgruppen deutlich gemacht und die genutzten ML-, Evaluations- und Ranking-Algorithmen dargestellt. Der Datensatzgröße-Einfluss wird im Abschnitt 6.4 näher beleuchtet. Dabei wird auf die Erzeugung künstlicher Daten sowie auf die dabei vorgenommene Messung der Modellperformance-Änderung eingegangen.

7 Zielgrößenverläufe und Limitation grafischer Kennzahlenevaluation

In diesem Kapitel erfolgt die Darstellung der aufgenommenen Zielgrößen. Zudem wird anhand einer grafischen Kennzahlenevaluation die Herleitung der Notwendigkeit einer Untersuchung zur ML-basierten Prozessüberwachung vorgenommen.

7.1 Versuchsergebnisse der Zielgrößen

In diesem Abschnitt erfolgt die Visualisierung der aufgenommenen Zielgrößen. Im Falle nicht vorhandener Zielgrößenaufnahmen (z. B. wird der Werkzeugverschleiß nur in bestimmten Intervallen detektiert) liegen in den Diagrammen Leerbereiche vor. Offensichtliche Sprünge in den Verläufen deuten auf eine Werkzeugveränderung infolge eines Schneidenausbruchs oder einen Werkzeugwechsel sowie fallabhängig auf eine Prozesszustand-Variation (d. h. Änderung der Prozessparameter oder -bedingungen, siehe dazu Abschnitt 5.1.4.1) hin. Die kommenden Abschnitte zeigen, dass mit dem im Kapitel 5 beschriebenen experimentellen Vorgehen eine Datenbasis mit hoher Variabilität in den Zielgrößen unter realitätsnahen Randbedingungen erzeugt wird.

7.1.1 Anomaliezustand

In der Abbildung 7.1 sind die aufgetretenen Anomalien grafisch dargestellt. Deutlich ist dabei die systematische Erzeugung der Fehlbohrungen in der Versuchsreihengruppe A. In den restlichen Versuchsgruppen treten die Anomalien unbeabsichtigt auf.




Abbildung 7.1: Versuchsergebnisse der Anomaliezustand-Zielgrößen (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 und die Anomaliebeschreibungen im Abschnitt 5.2.1 zu finden)

7.1.2 Prozesszustand

Die Prozesszustände sind aus sich heraus keine Messgrößen und gemäß den Angaben zu den einzelnen Versuchsreihen-Gruppen in den Tabellen A.9 - A.13 des Anhangs A.4 ablesbar.

7.1.3 Werkstückqualität

In diesem Abschnitt erfolgt die Darstellung der aufgenommenen Qualitätskenngrößen. Leerbereiche in Diagrammen entstehen aufgrund einiger werkstoffspezifischer Kennzahlen, so ist beispielsweise die Delamination nur beim FVK-Material möglich. Als allgemeine Beobachtung kann ebenfalls im Vorfeld gesagt werden, dass abrupte Sprünge in den Messverläufen auf Werkzeugveränderungen infolge von Bohranomalien oder Werkzeugwechsel sowie aufgrund von Prozesszustand-Variation (siehe dazu weitere Angaben in 5.1.4.1) entstehen.

In der Abbildung 7.2 sind die Messdaten für den Ein- und Austrittsgrat Q_{GE} und Q_{GA} zu finden. Darin sind ebenfalls die industrierelevanten Qualitätsgrenzen eingetragen. Auffällig ist der tendenziell höhere Austrittsgrat Q_{GA} bei dem Ti64-Werkstoff.




Abbildung 7.2: Versuchsergebnisse zum Ein- und Austrittsgrat Q_{GE} und Q_{GA} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenzen: [0,1 mm; 0,2 mm]; Leerstellen entsprechen Bohrungen im CFK-Material)

Die Abbildung 7.3 zeigt Messwerte von unter-, inner- und oberhalb der Toleranz liegenden Bohrungsdurchmessern. Diese Verteilung über alle Bereiche bietet eine breite Datengrundlage für das ML-Modelltraining. Kontinuierliche Veränderung der Messgrößen entsteht u. a. durch abrasiven Verschleiß (z. B. beim Bohren von FVK in der Versuchsreihengruppe Q-CFK-D).

Die Abbildung 7.4 stellt die Rauigkeit an der Bohrungswand Q_{Ra} dar. Dabei sind Ansammlungen bzw. Sprünge infolge der Variation von Prozesszuständen oder Werkstoffen sowie Werkzeugveränderungen (z. B. Schneidwerkstoff-Ausbrüche infolge von Bohranomalien) erkennbar.

Die Zielgrößen Delaminations-Faktor Q_{DF} und Delaminationsradius-Faktor Q_{DR} sind in der Abbildung 7.5 dargestellt. Deren qualitativ ähnliches Verhalten ist aufgrund des gleichen Schadensmechanismus nachvollziehbar. Nur die Bohrungen im CFK-Material mit einer Thermoplastmatrix (Versuchsreihen $P1d$ und $A4$, siehe Abschnitt 5.1.4.1) erzeugen einen innerhalb der Toleranz liegenden Delaminationsradius-Faktor Q_{DR} . Abrupte Sprünge in den




Abbildung 7.3: Versuchsergebnisse zum Bohrungsdurchmesser Q_D (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenzen: $Q_D = 6,34\text{ mm}$ und $Q_D = 6,39\text{ mm}$)




Abbildung 7.4: Versuchsergebnisse zur Rauigkeit der Bohrungswand Q_{Ra} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $Q_{Ra} = 1,6\text{ }\mu\text{m}$)

Messverläufen deuten auf Prozessparameterwechsel oder Werkzeugveränderungen infolge von Bohranomalien oder Werkzeugwechsel hin. Die gewählten Prozessparameter und das Werkzeug (welches am Anfang im Neuzustand vorlag) sind industriell etabliert, daher muss von einem nicht anwendungsgerechten Toleranzgrenzwert für Q_{DR} ausgegangen werden. Da die Wahl eines anderen Grenzwerts durch eine Abschätzung nicht auf einer fundierteren Basis fußen würde, wird dieser bei $Q_{DR} = 1$ für das Training der ML-Modellierungs-Pipeline beibehalten.

In der Abbildung 7.6 sind die Messergebnisse zum Faserüberstand-Faktor Q_{FF} dargestellt. Die Toleranzgrenze von $Q_{FF} = 0,5$ wird empirisch auf etwa der Hälfte der halben Wertebereich-Spannweite festgelegt, da für Q_{FF} keine industrierelevanten Zahlen vorliegen.




Abbildung 7.5: Versuchsergebnisse zur Delamination (Q_{DF} = Delaminations-Faktor; Q_{DR} = Delaminationsradius-Faktor; die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenzen: $Q_{DF} = Q_{DR} = 1$)




Abbildung 7.6: Versuchsergebnisse zum Faserüberstand-Faktor Q_{FF} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $Q_{FF} = 0,5$)

7.1.4 Werkzeugverschleiß

Allgemein kann für die folgenden Abbildungen 7.7 - 7.11 gesagt werden, dass abrupte Sprünge der Messgrößen durch Veränderungen am Werkzeug infolge von Bohranomalien (z. B. bei Schneidenausbrüchen) oder Werkzeugwechsel entstehen. Ein Effekt der Prozesszustands-Variation (siehe vergleichend Abschnitt 5.1.4.1) kann, im Gegensatz zu den Beobachtungen bei der Werkstückqualität, auf die Verläufe der Werkzeugverschleiß-Zielgrößen wie erwartet nicht bestätigt werden.

Die Messwerte zur maximalen Verschleißmarkenbreite V_{VB} sind in der Abbildung 7.7 zu sehen. Bei dem Material Al2024 ist das Erkennen einer Verschleißmarke nicht eindeutig möglich. Als Toleranzobergrenze wird der Wert von $V_{VB} = 100 \mu\text{m}$ angewandt.

Die Schädigung an der Freifläche in Form der Ausbruchsfläche V_{BA} ist in der Abbildung 7.8 illustriert. Als Grenzwert dient der Zustand, bei dem kein Ausbruch vorhanden ist. Die Abschnitte konstanter Werte resultieren aus der Schlussfolgerung, dass bei identischen aufeinanderfolgenden Messwerten in den zwischenliegenden Bohrungen kein Ausbruch stattfindet.




Abbildung 7.7: Versuchsergebnisse zur maximalen Verschleißmarkenbreite V_{VB} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $V_{VB} = 100 \mu\text{m}$)




Abbildung 7.8: Versuchsergebnisse zur Ausbruchsfläche an der Freifläche V_{BA} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $V_{BA} = 0 \text{mm}^2$)

In der Abbildung 7.9 ist die Hauptschneiden-Abflachung V_{HA} der Messreihen zu sehen. Auffällig ist die zwischenzeitliche abrupte Veränderung für den Werkstoff Al2024, was auf die Bildung einer Aufbauschneide hindeutet (siehe ebenfalls Abbildung A.17 im Anhang A.12). Das Festlegen der Toleranzgrenze erfolgt hierbei empirisch bei der halben Spannweite der Messwerte.

Des Weiteren ist die Querschneide-Abflachung in der Abbildung 7.10 visualisiert. Die starken Ausreißer sind auf die Bildung der Aufbauschneide in der Versuchsreihe $Q3b$ zurückzuführen (siehe Abbildung A.17 im Anhang).

Die Abbildung 7.11 stellt die Verschleißkenngröße Hauptschneiden-Volumen V_{HV} dar. Darin ist besonders in dem Verlauf der Versuchsreihengruppe $Q-CFK-D$ der abrasive Verschleiß in Form des Schneidstoff-Volumenabtrags sichtbar. Zudem können Sprünge in dem Verlauf aufgrund von Schneidenausbrüchen auftreten.




Abbildung 7.9: Versuchsergebnisse zur Hauptschneiden-Abflachung V_{HA} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $V_{HA} = 40 \mu\text{m}$)




Abbildung 7.10: Versuchsergebnisse zur Querschneiden-Abflachung V_{QA} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $V_{QA} = 5 \mu\text{m}$)




Abbildung 7.11: Versuchsergebnisse zum Hauptschneiden-Volumen V_{HV} (die Versuchsreihen-Gruppen sind im Abschnitt 5.1.4 erläutert; Toleranzgrenze: $V_{HV} = 0,01 \text{ mm}^3$)

7.2 Limitation grafischer Kennzahlenevaluation

Nach der Analyse der Zielgrößenverläufe werden in diesem Abschnitt die Grenzen auf grafischer Auswertung basierter (und damit auf dem Expertenwissen) Prozessüberwachung aufgezeigt.

Bei einem breit variierenden Prozesszustand-Raum ist ebenfalls eine Fluktuation in den Größen der Überwachungs-Sensoren zu erwarten. Ein Beispiel hierfür wird in der Abbildung 7.12 präsentiert. Darin ist jeweils ein repräsentatives Beispiel des gefilterten Spindelmotorstroms I_{SM} für eine Bohrung jeder Versuchsreihe dargestellt und nach Werkstoff gruppiert. Bohrungen mit Anomalien werden dabei nicht dargestellt. Anhand der Verläufe in der Abbildung 7.12 wird deutlich, dass bei breiter Variation des Prozesszustands dieser mithilfe grafischer Analyse nicht eindeutig überwacht werden kann. Die Betrachtung der mittleren Spindelmotorströme I_{SM} im Vollschnitt würde eine eindeutige Trennung selbst zwischen den Werkstoffen nicht zulassen. Daraus wird die Schlussfolgerung gezogen, dass weitere Sensorgrößen unter Ausnutzung weiterer abstrakter Kennzahlen innerhalb von machine learning basierter Modellierungs-Pipelines auf ihre Eignung zur Prozessüberwachung geprüft werden sollten.




Abbildung 7.12: Repräsentative Verläufe des gefilterten Spindelmotorstroms jeweils einer normalen Bohrung aus jeder Versuchsreihe (Prozessbeschreibungen: siehe Tabellen A.9 - A.13; I_{SM} = Spindelmotorstrom, t = Zeit; Ti64 = Titan-Legierung, CFK-D = CFK mit Duroplast-Matrix, Al2024 = Aluminium-Legierung, CFK-T = CFK mit Thermoplast-Matrix)

Aufbauend auf den in der Abbildung 7.12 dargestellten Verläufen des Spindelmotor-Stroms I_{SM} wird in der Abbildung 7.13 ein weiteres Beispiel für die Grenze der grafischen Verfahren zur Prozessüberwachung aufgezeigt. Darin sind die Mittelwerte von I_{SM} im Vollschnitt über die Dauer Δt dieser Bohrphase aufgetragen. Dabei wird der Kennwert jeder ausgeführten Bohrung, inklusive der Anomalie, aufgenommen. Anzumerken ist, dass Δt ausschließlich zur besseren Visualisierung aufgetragen ist, da diese Größe beim konstanten Prozesszustand nur von der Materialdicke und der Güte der Bohrphasenerkennung abhängt und sich damit nicht zur Prozesszustand-Überwachung eignet (daher wird dieser Kennwert auch nicht als Feature in der ML-basierten Modellierung verwendet). Zudem werden anomale Bohrungen, bei denen die Identifikation der Bohrphasen nicht möglich ist, dem Punkt [0;0] in dem Streugraph zugeordnet. In den Diagrammen der Abbildung 7.13 wird deutlich, dass eine eindeutige visuelle Trennung der Prozesszustände nicht vorliegt. Es ist sichtbar, dass die Kennwerte der Anomalien z. T. denen der normalen Bohrungen gleichen. Daher ist der Aufbau eines Expertensystems basierend auf grafischer Kennzahlenevaluation nicht ohne Weiteres umsetzbar.

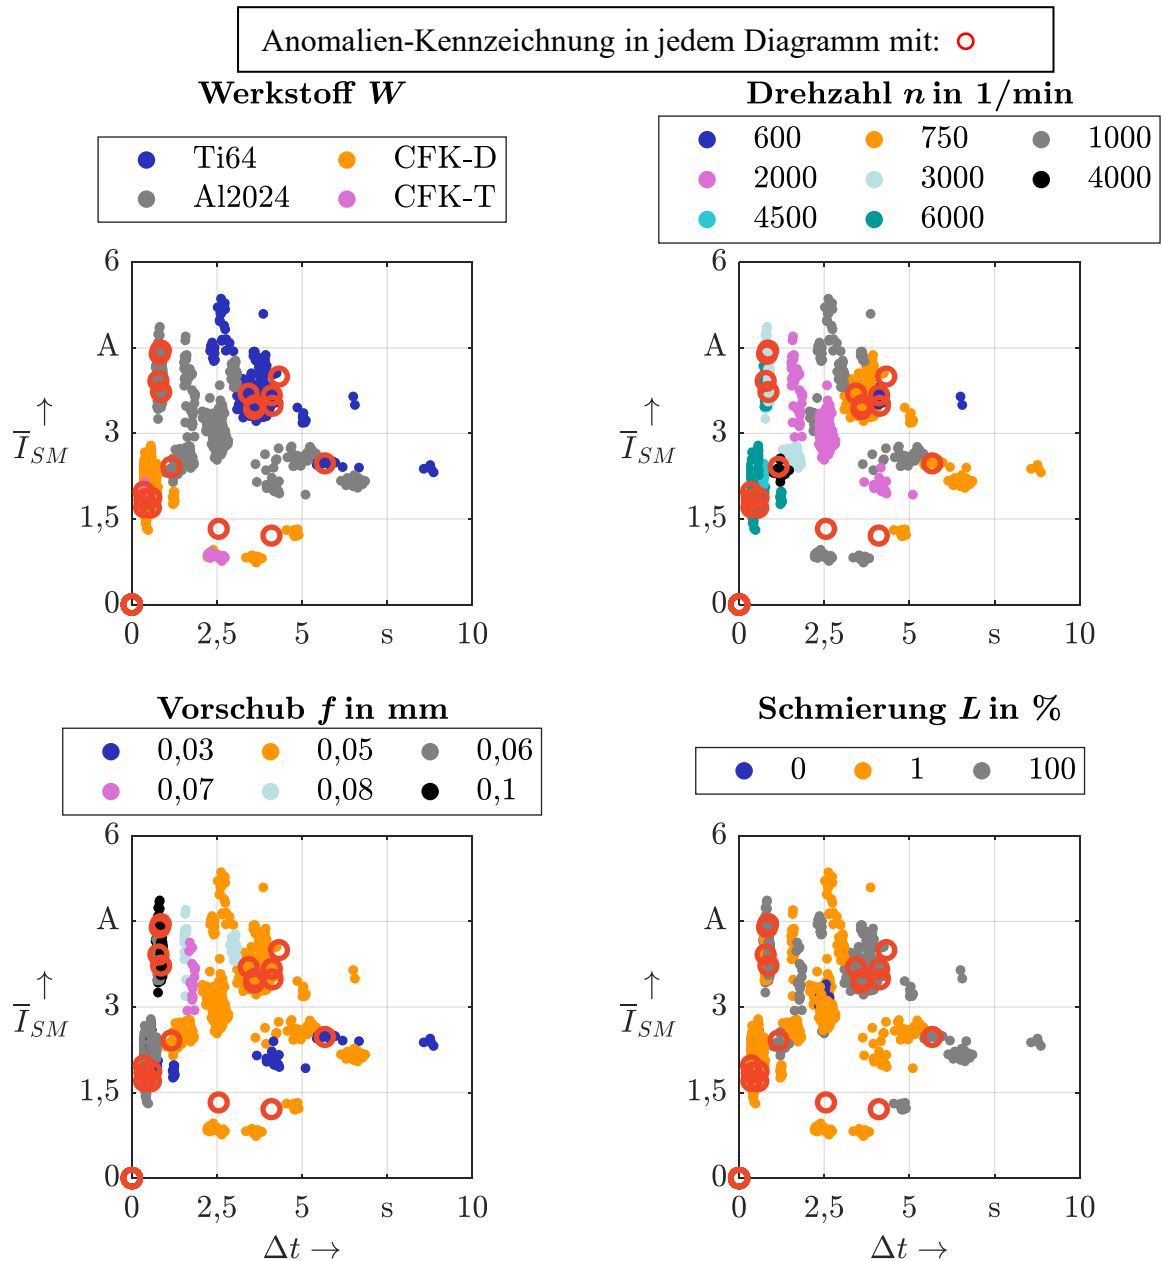


Abbildung 7.13: Mittelwert des gefilterten Spindelmotorstroms im Vollschnitt aller ausgeführten Bohrungen gruppiert nach ausgewählten Prozesszuständen (\bar{I}_{SM} = Mittelwert des Spindelmotorstroms im Vollschnitt, Δt = Dauer des Vollschnitts; Werkstoffe: Ti64 = Titan-Legierung, CFK-D = kohlenstofffaserverstärkter Kunststoff mit duroplastischer Matrix, Al2024 = Aluminium-Legierung, CFK-T = kohlenstofffaserverstärkter Kunststoff mit thermoplastischer Matrix)

In diesem Abschnitt wird festgestellt, dass ein Expertensystem zur Bohrprozess-Überwachung basierend auf grafischen Analysen an seine Grenzen stößt und das Testen der Potentiale von ML-Algorithmen ein sinnvolles Untersuchungsziel darstellt.

8 Anomaliedetektion

Dieses Kapitel enthält die Ergebnisse ML-basierter Detektion von Prozessanomalien. Wie im Abschnitt 6.3.1 beschrieben, werden hierbei die Methoden des *unüberwachten Clusterings* (Abschnitt 8.1), der *unüberwachten Ausreißeridentifikation* (Abschnitt 8.2) und der *überwachten Klassifikation* (Abschnitt 8.3) eingesetzt und in ihrer Performance bewertet. Es erfolgt dabei die Vorhersage entweder der beiden diskreten Anomaliezustände *Anomalie ja / nein* oder der einzelnen Anomaliearten *keine Anomalie / doppelt / angebohrt / schräg / nicht durch*. Es wird ebenfalls der Einfluss einer Datenset-Erweiterung mittels künstlicher Daten auf die Vorhersagegüten diskutiert. In dieses Kapitel sind teilweise die Erkenntnisse aus der vom Autor dieser Dissertation betreuten Masterarbeit von SCHIBSDAT [Schi23], die zudem in [SR23] veröffentlicht wurden, eingeflossen.

8.1 Unüberwachtes Clustering

Die Anomaliedetektion mittels unüberwachtem Clustering erfolgt durch das Einteilen der Daten in 2 (mögliche Klassen: *Anomalie ja / nein*) bzw. in 5 Cluster (mögliche Klassen: *keine Anomalie / doppelt / angebohrt / schräg / nicht durch*). Bei dieser Verfahrensgruppe ist das Labeln der Daten nicht notwendig.

8.1.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

Beim Einsatz der Feature-Vorbereitungsmethoden findet ausschließlich bei der Anwendung der Principal Component Analysis PCA_F eine Dimensionsreduktion statt, siehe Abbildung 8.1. Dabei wird die Datenmenge um 98 % reduziert. Die Anwendung des Laplace-Punktwerts $Lapl_F$ bringt für den vorliegenden Datensatz keine Dimensionsreduktion. Die Untersuchung der Merkmalsignifikanz ist nicht möglich, da in diesem Abschnitt verwendete Methoden eine Feature-Projektion ausführen, wodurch ursprüngliche Features nicht erhalten werden somit deren Signifikanz nicht abgeschätzt werden kann (siehe Abschnitt 2.3.2.3).




Abbildung 8.1: Anomaliedetektion: Feature-Vorbereitung beim unüberwachten Clustering ($Stand_F$ = Z-Standardisierung, $Lapl_F$ = Laplace-Punktwert, PCA_F = Principal Component Analysis)

8.1.2 Ranking der finalen Modelle

In diesem Abschnitt erfolgt die Ergebnisdarstellung der Modellierungs-Pipelines und deren Vergleich untereinander.

8.1.2.1 Zielgrößenbezogene Auswertung

In Abbildung 8.2 sind die Evaluationsergebnisse sowie das Ranking für die Clustereinteilung in Form von Heatmaps dargestellt. Sämtliche Modellierungs-Pipelines weisen eine sehr schlechte Cluster-Qualität gemäß der Normalised Mutual Information auf (vgl. Abschnitt 2.3.3.2; für sämtliche Modellierungs-Pipelines gilt $NMI_E \approx 0$). Zu beachten ist hierbei unabhängig von der Modellierungsgüte, dass eine Modellierungs-Pipeline nicht zwangsläufig gemäß jeder Evaluationskennzahl am vorteilhaftesten sein muss, um insgesamt die beste Bewertung gemäß der Punktezahl m zu erlangen (siehe dazugehöriges kennzahlenübergreifendes Ranking-Verfahren im Abschnitt 6.3.1.1). Dies kann u. a. damit begründet werden, dass bestimmte Evaluationskennzahlen eine höhere Gewichtung erfahren (siehe Abschnitt 6.3). Zudem werden Ergebnisse in der Abbildung 8.2 als „am besten / am schlechtesten“ farblich zusammenfassend zum Zwecke einer besseren Übersicht markiert, auch wenn sie untereinander geringfügige (vernachlässigbare) Unterschiede aufweisen.

Damit liegt keine Übereinstimmung zwischen den wahren und vorhergesagten Clustereinteilungen vor. Dieses Ergebnis gilt sowohl für die 2- als auch für die 5-Cluster-Analyse. Daraus lässt sich schlussfolgern, dass sich das unüberwachte Clustering nicht zur Anomaliedetektion eignet.

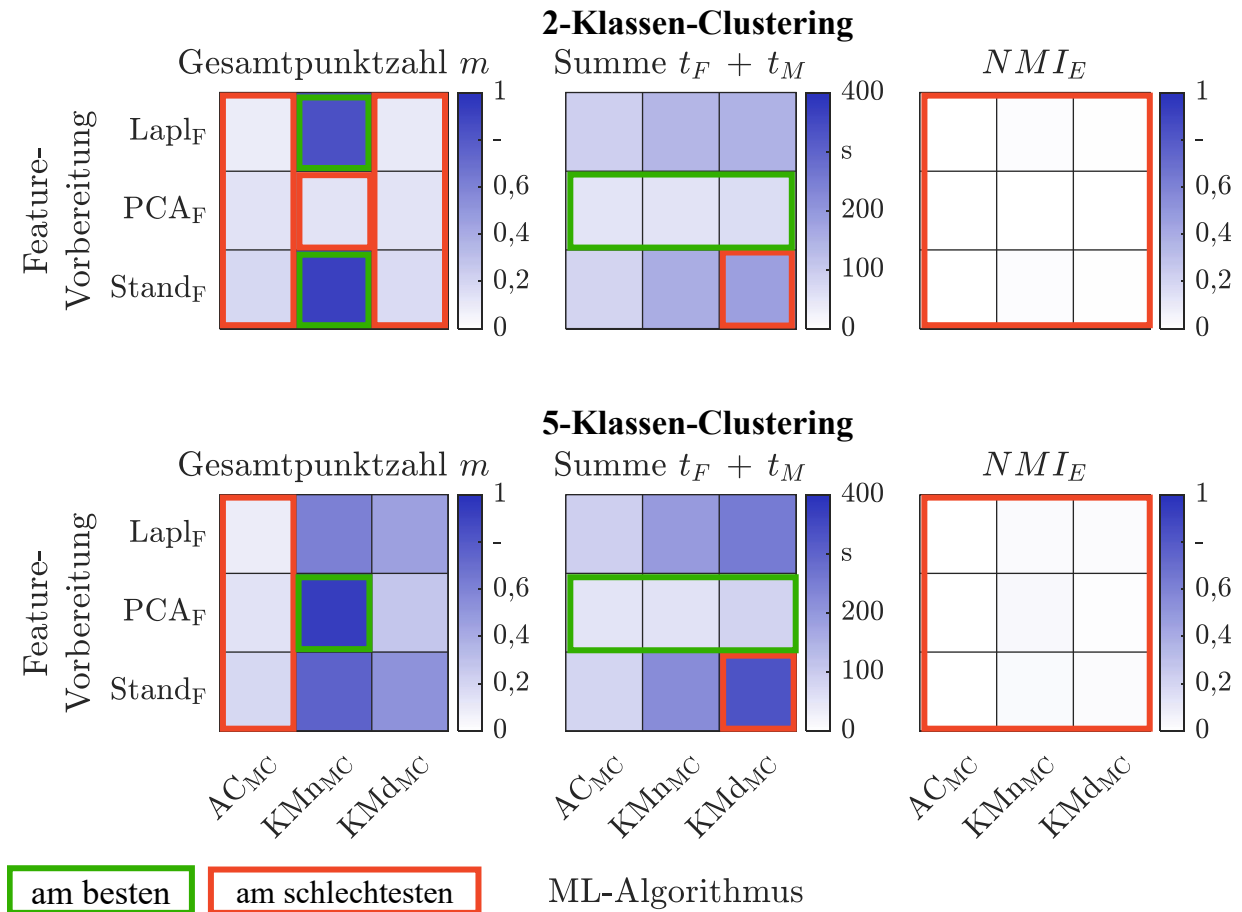


Abbildung 8.2: Modellbewertung und -ranking beim unüberwachten Clustering für binäre, d. h. „Anomalie ja/nein“, oder spezifische Detektion der Anomalien, d. h. „keine Anomalie / doppelt / schräg / nicht durch / angebohrt“ (Lapl_F = Laplace-Punktwert, PCA_F = Principal Component Analysis, Stand_F = Z-Standardisierung, KMn_{MC} = k-Means, KMd_{MC} = k-Medoids, AC_{MC} = Agglomerative Hierarchische Clusteranalyse, t_F = Zeit Feature-Vorbereitung, t_M = Zeit Modelltraining, NMI_E = Normalized Mutual Information)

8.2 Unüberwachte Ausreißeridentifikation

Die sich anschließenden Unterabschnitte präsentieren die Ergebnisse der eingesetzten Novelty Detection. Der Vorteil dieser Modellierungsmethode ist, dass für das Modelltraining keine anomalen Daten notwendig sind. Es wird auf die Feature-Vorbereitung, das Modellranking sowie die Analyse der Modellierungsstufen eingegangen.

8.2.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

Die Ergebnisse der Feature-Vorbereitung sind identisch zu denen des unüberwachten Clustering im Abschnitt 8.1.1, da bei beiden ML-Verfahrensgruppen dieselben zielgrößenunabhängigen Methoden der Feature-Vorbereitung eingesetzt werden.

8.2.2 Ranking der finalen Modelle

Im Folgenden werden die Modellergebnisse untereinander verglichen und eingestuft. Bei dieser ML-Analyseart ist nur die Vorhersage einer Zielgröße möglich: „Anomalie ja/nein“.

8.2.2.1 Zielgrößenbezogene Auswertung

Da die Modellierungs-Pipelines aus nur 2 Stufen bestehen (Feature-Vorbereitung und ML-Algorithmus), ist eine vergleichende Darstellung der Gesamtpunktzahl aller 15 lokal besten Modelle auf einer Heatmap in der Abbildung 8.3 möglich. Bei 4 durch Permutation erstellten Datensätzen werden zuerst 60 Modelle trainiert, wovon je vier einer Modellierungs-Pipeline angehören, aus denen das lokal beste Modell ausgewählt wird. In der Bewertung heben sich die Modelle mit der Feature-Vorbereitung Principal Component Analysis PCA_F und dem ML-Algorithmus Local Outlier Factor LOF_{MA} deutlich ab.




Abbildung 8.3: Unüberwachte Ausreißeridentifikation - Punktebewertung ($Lapl_F$ = Laplace-Punktwert, PCA_F = Principal Component Analysis, $Stand_F$ = Z-Standardisierung, IF_{MA} = Isolation Forest, LOF_{MA} = Local Outlier Factor, MD_{MA} = Mahalanobis-Distanz, $RRCF_{MA}$ = Robust Random Cut Forest, ESV_{MA} = One-Class Support Vector Machine)

In der Abbildung 8.4 wird auf die Güte der Modellperformance der besten 10 Modelle anhand folgender wichtigster Evaluationskennzahlen eingegangen:

- *Gesamtpunktzahl m* (siehe dazugehöriges kennzahlenübergreifendes Ranking-Verfahren im Abschnitt 6.3.1.2): Die Modellierungs-Pipeline bestehend aus der Feature-Vorbereitung Principal Component Analysis PCA_F und dem ML-Algorithmus Mahalanobis-Distanz MD_{MA} wird als bestes Modell im ausgewogenen Vergleich identifiziert (siehe spezifische Modellbeschreibung in der Tabelle A.29 im Anhang A.13.1). Die Gesamtperformance der nächsten 5 Modelle ist nur geringfügig niedriger.
- *Modellgröße H* : Die Modellierungs-Pipelines $Stand_F$ - $RRCF_{MA}$ und $Lapl_F$ - LOF_{MA} (zur Auflösung der Bezeichnungen siehe Abbildung 8.4) weisen eine Modellgröße im Bereich $H = [0,2; 1]$ GB auf. Die Werte der restlichen Modelle sind dazu im Vergleich vernachlässigbar.
- *Vorhersagezeit t_V* : Die schnellste Vorhersage von $t_V < 1s$ erfolgt durch die Modellierungs-Pipeline aus der Feature-Vorbereitung Principal Component Analysis PCA_F und dem ML-Algorithmus Local Outlier Factor LOF_{MA} .
- *Wichtigste Evaluationskennzahlen e_j der Vorhersagegüte mit Wertebereich $\Delta = [0;1]$ und $\Delta = [-1;1]$* : Hier erfolgt die Darstellung der gemäß Tabelle A.26 im Anhang A.11.2 am höchsten gewichteter, exemplarischer Evaluationskennzahlen, deren Skalenrichtung gleich ist (großer Wert = gutes Ergebnis). Es werden die Werte für e_j des besten lokalen Modells, welches an den 4 zur Verfügung stehenden Test-Sets ausgewertet wird,

gemittelt (\bar{e}_j). Zudem ist das Intervall der Standardabweichung s aufgetragen. Dabei wird deutlich, dass die Modellierungs-Pipelines mit den höchsten Gesamtpunktzahlen m auch die besten Vorhersagegüten aufweisen. Die Kennzahlen \bar{e}_j der Vorhersagegüten bester Modelle befinden sich im Ergebnisintervall $\bar{e}_j \approx [0,6; 0,77]$ und lassen sich damit generell in einem mittulguten Bereich einstufen. Mit der geringen Standardabweichung s der Evaluationskennzahlen wird ein stabiles Verhalten der besten Modelle nachgewiesen. Bei einer starken Streuung der Modellierungsergebnisse wäre eine hohe Abhängigkeit der Vorhersagegüte von dem vorliegenden Datensatz und damit Überanpassung zu erwarten.

In der Abbildung 8.5 sind die Konfusionsmatrizen für die am besten bewertete Modellierungs-Pipeline $\text{PCA}_F\text{-MD}_{\text{MA}}$ (siehe spezifische Modellbeschreibung in der Tabelle A.29 im Anhang A.13.1) dargestellt. Das dazugehörige kennzahlenübergreifende Ranking-Verfahren ist im Abschnitt 6.3.1.2 erklärt. Die linke Konfusionsmatrix zeigt die Auswertung an einem unbekanntem Test-Set und die rechte an den 4 verfügbaren Test-Sets, bei denen es zu Daten-Leckage kommt (siehe dazu Abschnitt 6.3.1.2). Der Anteil der Falschzuordnung anomaliebehafteter Bohrungen als „keine Anomalie“ ist mit $FNR_E = 0,36$ für eine Industrieanwendung zu hoch. Der Anteil normaler Bohrungen, die als Anomalien eingeordnet werden ($= FPR_E$), ist sehr gering.

Im Hinblick auf die Erkennung möglichst vieler Prozessanomalien bietet die True Positive Rate TPR_E eine ausschließlich diesem Zwecke dienende Perspektive. Demnach bietet das Modell $\text{PCA}_F\text{-ESV}_{\text{MA}}$ (siehe spezifische Modellbeschreibung in der Tabelle A.30 im Anhang A.13.1) die beste Anomalieerkennung mit einem Wert von $TPR_E = 0,98$, was in diesem Falle bedeutet, dass 98% der Anomalien erkannt werden (siehe dazugehörige Konfusionsmatrix in der Abbildung A.18 im Anhang A.13.1). Diese präzise Anomalieerkennung geschieht jedoch auf Kosten vieler Falschalarme und ist unter dem Gesichtspunkt, den Prüfaufwand zu reduzieren, ungeeignet.

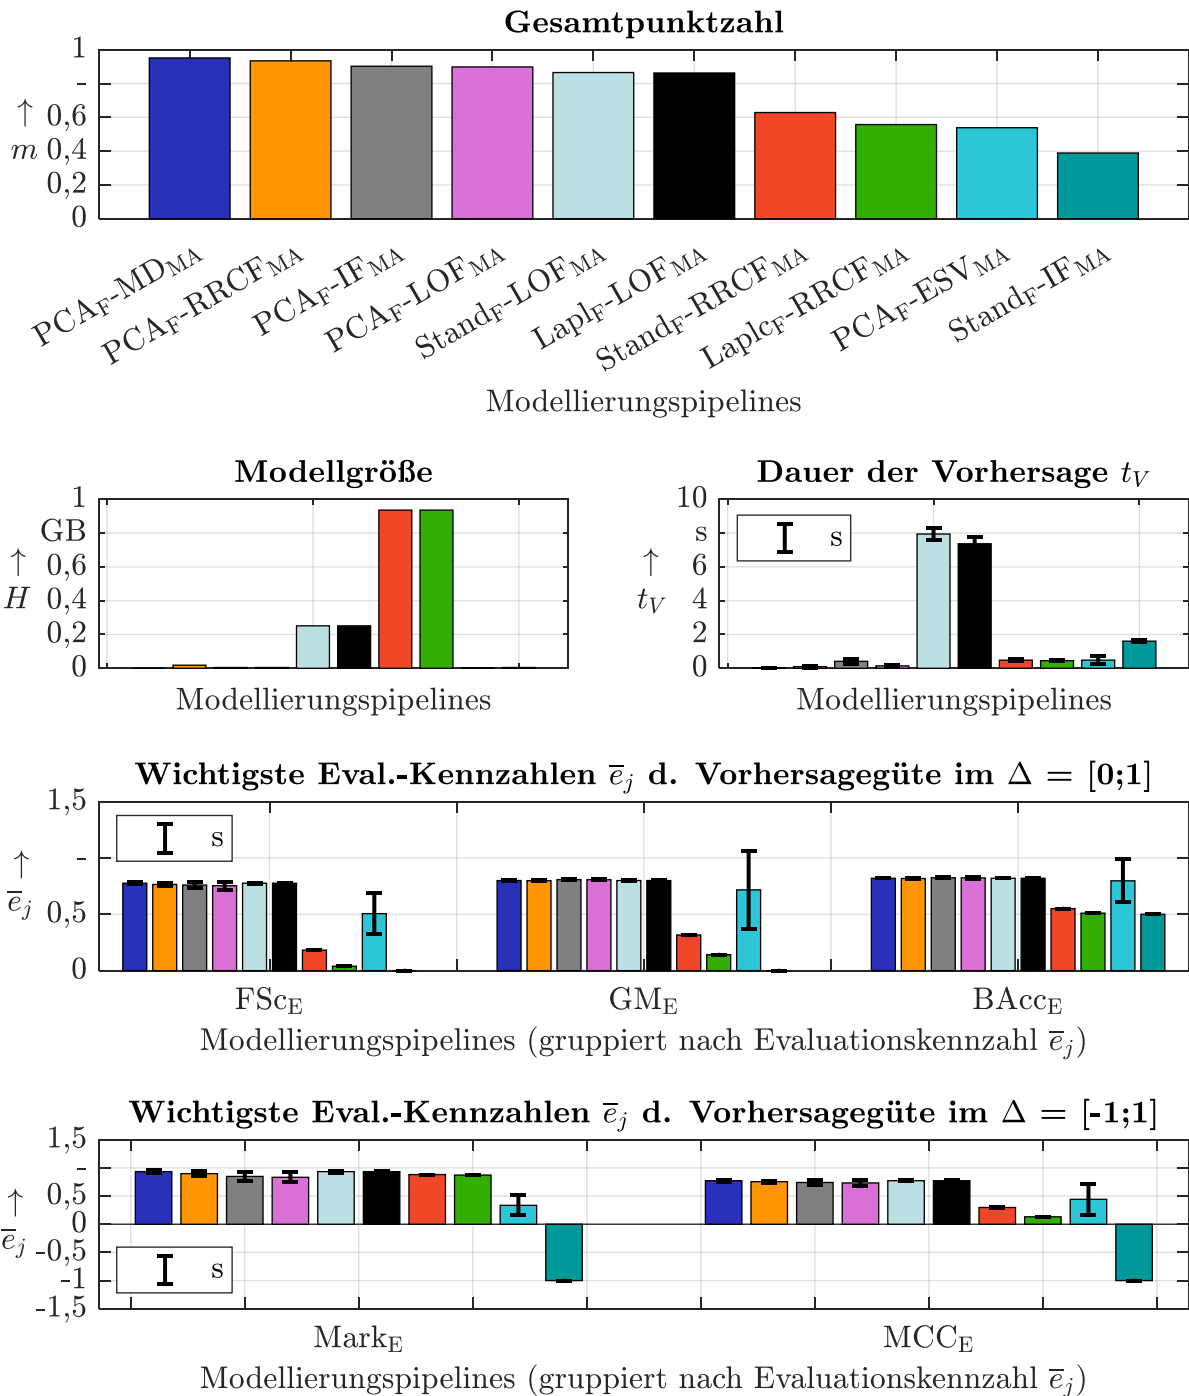


Abbildung 8.4: Unüberwachte Ausreißeridentifikation - beste Modelle (Lapl_F = Laplace-Punktwert, PCA_F = Principal Component Analysis, Stand_F = Z-Standardisierung, IF_{MA} = Isolation Forest, LOF_{MA} = Local Outlier Factor, MD_{MA} = Mahalonobis-Distanz, RRCF_{MA} = Robust Random Cut Forest, ESV_{MA} = One-Class Support Vector Machine, FS_{CE} = F-Score, GM_E = G-Mean, FM_E = Fowlkes-Mallows Index, Mark_E = Markedness, MCC_E = Matthew Correlation Coefficient, m = gewichteter Gesamt-Punktwert, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Test-Sets, H = Speichergröße des Modells, t_V = Vorhersagezeit, s = Standardabweichung, Δ = Wertebereich)




Abbildung 8.5: Unüberwachte Ausreißeridentifikation - Konfusionsmatrix der allgemein besten Modellierungs-Pipeline PCA_F-MD_{MA} (Feature-Vorbereitungsmethode: Principal Component Analysis PCA_F , ML-Algorithmus: Mahalanobis-Distanz MD_{MA} ; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert; (siehe spezifische Modellbeschreibung in der Tabelle A.29 im Anhang A.13.1))

8.2.3 Analyse der Modellierungsstufen

In der Abbildung 8.6 ist die durchschnittliche Summe gewichteter Gesamt-Punktwerte \bar{m} der Modellierungsstufen-Methoden (Feature-Vorbereitung und ML-Algorithmus) aufgetragen. Daraus lässt sich ableiten, dass die Dimensionsreduktion in Form der Principal Component Analysis PCA_F die Anomalieerkennung vereinfacht. Unter den ML-Algorithmen hebt sich der Local Outlier Factor LOF_{MA} ab. Gleichzeitig wird jedoch auch die Bedeutung der im Abschnitt 8.2.2 durchgeführten Einzelbewertung der Modellierungs-Pipelines und somit Wichtigkeit der Kombination der einzelnen Modellierungsschritte deutlich. Darin wird die Modellierungs-Pipeline bestehend aus dem ML-Algorithmus MD_{MA} als am besten bewertet. Daher wird deutlich, dass das Zusammenspiel einzelner Optimierungsstufen einen entscheidenden Einfluss hat.




Abbildung 8.6: Modellierungsstufen-Bewertung bei unüberwachter Ausreißeridentifikation (\bar{m} = durchschnittliche Summe der gewichteten Gesamt-Punktwerte; $Lapl_F$ = Laplace-Punktwert, PCA_F = Principal Component Analysis, $Stand_F$ = Z-Standardisierung, LOF_{MA} = Local Outlier Factor, $RRCF_{MA}$ = Robust Random Cut Forest, IF_{MA} = Isolation Forest, MD_{MA} = Mahalanobis Distanz, ESV_{MA} = Ein-Klassen Support Vector Machine)

8.3 Überwachte Klassifikation

Ein weitere untersuchte ML-Verfahrensgruppe zur Anomaliedetektion ist die überwachte Klassifikation, die fortlaufend mit dem Zusatz „überwacht“ aufgeführt wird, um die ML-Verfahrensgruppe durchgängig zu verdeutlichen. Die überwachte Klassifikation setzt voraus, dass die entstandenen Anomalien mit dazugehörigen Sensordaten erfasst werden. Es werden dabei folgende Analysen erstellt:

- *2-Klassen-Klassifikation:* Zielgrößen lassen sich in Klassen *Anomale ja / nein* einteilen.
- *5-Klassen-Klassifikation:* Die Zielgrößen werden gemäß ihren Anomaliearten unterteilt: *keine Anomalie/ doppelt / angebohrt / schräg / nicht durch*.

Mit der überwachten Klassifikation wird zudem der Frage nachgegangen, ob das aufwendige Labeln der Daten im Hinblick auf die Vorhersagegüte der Modelle lohnenswert ist. Im Folgenden wird nach einer Feature-Signifikanzanalyse auf die zielgrößenbezogene Vorhersagegüte der ML-Klassifikationsmodelle sowie auf deren zielgrößenübergreifende Performance eingegangen. Es wird zudem eine Untersuchung der 4 Modellierungsstufen (Validierungsmethode, Feature-Vorbereitung, ML-Algorithmus und Objektivfunktion) umgesetzt.

8.3.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

Nach der Standardisierung der erzeugten Feature-Matrizen und der anschließenden Dimensionsreduktion ist die durchschnittliche Feature-Anzahl methodenabhängig in der Abbildung 8.7 verglichen. Es werden dabei die finalen Feature-Anzahlen resultierend aus den eingesetzten Feature-Vorbereitungsmethoden Chi-Quadrat-Ranking (Chi2_F), Neighbourhood Component Analysis (NCA_F), Principal Component Analysis (PCA_F) und Relief-Algorithmus (Rlf_F) aufgetragen. Auffällig ist dabei die sehr hohe Reduktionsquote, die sich zwischen $\approx 99,9\%$ bei der Neighbourhood Component Analysis NCA_F und $\approx 97,5\%$ bei dem Relief-Algorithmus Rlf_F bewegt. Die 5-Klassen-Klassifikation benötigt je nach Feature-Selektionsalgorithmus $\approx 50\text{...}225\%$ mehr Features als die 2-Klassen-Klassifikation, um die Zielgrößen zu erklären. Die Principal Component Analysis ist zielgrößenunabhängig und weist damit eine konstante Featureanzahl auf.

Die Abbildung 8.8 fasst die Signifikanz der einzelnen Ausprägungen der Feature-Extraktionspfade Sensorgröße, Datenrepräsentation, Bohrphase und Domäne zusammen. Die Signifikanzwerte sind dabei nur innerhalb eines Diagramms untereinander vergleichbar:

- *Sensorgröße:* SmartADU-interne Sensoren haben größtenteils eine höhere Signifikanz als die meisten externen Sensoren. Diese lässt sich nicht grundsätzlich mit der externen Applikation der Sensorik begründen, da die Werkstückbewegung d deutlich signifikanter als die restlichen externen Sensoren ist. Gleichzeitig stechen keine Sensorgrößen mit hoher Signifikanz einzeln hervor, was ein Hinweis auf mangelnden Zusammenhang mit den Zielgrößen und damit möglicherweise schwierige Anomalieerkennung sein kann.
- *Datenrepräsentation:* Die Rohdaten, gefilterten Sensordaten und die gefilterte obere Einhüllende beinhalten die meiste Information. Die Signifikanz der Features aus den Rohdaten ist nachvollziehbar, da bei Anomalien kurzzeitige Effekte (z. B. Zerspankraft-Spitzen infolge hoher Spanungsquerschnitte) zu erwarten sind und diese bei gefilterten Daten tendenziell beseitigt werden.




Abbildung 8.7: Anomaliedetektion: Feature-Vorbereitung bei überwachter Klassifikation; die Balkenbeschriftungen entsprechen den über die Datensätze gemittelten finalen Featurezahlen jeder Methode ($Chi2_F$ = Chi-Quadrat-Ranking, NCA_F = Neighbourhood Component Analysis, PCA_F = Principal Component Analysis, Rlf_F = Relief-Algorithmus)

- *Bohrphase*: Der Datenbereich der Gesamtmessung ist am wenigsten relevant, was die Bedeutung der Einzelbetrachtung der Datenbereiche hervorhebt. Entgegen der Erwartung hebt sich die Bedeutung der Bohrphase Eintritt Ph_E nicht ab, obwohl die in dieser Arbeit betrachteten Anomalien zu Bohrungsbeginn entstehen.
- *Domäne*: Die Feature-Extraktion aus dem Frequenz-, Spektral- und Bildbereich bringt die signifikantesten Features bei der Anomaliedetektion hervor.

Auffällig ist, dass die Signifikanzniveaus der extrahierten Features für die 2-Klassen- und 5-Klassen-Klassifikation der Anomalieanalyse sich bis auf wenige Ausnahmen mit einer ähnlichen Tendenz bewegen.

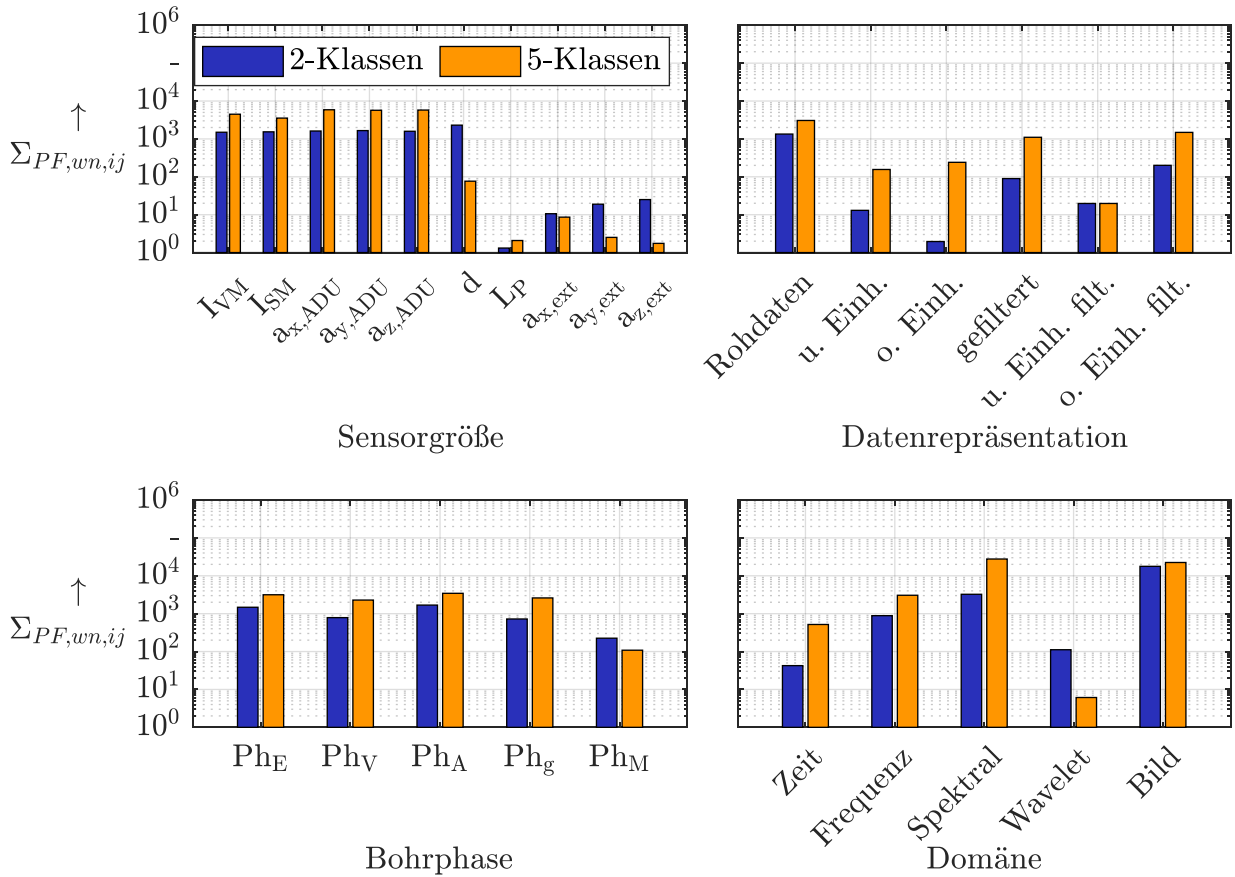


Abbildung 8.8: Anomaliendetektion: Feature-Signifikanz bei überwachter Klassifikation ($\Sigma_{PF,wn,ij}$ = gewichtete Summe der normierten Feature-Signifikanzwerte (nur innerhalb jedes einzelnen Diagramms vergleichbar), I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, d = Distanz Werkstück, L_P = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, u./o. Einh. = untere/obere Einhüllende, u./o. Einh. filt. = untere/obere Einhüllende gefiltert, Ph_E = Eintritt, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

8.3.2 Ranking der finalen Modelle

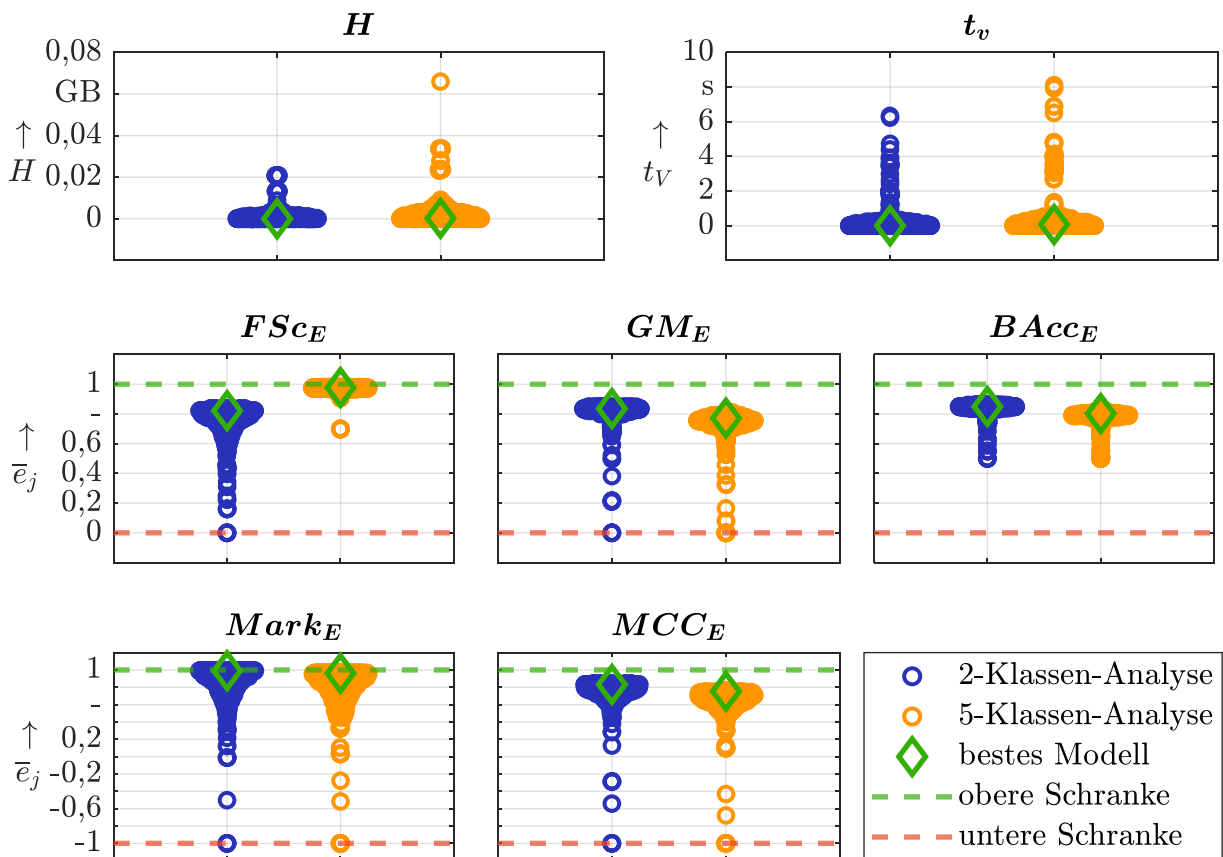
Die finalen Modelle, die streng genommen jeweils eine ganze Modellierungs-Pipeline sind, werden auf ihre Performance bei den beiden Überwachungs-Kenngrößen sowie auf ihr zielgrößenübergreifendes Verhalten hin untersucht.

8.3.2.1 Zielgrößenbezogene Auswertung

Die Abbildung 8.9 fasst die wichtigsten Evaluationskennzahlen e_j für die 2- und 5-Klassen Klassifikation zusammen. Das Auftragen von \bar{e}_j als Mittelwert über 4 Datenset-Permutationen erfolgt für jede Modellierungs-Pipeline. Die Datenpunkte sind vertikal gemäß ihrem Wert angeordnet und innerhalb jeder auf der x-Achse gruppierter Zielgröße wiederum einer auf einem Kerndichteschätzer basierender Wahrscheinlichkeitsverteilung zugeordnet [Hae+04]. Damit wird bei häufig vorkommenden Werten der horizontale Datenauftrag gestreckt, womit die Häufigkeitsverteilung der Evaluationskennzahlen \bar{e}_j leicht erkennbar ist.

Auffällig ist, dass der Großteil der Modellierungs-Pipelines eine ähnliche Performance gemäß der Abbildung 8.9 aufweist. Die Modellgröße H beträgt meist nur wenige Megabyte, und die

Vorhersagezeit t_V ist ebenfalls sehr niedrig für die meisten Modelle (< 1 s). Die Kennzahlen der Vorhersagegüten (F-Score, Geometric Mean, Balanced Accuracy, Markedness und Matthews Correlation Coefficient) bewegen sich mehrheitlich in einem Wertebereich von $e_j > 0,7$. Dies deutet auf eine sehr gute bis exzellente Vorhersagequalität hin (siehe Abschnitt 2.3.4.2). Auffällig ist dabei die unterschiedliche Tendenz zwischen der 2- und 5-Klassen-Klassifikation. Dies ist möglicherweise auf verschiedene Klassenanzahlen und damit auf den Einfluss des Weighted-Macro Averaging (siehe Abschnitt 6.3.1.3) bei der 5-Klassen-Klassifikation zurückzuführen. In der Tabelle A.31 im Anhang A.13.1 sind die Modell-Hyperparameter und exemplarische Evaluationskennzahlen für die jeweils besten Modelle, die anhand der Summe der gewichteten Gesamt-Punktwerte m bestimmt sind, eingetragen.



(Die x-Achse stellt bei jedem Graph die diskrete Repräsentation der Zielgrößen dar)

Abbildung 8.9: Anomaliedetektion: Modell-Performance bei überwachter Klassifikation (Mengendarstellung der wichtigsten Evaluations-Kennzahlen des Optimums jeder Modellierungs-Pipeline, die an 4 Test-Sets ausgewertet ist; H = Modell-Speichergröße, t_V = Dauer der Vorhersage, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Datensätze, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

In der Abbildung 8.10 werden die Konfusionsmatrizen der allgemein besten Modelle für die 2- und 5-Klassen-Klassifikation aufgezeigt (zur Beschreibung der Modell-Hyperparameter und exemplarischer Evaluationskennzahlen siehe Tabelle A.31 im Anhang A.13.1). Das dazugehörige kennzahlenübergreifende Ranking-Verfahren ist in dem Abschnitt 6.3.1.3 referenziert. Zu beachten ist, dass in den Konfusionsmatrizen die Vorhersage der Modelle für die 4 zur Verfügung stehenden Test-Sets beinhaltet ist, wodurch die Gesamtanzahl der ausgewerteten Bohrungen 1376 beträgt. Als Ergebnis lassen sich folgende Aussagen aufstellen:

- Etwa 70 % der Anomalien werden von den besten Modellierungs-Pipelines erkannt.
- Nur ein geringer Teil der normalen Bohrungen wird als Anomalie vorhergesagt.
- Die Anomalieart *schräg* kann durch die ML-Algorithmen nicht identifiziert werden
- Einige Evaluationskennzahlen sind auch für unbalancierte Datensets sehr gut geeignet, wie z. B. Matthews Correlation Coefficient MCC_E , Geometric Mean GM_E und Balanced Accuracy $BAcc_E$. Trotz weniger fehlerhafter Klasseneinteilungen (z. B. 13 von 1476) ist bei diesen ein deutlicher Abstand zur oberen Schranke der Evaluationskennzahl (= 1) ersichtlich.
- Die 5-Klassen-Modelle erkennen die Anomalien zwar teilweise als solche, können ihre Arten jedoch nicht zuverlässig unterscheiden und bieten gegenüber den 2-Klassen-Modellen keinen Mehrwert.

Anhand der Ergebnisse wird jedoch die Wichtigkeit der Nutzung unterschiedlicher Evaluationskennzahlen sowie die Notwendigkeit der Auswertung der realen Klassenzuordnung mittels Konfusionsmatrizen deutlich.




Abbildung 8.10: Anomaliedetektion: beste Modelle der überwachten Klassifikation mit ihren Konfusionsmatrizen, die alle Daten der 4 vorhandenen Test-Sets umfassen (bester 2-Klassen-Klassifizierer: Validierung: Hold-Out HO_V / Feature Vorbereitung: Chi-Quadrat-Ranking $Chi2_F$ / ML-Algorithmus: Decision Tree DT_{MK} / Objektivfunktion: Balanced Accuracy $BAcc_E$ (zur Beschreibung der Modell-Hyperparameter und exemplarischer Evaluationskennzahlen siehe Tabelle A.31 im Anhang A.13.1); bester 5-Klassen-Klassifizierer: Validierung: Resubstitution RS_V / Feature Vorbereitung: Neighbourhood Component Analysis NCA_F / ML-Algorithmus: K-Nearest Neighbour KNN_{MK} / Objektivfunktion: Matthew Correlation Coefficient MCC_E (zur Beschreibung der Modell-Hyperparameter und exemplarischer Evaluationskennzahlen siehe Tabelle A.31 im Anhang A.13.1); höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

Im Falle der Anomaliedetektion ist zudem die Betrachtung der Modellierungs-Pipelines mit der besten True Positive Rate TPR_E von hohem Interesse, da ein hoher Wert hierbei mit einer hohen Erkennung der positiven Klassen, d. h. der vorhandenen wahren Anomalien, einhergeht. In der Abbildung A.19 im Anhang A.13.1 ist die Konfusionsmatrix des 2-Klassen-Klassifizierers mit der höchsten True Positive Rate TPR_E aufgestellt. Hierbei erfolgt nur

die Betrachtung der Zielgröße „Anomalie ja/nein“, da bei der 5-Klassen-Klassifikation keine positive Klasse als solche vorliegt. Die Beschreibung der Modell-Hyperparameter und exemplarischer Evaluationskennzahlen erfolgt in der Tabelle A.32. Ähnlich wie bei der unüberwachten Ausreißeridentifikation tritt beim 2-Klassen-Klassifizierer der Effekt auf, dass die meisten Anomalien zwar erkannt werden, jedoch auch viele normale Bohrungen als Anomalie gekennzeichnet sind. Daher eignet sich diese Art des Klassifizierers nicht zum Einsatz unter dem Gesichtspunkt der Prüfaufwand-Minimierung.

8.3.2.2 Zielgrößenübergreifende Auswertung

Beim zielgrößenübergreifenden Einsatz der Modellierungs-Pipelines zeigt sich eine Bestätigung der im vorherigen Abschnitt erfolgten Feststellung, dass sich im Spitzenbereich ein Großteil der Modelle in ihrer Performance sehr ähnelt. In der Abbildung 8.11 wird dies durch sehr ähnliche Werte für die (über die Zielgrößen hinweg) gemittelte Summe der gewichteten Gesamtpunktwerte \bar{m} bestätigt. Die in etwa besten 600 Modelle von insgesamt 720 unterscheiden sich in dem Punktwert \bar{m} nur gering. Nach einem Mittelbau von etwa 100 Modellierungs-Pipelines fallen nur etwa 20 in ihrer Gesamtbewertung deutlich von der Gesamtheit ab.




Abbildung 8.11: Anomaliedetektion: zielgrößenübergreifende Auswertung der überwachten Klassifikation (\bar{m} = Durchschnitt der gewichteten Gesamtpunktwerte)

8.3.3 Analyse der Modellierungsstufen und der Überanpassung

Eine Analyse jeder Methode der 4 Modellierungsstufen sowie ihres Verhaltens im Hinblick auf die Überanpassung ist in der Abbildung 8.12 erstellt. Die technischen Grundlagen zur Überanpassung sind im Abschnitt 2.3.2.2 und die dazugehörige umgesetzte Vorgehensweise zu deren Analyse im Abschnitt 6.3.1.3 erklärt.

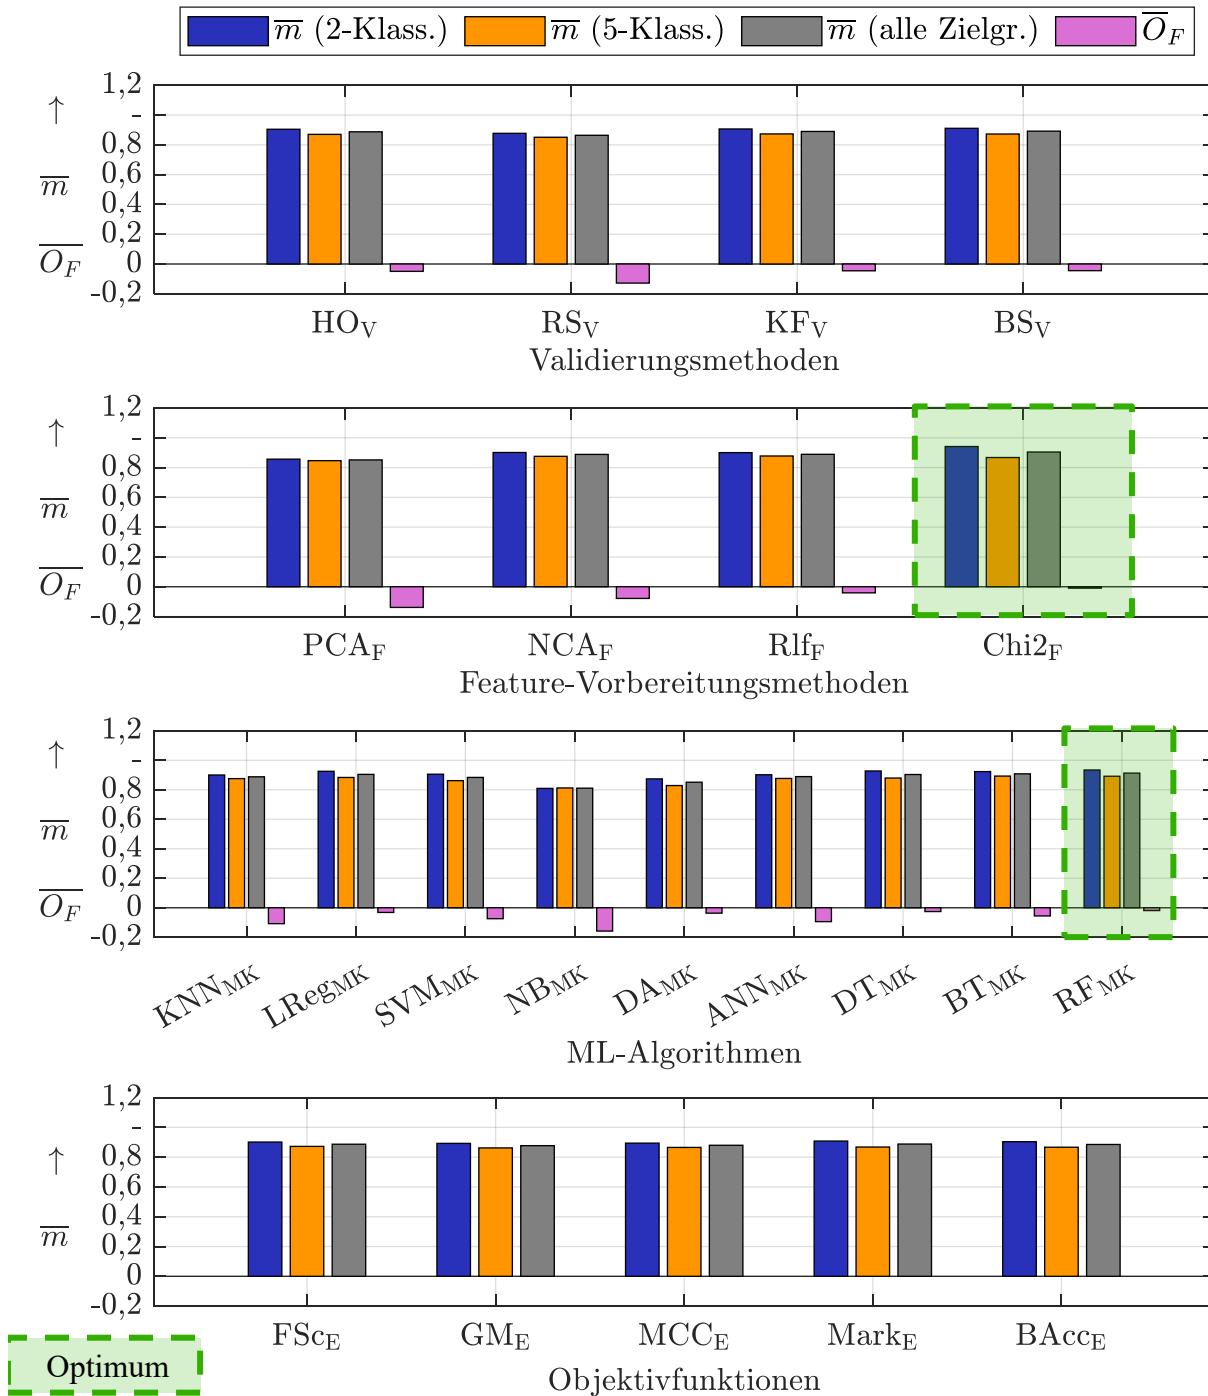


Abbildung 8.12: Anomaliedetektion: Analyse der Modellierungsstufen und der Überanpassung bei überwachter Klassifikation (\bar{m} = Durchschnitt der gewichteten Gesamtpunktwerte für die vorliegende Methode einer Modellierungsstufe über aller Modellierungs-Pipelines hinweg, \bar{O}_F = über alle Modellierungs-Pipelines der vorliegenden Modellierungsstufe gemittelter Bewertungsfaktor für die Überanpassung (siehe Abschnitt 6.3.1.3), Klass. = Klassifikation, Zielgr. = Zielgrößen; zur Symbol-Kennzeichnung der Zielgrößen, Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie der Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.1 und die Anhänge A.1.3 und A.10.1 verwiesen)

In der Abbildung 8.12 ist der Durchschnitt der Summe gewichteter Punktwerte \bar{m} für die vorliegende Methode einer Modellierungsstufe über alle Modellierungs-Pipelines hinweg für die 2-Klassen- und 5-Klassen-Klassifikation sowie für alle Modellierungen insgesamt

aufgetragen. Zusätzlich dazu sind die durchschnittlichen Faktoren der Überanpassung \bar{O}_F über alle Zielgrößen hinweg dargestellt. Zudem sind darin, falls möglich, die optimalen Methoden der Modellierungsstufen markiert. Ein Optimum wird als solches dann definiert, sobald eine gemittelte Summe der gewichteten Gesamt-Punktwerte \bar{m} den höchsten Wert aufweist und dieser um $\approx 0,01$ höher als der zweitgrößte Wert ist. Dieses Abstand ist bei den insgesamt nah beieinander liegenden Werten sowie dem engen Intervall von $[0; 1]$ für \bar{m} vertretbar.

Die dargestellten Werte lassen folgende Schlussfolgerungen zu:

- *Validierungs-Methoden:* Die einzelnen Methoden haben entgegen der Erwartung ähnliche Bewertungen \bar{m} , was den Einsatz der rechenärmeren Hold-Out Validierung HO_V bei der Hyperparameteroptimierung als vorteilhaft erscheinen lässt. Die Methode der Resubstitution RS_V weist die höchste Überanpassung auf, wie gemäß den theoretischen Grundlagen erwartet (siehe Abschnitt 2.3.2.3).
- *Feature-Vorbereitungsmethoden:* Auch wenn hier ebenfalls kein sehr großer Unterschied zwischen den einzelnen Methoden zu beobachten ist, kann das Chi-Quadrat-Ranking $Chi2_F$ als die vorteilhafteste Methode gemäß der Punktebewertung und der Überanpassung identifiziert werden.
- *ML-Algorithmen:* Der Random Forest Algorithmus RF_{MK} erfährt die beste mittlere Bewertung und die niedrigste Überanpassung, jedoch bei niedrigen Abständen zu weiteren Algorithmen. Die Diskriminanzanalyse DA_{MK} und der Naive Bayes NB_{MK} fallen in der Bewertung von den restlichen Algorithmen ab.
- *Objektivfunktionen:* Ein Einfluss der Objektivfunktionen auf die Ergebnisse der Hyperparameteroptimierung wird nicht registriert. Die Auswertung der Überanpassung ist bei der Betrachtung der Objektivfunktionen als Modellierungsstufe nicht praktikabel, da diese während der Hyperparameter-Optimierung die zu minimierende Größe ist und somit ein objektiver Vergleich dieser Größe als Evaluationskennzahl beim Validierungs- und Test-Set nicht gegeben ist.

Zusammenfassend lässt sich feststellen, dass die Variation der Modellierungsstufen Validierungsmethode und Objektivfunktion keinen Einfluss auf Modellierungsergebnisse hat. Innerhalb der Feature-Vorbereitungsmethoden ist ein leichter Einfluss der Methoden sichtbar (mit Chi-Quadrat-Ranking $Chi2_F$ als vorteilhafteste Methode). Etwas deutlicher ist der Einfluss der ML-Algorithmen identifizierbar (mit Random Forest RF_{MK} als vorteilhaftesten Algorithmus).

8.4 Einfluss der Datensatzgröße

In dieser Analyse gilt es, die wichtigsten Evaluationskennzahlen für die besten identifizierten Modelle (siehe das Ranking-Verfahren im Abschnitt 6.3.1.3), jeweils trainiert an dem realen und künstlich erweiterten Datensatz, für jede ML-Verfahrensgruppe zu vergleichen. Das Ergebnis dazu ist in der Tabelle A.33 im Anhang A.13.1 zu sehen. Die Dauer des Modelltrainings und der Vorhersage nehmen bei der Nutzung des künstlich vergrößerten Datensatzes zu. Je nach Verfahrensgruppe ist die Vorhersagegüte der am realen Datensatz trainierten Modelle schlechter oder besser. Dies lässt den Schluss zu, dass sich die vorgeschlagene künstliche Datensatzerweiterung nicht als Datenbasis zum Training präziserer ML-Modelle zur Anomaliedetektion eignet.

8.5 Zusammenfassung und Bewertung

In diesem Kapitel wird die Anomaliedetektion während des Bohrprozesses mit den ML-Verfahrensgruppen unüberwachtes Clustering, unüberwachte Ausreißeridentifikation und überwachte Klassifikation untersucht. Bei der ML-Verfahrensgruppe des unüberwachten Clusterings wird das 2- und 5-Klassen Clustering, für welches ungelabelte Daten verwendet werden, in 18 Modellierungs-Pipelines untersucht. Dabei wird eine fehlende Eignung des Clusterings zur Anomaliedetektion festgestellt, da die Anomaliezustände nicht in eigene separate Cluster eingeteilt werden.

Des Weiteren wird die unüberwachte Ausreißeridentifikation in Form der Novelty Detection anhand von 15 Modellierungs-Pipelines untersucht, wofür beim Modelltraining nur Sensordaten normaler Bohrungen benötigt werden. Das kennzahlenübergreifend am präzisesten arbeitende Modell erkennt knapp unter 2/3 der vorhandenen Bohrungsanomalien. Bei der speziellen Betrachtung der Modellierungs-Pipelines, während der nur die vollständige Erfassung jeglicher Anomalien von Interesse ist, ist mit einigen Modellen eine 98 %-ige Anomalieerkennung möglich. Diese Modelle stufen auch einen Großteil der normalen Bohrungen als Anomalien ein und sind damit unbrauchbar. Im Mittel zeigen die Feature-Vorbereitungsmethode Principal Component Analysis PCA_F und der ML-Algorithmus Local Outlier Factor LOF_{MA} die beste Performance.

Abschließend wird die Anomaliedetektion mittels überwachter Klassifikation unter Nutzung 720 verschiedener Modellierungs-Pipelines untersucht. Bei der dazugehörigen Feature-Vorbereitung wird eine Datenreduktion von mindestens 97,5 % erreicht. Die relevantesten Features besitzen folgende Eigenschaften: sie stammen aus den maschineninternen Sensordaten; die Datenrepräsentation entspricht den Rohdaten, gefilterten Daten oder der gefilterten oberen Einhüllenden der Zeitverläufe; die betrachtete Bohrphase ist der Bohrungsein- oder -austritt; die Domäne der Daten ist der Frequenz-, Spektral- oder Bildbereich. Die über alle Evaluationskennzahlen am besten arbeitenden Modellierungs-Pipelines erkennen bei dem stark unbalancierten Datensatz rund 70 % der Anomalien. Modelle, die eine Mehrheit der Anomalien erkennen (ein Spitzenwert von $\approx 92,5\%$ wird erreicht) stufen jedoch auch einen Großteil der normalen Bohrungen als Anomalie ein und sind damit unbrauchbar. Die Variation der Validierungsmethoden und der Objektivfunktionen während der Hyperparameteroptimierung hat keinen signifikanten Einfluss auf die generelle Modellperformance. Bei den Feature-Vorbereitungsmethoden erweist sich das Chi-Quadrat Ranking $Chi2_F$ als die vorteilhafteste Option, bei ML-Algorithmen zeigt der Random Forest RF_{MK} im Durchschnitt die akkuratesten Vorhersagen.

Mit der vorgeschlagenen Datensatzerweiterung mittels künstlicher Daten wird eine Verbesserung der Modellperformance nicht erreicht.

Zusammenfassend lässt sich sagen, dass bei den besten ausgeglichen überwachten Klassifizierern, d. h. bei Modellen ohne einer hohen Rate an Fehlalarmen (= falsch positiver Zuordnungen), die höchsten Anomalie-Erkennungsraten von $\approx 70\%$ erreicht werden. Bei einer hohen Quote falsch positiver Zuordnungen, d. h. wenn normale Bohrungen als Anomalien markiert werden, lassen sich mit der unüberwachten Ausreißeridentifikation Anomalie-Erkennungsquoten von max. $\approx 98\%$ erreichen. Jedoch kann davon ausgegangen werden, dass derartige Modellierungsgütern im Industrieinsatz aufgrund der zu niedrigen Anomalieerkennung- bzw. zu hohen Fehlalarmquote nicht den Anforderungen entsprechen.

9 Prozesszustand-Überwachung

In diesem Kapitel werden die Ergebnisse ML-basierter Prozesszustand-Überwachung vorgestellt und untereinander verglichen. Gemäß der im Abschnitt 6.3.2 vorgestellten Methodik erfolgt hierbei der Einsatz des unüberwachten Clusterings und der überwachten Klassifikation. Es werden dabei die diskreten Prozesszustände, die nach Definition in dieser Arbeit aus Prozessparametern und -bedingungen bestehen, überwacht. Diese sind *Werkstoff*, *Drehzahl*, *Vorschub pro Werkzeugumdrehung*, *Aufspannweite des Werkstücks*, *Kontaktzustand zwischen Maschine und Werkstück*, *Schmierungszustand* und *Peck-Feed-Amplitude*. Neben der Ergebnisvorstellung resultierend aus dem Modelltraining mit realen Trainings-Daten wird zudem der Einfluss einer Datensetzerweiterung durch künstliche Daten untersucht. Im Anschluss erfolgt eine Anwendungsempfehlung. In dieses Kapitel sind teilweise Erkenntnisse aus der vom Autor dieser Dissertation betreuten Masterarbeit von MOLKENTIN [Mol21], die zudem in [Hin+22] veröffentlicht sind, eingeflossen.

9.1 Unüberwachtes Clustering

In den folgenden Abschnitten werden die Ergebnisse der Prozesszustand-Überwachung durch unüberwachtes Clustering vorgestellt. Dabei wird auf die Feature-Vorbereitung sowie die Sensor-Signifikanzanalyse eingegangen. Zudem werden zielgrößenbezogene, jedoch auch zielgrößenübergreifende Ergebnisse diskutiert. Abschließend erfolgt die Vorstellung der Studie zu den 2 vorhandenen Modellierungsstufen (Feature-Vorbereitung und ML-Algorithmus).

9.1.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

Die Feature-Vorbereitung gleicht derjenigen aus der Clustering-basierten Anomaliedetektion im Abschnitt 8.1.1, da bei dieser ML-Verfahrensgruppe im Normalfall die Zielgrößen nicht vorhanden sind und daher nicht zielgrößenbezogene Feature-Vorbereitungsmethoden eingesetzt werden.

9.1.2 Ranking der finalen Modelle

Die finalen Modellierungs-Pipelines werden zuerst im Hinblick auf das Clustering der einzelnen Zielgrößen (= Prozesszustände) vorgestellt. Im Anschluss wird auf die Performance der Modellierungs-Pipelines über die Zielgrößen hinweg eingegangen.

9.1.2.1 Zielgrößenbezogene Auswertung

Im Folgenden wird die Auswertung jeder Modellierungspipeline je Zielgröße durchgeführt. Ausgehend davon wird auf die Modelle mit potentiell akzeptablen Clustering-Zuordnungen eingegangen. In der Abbildung 9.1 ist die Ergebnismenge aus allen Modellierungs-Pipelines bestehend aus Feature-Vorbereitung und ML-Algorithmus in einem Boxplot dargestellt. Die Clustering-Qualität wird anhand der Normalized Mutual Information NMI_E bewertet.




Abbildung 9.1: Prozesszustand: Clustering-Qualität anhand der Normalized Mutual Information NMI_E aller Modellierungs-Pipelines (rote Markierungen = Median; W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, A_{PF} = Peck-Feed-Amplitude, L = Schmierungszustand, d_c = Aufspannweite, c_{CC} = Kontaktzustand Maschine/Werkstück)

Bei einer Übereinstimmung zwischen der vorhergesagten und wahren Clustereinteilung wäre $NMI_E = 1$ und bei einer vollständig falschen Zuordnung wäre $NMI_E = 0$ [AJ03]. Bei einem Wert von $NMI_E = 0,5$ sind laut der Abschätzung in [KS20] ungefähr $\approx 88\%$ der Datenpunkte den Clustern richtig zugeordnet. Daher wird im weiteren Verlauf die Schwelle, ab der das Clustering-Ergebnis als potentiell hochwertig eingestuft wird, als $NMI_E \geq 0,5$ definiert. Die Ergebnisse für die Größen Werkstoff W , Drehzahl n , Vorschub pro Werkzeugumdrehung f sowie Peck-Feed-Amplitude A_{PF} weisen Modellierungs-Pipelines mit potentiell hochwertigen Ergebnissen auf. Damit wird auf das Clustering der restlichen Zielgrößen im Weiteren nicht eingegangen. Ersichtlich ist dabei, dass die Verteilung der Ergebnisse für NMI_E aufgrund der dezentralen Lage des Medians (in Abbildung 9.1 rot markiert) ungleich ist und damit ein signifikanter Anteil der Werte für NMI_E gegen 0 geht.

Im nächsten Schritt wird die Identifikation der Modellierungs-Pipelines mit potentiell hochwertigen Clusterergebnissen vorgenommen, siehe dazugehörige Heatmaps in der Abbildung 9.2. Die Auflistung und Beschreibung der besten Modelle sowie die Angabe derer exakten Evaluations-Kennzahlen ist in der Tabelle A.34 im Anhang A.13.2 zu finden. Es werden dabei nur Modelle für die Zielgrößen angegeben, die gemäß der Normalized Mutual Information NMI_E eine potentiell annehmbare Clustering-Güte haben.

Die Normalized Mutual Information soll trotz der teilweise erreichten Werte von $NMI_E \geq 0,5$ anhand der wahren Clusterzuordnungen kritisch betrachtet werden. Dazu werden in der Abbildung A.20 im Anhang A.13.2 die zugeordneten und wahren Cluster für die jeweils besten Modelle der Prozesszustand-Größen Werkstoff W , Drehzahl n , Vorschub pro Werkzeugumdrehung f und Peck-Feed-Amplitude A_{PF} aus der Abbildung 9.2 verglichen. Hierbei ist folgende manuelle Zuordnung notwendig, da beim unüberwachten Clustering die erstellten Cluster aufgrund fehlender Zielgrößen beim Modell-Training nicht zwangsläufig die wahren Cluster

repräsentieren: Es wird durch einen manuellen Mehrheitsabgleich zwischen den vorhergesagten und wahren Labels eine Zuordnung durchgeführt. Sind beispielsweise die meisten Bohrungen in Ti64 dem Cluster 1 zugeordnet, so wird dies als das Ti64-Cluster interpretiert. Zu beachten ist hierbei unabhängig von der Modellierungsgüte, dass eine Modellierungs-Pipeline nicht zwangsläufig gemäß jeder Evaluationskennzahl am vorteilhaftesten sein muss, um insgesamt die beste Bewertung gemäß dem gewichteten Gesamt-Punktwert m zu erlangen (siehe dazugehöriges kennzahlenübergreifendes Ranking-Verfahren im Abschnitt 6.3.1.1). Dies kann u. a. damit begründet werden, dass bestimmte Evaluationskennzahlen eine höhere Gewichtung erfahren (siehe Abschnitt 6.3). Zudem werden Ergebnisse in der Abbildung A.20 als „am besten / am schlechtesten“ farblich zusammenfassend zum Zwecke einer besseren Übersicht markiert, auch wenn sie untereinander geringfügige (vernachlässigbare) Unterschiede aufweisen.

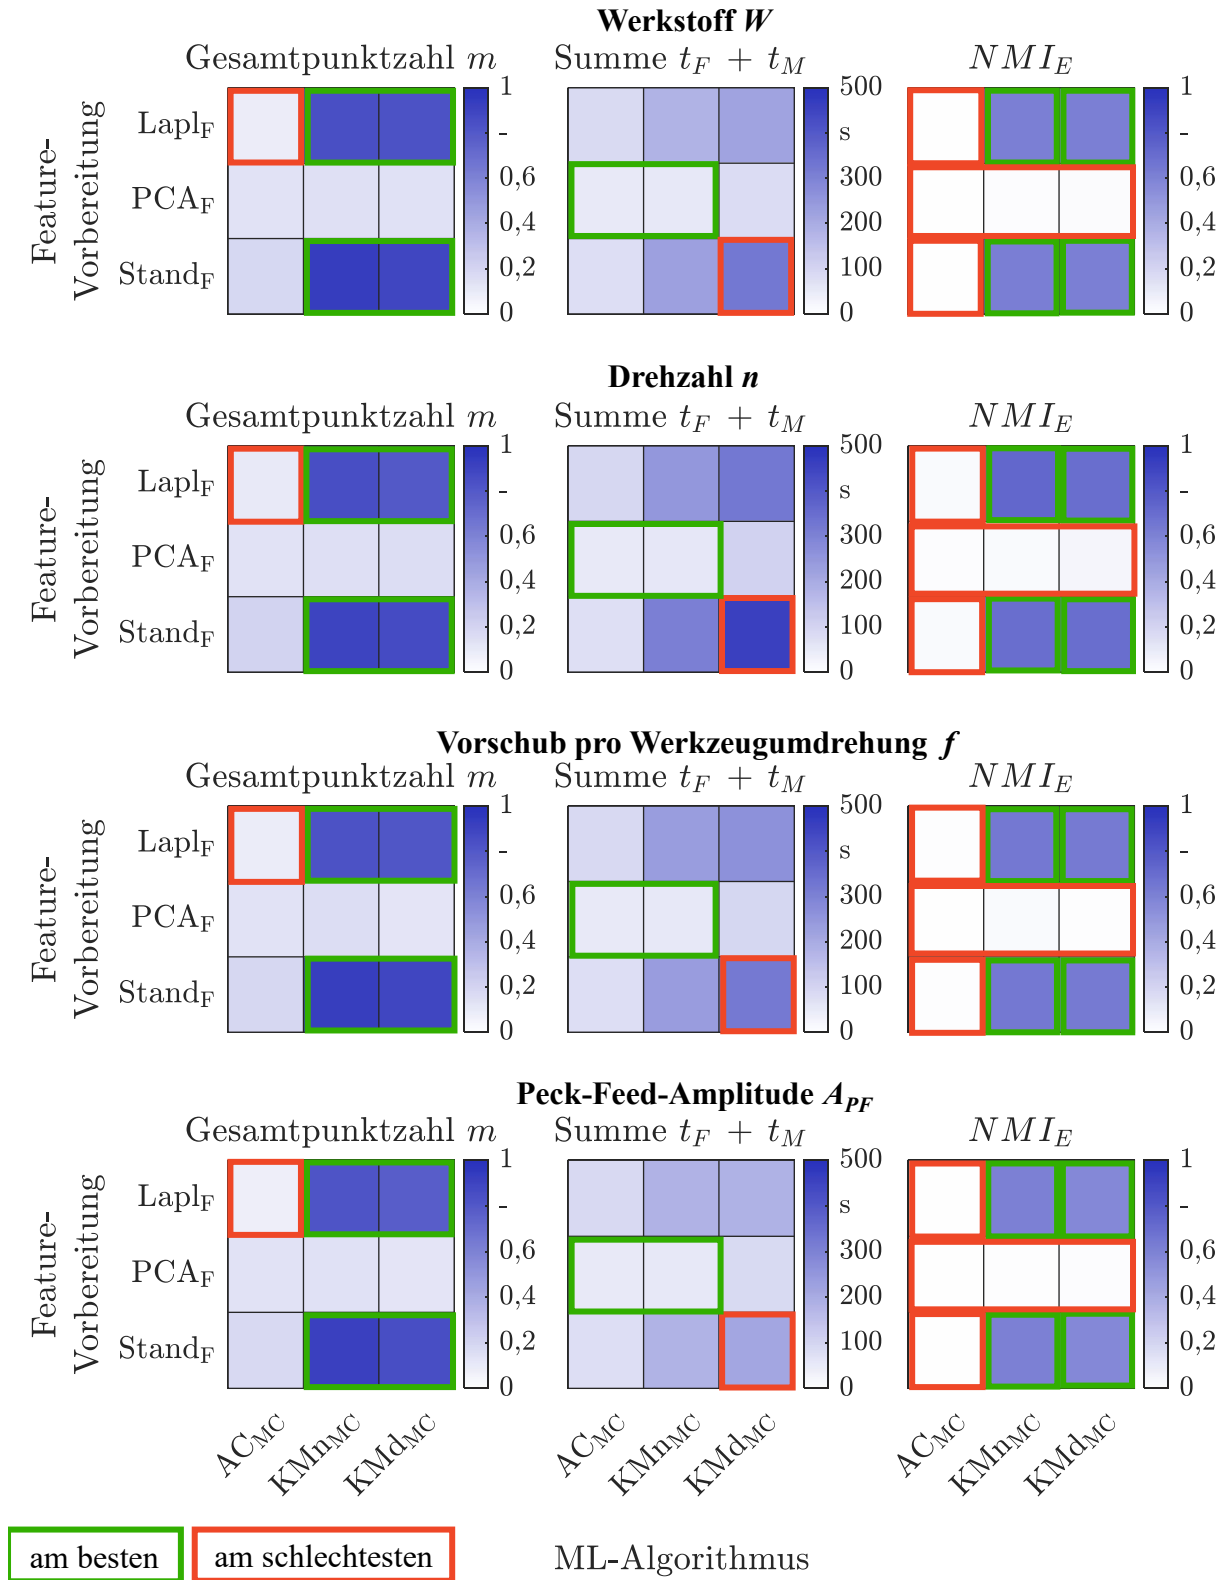


Abbildung 9.2: Prozesszustand: Clustering-Ergebnisse ($Lapl_F$ = Laplace-Punktwert, PCA_F = Principal Component Analysis, $Stand_F$ = Z-Standardisierung, KMn_{MC} = K-Means, KMd_{MC} = K-Medoids, AC_{MC} = Agglomerative Hierarchische Clusteranalyse, t_F / t_M = Dauer Feature-Vorbereitung / Modell-Training, NMI_E = Normalized Mutual Information)

Die Konfusionsmatrizen in der Abbildung A.20 im Anhang A.13.2 weisen eine Zuordnungsgenauigkeit von etwa 70 % auf, was nicht auf eine hohe Clustering-Güte hindeutet und von den

Aussagen zum Zusammenhang zwischen dem Wert für die Normalized Mutual Information NMI_E und dem Anteil richtig zugeordneter Datenpunkte in [AJ03] abweicht. Auffällig ist zudem die Häufung falsch eingeordneter Datenpunkte, wodurch ein eigenes Cluster gebildet wird. Dies lässt den Schluss zu, dass bei geringfügig abweichenden Prozessdaten (z. B. $f = [0,03; 0,05]$) die Daten für eine Unterscheidung zu ähnlich sind. Mit dem vorliegenden Grunddatensatz lässt sich der Schluss ziehen, dass das ML-basierte unüberwachte Clustering sich nicht zur präzisen Prozesszustand-Überwachung beim semi-automatischen Bohren eignet.

9.1.2.2 Zielgrößenübergreifende Auswertung

Sollte die Anwendung einer Modellierungs-Pipeline über die Zielgrößen hinweg von Interesse sein, ist deren durchschnittliche Performance bedeutend. Zur Bestimmung der am universellsten einsetzbaren Kombinationen aus Feature-Vorbereitung und ML-Clustering-Algorithmus wird deren Performance über die Zielgrößen hinweg gemittelt. Das dazugehörige Ergebnis ist in der Abbildung 9.3 zu sehen. Dabei wird deutlich, dass die Kombinationen aus der Standardisierung und dem Laplace-Punktwert als Feature-Vorbereitung und den K-Means- und K-Medoids-Clusteringalgorithmen insgesamt am besten gemäß dem in Abschnitt 6.3.2.1 definierten Ranking die vorliegenden Prozesszustände clustern. Zu beachten ist hierbei, dass eine Modellierungs-Pipeline nicht zwangsläufig gemäß jeder Evaluationskennzahl am vorteilhaftesten sein muss, um insgesamt die beste Bewertung gemäß der Punktezahl m zu erlangen. Dies kann u. a. damit begründet werden, dass bestimmte Evaluationskennzahlen eine höhere Gewichtung erfahren (siehe Abschnitt 6.3). Zudem werden Ergebnisse in der Abbildung 9.3 als „am besten / am schlechtesten“ farblich zusammenfassend zum Zwecke einer besseren Übersicht markiert, auch wenn sie untereinander geringfügige (vernachlässigbare) Unterschiede aufweisen.

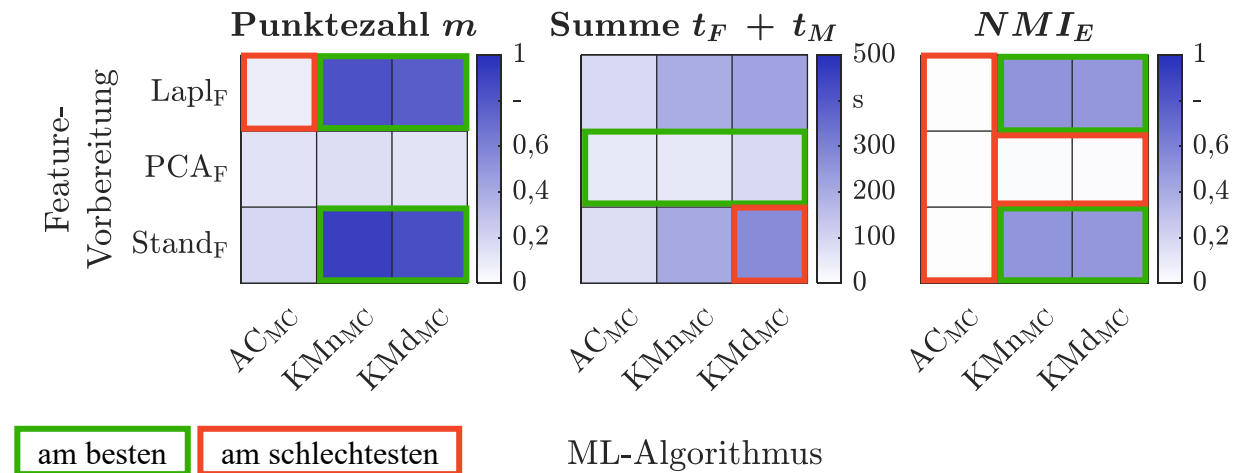


Abbildung 9.3: Prozesszustand: zielgrößenübergreifendes Clustering ($Lapl_F$ = Laplace-Punktwert, PCA_F = Principal Component Analysis, $Stand_F$ = Z-Standardisierung, KMn_{MC} = K-Means, KMd_{MC} = K-Medoids, AC_{MC} = Agglomerative Hierarchische Clusteranalyse, t_F / t_M = Dauer Feature-Vorbereitung / Modell-Training, NMI_E = Normalized Mutual Information)

9.1.3 Analyse der Modellierungsstufen

In der Abbildung 9.4 sind die durchschnittlichen gewichteten Gesamt-Punktwerte \bar{m} der Methoden einzelner Modellierungsstufen visualisiert. Dabei sind die gewichteten Gesamt-Punktwerte m für jede Methode über deren Ergebnisse bei den einzelnen Zielgrößen gemittelt. Als Ergebnis steht fest, dass die Z-Standardisierung Stand_F als Feature-Vorbereitungsmethode und der K-Means-Algorithmus KMn_{MC} als Clustering-Verfahren durchschnittlich am besten zum Sortieren von Bohrungsdaten nach den Prozesszuständen einsetzbar sind.




Abbildung 9.4: Prozesszustand: Modellierungsstufen-Bewertung beim unüberwachte Clustering (Lapl_F = Laplace-Punktwert, PCA_F = Principal Component Analysis, Stand_F = Z-Standardisierung; ML-Algorithmen: KMn_{MC} = K-Means, KMd_{MC} = K-Medoids, AC_{MC} = Agglomerative Hierarchische Clusteranalyse, \bar{m} = durchschnittlicher gewichteter Gesamt-Punktwert)

9.2 Überwachte Klassifikation

In diesem Abschnitt werden die Ergebnisse der überwachten Klassifikation beim Prozesszustand-Monitoring analysiert. Der Zusatz „überwacht“ wird durchgängig beibehalten, um die ML-Verfahrensgruppe fortlaufend zu verdeutlichen. Anfangs erfolgt die Vorstellung der Feature-Vorbereitung inklusive der Sensorrelevanz-Analyse. Daraufhin wird das Ranking der Modellierungs-Pipelines im Hinblick auf einzelne Zielgrößen als auch über Zielgrößen hinweg präsentiert. Abschließend erfolgt die Analyse der einzelnen Methoden innerhalb jeder Modellierungsstufe (Validierungsmethode, Feature-Vorbereitung, ML-Algorithmus und Objektivfunktion) sowie die Bewertung der Modell-Überanpassung.

9.2.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

Die Abbildung 9.5 stellt die Ergebnisse der Feature-Anzahl nach der Anwendung der Feature-Vorbereitungsmethoden zusammenfassend dar. Dabei repräsentieren die Balken den Mittelwert der Feature-Anzahl über die 4 permutierten Datensätze des verbundenen Trainings- und Validierungs-Sets. Die höchste Kompression wird durchschnittlich bei der Neighbourhood Component Analysis NCA_F erreicht. Das Chi-Quadrat-Ranking Chi2_F eignet sich nicht bei allen Zielgrößen zur Feature-Selektion. Bei einigen Zielgrößen (Drehzahl n , Vorschub pro Werkzeugumdrehung f und Peck-Feed-Amplitude A_{PF}) ruft der Einsatz der in MATLAB

genutzten Bibliothek *relieff* trotz befolgter empfohlener Standard-Einstellungen einen Laufzeit-Fehler hervor [Mat24a]. Hypothetisch ist es möglich, dass die Features für den Relieff-Algorithmus zu ähnlich bzw. zu variabel in Bezug auf bestimmte Zielgrößen sind. Eine tiefer gehende Untersuchung würde jedoch den Rahmen dieser Arbeit sprengen. Die Datenreduktion bei der Principal Component Analysis PCA_F befindet sich in einem ähnlichen Bereich wie bei dem Relief-Algorithmus Rlf_F . Zusammenfassend lässt sich sagen, dass auch bei der Prozesszustand-Überwachung eine sehr hohe Datenreduktion-Rate zwischen mindestens 90,3 % (Chi-Quadrat-Ranking bei der Zielgröße Werkstoff W) und 99,92 % (Chi-Quadrat-Ranking bei der Zielgröße Schmierungsstatus L) erreicht wird. Die bedeutet beim letzteren, dass etwa 20 relevante Features (aus den 23560 ursprünglich extrahierten) identifiziert werden. Die für alle Zielgrößen einsetzbare Neighbourhood Component Analysis reduziert die Feature-Anzahl für jede Zielgröße um mindestens 99,58 %, womit maximal 100 Features (von 23560) als relevant eingestuft werden.




Abbildung 9.5: Prozesszustand: Feature-Vorbereitung bei überwachter Klassifikation (Die Balken stellen den Mittelwert der Feature-Anzahl über die 4 permutierten Datensätze dar; W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontaktzustand Bohrmaschine/Werkstück, L = Schmierung, A_{PF} = Peck-Feed-Amplitude, $Chi2_F$ = Chi-Quadrat-Ranking, NCA_F = Neighbourhood Component Analysis, PCA_F = Principal Component Analysis, Rlf_F = Relief-Algorithmus)

In der Abbildung 9.6 wird die Wichtigkeit der einzelnen Ausprägungen der Feature-Extraktionspfade abgebildet. Aus Gründen der Lesbarkeit werden die Einträge der normierten und gewichteten Signifikanzwerte $\Sigma_{PF,wn,ij}$ als Datenpunkte mit farbigen Verbindungslinien dargestellt. Die Werte für $\Sigma_{PF,wn,ij}$ sind nicht zwischen den einzelnen Diagrammen vergleichbar, da die Bewertung relativ innerhalb der einzelnen Extraktionspfade erfolgt. In der folgenden Auflistung finden sich die Quintessenzen zu den relevantesten Feature-Quellen:

- *Sensorgroße*: Es kann grundsätzlich eine variierende Signifikanz in Abhängigkeit der Zielgröße festgestellt werden. Bei den internen SmartADU-Sensorgroßen wird der Spindelmotorstrom I_{SM} vor allem für die Zielgrößen Werkstoff W , Drehzahl n und Peck-Feed-Amplitude A_{PF} als am relevantesten eingestuft. Mit der in [HMR19] nachgewiesenen Korrelation zwischen dem Schnittmoment M_c und dem Spindelmotorstrom I_{SM} bei der SmartADU folgt daraus die Ableitung des Zusammenhangs von W , n und A_{PF} mit dem Schnittmoment M_c . Der Zusammenhang des Schnittmoments M_c mit dem vorliegenden Werkstoff W und der Peck-Feed-Amplitude A_{PF} kann aus der Zerspanpraxis bestätigt werden.

Der Verspannungszustand c_{CC} wird insbesondere durch den Schalldruck beschrieben.

Dies deckt sich mit der Erfahrung, dass unterschiedliche Verspannungszustände des Werkstücks die Geräuschkulisse beim Bohren beeinflussen.

Die externen Beschleunigungssensoren weisen eine hohe Wichtigkeit bei dem Monitoring der Aufspannweite d_C und des Schmierungs Zustands L auf, was auf den Einfluss dieser Zielgrößen auf hochfrequente Schwingungsanteile hindeutet, da die externen Sensoren eine etwa 50 -fache Abtastrate im Vergleich zu den SmartADU-internen Sensoren aufweisen.

Abweichend von der Erwartung stellt sich kein Zusammenhang zwischen der Peck-Feed-Amplitude A_{PF} und den externen Beschleunigungssensoren ein.

Insgesamt lässt sich jedoch ableiten, dass jeder der eingesetzten Sensoren für die Prozesszustand-Überwachung von Bedeutung ist.

- *Datenrepräsentation*: Die Rohdaten sind für alle Zielgrößen relevant. Die Daten der unteren Einhüllenden können dagegen für keine Zielgröße als signifikant eingestuft werden. Der Maschine/Werkstück-Kontakt c_{CC} wird vorwiegend durch die Features, die aus den gefilterten Verläufen stammen, erklärt.
- *Bohrphase*: Zwischen den Bohrphasen sind keine signifikanten Unterschiede erkennbar. Dies kann damit begründet werden, dass im Bohrungseintritt, -vollschnitt und -austritt relevante Information enthalten ist, die folglich auch in den Sensordaten-Zeitverläufen der Phasen Gesamtbohrung Ph_g und Gesamtmessung Ph_M zu finden ist.
- *Domäne*: Die abstrakten Spektral- und Bild-Domänen bergen die wichtigste Information.

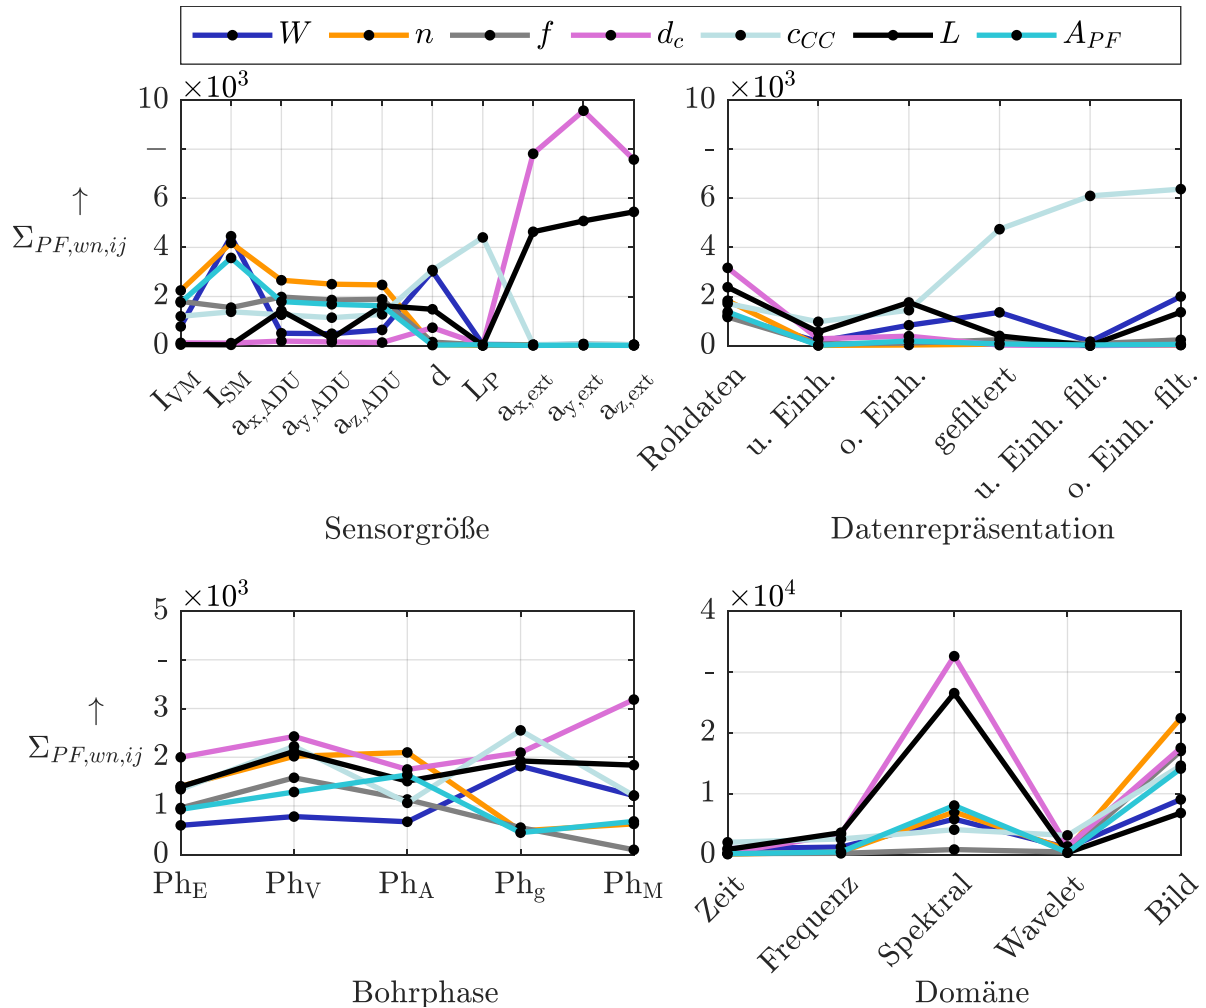


Abbildung 9.6: Prozesszustand: Feature-Signifikanz bei überwachter Klassifikation (W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, $\Sigma_{PF,wn,ij}$ = gewichtete Summe der normierten Feature-Signifikanzwerte (nur innerhalb jedes einzelnen Diagramms vergleichbar), I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, d = Distanz Werkstück, L_P = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, u./o. Einh. = untere/obere Einhüllende, u./o. Einh. filt. = untere/obere Einhüllende gefiltert, Ph_E = Eintritt, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

9.2.2 Ranking der finalen Modelle

Im Folgenden werden die Ergebnisse der Modellierungs-Pipelines separat für jede Zielgröße sowie über die Zielgrößen hinweg vorgestellt und bewertet.

9.2.2.1 Zielgrößenbezogene Auswertung

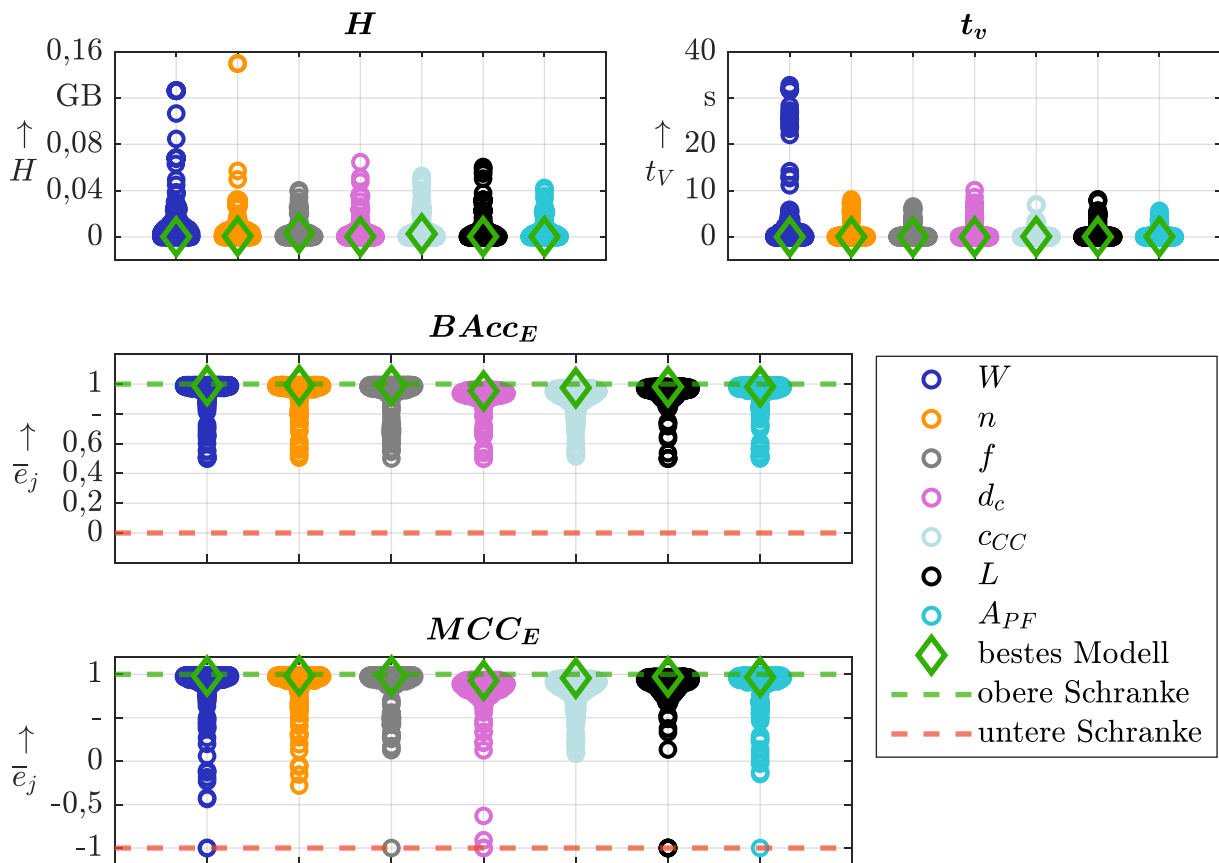
In der Abbildung 9.7 sind die Kernergebnisse der zielgrößenbezogenen Auswertung zur Prozesszustand-Überwachung zu sehen. Die Evaluation umfasst für jede Zielgröße den Vergleich von maximal 720 Modellierungs-Pipelines. Lediglich für die Zielgrößen Werkstoff W , Drehzahl n und Peck-Feed-Amplitude A_{PF} kann die Feature-Vorbereitungsmethode Chi2_F nicht umgesetzt werden (siehe dazugehörige Erklärung im Abschnitt 9.2.1), weswegen hierbei nur 540 Modellierungs-Pipelines gebildet werden. Die Ergebnispräsentation in Abbildung 9.7 erfolgt, wie bereits bei der Anomaliedetektion im Abschnitt 8.3.2.1 geschehen, durch eine Darstellung der jeweiligen Evaluationskennzahl kombiniert mit einer Häufigkeitsverteilung basierend auf einem Kerndichteschätzer. Dies bedeutet, dass bei einer hohen Anzahl von Modellierungs-Pipelines mit gleichem numerischen Wert einer Evaluationskennzahl die Darstellung horizontal gestreckt wird. Die Modelle zeichnen sich durch niedrige Speichergrößen H (oftmals nur wenige Megabyte) aus. Die Dauer der Vorhersage t_V liegt meist unter 10 s.

Die Mehrheit der Bewertungen bewegt sich nah der oberen Schranke von $\bar{e} \approx 1$ für alle Zielgrößen. Dies ist ein klarer Hinweis für eine hohe Vorhersagegüte (siehe Abschnitt 2.3.4.2). Lediglich bei der Aufspannweite d_c lässt sich eine verminderte Vorhersagegüte der besten Modelle erkennen. Diese Aussagen werden in den Tabellen A.35 und A.36 im Anhang A.13.2 mit exemplarischen exakten Evaluationsparametern des allgemein besten Modells für jede Zielgröße bestätigt. Darin sind ebenfalls die Modell-Hyperparameter der allgemein besten Modelle je Zielgröße angegeben. Auffällig ist zudem, dass die meisten Modellierungs-Pipelines ähnliches Verhalten im Bereich hoher Vorhersagegüten aufweisen.

Die Abbildungen 9.8 und 9.9 stellen die Konfusionsmatrizen für die am besten bewerteten Modelle jeder Zielgröße dar (die Hyperparameter und exemplarische Evaluations-Kennzahlen sind in den Tabellen A.35 und A.36 im Anhang A.13.2 angegeben). Das dazugehörige kennzahlenübergreifende Ranking-Verfahren ist im Abschnitt 6.3.2.2 referenziert. Dabei werden die wahren und vorhergesagten Werte der 4 durch Permutation hergestellten Test-Datensätze verglichen. In den Darstellungen werden die festgestellten hohen Vorhersagegüten mit zum Teil fehlerfreier Einordnung einzelner Klassen bestätigt. Eine weitere wichtige Erkenntnis ist, dass die als „n. d.“ gekennzeichneten Bohrungsanomalien während der Vorschub-Überwachung genauso gut erkannt werden, wie bei der reinen überwachten Klassifikation der Anomalien (siehe Abschnitt 8.3.2.1). Diese Aussage gilt für die reine Anomalieerkennung, d. h. hierbei erfolgt keine Bestimmung der Anomalieart. Dies hat zur Folge, dass die Anomalieerkennung in der Prozesszustand-Überwachung integriert werden kann, falls anomaliehaltige gelabelte Trainings-Daten bei der Vorschub-Überwachung zur Verfügung stehen.

9.2.2.2 Zielgrößenübergreifende Auswertung

Anhand der Abbildung 9.7 ist sichtbar, dass eine Mehrzahl der Modellierungs-Pipelines eine ähnliche Modellperformance besitzt. Diese Beobachtung wird in der Abbildung 9.10 bestätigt, worin sich etwa 500 lt. der Gesamtbewertungs-Kennzahl Durchschnitt der Summe gewichteter Punktwerte \bar{m} besten Modellierungs-Pipelines nicht signifikant unterscheiden. Nach einer



(Die x-Achse stellt bei jedem Graph die diskrete Repräsentation der Zielgrößen dar)

Abbildung 9.7: Prozesszustand: Modell-Performance bei überwachter Klassifikation (Mengendarstellung der wichtigsten exemplarischen Evaluations-Kennzahlen jeder Modellierungs-Pipeline, die an 4 Test-Sets ausgewertet ist; W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontakt Maschine/Werkstoff; L = Schmierung, A_{PF} = Peck-Feed-Amplitude, H = Modell-SpeichergroÙe, t_v = Dauer der Vorhersage, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Datensätze, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

kleinen Übergangsmenge bildet sich eine Restgruppe von etwa 200 Modellierungs-Pipelines, die eine deutlich schlechtere Gesamtbewertung erhält. Es setzt sich keine Modellierungs-Pipeline über die Zielgrößen hinweg deutlich von den anderen ab. Somit kann gesagt werden, dass sich eine Vielzahl an Modellierungs-Pipelines zum Monitoring der vorgestellten Prozesszustand-Zielgrößen mit einer hohen Vorhersagegüte eignet.

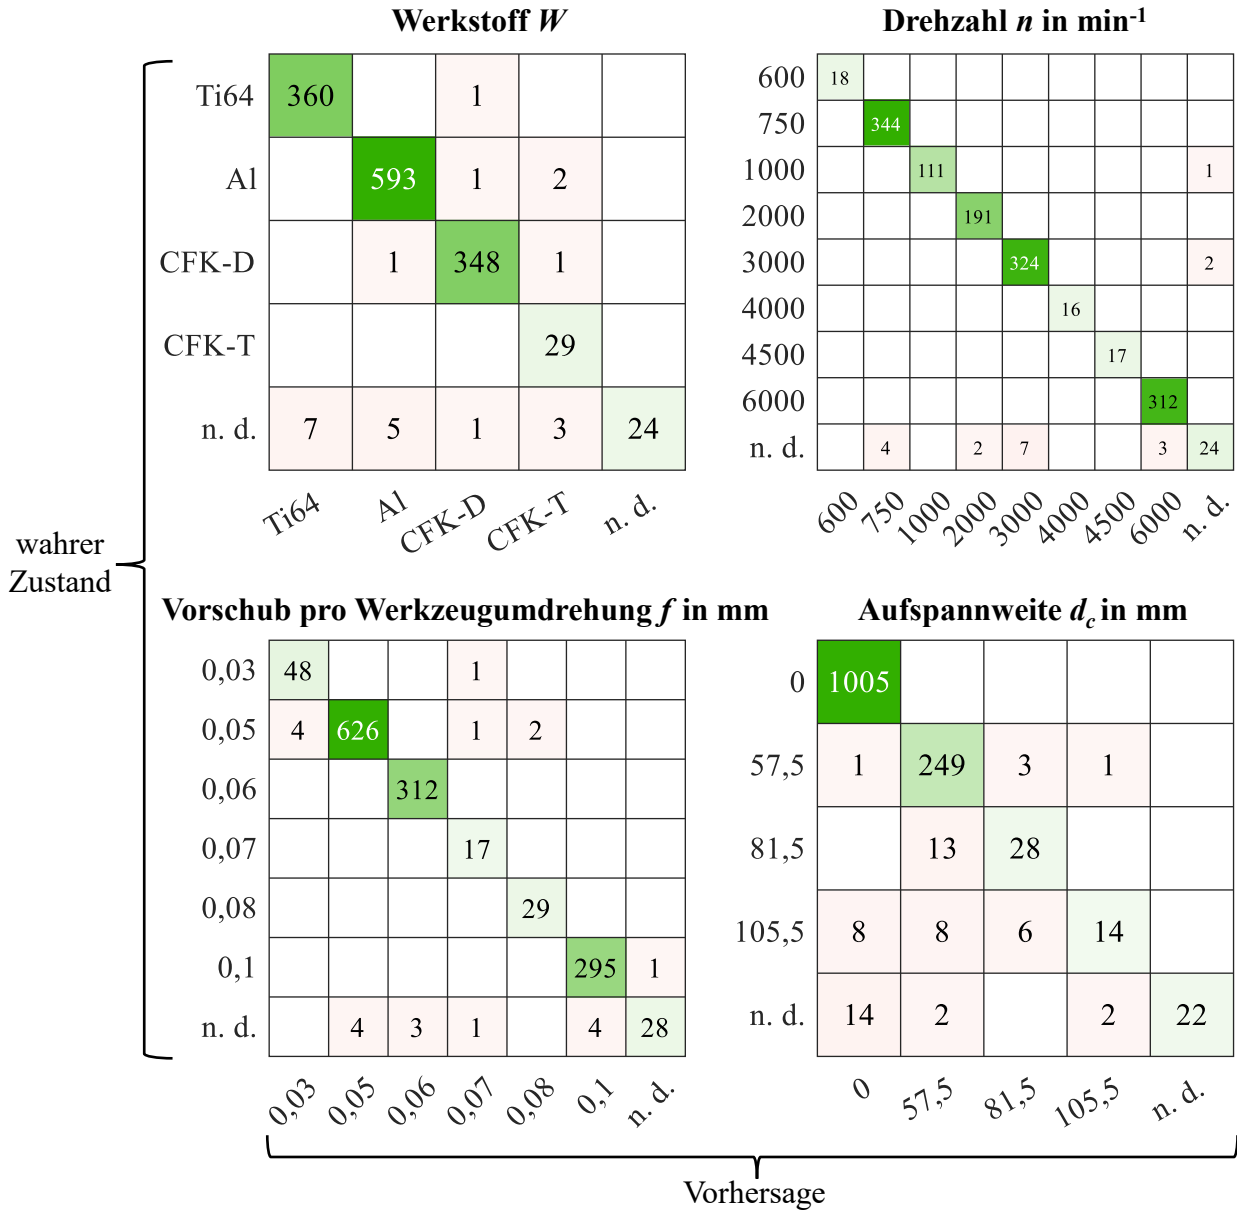


Abbildung 9.8: Prozesszustand: beste Modelle der überwachten Klassifikation mit ihren Konfusionsmatrizen, die alle Daten der 4 vorhandenen Test-Sets umfassen, Teil 1 (die Hyperparameter und exemplarische Evaluations-Kennzahlen der jeweiligen besten und damit hier dargestellten Modellierungs-Pipelines für jede Zielgröße sind in der Tabelle A.35 im Anhang A.13.2 verzeichnet; n. d. = nicht definiert, was einer Prozessanomalie gleichgesetzt wird; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 9.9: Prozesszustand: beste Modelle der überwachten Klassifikation mit ihren Konfusionsmatrizen, die alle Daten der 4 vorhandenen Test-Sets umfassen, Teil 2 (die Hyperparameter und exemplarische Evaluations-Kennzahlen der jeweiligen besten und damit hier dargestellten Modellierungs-Pipelines für jede Zielgröße sind in der Tabelle A.36 im Anhang A.13.2 verzeichnet; n. d. = nicht definiert, was einer Prozessanomalie gleichgesetzt wird; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 9.10: Prozesszustand: zielgrößenübergreifende Auswertung der überwachten Klassifikation (\bar{m} = Durchschnitt der Summe gewichteter Punktwerte)

9.2.3 Analyse der Modellierungsstufen und der Überanpassung

Die Analyse der Methoden jeder Modellierungsstufe erfolgt in gleicher Weise wie bei der Anomaliedetektion mittels Überwachter Klassifikation (siehe Abschnitt 8.3). Die Ergebnisse sind in der Abbildung 9.11 zu sehen. Darin ist der Durchschnitt der Summe gewichteter Punktwerte \bar{m} jeder Methode über alle Modellierungs-Pipelines hinweg sowohl für jede Zielgröße als auch zielgrößenübergreifend dargestellt. Der absolute Werteunterschied ist darin zwar gering, dieser wurde jedoch in Voruntersuchungen ab einer Differenz von $\approx 0,01$ empirisch als signifikant festgestellt. Zusätzlich ist in der Abbildung 9.11 der gemittelte Bewertungsfaktor der Überanpassung \bar{O}_F eingetragen. Die technischen Grundlagen zur Überanpassung sind im Abschnitt 2.3.2.2 und die dazugehörige umgesetzte Vorgehensweise zu deren Analyse im Abschnitt 6.3.1.3 erklärt.

Für jede Modellierungsstufe der Modellierungs-Pipelines ergeben sich im Hinblick auf die Hyperparameteroptimierung und die Vorhersagegüte folgende Resultate, die durch die Kenntnis der numerischen Werte aus der Abbildung 9.11 gestützt werden:

- *Validierungs-Methoden:* Die Resubstitution RS_V eignet sich weniger zur Hyperparameteroptimierung als die anderen Methoden. Die restlichen Verfahren zeigen keine signifikanten Unterschiede auf. Daher wird die gemäß Abschnitt 2.3.2.3 weniger rechenaufwendige Hold-Out-Validierung HO_V zur Hyperparameteroptimierung als am besten geeignet angesehen.
- *Feature-Vorbereitungsmethoden:* Die Neighbourhood Component Analysis NCA_F erweist sich als überlegen gegenüber den anderen Methoden. Demgegenüber ist das Chi-Quadrat-Ranking $Chi2_F$ für die Prozesszustand-Überwachung nicht zu empfehlen, da diese Methode nicht bei jeder Zielgröße die Features in ihrer Signifikanz unterscheiden kann und damit bei diesem Verfahren nicht durchgängig eine Feature-Selektion möglich ist.
- *ML-Algorithmen:* Hierbei erweisen sich die auf Entscheidungsbäumen basierten Ensemble Learner (Boosted Tree BT_{MK} und Random Forest RF_{MK}) als überlegen. Der Naive-Bayes Klassifikationsalgorithmus NB_{MK} fällt von den restlichen Methoden deutlich ab.
- *Objektivfunktionen:* Die Auswahl der Objektivfunktion beeinflusst nicht das Ergebnis der Hyperparameteroptimierung.

Zusammenfassend lässt sich sagen, dass bei den Validierungsmethoden und den Objektivfunktionen im Hinblick auf die Hyperparameter-Optimierung ein Großteil der Methoden geeignet ist. Demgegenüber können einzelne optimale Feature-Vorbereitungsmethoden und ML-Algorithmen für die Hyperparameter-Optimierung und das Modell-Training identifiziert werden.

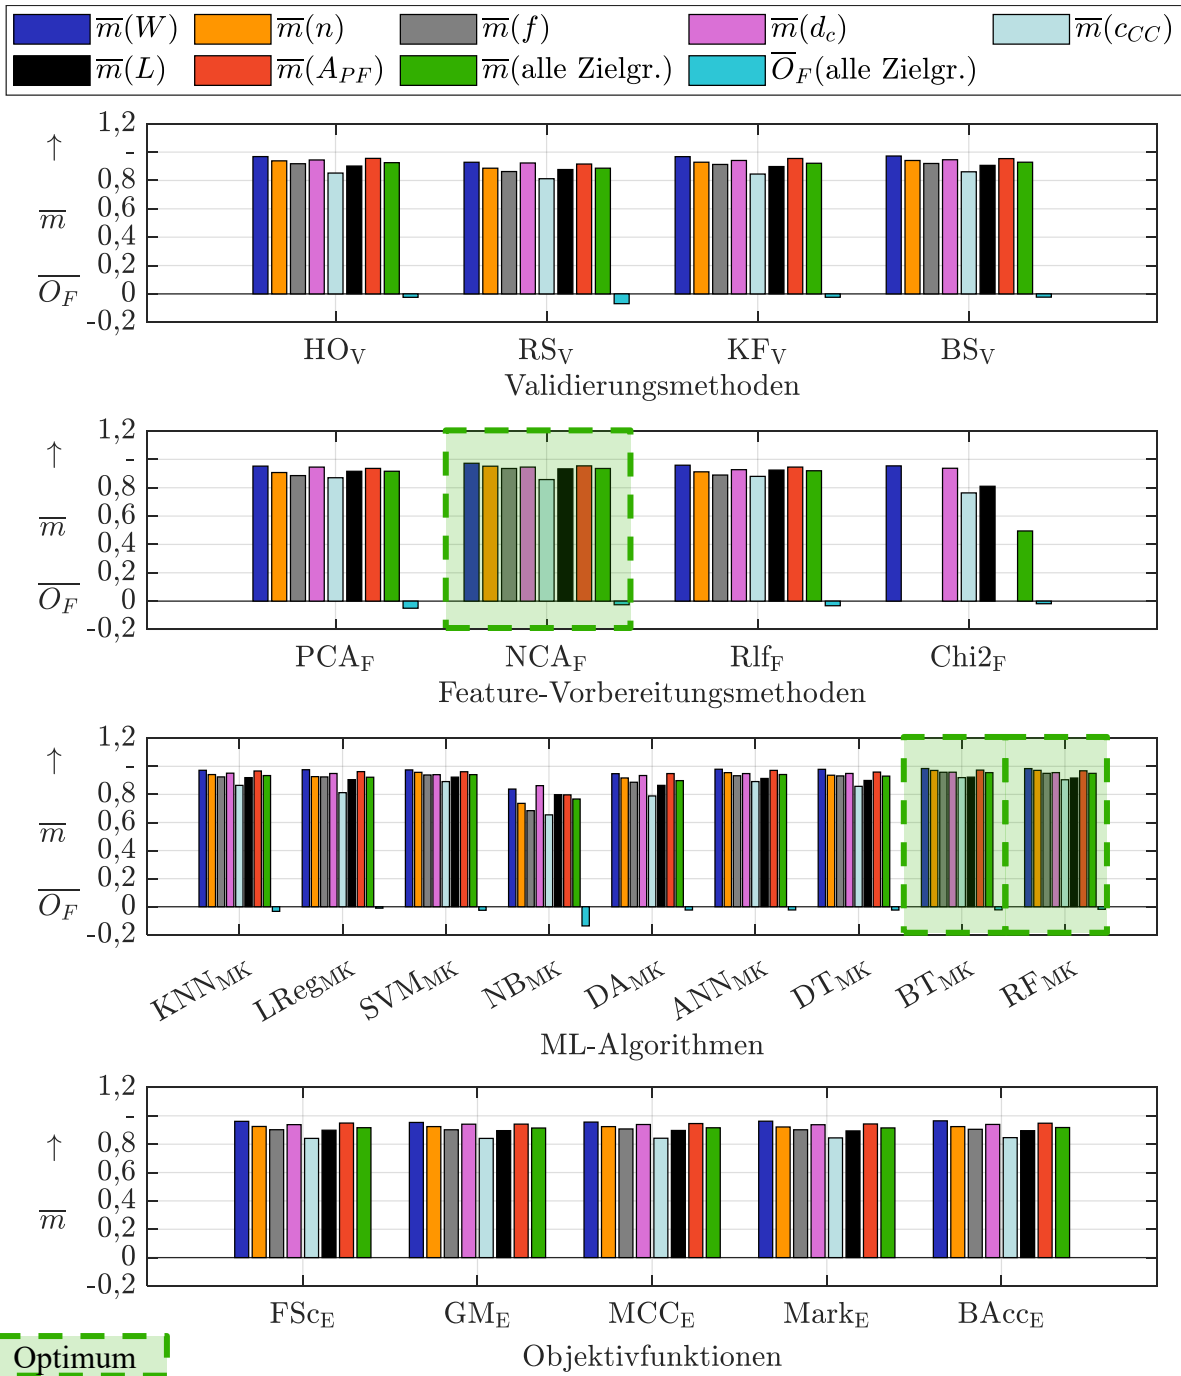


Abbildung 9.11: Prozesszustand: Modellierungsstufen und Überanpassung bei überwachter Klassifikation; Die Markierung des Optimums jeder Modellierungsstufe erfolgt, falls die beste(n) Option(en) ein um $\approx 0,01$ höheres \bar{m} als die zweitbeste vorweist (\bar{m} = Durchschnitt der Summe gewichteter Punktwerte für die vorliegende Methode einer Modellierungsstufe über aller Modellierungs-Pipelines hinweg, \bar{O}_F = über alle Modellierungs-Pipelines einer Modellierungsstufe gemittelter Bewertungsfaktor für die Überanpassung (siehe Abschnitt 6.3.1.3), Klass. = Klassifikation, Zielgr. = Zielgrößen; zur Symbol-Kennzeichnung der Zielgrößen, Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie der Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.2 und die Anhänge A.1.3 und A.10.1 verwiesen)

9.3 Einfluss der Datensatzgröße

Um den Einfluss des künstlichen Datensatzes auf die Vorhersagegüte zu untersuchen, wird die Performance der besten Modellierungs-Pipelines (ermittelt an den realen Daten, siehe Tabellen A.35 und A.36 im Anhang A.13.2; das dazugehörige Ranking-Verfahren ist im Abschnitt 6.3.2.2 referenziert) anhand des Trainings mit dem realen und künstlich erweiterten Datenset verglichen. Es sei hierbei angemerkt, dass die Untersuchungen der Validierungsmethoden sowie der Objektivfunktionen nicht mehr von Bedeutung sind, da die zuvor ermittelten Hyperparameter übernommen werden und deren Optimierung nicht stattfindet. Für den reinen Aufbau eines Vorhersagemodells sind ausschließlich die Schritte der Datenvorverarbeitung und des Modelltrainings mit vorgegebenen Hyperparametern durchzuführen (siehe dazu die entwickelte Methodik im Abschnitt 6.4)

Die Trainings- und Vorhersagedauern sowie die Vorhersagegüte für das Clustering ändern sich bei dem künstlich erweiterten Datenset nicht. Ein mögliche Erklärung hierzu wäre, dass die vorliegende Steigerung der Datenmenge für die Clustering-Algorithmen nicht signifikant ist, da bei den gewählten Verfahren keine rechenaufwendigen Minimierungsaufgaben, im Gegensatz zu den überwachten Klassifikations- und Regressionsmethoden, ausgeführt werden. Dabei werden nur die Zielgrößen Werkstoff W , Drehzahl n , Vorschub pro Werkzeugumdrehung f sowie Peck-Feed-Amplitude A_{PF} untersucht, da für die anderen Zielgrößen gemäß den Ausführungen im Abschnitt 9.1.2 keine verwertbaren Ergebnisse entstehen.

Für die überwachte Klassifikation werden folgende Resultate ermittelt. Die Modellierungs- und Vorhersagedauern nehmen bei dem künstlichen Datenset zu. Dabei steigert sich die Modellierungsdauer t_M um das 2- bis 30-fache je nach Zielgröße und beträgt maximal $t_M \approx 14\text{ s}$ bei der Peck-Feed-Amplitude A_{PF} . Die Vorhersagedauer t_V steigert sich um das 7- und 50-fache je nach Zielgröße und beträgt maximal $t_V = 0,68\text{ s}$ bei dem Maschine/Werkstück-Kontakt c_{CC} . Dies lässt sich auch intuitiv durch die größere Datenmenge begründen, liegt jedoch immer noch in einem Rahmen der Anwendbarkeit innerhalb vieler Fertigungs-Taktfolgen. Obwohl die Vorhersagegüte bei den Modellen, die auf dem realen und damit kleineren Datensatz trainiert sind, ohnehin sehr hoch ist, kann diese durch das Modelltraining an dem künstlich erweiterten Datensatz bei allen Zielgrößen gesteigert werden. Trotz des hohen Ausgangsniveaus ist ein weiterer Anstieg bei jeder Zielgröße für die Evaluationskennzahl Matthews Correlation Coefficient MCC_E laut der Abbildung 9.12 festzustellen. Durch das bisher beobachtete qualitativ ähnliche Verhalten unterschiedlicher Kennzahlen der Modellgüte ist somit auch eine Verbesserung bei anderen Metriken zu erwarten. Folglich ist die in dieser Arbeit vorgeschlagene und umgesetzte künstliche Datensatz-Erweiterung (siehe Abschnitt 6.4) für die Prozesszustand-Überwachung mittels überwachter Klassifikation von Nutzen.

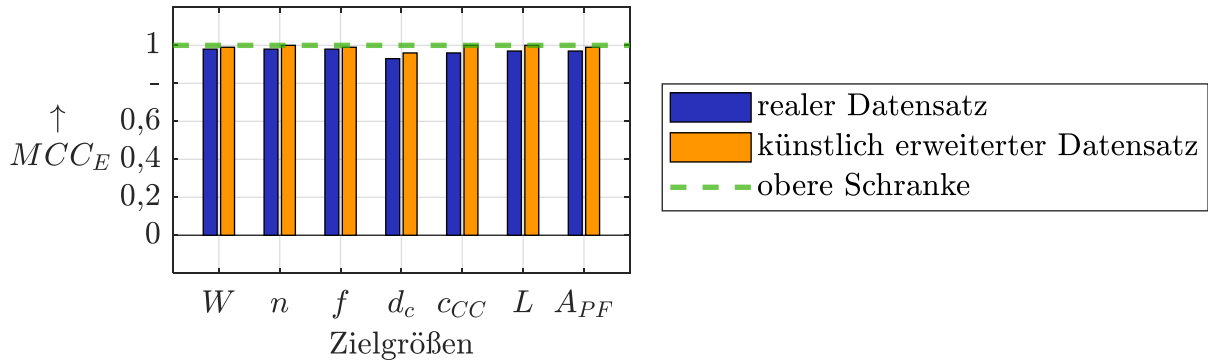


Abbildung 9.12: Prozesszustand: Einfluss der Datensatzgröße auf die Modellierungsgüte der überwachten Klassifikation bei künstlicher Erweiterung des Datensatzes (MCC_E = Matthews Correlation Coefficient, W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontaktzustand Bohrmaschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

9.4 Zusammenfassung und Bewertung

In diesem Kapitel werden die Potentiale ML-basierter Prozesszustand-Überwachung, bestehend aus dem Monitoring der Schnittparameter (Drehzahl, Vorschub pro Werkzeugumdrehung und Peck-Feed-Amplitude) und der Prozessbedingungen (Werkstoff, Kontaktzustand Maschine/Werkstück, Schmierungszustand und Aufspannweite der Materialprobe) untersucht. Das ML-basierte Monitoring wird mit unüberwachten ML-Clusteringalgorithmen und mit überwachten ML-Klassifikationsalgorithmen getestet und evaluiert. In der Tabelle 9.1 sind die klassenbezogenen maximalen Fehlerquoten $L_{E,K}$ der jeweils besten Modellierungs-Pipelines jeder Zielgröße dargestellt. Dabei wird die Betrachtung der Klasse „n. d.“ ausgeschlossen, da diese formell der Anomaliedetektion zugeordnet wird und in der Thematik dieses Kapitels nur als Nebenprodukt entstanden ist. Die klassenbezogene Fehlerquote $L_{E,K}$ wird zum Zwecke einer zusammenfassenden und direkt greifbaren Beurteilung folgendermaßen definiert: Für die Vorhersage jeder Klasse werden die Fehlerquoten ermittelt. Der Maximalwert dieser Fehlerquoten entspricht $L_{E,K}$, siehe dazu beispielhaft $L_{E,K} \approx 0,6\%$ in der Konfusionsmatrix für die Vorhersage von des Werkstoffs CFK-D in der Abbildung 9.8. Die Vorhersagen restlicher Werkstoffe haben geringere Fehlerquoten (die Klasse „n. d.“ wird nicht betrachtet, da diese als Zusatzauswertung zur Anomaliedetektion separat zur Prozesszustand-Überwachung betrachtet wird)

Beim unüberwachten Clustering werden die Daten in eine vorgegebene Anzahl an Clustern, deren Anzahl der Menge an möglichen diskreten Zuständen einer Überwachungs-Zielgröße entspricht, eingeordnet. Im Falle einer hohen Anzahl an Daten aus gleichen Prozesszuständen in einem Cluster kann von einer hohen Güte der Dateneinordnung in die Cluster gesprochen werden. Dazu werden je Zielgröße 9 unterschiedliche Modellierungs-Pipelines, die jeweils aus unterschiedlichen Verfahren der Feature-Vorbereitung und der ML-Clusteringalgorithmen gebildet werden, trainiert und untereinander verglichen. Basierend auf den Ergebnissen kann jedoch für ML-basiertes unüberwachtes Clustering keine industrielle Anwendungsempfehlung ausgesprochen werden.

Die überwachte Klassifikation wird je nach Zielgröße an 540 bis 720 Modellierungs-Pipelines untersucht. Bei der Bildung der Modellierungs-Pipelines werden die Validierungsmethode, die Objektivfunktion (beide im Hinblick auf die Hyperparameteroptimierung von Bedeutung) sowie die Feature-Vorbereitung und der ML-Algorithmus (beide im Hinblick auf das Modell-

training von Bedeutung) variiert, siehe dazu weitere Erklärung im Abschnitt 6.3.2.2. Bei der zum Anfang durchgeführten Feature-Vorbereitung wird über die Methoden hinweg eine sehr hohe Datenreduktion erreicht. Mit der Neighbourhood Component Analysis liegt diese bei mindestens 99,58 % für jede Zielgröße. Zur Feature-Signifikanz werden folgende Erkenntnisse gesammelt:

- Die Signifikanz der untersuchten Sensorgrößen ist abhängig von der Zielgröße.
- Die Datenrepräsentation als Rohdaten ist im Hinblick auf alle Zielgrößen sehr gut nutzbar, die Signifikanz restlicher Datenrepräsentationen ist zielgrößenabhängig.
- Zwischen den Features aus den einzelnen Bohrphasen sind keine relevanten Signifikanz-Unterschiede erkennbar.
- Die Spektral- und Bilddomäne beinhalten die wichtigste Information.

Die trainierten Modelle der überwachten Klassifikation zeichnen sich durch eine kleine (Speicher-)Größe von meist weniger als 100 Megabyte und eine Vorhersagezeit von größtenteils schneller als 10 s aus. Auffallend ist zudem, dass der Großteil der Modelle eine ähnlich hohe Vorhersagegüte hat, bei der nur wenige Prozesszustände falsch klassifiziert werden. Beispielsweise weisen die besten Modelle für die Vorhersage des vorliegenden Werkstoffs, der Drehzahl, des Vorschubs, des Schmierungs Zustands sowie der Peck-Feed-Amplitude sehr hohe Werte von mindestens 0,97 für die Evaluationskennzahlen Matthews Correlation Coefficient und Balanced Accuracy auf (bei einem maximalen möglichen Wert von jeweils 1). Ausgehend vom diesem hohen Niveau fallen lediglich die Vorhersagegüten für die Aufspannweite und den Kontaktzustand Maschine/Werkstück mit den dazugehörigen Werten von mindestens 0,93 ab. In der Tabelle 9.1 wird deutlich, dass nur bei der Aufspannweite d_c die maximale klassenbezogene Fehlerquote $L_{E,K} \geq 5\%$ beträgt.

Obwohl für jede Zielgröße nach dem eingeführten Ranking-Schema die besten Modellierungs-Pipelines in diesem Kapitel identifiziert werden, muss zusätzlich gesagt werden, dass die meisten Modellierungs-Pipelines über Zielgrößen hinweg sehr präzise Ergebnisse liefern. Zudem kann festgestellt werden, dass beim Monitoring des Vorschubs Anomalieereignisse mit einer gleichwertigen Genauigkeit erkannt werden wie bei einem auf Anomalieerkennung trainierten Modell (siehe Abschnitt 8.3.2.1).

Bei der Betrachtung der Modellierungsstufen gibt es im Hinblick auf die Hyperparameteroptimierung keine bei der Vorhersagegüte herausstechende Technik innerhalb der Validierungsmethoden und Objektivfunktionen. Daher wird bei der vorliegenden Aufgabe die rechenarme Hold-Out-Validierung als am geeignetsten angesehen. Die Feature-Vorbereitungsmethode der Neighbourhood Component Analysis wird zur Anwendung aufgrund ihrer durchschnittlich besten Bewertung innerhalb der Modellierungs-Pipelines empfohlen. Die auf Entscheidungsbäumen basierten Ensemble Learner in Form von Boosted Tree und Random Forest weisen im Schnitt die beste generelle Performance auf (die technischen Grundlagen zu den ML-Algorithmen sind im Abschnitt 2.3.4.1 zu finden).

Die Datensatzerweiterung mit künstlichen Daten verbessert die Modellierungsergebnisse trotz des bereits sehr hohen Ausgangsniveaus.

Die Quintessenz der vorgestellten Ergebnisse ist, dass ein breites Spektrum von ML-Modellen überwachter Klassifikation aufgrund sehr hoher Vorhersagegüten und integrierter Anomaliedetektion fürs Prozesszustand-Monitoring (mit Ausnahme der Zielgröße Aufspannweite) empfohlen wird.

Tabelle 9.1: Prozesszustand: Zusammenfassung der Vorhersagegüten bester Modelle (Eintrag der maximalen klassenbezogenen Fehlerquote $L_{E,K}$; NMI_E = Normalized Mutual Information, W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontakt Maschine/Werkstoff; L = Schmierung, A_{PF} = Peck-Feed-Amplitude)

Zielgrößen	max. klassenbezogene Fehlerquote $L_{E,K}$	
	unüberwachtes Clustering	überwachte Klassifikation
W	100 %	0,6 %
n	100 %	0,9 %
f	100 %	2 %
d_c	sehr hoch, da $NMI_E \leq 0,5$	61 %
c_{CC}	sehr hoch, da $NMI_E \leq 0,5$	2 %
L	sehr hoch, da $NMI_E \leq 0,5$	0,2 %
A_{PF}	53 %	2 %

10 Werkstückqualität-Überwachung

Dieses Kapitel behandelt das Monitoring der Werkstückqualität mit den ML-Methoden der überwachten Klassifikation und Regression. Dabei werden die diskreten Klassen sowie kontinuierliche Werte der Qualitätskenngrößen Grat Eintritt/Austritt, Bohrungsdurchmesser, Mittenrauwert der Bohrungswand, Delaminations-Faktor, Faserüberstands-Faktor und Delaminationsradius-Faktor vorhergesagt. Die Ergebnisvorstellung der Klassifikation und Regression erfolgt parallel, da diese überwachten ML-Verfahren strukturell eine im Großteil identische Teilschritt-Abfolge aufweisen. Ähnlich wie in vorherigen Ergebniskapiteln werden zuerst die Resultate der Modellierung basierend auf dem realen Datenset vorgestellt, wobei eine Analyse im Hinblick auf eine zielgrößenbezogene und zielgrößenübergreifende Auswertung erfolgt und die Verfahren der einzelnen Modellierungsstufen untersucht werden. Daraufhin wird der Einfluss der künstlichen Datenset-Erweiterung erläutert. In dieses Kapitel sind teilweise Erkenntnisse der vom Autor dieser Dissertation betreuten Masterarbeit von JUNGHANS [Jun22b] sowie der Bachelorarbeit von VOLKMANN [Vol22], die z. T. in [JRH23] veröffentlicht wurden, eingeflossen.

10.1 Überwachte Klassifikation und Regression

Dieser Abschnitt behandelt die Ergebnisse der überwachten Klassifikation und Regression, bei denen die Modelle an den experimentell aufgenommenen Daten trainiert werden. Die Zusatzangabe „überwacht“ wird durchgängig beibehalten, um die ML-Verfahrensgruppe zu verdeutlichen. Zu Anfang werden die Resultate der Feature-Vorbereitung und der Sensorrelevanz-Analyse präsentiert. Danach erfolgt die Analyse der zielgrößenbezogenen und -übergreifenden Vorhersagen inklusive der Vorstellung der Modellierungs-Pipelines mit den besten Vorhersagegütern. Anschließend werden die besten Methoden innerhalb jeder Modellierungsstufe (Validierungsmethode, Feature-Vorbereitung, ML-Algorithmus und Objektivfunktion) identifiziert sowie die Überanpassung bei den Klassifikationsalgorithmen bewertet.

10.1.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

In der Abbildung 10.1 ist die Anzahl der als relevant eingestuften Features für die überwachte Klassifikation und Regression eingetragen. Es ist sichtbar, dass die Neighbourhood Component Analysis durchgängig die höchste Daten-Reduktionsrate von mindestens 99,5 % aufweist. Die Reduktionsraten der restlichen Feature-Vorbereitungsmethoden weisen über alle Zielgrößen hinweg gemittelt keine signifikanten Unterschiede untereinander auf. Zwischen den Zielgrößen lässt sich keine Systematik bei der Datenreduktion erkennen. Im Gesamtüberblick ähneln sich die Reduktionsraten bei der Klassifikation und Regression.

Die Abbildung 10.2 stellt die Signifikanzen der einzelnen Ausprägungen der Feature-Extraktionspfade für die überwachte Klassifikation dar. Die Ergebnisse für die überwachte




Abbildung 10.1: Werkstückqualität-Überwachung: Feature-Vorbereitung (Die Balken stellen den Mittelwert der Feature-Anzahl über die 4 permutierten Datensätze des verbundenen Trainings- und Validierungs-Sets dar; Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor, $Chi2_F$ = Chi-Quadrat-Ranking, NCA_F = Neighbourhood Component Analysis, PCA_F = Principal Component Analysis, Rlf_F = Relief-Algorithmus, FT_F = F-Test-Ranking)

Regression sind in gleicher Form in der Abbildung A.21 im Anhang A.13.3 zu finden. Zu beachten ist dabei, dass die Signifikanzwerte nur innerhalb eines Diagramms untereinander vergleichbar sind. Aus den Abbildungen lassen sich folgende Schlussfolgerungen ziehen:

- *Sensorgröße*: Der Vorschubmotor-Strom I_{VM} weist eindeutig die höchste Signifikanz bei der Klassifikation und Regression auf. Besonders in Bezug auf die Schädigungsformen Grat am Austritt Q_{GE} , Delaminationsradius-Faktor Q_{DR} , Delaminations-Faktor Q_{DF} und Faserüberstand-Faktor Q_{FF} kann dieser Zusammenhang gemäß den Ausführungen im Abschnitt 2.1.3 bestätigt werden, da demnach diese Schädigungsformen signifikant von der Vorschubkraft F_f abhängen und diese gemäß [HMR19] mit dem Vorschubmotorstrom I_{VM} der SmartADU korreliert. Somit stoßen die ML-basierten Ergebnisse dieser Arbeit in ähnliche Bereiche vor, wie dies bei den experimentellen und analytischen Ergebnissen in [Klo17] und [Lis21] zu finden ist.

Zudem werden die Austritt-Schädigungen Delaminations-Faktor Q_{DF} und der Faserüberstand-Faktor Q_{FF} vorwiegend durch den Schalldruck bzw. die externen Beschleunigungssensoren erklärt, was ein Hinweis auf deren Zusammenhang mit hochfrequenten Schwingungsanteilen ist, da die externen Sensoren eine etwa 50-fache

Abtastrate gegenüber den internen Sensoren aufweisen.

Bei der Klassifikation ist zudem eine ebenfalls, jedoch in geringerem Umfang, erhöhte Wichtigkeit des Spindelmotorstrom I_{SM} festzustellen. Bei den externen Sensorgrößen ist zudem eine teilweise zielgrößenabhängige erhöhte Sensor-Signifikanz erkennbar.

- *Datenrepräsentation:* Entgegen den bisherigen Ergebnissen bei der Anomaliedetektion (Abschnitt 8.3.1) und der Prozesszustand-Überwachung (Abschnitt 9.2.1) sind die ungefilterten Daten bei beiden ML-Verfahrensgruppen als weniger wichtig eingestuft. Dies ist ein Hinweis darauf, dass Qualitätseigenschaften nicht vorwiegend durch kurzzeitige oder hochfrequente Ereignisse bestimmt werden.
- *Bohrphase:* Hierbei existieren im Mittel keine nennenswerten Signifikanzunterschiede. Dies widerspricht der Annahme, dass Qualitätskenngrößen am Bohrungseintritt (Grat Eintritt Q_{GE}) und dementsprechend Qualitätsgrößen am Bohrungsausritt (Grat Austritt Q_{GA} , Delaminations-Faktor Q_{DF} , Faserüberstand-Faktor Q_{FF} und Delaminationsradius-Faktor Q_{DR}) durch Features aus den entsprechenden Bohrphasen Eintritt Ph_E und Austritt Ph_A beschrieben werden.
- *Domäne:* Die Spektral- und Bilddomäne bringen die relevantesten Features hervor.

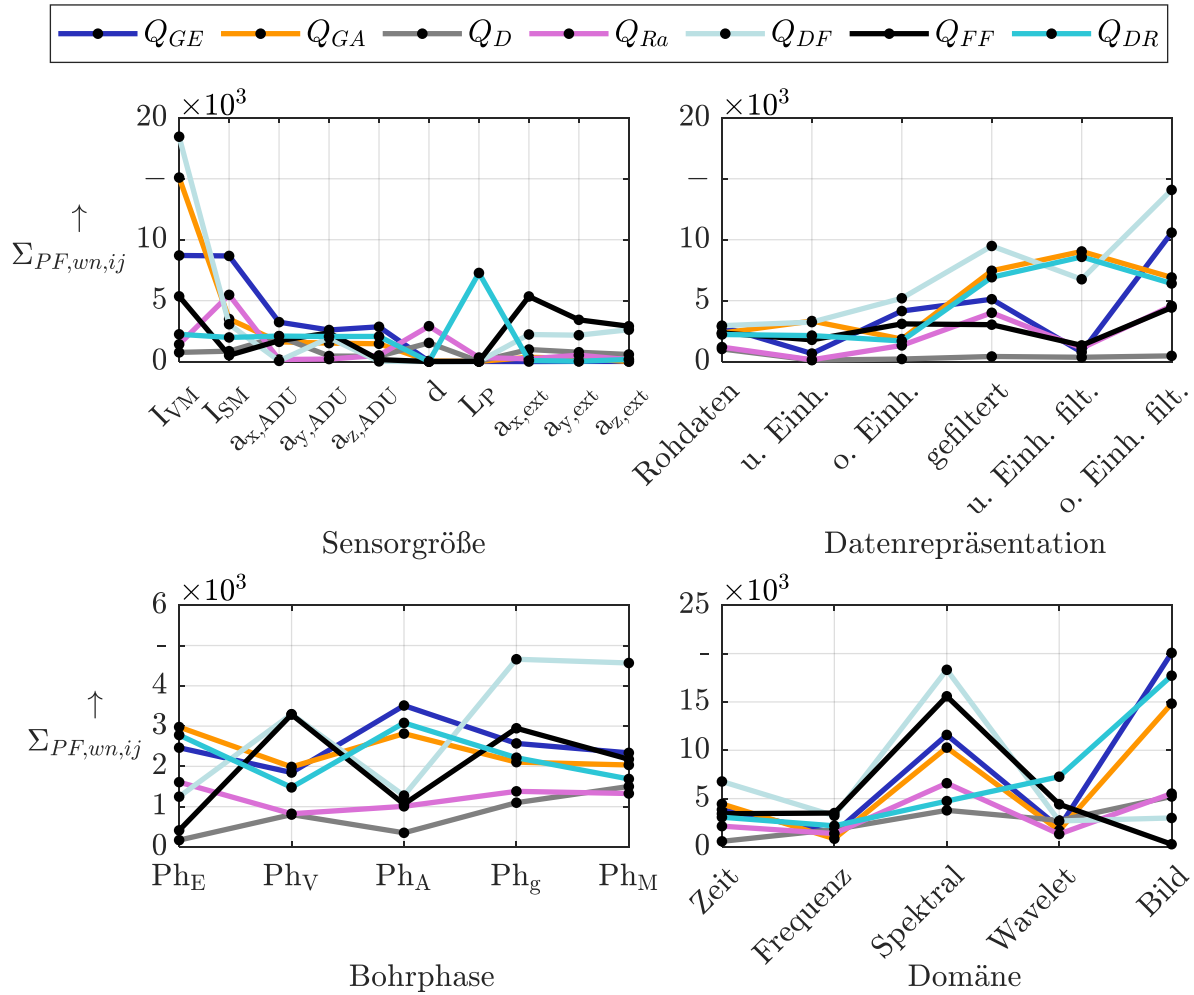


Abbildung 10.2: Werkstückqualität-Überwachung: Feature-Signifikanz bei überwachter Klassifikation (Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor; $\Sigma_{PF,wn,ij}$ = gewichtete Summe der normierten Feature-Signifikanzwerte (nur innerhalb jedes einzelnen Diagramms vergleichbar), I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, d = Distanz Werkstück, LP = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, u./o. Einh. = untere/obere Einhüllende; u./o. Einh. filt. = untere/obere Einhüllende gefiltert, Ph_E = Eintritt, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

10.1.2 Ranking der finalen Modelle

Nachfolgend werden die Modellierungs-Pipelines auf ihre Eignung bezogen auf die einzelnen Zielgrößen sowie auf ihr generelles Verhalten über die Zielgrößen hinweg untersucht.

10.1.2.1 Zielgrößenbezogene Auswertung

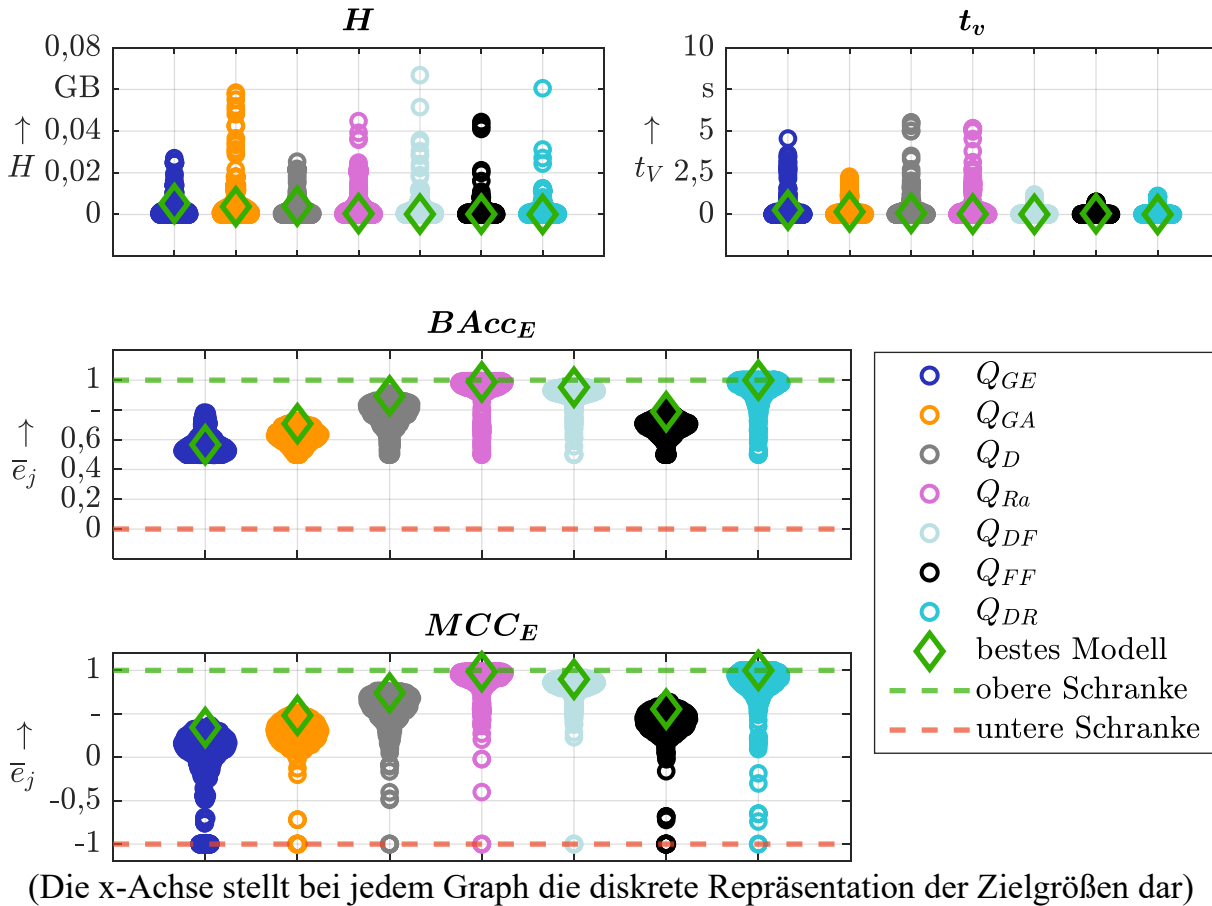
In diesem Abschnitt werden die Modellierungsergebnisse der Klassifikation und Regression für jede Zielgröße verglichen. Für die definierten Klassengrenzen sei auf die Ausführungen im Abschnitt 6.3.3 verwiesen. In den Abbildungen 10.3 und 10.4 sind die Evaluationsergebnisse der untersuchten Modellierungs-Pipelines je Zielgröße dargestellt (Anzahl untersuchter Klassifikations- und Regressions-Pipelines: 720 / 560). Wie es bereits in vorherigen Abschnitten durchgeführt wurde, werden die Ergebnisse auch hier als eine Häufigkeitsverteilung basierend auf einem Kerndichteschätzer präsentiert, siehe Erläuterungen im Abschnitt 8.3.2.1.

Die Speichergrößen H für alle Modellierungs-Pipelines liegen maximal im Bereich $H = 0,3$ GB, was auf heutigen Edge-Devices verarbeitbar ist. Tendenziell haben die Regressionsmodelle einen um den Faktor 5 höheren Speicherbedarf. Die Mehrheit der Modelle beider Verfahrensgruppen benötigt jedoch nur wenige Megabyte Speicherplatz. Zudem weisen die meisten Klassifikations- und Regressionsmodelle eine sehr kurze Vorhersagedauer von $t_V \leq 1$ s auf, was deren Anwendbarkeit im Produktionsumfeld unterstreicht.

Um einen zusammenfassenden Überblick über die Vorhersagegüte für alle Modelle zu bieten, werden für die Klassifikation (Abbildung 10.3) die in vorherigen Kapiteln bewährten exemplarischen Evaluationskennzahlen Balanced Accuracy $BACC_E$ und Matthews Correlation Coefficient MCC_E herangezogen. Bei den Regressionsmodellen (Abbildung 10.4) wird für die exemplarische Bewertung des Zusammenhangs zwischen wahrem Wert und Vorhersage auf die dimensionslosen Kennwerte Bestimmtheitsmaß R_E^2 und Pearson-Korrelationskoeffizient $R_{XY,E}$ zurückgegriffen, da diese einen fest definierten Wertebereich besitzen und damit eine Vergleichbarkeit zwischen den Zielgrößen vorhanden ist.

Bei der Darstellung der Vorhersagekennzahlen in den Abbildungen 10.3 und 10.4 wird deutlich, dass die Zielgrößen Rauigkeit Q_{Ra} und Delaminations-Faktor Q_{DF} durch die Klassifikation als auch durch die Regression bei einer Vielzahl von Modellierungs-Pipelines mit einer hohen Vorhersagegüte modelliert werden. In den dazugehörigen Graphen bewegen sich für viele Modelle die Werte der Evaluationskennzahlen nahe dem Maximalwert $\bar{e}_j = 1$. Bei der überwachten Klassifikation ist dies zudem bei dem Delaminationsradius-Faktor Q_{DR} und bei der überwachten Regression annähernd bei dem Bohrungsdurchmesser Q_D der Fall. Der Faserüberstand-Faktor wird bei beiden Verfahrensgruppen nur mit einer guten Güte vorhergesagt, die besten Werte der Evaluationskennzahlen liegen hierbei bei $\bar{e}_j \approx 0,8$. Für den Ein- und Austrittsgrat liegen die Kennzahlen niedriger, womit hierbei nur von einer moderaten Vorhersagegüte nur noch bei der Regression gesprochen werden kann. Diese Aussagen fußen auf Orientierungswerten für die Evaluationskennzahlen aus dazugehöriger Literatur (siehe technische Grundlagen im Abschnitt 2.3.4.2). Die Ergebnisse lassen den Schluss zu, dass die Mehrheit der Qualitäts-Kenngrößen mit ML-Algorithmen überwacht werden kann.

In den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 sind die Eigenschaften und exemplarische Evaluations-Kennzahlen der generell am besten eingestufteten Klassifikations- und Regressionsmodelle für die Zielgrößen der Werkstückqualität aufgeführt. Die dazugehörigen kennzahlenübergreifenden Ranking-Verfahren sind in den Abschnitten 6.3.3.1 und 6.3.3.2

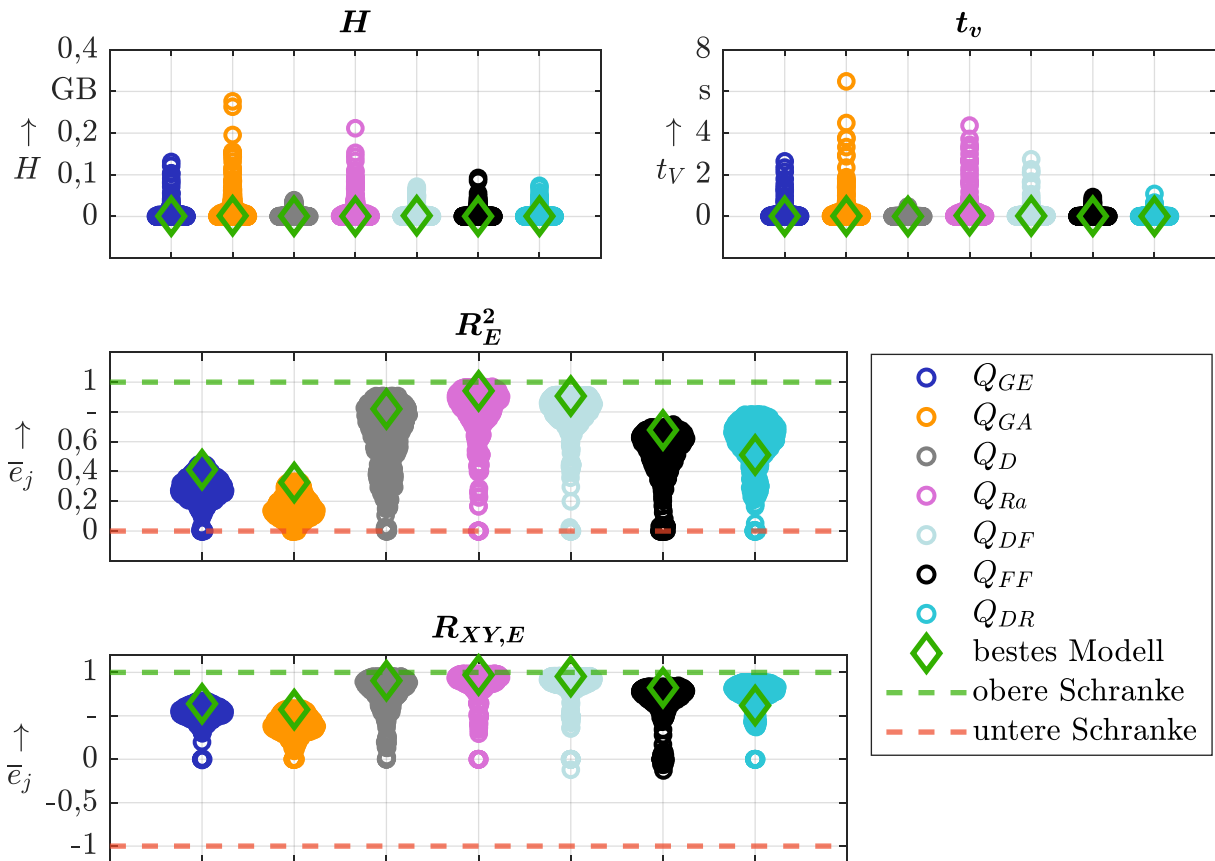


(Die x-Achse stellt bei jedem Graph die diskrete Repräsentation der Zielgrößen dar)

Abbildung 10.3: Werkstückqualität-Überwachung: Modell-Performance bei überwachter Klassifikation (Mengendarstellung ausgewählter Evaluations-Kennzahlen jeder Modellierungs-Pipeline, die an 4 Test-Sets ausgewertet ist; Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor, H = Modell-Speichergröße, t_v = Dauer der Vorhersage, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Datensätze, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

referenziert. Bei den Klassifikations-Modellen werden zusätzlich die 2-Klassen-Modellierungs-Pipelines, die zu der besten True Positive Rate TPR_E bei dem Test-Datensatz führen, in der Tabelle A.39 im Anhang A.13.3 mit ihren Hyperparametern und exemplarischen Evaluations-Kennzahlen gelistet. Hierbei besteht der Fokus ausschließlich auf der sicheren Bestimmung der positiven Klasse, die außerhalb der Qualitätsvorgaben liegende Bohrungen repräsentiert. Dabei werden falsch positive Klasseneinteilungen (=Fehlalarm) nicht bewertet. Die Betrachtung der True Positive Rate TPR_E besitzt für binäre Modelle eine höhere Aussagekraft als für multi-Klassen-Modelle, da hier jeweils eine eindeutige positive und negative Klasse vorliegt. Daher wird auf die Darstellung der True Positive Rate TPR_E der Modelle mit mehr als 2 Klassen verzichtet. Bei einigen Zielgrößen hat das beste generelle Modell die ebenfalls beste True Positive Rate TPR_E . Für den Mittenrauwert der Bohrungswand Q_{Ra} , den Delaminations-Faktor Q_{DF} und den Faserüberstand-Faktor Q_{FF} werden praktisch alle außerhalb der Toleranz liegenden Bohrungen erkannt ($TPR_E \geq 0,99$)

Im Anschluss an die vorgestellten Kennzahlentabellen erfolgt die Gegenüberstellung von Vorhersage und wahren Wert anhand der Test-Datensätze mithilfe von Konfusionsmatrizen für die Klassifikation und Streudiagrammen für die Regression in den Abbildungen 10.5 -



(Die x-Achse stellt bei jedem Graph die diskrete Repräsentation der Zielgrößen dar)

Abbildung 10.4: Werkstückqualität-Überwachung: Modell-Performance bei überwachter Regression (Mengendarstellung ausgewählter Evaluations-Kennzahlen jeder Modellierungs-Pipeline, die an 4 Test-Sets ausgewertet ist; Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor, H = Modell-Speichergroße, t_V = Dauer der Vorhersage, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Datensätze, R_E^2 = Bestimmtheitsmaß, $R_{XY,E}$ = Pearson-Korrelationskoeffizient)

10.11. Die Werte der Evaluationskennzahlen in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 zeigen, dass zur Bestimmung der generell besten Modellierungs-Pipelines eine Bewertung über möglichst viele Evaluationskennzahlen notwendig ist, wie in dem im Abschnitt 6.3.3.2 eingeführtem Ranking-Verfahren geschehen. Bei der Betrachtung von einzelnen als „objektiv“ geltenden Evaluationskennzahlen (z. B. MCC_E , $Mark_E$, FSC_E , ...) würden unterschiedliche Modell-Rankings entstehen.

Grat Eintritt Q_{GE}

In der Abbildung 10.5 wird die Tendenz deutlich, außerhalb der Toleranz liegende Eintritts-Grathöhen fälschlicherweise als innerhalb der Toleranz liegend einzustufen. Umgekehrt gibt es jedoch keinen einzigen falschen Alarm bezogen auf innerhalb der Toleranz liegende Bohrungen. Damit ist das Modell trotz der sehr hohen Gesamtgenauigkeit nicht brauchbar aufgrund der verhältnismäßig hohen Falsch Negativ Rate FNR_E , da damit ein signifikanter Anteil außerhalb der Toleranz liegenden Bohrungen als innerhalb liegend klassifiziert wird. Die Wurzel des mittleren quadratischen Fehlers beträgt für den Eintritts-Grat beim besten generellen Regressionsmodell $RMSE_E \approx 0,03$ mm und liegt damit bei 15 % der Toleranzbreite. Mit steigender wahrer Grathöhe steigt der $RMSE_E$.




Abbildung 10.5: Beste Modelle zur Vorhersage des Eintrittsgrats Q_{GE} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; die Klassengrenzen liegen bei $Q_{GE} = 0,1$ mm und $Q_{GE} = 0,2$ mm; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

Grat Austritt Q_{GA}

Anhand der Abbildung 10.6 ist sichtbar, dass trotz der insgesamt mehrheitlich richtig klassifizierten Grathöhen am Austritt Q_{GA} bei kleinen, in der Toleranz liegenden wahren Werten, die Vorhersagegüte nicht die Anforderungen der Industrie erfüllen dürfte. Der Anteil der Fehlklassifizierung ist bei den außerhalb der Toleranz liegenden wahren Klassen mehrheitlich falsch negativ. Diese Aussage wird durch die Ergebnisse der Regression, die bei höheren Gratwerten ungenauer wird und bei der sehr hohe Grathöhen oftmals als zu niedrig vorhergesagt werden, bestätigt. Hierbei liegt die Wurzel des mittleren quadratischen Fehlers bei $RMSE_E \approx 0,05$ mm, welche sich damit bei 25 % der Toleranzbreite befindet. Dies ist um etwa 0,02 mm höher als bei dem Vergleichswert des Eintritts-Grats Q_{GE} .

Bohrungsdurchmesser Q_D

In der Abbildung 10.7 ist sichtbar, dass die Mehrzahl der Bohrungen richtig klassifiziert wird. Bei den Bohrungen unterhalb der Toleranz werden etwa 11 % und oberhalb der Toleranz etwa 16 % der Bohrungen fälschlicherweise als ordnungsgemäß klassifiziert. Bei dem Regressionsergebnis weist das beste Modell als Wurzel des mittleren quadratischen Fehlers $RMSE_E \approx 0,01$ mm auf. Dies entspricht einem Anteil von etwa 20 % der Toleranzbreite. Der Regressionsfehler $RMSE_E$ ist nicht von der Höhe des wahren Wertes abhängig.

Rauigkeit Q_{Ra}

Das beste Klassifikations-Modell weist eine fast fehlerfreie Klassenzuordnung auf (Abbildung 10.8). Zudem wird eine fast fehlerlose Erkennung der außerhalb der Toleranz liegenden Bohrungen mit der Modellierungs-Pipeline, welche die höchste True Positive Rate TPR_E hat, ermöglicht. Die Wurzel des mittleren quadratischen Fehlers $RMSE_E$ bei dem besten Regressionsmodell beträgt $RMSE_E \approx 0,21$ μ m (etwa 12,5 % des Toleranzbereichs). Beim $RMSE_E$ ist keine Abhängigkeit von der Höhe der wahren Zielgröße zu sehen.




Abbildung 10.6: Beste Modelle zur Vorhersage des Austrittsgrats Q_{GA} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; die Klassengrenzen liegen bei $Q_{GA} = 0,1$ mm und $Q_{GA} = 0,2$ mm; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

Delaminations-Faktor Q_{DF}

Anhand der Abbildung 10.9 wird sichtbar, dass das generell beste Klassifikations-Modell eine hohe Vorhersagegüte aufweist, bei der nur etwa 5% der Klassifikationen falsch sind. Zudem ist es möglich, jegliche außerhalb der Toleranz liegenden Delaminations-Faktoren zu detektieren, siehe dazu die Konfusionsmatrix mit der besten True Positive Rate TPR_E . Diese Eigenschaft geht jedoch zu Lasten vieler Falschalarme, da mehr als die Hälfte der in Toleranz liegenden Bohrungen als außerhalb liegend klassifiziert werden. Die Wurzel des mittleren quadratischen Fehlers $RMSE_E$ des besten Regressionsmodells beträgt $RMSE_E \approx 0,07$. Dies entspricht etwa 7% der Toleranzbreite. Es ist ein leichter Anstieg von $RMSE_E$ mit steigendem wahren Delaminationsradius-Faktor Q_{DF} zu beobachten.

Faserüberstand-Faktor Q_{FF}

Laut der Abbildung 10.10 können mit dem generell besten Klassifikations-Modell die außerhalb der Toleranz liegenden Bohrungen nicht präzise bestimmt werden. Diese Aufgabe kann durch die Modellierungs-Pipeline mit der besten True Positive Rate TPR_E übernommen werden, was jedoch einen hohen Anteil an falschen Alarmen mit sich zieht. Das beste Regressionsmodell erreicht ein $RMSE_E \approx 0,078$ ($\approx 15\%$ der Toleranzbreite).

Delaminationsradius-Faktor Q_{DR}

Das generell beste Klassifikations-Modell hat eine fehlerlose Klasseneinteilung, siehe Abbildung 10.11. Demgegenüber beträgt beim besten Regressionsmodell die Wurzel des mittleren quadratischen Fehlers $RMSE \approx 0,2$ ($\approx 20\%$ der Toleranzbreite). Bei dieser Zielgröße wird deutlich, dass sich die Klassifikation zur Überwachung deutlich besser eignet.




Abbildung 10.7: Beste Modelle zur Vorhersage des Durchmessers Q_D mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; die Klassengrenzen liegen bei $Q_D = 6,34$ mm und $Q_D = 6,39$ mm; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

10.1.2.2 Zielgrößenübergreifende Auswertung

In der Abbildung 10.12 stellt sich das bereits in der Anomaliedetektion (Abbildung 8.11) und Prozesszustand-Überwachung (Abbildung 9.10) bekannte Verhältnis ein. Die Mehrheit der Modellierungs-Pipelines hat eine geringe Abweichung untereinander gemäß dem Durchschnitt des gewichteten Gesamt-Punktwerts \bar{m} über alle Zielgrößen hinweg. Mit den bereits detektierten präzisen Modellierungs-Pipelines im vorherigen Abschnitt deutet dies darauf hin, dass die Mehrheit der genutzten Methoden für die Werkstückqualität-Überwachung bei semi-automatischen Bohrprozessen im ähnlichen Rahmen anwendbar ist und sich in ihrer Gesamtperformance ähnelt. Es sei hierbei darauf hingewiesen, dass für die überwachte Klassifikation in Summe 720 und für die überwachte Regression 560 Modellierungs-Pipelines entwickelt sind.




Abbildung 10.8: Beste Modelle zur Vorhersage des Mittenrauwerts an der Bohrungswand Q_{Ra} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $Q_{Ra} = 1,6 \mu\text{m}$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 10.9: Beste Modelle zur Vorhersage des Delaminations-Faktors Q_{DF} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $Q_{DF} = 1$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 10.10: Beste Modelle zur Vorhersage des Faserüberstand-Faktors Q_{FF} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $Q_{FF} = 0,5$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 10.11: Beste Modelle zur Vorhersage des Delaminationsradius-Faktors Q_{DR} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $Q_{DR} = 1$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 10.12: Werkstückqualität-Überwachung: zielgrößenübergreifende Auswertung der überwachten Klassifikation und Regression in Form einer Übersicht über die Bewertung der Modellmenge (\bar{m} = Durchschnitt des gewichteten Gesamt-Punktwerts über alle Zielgrößen der Werkstückqualität hinweg)

10.1.3 Analyse der Modellierungsstufen und der Überanpassung

In der Abbildung 10.13 wird die Performance der Modellierungsstufen für die überwachte Klassifikation analysiert. Eine analoge Auswertung für die Regression ist in der Abbildung A.22 im Anhang A.13.3 zu finden. Das Vorgehen findet Anwendung in der bereits vorgestellten Anomaliedetektion (Abschnitt 8.3.3) und Prozesszustand-Überwachung (Abschnitt 9.2.3) und wird in den dazugehörigen Abschnitten näher erläutert. Der Fokus der vorliegenden Auswertung liegt ausschließlich auf den zielgrößenübergreifenden Kennzahlen *Durchschnitt des gewichteten Gesamt-Punktwerts* \bar{m} und *Bewertungsfaktor für die Überanpassung* \bar{O}_F . Die technischen Grundlagen zur Überanpassung sind dazu im Abschnitt 2.3.2.2 und die dazugehörige umgesetzte Vorgehensweise zu deren Analyse im Abschnitt 6.3.3.1 erklärt. Bei der Regression ist eine objektive Bewertung der Überanpassung aufgrund dessen, dass die meisten Evaluationskennzahlen und damit auch Objektivfunktionen dimensionsbehaftet sind, nicht praktikabel und wird daher nicht verfolgt. Als Ergebnis kann folgendes festgehalten werden:

- *Validierungs-Methoden:* Die Resubstitution RS_V fällt von den restlichen (untereinander gleichwertigen) Methoden bei der Gesamtbewertung und Überanpassung geringfügig während der Klassifikation ab. Bei der Regression sind die Methoden gleichwertig. Daher wird der Einsatz der schnelleren Hold-Out-Validierung HO_V empfohlen.
- *Feature-Vorbereitungsmethoden:* Das Chi-Quadrat-Ranking $Chi2_F$ führt bei der Klassifikation durchschnittlich zu Ergebnissen mit höchster Modellierungsgüte. Die Principal Component Analysis weist dabei die höchste Überanpassung auf, obwohl ihre Feature-Anzahl als in etwa gleichwertig zu der vom Chi-Quadrat-Ranking $Chi2_F$ und Relieff-Algorithmus Rlf_F zu bewerten ist, siehe dazu Abbildung 10.1. Bei der Regression sind die Neighbourhood Component Analysis NCA_F und das F-Test-Ranking FT_F den anderen Methoden überlegen.
- *ML-Algorithmen:* Der auf Entscheidungsbäumen basierte ML-Algorithmus Boosted Tree BT_{MK} setzt sich von den restlichen Methoden bei der Klassifikation und ebenfalls bei der Regression (hierbei zusammen mit dem Random Forest RF_{MR}) geringfügig ab.
- *Objektivfunktionen:* Es existiert im Allgemeinen kein bedeutender Unterschied zwischen den Verfahren.

Anhand der präsentierten Auswertung wird deutlich, dass sich die unterschiedlichen Methoden der Modellierungsstufen durchschnittlich bis auf wenige Ausnahmen in ihrer Performance wenig unterscheiden und die besten Verfahren sich nur geringfügig vom Rest absetzen. Diese Aussage deckt sich mit dem Informationsgehalt zur zielgrößenübergreifenden Performance-Auswertung in der Abbildung 10.12.

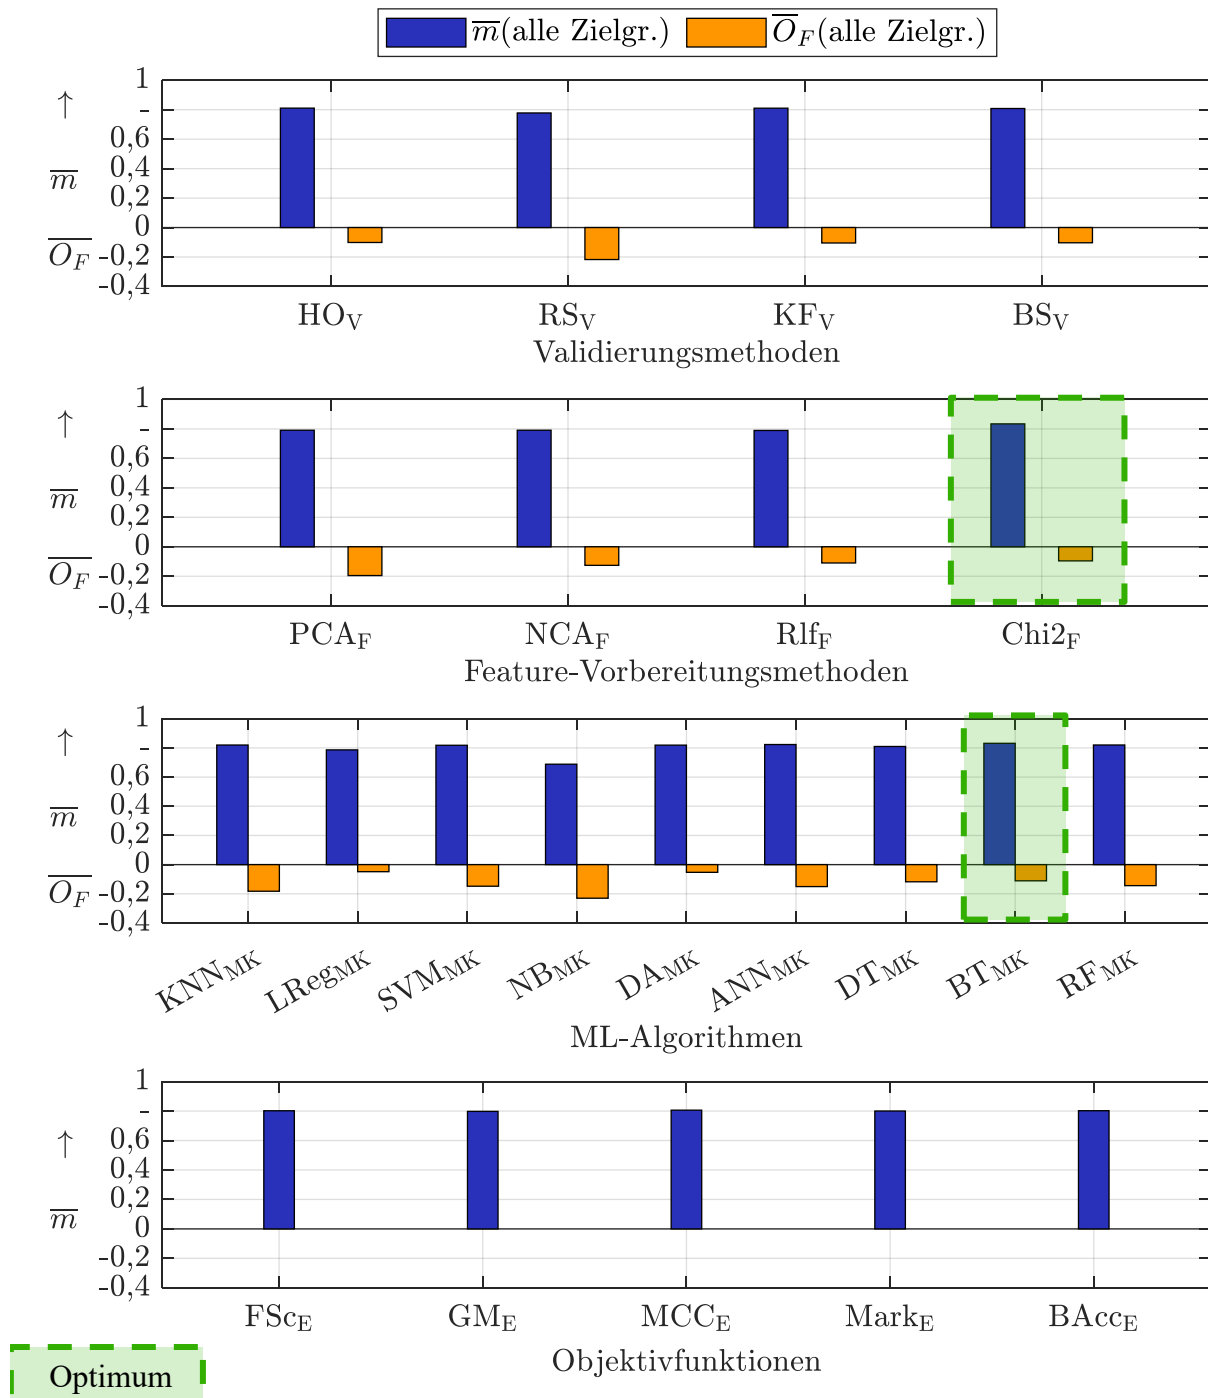


Abbildung 10.13: Werkstückqualität: Modellierungsstufen und Überanpassung bei überwachter Klassifikation; die Markierung des Optimums jeder Modellierungsstufe erfolgt falls die beste(n) Option(en) ein um $\approx 0,01$ höheres \bar{m} als die zweitbeste vorweist (\bar{m} = Durchschnitt des gewichteten Gesamt-Punktwerts für die vorliegende Methode einer Modellierungsstufe über aller Modellierungs-Pipelines hinweg, \bar{O}_F = über alle Modellierungs-Pipelines gemittelter Bewertungsfaktor für Überanpassung (siehe Abschnitt 6.3.1.3); zur Symbol-Kennzeichnung der Zielgrößen, Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie der Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.3 und die Anhänge A.1.3 und A.10.1 verwiesen)

10.2 Einfluss der Datensatzgröße

Im Folgenden wird der Einfluss künstlicher Datenset-Erweiterung diskutiert. Die verwendete Methode ist in dem Abschnitt 6.4 erläutert. Die Untersuchung erfolgt anhand der am besten identifizierten Modellierungs-Pipelines gemäß den Tabellen A.37, A.38, A.40 und A.41 im Anhang A.13.3. Die dazugehörigen Ranking-Verfahren sind in den Abschnitten 6.3.3.1 und 6.3.3.2 referenziert. Auf die Darstellung der Trainings- und Vorhersagezeiten t_M und t_V wird aus Gründen der Übersichtlichkeit verzichtet, da diese sich zielgrößenabhängig in einer Größenordnung des etwa 1- bis 125-fachen ihres Pendanten beim Modell-Training anhand des realen Datensatzes vergrößern. Der maximale absolute Wert der Vorhersagezeit unter Nutzung des künstlich erweiterten Datensatzes beträgt $t_V = 7\text{ s}$ (bei der Klassifikation des Grats am Eintritt Q_{GE}), wodurch der Einsatz der Modelle im laufenden Produktionsbetrieb bei ausreichend langer Zykluszeit des Bohrprozesses weiterhin als möglich eingeschätzt wird.

In der Abbildung 10.14 werden die charakteristischen Vorhersagegüte-Kennzahlen Matthews Correlation Coefficient MCC_E bei der Klassifikation und das Bestimmtheitsmaß R_E^2 bei der Regression verglichen. Diese besitzen den gleichen Wertebereich, was einen Vergleich zwischen den beiden Verfahrensgruppen möglich macht. Bei der Klassifikation wird bei allen Zielgrößen die Vorhersagegüte beim Modell-Training anhand des künstlich erweiterten Datensatzes verbessert. Tendenziell ist die Verbesserung bei bereits mit dem realen Datensatz akkurat arbeitenden Modellen am größten. Bei der Regression wird bei den meisten Zielgrößen ebenfalls eine Verbesserung erreicht. Eine Ausnahme bildet hierbei der Faserüberstands-Faktor Q_{FF} , für den das Modelltraining aufgrund fehlender Konvergenz des Trainings-Prozesses fehlschlug.

Als Fazit bleibt festzuhalten, dass bei einem kleinen Datensatz die künstliche Datenset-Erweiterung oftmals ein nützliches Mittel ist, um die Vorhersagegüte der trainierten Modelle bei der Werkstückqualität zu verbessern. Die Verfahren sollten jedoch vor der Anwendung auf mögliche Fehlfunktionen getestet werden.

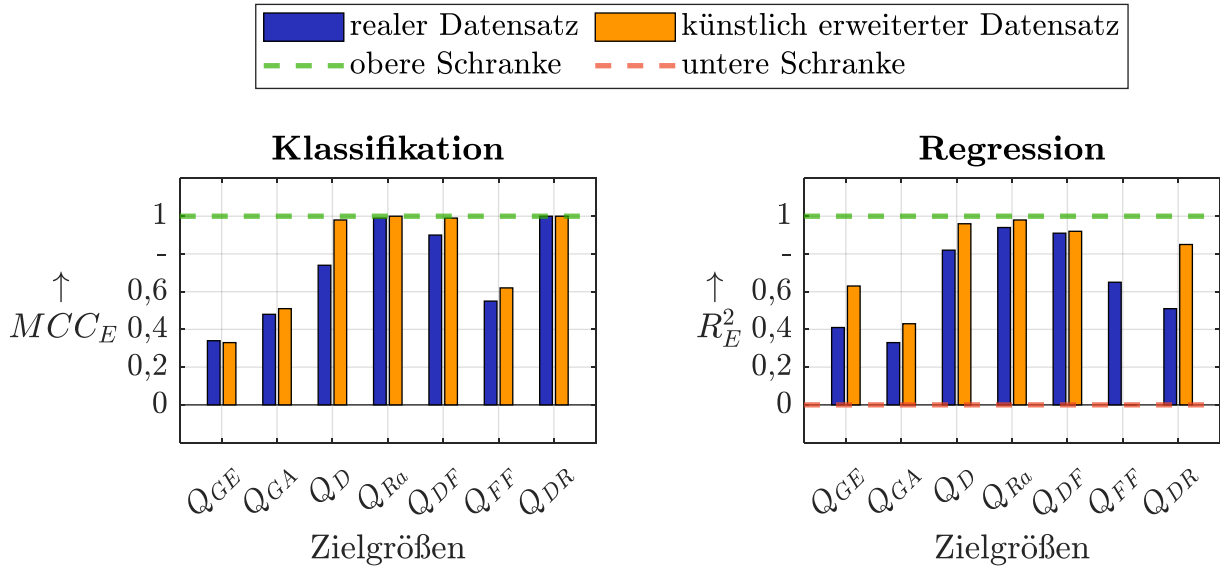


Abbildung 10.14: Werkstückqualität-Überwachung: Einfluss der Datensatzgröße auf die Modellierungsgüte der überwachten Klassifikation und Regression bei künstlicher Erweiterung des Datensatzes (MCC_E = Matthews Correlation Coefficient, R_E^2 = Bestimmtheitsmaß, Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstands-Faktor, Q_{DR} = Delaminationsradius-Faktor)

10.3 Zusammenfassung und Bewertung

In diesem Kapitel erfolgt die Bewertung der überwachten Klassifikations- und Regressions-Algorithmen hinsichtlich ihrer Eignung zur Überwachung der erreichten Werkstückqualität mit den Zielgrößen Grat am Eintritt, Grat am Austritt, Bohrungsdurchmesser, Mittenrauwert der Bohrungswand sowie jeweils Delaminations-Faktor, Faserüberstand-Faktor und Delaminationsradius-Faktor am Bohrungsaustritt von CFK-Werkstoffen. Bei der Klassifikation werden die Qualitäts-Kennwerte gemäß den Toleranzgrenzen in der Tabelle 6.12 in eigene Klassen unterteilt, während bei der Regression die kontinuierlichen Qualitäts-Kennwerte vorhergesagt werden. Dazu werden bei beiden Verfahrensgruppen die Methoden in den 4 Modellierungsstufen (Validierungs-Methode, Feature-Vorbereitung, ML-Algorithmus und Objektivfunktion) variiert. Für die Klassifikation ergeben sich 720 und für die Regression 560 Modellierungs-Pipelines.

Zu Beginn wird die Datenreduktions-Rate ausgehend von den 23560 extrahierten Features untersucht. Die Methode Neighbourhood Component Analysis erreicht generell die höchste Datenreduktion (mindestens 99,5%). Dies bedeutet, dass zu Beginn ohne tiefes Domänen-Wissen eine hohe Feature-Anzahl aus den Sensordaten entnommen und zur Feature-Selektion weitergeleitet werden kann. Bei der Feature-Signifikanz ist der Vorschubmotor-Strom die generell wichtigste Sensorgroße. Die restlichen Sensoren weisen teilweise in Abhängigkeit der Zielgröße eine erhöhte Signifikanz auf. Bei der Datenrepräsentation sind die gefilterten Daten deutlich relevanter als die Rohdaten. Zwischen den Bohrphasen existieren in der Wichtigkeit keine nennenswerten Unterschiede. Die Spektral- und Bilddomäne bringen die wichtigsten Features hervor.

Die Speichergrößen liegen für alle Modelle bei max. 0,3 GB und die Vorhersagezeiten sind beim Großteil der Ergebnisse kleiner als 1 s. Als repräsentative Kennzahlen der Vorhersagegüte werden für die Klassifikation der Matthews Correlation Coefficient und die Balanced Accuracy

sowie für die Regression das Bestimmtheitsmaß und der Pearson-Korrelationskoeffizient betrachtet. Es wird beobachtet, dass ein Großteil der Modelle (etwa 90 %) für jede Zielgröße sich in seiner Gesamtbetrachtung nicht fundamental unterscheidet. Zusammenfassend können folgende Aussagen getroffen werden: Am akkuratesten werden die Zielgrößen Rauigkeit und Delaminations-Faktor jeweils bei der Klassifikation und Regression vorhergesagt. Von einer mittelhohen Vorhersagegüte kann bei der Klassifikation und Regression der Zielgrößen Delaminationsradius-Faktor, Bohrungsdurchmesser und Faserüberstand-Faktor gesprochen werden. Die Vorhersage des Grats am Ein- und Austritt erreicht bei der Klassifikation nur ungenaue und bei der Regression nur mittelmäßig genaue Ergebnisse. In Bezug auf jede Zielgröße entstehen folgende Quintessenzen basierend auf den Ergebnissen der jeweils besten Modellierungs-Pipeline. In der Tabelle 10.1 werden die Aussagen anhand der darin enthaltenen Evaluations-Kennzahlen zusätzlich untermauert.

- *Grat Eintritt*: Die trainierten Modelle sind trotz der sehr hohen Gesamtgenauigkeit nicht brauchbar aufgrund der verhältnismäßig hohen Falsch Negativ Rate FNR_E , da damit ein signifikanter Anteil außerhalb der Toleranz liegenden Bohrungen als innerhalb liegend klassifiziert wird. Innerhalb der Toleranz liegenden Bohrungen werden jedoch zuverlässig eingeordnet. Die Regression weist einen geschätzten mittleren Fehler von 0,03 mm auf.
- *Grat Austritt*: Außerhalb der Toleranz liegende Bohrungen werden mehrheitlich falsch klassifiziert. Die Regression weist einen geschätzten mittleren Fehler von 0,05 mm auf.
- *Bohrungsdurchmesser*: Je Klasse werden zwischen 10 und 16 % der Bohrungen falsch klassifiziert. Die Regression weist einen geschätzten mittleren Fehler von 0,01 mm auf.
- *Rauigkeit*: Die Klassifikation erreicht präzise Ergebnisse mit der Möglichkeit, fast alle außerhalb der Toleranz liegenden Bohrungen zu detektieren. Bei der Regression wird ein geschätzter mittlerer Fehler von 0,21 μm erreicht, was in etwa 13 % der Toleranzbreite entspricht.
- *Delaminations-Faktor*: Bei der Klassifikation werden nur $\approx 5\%$ der Bohrungen falsch eingeordnet, und mit einzelnen Modellen ist es möglich, jegliche außerhalb der Toleranz liegende Bohrungen zu ermitteln. Bei der Regression entsteht ein geschätzter mittlerer Fehler von $\approx 7\%$ der Toleranzbreite.
- *Faserüberstand-Faktor*: In Bezug auf alle Klassen ist die Einteilung ungenau. Jedoch sind einzelne Modelle in der Lage, jegliche außerhalb der Toleranz liegende Bohrungen zu detektieren, was zu Lasten vieler Falschalarne geht. Beim besten Regressions-Modell entsteht ein geschätzter mittlerer Fehler von $\approx 15\%$ der Toleranzbreite.
- *Delaminationsradius-Faktor*: Es wird eine fehlerfreie Klasseneinteilung und eine Vorhersage der kontinuierlichen Qualitätswerte mit einem geschätzten mittleren Fehler von etwa 20 % der Toleranzbreite erreicht.

Bei der Betrachtung der Modellierungs-Stufen wird bei den Validierungsmethoden von der Re-substitution abgeraten. Zur Feature-Vorbereitung wird bei der Klassifikation die Anwendung des Chi-Quadrat-Rankings und bei der Regression der Neighbourhood Component Analysis und des F-Test-Rankings empfohlen. Die Entscheidungsbaum-basierten ML-Algorithmen (Boosted Tree und Random Forest) setzen sich beim Gesamtergebnis bei der Klassifikation und Regression vom Rest ab. Die Objektivfunktionen haben keinen Einfluss auf die Ergebnisse. Bis auf eine Ausnahme (Faserüberstand-Faktor bei der Regression) bewirkt das Training auf einem künstlich erweiterten Datenset eine Steigerung der Vorhersagegüte von

Modellierungs-Pipelines, die bei dem realen Datensatz die beste Performance liefern.

Als Zusammenfassung kann gesagt werden, dass bei den meisten untersuchten Qualitäts-Kenngrößen die ML-basierte Überwachung brauchbare Ergebnisse liefert und diese durch eine künstliche Datenset-Erweiterung verbessert werden können.

Tabelle 10.1: Werkstückqualität: Zusammenfassung der Vorhersagegüten bester Modelle anhand einfacher Kennzahlen (Eintrag der maximalen klassenbezogenen Fehlerquote $L_{E,K}$ bei der überwachten Klassifikation sowie des Verhältnisses aus der Wurzel des mittleren quadratischen Fehlers $RMSE_E$ und der Toleranzbreite bei der überwachten Regression; Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor; Evaluationskennzahl: $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers)

Zielgrößen	max. klassenbezogene Fehlerquote $L_{E,K}$ bei überwachter Klassifikation	$RMSE_E$ bezogen auf die Toleranzbreite bei überwachter Regression
Q_{GE}	100 %	15 %
Q_{GA}	78 %	25 %
Q_D	16 %	20 %
Q_{Ra}	2,4 %	13 %
Q_{DF}	5,3 %	7 %
Q_{FF}	35 %	15 %
Q_{DR}	0 %	20 %

11 Werkzeugverschleiß-Überwachung

In diesem Kapitel werden die Potentiale beim Einsatz der ML-basierten überwachten Klassifikation und Regression zur Überwachung des Werkzeugverschleißes untersucht. Es werden die Verschleißkenngrößen *maximale Verschleißmarkenbreite*, *Ausbruchsfläche an der Freifläche*, *Hauptschneiden-Abflachung*, *Querschneide-Abflachung* und *Hauptschneiden-Volumen* in Klassen eingeteilt und als kontinuierliche Werte vorhergesagt. Wie im Kapitel 10 geschehen, erfolgt die Ergebnisvorstellung der Klassifikation und Regression parallel, da diese überwachten ML-Verfahren strukturell eine im Großteil ähnliche Teilschritt-Abfolge aufweisen. Zuerst erfolgt die Resultat-Vorstellung der Modellierung basierend auf dem realen Datensatz mit einer zielgrößenbezogenen und zielgrößenübergreifenden Auswertung sowie einer Analyse der Modellierungsstufen. Im Anschluss wird der Einfluss der künstlichen Datenset-Erweiterung erläutert. Am Kapitelende erfolgt eine Anwendungsempfehlung. In dieses Kapitel sind teilweise Erkenntnisse der vom Autor dieser Dissertation betreuten Masterarbeit von JUNGHANS [Jun22b] sowie der Bachelorarbeit von VOLKMANN [Vol22], die z. T. in [JRH23] veröffentlicht wurden, eingeflossen.

11.1 Überwachte Klassifikation und Regression

In diesem Kapitel wird anfangs die Feature-Vorbereitung inklusive der Sensorrelevanz analysiert. Anschließend werden die finalen Modelle in ihrer Vorhersagegüte hinsichtlich der einzelnen Zielgrößen sowie über die Zielgrößen hinweg bewertet. Zum Abschluss erfolgt die Diskussion der einzelnen Methoden innerhalb jeder der 4 Modellierungsstufen (Validierungsmethode, Feature-Vorbereitung, ML-Algorithmus und Objektivfunktion). Bei den Ergebnissen der überwachten Klassifikation wird zudem die Bewertung der Überanpassung vorgestellt. Die Zusatzangabe „überwacht“ wird durchgängig beibehalten, um die ML-Verfahrensgruppe zu verdeutlichen.

11.1.1 Ergebnisse der Feature-Vorbereitung und Sensorrelevanz

Die Abbildung 11.1 stellt die Ergebnisse der Datenreduktion in Abhängigkeit der verwendeten Methoden für die überwachte Klassifikation und Regression dar. Bei der Klassifikation wird durchschnittlich die höchste Datenreduktion mit der Neighbourhood Component Analysis NCA_F und bei der Regression mit der Principal Component Analysis PCA_F erreicht. In beiden Fällen wird für den Großteil der Zielgrößen die finale Feature-Anzahl von 100 unterschritten. Zudem liegen bei der Regression die Ergebnisse der Feature-Vorbereitungsmethoden enger beieinander. Zwischen den Zielgrößen lässt sich kein systematischer Unterschied bei der finalen Feature-Anzahl erkennen. Auffällig ist, dass beim Werkzeugverschleiß durchschnittlich höhere Reduktionsraten als bei der Prozesszustand- und Werkstückqualität-Vorhersage erreicht werden (siehe Abschnitt 9.2.1 und 10.1.1).




Abbildung 11.1: Werkzeugverschleiß: Feature-Vorbereitung (Die Balken stellen den Mittelwert der Feature-Anzahl über die 4 permutierten Datensätze des verbundenen Trainings- und Validierungs-Sets dar; V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen, Chi2_F = Chi-Quadrat-Ranking, NCA_F = Neighbourhood Component Analysis, PCA_F = Principal Component Analysis, Rlf_F = Relief-Algorithmus, FT_F = F-Test-Ranking)

In der Abbildung 11.2 werden die Signifikanzen der einzelnen Ausprägungen der Feature-Extraktionspfade für die Klassifikation dargestellt. Für die Regressionsanalyse ist eine analoge Darstellung in der Abbildung A.23 im Anhang A.13.4 zu finden. Hierbei ist zu beachten, dass die Signifikanzen nur innerhalb jedes Diagramms vergleichbar sind. Für jeden Extraktionspfad werden die Erkenntnisse im Folgenden festgehalten:

- *Sensorgroße*: Bei der Verfahrensgruppe überwachte Klassifikation sind die Features aus dem Vorschubmotorstrom I_{VM} am relevantesten (siehe Abbildung 11.2). Mit den Erkenntnissen aus [HMR19] zum Zusammenhang zwischen dem Vorschubmotorstrom I_{VM} und der Vorschubkraft F_f bei der SmartADU kann hieraus die Abhängigkeit des Werkzeug-Verschleißzustands mit der Vorschubkraft F_f hergeleitet werden. Zunehmende Vorschubkräfte bei höherem Werkzeugverschleiß können ebenfalls empirisch aus den durchgeführten Versuchen und der allgemeinen Zerspanpraxis bestätigt werden.

In der Abbildung A.23 im Anhang A.13.4 ist eine auffällig hohe Signifikanz der Sensorgroße Distanz Werkstück d , welche die Werkstückbewegung repräsentiert, mit den die Schärfe der Schneide beschreibenden Kennzahlen Hauptschneiden-Abflachung V_{HA} , Querschneide-Abflachung V_{QA} und Hauptschneiden-Volumen V_{HV} bei der überwachten

Regression festzustellen.

- *Datenrepräsentation:* Es wird eine durchgängig höhere Wichtigkeit der Features aus gefilterten Sensordatenverläufen festgestellt. Dies wird besonders für die maximale Verschleißmarkenbreite V_{VB} deutlich. Eine mögliche Schlussfolgerung wäre, dass der Verschleißzustand nicht durch kurzzeitige Ereignisse, sondern kontinuierlich durch gesamte Sensordatenverläufe beschrieben werden kann.
- *Bohrphase:* Bei der Klassifikation werden die Features aus der Phase Bohrungseintritt Ph_E als weniger relevant eingestuft, wobei sich die Wichtigkeiten der restlichen Bohrungsphasen nicht signifikant unterscheiden. Bei der Regression heben sich die Phasen Gesamtbohrung Ph_g und Gesamtmessung Ph_M in ihrer Signifikanz ab. Hierbei wird die These aus der Beschreibung zur Datenrepräsentation, bei der die Gesamtbetrachtung der Sensordaten den Werkzeugzustand am genauesten wiedergibt, untermauert.

Zudem wird die Wichtigkeit der Features aus der Bohrphase Eintritt Ph_E (bei Klassifikation) und der Bohrphase Vollschnitt Ph_V in Bezug auf die Beschreibung der Querschneide-Abflachung V_{QA} deutlich. Dieses Analyseergebnis kann mit folgender Überlegung verknüpft werden: Die Querschneide tritt nur in den beiden genannten Bohrphasen in Kontakt mit dem Werkstoff.

- *Domäne:* Die Features der Spektral- und Bilddomäne sind am relevantesten.

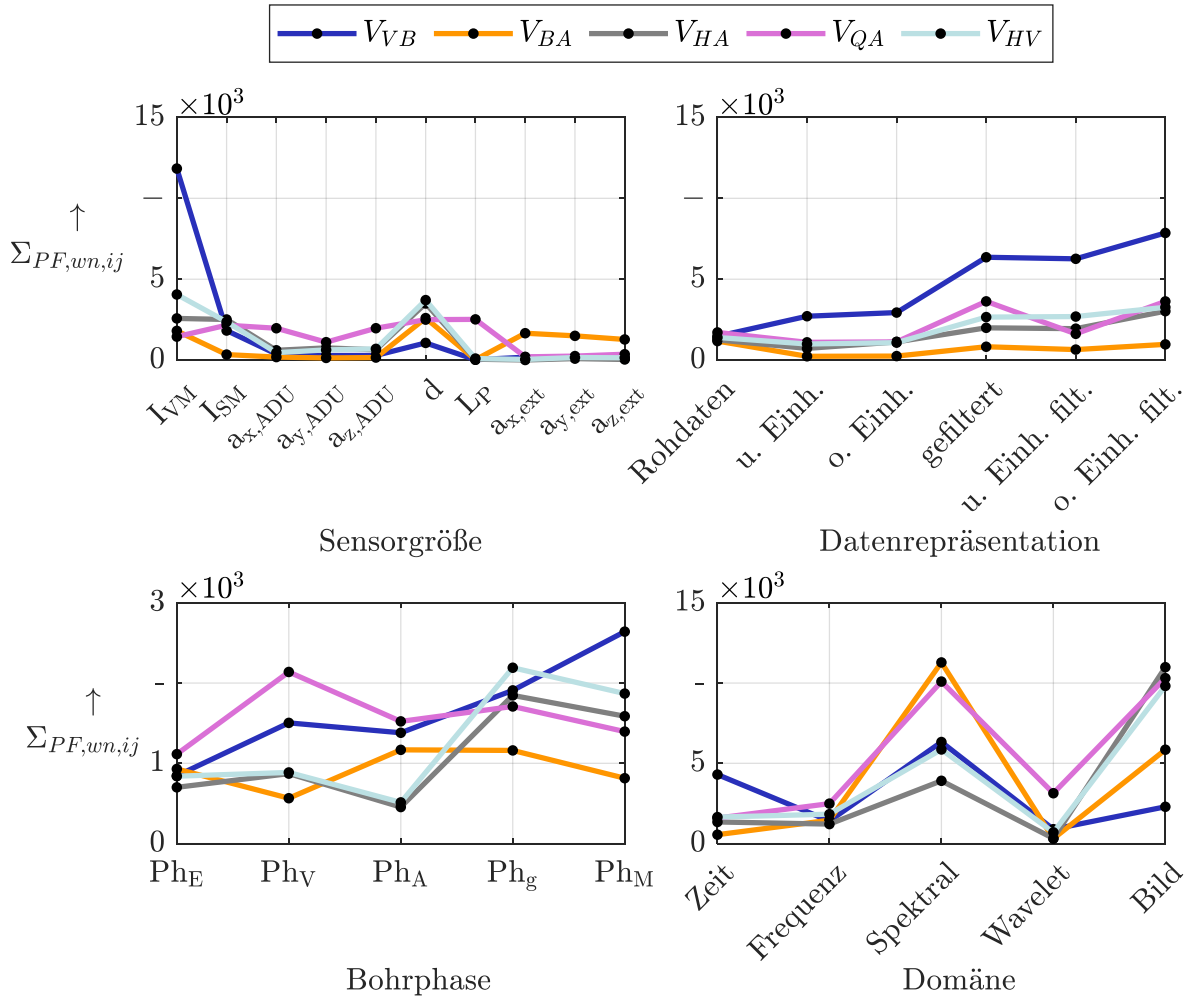


Abbildung 11.2: Werkzeugverschleiß: Feature-Signifikanz bei überwachter Klassifikation (V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchsfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen; $\Sigma_{PF,wn,ij}$ = gewichtete Summe der normierten Feature-Signifikanzwerte (nur innerhalb jedes einzelnen Diagramms vergleichbar), I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, d = Distanz Werkstück, L_P = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, u./o. Einh. = untere/obere Einhüllende, u./o. Einh. filt. = untere/obere Einhüllende gefiltert, Ph_E = Eintritt, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

11.1.2 Ranking der finalen Modelle

In kommenden Unterabschnitten werden die Modellierungs-Pipelines auf Ihre Eignung bezogen auf die einzelnen Zielgrößen sowie auf ihr generelles Verhalten über die Zielgrößen hinweg untersucht. Je nach Machbarkeit werden die Ergebnisse der Klassifikation und Regression in einzelnen oder gemeinsamen Diagrammen dargestellt, um Analogien zu erfassen.

11.1.2.1 Zielgrößenbezogene Auswertung

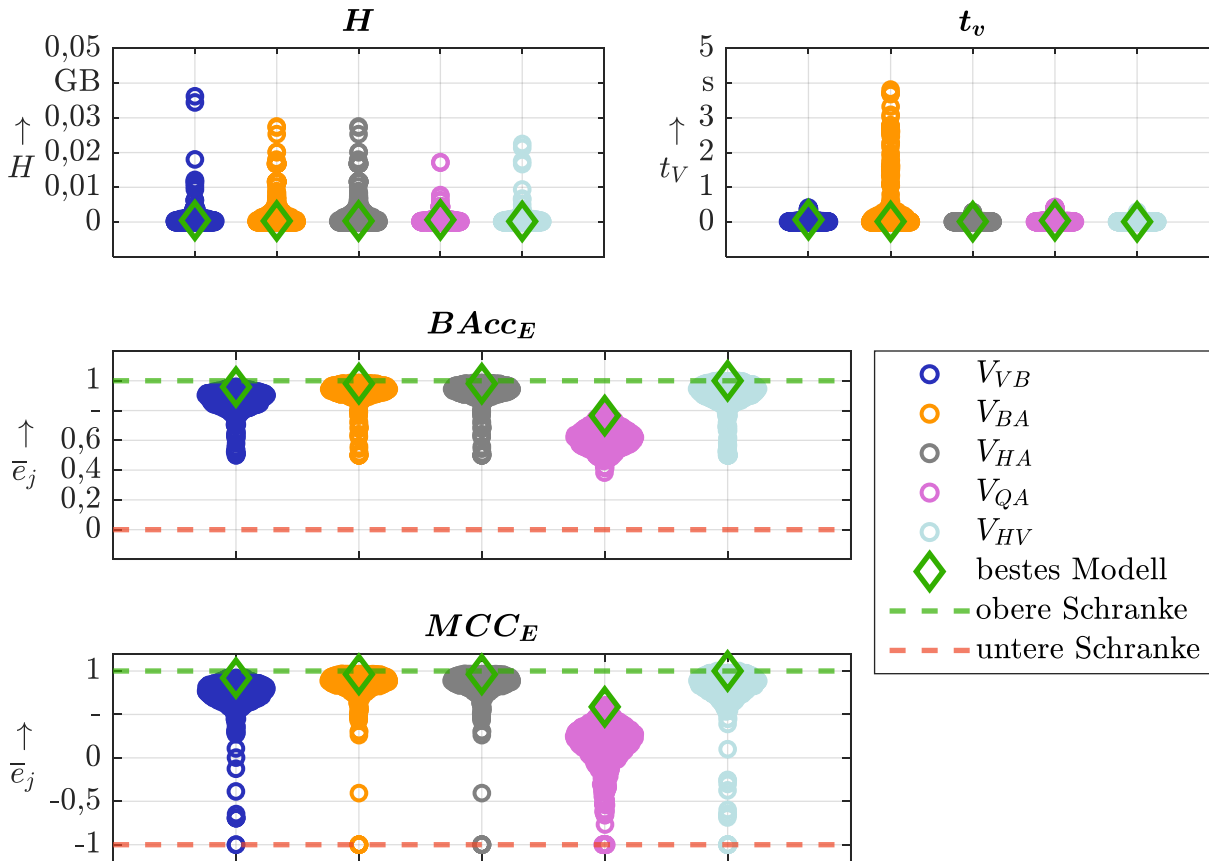
In diesem Abschnitt werden die Ergebnisse der Werkzeugverschleiß-Vorhersage parallel für die Verfahrensgruppen der überwachten Klassifikation und Regression analysiert. In den Abbildungen 11.3 und 11.4 sind ausgewählte Kennzahlen für die untersuchten Modellierungs-Pipelines in Form einer Häufigkeitsverteilung, die auf einem Kerndichteschätzer basiert (siehe dazu weitere Information im Abschnitt 8.3.2.1), vergleichend gegenübergestellt. Für die überwachte Klassifikation sind 720 und für die überwachte Regression 560 Modelle trainiert.

Die Speichergrößen H betragen für beide Verfahrensgruppen bis auf eine Ausnahme weniger als 100 MB. Die Mehrheit der Modellierungs-Pipelines ist wenige Megabyte groß. Die Regressionsmodelle benötigen im Schnitt das bis zu 5-fache an Speicherplatz, was aber bei den geringen Absolutwerten vernachlässigbar ist. Zwischen den Zielgrößen existieren keine nennenswerten Unterschiede.

Die Dauer der Vorhersage für beide Verfahrensgruppen liegt durchgängig bei $t_V < 4$ s, meist jedoch bei einem Bruchteil einer Sekunde. Innerhalb der Klassifikation ist es auffällig, dass für die Ausbruchfläche an der Freifläche V_{BA} eine im Vergleich zu anderen Zielgrößen durchschnittlich längere Vorhersagedauer vonnöten ist. In Bezug auf diese Zielgröße sei darauf hingewiesen, dass innerhalb dieser Arbeit mit der ML-basierten Modellierung nicht die prozessparallele Schneidstoff-Ausbruchdetektion verfolgt wird, sondern der Werkzeugzustand nach dem Abschluss des Bohrprozesses bewertet wird. Als Fazit steht jedoch, dass bei der Mehrheit der Modellierungs-Pipelines deren Anwendung zur Prozessüberwachung aufgrund der schnellen Vorhersage vorstellbar ist.

Als exemplarische Evaluationskennzahlen der Vorhersagegüte werden Balanced Accuracy $BACC_E$ und Matthews Correlation Coefficient MCC_E für die Klassifikation (Abbildung 11.3) sowie das Bestimmtheitsmaß R_E^2 und der Pearson-Korrelationskoeffizient $R_{XY,E}$ für die Regression (Abbildung 11.4) ausgewählt. Mit diesen Metriken wird der Vergleich der Modellperformance zwischen den Zielgrößen ermöglicht. Bei der Auswertung ergibt sich für beide Verfahrensgruppen das gleiche Bild. Die erstellten Klassifikationen sowie die numerischen Vorhersagen der Verschleißzustände maximale Verschleißmarkenbreite V_{VB} , Ausbruchfläche an der Freifläche V_{BA} , Hauptschneiden-Abflachung V_{HA} sowie Hauptschneidenvolumen V_{HV} stimmen laut den präsentierten Evaluationskennzahlen bei vielen Modellierungs-Pipelines bei einer guten bis sehr guten Genauigkeit mit den wahren Werten überein. Dabei weisen die Spitzenmodelle bei diesen Zielgrößen hohe Werte für die Evaluationskennzahlen, die im Bereich von $\bar{e}_j \approx 0,95$ liegen, auf. Die Mehrheit der restlichen Modelle erreicht Ergebnisse von $\bar{e}_j \geq 0,7$. Lediglich bei der Querschneide-Abflachung V_{QA} ist die Vorhersage ungenau, obwohl laut der Feature-Signifikanzanalyse in der Abbildung 11.2 relevante Features für diese Größe ermittelt sind.

Wie bereits in den Ausführungen zu der Werkstückqualität im Abschnitt 10.1.2.1 umgesetzt, erfolgt in den Tabellen A.42 und A.44 im Anhang A.13.4 die Charakterisierung der



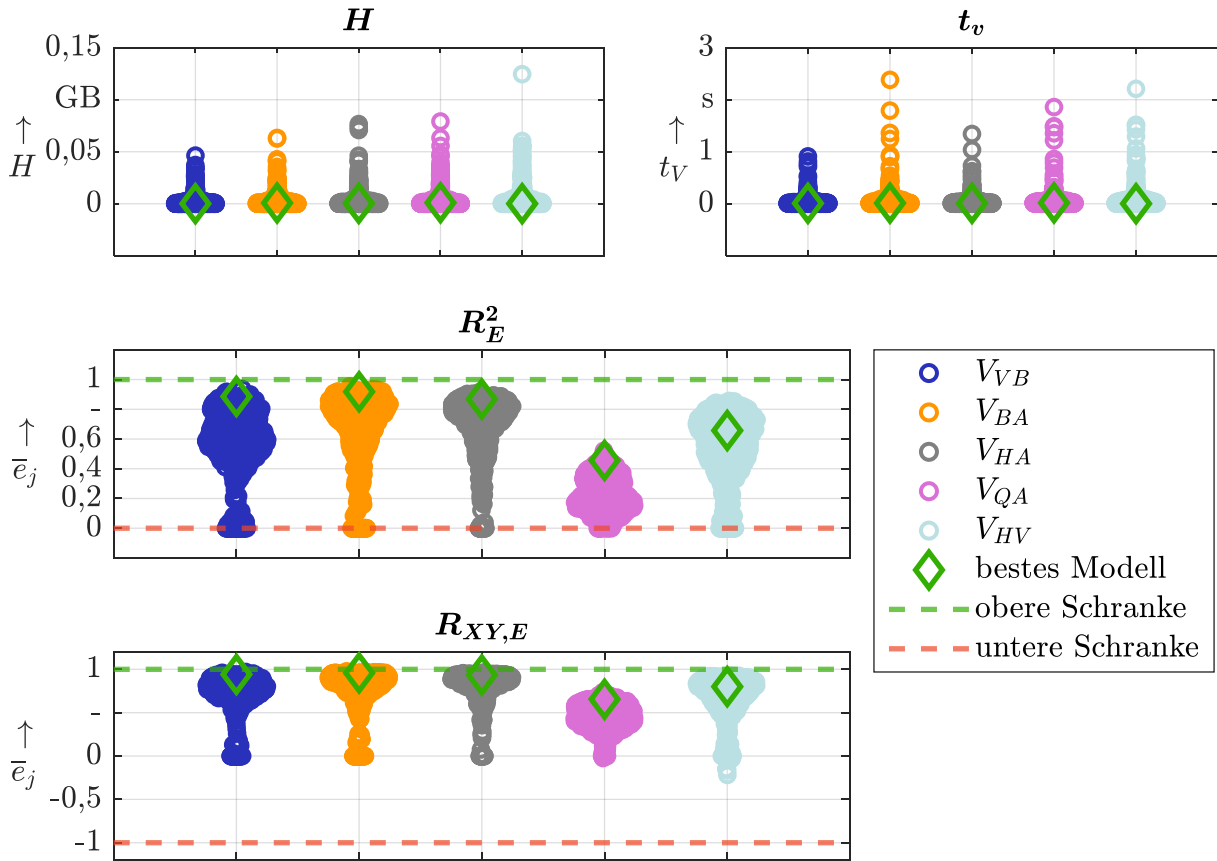
(Die x-Achse stellt bei jedem Graph die diskrete Repräsentation der Zielgrößen dar)

Abbildung 11.3: Werkzeugverschleiß: Modell-Performance bei überwachter Klassifikation (Mengendarstellung der wichtigsten Evaluations-Kennzahlen jeder Modellierungs-Pipeline, die an 4 Test-Sets ausgewertet ist; V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen, H = Modell-Speichergröße, t_V = Dauer der Vorhersage, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Datensätze, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

besten Klassifikations- und Regressionsmodelle sowie die Angabe dazugehöriger Evaluations-Kennzahlen für den Werkzeugverschleiß. Die dazugehörigen Ranking-Verfahren sind in den Abschnitten 6.3.4.1 und 6.3.4.2 referenziert. In der Tabelle A.43 im Anhang A.13.4 werden die Modelleigenschaften sowie exemplarische Evaluations-Kennzahlen für die 2-Klassen-Modellierungs-Pipelines, die zu der besten True Positive Rate TPR_E bei dem Test-Datensatz führen, im Rahmen der Werkzeugverschleiß-Vorhersage gelistet. Sollten die allgemein besten Modelle (siehe Tabelle A.42) bereits die beste True Positive Rate TPR_E aufweisen, werden sie nicht mehr in der Tabelle A.43 aufgeführt. Damit werden die Modellierungs-Pipelines identifiziert, die sich ausschließlich auf die Bestimmung außerhalb der Toleranz liegender Zielgrößen fokussieren. Im Folgenden wird die Gegenüberstellung von Vorhersage / wahren Wert anhand der Test-Datensätze mithilfe von Konfusionsmatrizen für die Klassifikation und von Streudiagrammen für die Regression in den Abbildungen 11.5 - 11.9 vorgenommen.

Maximale Verschleißmarkenbreite V_{VB}

Die Abbildung 11.5 zeugt von einer hohen Klassifikationsgüte, wobei das Modell mit der besten TPR_E nur einen außerhalb der Toleranz liegenden Verschleißzustand als fälschlicherweise



(Die x-Achse stellt bei jedem Graph die diskrete Repräsentation der Zielgrößen dar)

Abbildung 11.4: Werkzeugverschleiß: Modell-Performance bei überwachter Regression (Mengendarstellung der wichtigsten Evaluations-Kennzahlen jeder Modellierungs-Pipeline, die an 4 Test-Sets ausgewertet ist, V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchsfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen, H = Modell-Speichergroße, t_V = Dauer der Vorhersage, \bar{e}_j = durchschnittliche Evaluationskennzahl über 4 Datensätze, R_E^2 = Bestimmtheitsmaß, $R_{XY,E}$ = Pearson-Korrelationskoeffizient)

innerhalb der Toleranz liegend einordnet. Die Wurzel des mittleren quadratischen Fehlers beträgt $RMSE_E \approx 34 \mu\text{m}$ ($\approx 34\%$ der Toleranzbreite). Tendenziell werden geringe maximale Verschleißmarkenbreiten ungenauer als die größeren vorhergesagt.

Ausbruchsfläche an der Freifläche V_{BA}

Wie in Abbildung der 11.6 sichtbar, werden die Werkzeuge mit Ausbrüchen an den Freiflächen mit nur wenigen Ausnahmen erkannt. Anders sieht es bei der mäßig genauen Regression aus. Hierbei werden oftmals nicht vorhandene Ausbruchsflächen vorhergesagt.

Hauptschneiden-Abflachung V_{HA}

Die Erkennung der außerhalb der Toleranz liegender Hauptschneiden-Abflachung V_{HA} erfolgt ohne Fehler, und die Anzahl der „falschen Alarme“ ist sehr gering (siehe Abbildung 11.7). Die Wurzel des mittleren quadratischen Fehlers beträgt $RMSE_E \approx 5,28 \mu\text{m}$ ($\approx 12,5\%$ der Toleranzbreite) und ist unabhängig von der Größe der wahren Werte. Im Vergleich zu der oftmals genutzten Kennzahl Verschleißmarkenbreite lässt sich die Hauptschneiden-Abflachung




Abbildung 11.5: Beste Modelle zur Vorhersage der maximalen Verschleißmarkenbreite V_{VB} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.42, A.43 und A.44 im Anhang A.13.4 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $V_{VB} = 100 \mu\text{m}$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

V_{HA} gemäß der vorliegenden Auswertung präziser modellieren, was die werkstoffübergreifende Eignung dieser Verschleißkenngröße unterstreicht.

Querschneide-Abflachung V_{QA}

Gemäß der Abbildung 11.8 weist das generell beste Klassifikationsmodell die innerhalb der Toleranz liegenden wahren Verschleißzustände größtenteils richtig zu, was jedoch nicht für die außerhalb der Vorgaben liegenden Zustände gilt. Die Modellierungs-Pipeline mit der besten TPR_E ordnet die außerhalb der Toleranz liegenden Zustände richtig zu, dies geschieht jedoch zu Lasten vieler „falschen Alarme“. Die beste Regressions-Modellierungs-Pipeline weist einen Wert von $RMSE_E \approx 1,62 \mu\text{m}$ für die Wurzel des mittleren quadratischen Fehlers auf.

Hauptschneiden-Volumen V_{HV}

In der Abbildung 11.9 ist sichtbar, dass das beste generelle Klassifikations-Modell eine fehlerlose Klasseneinteilung vorweist. Die beste Regressions-Modell erreicht einen Wert von $RMSE_E \approx 6 \cdot 10^{-4} \text{mm}^3$ ($\approx 6\%$ der Toleranzbreite) für die Wurzel des mittleren quadratischen Fehlers.

11.1.2.2 Zielgrößenübergreifende Auswertung

Die Mehrheit der Modellierungs-Pipelines hat eine geringe Abweichung untereinander gemäß dem Durchschnitt der Summe gewichteter Punktwerte \bar{m} über alle Zielgrößen des Werkzeugverschleißes hinweg. Dies gilt für die Klassifikation und Regression und ist ähnlich den Resultaten aus der Anomaliedetektion, Prozesszustand- und der Werkstückqualität-Überwachung. Die Aussage wird mit der Auswertung in der Abbildung A.24 im Anhang A.13.4 bestätigt. Für die Zielgrößen des Werkzeugverschleißes ist daher ein Großteil der erstellten Modelle für das Monitoring anwendbar.




Abbildung 11.6: Beste Modelle zur Vorhersage der Ausbruchsfläche V_{BA} an der Freifläche mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.42, A.43 und A.44 im Anhang A.13.4 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $V_{BA} = 0 \text{ mm}^2$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 11.7: Beste Modelle zur Vorhersage der Hauptschneiden-Abflachung V_{HA} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.42, A.43 und A.44 im Anhang A.13.4 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $V_{HA} = 40 \mu\text{m}$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 11.8: Beste Modelle zur Vorhersage der Querschneide-Abflachung V_{QA} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.42, A.43 und A.44 im Anhang A.13.4 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $V_{QA} = 5 \mu\text{m}$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)




Abbildung 11.9: Beste Modelle zur Vorhersage des Hauptschneiden-Volumens V_{HV} mit der überwachten Klassifikation und Regression, ausgewertet an 4 vorhandenen Test-Sets (die dazugehörigen Modellierungs-Pipelines sind in den Tabellen A.42, A.43 und A.44 im Anhang A.13.4 verzeichnet; TPR_E = True Positive Rate; die Klassengrenze liegt bei $V_{HV} = 0,01 \text{mm}^3$; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

11.1.3 Analyse der Modellierungsstufen und der Überanpassung

Die Analyse der Modellierungsstufen inklusive deren Überanpassung erfolgt in gleicher Weise wie bei dem analogen Abschnitt 10.1.3 der Werkstückqualität-Überwachung, weswegen zur näheren Erklärungen der Auswertemethode auf die darin aufgeführten Angaben verwiesen wird. Die technischen Grundlagen zur Überanpassung sind im Abschnitt 2.3.2.2 und die dazugehörige umgesetzte Vorgehensweise zu deren Analyse im Abschnitt 6.3.4 erklärt. In der Abbildung 11.10 werden die Ergebnisse für die Klassifikation aufgeführt. Die Resultate analoger Auswertung für die Regression sind der Abbildung A.25 im Anhang A.13.4 zu entnehmen. Folgende Schlussfolgerungen können aus den Darstellungen gezogen werden:

- *Validierungs-Methoden:* Wie bei der Werkstückqualität-Überwachung fällt die Resubstitution RS_V auch beim Werkzeug-Verschleiß unter den restlichen (untereinander gleichwertigen) Methoden bei der Gesamtbewertung und Überanpassung geringfügig während der Klassifikation ab. Bei der Regression sind die Methoden gleichwertig. Daher ist der Einsatz der rechenärmsten Hold-Out-Validierung HO_V zu empfehlen.
- *Feature-Vorbereitungsmethoden:* Bei der Klassifikation weisen die Neighbourhood Component Analysis NCA_F und das Chi-Quadrat-Ranking $Chi2_F$ durchschnittlich die beste Performance auf, wobei das letztere auch die geringste Überanpassung bietet. Bei der Regression setzt sich der Relieff-Algorithmus Rlf_F geringfügig von den restlichen Methoden ab.
- *ML-Algorithmen:* Im Rahmen der Klassifikation ist der Einsatz des künstlichen neuronalen Netzes ANN_{MK} durchschnittlich am vorteilhaftesten. Bei der Regression bieten die verwandten Algorithmen Entscheidungsbaum DT_{MR} , Boosted Tree BT_{MR} und Random Forest RF_{MR} im Durchschnitt untereinander eine ähnliche und den restlichen Methoden gegenüber überlegene Performance.
- *Objektivfunktionen:* Es ist kein Unterschied zwischen den Objektivfunktionen zu erkennen.

Auf Basis der präsentierten Ergebnisse kann der Schluss gezogen werden, dass sich die unterschiedlichen Methoden der Modellierungsstufen durchschnittlich bis auf wenige Ausnahmen in ihrer Performance wenig unterscheiden und die besten Verfahren sich nur geringfügig vom Rest absetzen. Diese Aussage deckt sich mit dem Informationsgehalt zur zielgrößenübergreifenden Performance-Auswertung in der Abbildung A.24 im Anhang A.13.4.

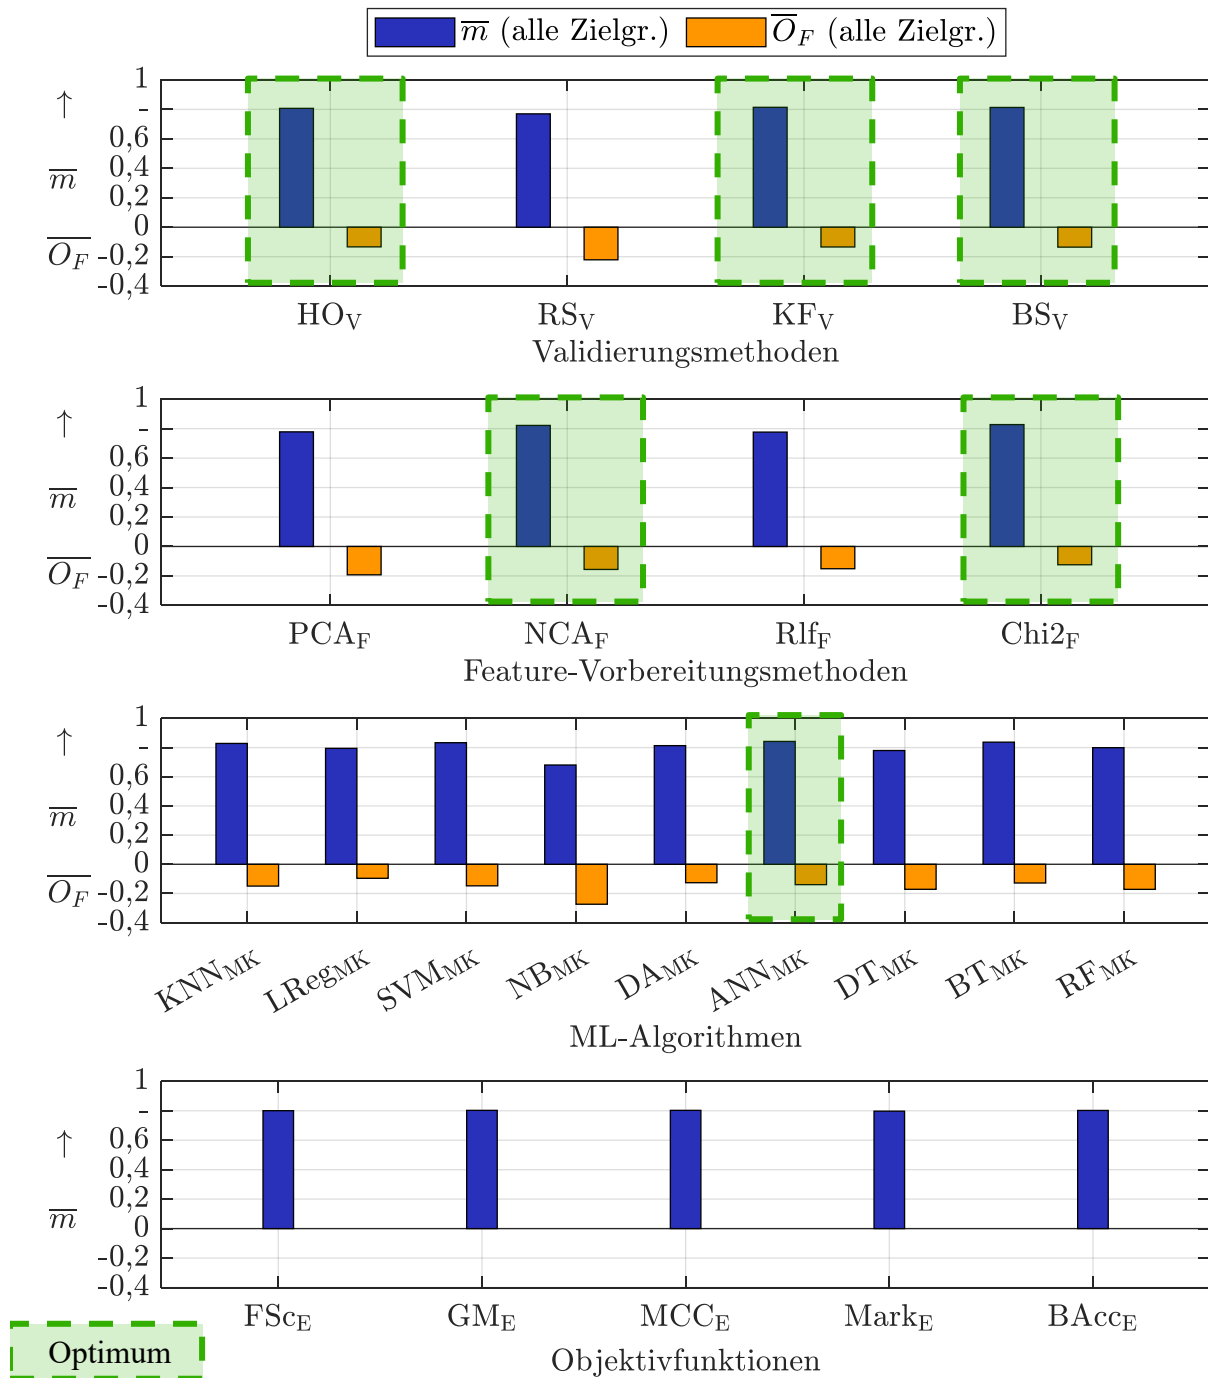


Abbildung 11.10: Werkzeugverschleiß: Modellierungsstufen und Überanpassung bei überwachter Klassifikation; die Markierung des Optimums jeder Modellierungsstufe erfolgt falls die beste(n) Option(en) ein um $\approx 0,01$ höheres \bar{m} als die zweitbeste vorweist (\bar{m} = Durchschnitt der Summe gewichteter Punktwerte für die vorliegende Methode einer Modellierungsstufe über aller Modellierungs-Pipelines hinweg, \bar{O}_F = über alle Modellierungs-Pipelines gemittelter Bewertungsfaktor für Überanpassung (siehe Abschnitt 6.3.1.3); zur Symbol-Kennzeichnung der Zielgrößen, Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie der Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.4 und die Anhänge A.1.3 und A.10.1 verwiesen)

11.2 Einfluss der Datensatzgröße

Der Einfluss eines künstlich erweiterten Datensatzes auf die Modellierungsgüte wird gemäß den Ausführungen im Abschnitt 6.4 untersucht. Die nähere Beschreibung mit den Einzelheiten der Evaluationsmethodik ist zudem in dem verwandten Abschnitt 10.2 zur Werkstückqualität-Überwachung zu finden.

Die Trainings- und Vorhersagezeiten t_M und t_V betragen zielgrößenabhängig maximal das 85-fache ihres Pendantes beim Modell-Training anhand des realen Datensatzes. Der maximale absolute Wert der Vorhersagezeit beträgt $t_V = 0,38\text{s}$ (Bei der Regression der Ausbruchfläche an der Freifläche V_{BA}).

Anhand der Abbildung 11.11 wird deutlich, dass sich die Vorhersagegüte jeglicher Zielgrößen bei der Klassifikation und Regression verbessert hat.

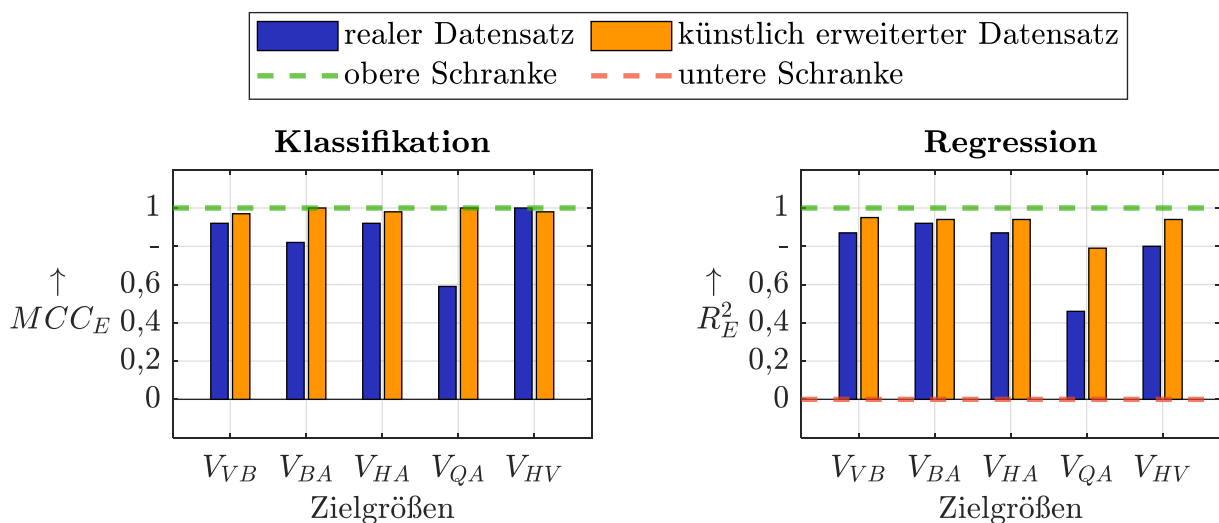


Abbildung 11.11: Werkzeugverschleiß: Einfluss der Datensatzgröße auf die Modellierungsgüte der überwachten Klassifikation und Regression bei künstlicher Erweiterung des Datensatzes (MCC_E = Matthews Correlation Coefficient, R_E^2 = Bestimmtheitsmaß, V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen)

11.3 Zusammenfassung und Bewertung

In den vorherigen Abschnitten wird die Eignung der ML-basierten Überwachung des Werkzeugverschleißes in Form von überwachter Klassifikation und Regression untersucht. Als Zielgrößen werden die maximale Verschleißmarkenbreite, die Ausbruchfläche an der Freifläche, die Hauptschneiden-Abflachung, die Querschneide-Abflachung sowie das Hauptschneiden-Volumen betrachtet. Im Falle der Klassifikation werden die Qualitäts-Kennwerte gemäß den Toleranzgrenzen in der Tabelle 6.13 in Klassen unterteilt und im Falle der Regression besteht das Ziel, die kontinuierlichen Qualitäts-Werte vorherzusagen. Dabei werden die Techniken der 4 Modellierungsstufen (Validierungs-Methode, Feature-Vorbereitung, ML-Algorithmus und Objektivfunktion) variiert. Für die Klassifikation ergeben sich 720 und für die Regression 560 Modellierungs-Pipelines.

Bei der Feature-Vorbereitung erfolgt die höchste Datenreduktion mittels der Neighbourhood Component Analysis bei der Klassifikation und der Principal Component Analysis bei der Regression. In beiden Fällen wird der Datensatz bei allen Modellierungen um mindestens 99,5 % reduziert. Bei beiden Verfahrensgruppen sind die Features aus dem Vorschubmotorstrom I_{VM} und der Werkstückdistanz d (als Repräsentation der Werkstückbewegung) am relevantesten. Innerhalb der Datenrepräsentation weisen die Features aus gefilterten Sensordaten-Verläufen die höchste Signifikanz auf. Es kann nur ein minimaler Einfluss der Bohrphasen auf die Feature-Signifikanz festgestellt werden. Analog den Erkenntnissen aus der Werkstückqualität-Überwachung sind die Features aus der Spektral- und Bilddomäne am relevantesten.

Grundsätzlich weisen die Modellierungs-Pipelines im Hinblick auf einzelne Zielgrößen mehrheitlich keinen fundamentalen Unterschied in der Modellierungsgüte untereinander auf. Dabei kann festgestellt werden, dass die meisten Modelle der Klassifikation und Regression eine Speichergröße von weniger als 100 MB aufweisen und für die Vorhersage weniger als 4 s benötigen. Beide Verfahrensgruppen bieten für die Zielgrößen maximale Verschleißmarkenbreite, Ausbruchsfläche an der Freifläche, Hauptschneiden-Abflachung und Hauptschneiden-Volumen. In den betrachteten vielfältigen Evaluations-Kennzahlen tendenziell genaue Vorhersagen in mindestens einer ML-Verfahrensgruppe. Lediglich bei der Abflachung der Querschneide wird eine minderwertige Vorhersagegüte erreicht. Nach der allgemeinen Betrachtung der Modellierungs-Qualität erfolgt im Sinne einer präziseren Bewertung die Analyse der besten Modelle für jede Zielgröße, deren Ergebnisse zusätzlich in der Tabelle 11.1 und im Folgenden anhand einfacher Kennzahlen deutlich zusammengefasst sind:

- *maximale Verschleißmarkenbreite*: Die Verschleißzustände werden bei einem balancierten Datensatz mit einer maximalen klassenbezogenen Fehlerquote von $\approx 9\%$ eingeordnet. Die Regressionsergebnisse sind bei dieser Zielgröße ungenau, da ein geschätzter mittlerer Fehler von $\approx 34\%$ der Toleranzbreite entsteht.
- *Ausbruchsfläche an der Freifläche*: Der Klassifikations-Fehler für jede Klasse beträgt maximal 3 %, weswegen von einer präzisen Einordnung gesprochen werden kann. Bei der Regression sind die Ergebnisse dagegen ungenau.
- *Hauptschneiden-Abflachung*: Die Klassifikationsergebnisse zeugen ebenfalls von einer hohen Genauigkeit (maximale Fehlerquote je Klasse $\approx 3\%$). Die Regression wird mit einem geschätzten mittleren Fehler von $\approx 12,5\%$ der Toleranzbreite umgesetzt. Dies ist bei dieser robust messbaren Kenngröße als eine tendenziell gute Genauigkeit, insbesondere im Vergleich zu der erreichten Vorhersagegüte der oftmals in der Wissenschaft und Industrie betrachteten Verschleißmarkenbreite, anzusehen.
- *Querschneide-Abflachung*: Die Ergebnisse sind bei der Klassifikation und Regression ungenau.
- *Hauptschneiden-Volumen*: Bei dieser Zielgröße werden präzise Vorhersagen ohne Klassifikationsfehler und mit einem geschätzten mittleren Fehler von $\approx 6\%$ der Toleranzbreite bei der Regression erreicht.

Bei der Betrachtung der Modellierungsstufen ergeben sich folgende Feststellungen, auch wenn der Unterschied zwischen den einzelnen Techniken teilweise sehr gering ausfällt. Als Validierungs-Methode ist die Resubstitution während der Hyperparameter-Optimierung nicht zu empfehlen. Im Rahmen der Feature-Vorbereitung eignen sich bei der Klassifikation am besten die Neighbourhood Component Analysis und das Chi-Quadrat-Ranking sowie bei

der Regression der Relieff-Algorithmus. Bei der Auswahl der ML-Algorithmen werden bei der Klassifikation das künstliche neuronale Netz sowie bei der Regression die untereinander verwandten Methoden Entscheidungsbaum, Boosted Tree und Random Forest empfohlen. Die Variation der Objektivfunktionen hat keinen Einfluss auf die Ergebnisse der Hyperparameter-Optimierung. Der Einsatz eines künstlich erweiterten Datensets steigert die Vorhersagegüte der besten Modelle mit Hyperparametern, die zuvor am realen Datensatz ermittelt wurden.

Zusammengefasst kann gesagt werden, dass bei 4 von 5 untersuchten Verschleißkenngrößen die ML-basierte Überwachung entweder mittels der Klassifikation oder Regression gute Ergebnisse liefert und diese durch eine künstliche Datenset-Erweiterung verbessert werden können.

Tabelle 11.1: Werkzeugverschleiß: Zusammenfassung der Vorhersagegüten bester Modelle anhand einfacher Kennzahlen (Eintrag der maximalen klassenbezogenen Fehlerquote $L_{E,K}$ bei der überwachten Klassifikation sowie des Verhältnisses aus der Wurzel des mittleren quadratischen Fehlers $RMSE_E$ und der Toleranzbreite bei der überwachten Regression; Zielgrößen: V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchsfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen)

Zielgrößen	max. klassenbezogene Fehlerquote $L_{E,K}$ bei überwachter Klassifikation	$RMSE_E$ bezogen auf die Toleranzbreite bei überwachter Regression
V_{VB}	9%	34%
V_{BA}	3%	Bezug nicht möglich, da Toleranzgrenze bei $V_{BA} = 0 \text{ mm}^2$
V_{HA}	3%	12,5%
V_{QA}	43%	32,4%
V_{HV}	0%	6%

12 Bewertung der Vorhersagegüten und industriebezogene Anwendungsempfehlung

12.1 Vorhersagegüte der Zielgrößen

In diesem Abschnitt erfolgt die Einordnung der erreichten Vorhersagegüten in Bezug zu den bekannten oder angenommenen industriellen Toleranzfeldern. Des Weiteren wird ein Vergleich zwischen den in dieser Arbeit erreichten Vorhersagegüten und den aus dem Stand der Technik (Kapitel 3) bekannten Ergebnissen gezogen.

12.1.1 Betrachtung der Zielgrößen-Vorhersagen im Kontext der industriellen Toleranzfelder

In diesem Abschnitt wird die Gesamteinschätzung zum Nutzwert des ML-basierten Monitorings der betrachteten Zielgrößen abgegeben. Dies geschieht unter folgenden Aspekten:

- Es erfolgt die Betrachtung der am genauesten arbeitenden Modellierungs-Pipelines aus den jeweiligen Kapiteln 8 - 11
- Zu den aus Kapiteln 8 - 11 ermittelten numerischen Evaluationskennzahlen wird die klassenbezogene maximale Fehlerquote je Zielgröße $L_{E,K}$ (siehe Erklärung im Abschnitt 9.4) für das unüberwachte Clustering, die unüberwachte Ausreißeridentifikation und die überwachte Klassifikation als eine zusammenfassende Evaluationskennzahl im Sinne einer allgemeinen Verständlichkeit zusätzlich betrachtet. Diese wird im Gegensatz zu der Analyse der normalen Fehlerquote über alle Klassen hinweg nicht von einem Datenset mit unausgewogenen Klassenanteilen in ihrer Sinnhaftigkeit verfälscht. Bei der überwachten Regression wird das Verhältnis aus der Wurzel des mittleren quadratischen Fehlers $RMSE_E$ und der Toleranzbreite als eine einfache Evaluations-Kennzahl zur Zusammenfassung gebildet. Es wird folgende Einordnung der beiden zusammenfassenden Evaluationskennzahlen in Gütestufen vorgenommen, die als eine Verschärfung des allgemeinen Standes der Technik (siehe Abschnitt 2.3) angesehen werden kann. Bei Evaluationskennwerten von $\geq 20\%$ wird die Anwendung als nicht geeignet bewertet. Bei Werten von $\leq 5\%$ wird sie dagegen als geeignet eingestuft. Die dazwischen liegenden Ergebnisse werden als bedingt geeignet betrachtet, da in diesem Falle die Tauglichkeit der entsprechenden Modellierungs-Pipelines als abhängig von unternehmensinternen und anwendungsbezogenen Leitlinien eingeschätzt wird.
- Nutzung der in dieser Arbeit verwendeten Toleranzgrenzen (siehe Tabellen 6.12 und 6.13) bei der Werkstückqualität- und Werkzeugverschleiß-Überwachung

Aus Gründen der Übersichtlichkeit erfolgt die finale Beurteilung in 2 Tabellen zu Methoden des unüberwachten (Tabelle 12.1) und des überwachten Lernens (Tabelle 12.2).

12.1.1.1 Anomaliedetektion

Die zur Anomaliedetektion eingesetzten unüberwachten ML-Methoden (Clustering und unüberwachte Ausreißeridentifikation) werden gemäß den Ergebnissen in vorherigen Kapiteln nicht für den industriellen Einsatz empfohlen, siehe dazu die Zusammenfassung in der Tabelle 12.1. Dies ist durch die unzureichende Qualität der dazugehörigen Evaluationskennzahlen begründet. In der Tabelle 12.2 werden überwachte ML-Methoden zur ausschließlichen Anomaliedetektion ebenfalls als ungeeignet eingestuft. Gemäß den Ergebnissen im Abschnitt 9.2.2.1 muss hinzugefügt werden, dass eine Anomaliedetektion, die in der Vorschub-Überwachung integriert ist, Ergebnisse mit mindestens genauso guter Vorhersagegüte wie bei der ausschließlichen Anomaliedetektion erreicht. Somit ist mit den besten Methoden dieser Arbeit eine Erkennungsquote bei den Anomalien von $\approx 70\%$ erreicht (siehe vgl. Abschnitt 9.2.2.1), was nicht den industriellen Anforderungen entspricht.

Tabelle 12.1: Fazit zu Vorhersagegüten mit unüberwachten ML-Verfahren (Zielgrößen der Anomaliezustände: keine Anomalie, doppelt, angebohrt, nicht durch, schräg; Zielgrößen Prozesszustände: W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, A_{PF} = Peck-Feed-Amplitude, L = Schmierungszustand, d_c = Aufspannweite, c_{CC} = Kontaktzustand Maschine/Werkstück)

Zielgrößengruppe	Zielgröße	ML-Verfahrensgruppe	
		Clustering	unüberwachte Ausreißeridentifikation
Anomaliedetektion	Anomalie ja/nein	nicht geeignet	nicht geeignet
	Anomaliezustände	nicht geeignet	nicht anwendbar
Prozesszustand-Überwachung	$W, n, f, A_{PF}, L, d_c, c_{CC}$	nicht geeignet	nicht anwendbar

12.1.1.2 Prozesszustand-Überwachung

Die überwachte Klassifikation des Prozesszustandes bietet mit der Ausnahme der Aufspannweite gute Klassifikationsergebnisse und wird daher für den Industrieinsatz empfohlen, siehe Tabelle 12.2. Unüberwachtes Clustering eignet sich nicht zum Monitoring des Prozesszustandes, siehe Tabelle 12.1.

12.1.1.3 Werkstückqualität-Überwachung

Im Rahmen der Werkstückqualität-Überwachung werden die Vorhersagegüten für den Bohrungsdurchmesser Q_D , die Rauigkeit der Bohrungswand Q_{Ra} , den Delaminations-Faktor Q_{DF} sowie den Delaminationsradius-Faktor Q_{DR} mithilfe der überwachten Klassifikation oder Regression als geeignet oder bedingt geeignet eingestuft. Beim Eintritts-Grat Q_{GE} und

dem Faserüberstand-Faktor Q_{FF} wird eine bedingt geeignete Vorhersagegüte nur bei der Regression erreicht. Für den Austritts-Grat Q_{GA} , der bei Nietbohrungen von erheblicher Bedeutung ist, kann nicht von einer Eignung der ML-basierten Überwachung gesprochen werden, siehe Tabelle 12.2. Deutlich wird dabei die tendenziell präzisere Überwachung der Qualitätskennzahlen der CFK-Werkstoffe im Vergleich zu den metallischen Werkstoffen.

12.1.1.4 Werkzeugverschleiß-Überwachung

Die Bestimmung des Werkzeugverschleißes ist bei den Zielgrößen Ausbruchsfläche an der Hauptschneiden-Freifläche V_{BA} , Hauptschneiden-Abflachung V_{HA} sowie Hauptschneiden-Volumen V_{HV} vor allem mittels überwachter Klassifikation potentiell mit einer hohen Vorhersagegüte möglich. Die Vorhersage der maximalen Verschleißmarkenbreite V_{VB} könnte in Abhängigkeit anwendungs- oder unternehmensspezifischer Vorgaben innerhalb der Klassifikation ebenfalls genutzt werden. Die Querschneide-Abflachung V_{QA} kann mit den entwickelten Modellierungs-Pipelines nicht präzise überwacht werden, siehe Tabelle 12.2.

Als Ergebnis wird hiermit festgehalten, dass die Mehrheit der Zielgrößen aus dem Prozesszustand- und Werkzeugverschleißmonitoring mit den entwickelten ML-Methoden überwacht werden kann, siehe Tabelle 12.2. Dies ist in Bezug auf die Automatisierung des Prüfaufwands und die Werkzeugstandzeit-Ausnutzung industriell wertvoll. Bei der Werkstückqualität ist das Potential zwar geringer, jedoch immer noch bei der Mehrheit der Zielgrößen vorhanden. Eine mögliche Absicherung der Regressions-Ergebnisse in einer Industrieumgebung ist durch die Betrachtung der Vorhersagen im Zusammenhang mit den bekannten möglichen Fehlerbereichen möglich. Es kann ein *Schutzband* zur Erhöhung der Ergebnis-Konfidenz definiert werden, indem zu dem ermittelten numerischen Kennwert einer Zielgröße der bekannte mittlere Fehler des ML-Regressionsmodells in Richtung der Toleranzgrenze hinzugerechnet oder abgezogen wird. Damit entsteht eine konservative, abgesicherte Bewertung des Regressions-Ergebnisses. Die ML-basierte Anomaliedetektion ist nicht mit den getesteten Modellierungs-Pipelines anforderungsgerecht einsetzbar.

Tabelle 12.2: Fazit zu Vorhersagegüten mit überwachten ML-Verfahren (Zielgrößen der Anomaliezustände: keine Anomalie, doppelt, angebohrt, nicht durch, schräg; Zielgrößen Prozesszustände: W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, A_{PF} = Peck-Feed-Amplitude, L = Schmierungszustand, d_c = Aufspannweite, c_{CC} = Kontaktzustand Maschine/Werkstück; Zielgrößen Werkstückqualität-Überwachung: Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert an der Bohrungswand, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor; Zielgrößen Werkzeugverschleiß-Überwachung: V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen)

Zielgrößengruppe	Zielgröße	ML-Verfahrensgruppe	
		überwachte Klassifikation	überwachte Regression
Anomaliedetektion	Anomalie ja/nein	nicht geeignet	nicht anwendbar
	Anomaliezustände	nicht geeignet	nicht anwendbar
Prozesszustand	$W, n, f, A_{PF}, L, c_{CC}$	geeignet	nicht anwendbar
	d_c	nicht geeignet	nicht anwendbar
Werkstückqualität	Q_{GE}, Q_{FF}	nicht geeignet	bedingt geeignet
	Q_{GA}	nicht geeignet	nicht geeignet
	Q_D, Q_{DF}	bedingt geeignet	bedingt geeignet
	Q_{Ra}, Q_{DR}	geeignet	bedingt geeignet
Werkzeugverschleiß	V_{VB}	bedingt geeignet	nicht geeignet
	V_{BA}	geeignet	Bezug nicht da
	V_{HA}, V_{HV}	geeignet	bedingt geeignet
	V_{QA}	nicht geeignet	nicht geeignet

12.1.2 Betrachtung der Zielgrößen-Vorhersagen im Kontext des Standes der Technik

Ein vollständiger Abgleich der in dieser Arbeit erreichten Vorhersagegüten mit dem Stand der Technik (Abschnitt 3.2) ist nicht möglich, da z. B. für das semi-automatische Bohren keine Vergleichswerte vorhanden sind oder die Skalen der Zielgrößen sich zwischen den hier gezeigten und im Stand der Technik extrahierten Ergebnissen unterscheiden. Von dieser Begebenheit wurde bereits zu Beginn dieser Arbeit aufgrund der vorhandenen Forschungslücke beim semi-automatischen Bohren ausgegangen. Nichtsdestotrotz wird in diesem Abschnitt der Versuch unternommen, möglichst ähnliche Szenarien aus der Literatur beim (meist automatischen) Bohren und restlichen Produktionsprozessen dem semi-automatischen Bohren aus dieser Arbeit gegenüberzustellen.

12.1.2.1 Anomaliedetektion

Gemäß den Tabellen 3.2 und 3.6 im Abschnitt 3.2.2.1 werden in der Literatur für die True Positive Rate TPR_E Werte im Intervall $[0,9; 1]$ erreicht. Diese werden auch in dieser Arbeit durch die trainierten Modelle bestätigt, siehe Abschnitt 8.2.2 zum Thema der unüberwachten Ausreißeridentifikation mit der Novelty Detection ($TPR_E = 0,98$) oder die Abbildung A.19 im Anhang A.13.1 zur überwachten Klassifikation ($TPR_E = 0,93$). Bei der Balanced Accuracy $BACC_E$ werden sogar bessere Kennwerte als im Stand der Technik erreicht ($BACC_E = 0,85$ in der Tabelle A.31 im Anhang A.13.1 gegenüber $BACC_E = 0,75$ in der Tabelle 3.2)

12.1.2.2 Prozesszustand

In der Recherche zum Stand der Technik (Kapitel 3) wird eine Spannbreite der maximalen klassenbezogenen Vorhersage-Fehlerquote $L_{E,K} = [0 \dots 0,97]$ bei unterschiedlichen Zielgrößen festgestellt (Tabellen 3.3 und 3.7; $L_{E,K}$ ist als der Maximalwert der Fehlerquote bei der Vorhersage jeder Klasse in der Konfusionsmatrix definiert). Die Resultate dieser Arbeit weisen bei fast allen Zielgrößen (Werkstoff W , Drehzahl n , Vorschub pro Werkzeugumdrehung f , Kontakt Maschine/Werkstück c_{CC} , Schmierungszustand L und Peck-Feed-Amplitude A_{PF}) eine Fehlerquote $L_E \leq 0,02$ auf. Lediglich bei der Aufspannweite d_c ist diese deutlich höher ($L_E = 0,36$). Daher kann meist von sehr guten Ergebnissen bei der Überwachung des Prozesszustands gesprochen werden.

12.1.2.3 Werkstückqualität

Gemäß den Tabellen 3.4 und 3.8 werden in der Literatur bei der Klassifikation von Schlecht- und Gutteilen Werte für die Fehlerquote in einem Intervall $L_E = [0,03; 0,17]$, für die True Positive Rate $TPR_E \approx 0,98$ und für den Matthews Correlation Coefficient $MCC_E \approx 1$ erreicht. Im Falle der Regression von Werkstück-Qualitätskennzahlen befinden sich Literaturergebnisse für das Bestimmtheitsmaß in einem Bereich $R_E^2 = [0,77; 0,92]$.

Die Klassifikations-Ergebnisse dieser Arbeit liefern bei den Qualitäts-Kenngrößen Höhe Eintrittsgrat Q_{GE} , Rauheit der Bohrungswand Q_{Ra} sowie Delaminationsradius-Faktor Q_{DR} ähnlich gute Vorhersagegüten bei den Kennzahlen TPR_E und MCC_E wie die besten Werte aus dem Stand der Technik (siehe Tabellen A.37, A.38 und A.39 im Anhang A.13.3). Bei der exakten Bestimmung der Werkstück-Qualitätswerte durch Regression weisen die Ergebnisse für die Rauheit an der Bohrungswand Q_{Ra} , den Delaminationsfaktor Q_{DF} und den Bohrungsdurchmesser Q_D genauso gute oder noch bessere Werte bei der Korrelation zwischen den wahren und vorhergesagten Qualitäts-Kenngrößen (Bereich für erreichtes Bestimmtheitsmaß: $R_E^2 = [0,82; 0,94]$, siehe Tabellen A.40 und A.41 im Anhang A.13.3) auf.

12.1.2.4 Werkzeugverschleiß

Beim Werkzeugverschleiß-Monitoring werden innerhalb bekannter Forschungsergebnisse bei der Klassifikation unterschiedliche Werte im Bereich der Fehlerquote $L_E = [0; 0,61]$ und des F-Score $FS_{CE} = [0,9; 1]$ erreicht. Mit der Regression ist ein Zusammenhang zwischen den wahren und vorhergesagten Werten mit dem Bestimmtheitsmaß im Bereich von $R_E^2 = [0,97; 1]$ dokumentiert, siehe Tabellen 3.5 und 3.9. Dabei muss gesagt werden, dass lt. Literatur größtenteils nur das Monitoring der Verschleißmarkenbreite untersucht ist. In dieser Arbeit wird

beim semi-automatischen Bohren innerhalb der Klassifikation die am F-Score gemessene Vorhersagegüte im Intervall von $FS_{CE} = [0,91; 1]$ bei den Zielgrößen maximale Verschleißmarkenbreite V_{VB} , Hauptschneiden-Abflachung V_{HA} , Ausbruchsfläche an der Freifläche V_{BA} und Hauptschneiden-Volumen V_{HV} erreicht. Innerhalb der Regression kann mit den präsentierten Untersuchungen für V_{VB} , V_{HA} und V_{BA} ein Bestimmtheitsmaß im Bereich von $R_E^2 = [0,87; 0,92]$ erzielt werden.

12.2 Feature-Extraktion

In diesem Abschnitt werden die Methoden und Bereiche zusammengefasst, die zur Extraktion relevantester Features führen. Das Ergebnis ist in der Tabelle 12.3 zu sehen. Die Feature-Signifikanzanalyse ist nur für die überwachten ML-Verfahrensgruppen möglich, da hierbei Zielgrößen als Vergleich zur Signifikanzbestimmung vorliegen, siehe Abschnitt 6.3.1.3. Es sei hierbei darauf hingewiesen, dass die als weniger relevant eingestuften Feature-Quellen trotzdem zur Bestimmung der Zielgrößen beitragen und auf diese nach Möglichkeit nicht verzichtet werden soll.

Als Ergebnis ist festzuhalten, dass der Vorschubmotorstrom die tendenziell wichtigste Sensorgröße ist. Gefilterte Zeitverläufe und die gefilterten Einhüllenden der Zeitverläufe bieten die Grundlage für die relevantesten Features. Der Einfluss der Bohrphase ist nur beim Einsatz der überwachten Regression im Zuge der Werkzeugverschleiß-Überwachung signifikant vorhanden. Über alle Zielgrößengruppen hinweg wird zudem deutlich, dass die wichtigsten Kennzahlen aus den abstrakten Spektral- und Bilddomänen ermittelt werden.

Tabelle 12.3: Fazit zur Feature-Extraktion mit überwachten ML-Verfahren (I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, d = Distanz Werkstück, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

Zielgrößengruppe	Feature-Extraktion	relevanteste Features je nach ML-Verfahrensgruppe	
		überwachte Klassifikation	überwachte Regression
Prozesszustand	Sensorgröße	alle	nicht anwendbar
	Repräsentation	Rohdaten der Zeitverläufe; gefilt. Zeitverläufe und Einhüllenden	nicht anwendbar
	Bohrphase	kein Unterschied	nicht anwendbar
	Domäne	Spektral, Bild	nicht anwendbar
Werkstückqualität	Sensorgröße	I_{VM}, I_{SM}	I_{VM}
	Repräsentation	– gefilterte Zeitverläufe und Einhüllenden –	
	Bohrphase	—— kein Unterschied ——	
	Domäne	—— Spektral, Bild ——	
Werkzeugverschleiß	Sensorgröße	—— I_{VM}, d ——	
	Repräsentation	– gefilterte Zeitverläufe und Einhüllenden –	
	Bohrphase	Ph_V, Ph_A, Ph_g, Ph_M	Ph_g, Ph_M
	Domäne	—— Spektral, Bild ——	

12.3 Methoden innerhalb der Modellierungsstufen

In diesem Abschnitt werden die durchschnittlich am präzisesten arbeitenden Methoden der Modellierungsstufen für die überwachten ML-Verfahrensgruppen zusammengestellt. Auf Ausführungen zu den unüberwachten Methoden wird hierbei verzichtet, da bei diesen keine Eignung zum Einsatz in der Produktion festgestellt wird (siehe Abschnitt 12.1.1).

Die zusammengefassten Ergebnisse lt. Tabelle 12.4 deuten darauf hin, dass als Validierungsmethode durchgängig die Hold-Out-Validierung zu empfehlen ist. Zur Feature-Vorbereitung werden zielgrößenabhängige Verfahren empfohlen. Als am besten arbeitende ML-Algorithmen werden größtenteils auf Entscheidungsbäumen basierte Methoden identifiziert. Die Variation der Objektivfunktionen während der Hyperparameter-Optimierung hat keinen relevanten Einfluss auf das Endergebnis.

Tabelle 12.4: Fazit zu Modellierungsstufen mit überwachten ML-Verfahren ($Chi2_F =$ Chi-Quadrat-Ranking, $NCA_F =$ Neighbourhood Component Analysis, $FT_F =$ F-Test-Ranking, $Rlf_F =$ Relief-Algorithmus, $RF_{MK}/RF_{MR} =$ Random Forest für Klassifikation/Regression, $BT_{MK}/BT_{MR} =$ Boosted Tree für Klassifikation/Regression, $DT_{MR} =$ Entscheidungsbaum für Regression, $ANN_{MK} =$ künstliches neuronales Netz für Klassifikation)

Zielgrößengruppe	Modellierungsstufe	empfohlene Methoden der Modellierungsstufen	
		überwachte Klassifikation	überwachte Regression
Prozesszustand	Validierungs-Methode	Hold-Out	nicht anwendbar
	Feature-Vorbereitung	NCA_F	nicht anwendbar
	ML-Algorithmus	RF_{MK}	nicht anwendbar
	Objektiv-Funktion	kein Unterschied	nicht anwendbar
Werkstückqualität	Validierungs-Methode	—— Hold-Out ——	
	Feature-Vorbereitung	$Chi2_F$	NCA_F, FT_F
	ML-Algorithmus	BT_{MK}	BT_{MR}, RF_{MR}
	Objektiv-Funktion	—— kein Unterschied ——	
Werkzeugverschleiß	Validierungs-Methode	—— Hold-Out ——	
	Feature-Vorbereitung	$Chi2_F, NCA_F$	Rlf_F
	ML-Algorithmus	ANN_{MK}	$BT_{MR}, RF_{MR}, DT_{MR}$
	Objektiv-Funktion	—— kein Unterschied ——	

12.4 Einsatz künstlicher Daten

Eine einheitliche Tendenz zum Effekt der Datenseterweiterung mit künstlichen Daten ist anhand der Ergebnisse nicht vorhanden.

13 Zusammenfassung, Limitation und Ausblick

13.1 Zusammenfassung

Das Ziel dieser Arbeit ist die Eignungsuntersuchung von Methoden des maschinellen Lernens für die Prozessüberwachung der semi-automatischen Herstellung von Durchgangsbohrungen mittels Vollbohren mit Wendelbohrern. Als Motivationsgrundlage dient die aktuelle Situation in der Luftfahrt-Industrie, in der die Produktionskapazitäten der zivilen Flugzeuge auf Jahre hinweg ausgelastet sind. Eine Ratensteigerung der Fertigung kann durch eine Freisetzung von Ressourcen mithilfe einer datenbasierten Prozess- und Ergebnisüberwachung erfolgen, da die freiwerdenden Kapazitäten zur Abarbeitung des Auftragsvolumens eingesetzt werden können. Als Grundlage der datenbasierten Überwachung dient die Sensorintegration und Vernetzung der Fertigungsmaschinen in Verbindung mit Methoden des *maschinellen Lernens* (ML), die in den letzten Jahren immens an Bedeutung gewonnen haben. Der größte Anteil an Fügestellen in der Luftfahrzeug-Strukturmontage wird mithilfe der Nietverbindungen realisiert, von denen in einem Langstrecken-Flugzeug eine Anzahl von mindestens 230.000 vorliegt und die eine hochgenaue Nietbohrung benötigen [Air15]. Damit ist das Potential einer großen Datenbasis für das Training von ML-Algorithmen gegeben. Da die semi-automatischen Bohrprozesse eine dominante Verfahrensvariante repräsentieren, wird damit das bereits erwähnte Forschungsziel begründet.

Als Forschungsziel soll die Eignung der ML-Methoden bei der *Anomaliedetektion*, *Prozesszustand*-, *Werkstückqualität*- und *Werkzeugverschleiß-Überwachung* semi-automatischer Bohrprozesse untersucht werden. Dabei sind die Vorhersagegüten der ML-Verfahrensgruppen *unüberwachtes Clustering*, *unüberwachte Ausreißeridentifikation*, *überwachte Klassifikation* sowie *überwachte Regression* zu analysieren. Die Ergebnisse sollen in Abhängigkeit der *Feature-Vorbereitung*, der *Validierungsmethode*, des *ML-Algorithmus* und der *Objektivfunktion* systematisch bewertet werden. Als weitere Einflussparameter sind dabei die *Feature-Extraktion* mit den eingesetzten Sensoren und ihrer *Extraktions-Domäne* sowie *künstlich erzeugte Trainingsdaten* zu betrachten.

Zur Erzeugung des notwendigen Datensatzes erfolgt die Herstellung von 1722 Durchgangsbohrungen mit 41 Prozessparametersätzen in Aluminium, Titan- und CFK-Werkstoffen mithilfe der elektrischen semi-automatischen Bohrvorschubeinheit SmartADU beim Einsatz von Wendelbohrern. Neben den aufgenommenen Sensordaten mittels interner SmartADU-Sensoren und externer Messfühler am adaptiven Prüfstand erfolgt ebenfalls eine Aufnahme der Zielgrößen, die in folgende Gruppen eingeteilt sind: *Anomaliezustand*, *Prozesszustand*, *Werkstückqualität* und *Werkzeugverschleiß*.

Mit den programmierten Modellierungs-Pipelines wird durch den Vergleich mit den in dieser Arbeit dargestellten wahren Zielgrößenverläufen die Eignung von ML-Methoden zur Anomaliedetektion, Prozesszustand-, Werkstückqualität- und Werkzeugverschleiß-Überwachung

untersucht. Die Ergebnisse werden mithilfe vielfältiger Kennzahlen bewertet. In Bezug auf die erreichte Vorhersagegüte der untersuchten ML-Modellierungspipelines werden die Resultate in einer zusammenfassenden Betrachtung nach eigener Abschätzung in geeignete, bedingt geeignete und ungeeignete Szenarien für die ML-basierte Überwachung eingeteilt.

Die trainierten ML-Modelle stellen sich zur Anomaliedetektion als ungeeignet heraus. Zur Überwachung der Werkstückqualität können zum Teil (d. h. in Abhängigkeit der Zielgrößen und der ML-Verfahrensgruppen) ML-Modelle mit bedingt geeigneter und geeigneter Vorhersagegüte aufgebaut werden. Bei dem Prozesszustand- und Werkzeugverschleiß-Monitoring können für die Mehrheit der Zielgrößen ML-Modelle mit geeigneter Vorhersagegüte trainiert werden. Grundsätzlich ist dabei ersichtlich, dass die überwachte Klassifikation die vorteilhafteste ML-Verfahrensgruppe ist. Mit den vorliegenden Ergebnissen wird eine Grundlage zur sensordatenbasierten Automatisierung des Prüfaufwands und zur effizienten Standzeitausnutzung des Werkzeugs gelegt.

13.2 Limitation

Beim Rückblick auf das gewählte wissenschaftliche Vorgehen werden limitierende Faktoren deutlich, die zur Reduktion der Qualität der trainierten Modelle geführt haben könnten. Die Abtastrate interner SmartADU-Sensoren von $f_{Hz} = 100$ Hz lässt vermuten, dass nicht alle relevanten Prozesseigenschaften erfasst werden. Des Weiteren ist als kritisch anzusehen, dass während der Versuche nicht bei jeder Prozessparameterkonfiguration ein identischer Sensoreinsatz erfolgte. Dies ist zum Teil den technischen Möglichkeiten, aber auch der Weiterentwicklung des Prüfstands geschuldet. Bei einer Versuchsdurchführung im Labor lässt sich zudem der Nachteil fehlender realer Industriebedingungen anmerken.

In dem Bereich des Modelltrainings wird im Nachhinein der unter Umständen fehlende Fokus auf intensiveren Einsatz neuronaler Netze kritisch gesehen. Diese Familie von ML-Algorithmen ist für ihre Vielseitigkeit und Performanz bekannt und gewann in letzten Jahren immer mehr an Bedeutung. Des Weiteren kann davon ausgegangen werden, dass eine präzisere Kenntnis der Toleranzwerte für die Werkstückqualität und den Werkzeugverschleiß eine noch realistischere Abschätzung der Modellperformanz innerhalb der Klassifikation geboten hätte.

13.3 Ausblick

Neben dem Umsetzen der bereits identifizierten Verbesserungsmöglichkeiten aus dem Abschnitt 13.2 werden für die Zukunft weitere Untersuchungen vorgeschlagen. Mit der Realisierung dieser Vorschläge wird eine Verbesserung der Vorhersagegüte ML-basierter Überwachungsmethoden beim Monitoring von semi-automatischen Bohrprozessen erwartet.

Es hat sich gezeigt, dass intern in der semi-automatischen Vorschubeinheit verbaute Sensoren eine höhere Signifikanz trotz der niedrigeren Abtastrate als extern applizierte Messaufnehmer aufweisen. Daher könnte die Untersuchung des Effekts der vollständigen mechanischen Integration externer Sensoren in die Maschine im Hinblick auf die Signifikanz der aufgenommenen Sensorgrößen vielversprechend sein. Zusätzlich ist die Eignungsuntersuchung weiterer Sensoren anzustreben, beispielsweise Temperatur-, Bild- oder Körperschall-Fühler. Bezogen auf den Industrieinsatz wird der Aufbau einer Datenbasis innerhalb der realen Fertigungsumgebung empfohlen. Damit ist automatisch von einer größeren Anzahl an Datenbeispielen

und breiter erfassten Prozessvariation auszugehen. Dabei ist auch eine Datenaufnahme mit unterschiedlichen Werkzeugen zum Ausbau der Datenbasis von Bedeutung. Zudem ist für die Validierung im Praxiseinsatz die Vernetzung der eingesetzten Fertigungsmaschinen in einem cyber-physischen System notwendig, um eine simultane Prozessüberwachung zu gewährleisten.

Beim Einsatz der ML-Algorithmen ist die Integration bekannter, physikalisch oder empirisch begründeter, analytischer Zusammenhänge zu untersuchen, was zur Wissenserweiterung der Modelle beiträgt. Des Weiteren können die Ergebnisse dieser Arbeit zur zielgerichteten Bildung von kombinierten ML-Modellen (= Ensemble Learning) aus unterschiedlichen Modellfamilien dienen. Die Eignungsuntersuchung von ML-Algorithmen mit automatisierter Feature-Extraktion beinhaltet das Potential einer vom Domänenwissen unabhängigen Informations-Entnahme aus den Sensordaten. Zudem könnte die Idee untersucht werden, bestärkendes Lernen zur Auswahl der optimalen Schnittparameter in Abhängigkeit des Werkzeugverschleißes vorzunehmen, um die Toleranzfelder der Werkstückqualität zu erfüllen.

Die vorgestellte systematische Untersuchungsmethodik ist außerdem beim automatischen und manuellen Bohren in der Luftfahrzeug-Strukturmontage einsetzbar.

Literaturverzeichnis

- [AA20] M. S. Alajmi und A. M. Almeshal. „Predicting the Tool Wear of a Drilling Process Using Novel Machine Learning XGBoost-SDA“. In: *Materials* 13.21 (2020). ISSN: 1996-1944.
- [Aam+20] M. Aamir, M. Tolouei-Rad, K. Giasin und A. Vafadar. „Machinability of Al2024, Al6061, and Al5083 alloys using multi-hole simultaneous drilling approach“. In: *Journal of Materials Research and Technology* 9.5 (2020), S. 10991–11002. ISSN: 2238-7854.
- [Abd+15] A. M. Abdelhafeez, S. L. Soo, D. K. Aspinwall, A. Dowson und D. Arnold. „Burr Formation and Hole Quality when Drilling Titanium and Aluminium Alloys“. In: *Procedia CIRP* 37 (2015), S. 230–235. ISSN: 2212-8271.
- [Ahm09] J. Ahmad. *Machining of Polymer Composites*. Boston, MA: Springer US, 2009. ISBN: 978-0-387-68619-6.
- [Air13] Airbus. „FAST (Flight Airworthiness Support Technology)—Special Edition A350XWB“. In: *Airbus Technical Magazine* (2013). ISSN: 1293-547.
- [Air15] Airbus. „Liefern, Steigern, Vorbereiten“. In: *One - Airbus news for Airbus people* (2015).
- [Air24] Airbus. *Global Market Forecast 2024*. 2024. URL: <https://www.airbus.com/en/products-services/commercial-aircraft/global-market-forecast> (besucht am 22.02.2025).
- [AIT25] Advanced Integration Technology (AIT). *Spirit A350 Flex Track Driller With Fastening Technology*. 2025. URL: https://www.aint.com/projects/drilling_projects/spirit_a350_flex_track_driller_with_fastening_technology (besucht am 01.02.2025).
- [AJ03] L. N. F. Ana und A. K. Jain. „Robust data clustering“. In: *2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Bd. 2. 2003, S. 128–133.
- [All18] E. Allibhai. *Hold-out vs. Cross-validation in Machine Learning*. 2018. URL: <https://medium.com/@eijaz/holdout-vs-cross-validation-in-machine-learning-7637112d3f8f> (besucht am 31.12.2021).
- [Alp14] E. Alpaydin. *Introduction to machine learning*. Third edition. Adaptive computation and machine learning. Cambridge, Massachusetts: The MIT Press, 2014. ISBN: 978-0-262-02818-9.
- [Ami+15] H. U. Amin, A. S. Malik, R. F. Ahmad, N. Badruddin, N. Kamel, M. Hussain und W.-T. Chooi. „Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques.“ In: *Australasian physical & engineering sciences in medicine* 38.1 (2015), S. 139–149. ISSN: 1879-5447.

- [AS10] J. V. Abellan-Nebot und F. R. Subiron. „A review of machining monitoring systems based on artificial intelligence process models“. In: *The international journal of advanced manufacturing technology*. 47.1-4 (2010). ISSN: 0268-3768.
- [Atl23] Atlas Copco. *Battery or pneumatic. Selecting the best manual drill for aerospace applications*. 2023. URL: <https://www.atlascopco.com/nl-be/itba/expert-hub/articles/battery-or-pneumatic-selecting-the-best-manual-drill-for-aerospace-applications> (besucht am 31.01.2025).
- [Atl25a] Atlas Copco. *Battery Drill – Pistol (EBB / EBP)*. 2025. URL: https://www.atlascopco.com/pt-ao/itba/products/drilling-solutions/handheld-drills/battery-drills/ebb26-battery-drill?filters=CategoryFilter%3DBattery%2520Drill%2520%25E2%2580%2593%2520Pistol%26productFilter%3Dfallback_searchquerydefinition%26category%3D21006%252F22103&page=1 (besucht am 31.01.2025).
- [Atl25b] Atlas Copco. *Drilling Solutions*. 2025. URL: <https://www.atlascopco.com/nl-be/itba/products/drilling-solutions> (besucht am 31.01.2025).
- [Att25] M. Attard. *Median Absolute Error*. 2025. URL: https://insidelearningmachines.com/median_absolute_error/ (besucht am 01.08.2025).
- [Aur+09] J.C. Aurich, D. Dornfeld, P.J. Arrazola, V. Franke, L. Leitz und S. Min. „Burrs—Analysis, control and removal“. In: *CIRP Annals* 58.2 (2009), S. 519–542. ISSN: 0007-8506.
- [AZB24] J. Joaquin, M. C. Zabaljauregui und F. L. Barrenechea. „A meta-learning strategy based on deep ensemble learning for tool condition monitoring of machining processes“. In: *Procedia CIRP* 126 (2024). 17th CIRP Conference on Intelligent Computation in Manufacturing Engineering (CIRP ICME ‘23), S. 429–434. ISSN: 2212-8271.
- [Bad+20] S. Badillo, B. Banfai, F. Birzele, I. I. Davydov, L. Hutchinson, T. Kam-Thong, J. Siebourg-Polster, B. Steiert und J. D. Zhang. „An Introduction to Machine Learning“. In: *Clinical pharmacology and therapeutics* 107.4 (2020), S. 871–885.
- [Bar10] A. M. Bartkowiak. „Anomaly, novelty, one-class classification: A short introduction“. In: *2010 International Conference on Computer Information Systems and Industrial Management Applications (CISIM)*. 2010, S. 1–6.
- [Bar11] D. Barina. „Gabor Wavelets in Image Processing“. In: *Proceedings of the 17th Conference STUDENT EEICT* 17 (2011). arXiv: 1602.03308 [cs.CV]. URL: <https://arxiv.org/abs/1602.03308> (besucht am 22.06.2025).
- [Bau20] C. Bauerdick. „Methodische Entwicklung einer in-Prozess Qualitätsüberwachung bei der Drehbearbeitung basierend auf maschineninternen Daten“. Dissertation. Technische Universität Darmstadt, 2020.
- [BDG08] A. Benammar, R. Draï und A. Guessoum. „Detection of delamination defects in CFRP materials using ultrasonic signal processing“. In: *Ultrasonics* 48.8 (2008), S. 731–738. ISSN: 0041-624X.
- [BDP21] M. Breque, L. De Nul und A. Petridis. *Industry 5.0 – Towards a sustainable, human-centric and resilient European industry*. Brüssel: Publications Office of the European Union, 2021. ISBN: 978-9-276-25308-2.

- [Ber17] H. Bernstein. *Messtechnik in der Praxis*. 1. Aufl. Berlin/Boston: De Gruyter, 2017. ISBN: 978-3-110-54442-8.
- [Ber19] D. Berrar. „Cross-Validation“. In: *Encyclopedia of Bioinformatics and Computational Biology*. Elsevier, 2019, S. 542–545. ISBN: 978-0-128-11432-2.
- [BH95] Y. Benjamini und Y. Hochberg. „Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing“. In: *Journal of the Royal Statistical Society. Series B (Methodological)* 57.1 (1995), S. 289–300. ISSN: 0035-9246.
- [BHB17] J. Bachmann, C. Hidalgo und S. Bricout. „Environmental analysis of innovative sustainable composites with potential use in aviation sector—A life cycle assessment review“. In: *Science China Technological Sciences* 60 (2017), S. 1301–1317.
- [BK17] F. Bleicher und C. Kumpf. „Schwingungsunterstützte Zerspanung“. In: *Spannende Fertigung*. Vulkan Verlag. 2017, S. 37–47.
- [Bla12] J. Blackburn. „Laser welding of metals for aerospace and other applications“. In: *Welding and Joining of Aerospace Materials*. Hrsg. von M.C. Chaturvedi. Woodhead Publishing Series in Welding and Other Joining Technologies. Woodhead Publishing, 2012, S. 75–108. ISBN: 978-1-845-69532-3.
- [Ble+18] F. Bleicher, G. Wiesinger, C. Kumpf, D. Finkeldei, C. Baumann und C. Lechner. „Vibration assisted drilling of CFRP/metal stacks at low frequencies and high amplitudes“. In: *Production Engineering* 12.2 (2018), S. 289–296. ISSN: 0944-6524.
- [BNN11] L. C. Brandão, F. O. Neves und G. C. Nocelli. „Evaluation of Hole Quality in Hardened Steel with High-Speed Drilling Using Different Cooling Systems“. In: *Advances in Mechanical Engineering* 3 (2011). ISSN: 1687-8132, 1687-8140.
- [Bol79] S. Boll. „Suppression of acoustic noise in speech using spectral subtraction“. In: *IEEE Transactions on Acoustics, Speech, and Signal Processing* 27.2 (1979), S. 113–120.
- [Boy+18] H. Boyes, B. Hallaq, J. Cunningham und T. Watson. „The industrial internet of things (IIoT): An analysis framework“. In: *Computers in Industry* 101 (2018), S. 1–12. ISSN: 0166-3615.
- [Bre+00] M. M. Breunig, H.-P. Kriegel, R. T. Ng und J. Sander. „LOF: identifying density-based local outliers“. In: *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*. SIGMOD '00. Dallas, Texas, USA: Association for Computing Machinery, 2000, S. 93–104.
- [Bre16] U. P. Breuer. „Commercial Aircraft Composite Technology“. In: Cham: Springer, 2016. ISBN: 978-3-319-31917-9. URL: <https://api.semanticscholar.org/CorpusID:113976937> (besucht am 01. 12. 2024).
- [Bro23] J. Brownlee. *A Tour of Machine Learning Algorithms*. 2023. URL: <https://machinelearningmastery.com/a-tour-of-machine-learning-algorithms/> (besucht am 04. 01. 2025).
- [BRS03] M. Bäker, J. Rösler und C. Siemers. „The influence of thermal conductivity on segmented chip formation“. In: *Computational Materials Science* 26 (2003). 11th International Workshop on Computational Mechanics of Materials, S. 175–182. ISSN: 0927-0256.

- [Bu+16] Y. Bu, W. H. Liao, W. Tian, J. X. Shen und J. Hu. „An analytical model for exit burrs in drilling of aluminum materials“. In: *The International Journal of Advanced Manufacturing Technology* 85.9 (2016), S. 2783–2796. ISSN: 0268-3768, 1433-3015.
- [Bus+23] L. Buss, L. Schumski, J. Sölter, K. Avila, B. Karpuschewski und U. Fritsching. „Minimum Quantity Lubrication (MQL) multiphase dynamics of a vibration-assisted drilling process“. In: *Procedia CIRP* 117 (2023). 19th CIRP Conference on Modeling of Machining Operations, S. 420–425. ISSN: 2212-8271.
- [Bus25] The Business Research Company. *AI in Manufacturing Market Definition*. 2025. URL: <https://www.thebusinessresearchcompany.com/report/ai-in-manufacturing-global-market-report> (besucht am 22.02.2025).
- [BW21] C. Brecher und M. Weck. *Mechatronische Systeme, Steuerungstechnik und Automatisierung*. 9. Aufl. Werkzeugmaschinen Fertigungssysteme. Wiesbaden: Springer Vieweg, 2021. ISBN: 978-3-662-46568-4.
- [Cav+21] W. L. Cavalcanti, K. Brune, M. Noeske, K. Tserpes, W. M. Ostachowicz und M. Schlag. *Adhesive Bonding of Aircraft Composite Structures: Non-destructive Testing and Quality Assurance Concepts*. Cham: Springer Nature, 2021. ISBN: 978-3-319-92809-8.
- [CB03] S. K. Choudhury und G. Bartarya. „Role of temperature and surface finish in predicting tool wear using neural network and design of experiments“. In: *International Journal of Machine Tools and Manufacture* 43.7 (2003), S. 747–753. ISSN: 0890-6955.
- [CBS24] G. Cavaliere, Y. Borgianni und E. Savio. „Performances of an in-line deep learning-based inspection system for surface defects of die-cast components for hybrid vehicles“. In: *Procedia CIRP* 126 (2024). 17th CIRP Conference on Intelligent Computation in Manufacturing Engineering (CIRP ICME '23), S. 999–1004. ISSN: 2212-8271.
- [CC19] J. C. Chen und W.-L. Chen. „A tool breakage detection system using an accelerometer sensor“. In: *Journal of Intelligent Manufacturing* 10 (1999), S. 187–197.
- [Cel14] Y. H. Çelik. „Investigating the Effects of Cutting Parameters on the Hole Quality in Drilling the Ti6Al4V Alloy“. In: *Materials and technology* 48.5 (2014), S. 653–659.
- [Che97] W.-C. Chen. „Some experimental investigations in the drilling of carbon fiber-reinforced plastic (CFRP) composite laminates“. In: *International Journal of Machine Tools and Manufacture* 37.8 (1997), S. 1097–1108. ISSN: 0890-6955.
- [Chu23] J. Chung. „Process Monitoring and Control of Advanced Manufacturing based on Physics-Assisted Machine Learning“. Dissertation. Virginia Polytechnic Institute und State University, 2023.
- [Cle79] W. S. Cleveland. „Robust Locally Weighted Regression and Smoothing Scatterplots“. In: *Journal of the American Statistical Association* 74.368 (1979), S. 829–836.
- [Coh60] J. Cohen. „A Coefficient of Agreement for Nominal Scales“. In: *Educational and Psychological Measurement* 20.1 (1960), S. 37–46.

- [Cor19] M. Cordes. „Modellierung von Bahngenauigkeit und dynamischer Stabilität beim robotergeführten Fräsen“. Dissertation. Technische Universität Hamburg, 2019.
- [CYO16] Y. H. Çelik, H. Yildiz und C. Özek. „Effect of cutting parameters on workpiece and tool properties during drilling of Ti-6Al-4V“. In: *Materials Testing* 58.6 (2016), S. 519–525.
- [DAB16] A. N. Dahnel, H. Ascroft und S. Barnes. „The Effect of Varying Cutting Speeds on Tool Wear During Conventional and Ultrasonic Assisted Drilling (UAD) of Carbon Fibre Composite (CFC) and Titanium Alloy Stacks“. In: *Procedia CIRP* 46 (2016). 7th HPC 2016 – CIRP Conference on High Performance Cutting, S. 420–423. ISSN: 2212-8271.
- [DBW19] B. Denkena, B. Bergmann und M. Witt. „Material identification based on machine-learning algorithms for hybrid workpieces during cylindrical operations“. In: *Journal of Intelligent Manufacturing* 30 (2019), S. 2449–2456.
- [DCA07] J. P. Davim, J. C. Rubio und A. M. Abrao. „A novel approach based on digital image analysis to evaluate the delamination factor after drilling composite laminates“. In: *Composites Science and Technology* 67.9 (2007), S. 1939–1945. ISSN: 0266-3538.
- [DD22] A. Vinoth und S. Datta. „Fundamentals of Machine Learning“. In: Hrsg. von S. Datta und J. P. Davim. *Management and Industrial Engineering*. Cham: Springer International Publishing, 2022. ISBN: 978-3-030-75846-2.
- [DD23] S. Dayam und K. A. Desai. „Development of a Smart Supervision System for Achieving Chatter-free Manual Drilling Operation“. In: *Procedia CIRP* 117 (2023). 19th CIRP Conference on Modeling of Machining Operations, S. 371–377. ISSN: 2212-8271.
- [Den+02] B. Denkena, T. Friemuth, S. Fedorenke und M. Groppe. „An der Schneide wird das Geld verdient-Neue Parameter zur Charakterisierung der Schneidengeometrien an Zerspanwerkzeugen“. In: *Sonderausgabe Werkzeuge* 12 (2002), S. 24–26.
- [Des25a] Desoutter. *Manuelle Akkulösungen*. 2025. URL: <https://www.desouttertools.com/de-de/products/series/manual-battery-solutions-32077#164685> (besucht am 31.01.2025).
- [Des25b] Desoutter. *Manuelles Druckluftbohren*. 2025. URL: <https://www.desouttertools.com/de-de/products/series/pneumatic-manual-drilling-320765> (besucht am 31.01.2025).
- [Des25c] Desoutter. *Unsere Lösungen für ausnahmslos korrektes Bohren beim ersten Anlauf*. 2025. URL: <https://www.desouttertools.com/de-de/solutions/to-drill> (besucht am 31.01.2025).
- [Des25d] Desoutter. *Druckluft Bohrvorschubeinheit ADU*. 2025. URL: <https://www.desouttertools.com/de-de/products/series/pneumatic-advanced-drilling-units-adu-32078> (besucht am 01.02.2025).
- [Die16] J. Dietrich. *Praxis der Zerspantechnik*. 12. Aufl. Wiesbaden: Springer Vieweg, 2016. ISBN: 978-3-658-14053-3.

- [Dob19] H. Dobbehaus. „Korrelation von maschinenintern aufgezeichneten Sensordaten mit Zerspankräften und Prozessgüte bei der semiautomatischen Fertigung von Nietbohrungen“. Bachelorarbeit. Technische Universität Hamburg, 2019.
- [Dom+22] C. Domínguez-Monferrer, J. Fernández-Pérez, R. De Santos, M. H. Miguélez und J. L. Cantero. „Machine learning approach in non-intrusive monitoring of tool wear evolution in massive CFRP automatic drilling processes in the aircraft industry“. In: *Journal of Manufacturing Systems* 65 (2022), S. 622–639. ISSN: 0278-6125.
- [Dos15] F. Dose. „Methode zur wissensbasierten Prozessentwicklung: Ein Ansatz für die Berücksichtigung sich wandelnder Teilsysteme beim Bohren von Schichtverbunden“. Dissertation. Technische Universität Hamburg, 2015.
- [DT11] B. Denkena und H. K. Tönshoff. *Spanen*. 3. Aufl. Heidelberg: Springer, 2011. ISBN: 978-3-642-19771-0.
- [DV90] P. Duhamel und M. Vetterli. „Fast fourier transforms: A tutorial review and a state of the art“. In: *Signal Processing* 19.4 (1990), S. 259–299. ISSN: 0165-1684.
- [EDW17] M. Eynian, K. Das und A. Wretland. „Effect of tool wear on quality in drilling of titanium alloy Ti6Al4V, Part I: Cutting Forces, Burr Formation, Surface Quality and Defects“. In: *High Speed Machining* 3.1 (), S. 1–10. ISSN: 2299-3975.
- [Eis19] S. Eiselin. *Airbus testet in Hamburg das Werk der Zukunft*. 2019. URL: <https://www.aerotelegraph.com/eroeffnung-hanga-245-automatisierung-airbus-testet-in-hamburg-das-werk-der-zukunft> (besucht am 01.02.2025).
- [EKR87] J.-P. Eckmann, S. Kamphorst und D. Ruelle. „Recurrence Plots of Dynamical Systems“. In: *Europhysics Letters (epl)* 4.9 (1987), S. 973–977.
- [EKT03] Y. M. Ertekin, Y. Kwon und T.-L. Tseng. „Identification of common sensory features for the control of CNC milling operations under varying cutting conditions“. In: *International Journal of Machine Tools and Manufacture* 43.9 (2003), S. 897–904. ISSN: 0890-6955.
- [Eng18] K. Engmann. *Technologie des Flugzeuges*. 7. Aufl. Würzburg: Vogel Buchverlag, 2018. ISBN: 978-3-834-33423-7.
- [Ert09] W. Ertel. „Maschinelles Lernen und Data Mining“. In: *Grundkurs Künstliche Intelligenz*. Vieweg+Teubner, 2009, S. 179–242. ISBN: 978-3-8348-9989-7.
- [EW21] A. Ernst und M. Weigold. „Machine Data-based Prediction of Blisk Geometry Characteristics“. In: *MM Science Journal* (Spezialausgabe zur High Speed Machining Conference) (2021), S. 5046–5051. ISSN: 1805-0476.
- [Far11] A. Faraz. „Experimental study on delamination, mechanical loads and tool wear in drilling of woven composite laminates.“ Dissertation. Technische Universität Dortmund, 2011.
- [Fay+96] U. M. Fayyad, G. Piatetsky-Shapiro, P. Smyth und R. Uthurusamy. *Advances in Knowledge Discovery and Data Mining*. Cambridge, Massachusetts: AAAI/MIT Press, 1996. ISBN: 978-0-2625-6097-9.

- [FD23] M. Flehmke und J. H. Dege. „Manuelles Bohren bei der Montage von Flugzeugstrukturen: neue Technologien und Herausforderungen im Fokus“. In: *Unter Span* (2023), S. 28–29.
- [FD24] M. Finio und A. Downie. *How is AI being used in manufacturing*. 2024. URL: <https://www.ibm.com/think/topics/ai-in-manufacturing> (besucht am 22.02.2025).
- [Fer+21] J. Fernández-Pérez, J. Díaz-Álvarez, M. H. Miguélez und J. L. Cantero. „Combined analysis of wear mechanisms and delamination in CFRP drilling“. In: *Composite Structures* 255 (2021). ISSN: 0263-8223.
- [Fer+21b] A. Fertig, L. Grau, M. Altmannsberger und M. Weigold. „Tool condition monitoring and tool defect detection for end mills based on high-frequency machine tool data“. In: *MM Science Journal* 2021 (2021), S. 5160–5166.
- [Fer23] A. J. Fertig. „Datenbasierte, prozessparallele Qualitätsprognose für spannend hergestellte Werkstücke mittels maschinellen Lernens“. Dissertation. Technische Universität Darmstadt, 2023.
- [FJJ24] M. Flehmke, S. Junghans, A. Jessen, G. Shchegel, C. Möller und J. H. Dege. „Improving Efficiency and Sustainability Through Predictive Tool Wear Monitoring During Manual Drilling of CFRP“. In: *Production at the Leading Edge of Technology*. Hrsg. von T. Bauernhansl, A. Verl, M. Liewald und H.-C. Möhring. Cham: Springer Nature Switzerland, 2024, S. 104–113. ISBN: 978-3-031-47394-4.
- [Fle+23] M. Flehmke, D. Romanenko, O. Rosenthal und J. H. Dege. „Klassifizierung von Prozesszuständen beim Bohren“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 118.5 (2023), S. 302–306.
- [Fle+24] M. Flehmke, M. Hinrichs, C. Möller und J. H. Dege. „Cutting Carbon Footprint With Smart Tool Management And Cemented Carbide (WC-Co) Upcycling“. In: *Proceedings of the CPSL 2024*. Hrsg. von D. Herberger und M. Hübner. 2024, S. 766–776.
- [FM83] E. B. Fowlkes und C. L. Mallows. „A Method for Comparing Two Hierarchical Clusterings“. In: *Journal of the American Statistical Association* 78.383 (1983), S. 553–569.
- [Fol+24] F. J. Folgado, D. Calderón, I. González und A. J. Calderón. „Review of Industry 4.0 from the Perspective of Automation and Supervision Systems: Definitions, Architectures and Recent Trends“. In: *Electronics* 13.4 (2024). ISSN: 2079-9292.
- [Fon+21] A. Fono, G. Thiele, M. Klein und J. Krüger. „Assistance Method for the Application-Driven Design of Machine Learning Algorithms“. In: *IOP Conference Series: Materials Science and Engineering* 1140.1 (2021).
- [Fra14] Fraunhofer-Institut für Werkstoff- und Strahltechnik IWS. *Neue Fügetechnologien für metallische Rumpfstrukturen*. 2014. URL: https://www.iws.fraunhofer.de/content/dam/iws/de/documents/publikationen/jahresberichtsbeitraege/JB_IWS_2014_de_S30-31.pdf (besucht am 25.01.2025).

- [Fra25] Fraunhofer-Institut für Fertigungstechnik und Angewandte Materialforschung IFAM. *Automatisierte Fertigungstechnologien und neue Bauweisen für einen thermoplastischen CFK-Flugzeugrumpf im Maßstab 1:1 für die nachhaltige Luftfahrt*. 2025. URL: <https://www.ifam.fraunhofer.de/de/technologien/endmontage-mffd.html> (besucht am 25.01.2025).
- [Fri18] A. H. Fritz. *Fertigungstechnik*. 12. Aufl. Wiesbaden: Springer Vieweg, 2018. ISBN: 978-3-662-56534-6.
- [FS24] M. Flehmke und S. Schibsdatt. „Smartes Bohren“. In: *CU Reports* 78.1 (2024). URL: <https://tore.tuhh.de/handle/11420/52998> (besucht am 12.03.2025).
- [Gao+24] R. X. Gao, J. Krüger, M. Merklein, H.-C. Möhring und J. Váncza. „Artificial Intelligence in manufacturing: State of the art, perspectives, and future directions“. In: *CIRP Annals* 73.2 (2024), S. 723–749. ISSN: 0007-8506.
- [GBC16] I. Goodfellow, Y. Bengio und A. Courville. *Deep Learning*. Cambridge, Massachusetts: MIT Press, 2016. ISBN: 978-0-2620-3561-3.
- [GBV20] M. Grandini, E. Bagli und E. Visani. *Metrics for Multi-Class Classification: an Overview*. 2020. URL: <https://arxiv.org/abs/2008.05756> (besucht am 20.01.2025).
- [GEM21] P. Georgi, S. Eschelbacher und H.-C. Moehring. „Utilization of machine learning approaches for tool wear detection and prediction in the circular sawing process of metallic materials“. In: *MM Science Journal* 2021 (2021), S. 5120–5125.
- [Gen+19] D. Geng, Y. Liu, Z. Shao, Z. Lu, J. Cai, X. Li, X. Jiang und D. Zhang. „Delamination formation, evaluation and suppression during drilling of composite laminates: A review“. In: *Composite Structures* 216 (2019), S. 168–186. ISSN: 0263-8223.
- [Ger22] N. Gerdes. „Qualitätssicherung in der additiven Metallfertigung durch hyperspektrale Bildgebung und maschinelles Lernen“. Dissertation. Gottfried Wilhelm Leibniz Universität Hannover, 2022.
- [Gia+16] K. Giasin, A. Hodzic, V. Phadnis und S. Ayvar-Soberanis. „Assessment of cutting forces and hole quality in drilling Al2024 aluminium alloy: experimental and finite element study“. In: *The International Journal of Advanced Manufacturing Technology* 87.5 (2016), S. 2041–2061. ISSN: 0268-3768, 1433-3015.
- [Glo19] A. Glowacz. „Fault Detection of Electric Impact Drills and Coffee Grinders Using Acoustic Signals“. In: *Sensors* 19.2 (2019). ISSN: 1424-8220.
- [GLS19] R. A. Gite, P. K. Loharkar und R. Shimpi. „Friction stir welding parameters and application: A review“. In: *Materials Today: Proceedings* 19 (2019). 1st International Conference on Manufacturing, Material Science and Engineering, S. 361–365. ISSN: 2214-7853.
- [Goe20] Goebel Fasteners Inc. *Why Are Airplanes Manufactured With Riveted Joints Instead of Welded?* 2020. URL: <https://www.goebelfasteners.com/why-are-airplanes-manufactured-with-riveted-joints-instead-of-welded/> (besucht am 26.01.2025).

- [Gol+04] J. Goldberger, G. E. Hinton, S. Roweis und R. R. Salakhutdinov. „Neighbourhood Components Analysis“. In: *Advances in Neural Information Processing Systems*. Hrsg. von L. Saul und L. Weiss Y. and Bottou. Bd. 17. MIT Press, 2004.
- [Gro19] M. Grootendorst. *Validating your Machine Learning Model: Going beyond k-Fold Cross-Validation*. 2019. URL: <https://towardsdatascience.com/validating-your-machine-learning-model-25b4c8643fb7> (besucht am 03.08.2024).
- [Gru08] H. Gruss. „Schweißgerechte Struktur- und Prozessstrategien im Flugzeugbau“. Dissertation. Otto-von-Guericke-Universität Magdeburg, 2008.
- [GS21] P. Gupta und N. K. Sehgal. *Introduction to machine learning in the cloud with Python: concepts and practices*. Cham: Springer, 2021. ISBN: 978-3-030-71270-9. URL: <https://bib-pubdb1.desy.de/record/461738> (besucht am 02.04.2024).
- [Guh+16] S. Guha, N. Mishra, G. Roy und O. Schrijvers. „Robust Random Cut Forest Based Anomaly Detection on Streams“. In: *Proceedings of The 33rd International Conference on Machine Learning*. Hrsg. von M. F. Balcan und K. Q. Weinberger. Bd. 48. Proceedings of Machine Learning Research. New York, New York, USA: PMLR, 2016, S. 2712–2721.
- [Guy+06] I. Guyon, S. Gunn, M. Nikravesh und L. A. Zadeh. *Feature Extraction: Foundations and Applications (Studies in Fuzziness and Soft Computing)*. 1. Aufl. Berlin, Heidelberg: Springer, 2006. ISBN: 978-3-540-35487-1.
- [Had+13] K. Haddad, A. Rahman, M. A Zaman und S. Shrestha. „Applicability of Monte Carlo cross validation technique for model development and validation using generalised least squares regression“. In: *Journal of Hydrology* 482 (2013), S. 119–128. ISSN: 0022-1694.
- [Hae+04] W. K. Härdle, M. Müller, S. Sperlich und A. Werwatz. *Nonparametric and Semiparametric Models*. 1. Aufl. Berlin, Heidelberg: Springer, 2006. ISBN: 978-3-642-62076-8.
- [Hae+16] A. Haeger, G. Schoen, F. Lissek, D. Meinhard, M. Kaufeld, G. Schneider, S. Schuhmacher und V. Knoblauch. „Non-destructive Detection of Drilling-induced Delamination in CFRP and its Effect on Mechanical Properties“. In: *Procedia Engineering* 149 (2016), S. 130–142.
- [Han+13] K. Hansen, G. Montavon, F. Biegler, S. Fazli, M. Rupp, M. Scheffler, O. A. von Lilienfeld, A. Tkatchenko und K.-R. Müller. „Assessment and Validation of Machine Learning Methods for Predicting Molecular Atomization Energies“. In: *Journal of chemical theory and computation* 9.8 (2013), S. 3404–3419. ISSN: 1549-9618.
- [Han+19] G. S. Handelman, H. K. Kok, R. V. Chandra, A. H. Razavi, S. Huang, M. Brooks, M. J. Lee und H. Asadi. „Peering Into the Black Box of Artificial Intelligence: Evaluation Metrics of Machine Learning Methods“. In: *AJR. American journal of roentgenology* 212.1 (2019), S. 38–43.
- [HCN05] X. He, D. Cai und P. Niyogi. „Laplacian score for feature selection“. In: NIPS’05. Vancouver, British Columbia, Canada: MIT Press, 2005, S. 507–514.

- [Hei14] U. Heisel, F. Klocke, E. Uhlmann und G. Spur. *Handbuch Spanen*. 2. Aufl. Edition Handbuch der Fertigungstechnik. München: Hanser, 2014. ISBN: 978-3-446-42826-3.
- [Hen15] M. Henerichs. „Bohrbearbeitung von CFK unter besonderer Berücksichtigung der Schneidkantenmikrogeometrie“. Dissertation. ETH Zürich, 2015.
- [Hes16] W. Hesse. *Aluminium-Werkstoff-Datenblätter : = Aluminium Material Data Sheets*. 7. Aufl. Beuth Wissen. Berlin, Wien, Zürich: Beuth Verlag, 2016.
- [HH13] W. Hintze und D. Hartmann. „Modeling of Delamination During Milling of Unidirectional CFRP“. In: *Procedia CIRP* 8 (2013). 14th CIRP Conference on Modeling of Machining Operations (CIRP CMMO), S. 444–449. ISSN: 2212-8271.
- [Hig00] A. Higgins. „Adhesive bonding of aircraft structures“. In: *International Journal of Adhesion and Adhesives* 20.5 (2000), S. 367–376. ISSN: 0143-7496.
- [Hin+04] W. Hintze, R. Clausen, M. Plucinski, E. Stöver und F. Meißner. *Bohrvorrichtung*. Patent. Anmelder: Airbus Deutschland GmbH. 2004. URL: <https://patentimages.storage.googleapis.com/11/e0/c7/2dab93199af8ef/DE10308089A1.pdf> (besucht am 27.01.2025).
- [Hin+07] W. Hintze, R. Clausen, D. Hartmann, J. Kindler, S. Santos und M. Schwerdt. „Precision of machined CFRP - The challenge of dimensional accuracy“. In: *Proceedings of the 1st International Workshop on Aircraft Systems Technologies (AST2007)* (2007), S. 361–374.
- [Hin+19a] W. Hintze, H. Loedding, A. Friedewald, J. P. Mehnen, D. Romanenko, C. Moeller, C. Brillinger und J. N. Sikorra. „Digital assistance systems for smart drilling units in aircraft structural assembly“. In: *International Workshop on Aircraft System Technologies* 7 (2019), S. 255–266.
- [Hin+19b] W. Hintze, H. Löedding, A. Friedewald, J. P. Mehnen, D. Romanenko und J. N. Sikorra. „Digitalisierte Bohrtechnologie für die Strukturmontage“. In: *Innovation Report* 6.1 (2019). CFK-Valley Stade e.V., S. 46–47.
- [Hin+21] W. Hintze, J. P. Mehnen, L. Koettner und D. Romanenko. „Halbautomatisches Bohren wird jetzt mit KI überwachbar: Bohrprozess im Griff“. In: *Maschinenmarkt* (2021). URL: <https://www.maschinenmarkt.vogel.de/halbautomatisches-bohren-wird-jetzt-mit-ki-ueberwachbar-a-1c7f146d9b68c3a7c99a388792ff64f2/> (besucht am 29.02.2024).
- [Hin+22] W. Hintze, D. Romanenko, L. Molquentin, L. Koettner und J. Mehnen. „Holistic process monitoring with machine learning classification methods using internal machine sensors for semi-automatic drilling“. In: *Procedia CIRP: Leading manufacturing systems transformation – Proceedings of the 55th CIRP Conference on Manufacturing Systems 2022* 107 (2022), S. 972–977.
- [Hin+23] D. Hinzmann, D. Hasselder, S. Lezama, O. Kirik, V. Pandey, E. Bosler, D. Spitta, E. Uhlmann, J. Krüger, V. Markl, D. Oberschmidt und M. Rötting. „Interaction of Artificial Intelligence and Machining Processes Regarding Industry 4.0 Production Systems“. In: *Production at the Leading Edge of Technology*. Hrsg. von T. Bauernhansl, A. Verl, M. Liewald und H.-C. Möhring. Cham: Springer Nature Switzerland, 2024, S. 54–63.

- [Hin13] W. Hintze. *Optimierungspotenziale für die CFK-Bearbeitung*. 2013. URL: <https://www.maschinenmarkt.vogel.de/optimierungspotenziale-fuer-die-cfk-bearbeitung-a-425074/?p=3> (besucht am 02.02.2025).
- [Hin21a] W. Hintze. *CFK-Bearbeitung*. 1. Aufl. Berlin, Heidelberg: Springer Vieweg, 2021. ISBN: 978-3-662-63264-2.
- [Hin21b] W. Hintze. „Vorlesung Umform- und Zerspantechnologie“. Technische Universität Hamburg, 2021.
- [HMA24] M. Hassan, A. Mohamed und H. Attia. „A Generalized Multi-Stage Deep Machine Learning Framework for Tool Wear Level Prediction in Milling Operations“. In: *Procedia CIRP* 126 (2024). 17th CIRP Conference on Intelligent Computation in Manufacturing Engineering (CIRP ICME '23), S. 441–446. ISSN: 2212-8271.
- [HMR19] W. Hintze, J. P. Mehnen und D. Romanenko. *Assistenzsysteme und Prozesse für Smarte ADU-Bohrtechnologien zur Flugzeugmontage in 2020: Schlussbericht: nach BNBest-BMBF 98 zum Einzelvorhaben*. Hrsg. von W. Hintze. Hamburg, 2019.
- [Hoc20] T. Hocke. „Klassifizierung und Untersuchung von thermografisch erfassten Fertigungsfehlern im Automated-Fiber-Placement-Prozess“. Dissertation. Gottfried Wilhelm Leibniz Universität Hannover, 2020.
- [HS17] J. Hedderich und L. Sachs. *Angewandte Statistik: Methodensammlung Mit R*. Berlin: Springer Spektrum, 2017. ISBN: 978-3-662-56656-5.
- [HSS21] M. Hourmand, A. Sarhan, M. Sayuti und M. Hamdi. „A Comprehensive Review on Machining of Titanium Alloys“. In: *Arabian Journal for Science and Engineering* 46 (2021), S. 1–37.
- [HTF09] T. Hastie, R. Tibshirani und J. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. Aufl. Springer Series in Statistics. New York, NY: Springer, 2009. ISBN: 978-0-387-84857-0.
- [Hul24] D. Hulst. *Commercial Market Outlook*. 2024. URL: <https://www.boeing.com/commercial/market/commercial-market-outlook#downloads> (besucht am 22.02.2025).
- [HW23] F. He und M. Weigold. „Quality monitoring for drilling based on internal data of machine tool“. In: *MM Science Journal* (Special Issue | HSM 2023).
- [Ina+14] I. Inagaki, T. Takechi, Y. Shirai und N. Ariyasu. „Application and Features of Titanium for the Aerospace Industry“. In: *Nippon Steel & Sumitomo Metal Technical Report No. 106*. 2014. URL: <https://api.semanticscholar.org/CorpusID:138460261> (besucht am 27.01.2025).
- [Jak19] W. Jakoby. *Qualitätsmanagement für Ingenieure*. 2. Aufl. Wiesbaden: Springer Vieweg, 2019. ISBN: 978-3-658-26595-3.
- [Jal+13] J. Jallageas, J.-Y. K’nevez, M. Chérif und O. Cahuc. „Modeling and optimization of vibration-assisted drilling on positive feed drilling unit“. In: *The International Journal of Advanced Manufacturing Technology* 67.5-8 (2013), S. 1205–1216. ISSN: 0268-3768.
- [Jam+13] G. James, D. Witten, T. Hastie und R. Tibshirani. *An Introduction to Statistical Learning*. 1. Aufl. New York, NY: Springer, 2013. ISBN: 978-1-4614-7137-0.

- [Jan03] R. Janssen. „Bohren und Zirkularfräsen von Schichtverbunden aus Aluminium, CFK und Titanlegierungen.“ Dissertation. Universität Bremen, 2003.
- [Jo21] T. Jo. *Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning*. 1. Aufl. Cham: Springer Nature Switzerland, 2021. ISBN: 978-3-0306-5901-1.
- [Jos19] A. V. Joshi. *Machine Learning and Artificial Intelligence*. 1. Aufl. Cham: Springer Nature Switzerland, 2019. ISBN: 978-3-0302-6621-9.
- [Jov+12] R. Joven. „Thermal properties of carbon fiber/epoxy composites with different fabric weaves“. In: *SAMPE International Symposium Proceedings*. Charleston, SC, 2012.
- [JPJ22] A. Jadon, A. Patil und S. Jadon. *A Comprehensive Survey of Regression Based Loss Functions for Time Series Forecasting*. 2022. URL: <https://arxiv.org/abs/2211.02989> (besucht am 27.12.2024).
- [JRH23] S. Junghans, D. Romanenko und W. Hintze. „Nutzung von Methoden des Maschinellen Lernens für die Werkstückqualitäts- und Werkzeugverschleißüberwachung bei semi-automatischen Bohrprozessen“. In: *Konferenzband 72. Deutscher Luft- und Raumfahrtkongress (DLRK)* (2023).
- [JSB16] H. Jodlbauer, M. Schagerl und M. Brunner. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 111.4 (2016), S. 222–224.
- [Jun+23] J. Junghans, M. Flehmke, J. Stützle, C. Möller und J. H. Dege. „Enhancing tool replacement decisions in milling of Ti-6Al-4V using convolutional neural networks and time-series-to-image encoding“. In: *MIC Procedia* 23 (2023), S. 107–114.
- [Jun22a] A. Jung. *Machine Learning*. 1. Aufl. Singapore: Springer Singapore, 2022. ISBN: 978-981-16-8192-9.
- [Jun22b] S. Junghans. „Nutzung von Methoden des Maschinellen Lernens für die Werkstückqualitäts- und Werkzeugverschleißüberwachung bei semi-automatischen Bohrprozessen“. Masterarbeit. Hamburg: Technische Universität Hamburg, 2022.
- [Kar01] B. Karpuschewski. „Sensoren zur Prozeßüberwachung beim Spanen“. Habilitation. Gottfried Wilhelm Leibniz Universität Hannover, 2001.
- [KBK09] M. Kurt, E. Bagci und Y. Kaynak. „Application of Taguchi methods in the optimization of cutting parameters for surface finish and hole diameter accuracy in dry drilling processes“. In: *The International Journal of Advanced Manufacturing Technology* 40.5 (2009), S. 458–469. ISSN: 0268-3768, 1433-3015.
- [KHS12] T. Kivak, K. Habali und U. Seker. „The Effect of Cutting Paramaters on The Hole Quality and Tool Wear During The Drilling of Inconel 718“. In: *Gazi University Journal of Science* 25.2 (2012), S. 533–540.
- [Kie52] O. Kienzle. „Die Bestimmung von Kräften und Leistungen an spanenden Werkzeugen und Werkzeugmaschinen“. In: *VDI-Z* 94.11 (1952), S. 299–305.

- [Kip19] A. Kipp. *Airbus setzt in Hamburg auf Roboter-Technologie*. 2019. URL: <https://www.welt.de/regionales/hamburg/article201244134/Produktionsprozesse-Airbus-setzt-in-Hamburg-auf-Roboter-Technologie.html> (besucht am 01.02.2025).
- [KKB08] M. Kurt, Y. Kaynak und E. Bagci. „Evaluation of drilled hole quality in Al 2024 alloy“. In: *The International Journal of Advanced Manufacturing Technology* 37.11 (2008), S. 1051–1060. ISSN: 0268-3768, 1433-3015.
- [Klo17] S. Klotz. „Dynamische Parameteranpassung bei der Bohrungsherstellung in faserverstärkten Kunststoffen unter zusätzlicher Berücksichtigung der Einspannsituation“. Dissertation. RWTH Aachen, 2017.
- [Klo18] F. Klocke. *Fertigungsverfahren 1: Zerspanung mit geometrisch bestimmter Schneide*. 9. Aufl. VDI-Buch. Berlin, Heidelberg: Springer Vieweg, 2018. ISBN: 978-3-662-54206-4.
- [Koc+22] J. Koch, D. Schoepflin, A. Venkatanarasimhan und T. Schüppstuhl. „Tool Wear Classification in Automated Drilling Operations of Aircraft Structure Components using Artificial Intelligence Methods“. In: *SAE International Journal of Advances and Current Practices in Mobility* 4 (2022), S. 1072–1081.
- [Koe+20] L. Koettner, J. P. Mehnen, D. Romanenko, S. Bender und W. Hintze. „Process monitoring using machine learning for semi-automatic drilling of rivet holes in the aerospace industry: Proceedings of the 10th Congress of the German Academic Association for Production Technology (WGP)“. In: *Production at leading edge of technology* 10 (2020), S. 497–507.
- [Koh95] R. Kohavi. „A study of cross-validation and bootstrap for accuracy estimation and model selection“. In: *Proceedings of the 14th International Joint Conference on Artificial Intelligence*. Bd. 2. IJCAI’95. Montreal, Quebec, Canada: Morgan Kaufmann Publishers Inc., 1995, S. 1137–1143. ISBN: 1 558 60363 8.
- [Krs+14] D. Krstajic, L. J. Buturovic, D. E. Leahy und S. Thomas. „Cross-validation pitfalls when selecting and assessing regression and classification models“. In: *Journal of cheminformatics* 6.1 (2014), S. 10. ISSN: 1758-2946.
- [KS20] N. Kachouie und M. Shutaywi. „Weighted Mutual Information for Aggregated Kernel Clustering“. In: *Entropy* 22.3 (2020).
- [KSS22] F. Kähler, O. Schmedemann und T. Schüppstuhl. „Anomaly detection for industrial surface inspection: application in maintenance of aircraft components“. In: *Procedia CIRP* 107 (2022). Leading manufacturing systems transformation – Proceedings of the 55th CIRP Conference on Manufacturing Systems 2022, S. 246–251. ISSN: 2212-8271.
- [KT93] D. Kammermeier und F. Tikal. *Vollhartmetallbohrer und -fräser: Qualität und Leistungsfähigkeit moderner Schneidstoffe*. Landsberg: Moderne Industrie, 1993. ISBN: 978-3-478-93098-7.
- [Kub17] M. Kubat. *An Introduction to Machine Learning*. 2. Aufl. Cham: Springer Nature, 2017. ISBN: 978-3-319-63912-3.
- [Kub24] C. Kubik. „Zuverlässige maschinelle Lernmodelle zur Zustandsdiagnose von Fertigungsprozessen am Beispiel des Stanzens“. Dissertation. Technische Universität Darmstadt, 2024.

- [Kum18] A. Kumar. *Machine Learning: Validation Techniques*. 2018. URL: <https://dzone.com/articles/machine-learning-validation-techniques> (besucht am 20.08.2022).
- [Kum20] S. Kumar. *Understanding 8 types of Cross-Validation: A Deep dive explanation of cross-validation and its types*. 2020. URL: <https://towardsdatascience.com/understanding-8-types-of-cross-validation-80c935a4976d> (besucht am 17.12.2022).
- [Kum21] A. Kumar. *Hold-out Method for Training Machine Learning Models*. 2021. URL: <https://vitalflux.com/hold-out-method-for-training-machine-learning-model/> (besucht am 22.01.2022).
- [Lae+12] R. Lässig, M. Eisenhut, A. Mathias, R. T. Schulte, F. Peters, T. Kümann, T. Waldmann und W. Begemann. *Serienproduktion von hochfesten Faserverbundbauteilen: Perspektiven für den deutschen Maschinen- und Anlagenbau; Studie*. Roland Berger Strategy Consultants, 2012. URL: <https://books.google.de/books?id=CjDkvgEACAAJ> (besucht am 21.03.2025).
- [Lak21] G. V. Lakshana. *4 Ways to Evaluate your Machine Learning Model Cross-Validation Techniques*. 2021. URL: <https://www.analyticsvidhya.com/blog/2021/05/4-ways-to-evaluate-your-machine-learning-model-cross-validation-techniques-with-python-code/> (besucht am 02.08.2022).
- [Lee+25] S. Lee, P. Mongan, A. Farhadi, E. Hinchy, N. O’Dowd und C. McCarthy. „In-situ evaluation of hole quality and cutting tool condition in robotic drilling of composite materials using machine learning“. In: *Journal of Intelligent Manufacturing* (2025), S. 1–22.
- [Lee19] W. M. Lee. *Python Machine Learning*. 1. Aufl. Indianapolis: Wiley, 2019. ISBN: 978-1-523-12845-7.
- [Li+23a] S.-S. Li, X. Yue, Q.-Y. Li, H.-L. Peng, B.-X. Dong, T.-S. Liu, H.-Y. Yang, J. Fan, S.-L. Shu, F. Qiu und Q.-C. Jiang. „Development and applications of aluminum alloys for aerospace industry“. In: *Journal of Materials Research and Technology* 27 (2023), S. 944–983. ISSN: 2238-7854.
- [Li+23b] Z. Li, W. Tian, J. Hu, M. Wang, B. Li und W. Liao. „Deformation error compensation by stiffness model of mechanical joint on a flexible track drilling robot for aircraft assembly“. In: *International Journal of Advanced Manufacturing* 127 (2023), S. 5863–5878.
- [Lis21] F. Lissek. „Beitrag zum Verständnis der Zerspanung nachgiebiger Strukturen aus kohlefaserverstärkten Kunststoffen: Charakterisierung, Modellierung und Bewertung instationärer Bohrprozesse“. Dissertation. Technische Universität Ilmenau, 2021.
- [Liu+10] Y. Liu, Z. Li, H. Xiong, X. Gao und J. Wu. „Understanding of Internal Clustering Validation Measures“. In: *2010 IEEE International Conference on Data Mining*. 2010, S. 911–916.
- [LL24] J. Li und M. A. Lanham. *Predictive Maintenance in Drilling Operations: A Machine Learning Approach for Drill Bit Failure Prediction*. 2024. URL: https://matthewalanham.com/Students/2024/2024_PUSRS_Predictive_Maintenance_in_Drilling_Operations_A_Machine_Learning_Approach_for_Drill_Bit_Failure_Prediction.pdf (besucht am 09.02.2025).

- [LPS21] R. Larracy, A. Phinyomark und E. Scheme. „Machine Learning Model Validation for Early Stage Studies with Small Sample Sizes“. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (2021), S. 2314–2319.
- [LTZ08] F. T. Liu, K. M. Ting und Z.-H. Zhou. „Isolation Forest“. In: *Eighth IEEE International Conference on Data Mining*. 2008, S. 413–422.
- [Lue+19] A. Lübbering, T. Langhorst, W. Hintze, J. P. Mehnen, D. Romanenko, J. N. Sikorra und S. Steinbach. *System zur Steuerung und Überwachung von Bohrprozessdaten*. Patent. Anmelder: Johannes Lübbering GmbH (Europäisches Patent EP 3 789 142 B1). 2019. URL: <https://data.epo.org/publication-server/rest/v1.2/patents/EP3789142NWB1/document.pdf> (besucht am 11.03.2025).
- [Lue25] Johannes Lübbering GmbH. *Bohren mit L.ADU*. 2025. URL: <https://www.luebbering.de/de/bohren/bohren-mit-l-adu> (besucht am 01.02.2025).
- [LW07] G. Lütjering und J. C. Williams. *Titanium*. 2. Aufl. Engineering materials and processes. Berlin, New York: Springer, 2007. ISBN: 978-3-540-71397-5.
- [LWH16] Z. Li, K. Wang und Y. He. „Industry 4.0 - Potentials for Predictive Maintenance“. In: *6th International Workshop of Advanced Manufacturing and Automation*. 2016.
- [Mal+20] F. Maleki, N. Muthukrishnan, K. Ovens, C. Reinhold und R. Forghani. „Machine Learning Algorithm Validation: From Essentials to Advanced Applications and Implications for Regulatory Certification and Deployment“. In: *Neuroimaging clinics of North America* 30.4 (2020), S. 433–445.
- [Man+18] K. Manohar, T. Hogan, J. Buttrick, A. G. Banerjee, J. N. Kutz und S. L. Brunton. „Predicting shim gaps in aircraft assembly with machine learning and sparse sensing“. In: *Journal of Manufacturing Systems* 48 (2018), S. 87–95. ISSN: 0278-6125.
- [Man92] B.S. Manjunath. „Gabor wavelet transform and application to problems in early vision“. In: *Conference Record of the Twenty-Sixth Asilomar Conference on Signals, Systems and Computers*. 1992, 796–800 vol.2.
- [Mar+16] A. Marino, P. Cirillo, C. Natale, P. Chiacchio und S. Pirozzi. „A general low-cost and flexible architecture for robotized drilling in aircraft assembly lines“. In: *2016 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*. 2016, S. 1401–1408.
- [Mat20] The MathWorks, Inc. *Machine Learning with MATLAB*. 2020. URL: <https://de.mathworks.com/campaigns/offers/machine-learning-with-matlab.html> (besucht am 28.12.2022).
- [Mat22] The MathWorks, Inc. *Kreuzvalidierung: Bewerten und verbessern Sie die prädiktive Leistung von Modellen*. 2022. URL: <https://de.mathworks.com/discovery/cross-validation.html> (besucht am 18.03.2025).
- [Mat24a] The MathWorks, Inc. *MATLAB documentation: The Language of Technical Computing*. 2024. URL: <https://de.mathworks.com/help/matlab/> (besucht am 08.04.2024).
- [Mat24c] The MathWorks, Inc. *Audio Toolbox: Design and analyze speech, acoustic, and audio processing systems*. 2024. URL: <https://de.mathworks.com/products/audio.html> (besucht am 26.04.2024).

- [Mat24d] The MathWorks, Inc. *Wavelet Scattering*. 2024. URL: <https://de.mathworks.com/help/wavelet/ug/wavelet-scattering.html> (besucht am 28.04.2024).
- [Mat24e] The MathWorks, Inc. *Spectral Descriptors*. 2024. URL: <https://de.mathworks.com/help/audio/ug/spectral-descriptors.html> (besucht am 29.12.2024).
- [Mat25a] The MathWorks, Inc. *Relief algorithm*. 2025. URL: https://de.mathworks.com/help/stats/relieff.html#mw_aa6f4d74-db51-4c9f-9332-04e80146f69b (besucht am 01.01.2025).
- [Mat25b] The MathWorks, Inc. *Chi square ranking*. 2025. URL: <https://de.mathworks.com/help/stats/fscchi2.html> (besucht am 01.01.2025).
- [Mat25c] The MathWorks, Inc. *Unsupervised Anomaly Detection*. 2025. URL: <https://de.mathworks.com/help/stats/unsupervised-anomaly-detection.html> (besucht am 03.01.2025).
- [Mat25d] The MathWorks, Inc. *Feature Ranking Using F-Tests*. 2025. URL: <https://de.mathworks.com/help/stats/fsrftest.html> (besucht am 08.03.2025).
- [Mat75] B. W. Matthews. „Comparison of the predicted and observed secondary structure of T4 phage lysozyme“. In: *Biochimica et Biophysica Acta (BBA) - Protein Structure* 405.2 (1975), S. 442–451. ISSN: 0005-2795.
- [McL16] T. E. McLeay. „Unsupervised Monitoring of Machining Processes“. Dissertation. University of Sheffield, 2016.
- [Meh23] J. P. Mehnen. „Modellgestützte Berechnung der thermischen Belastung bei der Zerspanung von unidirektionalem CFK“. Dissertation. Technische Universität Hamburg, 2023.
- [Mei07] D. Meiners. „Beitrag zur Stabilität und Automatisierung von CFK-Produktionsprozessen“. Dissertation. Technische Universität Clausthal, 2007.
- [Mel+16] R. Melentiev, P. C. Priarone, M. Robiglio und L. Settineri. „Effects of Tool Geometry and Process Parameters on Delamination in CFRP Drilling: An Overview“. In: *Procedia CIRP* 45 (2016), S. 31–34. ISSN: 2212-8271.
- [Mel19] G. Melhem. „Aerospace Fasteners: Use in Structural Applications“. In: Taylor & Francis, 2019, S. 30–45. ISBN: 978-1-4665-1081-4.
- [Men81] W. Menkirch. „2. Density Sensitive Flow Visualization“. In: *Fluid Dynamics*. Hrsg. von R.J. Emrich. Bd. 18. Methods in Experimental Physics. Academic Press, 1981, S. 345–403.
- [Mil10] D. Miljković. „Review of novelty detection methods“. In: *The 33rd International Convention MIPRO*. Mai 2010, S. 593–598. ISBN: 978-1-4244-7763-0.
- [Miz+22] K. Mizuhara, M. Kato, Y. Hirono, J. Okuno, K. Yanagihara und Y. Kakinuma. „Automatic chip detection using DifferNet“. In: *MIC Procedia* 22 (2022), S. 24–28.
- [MJX21] A. M. Mandra, J. Jiang und F. Xi. „A new burr formation model for drilling with tool wear“. In: *The International Journal of Advanced Manufacturing Technology* 116.5 (2021), S. 1437–1450. ISSN: 0268-3768, 1433-3015.

- [MKD01] S. Min, J. Kim und D. A. Dornfeld. „Development of a drilling burr control chart for low alloy steel, AISI 4118“. In: *Journal of Materials Processing Technology* 113.1 (2001), S. 4–9. ISSN: 0924-0136.
- [Moc82] J. Mockus. „The Bayesian approach to global optimization“. In: *System Modeling and Optimization*. Hrsg. von R. F. Drenick und F. Kozin. Berlin, Heidelberg: Springer, 1982, S. 473–481. ISBN: 978-3-540-39459-4.
- [Mol21] L. Molquentin. „Zustandsüberwachung von semi-automatischen Bohrprozessen unter Nutzung von Klassifikationsmethoden des Maschinellen Lernens“. Masterarbeit. Technische Universität Hamburg, 2021.
- [MP18] R. Fernandes de Mello und M. Antonelli Ponti. *Machine learning: a practical approach on the statistical learning theory*. Cham: Springer, 2018. ISBN: 978-3-319-94988-8.
- [Mra13] M. Mrazova. „Advanced composite materials of the future in aerospace industry“. In: *INCAS Bulletin* 5 (2013), S. 139–150.
- [MRS92] M. Mehta, T. J. Reinhart und A. H. Soni. „Effect of Fastener Hole Drilling Anomalies on Structural Integrity of PMR-15/Gr Composite Laminate“. In: *Proceedings of the Machining Composite Materials Symposium, ASM Materials Week* (1992), S. 113–126.
- [MS03] M. Markou und S. Singh. „Novelty detection: a review—part 1: statistical approaches“. In: *Signal Processing* 83.12 (2003), S. 2481–2497. ISSN: 0165-1684.
- [MS24] A. Mockenhaupt und T. Schlagenhaut. *Digitalisierung und Künstliche Intelligenz in der Produktion: Grundlagen und Anwendung*. 2. Aufl. Wiesbaden: Springer Vieweg, 2024. ISBN: 978-3-658-41934-9. URL: <https://books.google.de/books?id=oCrtzweACAAJ> (besucht am 23.02.2025).
- [MTR19] G. Martínez-Arellano, G. Terrazas und S. M. Ratchev. „Tool wear classification using time series imaging and deep learning“. In: *The International Journal of Advanced Manufacturing Technology* 104 (2019), S. 3647–3662. URL: <https://api.semanticscholar.org/CorpusID:199086042> (besucht am 24.01.2025).
- [Nai23] J. Nainani. *Understanding the evaluation of Unsupervised Learning with K-means*. 2023. URL: <https://smlra-kjsce.medium.com/understanding-the-evaluation-of-unsupervised-learning-with-k-means-fa5fd0af3e5b> (besucht am 03.01.2025).
- [Ng23] A. Ng. „online-Vorlesung: Machine Learning Specialization“. Coursera, 20. Okt. 2023.
- [Opi24] J. Opitz. „A Closer Look at Classification Evaluation Metrics and a Critical Reflection of Common Evaluation Practice“. In: *Transactions of the Association for Computational Linguistics* 12 (2024), S. 820–836. ISSN: 2307-387X.
- [Osm+18] M. H. Osman, N. F. Tamin, M. N. Ahmad, M. H. A. B. Rahman, M. K. Wahid, N. A. Maidin, M. H. Abu Bakar und A. A. Azahar. „Effect of Cutting Parameters on Surface Roughness in Dry Drilling of AISI D2 Tool Steel by Using Taguchi Method“. In: *Journal of Advanced Manufacturing Technology (JAMT)* 12.1(2) (2018), S. 535–546. URL: <https://jamt.utem.edu.my/jamt/article/view/4311> (besucht am 01.02.2025).

- [Pan+22] A. Panizza, S. T. Stefanek, S. Melacci, G. Veneri und M. Gori. *Learning to Identify Drilling Defects in Turbine Blades with Single Stage Detectors*. 2022. URL: <https://arxiv.org/abs/2208.04363> (besucht am 07.03.2025).
- [Pap+20] M. Papananias, T. E. McLeay, O. Obajemu, M. Mahfouf und V. Kadiramanathan. „Inspection by exception: A new machine learning-based approach for multistage manufacturing“. In: *Applied Soft Computing* 97 (2020). ISSN: 1568-4946.
- [Pat21] R. Patro. *Cross-Validation: K Fold vs Monte Carlo: Choosing the right validation technique*. 2021. URL: <https://towardsdatascience.com/cross-validation-k-fold-vs-monte-carlo-e54df2fc179b> (besucht am 18.12.2022).
- [Pau+17] T. Paulsen, O. Pecat, A. Wagner und E. Brinksmeier. „Modification of oscillation modes in low frequency vibration assisted drilling“. In: *Procedia Manufacturing* 14 (2017). 17th Machining Innovations Conference for Aerospace Industry, MIC 2017, 6-7 December 2017, Garbsen, Germany, S. 1–7. ISSN: 2351-9789.
- [Pau+20] T. Paulsen, N. Guba, J. Sölter und B. Karpuschewski. „Influence of the workpiece material on the cutting performance in low frequency vibration assisted drilling“. In: *CIRP Journal of Manufacturing Science and Technology* 31 (2020), S. 140–152. ISSN: 1755-5817.
- [Pau08] E. Pauksch, S. Holsten, M. Linß und Tikal. F. *Zerspantechnik*. 12. Aufl. Wiesbaden: Vieweg+Teubner, 2008. ISBN: 978-3-8348-0279-8.
- [Pau21] T. Paulsen. „Vibrationsunterstütztes Bohren metallischer Werkstoffe“. Dissertation. Leibniz-Institut für Werkstofforientierte Technologien Bremen, 2021.
- [PB14] O. Pecat und E. Brinksmeier. „Tool Wear Analyses in Low Frequency Vibration Assisted Drilling of CFRP/Ti6Al4V Stack Material“. In: *Procedia CIRP* 14 (2014). 6th CIRP International Conference on High Performance Cutting, HPC2014, S. 142–147. ISSN: 2212-8271.
- [Pec18] O. Pecat. „Vibrationsunterstütztes Bohren von Werkstoffverbunden aus CFK und Titan“. Dissertation. Leibniz-Institut für Werkstofforientierte Technologien Bremen, 2018.
- [Pee04] G. Peeters. *A large set of audio features for sound description (similarity and classification) in the CUIDADO project*. Techn. Ber. Ircam, 2004. URL: http://recherche.ircam.fr/anasyne/peeters/ARTICLES/Peeters_2003_cuidadoaudiofeatures.pdf (besucht am 23.11.2024).
- [Per+22] B. Pereira, C. A. Griffiths, B. Birch und A. Rees. „Optimization of an autonomous robotic drilling system for the machining of aluminum aerospace alloys“. In: *The International Journal of Advanced Manufacturing Technology* 119 (2022), S. 1–16.
- [Pet+03] M. Peters, C. Leyens, J. Kumpfert und C. H. Ward. „Titanium alloys for aerospace applications“. In: *Advanced Engineering Materials* 5 (6 2003), S. 419–427.
- [Pfe14] T. Pfeifroth. „Beitrag zur Verbesserung der spanenden Bohrbearbeitung von CFK auf Basis von Schädigungsmechanismen“. Dissertation. Universität Stuttgart, 2014.

- [Pil+12] L. Pilný, L. De Chiffre, M. Píška und M. F. Villumsen. „Hole quality and burr reduction in drilling aluminium sheets“. In: *CIRP Journal of Manufacturing Science and Technology* 5.2 (2012), S. 102–107. ISSN: 1755-5817. (Besucht am 23. 11. 2024).
- [Pol24] D. Poll. *Prognose bis 2030: Marktvolumen für Künstliche Intelligenz*. 2024. URL: <https://www.produktion.de/technik/zukunftstechnologien/kuenstliche-intelligenz/prognose-bis-2030-marktvolumen-fuer-kuenstliche-intelligenz-807.html> (besucht am 22. 02. 2025).
- [Pow20] D. M. W. Powers. *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation*. 2020. URL: <https://arxiv.org/abs/2010.16061> (besucht am 04. 07. 2024).
- [PR86] S. S. Pande und H. P. Relekar. „Investigations on reducing burr formation in drilling“. In: *International Journal of Machine Tool Design and Research* 26.3 (1986), S. 339–348. ISSN: 0020-7357.
- [Pra20] R. Pramoditha. *k-fold cross-validation explained in plain English: For evaluating a model’s performance and hyperparameter tuning*. 2020. URL: <https://towardsdatascience.com/k-fold-cross-validation-explained-in-plain-english-659e33c0bc0> (besucht am 12. 11. 2023).
- [PT17] M. Paluszek und S. Thomas. *MATLAB Machine Learning*. For professionals by professionals. New York: Apress, 2016. ISBN: 978-1-484-22250-8. URL: <https://books.google.de/books?id=3kXODQAAQBAJ> (besucht am 27. 06. 2024).
- [Ram+17] P. Rambabu, N. Eswara Prasad, V. V. Kutumbarao und R. J. H. Wanhill. „Aluminium Alloys for Aerospace Applications“. In: *Aerospace Materials and Material Technologies : Volume 1: Aerospace Materials*. Hrsg. von N. Eswara Prasad und R. J. H. Wanhill. Singapore: Springer, 2017, S. 29–52. ISBN: 978-9-811-02134-3.
- [Ray06] D. P. Raymer. *Aircraft design: A conceptual approach*. 4. Aufl. AIAA education series. Reston, Va.: American Institute of Aeronautics und Astronautics, 2006. ISBN: 1 563 47829 3.
- [Ree+24] T. Reeber, J. Henninger, N. Weingarz, P. Simon, M. Berndt, M. Glatt, B. Kirsch, R. Eisseler, J. Aurich und H.-C. Moehring. „Tool condition monitoring in drilling processes using anomaly detection approaches based on control internal data“. In: *Procedia CIRP* 121 (2024), S. 216–221.
- [Rei+16] N. Reich, J. Lessler, K. Sakrejda, S. Lauer, S. Iamsirithaworn und D. Cummings. „Case Study in Evaluating Time Series Prediction Models Using the Relative Mean Absolute Error“. In: *The American Statistician* 70 (2016).
- [RHV12] P. Rajakumar, P. Hariharan und L. Vijayaraghavan. „Drilling of carbon fibre reinforced plastic (CFRP) composites - A review“. In: *International Journal of Materials and Product Technology* 43 (2012), S. 43–67.
- [Ric19] S. Richter. *Statistisches und maschinelles Lernen*. Berlin, Heidelberg: Springer, 2019. ISBN: 978-3-662-59353-0.
- [RK03] M. Robnik-Sikonja und I. Kononenko. „Theoretical and Empirical Analysis of ReliefF and RReliefF“. In: *Machine Learning* 53 (2003), S. 23–69.

- [Rod+02] R. E. Haber, A. Alique, S. Ros und R. H. Haber. „Application of knowledge-based systems for supervision and control of machining processes“. In: *Handbook of Software Engineering and Knowledge Engineering*. 2002, S. 673–709.
- [RR07] A. Rahimi und B. Recht. „Random Features for Large-Scale Kernel Machines“. In: *Advances in Neural Information Processing Systems*. Hrsg. von J. Platt, D. Koller, Y. Singer und S. Roweis. Bd. 20. Curran Associates, Inc., 2007.
- [RRC19] G. Rebala, A. Ravi und S. Churiwala. *An Introduction to Machine Learning*. Cham: Springer International Publishing, 2019. ISBN: 978-3-030-15728-9.
- [Rui+20] L. Ruiz, M. Torres, A. Gómez, S. Díaz, J. M. González und F. Cavas. „Detection and Classification of Aircraft Fixation Elements during Manufacturing Processes Using a Convolutional Neural Network“. In: *Applied Sciences* 10.19 (2020). ISSN: 2076-3417.
- [Run16] T. A. Runkler. *Data Analytics*. Wiesbaden: Springer Fachmedien, 2016. ISBN: 978-3-658-14074-8.
- [Sad+13] A. Sadek, M. H. Attia, M. Meshreki und B. Shi. „Characterization and optimization of vibration-assisted drilling of fibre reinforced epoxy laminates“. In: *CIRP Annals* 62.1 (2013), S. 91–94. ISSN: 0007-8506.
- [Sam+99] V. J. Samar, A. Bopardikar, R. Rao und K. Swartz. „Wavelet Analysis of Neuroelectric Waveforms: A Conceptual Tutorial“. In: *Brain and Language* 66.1 (1999), S. 7–60. ISSN: 0093-934X.
- [Sam59] A. Samuel. „Some Studies in Machine Learning Using the Game of Checkers“. In: *IBM Journal of Research and Development* 3.3 (1959), S. 210–229.
- [Sau+22] K. Sauer, W. G. Drossel, M. Dix und S. Ihlenfeldt. *Qualitätsorientierte Prozessgestaltung der Bohrungsfertigung in kohlenstofffaserverstärkten Kunststoffen*. Berichte aus dem IWU. Wissenschaftliche Scripten, 2022. ISBN: 978-3-957-35162-3.
- [SC08] I. Steinwart und A. Christmann. *Support Vector Machines*. 1. Aufl. Information Science and Statistics. New York: Springer, 2008. ISBN: 978-0-387-77242-4.
- [Sch+21] L. Schumski, T. Paulsen, J. Sölter und B. Karpuschewski. „Finite element simulation of low frequency vibration-assisted drilling with modification of oscillation modes“. In: *Procedia CIRP* 102 (2021). 18th CIRP Conference on Modeling of Machining Operations (CMMO), Ljubljana, Slovenia, June 15-17, 2021, S. 168–173. ISSN: 2212-8271.
- [Sch+24a] L. Schumski, T. Tonn, L. Buss, J. Sölter, U. Fritsching und B. Karpuschewski. „Finite element simulation of the mechanical loads during low frequency vibration-assisted drilling utilizing the CEL-method“. In: *Procedia CIRP* 126 (2024). 17th CIRP Conference on Intelligent Computation in Manufacturing Engineering (CIRP ICME ‘23), S. 378–383. ISSN: 2212-8271.
- [Sch+24b] L. Schumski, T. Tonn, J. Sölter, K. Avila, L. Buss, B. Karpuschewski und U. Fritsching. „Minimum Quantity Lubrication (MQL) Supply through Internal Cooling Channels in Drilling Processes“. In: *Journal of Manufacturing and Materials Processing* 8.2 (2024). ISSN: 2504-4494.

- [Sch14] C. Schütte. „Bohren und Hobeln von kohlenstofffaserverstärkten Kunststoffen unter besonderer Berücksichtigung der Schneide-Faser-Lage“. Dissertation. Technische Universität Hamburg, 2014.
- [Sch19] M. Schmid. *Statusbericht CERATIZIT beim SmartADU2020-Verbundtreffen am 26.04.2019*. Stade, 2019.
- [Sch21] S. Schorr. „Prozessparallele Prognose der Werkstückqualität mithilfe von NC-internen Daten und maschinellem Lernen“. Dissertation. Universität des Saarlandes, 2021.
- [Sch90] J. T. Schaefer. „The Critical Success Index as an Indicator of Warning Skill“. In: *Weather and Forecasting* 5.4 (1990), S. 570–575.
- [Schi23] S. Schibsdatt. „Nutzung und Vergleich von Maschinellem Lernen und Qualitätsregelkarten für die Identifikation von Prozessanomalien bei semiautomatischen Bohrprozessen“. Masterarbeit. Technische Universität Hamburg, 2023.
- [Sci11] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot und E. Duchesnay. „Scikit-learn: Machine Learning in Python“. In: *Journal of Machine Learning Research* 12 (2011), S. 2825–2830.
- [SD19a] R. Stark und T. Damerau. „Digital Twin“. In: *CIRP Encyclopedia of Production Engineering*. Berlin, Heidelberg: Springer, 2019. ISBN: 978-3-642-35950-7.
- [SD19b] G. Dheeraj Simon und R. Deivanathan. „Early detection of drilling tool wear by vibration data acquisition and classification“. In: *Manufacturing Letters* 21 (2019), S. 60–65. ISSN: 2213-8463.
- [See21] L. Seeholzer. „Zerspanung von CFK und CFK/Aluminium-Stacks“. Dissertation. ETH Zürich, 2021.
- [SGR23] J. Stuhmann, A. Gosler und L. Ramme. *Herausforderungen und Entwicklungen in der Rumpfmontage der Luftfahrtindustrie*. Exkursion TU Hamburg 02. Februar 2023. Hamburg, 2023.
- [Sha93] J. Shao. „Linear Model Selection by Cross-validation“. In: *Journal of the American Statistical Association* 88.422 (1993), S. 486–494.
- [She00] C. Shearer. „The CRISP-DM model: the new blueprint for data mining“. In: *Journal of data warehousing* 5.4 (2000), S. 13–22.
- [Shm19] B. Shmueli. *Multi-Class Metrics Made Simple, Part II: the F1-score*. 2019. URL: <https://towardsdatascience.com/multi-class-metrics-made-simple-part-ii-the-f1-score-eb8b2c2ca1> (besucht am 14.01.2025).
- [Sho07] H. Schürmann. *Konstruieren mit Faser-Kunststoff-Verbunden: Mit 39 Tabellen*. 2. Aufl. VDI-/Buch]. Berlin, Heidelberg: Springer, 2007. ISBN: 978-3-540-72189-5.
- [SK23] J. Stuhmann und D. Küstner. „Digital Assembly Excellence“. präsentiert beim 65. Hamburg Aviation Forum. Präsentation. Hamburg, 12. Okt. 2023.
- [SLA12] J. Snoek, H. Larochelle und R. P. Adams. *Practical Bayesian Optimization of Machine Learning Algorithms*. 2012. URL: <https://arxiv.org/abs/1206.2944> (besucht am 21.04.2024).

- [SMB20] S. Schorr, M. Möller, J. Heib und D. Bähre. „In-process Quality Control of Drilled and Reamed Bores using NC-Internal Signals and Machine Learning Method“. In: *Procedia CIRP* 93 (2020). 53rd CIRP Conference on Manufacturing Systems 2020, S. 1328–1333. ISSN: 2212-8271.
- [SR23] S. Schibsdatt und D. Romanenko. „Self-acting anomaly detection and quality estimation for semi-automated drilling with machine learning methods“. präsentiert bei TYE-Train Your Engineering Network. Präsentation. Hamburg, 20. Nov. 2023.
- [SS17] T. C. Stocker und I. Steinke. *Statistik: Grundlagen und Methodik*. Berlin, Boston: De Gruyter Oldenbourg, 2017. ISBN: 978-3-110-35389-1.
- [SSA23] A.-A. Semenoglou, E. Spiliotis und V. Assimakopoulos. „Image-based time series forecasting: A deep convolutional neural network approach“. In: *Neural Networks* 157 (2023), S. 39–53. ISSN: 0893-6080.
- [Ste20] M. Stender. „Data-driven techniques for the nonlinear dynamics of mechanical structures“. Dissertation. Technische Universität Hamburg, 2020.
- [Sto07] E. Stöver. „Untersuchungen zum Bohren des Faser-Metall-Laminats Glare sowie von Glare-Schichtverbunden“. Dissertation. Technische Universität Hamburg, 2007.
- [Stu+21] S. Studer, T. B. Bui, C. Drescher, A. Hanuschkin, L. Winkler, S. Peters und K.-R. Müller. „Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology“. In: *Machine Learning and Knowledge Extraction* 3.2 (2021), S. 392–413. ISSN: 2504-4990.
- [Sug16] M. Sugiyama. *Introduction to Statistical Machine Learning*. Waltham, MA: Elsevier, 2016. ISBN: 978-0-128-02121-7.
- [SV10] A. Smola und S. V. N. Vishwanathan. *An Introduction to Machine Learning*. Cambridge: Cambridge University Press, 2010. ISBN: 0 521 82583 0.
- [Swa19] M. Swamynathan. *Mastering Machine Learning with Python in Six Steps: A Practical Implementation Guide to Predictive Data Analytics Using Python*. 2. Aufl. New York: Apress, 2019. ISBN: 978-1-4842-4947-5.
- [SZK21] N. Seliya, A. Abdollah Zadeh und T. M. Khoshgoftaar. „A literature review on one-class classification and its potential applications in big data“. In: *Journal of Big Data* 8.1 (2021), S. 122. ISSN: 2196-1115.
- [Tch+23] P. Tchasse, A. Schenek, K. Riedmüller und M. Liewald. „Detection of Defective Deep Drawn Sheet Metal Parts by Using Machine Learning Methods for Image Classification“. In: *Production at the Leading Edge of Technology*. Cham, 2023, S. 84–93. ISBN: 978-3-031-47394-4.
- [Tet+10] R. Teti, K. Jemelnik, G. O’Donnell und D. Dornfeld. „Advanced monitoring of machining operations“. In: *CIRP Annals* 59.2 (2010), S. 717–739. ISSN: 0007-8506.
- [Tho+05] P. Thompson, J. Hartmann, E. Feikert und J. Buttrick. „Flex Track for use in Production“. In: *SAE 2005 Transactions Journal of Aerospace-V114-1* (2005). ISSN: 0148-7191.
- [TPL22] T. Tran, N. T. Pham und J. Lundgren. „A deep learning approach for detecting drill bit failures from a small sound dataset“. In: *Scientific Reports* 12 (2022).

- [TVS10] J.-A. Ting, S. Vijayakumar und S. Schaal. *Encyclopedia of Machine Learning*. Hrsg. von C. Sammut und G. I. Webb. New York: Springer, 2010. ISBN: 978-0-387-30768-8.
- [Vab+19] A. Vabalas, E. Gowen, E. Poliakoff und A. J. Casson. „Machine learning algorithm validation with a limited sample size“. In: *PloS one* 14.11 (2019).
- [VDL12] C. Veiga, J. P. Davim und A. Loureiro. „Properties and applications of titanium alloys: A brief review“. In: *Reviews on Advanced Materials Science* 32 (2012), S. 133–148.
- [Vol22] K. Volkmann. „Überwachung der Werkstückqualität und des Werkzeugverschleißes mittels Maschinellen Lernens beim semi-automatischen Bohren von Aluminium“. Bachelorarbeit. Technische Universität Hamburg, 2022.
- [Vos+17] R. Voss, L. Seeholzer, F. Kuster und K. Wegener. „Cutting Process Tribometer Experiments for Evaluation of Friction Coefficient Close to a CFRP Machining Operation“. In: *Procedia CIRP* 66 (2017), S. 204–209. ISSN: 2212-8271.
- [VS18] B. Venkatesh und R. S. Sikarwar. „Drilling of Carbon Fibre Reinforced Polymer Materials - A Review“. In: *International Journal of Mechanical and Production Engineering Research and Development* 8.2 (2018), S. 157–166. ISSN: 2249-6890.
- [VV22] A. Vandone und A. Valente. „AI based monitoring system for DED part quality evaluation“. In: *Procedia CIRP* 107 (2022). Leading manufacturing systems transformation – Proceedings of the 55th CIRP Conference on Manufacturing Systems 2022, S. 635–640. ISSN: 2212-8271.
- [Wag+22] M. Wagner, D. Pietsch, M. Schwarzenberger, A. Jahn, D. Dittrich, U. Stamm, S. Ihlenfeldt und C. Leyens. „Digitalized laser beam welding for inline quality assurance through the use of multiple sensors and machine learning“. In: *Procedia CIRP* 111 (2022). 12th CIRP Conference on Photonic Technologies [LANE 2022], S. 518–521. ISSN: 2212-8271.
- [Waq+16] S. Waqar, S. Asad, S. Ahmad, C. A. Abbas und H. Elahi. „Effect of Drilling Parameters on Hole Quality of Ti-6Al-4V Titanium Alloy in Dry Drilling“. In: *Materials Science Forum* 880 (2016), S. 33–36.
- [Wes07] T. Wessels. „Bohren in Titan- und Nickelbasislegierungen“. Dissertation. Technische Universität Braunschweig, 2007.
- [WHG16] B. Wujek, P. Hall und F. Günes. „Best Practices for Machine Learning Applications“. In: 2016. URL: <https://api.semanticscholar.org/CorpusID:20946822> (besucht am 29.01.2024).
- [Wij23] C. Y. Wijaya. *Exploring Unsupervised Learning Metrics*. 2023. URL: <https://www.kdnuggets.com/2023/04/exploring-unsupervised-learning-metrics.html> (besucht am 04.01.2025).
- [Wit19] V. Wittpahl. *Künstliche Intelligenz. Technologien, Anwendung, Gesellschaft*. 1. Aufl. iit-Themenband. Berlin, Heidelberg: Springer Vieweg, 2019. ISBN: 978-3-662-58041-7.
- [WO15] Z. Wang und T. Oates. *Imaging Time-Series to Improve Classification and Imputation*. 2015. URL: <https://arxiv.org/abs/1506.00327> (besucht am 19.02.2025).

- [Wu24] Y. Wu. „Application of carbon fiber composite materials in aircraft“. In: *Applied and Computational Engineering* 61 (2024), S. 245–248.
- [WZH18] G. Wang, Y. Zhao und Y. Hao. „Friction stir welding of high-strength aerospace aluminum alloy and application in rocket tank manufacturing“. In: *Journal of Materials Science & Technology* 34.1 (2018), S. 73–91. ISSN: 1005-0302.
- [XL01] Q.-S. Xu und Y.-Z. Liang. „Monte Carlo cross validation“. In: *Chemometrics and Intelligent Laboratory Systems* 56 (2001), S. 1–11.
- [XLD04] Q.-S. Xu, Y.-Z. Liang und Y.-P. Du. „Monte Carlo cross-validation for selecting a model and estimating the prediction error in multivariate calibration“. In: *Journal of Chemometrics* 18.2 (2004), S. 112–120. ISSN: 0886-9383.
- [Xu+19] J. Xu, C. Li, M. Chen und F. Ren. „A comparison between vibration assisted and conventional drilling of CFRP/Ti6Al4V stacks“. In: *Materials and Manufacturing Processes* 34.10 (2019), S. 1182–1193.
- [XXL18] L. D. Xu, E. L. Xu und L. Li. „Industry 4.0: state of the art and future trends“. In: *International Journal of Production Research* 56.8 (2018), S. 2941–2962.
- [YKG24] O. Yay, G. Kunt und S. Gürgen. „Bolted Joints in Aerospace Structures“. In: *Joining Operations for Aerospace Materials*. Hrsg. von S. Gürgen. Cham: Springer Nature Switzerland, 2024, S. 41–53. ISBN: 978-3-031-59446-5.
- [Zav05] E. Zavarehei. *Boll Spectral Subtraction: The spectral Subtraction Method for enhancement of noisy speech*. MathWorks File Exchange, 2005. URL: <https://de.mathworks.com/matlabcentral/fileexchange/7675-boll-spectral-subtraction> (besucht am 19.04.2024).
- [Zed+13] Y. Zedan, V. Songmene, J. Kouam und J. Masounave. „Effects of lubrication modes on part quality during drilling 6061-T6 aluminium alloy“. In: *International Journal of Machining and Machinability of Materials* 13.2 (2013), S. 231. ISSN: 1748-5711, 1748-572X.
- [Zha+20] H. Zhao, J. Xi, K. Zheng, Z. Shi, J. Lin, K. Nikbin, S. Duan und B. Wang. „A review on solid riveting techniques in aircraft assembling“. In: *Manufacturing Review* 7 (2020).
- [Zha+24] J. Zhang, R. Heinemann, O. J. Bakker und M. Zhu. „In-process tool incidence identification based on temporal pyramid pooling and convolutional neural network“. In: *Procedia CIRP* 126 (2024). 17th CIRP Conference on Intelligent Computation in Manufacturing Engineering (CIRP ICME ‘23), S. 486–491. ISSN: 2212-8271.
- [Zha93] P. Zhang. „Model Selection via Multifold Cross Validation“. In: *The Annals of Statistics* 21.1 (1993), S. 299–313.
- [Zhe+16] Z. Shi, P. Yuan, Q. Wang, D. Chen und T. Wang. „New design of a compact aero-robotic drilling end effector: An experimental analysis“. In: *Chinese Journal of Aeronautics* 29.4 (2016), S. 1132–1141. ISSN: 1000-9361.
- [Zie22] A. Ziegenbein. „Prädiktive Qualität durch Werkzeugmaschinensignale: Effekte der Datenvorbereitung auf Klassifikationsergebnisse maschineller Lernverfahren“. Dissertation. Technische Universität Darmstadt, 2022.
- [ZL23] A. Zhang und Y. Li. „Thermal Conductivity of Aluminum Alloys—A Review“. In: *Materials* 16 (2023), S. 2972.

- [Zub+21] A. Duo Zubiaurre, T. Segreto, A. Caggiano, R. Basagoiti, R. Teti und P. Arrazola. „Drilling process monitoring: a framework for data gathering and feature extraction techniques“. In: *Procedia CIRP* 99 (2021), S. 189–195. ISSN: 2212-8271.

Normen- und Datenblattverzeichnis

- [Aer24] Aerospace Specification Metals Inc. „Titanium Ti-6Al-4V (Grade 5), Annealed“. 2024. URL: <https://asm.matweb.com/search/SpecificMaterial.asp?bassnum=mtp641> (besucht am 08.03.2024).
- [DIN 1302] Deutsches Institut für Normung e.V. „Angabe der Oberflächenbeschaffenheit in der technischen Produktdokumentation: Indication of surface texture in technical product documentation“. 1302 (Berlin). 2002.
- [DIN 1412] Deutsches Institut für Normung e.V. „Spiralbohrer aus Schnellarbeitsstahl: Anschliffformen“. 1412 (Berlin). 2021.
- [DIN 4288] Deutsches Institut für Normung e.V. „Geometrische Produktspezifikation (GPS) - Oberflächenbeschaffenheit: Tastschnittverfahren - Regeln und Verfahren für die Beurteilung der Oberflächenbeschaffenheit: Geometrical Product Specifications (GPS) - Surface texture: Profile method - Rules and procedures for the assessment of surface texture“. 4228 (Berlin). 2002.
- [DIN 6539] Deutsches Institut für Normung e.V. „Vollhartmetall-Spiralbohrer mit durchgehendem Zylinderschaft - Maße: Solid hardmetal twist drills with continuous parallel shank; Dimensions“. DIN 6539 (Berlin). 2006.
- [DIN 6581] Deutsches Institut für Normung e.V. „Bezugssysteme und Winkel am Schneidteil des Werkzeugs“. 6581 (Berlin). 1985.
- [DIN 8580] Deutsches Institut für Normung e.V. „Fertigungsverfahren – Begriffe, Einteilung“. 8580 (Berlin). 2003.
- [DIN 8589-2] Deutsches Institut für Normung e.V. „Fertigungsverfahren Spanen - Teil 2: Anforderungen: Bohren, Senken, Reiben“. 8589-2 (Berlin). 2003.
- [DIN ISO 513] Deutsches Institut für Normung e.V. „Klassifizierung und Anwendung von harten Schneidstoffen für die Metallzerspanung mit geometrisch bestimmten Schneiden – Bezeichnung der Hauptgruppen und Anwendungsgruppen: Classification and application of hard cutting materials for metal removal with defined“. DIN ISO 513 (Berlin). 2014.
- [Ext22] Extramet AG. „EMT 210: technische Angaben“. PA 4.12.12 (Plaffeien). 1. Juni 2022. URL: https://extramet.net/wp-content/uploads/Technische-Angaben-EMT-210_2022-1.pdf (besucht am 14.03.2024).
- [Hex15] Hexcel Corporation. „HexTow IMA“. (Stamford, Connecticut, Vereinigte Staaten). 2015. URL: https://www.hexcel.com/user_area/content_media/raw/IMA_HexTow_DataSheet.pdf (besucht am 07.03.2024).
- [Hex20] Hexcel Corporation. „HexPly M21 Data Sheet“. (Stamford, Connecticut, Vereinigte Staaten). 2020. URL: https://www.hexcel.com/user_area/content_media/raw/HexPly_M20_global_DataSheet.pdf (besucht am 07.03.2024).

-
- [Mat24b] MatWeb - Material Property Data. „Hexcel® HexPly® M21 356°F (180°C) Curing Epoxy Matrix“. 2024. URL: <https://www.matweb.com/search/datasheet.aspx?matguid=50512b22a4b84334b177966a2469f736&ckck=1> (besucht am 07.03.2024).
- [Thy24] Thyssenkrupp Materials Schweiz. „Titan Grade 5“. 2024. URL: https://d2zo35mdb530wx.cloudfront.net/_binary/UCPthyssenkruppBAMXSchweiz/de/downloads/werkstoffdatenblaetter-titan/link-titan_grade_5.pdf (besucht am 08.03.2024).
- [Wie18] Wieland SMH GmbH. „Werkstoffdatenblatt EN AW 2024 [EN AW-Al Cu4Mg1]“. 2018. URL: https://www.wieland.com/en/content/download/17162/file/EN-AW-2024_DE.pdf (besucht am 07.03.2024).

A Anhang

A.1 Grundlagen und Stand der Technik

A.1.1 Werkstoffe

In der Tabelle A.1 sind die mechanischen Eigenschaften wichtigster Werkstoffe in der Struktur von Luftfahrzeugen zusammengefasst.

*Tabelle A.1: Übersicht über die dominanten Werkstoffe der Luftfahrt-Strukturen nach [Li+23a], [ZL23], [Ram+17], [LW07], [Pet+03], [Ina+14], [VDL12], [Jov+12], [Hin21a, 10 ff.], [Hex20], [Sho07, S. 202] (Angabe der Eigenschaften bei Raumtemperatur; *Angaben für das in der Luftfahrt etablierte Endlosfaser-Verbundmaterial HexPly[®]M21E-IMA-34-194 als unidirektionales Prepreg entlang der Faserrichtung; n. d. = nicht definiert; **Angaben zur duromereren (Epoxidharz-) Matrix; ***UD-Schicht beim Faservolumenanteil $\varphi_F = 60\%$ ****repräsentative Angaben aus der o. g. Literatur für unidirektionale CFK-Werkstoffe entlang der Faserrichtung)*

Eigenschaft		Aluminium- Legierungen	Titan- Legierungen	CFK (Zug)
Dichte ρ	[g cm ⁻³]	2,64 – 2,8	4,3 – 4,8	≈ 1,58*
E-Modul E	[GPa]	67 – 73	110 – 145	178*
Zugfestigkeit R_m	[MPa]	225 – 560	140 – 1200	3050*
spezifische Festigkeit R_s	[N m g ⁻¹]	84 – 172	30 – 280	1930*
Dehngrenze $R_{p0,2}$	[MPa]	140 – 480	235 – 1400	n. d.
Bruchdehnung A_B	[%]	0,7 – 24	≥ 10	1,5 – 10**
Poisson-Zahl ν	[–]	0,32 – 0,35	0,33 – 0,34	0,37***
Wärmeleitfähigkeit λ	[W (m K) ⁻¹]	90 – 200	5,5 – 22	6,8****

A.1.2 Bohrprozess

In der Tabelle A.2 sind die Kraft- und Drehmomentanteile an einem Wendelbohrer verglichen.

Tabelle A.2: Kraftanteile an einem Wendelbohrer nach [Klo18, S. 577]

	Drehmoment [%]	Vorschubkraft [%]
Hauptschneiden	65-75	17-25
Querschneide	10-14	65-75
Führungsfasen	15-20	7-8

In [MKD01] wird eine Gratformen-Klassifikation vorgeschlagen, die in der Abbildung A.1 beispielhaft dargestellt ist.




Abbildung A.1: Gratformen nach [MKD01]

Die Abbildung A.2 stellt die Delaminationsarten und -mechanismen dar.

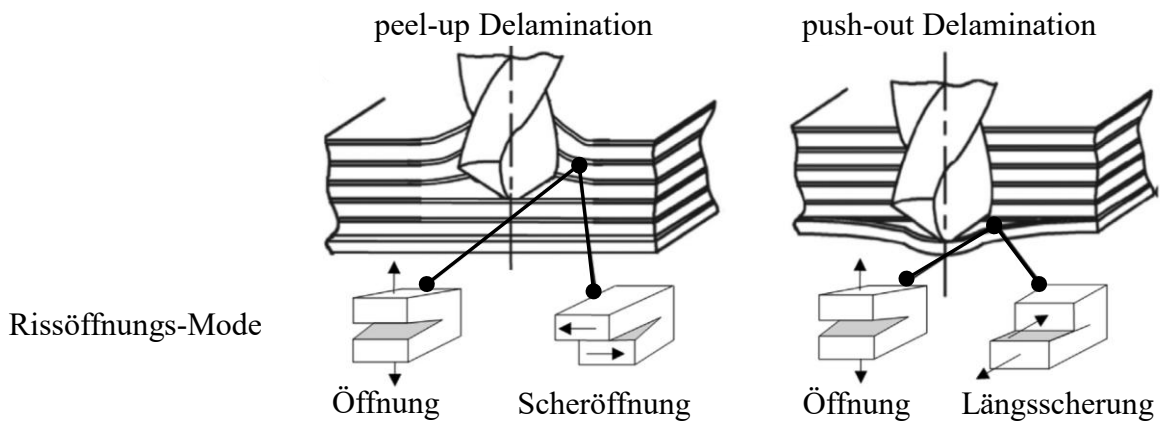


Abbildung A.2: Delaminationsarten und -mechanismen (zusammengefasst nach [Gen+19])

In der Abbildung A.3 sind unterschiedliche Systeme zur Erzeugung einer oszillierenden Werkzeugbewegung beim Bohrprozess gegenübergestellt.

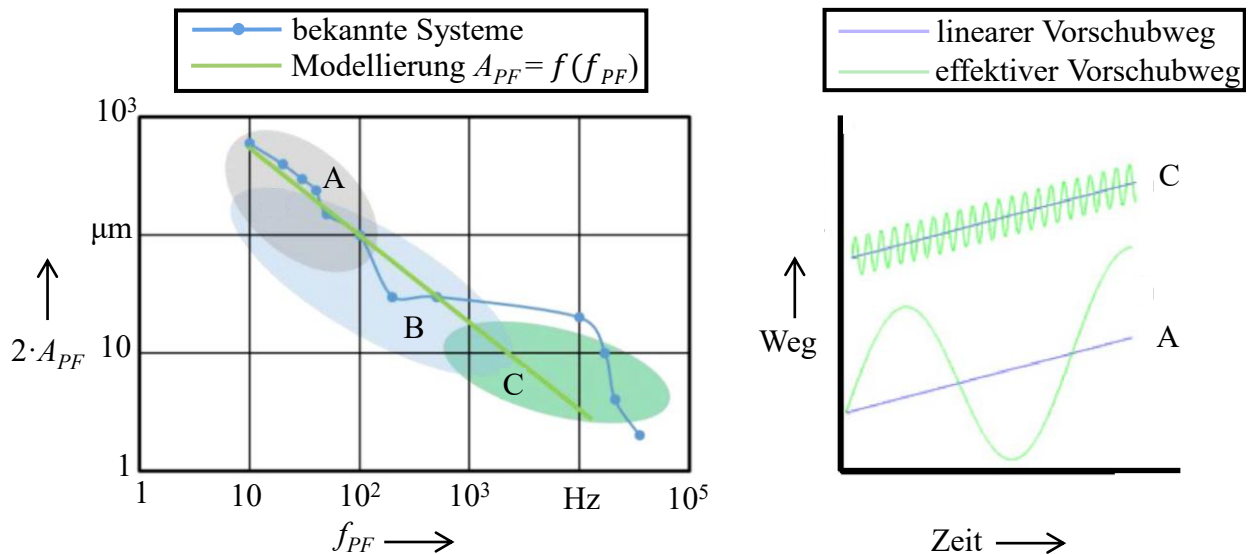


Abbildung A.3: Technologien für das vibrationsunterstützte Bohren nach [BK17], [Ble+18] (A_{PF} = Peck-Feed-Amplitude, f_{PF} = Peck-Feed-Frequenz; A = mechanische oder hydraulische Systeme; B = elektro-mechanische Aktuatoren; C = piezoelektrische Aktuatoren)

A.1.3 Maschinelles Lernen

In der Abbildung A.4 ist das Konzept *CRISP-ML(Q)* (*Cross-Industry Standard Process for the Development of Machine Learning Applications with Quality Assurance Methodology*) als Erweiterung von *CRISP-DM* visualisiert.

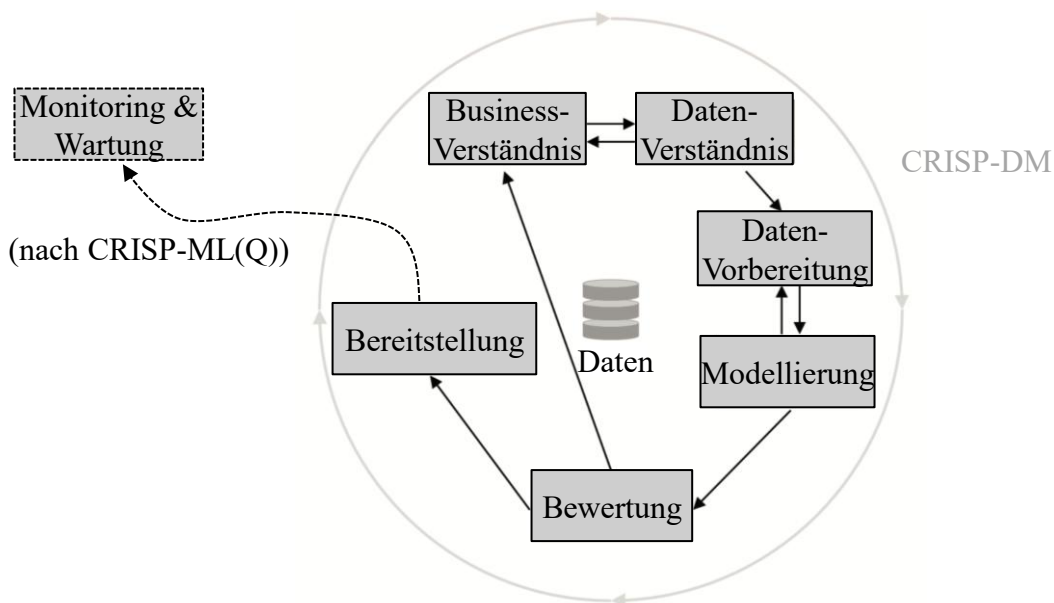


Abbildung A.4: Cross Industry Standard Process for Data Mining (CRISP-DM) und Cross-Industry Standard Process for the Development of Machine Learning Applications with Quality Assurance Methodology (CRISP-ML(Q)) nach [She00], [Stu+21]

Die Tabellen A.3 und A.4 stellen die mathematischen Definitionen und Wertebereiche wichtiger Evaluationskennzahlen der binären Klassifikation dar.

*Tabelle A.3: Evaluationskennzahlen der überwachten binären Klassifikation Teil 1
($TP/TN/FP/FN = \text{True Positive/True Negative/False Positive/False Negative-Vorhersage bei einer binären Klassifikation}$; $p_B = \text{Anzahl der Beispiele}$)*

Kennzahl	Symbol & Berechnung	Wertebereich [schlecht; gut]
Fehlerquote [Alp14]	$L_E = \frac{TP + TN}{p_B}$	[1; 0]
True Positive Rate [Alp14]	$TPR_E = \frac{TP}{TP + FN}$	[0; 1]
True Negative Rate [Run16]	$TNR_E = \frac{TN}{TN + FP}$	[0; 1]
Positive Predictive Value [Alp14]	$PPV_E = \frac{TP}{TP + FP}$	[0; 1]
False Discovery Rate [BH95]	$FDR_E = \frac{FP}{TP + FP}$	[1; 0]
Negative Predictive Value [Run16]	$NPV_E = \frac{TN}{TN + FN}$	[0; 1]
False Omission Rate [TVS10]	$FOR_E = \frac{FN}{TN + FN}$	[1; 0]
False Positive Rate [Alp14]	$FPR_E = \frac{FP}{FP + TN}$	[1; 0]
False Negative Rate [Alp14]	$FNR_E = \frac{FN}{FN + TP}$	[1; 0]

Tabelle A.4: Evaluationskennzahlen der überwachten binären Klassifikation Teil 2 (TP/TN/FP/FN = True Positive/True Negative/False Positive/False Negative-Vorhersage bei einer binären Klassifikation; PPV_E = Positive Predictive Value; TPR_E = True Positive Rate; TNR_E = True Negative Rate; FPR_E = False Positive Rate; p_B = Anzahl der Beispiele; β = Gewichtungsfaktor F-Score, welcher in dieser Arbeit zu β = 1 gesetzt wird (siehe dazu Abschnitt 2.3.4.2))

Kennzahl	Symbol & Berechnung	Wertebereich [schlecht; gut]
F-Score [GS21]	$FS_{c_E} = (1 + \beta^2) \frac{PPV_E \cdot TPR_E}{(\beta^2 \cdot PPV_E) + TPR_E}$	[0; 1]
Threat Score [Sch90]	$TS_E = \frac{TP}{TP + FN + FP}$	[0; 1]
Informedness [Pow20]	$Inf_E = \frac{TP}{TP + FN} - \frac{FP}{FP + TN}$	[-1; 1]
Markedness [Pow20]	$Mark_E = \frac{TP}{TP + FP} - \frac{FN}{FN + TN}$	[-1; 1]
Balanced Accuracy [Guy+06]	$BACC_E = \frac{TPR_E + TNR_E}{2}$	[0; 1]
Geometric Mean [Kub17]	$GM_E = \sqrt{TPR_E \cdot TNR_E}$	[0; 1]
Fowlkes-Mallows-Index [FM83]	$FM_E = \sqrt{TPR_E \cdot PPV_E}$	[0; 1]

Die Gleichungen A.1 und A.2 stellen jeweils die mathematischen Definitionen der Evaluationskennzahlen Matthews Correlation Coefficient MCC_E und Cohen's Kappa CK_E innerhalb der binären Klassifikation dar. Zur Definition der Eingangsvariablen, die auf den Einträgen der binären Konfusionsmatrix basieren, sei auf die Beschreibungen der Tabellen A.3 und A.4 verwiesen.

$$MCC_E = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP) \cdot (TP + FN) \cdot (TN + FP) \cdot (TN + FN)}} \quad (A.1)$$

$$CK_E = \frac{2 \cdot (TP \cdot TN - FN \cdot FP)}{(TP + FP) \cdot (FP + TN) + (TP + FN) \cdot (FN + TN)} \quad (A.2)$$

Die Tabelle A.5 stellt die mathematischen Definitionen und Wertebereiche wichtiger Evaluationskennzahlen der überwachten Regression dar.

Tabelle A.5: Evaluationskennzahlen der überwachten Regression ($p_B =$ Anzahl Datenbeispiele, $y_i =$ wahre Zielgröße, $\bar{y}_i =$ Durchschnitt wahre Zielgrößen, $\hat{y}_i =$ vorhergesagte Zielgröße)

Kennzahl	Symbol & Berechnung	Wertebereich [schlecht; gut]
Bestimmtheitsmaß [GS21]	$R_E^2 = 1 - \frac{\sum_{i=1}^{p_B} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{p_B} (y_i - \bar{y})^2}$	[0; 1]
Pearson-Korrelationskoeffizient [Jos19]	$R_{XY,E} = \frac{\sum_{i=1}^{p_B} (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^{p_B} (y_i - \bar{y})^2 \sum_{i=1}^{p_B} (\hat{y}_i - \bar{\hat{y}})^2}}$	[-1; 1]
relativer absoluter Fehler [Rei+16]	$RAE_E = \frac{\sum_{i=1}^{p_B} y_i - \hat{y}_i }{\sum_{i=1}^{p_B} y_i - \bar{y}_i }$	[0; ∞]
Wurzel des mittleren quadratischen Fehlers [Swa19]	$RMSE_E = \sqrt{\frac{1}{p_B} \sum_{i=1}^{p_B} (y_i - \hat{y}_i)^2}$	[0; ∞]
Wurzel des relativen mittleren quadratischen Fehlers [JPJ22]	$RRMSE_E = \sqrt{\frac{\frac{1}{p_B} \sum_{i=1}^{p_B} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{p_B} (\hat{y}_i)^2}}$	[0; ∞]
mittlere quadratische Abweichung [Jos19]	$MSE_E = \frac{1}{p_B} \sum_{i=1}^{p_B} (y_i - \hat{y}_i)^2$	[0; ∞]
mittlerer absoluter Fehler [Jos19]	$MAE_E = \frac{1}{p_B} \sum_{i=1}^{p_B} y_i - \hat{y}_i $	[0; ∞]
Median der absoluten Abweichung [Att25]	$MedA_E = \text{Median}(y_i - \hat{y}_i)$	[0; ∞]

In der Abbildung A.5 wird ein Beispiel des Bias-Varianz-Gleichgewichts in Abhängigkeit der ML-Modellkomplexität dargestellt.




Abbildung A.5: Varianz und Bias anhand eines Beispiel-Datensets aus [HTF09]

In der Abbildung A.6 ist ein Beispiel der diskreten Wavelet-Transformation dargestellt.




Abbildung A.6: Beispiel einer Wavelet-Transformation nach [Sam+99]

A.2 Bearbeitete Werkstoffe

A.2.1 Metallische Werkstoffe

In der Tabelle A.6 werden die Eigenschaften der bearbeiteten metallischen Werkstoffe beschrieben.

Tabelle A.6: Metallische Werkstoffe Al2024 [Hes16], [Eng18], [Wie18] und Ti64 (Ti-6Al-4V / Ti6Al4V / TiAl6V4) [Thy24], [Aer24]

		Al2024	Ti64
Basiselement		Aluminium	Titan
Alternativbezeichnung		AlC4uMg1	TiAl6V4
		4165	4911
		3.1354 - T4	3.7164.1
Probendicke h	[mm]	6	4,1
Dichte ρ	[g cm ⁻³]	2,77	4,43
E-Modul E	[GPa]	73	114
Zugfestigkeit R_m	[MPa]	≥ 400	≥ 895
Streckgrenze $R_{p0,2}$	[MPa]	≥ 270	≥ 830
Bruchdehnung A_B	[%]	≥ 8	≥ 10
Brinell-Härte HB	[HBW]	120	≤ 310
Poisson-Zahl ν	[-]	0,33	0,342
Wärmeleitfähigkeit λ	[W (m K) ⁻¹]	120	7,1

A.2.2 CFK-Werkstoffe

In der Tabelle A.7 werden die Eigenschaften der bearbeiteten CFK-Werkstoffe beschrieben.

Tabelle A.7: Eigenschaften bearbeiteter CFK-Werkstoffe [Mat24b], [Hex15], [Hex20], [Sho07, S. 131]

		CFK-D	CFK-T
Grundcharakteristik			
Aufbau		multiaxial	multiaxial
Faserorientierung	[°]	0° / 45° / 90° / 135°	-
Gesamtdicke h	[mm]	4,1	2,7
Prepregeigenschaften			
Bezeichnung		M21E-IMA-31-194	-
Typ		Laminat unidirektional	-
Faservol.-anteil φ_F	[%]	59,2	-
Fasergew.-anteil φ_M	[%]	66	-
Dichte ρ	[g cm ⁻³]	1,58	-
Lagendicke h_P	[mm]	0,184	-
Zug E-Modul längs $E_{ }$	[GPa]	178	-
Zugfestigkeit längs $R_{m }$	[MPa]	3050	-
Druck E-Modul längs $E_{ }$	[GPa]	146	-
Druckfestigkeit längs $R_{m }$	[MPa]	1500	-
Matrixeigenschaften			
Bezeichnung		Hexply [®] M21E	-
Polymerart		Duroplast	Thermoplast
Polymer		Epoxidharz	Polyphenylen- sulfid
Dichte ρ	[g cm ⁻³]	1,28	1,65
E-Modul E	[GPa]	3,5	3,9-4,3
Zugfestigkeit R_m	[MPa]	147	65-82
Bruchdehnung A_B	[%]	5	6,5
Fasereigenschaften			
Bezeichnung		Hextow [®] IMA	-
Dichte ρ	[g cm ⁻³]	1,79	-
Zug E-Modul $E_{ }$	[GPa]	298	-
Zugfestigkeit $R_{m }$ längs	[MPa]	6067	-
Bruchdehnung A_B	[%]	1,9	-
Faserdurchmesser D_f	[μm]	5,1	-

A.3 Eingesetzte Werkzeuge

In der Tabelle A.8 werden die Eigenschaften der eingesetzten Bohrwerkzeuge präsentiert.

Tabelle A.8: Eigenschaften verwendeter Bohrwerkzeuge im Neuzustand

KS-HB-04937-01 / KS-HB-04937-02		
Grundcharakteristik		
Bohrertyp		Wendelbohrer
Anschliffform		B [DIN 1412]
Hauptschneidenzahl		2 (symmetrische Anordnung)
Kühlung		Innenkühlkanal an jeder Schneide
Spanteiler		an jeder Schneide
Schneidstoff		
Materialgruppe		Vollhartmetall EMT210
Zusammensetzung		89 % Wolframcarbid; 10 % Cobalt
Klassifizierung		HF-N/S nach [DIN ISO 513]
Beschichtung		unbeschichtet / diamantbeschichtet 15 μm
Maße		
Nenn-Durchmesser D_{nom}	[mm]	6,352
Gesamtlänge l_1	[mm]	[87; 90]
Schneidlänge l_3	[mm]	[41; 44]
Geometrie		
Spitzenwinkel σ	$\left[^\circ\right]$	135
Seitenspanwinkel γ_f	$\left[^\circ\right]$	30
Seitenfreiwinkel α_f	$\left[^\circ\right]$	16
Schneidenabflachung Δr	$\left[\mu\text{m}\right]$	12,5 – 15

A.4 Versuchspläne

A.4.1 Versuchsreihengruppe P

Die Tabelle A.9 stellt den Versuchsplan zur Variation des Prozesszustands dar. Darin symbolisieren die geschweiften Klammern über mehrere Tabellenzeilen hinweg, dass der eingetragene Parameter über mehrere in Spalte 1 verzeichnete Versuchsreihen gilt.

Tabelle A.9: Versuchsplan Reihengruppe P („Anz.“ $\hat{=}$ Anzahl Bohrungen, „Wks.“ $\hat{=}$ Werkstoff, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, Werkzeug: KS-HB-04937-01)

Reihe/Anz.	Wkst.	v_c [$\frac{m}{min}$]	f [mm]	d_c [mm]	c_{CC} [-]	L [%]	A_{PF} [μm]	ext. Sensoren
P1a/20	Ti64	}20	}0,05	}57,5	}ja	}1	}125	} $S_{e,2-4}$
P1c/20	CFK-D							
P1d/20	CFK-T							
P1e/21	Ti64	15				100		$S_{e,2-4}$
P2a/20	}Al2024	20	}0,05	}57,5	}ja	}1	}125	} $S_{e,2-4}$
P2b/20		40						
P2c/20		60						
P3a/20	}Al2024	}40	0,03	}57,5	}ja	}1	}125	} $S_{e,2-4}$
P3c/20			0,08					
P4b/20	}Al2024	}40	}0,05	}57,5	}ja	}1	62,5	} $S_{e,2-4}$
P4c/20							0	
P5a/20	}Al2024	}40	}0,05	}57,5	}ja	0	}125	} $S_{e,2-4}$
P5c/20						100		
P6a/20	}Al2024	20	}0,05	}57,5	}nein	}1	}125	} $S_{e,2-4}$
P6b/20		40						
P6c/20		60						
P7b/20	}Al2024	}40	}0,05	81,5	}ja	}1	}125	} $S_{e,2-4}$
P7c/20				105,5				
P8a/20	Al2024	20	0,08	81,5	ja	1	125	$S_{e,2-4}$
P9b/10	}Al2024	}40	}0,05	81,5	}nein	}1	}125	} $S_{e,2-4}$
P9c/10				101,5				

A.4.2 Versuchsreihengruppe Q-Ti64

Die Tabelle A.10 stellt den Versuchsplan zur Bearbeitung des Titanwerkstoffs Ti64 dar. Darin symbolisieren die geschweiften Klammern über mehrere Tabellenzeilen hinweg, dass der eingetragene Parameter über mehrere in Spalte 1 verzeichnete Versuchsreihen gilt.

Tabelle A.10: Versuchsplan Reihengruppe Q-Ti64 („Anz.“ $\hat{=}$ Anzahl Bohrungen, „Wks.“ $\hat{=}$ Werkstoff, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, Werkzeug: KS-HB-04937-01)

Reihe/Anz.	Wks.	v_c [$\frac{m}{min}$]	f [mm]	d_c [mm]	c_{CC} [-]	L [%]	A_{PF} [μm]	ext. Sensoren
Q1/225	Ti64	15	0,05	0	nein	100	62,5	} $S_{e,1-4}$
Q1a/24								
Q1b/20		15	0,05		nein		62,5	
Q1c/21								
Q1d/20								
Q1e/20								

A.4.3 Versuchsreihengruppe Q-CFK-D

Die Tabelle A.11 stellt den Versuchsplan zur Bearbeitung des Materials CFK-D (CFK-Material mit duromerer Matrix) dar. Darin symbolisieren die geschweiften Klammern über mehrere Tabellenzeilen hinweg, dass der eingetragene Parameter über mehrere in Spalte 1 verzeichnete Versuchsreihen gilt.

Tabelle A.11: Versuchsplan Reihengruppe Q-CFK-D („Anz.“ $\hat{=}$ Anzahl Bohrungen, „Wks.“ $\hat{=}$ Werkstoff, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, Werkzeug: KS-HB-04937-01)

Reihe/Anz.	Wks.	v_c [$\frac{m}{min}$]	f [mm]	d_c [mm]	c_{CC} [-]	L [%]	A_{PF} [μm]	ext. Sensoren
Q2/225	CFK-D	120	0,06	0	nein	1	0	} $S_{e,1},$ $S_{e,2},$ $S_{e,4}$
Q2a/20		60	0,1					
Q2b/20		15	0,05		62,5			
Q2c/21		120	0,03			1	0	
Q2d/20		90	0,06		ja			
Q2e/20		120						

A.4.4 Versuchsreihengruppe Q-Al2024

Die Tabelle A.12 stellt den Versuchsplan zur Bearbeitung des Aluminiumwerkstoffs Al2024 dar. Darin symbolisieren die geschweiften Klammern über mehrere Tabellenzeilen hinweg, dass der eingetragene Parameter über mehrere in Spalte 1 verzeichnete Versuchsreihen gilt.

Tabelle A.12: Versuchsplan Reihengruppe Q-Al2024 („Anz.“ $\hat{=}$ Anzahl Bohrungen, „Wks.“ $\hat{=}$ Werkstoff, v_c = Schnittgeschwindigkeit, f = Vorschub pro Umdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, Werkzeug: KS-HB-04937-01)

Reihe/Anz.	Wks.	v_c [$\frac{\text{m}}{\text{min}}$]	f [mm]	d_c [mm]	c_{CC} [-]	L [%]	A_{PF} [μm]	ext. Sensoren
Q3/25	Al2024	60	0,1	0	ja	100	125	$S_{e,1-3}$
Q3a/20		40	0,07					
Q3b/20		120	0,06					
Q3c/20		15	0,05			100	62,5	
Q3d/20		80						
Q3e/20		60	0,1			105,5	100	

A.4.5 Versuchsreihengruppe A

Die Tabelle A.13 stellt den Versuchsplan zur Bearbeitung unterschiedlicher Werkstoffe mit gezielter Einbringung von Bohranomalien dar. Darin symbolisieren die geschweiften Klammern über mehrere Tabellenzeilen hinweg, dass der eingetragene Parameter über mehrere in Spalte 1 verzeichnete Versuchsreihen gilt.

Tabelle A.13: Versuchsplan Reihengruppe A („Anz.“ $\hat{=}$ Anzahl Bohrungen, „Wks.“ $\hat{=}$ Werkstoff, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude, Werkzeug Reihen A1-A4: KS-HB-04937-01, Werkzeug Reihe A5: KS-HB-04937-02)

Reihe/Anz.	Wks.	v_c [$\frac{\text{m}}{\text{min}}$]	f_n [mm]	d_c [mm]	c_{CC} [-]	L [%]	A_{PF} [μm]	ext. Sensoren
A1/100	Ti64	15	0,05	0	ja	100	62,5	$S_{e,1-3}$
A2/100	CFK-D	120	0,06			1	0	$S_{e,1-2}$
A3/100	Al2024	60	0,1			100	125	$S_{e,1-3}$
A4/20	CFK-T	120	0,06			1	0	$S_{e,1-2}$
A5/20	Al2024	60	0,1			100	125	$S_{e,1-3}$

A.5 Bohrungsanomalien

In der Abbildung A.7 sind die während der Versuchsdurchführung eingebrachten Anomalien in den unterschiedlichen Werkstoffen visualisiert.

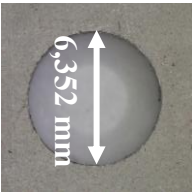
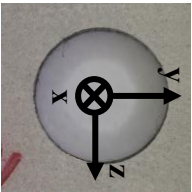
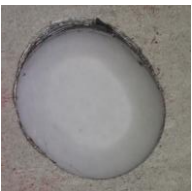

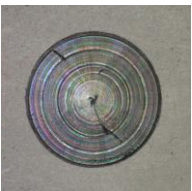
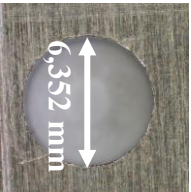




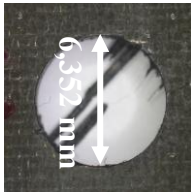
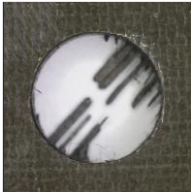



Werkstoff	keine Anomalie	doppelt	Anomalie angebohrt	schräg	nicht durch
Ti64					
Al2024					
CFK-D/T					
Erklärung und Häufigkeit	1563	in bestehende Bohrung gebohrt; 11x insgesamt	vorherige Bohrung angebohrt, 12x insgesamt	Bohrerachse gekippt; 9x insgesamt	Werkstück nicht durchgebohrt; 18x insgesamt
Umsetzung in Versuchsreihen A1-A5	-	Bohrprobe nicht weitergeschoben	Bohrprobe nicht ausreichend weitergeschoben	Werkstück um z-Achse geneigt eingespannt (~3°)	verkürzter Vorschubweg im Bohrprogramm

Abbildung A.7: Erzeugte Bohranomalien nach [Sch29]

A.6 Beispielprotokoll der Rauigkeitsmessung

Das Protokoll in der Abbildung A.8 stellt eine Beispiel-Rauigkeitsmessung mit dem Perthometer MarSurfGD 120 dar. Der dargestellte Profilverlauf wird als eine Tabellendatei zusätzlich separat exportiert. Aus dem Protokoll können die Rauigkeitskennzahlen Ra und Rz direkt entnommen werden.

A.6: BEISPIELPROTOKOLL DER RAUIGKEITSMESSUNG



	MarWin 9.00-17 SP 1	QE Rauheit Aufgabe: "Rauheit"		11.12.2023 1 12:58:35 Prüfer: Denys Romanenko Unterschrift:
	Teil:	Zeichnungs-Nr.:	Bearbeitungsschritt:	A1_1_90Grad
Kommentar:				
Messgerät: MarTalk Vorschubgerät: DriveUnit.GD 120 Taster: BFW A 4-45-2/90 20559		Lt: 2.99 mm Ls: 2.50 µm VB: +/-250.0 µm Vt: 0.50 mm/s Punkte: 5979		
Rauheit1: P; R[LC GS 0.25 mm]; 				
Rauheit2: P; R[LC GS 0.25 mm]; 				
Rauheitskennwerte - Rauheit1: P; R[LC GS 0.25 mm];				
Ra	0,4694 µm	0,0000		0,0000
Rz	3,0566 µm	0,0000		0,0000
Rauheitskennwerte - Rauheit2: P; R[LC GS 0.25 mm];				
Ra	0,4711 µm	0,0000		0,0000
Rz	3,0822 µm	0,0000		0,0000
	Ra		Rz	
	µm		µm	
Mittelwert		0,4703		3,0694

Abbildung A.8: Beispiel-Messprotokoll der Rauigkeitsmessung der 1. Bohrung aus der Versuchsreihe A1 (siehe Parameter in der Tabelle A.13 des Anhangs A.4.5) mit dem Perthometer MarSurfGD 120

A.7 ML-ADU-Monitor Umgebung

A.7.1 Ordnerstruktur Softwareumgebung

Die Abbildung A.9 stellt die Ordnerstruktur der Softwareumgebung ML-ADU-Monitor dar.

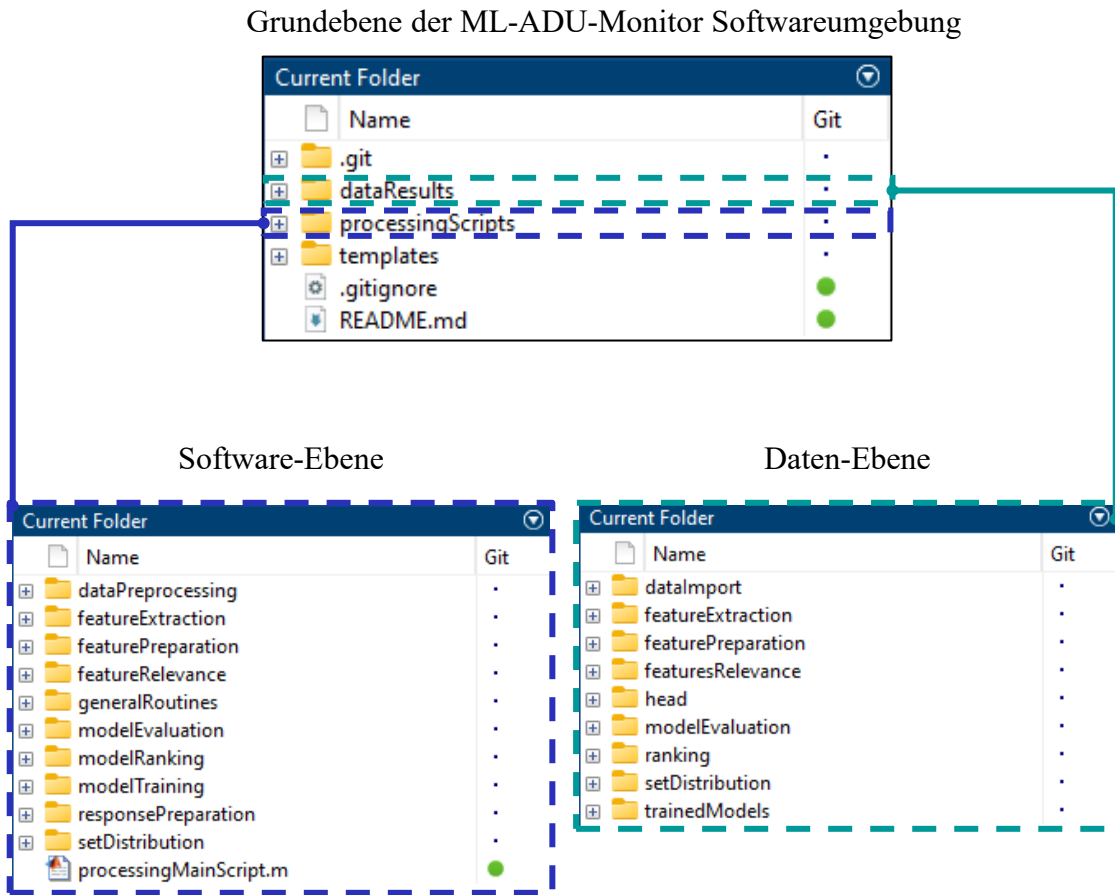


Abbildung A.9: Ordnerstruktur ML-ADU-Monitor Softwareumgebung

A.7.2 Hardwareumgebung

Die Tabelle A.14 stellt die eingesetzte Hardware bei der Datenverarbeitung und ML-Modellierung dar.

Tabelle A.14: Hardware-Spezifikationen des eingesetzten Tower-PC

Attribut	Spezifikation
Betriebssystem	Microsoft Windows 10
RAM physisch	16 GB
RAM virtuell	32 GB
CPU	Intel(R) Xeon(R) W-2125 CPU @ 4.GHz, 4 Kerne
GPU	Nvidia Quadro P620

A.8 Import von Sensorgrößen

A.8.1 Interne Sensorgrößen

In der Abbildung A.10 wird der Import interner Sensordaten dargestellt.

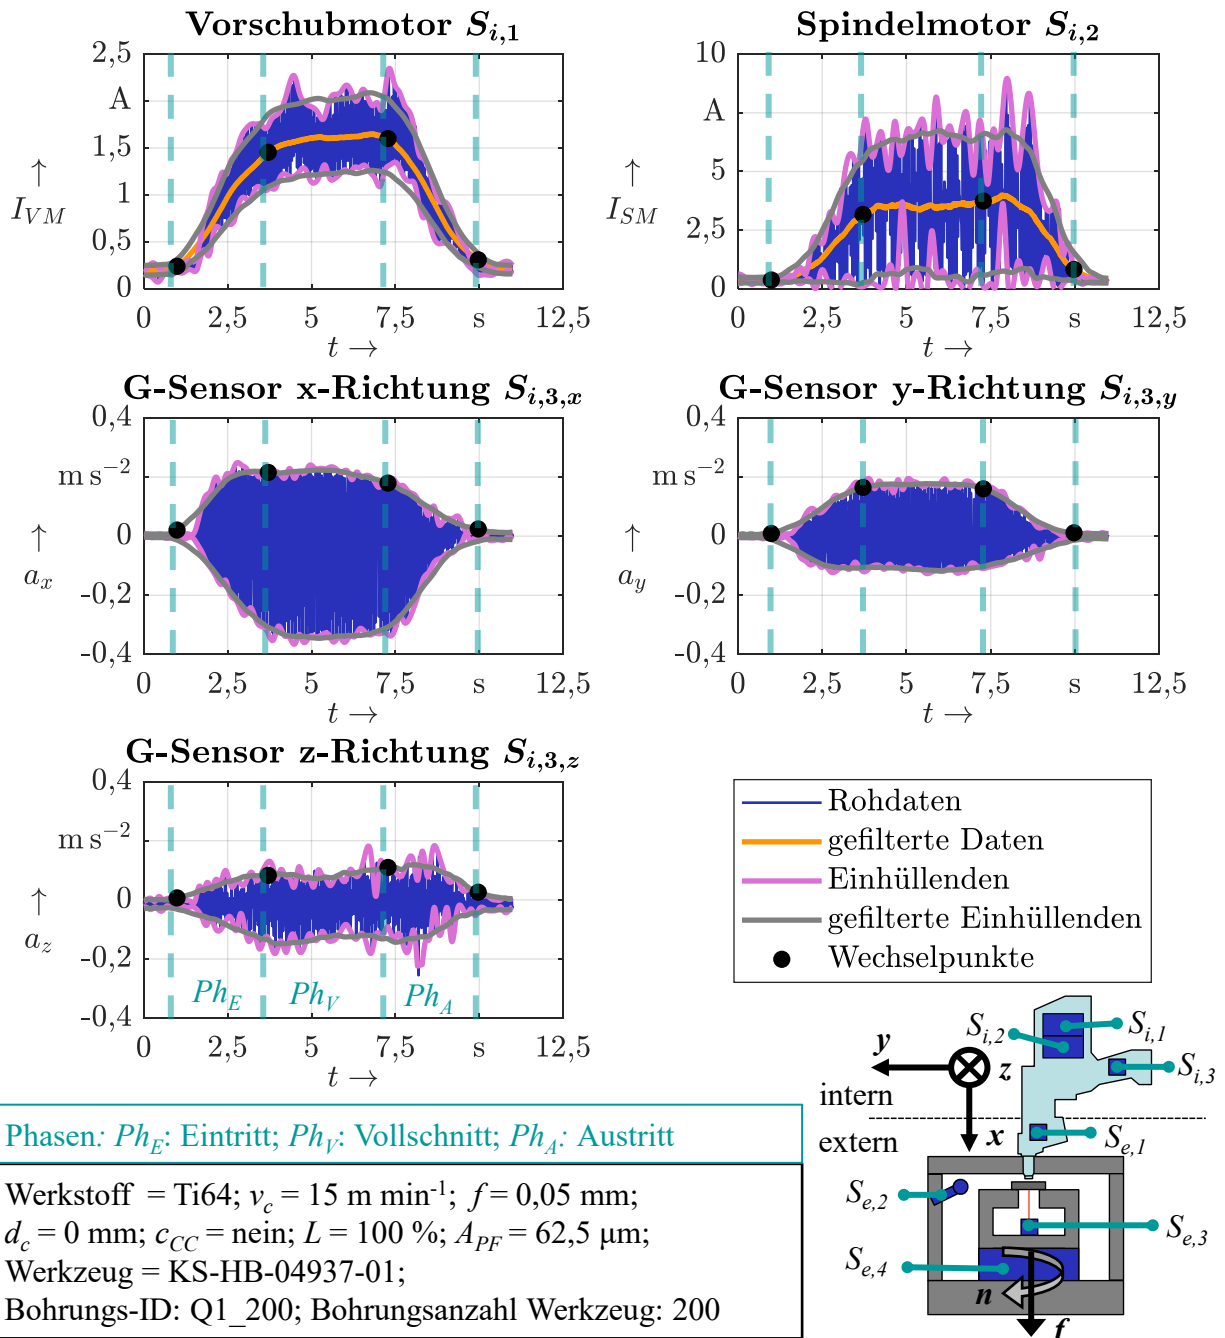
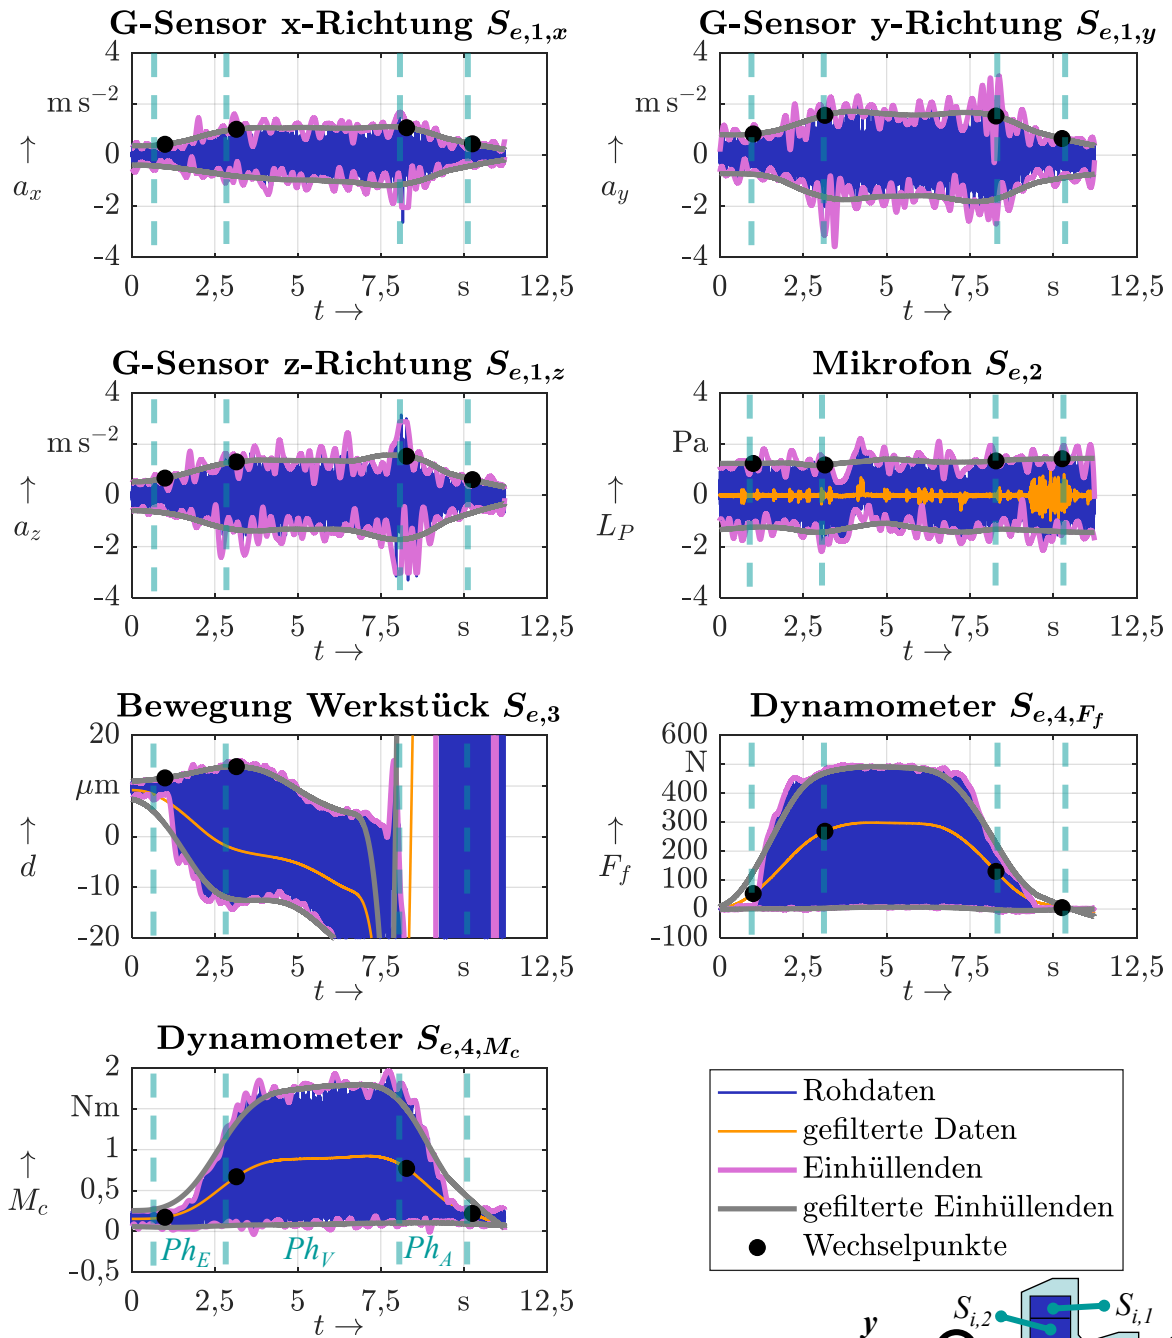


Abbildung A.10: Beispiel für den Import interner Sensorgrößen anhand der Bohrung Q1_200 nach [Jun22b] (I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z}$ = Beschleunigung in x/y/z-Richtung, t = Zeit, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, c_{CC} = Kontaktzustand zwischen Werkstück und Concentric Collet, L = Schmierzustand, A_{PF} = Peck-Feed-Amplitude)

A.8.2 Externe Sensorgrößen

In der Abbildung A.11 wird der Import externer Sensordaten dargestellt. In der Abbildung A.11 sind beim Sensor $S_{e,3}$ zur Erfassung der Werkstückbewegung d die Wechsellpunkte 3 und 4 nicht dargestellt, da zu dieser Zeit der Bohrer durch das Material durchgetreten ist und damit die Werkstückbewegung d mit dem Lasersensor nicht mehr auf der Werkstückoberfläche erfasst werden kann.



Phasen: Ph_E : Eintritt; Ph_V : Vollschnitt; Ph_A : Austritt

Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$;
 $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 100 \%$; $A_{PF} = 62,5 \mu\text{m}$;
 Werkzeug = KS-HB-04937-01;
 Bohrungs-ID: Q1_200; Bohrungsanzahl Werkzeug: 200




Abbildung A.11: Beispiel für den Import externer Sensorgrößen anhand der Bohrung Q1_200 nach [Jun22b](aufgrund der Platzverhältnisse wird auf die Variablenerklärungen in der Abbildung A.10 verwiesen)

A.9 Feature-Definition

A.9.1 Pfade der Feature-Extraktion

In der Tabelle A.15 sind die einzelnen Möglichkeiten der Kombinationsstufen zu den Datenquellen der Feature-Extraktion aufgelistet.

Tabelle A.15: Kombinationsstufen der Pfade zur Feature-Extraktion (I_{VM} = Vorschubmotor-Strom, I_{SM} = Spindelmotor-Strom, $a_{x/y/z,ADU}$ = Beschleunigungswerte interner SmartADU-G-Sensor in x/y/z-Richtung, $a_{x/y/z,ext}$ = Beschleunigungswerte externer G-Sensor in x/y/z-Richtung, L_P = Schalldruck, d = Distanzmessung zur Werkstück-Oberfläche (Indikator für Werkstückbewegung))

Kombinationsstufe	Möglichkeiten
Sensorgroße	I_{VM} ; I_{SM} ; $a_{x/y/z,ADU}$; $a_{x/y/z,ext}$; L_P ; d
Datenrepräsentation	Rohdaten, gefilterte Daten, obere Einhüllende ungefiltert/gefiltert, untere Einhüllende ungefiltert/gefiltert
Bohrphase	Eintritt, Vollschnitt, Austritt, Gesamtbohrung, Messvektor
Domäne	Zeit-, Frequenz-, Spektral-, Wavelet-, Bilddomäne

A.9.2 Wechsellpunkt-Bestimmung

Anhand des Pseudo-Codes A.1 ist die Wechsellpunkt-Bestimmung für die Sensordaten dargestellt.


In der Abbildung A.12 ist Beispiel für eine anomale Bohrung ohne Bohrphasen-Identifikation visualisiert.

```

1 // Pseudo-Code zur Bestimmung der Wechsellpunkte
2
3 // Einstellungen
4 SENSORDATEN = [I_VM_GEFILTERT, aXADU_EINHUELLENDE_OBEN_GEFILTERT]
5 WECHSELPUNKT_METHODEN = [linear, meanval, stdev, rms]
6 I = 0;
7 J = 0;
8 WECHSELPUNKT_LOGIK = "nein";
9
10 // Schleife über Sensordaten
11 wiederhole bis (WECHSELPUNKT_LOGIK = "ja" oder I == 2)
12 I = I + 1;
13 SENSOR = SENSORDATEN(I)
14 // Schleife über Identifikationsmethode der Wechsellpunkte
15 wiederhole bis (WECHSELPUNKT_LOGIK = "ja" oder J == 4)
16 J = J + 1
17 METHODE = WECHSELPUNKT_METHODEN(J)
18 // Nutzen der MATLAB-Funktion; Ausgabe = "ja" oder "nein"
19 WECHSELPUNKT_ID = findchangepts(SENSOR,METHODE)
20 // Validierung Ergebnis; Ausgabe = "ja" oder "nein"
21 WECHSELPUNKT_LOGIK = validierung(WECHSELPUNKT_ID)
22 ende
23 ende

```

Quellcode A.1: Pseudo-Code zur Bestimmung der Wechsellpunkte an internen Sensordaten



Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{ja}$; $L = 100 \%$;
 $A_{PF} = 62,5 \text{ } \mu\text{m}$; Werkzeug = KS-HB-04937-01; Bohrungs-ID: A1_48;
 Bohrungsanzahl Werkzeug: 48; Anomalie: nicht durch

Abbildung A.12: Beispiel für eine anomale Bohrung ohne Bohrphasen-Identifikation (I_{VM} = Spindelmotorstrom, t = Zeit, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, c_{CC} = Kontaktzustand zwischen Werkstück und Concentric Collet, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

A.9.3 Zeit-Domäne

In der Tabelle A.16 sind die einzelnen Features der Zeit-Domäne spezifiziert.

Tabelle A.16: Feature-Definition in der Zeit-Domäne

Definition	MATLAB-Implementierung
Durchschnitt	<i>mean(...)</i>
Durchschnitt der Beträge	<i>mean(abs(...))</i>
Standardabweichung	<i>std(...)</i>
Varianz	<i>var(...)</i>
Median	<i>median(...)</i>
Spannweite	<i>range(...)</i>
Nulldurchgangsrate	<i>zerocrossrate(...)</i>
mittlere absolute Abweichung	<i>mad(...)</i>
mittlere absolute Abweichung vom Median	<i>mad(...,1)</i>
Wölbung	<i>kurtosis(...)</i>
Schiefe	<i>skewness(...)</i>
quadratisches Mittel	<i>rms(...)</i>
quadriertes quadratisches Mittel	<i>rms(...)^2</i>
Interquartilsabstand	<i>iqr(...)</i>
Minimalwert	<i>min(...)</i>
Maximalwert	<i>max(...)</i>
Minimum der Beträge	<i>min(abs(...))</i>
Maximum der Beträge	<i>max(abs(...))</i>
Durchschnitt der 100 größten Werte	<i>mean(maxk(...,100))</i>
Durchschnitt der 100 größten Beträge	<i>mean(maxk(abs(...),100))</i>
Durchschnitt der 100 kleinsten Werte	<i>mean(mink(...,100))</i>
Durchschnitt der 100 kleinsten Beträge	<i>mean(mink(abs(...),100))</i>
Steigung	<i>(Daten(end) - Daten(1))/delta_t</i>
Integral der Datenkurve	<i>trapz(...)</i>
Integral der Datenkurve pro Zeit	<i>trapz(...)/delta_t</i>
Integral der Datenkurve (Betragwerte)	<i>trapz(abs(...))</i>
Integral der Datenkurve (Betragwerte) / Zeit	<i>trapz(abs(...))/delta_t</i>
Maximalwert / quadratisches Mittel	<i>peak2rms(...)</i>
Formfaktor	<i>rms(...)/mean(...)</i>
Puls-Indikator	<i>max(abs(...))/mean(...)</i>
Randbreite	<i>max(abs(...))/sum(sqrt(abs(...)))/length(...)^2</i>

A.9.4 Frequenz-Domäne

Der Quellcode A.2 stellt die Berechnungsschritte der umgesetzten Fast-Fourier-Transformation dar.

```
1 % Berechnung Amplitudenspektrum
2 Fs = 1 / mean(diff(timeDurationIns), 'omitmissing'); % Abtastrate
3 l = length(timeDurationIns); % Anzahl Datenpunkte
4 dataFFT = fft(data); % Ausführung FFT
5 dataFFTAmp = abs(dataFFT/l); % Amplitudenberechnung und Zurück-
   Skalierung
6 % ("fft" skaliert sie hoch um Anzahl der Datenpunkte)
7 dataFFTAmp = dataFFTAmp(1:round(l/2)+1); % Entnehmen der positiven
   Frequenzen
8 dataFFTAmp(2:end - 1) = 2* dataFFTAmp(2:end - 1); % einseitiges
   Spektrum.
9 f = (0:round(l/2))*Fs/l; % Anpassung Frequenzvektor
```

Quellcode A.2: Berechnung des Amplitudenspektrums

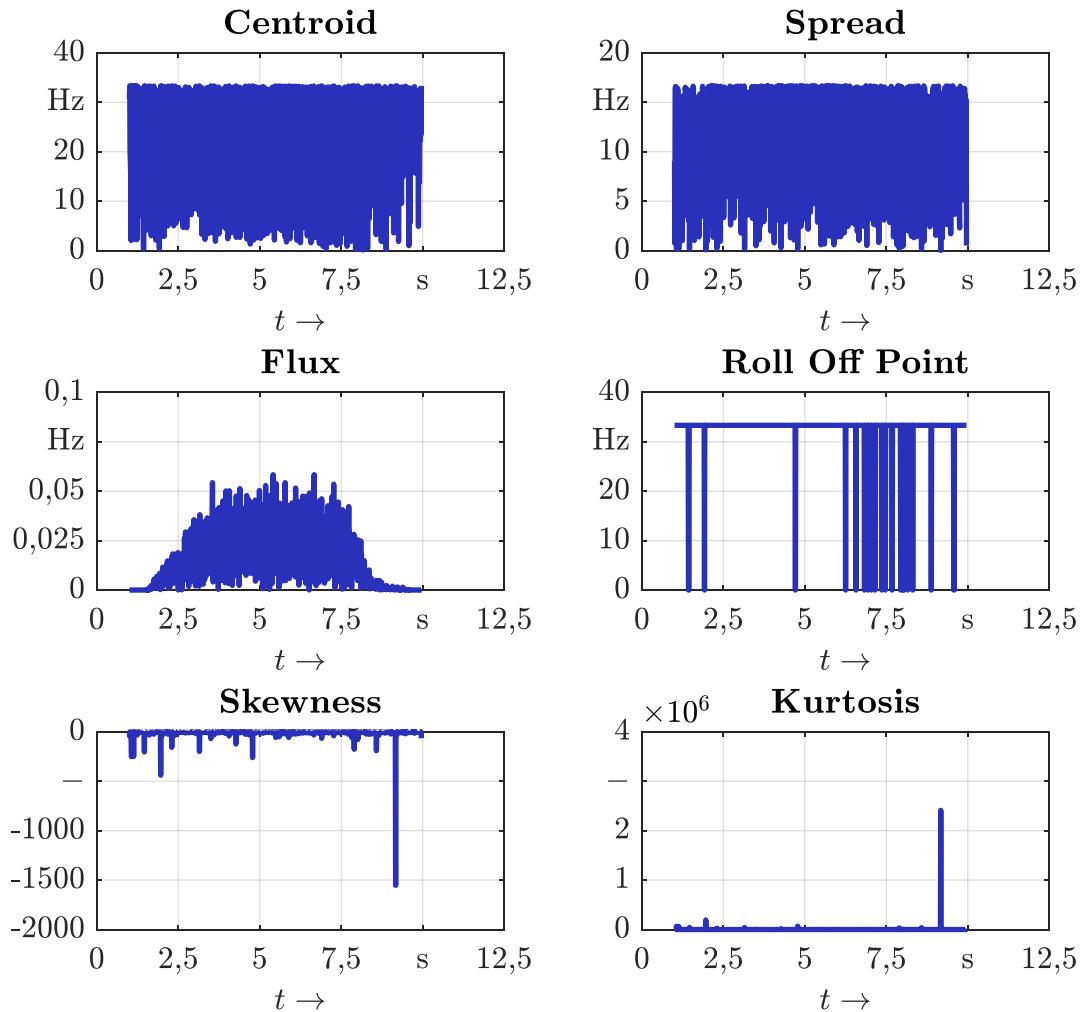
In der Tabelle A.17 sind die einzelnen Features der Frequenz-Domäne spezifiziert.

Tabelle A.17: Feature-Definition in der Frequenz-Domäne

Definition	MATLAB-Implementierung
Signalleistung vor FFT	<i>bandpower(...)</i>
Durchschnitt normalisierte Frequenz vor FFT	<i>meanfreq(...)</i>
Median normalisierte Frequenz vor FFT	<i>medfreq(...)</i>
Durchschnitt 5 größten Amplituden	Eigenfunktion
Durchschnitt 5 größten Frequenzen	Eigenfunktion
Durchschnitt der Frequenzen	<i>mean(...)</i>
Median der Frequenzen	<i>median(...)</i>
Varianz der Frequenzen	<i>var(...)</i>
Spannweite der Frequenzen	<i>range(...)</i>
Durchschnitt der Amplituden	<i>mean(...)</i>
Standardabweichung Amplitude	<i>std(...)</i>
Median Amplitude	<i>median(...)</i>
Varianz Amplitude	<i>var(...)</i>
Signalleistung Amplitude	<i>bandpower(...)</i>
Schiefe Amplitude	<i>skewness(...)</i>
quadratisches Mittel Amplitude	<i>rms(...)</i>
Spannweite Amplitude	<i>range(...)</i>
mittlere absolute Abweichung d. Amplitude	<i>mad(...)</i>
mittlere absolute Abweichung vom Median der Amplitude	<i>mad(...,1)</i>
Interquartilsabstand Amplitude	<i>iqr(...)</i>
Minimalwert Amplitude	<i>min(...)</i>
Maximalwert Amplitude	<i>max(...)</i>
Summe der Amplitudenwerte	<i>sum(...)</i>
Min./Max.-Verhältnis Amplitude	<i>min(...)/max()</i>
Wölbung Amplitude	<i>kurtosis(...)</i>

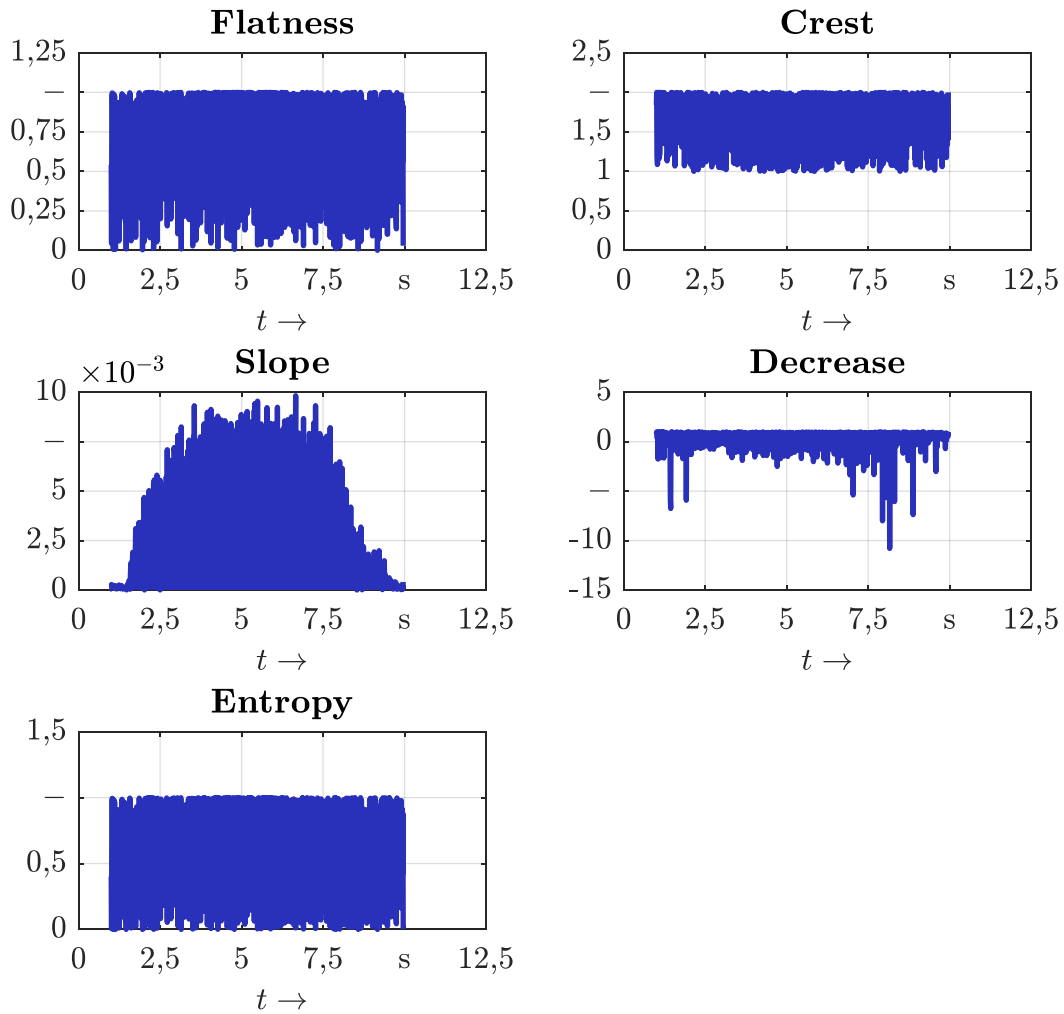
A.9.5 Spektral-Domäne

In den Abbildungen A.13 und A.14 sind die 11 durchgeführten Transformationen in die Spektral-Domäne, die in der MATLAB *Audio Toolbox* implementiert sind, beispielhaft aufgezeigt [Mat24c]. Aufgrund der teilweise nicht vorhandenen deutschen Bezeichnungen sind die Beschriftungen darin in den englischen Originalbezeichnungen gelassen.



Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 100 \%$;
 $A_{PF} = 62,5 \text{ }\mu\text{m}$; Werkzeug = KS-HB-04937-01; Bohrungs-ID: Q1_200;
 Bohrungsanzahl Werkzeug: 200

Abbildung A.13: Transformation in die Spektral-Domäne für die Bohrphase Gesamtbohrung Ph_g , Teil 1 (die Größen auf der y-Achse entsprechen den Überschriften der Teildiagramme; t = Zeit, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontaktzustand zwischen Werkstück und Concentric Collet, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)



Werkstoff = Ti64; $v_c = 15 \text{ m min}^{-1}$; $f = 0,05 \text{ mm}$; $d_c = 0 \text{ mm}$; $c_{CC} = \text{nein}$; $L = 100 \%$;
 $A_{PF} = 62,5 \text{ } \mu\text{m}$; Werkzeug = KS-HB-04937-01; Bohrungs-ID: Q1_200;
 Bohrungsanzahl Werkzeug: 200

Abbildung A.14: Transformation in die Spektral-Domäne für die Bohrphase Gesamtbohrung Ph_g , Teil 2 (die Größen auf der y-Achse entsprechen den Überschriften der Teildiagramme; t = Zeit, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, c_{CC} = Kontaktzustand zwischen Werkstück und Concentric Collet, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

In der Tabelle A.18 sind die einzelnen Features der Spektral-Domäne spezifiziert.

Tabelle A.18: Feature-Definition in der Spektral-Domäne

Definition	MATLAB-Implementierung
Durchschnitt	<code>mean(...)</code>
Standardabweichung	<code>std(...)</code>
Median	<code>median(...)</code>
Varianz	<code>var(...)</code>
Schiefe	<code>skewness(...)</code>
Spannweite	<code>range(...)</code>
quadratisches Mittel	<code>rms(...)</code>
mittlere absolute Abweichung	<code>mad(...)</code>
mittlere absolute Abweichung vom Median	<code>mad(...,1)</code>
Interquartilsabstand	<code>iqr(...)</code>
Minimalwert	<code>min(...)</code>
Maximalwert	<code>max(...)</code>
Summe	<code>sum(...)</code>
Min./Max.-Verhältnis	<code>min(...)/max()</code>
Wölbung	<code>kurtosis(...)</code>

A.9.6 Wavelet-Domäne

Der Quellcode A.3 stellt die Berechnungsschritte der Wavelet-Koeffizienten dar.

```

1 % "data" = Datenvektor Sensorgröße
2 % "Fs" = Abtastrate
3 sf = waveletScattering('SignalLength', numel(data), 'SamplingFrequency',
   ,Fs, 'QualityFactors', [8 1]); % Erstellung Netzwerk für die Wavelet
   Scattering Deposition mit dem Gabor (analytisches Morlet)
   Wavelet
4 smat = featureMatrix(sf, data); % Erstellung der Wavelet-
   Koeffizienten

```

Quellcode A.3: Extraktion von Features in der Wavelet-Domäne

In der Tabelle A.19 sind die einzelnen Features der Wavelet-Domäne spezifiziert.

Tabelle A.19: Feature-Definition in der Wavelet-Domäne

Definition	MATLAB-Implementierung
Durchschnitt	<code>mean(...)</code>
Durchschnitt Betragwerte	<code>mean(abs(...))</code>
Standardabweichung	<code>std(...)</code>
Median	<code>median(...)</code>
Varianz	<code>var(...)</code>
Spannweite	<code>range(...)</code>
mittlere absolute Abweichung	<code>mad(...)</code>
mittlere absolute Abweichung vom Median	<code>mad(...,1)</code>
Wölbung	<code>kurtosis(...)</code>
Schiefe	<code>skewness(...)</code>
quadratisches Mittel	<code>rms(...)</code>
quadriertes quadratisches Mittel	<code>rms(...)^2</code>
Interquartilsabstand	<code>iqr(...)</code>
Minimalwert	<code>min(...)</code>
Minimalwert der Betragwerte	<code>min(abs(...))</code>
Maximalwert	<code>max(...)</code>
Form-Faktor	<code>rms(...)/mean(...)</code>
Puls-Indikator	<code>max(abs(...))/mean(...)</code>
Randbreite	<code>max(abs(...))/ sum(sqrt(abs(...)))/length(...)^2</code>

A.9.7 Bild-Domäne

Die Erstellung der Bildrepräsentation wird anhand des vereinfachten MATLAB-Codes A.4 methodisch erklärt.

```

1 % "data" = Datenvektor Sensorgröße
2 data = downsample(data,15); % Absenken der Abtastfrequenz um Faktor
   15 und damit Kürzen der Vektorlänge
3 s = spectrogram(data, 'yaxis'); % Matrix der Short-Time-Fourier-
   Transformation
4 ampl = abs(s).^2; % Berechnung der Amplitudenwerte
5 grayImage = mat2gray(ampl); % Konvertierung der Matrixwerte in ein
   Graubild mit min/max-Werten: 0 / 1
6 grayImage = imresize(grayImage, finalFigureSize, Method='bicubic');
   % Konvertieren auf ein 10x10 Bild
7 grayImage = 255*im2double(grayImage); % Transformation auf
   Standardskala

```

Quellcode A.4: Extraktion von Features in der Bild-Domäne

In der Tabelle A.20 sind die einzelnen Features der Bild-Domäne spezifiziert.

Tabelle A.20: Feature-Definition in der Bild-Domäne

Definition	MATLAB-Implementierung
Durchschnitt	<i>mean(...)</i>
Durchschnitt Betragwerte	<i>mean(abs(...))</i>
Standardabweichung	<i>std(...)</i>
Median	<i>median(...)</i>
Varianz	<i>var(...)</i>
Spannweite	<i>range(...)</i>
mittlere absolute Abweichung	<i>mad(...)</i>
mittlere absolute Abweichung vom Median	<i>mad(...,1)</i>
Wölbung	<i>kurtosis(...)</i>
Schiefe	<i>skewness(...)</i>
quadratisches Mittel	<i>rms(...)</i>
quadriertes quadratisches Mittel	<i>rms(...)^2</i>
Interquartilsabstand	<i>iqr(...)</i>
Minimalwert	<i>min(...)</i>
Minimalwert der Betragwerte	<i>min(abs(...))</i>
Maximalwert	<i>max(...)</i>
Form-Faktor	<i>rms(...)/mean(...)</i>
Puls-Indikator	<i>max(abs(...))/mean(...)</i>
Randbreite	<i>max(abs(...))/ sum(sqrt(abs(...)))/length(...)^2</i>

A.9.8 Feature-Matrix

In der Abbildung A.15 kann die Zusammensetzung der Feature-Matrix eingesehen werden.

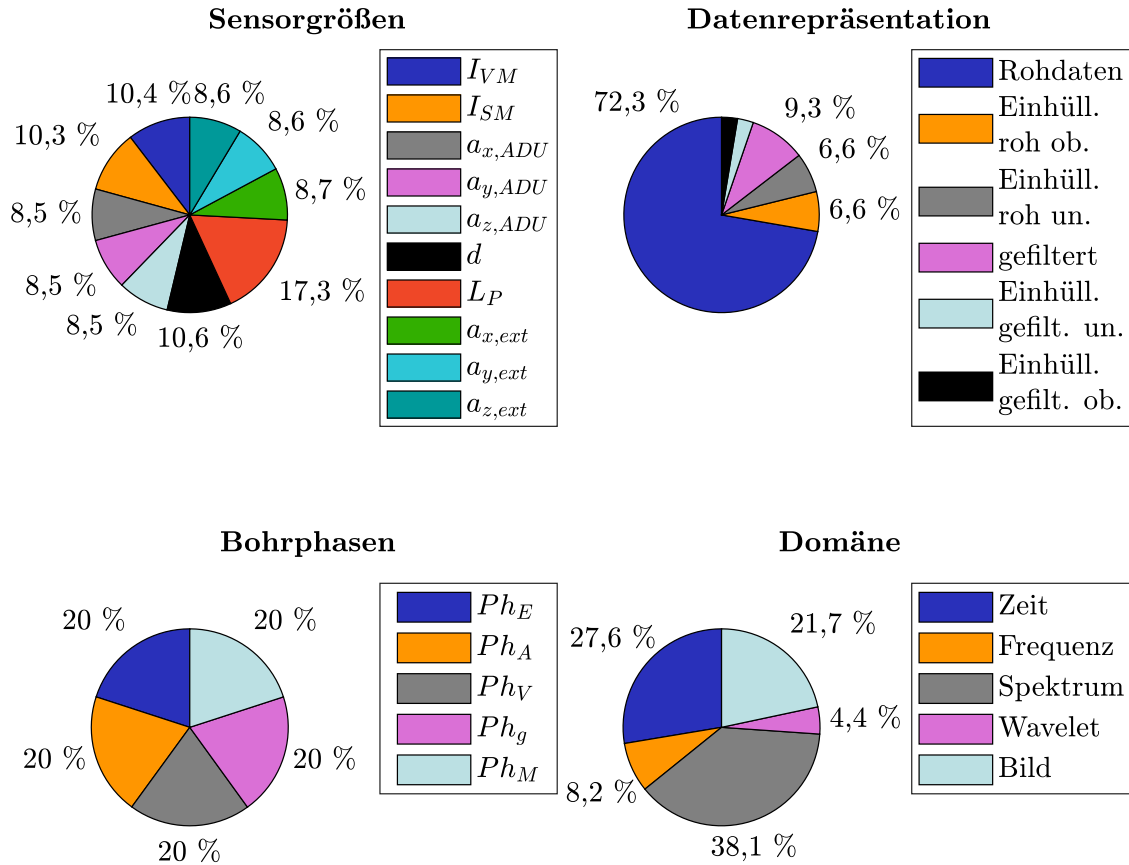


Abbildung A.15: Statistik der Feature-Matrix: Anteil jeder Gruppe der Feature-Vorbereitungs-Pfade an der Gesamtanzahl von 23560 Features, z. B. 20% entsprechen 4172 Features (I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des internen SmartADU-Sensors, d = Laser-Distanzmessung der Werkstück-Schwingung, L_P = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen SmartADU-Sensors, „Einhüll.“ = Einhüllende, „ob.“ = obere, „un.“ = untere, „gefilt.“ = gefiltert; Bohrphasen: Ph_E = Eintritt, Ph_A = Austritt, Ph_V = Vollschnitt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

A.10 Modell-Training

In dem Quellcode A.5 wird die Einbindung externer Bibliothek zur Bayes'scher Optimierung grob skizziert.

```
1 % Point to the (anonymous) objective function, which is defined as
  private function below
2 objFun = @(params)classANNHypParOpt(params, dataset, features,
  iNumberValidation, validationSetAcronym, objFuncAcronym);
3 % Get the optimised model after hyperparameter optimisation; possibly
  there is not result for it, hence return nan values
4 try
5 tic;
6 modelOptimised = bayesopt(objFun, hyperparameters, '
  MaxObjectiveEvaluations', head.config.modelTraining.general.
  maxObjectiveEvaluations, 'ConditionalVariableFcn', @condVarFcn);
7 evaluation.trainValSet.hypParOptTimeIns{iNumberValidation} = num2cell
  (toc);
8 close;
9 % ...
```

Quellcode A.5: Einbinden externer Bayes'scher Optimierung

A.10.1 Überwachte Klassifikation

In den Tabellen A.21 und A.22 sind die in der überwachten Klassifikation eingesetzten ML-Algorithmen mit ihrem untersuchten Hyperparameterraum eingetragen. Die restlichen Modellierungseinstellungen entsprechen den MATLAB-Standardwerten der jeweiligen Modellbibliothek.

Tabelle A.21: ML-Algorithmen bei überwachter Klassifikation - Teil 1 (die Hyperparameter sind kursiv als der dazugehörige MATLAB-Befehl geschrieben [Mat24a])

ML-Algorithmus	optimierte Hyperparameter mit Suchbereich
K-Nearest Neighbour (KNN _{MK})	<ul style="list-style-type: none"> - <i>Distance</i>: cityblock, chebychev, correlation, cosine, euclidean, hamming, jaccard, mahalnobis, minkowski, seuclidean, spearman - <i>DistanceWeight</i>: normal, invers, squaredinverse - <i>NumNeighbors</i>: [1; $\max(2, \text{Anzahl Beispiele} / 2)$] - <i>Standardize</i>: yes, no
Logistische Regression (LReg _{MK})	<ul style="list-style-type: none"> - <i>Regularization</i>: ridge, lasso - <i>Lambda</i>: [1; $\max(2, \text{Anzahl Beispiele} / 2)$] - <i>Coding</i>: onevsall, onevsone
Support Vector Machine (SVM _{MK})	<ul style="list-style-type: none"> - <i>BoxConstraint</i>: [10^{-3}; 10^3] - <i>KernelScale</i>: [10^{-3}; 10^3] - <i>KernelFunction</i>: gaussian, linear, polynomial, rbf - <i>PolynomialOrder</i>: [2; 4] - <i>Standardize</i>: yes, no - <i>Coding</i>: onevsall, onevsone
Naive-Bayes (NB _{MK})	<ul style="list-style-type: none"> - <i>Width</i>: [10^{-3}; 10^3] - <i>Kernel</i>: normal, box, epanechnikov, triangle - <i>Standardize</i>: yes, no
Diskriminanzanalyse (DA _{MK})	<ul style="list-style-type: none"> - <i>Delta</i>: [10^{-6}; 10^3] - <i>DiscrimType</i>: linear, quadratic, diagLinear, diagQuadratic, pseudoLinear, pseudoQuadratic - <i>Gamma</i>: [0; 1]
künstliches neuronales Netz (ANN _{MK})	<ul style="list-style-type: none"> - <i>hiddenLayerSizeRange</i>: [1; 300] - <i>hiddenLayerNumberRange</i>: [1; 10] - <i>Activation</i>: relu, tanh, sigmoid, none - <i>layerWeightsInitializer</i>: glorot, he - <i>layerBiasesInitializer</i>: zeros, ones - <i>lambda</i>: [10^{-5}; 10^5] / <i>Anzahl Beispiele</i> - <i>Standardize</i>: yes, no

Tabelle A.22: ML-Algorithmen bei überwachter Klassifikation - Teil 2 (die Hyperparameter sind kursiv als der dazugehörige MATLAB-Befehl geschrieben [Mat24a])

ML-Algorithmus	optimierte Hyperparameter mit Suchbereich
Entscheidungsbaum (DT _{MK})	<ul style="list-style-type: none"> - <i>MaxNumSplits</i>: [1; $\max(2, \text{Anzahl Beispiele} - 2)$] - <i>NumLearningCycles</i>: [10; 500] - <i>SplitCriterion</i>: gdi, deviance, twoing
Boosted Tree (BT _{MK})	<ul style="list-style-type: none"> - <i>Method</i>: GentleBoost, LogitBoost, AdaBoostM1, RUSBoost, AdaBoostM2, RUSBoost - <i>NumLearningCycles</i>: [10; 500] - <i>LearnRate</i>: [10^{-3}; 1] - <i>MaxNumSplits</i>: [1; $\max(2, \text{Anzahl Beispiele} - 1)$] - <i>MinLeafSize</i>: [1; $\max(2, \text{Anzahl Beispiele} / 2)$] - <i>NumVariablesToSample</i>: [1; $\max(2, \text{Anzahl Beispiele})$] - <i>SplitCriterion</i>: gdi, deviance, twoing
Random Forest (RF _{MK})	<ul style="list-style-type: none"> - <i>NumLearningCycles</i>: [10; 500] - <i>MaxNumSplits</i>: [1; $\max(2, \text{Anzahl Beispiele} - 1)$] - <i>MinLeafSize</i>: [1; $\max(2, \text{Anzahl Beispiele} / 2)$] - <i>NumVariablesToSample</i>: [1; $\max(2, \text{Anzahl Beispiele})$] - <i>SplitCriterion</i>: gdi, deviance, twoing

A.10.2 Überwachte Regression

In den Tabellen A.23 und A.24 sind die in der überwachten Regression eingesetzten ML-Algorithmen mit ihrem untersuchten Hyperparameterraum eingetragen. Die restlichen Modellierungseinstellungen entsprechen den MATLAB-Standardwerten der jeweiligen Modellbibliothek.

Tabelle A.23: ML-Algorithmen bei überwachter Regression - Teil 1 (die Hyperparameter sind kursiv als der dazugehörige MATLAB-Befehl geschrieben [Mat24a])

ML-Algorithmus	optimierte Hyperparameter mit Suchbereich
Lineare Regression (LReg _{MR})	<ul style="list-style-type: none"> - <i>Regularization</i>: ridge, lasso - <i>Lambda</i>: $[10^{-5}; 10^5]$ / <i>Anzahl Beispiele</i>
Support Vector Machine (SVM _{MR})	<ul style="list-style-type: none"> - <i>BoxConstraint</i>: $[10^{-3}; 10^3]$ - <i>KernelScale</i>: $[10^{-3}; 10^3]$ - <i>KernelFunction</i>: gaussian, linear, polynomial, rbf - <i>PolynomialOrder</i>: [2; 4] - <i>Standardize</i>: yes, no - <i>Epsilon</i>: $[10^{-3}; 10^2]$
Allgemeines Additives Modell (AAM _{MR})	<ul style="list-style-type: none"> - <i>InitialLearnRateForPredictors</i>: $[10^{-3}; 1]$ - <i>MaxNumSplitsPerPredictor</i>: [1; $\min(30, \max(2, \textit{Anzahl Beispiele} - 1))$] - <i>NumTreesPerPredictor</i>: [10; 500] - <i>Interactions</i>: [0; $(\textit{Anzahl Features}^2 - 1) / 2$]
künstliches neuronales Netz (ANN _{MR})	<ul style="list-style-type: none"> - <i>hiddenLayerSizeRange</i>: [1; 300] - <i>hiddenLayerNumberRange</i>: [1; 10] - <i>Activation</i>: relu , tanh, sigmoid, none - <i>layerWeightsInitializer</i>: glorot, he - <i>layerBiasesInitializer</i>: zeros, ones - <i>lambda</i>: $[10^{-5}; 10^5]$ / <i>Anzahl Beispiele</i> - <i>Standardize</i>: yes, no

Tabelle A.24: ML-Algorithmen bei überwachter Regression - Teil 2 (die Hyperparameter sind kursiv als der dazugehörige MATLAB-Befehl geschrieben [Mat24a])

ML-Algorithmus	optimierte Hyperparameter mit Suchbereich
Entscheidungsbaum (DT _{MR})	<ul style="list-style-type: none"> - <i>MaxNumSplits</i>: [1; $\max(2, \textit{Anzahl Beispiele} - 2)$] - <i>NumVariablesToSample</i>: [1; $\max(2, \textit{Anzahl Beispiele} - 2)$]
Boosted Tree (BT _{MR})	<ul style="list-style-type: none"> - <i>NumLearningCycles</i>: [10; 500] - <i>LearnRate</i>: $[10^{-3}; 1]$ - <i>MaxNumSplits</i>: [1; $\max(2, \textit{Anzahl Beispiele} - 1)$] - <i>MinLeafSize</i>: [1; $\max(2, \textit{Anzahl Beispiele} / 2)$] - <i>NumVariablesToSample</i>: [1; $\max(2, \textit{Anzahl Beispiele})$]
Random Forest (RF _{MR})	<ul style="list-style-type: none"> - <i>NumLearningCycles</i>: [10; 500] - <i>MaxNumSplits</i>: [1; $\max(2, \textit{Anzahl Beispiele} - 1)$] - <i>MinLeafSize</i>: [1; $\max(2, \textit{Anzahl Beispiele} / 2)$] - <i>NumVariablesToSample</i>: [1; $\max(2, \textit{Anzahl Beispiele})$] - <i>LearnRate</i>: $[10^{-3}; 1]$

A.10.3 Künstliche Datenset-Erweiterung

In der Abbildung A.16 ist ein Beispielergebnis zur Erzeugung künstlicher Daten zu sehen.

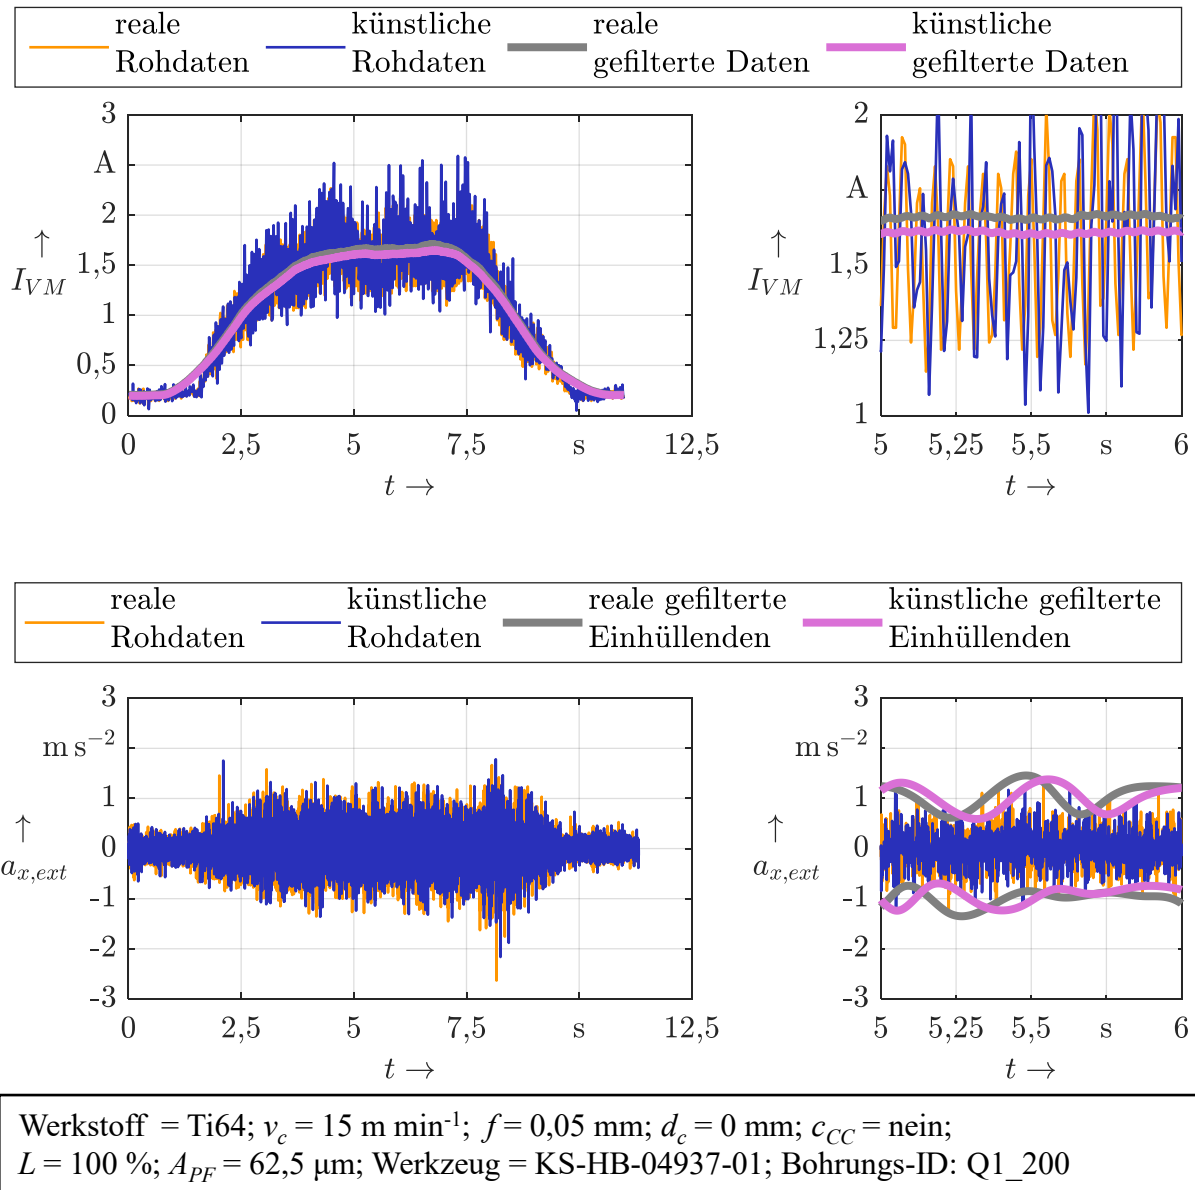


Abbildung A.16: Beispiel zur Erzeugung künstlicher Sensordaten (die rechte Spalte stellt eine Vergrößerung des links dargestellten Gesamtverlaufs dar; I_{VM} = Vorschubmotorstrom, $a_{x,ext}$ = Beschleunigungskomponente in x -Richtung des externen G-Sensors, t = Zeit, v_c = Schnittgeschwindigkeit, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite Werkstück, c_{CC} = Kontaktzustand Maschine/Werkstück, L = Schmierungszustand, A_{PF} = Peck-Feed-Amplitude)

A.11 Modell-Evaluation

A.11.1 Unüberwachtes Clustering

In der Tabelle A.25 sind die Evaluations-Kennzahlen, die für das unüberwachte Clustering eingesetzt werden, spezifiziert.

Tabelle A.25: Evaluations-Kennzahlen e_j für das unüberwachte Clustering

Gruppe	Kennzahl e_j (Wertebereich)	Gewichtung g_j	max. Punktezahl bei Wert
Ressourcen- verbrauch	Zeit Feature-Vorbereitung t_F ($[0; \infty]$)	0,1	min.
	Zeit Modell-Training t_M ($[0; \infty]$)	0,1	min.
Cluster- qualität	Normalized Mutual Information NMI_E ($[0; 1]$)	0,8	max.

A.11.2 Unüberwachte Ausreißeridentifikation und überwachte Klassifikation

In der Tabelle A.26 sind die Evaluations-Kennzahlen, die für die unüberwachte Ausreißeridentifikation und überwachte Klassifikation eingesetzt werden, spezifiziert. Die Erklärung der einzelnen Kennzahlen befindet sich im Abschnitt 2.3.4.2

Tabelle A.26: Evaluations-Kennzahlen e für die unüberwachte Ausreißeridentifikation und überwachte Klassifikation (*Bildung der finalen Wertes für die vorliegende Evaluationskennzahl durch: \bar{x} = Mittelwert oder s = Standardabweichung über Modellevaluationen an allen Test-Datensätzen)

Kennzahl e (Wertebereich)	Verarbeitung*	Gewichtung g_j	max. Punktezahl bei Wert
Dauer Feature-Vorbereitung t_F ($[0; \infty]$)	} \bar{x}/s	} 0,008 / 0,004	} min. / min.
Dauer Modell-Training t_M ($[0; \infty]$)			
Modell-Speichergröße H ($[0; \infty]$)			
F1-Score FSc_E ($[0; 1]$)		} 0,053 / 0,023	} max. / min.
Threat Score TS_E ($[0; 1]$)			
Informedness Inf_E ($[-1; 1]$)			
Markedness $Mark_E$ ($[-1; 1]$)			
Geometric Mean GM_E ($[0; 1]$)			
Fowlkes-Mallows Index FM_E ($[0; 1]$)			
Matthews Correlation coefficient MCC_E ($[-1; 1]$)			
Balanced Accuracy $BACC_E$ ($[0; 1]$)		} 0,035 / 0,015	} max. / min.
True Positive Rate TPR_E ($[0; 1]$)			
True Negative Rate TNR_E ($[0; 1]$)			
Positive Predictive Value PPV_E ($[0; 1]$)			
Negative Predictive Value NPV_E ($[0; 1]$)			
Cohen's Kappa CK_E ($[-1; 1]$)		} 0,008 / 0,004	} min. / min.
False Positive Rate FPR_E ($[0; 1]$)			
False Negative Rate FNR_E ($[0; 1]$)			
False Omission Rate FOR_E ($[0; 1]$)			
False Discovery Rate FDR_E ($[0; 1]$)		} 0,053 / 0,023	} min. / min.
Zeit Vorhersage t_V ($[0; \infty]$)			
Fehlerquote L_E ($[0; 1]$)	} 0,008 / 0,004	} min. / min.	

A.11.3 Überwachte Regression

In der Tabelle A.27 sind die Evaluations-Kennzahlen, die für die überwachten ML-Regressionsalgorithmen in der Werkstückqualität- und Werkzeugverschleiß-Überwachung eingesetzt werden, spezifiziert. Die Erklärung der einzelnen Kennzahlen befindet sich im Abschnitt 2.3.4.2.

Tabelle A.27: Evaluations-Kennzahlen e für die überwachte Regression (*Bildung der finalen Wertes für die vorliegende Evaluationskennzahl durch: \bar{x} = Mittelwert oder s = Standardabweichung über Modellevaluationen an allen Test-Datensätzen)

Kennzahl e (Wertebereich)	Verarbeitung*	Gewichtung g_j	max. Punktezahl bei Wert	
Dauer Hyperparameter-Optimierung t_H ($[0; \infty]$)	\bar{x}	0,025	min.	
Bestimmtheitsmaß R_E^2 ($[0; 1]$)	} \bar{x} / s	} 0,1 / 0,045	} max. / min.	
Zeit Vorhersage t_V ($[0; \infty]$)				} min. / min.
Wurzel des mittleren quadratischen Fehlers $RMSE_E$ ($[0; \infty]$)			} min. / min.	
Wurzel des relativen mittleren quadratischen Fehlers $RRMSE_E$ ($[0; \infty]$)				
mittlerer absoluter Fehler MAE_E ($[0; \infty]$)		} 0,05 / 0,023	} min. / min.	
mittlerer quadratischer Fehler MSE_E ($[0; \infty]$)				
relativer absolute Fehler RAE_E ($[0; \infty]$)		} max. / min.		
Pearson-Korrelationskoeffizient $R_{XY,E}$ ($[-1; 1]$)				
Median der absoluter Abweichung $MedA_E$ ($[0; \infty]$)		} 0,0135 / 0,006	} min. / min.	
relativer quadratischer Fehler RSE_E ($[0; \infty]$)				
Dauer Feature-Vorbereitung t_F ($[0; \infty]$)				
Dauer Modell-Training t_M ($[0; \infty]$)				
Modell-Speichergroße H ($[0; \infty]$)				

A.11.4 Einstufung der Evaluationskennzahlen mit einem festen Wertebereich

In der Tabelle A.28 sind die Stufen zur Interpretation der Evaluationskennzahlen mit einem festen Wertebereich anhand der im Abschnitt 2.3.4 verwendeten Quellen dargestellt.

Tabelle A.28: Einstufung der Evaluationskennzahlen mit festem Wertebereich (Die Einstufung erfolgt für die Kennzahlen, bei denen niedrige Werte für eine schlechte Vorhersagegüte stehen (z. B. True Positive Rate TPR_E / Matthews Correlation Coefficient MCC_E). Bei Kennzahlen mit umgekehrter Interpretationsrichtung müssen die Abstufungen in der Tabelle invertiert werden.)

Intervall der Kennzahlen mit dem Wertebereich [0; 1]	Intervall der Kennzahlen mit dem Wertebereich [-1; 1]	Einstufung Vorhersagegüte
[0,9; 1]	[0,9; 1]	sehr gut
[0,7; 0,9]	[0,5; 0,9]	gut
[0,5; 0,7]	[0,25; 0,5]	moderat
[0; 0,5]	[-1; 0,25]	schlecht

A.12 Aufbauschneiden-Bildung bei der Bearbeitung von Al2024

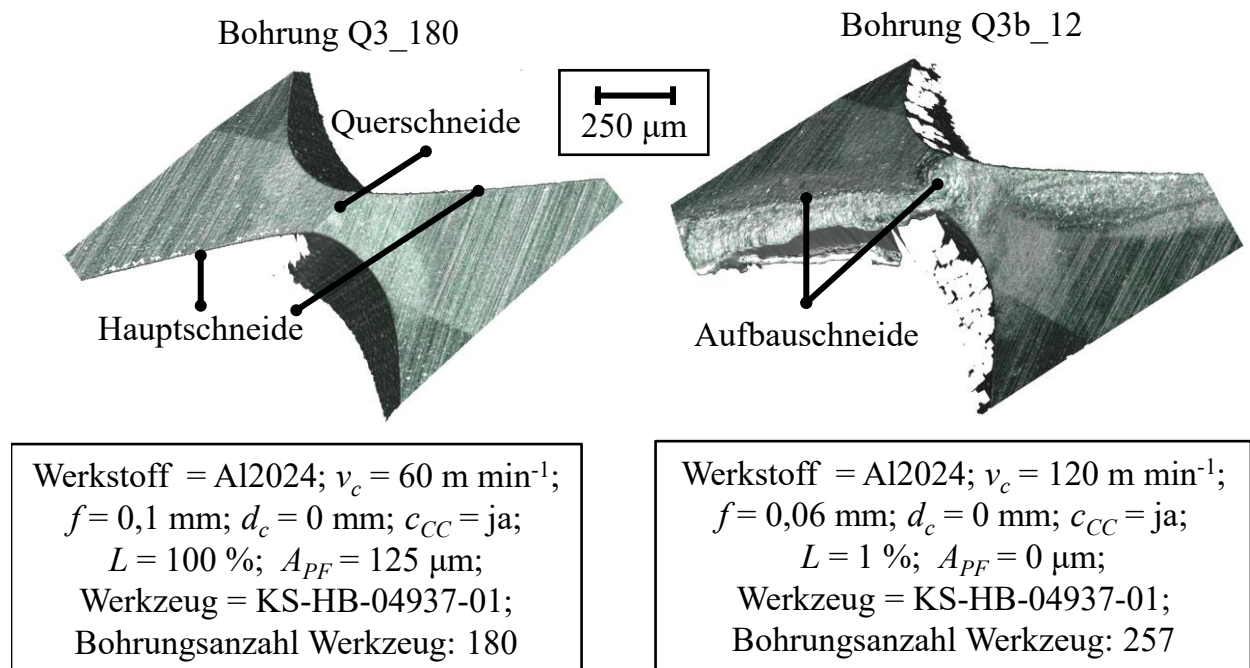


Abbildung A.17: Aufbauschneiden-Bildung am Werkstoff Al2024

A.13 Modellierungsergebnisse

A.13.1 Anomaliedetektion

In der Tabelle A.29 sind die Modellparameter und exemplarische Evaluationskennzahlen für das beste allgemeine Modell der unüberwachten Ausreißeridentifikation zur Anomaliedetektion,

welches anhand des gewichteten Gesamt-Punktwerts m bestimmt ist, eingetragen.

Tabelle A.29: Anomaliedetektion: bestes allgemeines Modell der unüberwachten Ausreißeridentifikation (H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, TPR_E = True Positive Rate, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Feature-Vorbereitung / ML-Algorithmus)						
2-Klassen-Klassifikation	Principal Component Analysis / Mahalanobis-Distanz <i>ML-Algorithmus-Hyperparameter</i> : als Hyperparameter werden mithilfe der MATLAB-Bibliothek <i>robustcov</i> die robuste Kovarianz-Matrix, die robusten Durchschnitts-Abschätzungen und die robusten Mahalanobis-Abstände angegeben. Die Angabe dieser Parameter ist aufgrund ihrer Länge in dieser Tabelle nicht praktikabel.						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	FSc_E [-]	GM_E [-]	$BAcc_E$ [-]	TPR_E [-]	MCC_E [-]
Anomaliedetektion	≈ 0	0,011	0,78	0,84	0,82	0,64	0,77

In der Tabelle A.30 sind die Modellparameter und exemplarische Evaluationskennzahlen für das Modell mit der besten True Positive Rate TPR_E der unüberwachten Ausreißeridentifikation zur Anomaliedetektion eingetragen.

Tabelle A.30: Anomaliedetektion: Modell mit der besten True Positive Rate TPR_R bei der unüberwachten Ausreißeridentifikation (H = Modellgröße, t_V = Dauer der Vorhersage, TPR_E = True Positive Rate, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Feature-Vorbereitung / ML-Algorithmus)						
2-Klassen-Klassifikation	Principal Component Analysis / One-Class Support Vector Machine <i>ML-Algorithmus-Hyperparameter:</i> Kernel-Skala: 1 Stärke Regularisierungs-Term: $5 \cdot 10^{-4}$ Dimension des erweiterten Raums: 16384						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H	t_V	TPR_E	GM_E	$BAcc_E$	$Mark_E$	MCC_E
	[MB]	[s]	[-]	[-]	[-]	[-]	[-]
Anomalie-detektion	≈ 0	0,011	0,98	0,84	0,82	0,64	0,77

In der Abbildung A.18 werden die Vorhersageergebnisse am Test-Set für die beste Modellierungs-Pipeline der unüberwachten Ausreißeridentifikation PCA_F-ESV_{MA} (Feature-Vorbereitungsmethode: Principal Component Analysis; ML-Algorithmus: Ein-Klassen Support Vector Machine) mit der besten reinen Anomalieerkennung bei einem Wert von $TPR_E = 0,98$ aufgezeigt. Dies bedeutet, dass $\approx 98\%$ der Anomalien erkannt werden. Dies geschieht jedoch auf Kosten vieler Falschalarme.

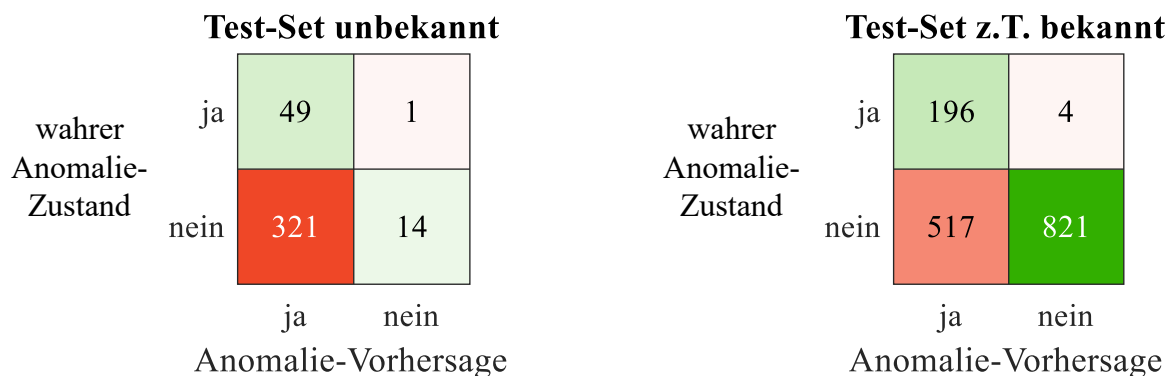


Abbildung A.18: Unüberwachte Ausreißeridentifikation: Vorhersageergebnisse mit bester True Positive Rate TPR_E bei der Modellierungs-Pipeline PCA_F-ESV_{MA} (Feature-Vorbereitungsmethode: Principal Component Analysis PCA_F , ML-Algorithmus: Ein-Klassen Support Vector Machine ESV_{MA} ; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert; siehe spezifische Modelleigenschaften in der Tabelle A.30)

In der Tabelle A.31 sind die Modellparameter und exemplarische Evaluationskennzahlen für die jeweils besten Modelle der überwachten Klassifikation zur Anomaliedetektion, die anhand

des gewichteten Gesamt-Punktwerts m bestimmt sind, eingetragen.

Tabelle A.31: Anomaliedetektion: beste allgemeine Modelle der überwachten Klassifikation (H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, TPR_E = True Positive Rate, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
2-Klassen-Klassifikation	Hold-Out / Chi-Quadrat-Ranking / Decision Tree / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 1316 Mindestanzahl an Beobachtungen je Blattknoten: 11 Split-Kriterium: Kreuzentropie						
5-Klassen-Klassifikation	Resubstitution / Neighbourhood Component Analysis / K-Nearest Neighbour / Matthew Correlation Coefficient <i>ML-Algorithmus-Hyperparameter:</i> Anzahl Nachbarn: 3 Distanz-Metrik: Mahalanobis-Distanz Distanz-Gewichtung: invers						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	FSc_E [-]	GM_E [-]	$BAcc_E$ [-]	TPR_E [-]	MCC_E [-]
2-Klassen-Klassifikation	0,6	0,03	0,82	0,84	0,85	0,7	0,83
5-Klassen-Klassifikation	67	0,07	0,98	0,77	0,8	0,98	0,75

In der Tabelle A.32 sind die Modellparameter und exemplarische Evaluationskennzahlen für das Modell mit der besten True Positive Rate TPR_E der überwachten Klassifikation zur Anomaliedetektion eingetragen. Hierbei erfolgt nur die Betrachtung der Zielgröße „Anomalie ja/nein“, da bei der 5-Klassen-Klassifikation keine positive Klasse als solche vorliegt.

Tabelle A.32: Anomaliedetektion: Modell mit der besten True Positive Rate bei der überwachten Klassifikation (H = Modellgröße, t_V = Dauer der Vorhersage, TPR_E = True Positive Rate, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
2-Klassen-Klassifikation	K(5)-Fold / Chi-Quadrat-Ranking / Diskriminanzanalyse / Geometric Mean <i>ML-Algorithmus-Hyperparameter:</i> Schwellwert Linearkoeffizient: 0 Diskriminanztyp: diagonal-quadratisch Regularisierungs-Gewicht: 0						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	TPR_E [-]	GM_E [-]	$BAcc_E$ [-]	$Mark_E$ [-]	MCC_E [-]
2-Klassen-Klassifikation	0,8	0,003	0,93	0,21	0,59	-0,5	-0,54

In der Abbildung A.19 ist die Konfusionsmatrix der Modellierungs-Pipeline mit der besten True Positive Rate TPR_E bei der überwachten Klassifikation zur 2-Klassen-Anomaliedetektion visualisiert.




Abbildung A.19: Anomaliedetektion: Modell mit bester True Positive Rate TPR_E bei der überwachten Klassifikation mit ihrer Konfusionsmatrix, die alle Daten der 4 vorhandenen Test-Sets umfasst (bester 2-Klassen-Klassifizierer: Validierung: K(5)-Fold KF_V / Feature Vorbereitung: Chi-Quadrat-Ranking $Chi2_F$ / ML-Algorithmus: Diskriminanzanalyse DA_{MK} / Objektivfunktion: Geometric Mean GM_E ; höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert)

In der Tabelle A.33 werden die wichtigsten Evaluationskennzahlen für die besten identifizierten Modelle, jeweils trainiert an dem realen und künstlich erweiterten Datensatz, für jede ML-Verfahrensgruppe der Anomaliedetektion (unüberwachtes Clustering, unüberwachte Ausreißeridentifikation und überwachte Klassifikation) verglichen.

Tabelle A.33: Anomaliedetektion: Einfluss der Datensatzgröße (t_M = Modellierungszeit, t_V = Vorhersagezeit, NMI = Normalized Mutual Information, MCC = Matthews Correlation Coefficient; zur Erklärung der Kurzbezeichnungen für Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.1 verwiesen))

Modellierungs-Information			Evaluations-Kennzahlen (realer / künstlich vergrößerter Datensatz)			
Art der Modellierung	Zielgröße	Modellierungs-Pipeline	t_M	t_V	NMI_E	MCC_E
			[s]	[s]	[-]	[-]
unüberwachtes Clustering	2-Klassen-Clustering	Stand _F /KMn _{MC}	114/ 467	-	0,013/ 0,014	-
	5-Klassen-Clustering	PCA _F /KMn _{MC}	3,3/ 74,6	-	0,03/ 0,008	-
unüberwachte Ausreißer-identifikat.	Anomalie „ja/nein“	PCA _F /MD _{MA}	0,012/ 4,58	0,022/ 0,2	-	0,77/ -1
überwachte Klassifikat.	2-Klassen Anomalie	HO _V /Chi2 _F /DT _{MK} /BACC _E	0,013/ 0,15	0,03/ 0,8	-	0,83/ 0,66
	5-Klassen Anomalie	RS _V /NCA _F /KNN _{MK} /MCC _E	0,016/ 2,7	0,07/ 0,42	-	0,75/ 0,98

A.13.2 Prozesszustand-Überwachung

In der Tabelle A.34 sind Angaben zu Modellparametern und exemplarische Evaluationskennzahlen für die jeweils besten Modelle des unüberwachten Clusterings zur Prozesszustand-Überwachung, die anhand des gewichteten Gesamt-Punktwerts m bestimmt sind, eingetragen. Es werden dabei nur die Zielgrößen betrachtet, die gemäß Abschnitt 9.1 eine potentiell annehmbare Clustering-Güte haben.

Tabelle A.34: Prozesszustand: beste allgemeine Modelle beim unüberwachten Clustering (W = Werkstoff, n = Drehzahl, f Vorschub pro Werkzeugumdrehung, A_{PF} = Peck-Feed-Amplitude, t_F = Dauer der Feature-Vorbereitung, t_M = Dauer des Modell-Trainings, NMI_E = Normalized Mutual Information)

Modelleigenschaften				
Zielgröße	Modellierungs-Pipeline (Feature-Vorbereitung / ML-Algorithmus)			
$W / n / f / A_{PF}$	Standardisierung / K-Means <i>ML-Algorithmus-Parameter:</i> Als Modellparameter wird jeweils der Ort der Cluster-Zentroide ausgegeben. Dies ist ein Vektor, dessen Länge der Beispiele-Anzahl entspricht und somit hier aus Platzgründen nicht dargestellt wird.			
wichtigste Evaluations-Kennzahlen				
Zielgrößen	t_F	t_M	NMI_E	
	[s]	[s]	[-]	
W	44	183	0,62	
n	44	263	0,7	
f	44	194	0,65	
A_{PF}	44	139	0,61	

In der Abbildung A.20 werden die zugeordneten und wahren Cluster für die jeweils besten Modelle (siehe Tabelle A.34) des unüberwachten Clusterings der Prozesszustand-Größen Werkstoff W , Drehzahl n , Vorschub pro Werkzeugumdrehung f und Peck-Feed-Amplitude A_{PF} aus der Abbildung 9.2 verglichen. Hierbei ist folgende manuelle Zuordnung notwendig, da beim unüberwachten Clustering die Zielgrößen nicht mit im Trainings-Prozess involviert sind: Es wird eine Zuordnung durch einen manuellen Positions- und Mehrheitsabgleich zwischen den vorhergesagten und wahren Labels durchgeführt. Sind beispielsweise die meisten Bohrungen in Ti64 dem Cluster 1 zugeordnet, so wird diese Clusternummer als das Ti64-Cluster interpretiert.

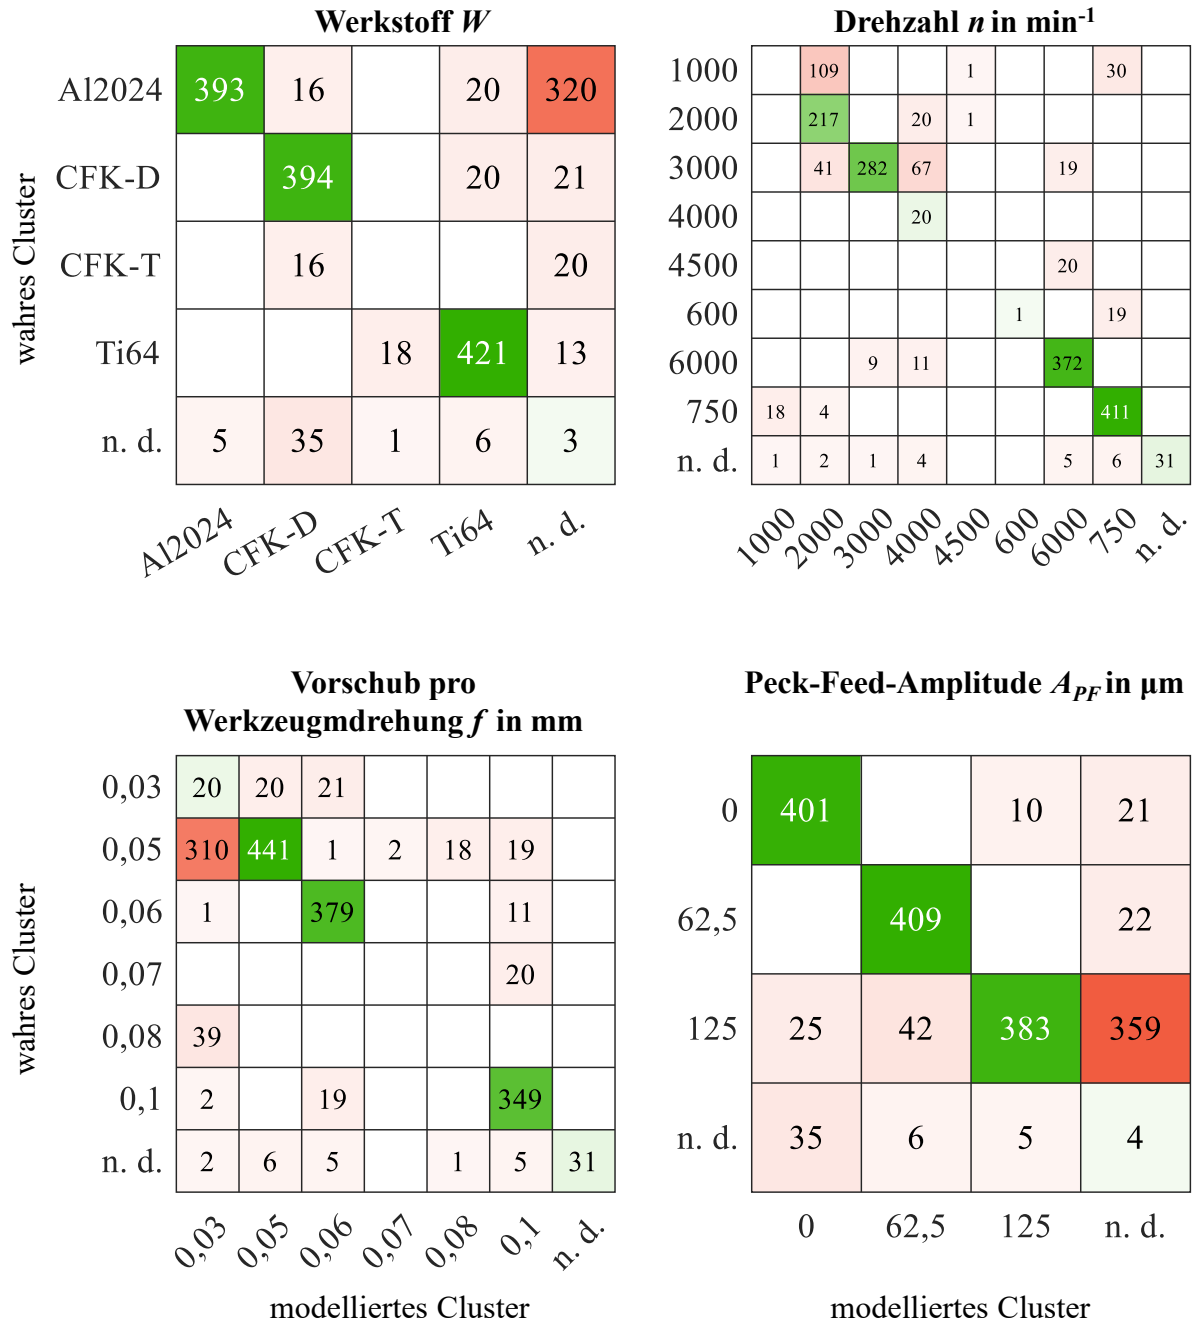


Abbildung A.20: Prozesszustand: Konfusionsmatrizen der jeweils besten Modelle ausgewählter Zielgrößen beim unüberwachten Clustering (höhere Anzahlen richtiger / falscher Zuordnungen werden mit einem stärkeren Grün- / Rotton markiert; die Modellierungs-Pipeline besteht aus Standardisierung als Feature-Vorbereitung und K-Means als ML-Algorithmus; zur weiteren Spezifikation und Evaluation der besten Modelle siehe Tabelle A.34)

In den Tabellen A.35 und A.36 sind die Eigenschaften und exemplarische Evaluations-Kennzahlen der generell am besten eingestuft Modelle der überwachten Klassifikation für die Zielgrößen des Prozesszustands aufgeführt.

Tabelle A.35: Prozesszustand: beste Modelle der überwachten Klassifikation, Teil 1 (W = Werkstoff, n = Drehzahl, f = Vorschub pro Werkzeugumdrehung, d_c = Aufspannweite, H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
W	Resubstitution / Principal Component Analysis / Logistische Regression / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> Regularisierungs-Typ: „lasso“; Regularisierung-Gewicht: 0,0011; multi-Klassen-Ansatz: „one-vs-one“						
n	Hold-Out / Neighbourhood Component Analysis / K-Nearest Neighbour / Matthews Correlation Coefficient <i>ML-Algorithmus-Hyperparameter:</i> Anzahl Nachbarn: 1; Distanz-Metrik: cityblock; Distanz-Gewichtung: invers						
f	Bootstrapping / Principal Component Analysis / Diskriminanzanalyse / Geometric Mean <i>ML-Algorithmus-Hyperparameter:</i> Schwellwert Linearkoeffizient: 10^{-6} ; Diskriminanztyp: pseudo-linear; Regularisierungs-Gewicht: 0,011						
d_c	Resubstitution / Principal Component Analysis / Boosted Tree / Geometric Mean <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 1217; Mindestanzahl an Beobachtungen je Blattknoten: 2; Split-Kriterium: Kreuzentropie; Anzahl Features an jedem Split: 193						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H	t_V	FSc_E	GM_E	$BAcc_E$	$Mark_E$	MCC_E
	[MB]	[s]	[-]	[-]	[-]	[-]	[-]
W	$6 \cdot 10^{-4}$	0,005	0,98	0,99	0,99	0,95	0,98
n	0,140	0,025	0,98	0,99	0,99	0,99	0,98
f	0,039	0,011	0,98	0,99	0,99	0,98	0,98
d_c	0,004	0,080	0,95	0,95	0,95	0,95	0,93

Tabelle A.36: Prozesszustand: beste Modelle der überwachten Klassifikation, Teil 2 (c_{CC} = Kontakt Maschine/Werkstoff, L = Schmierung, A_{PF} = Peck-Feed-Amplitude, H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
c_{CC}	Resubstitution / Neighbourhood Component Analysis / Boosted Tree / F-Score <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 162; Mindestanzahl an Beobachtungen je Blattknoten: 6; Split-Kriterium: „twoing“; Anzahl Features an jedem Split: 15						
L	Hold-Out / Relief-Algorithmus / Support Vector Machine / Geometric Mean <i>ML-Algorithmus-Hyperparameter:</i> multi-Klassen-Ansatz: „one-vs-all“; box constraint: 963; Kernel-Skala: 12,2; Kernel-Funktion: Gauß						
A_{PF}	Hold-Out / Principal Component Analysis / Support Vector Machine / Geometric Mean <i>ML-Algorithmus-Hyperparameter:</i> multi-Klassen-Ansatz: „one-vs-all“; box constraint: 573; Kernel-Skala: 69,5; Kernel-Funktion: Polynom						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H	t_V	FSc_E	GM_E	$BAcc_E$	$Mark_E$	MCC_E
	[MB]	[s]	[-]	[-]	[-]	[-]	[-]
c_{CC}	0,130	0,080	0,97	0,97	0,98	0,96	0,96
L	3,000	0,050	0,98	0,98	0,98	0,98	0,97
A_{PF}	0,275	0,071	0,98	0,98	0,98	0,97	0,97

A.13.3 Werkstückqualität-Überwachung

Die Abbildung A.21 stellt die Signifikanzen der einzelnen Ausprägungen der Feature-Extraktionspfade für die überwachte Regression der Werkstückqualität dar. Zu beachten ist dabei, dass die Signifikanzwerte nur innerhalb eines Diagramms untereinander vergleichbar sind.

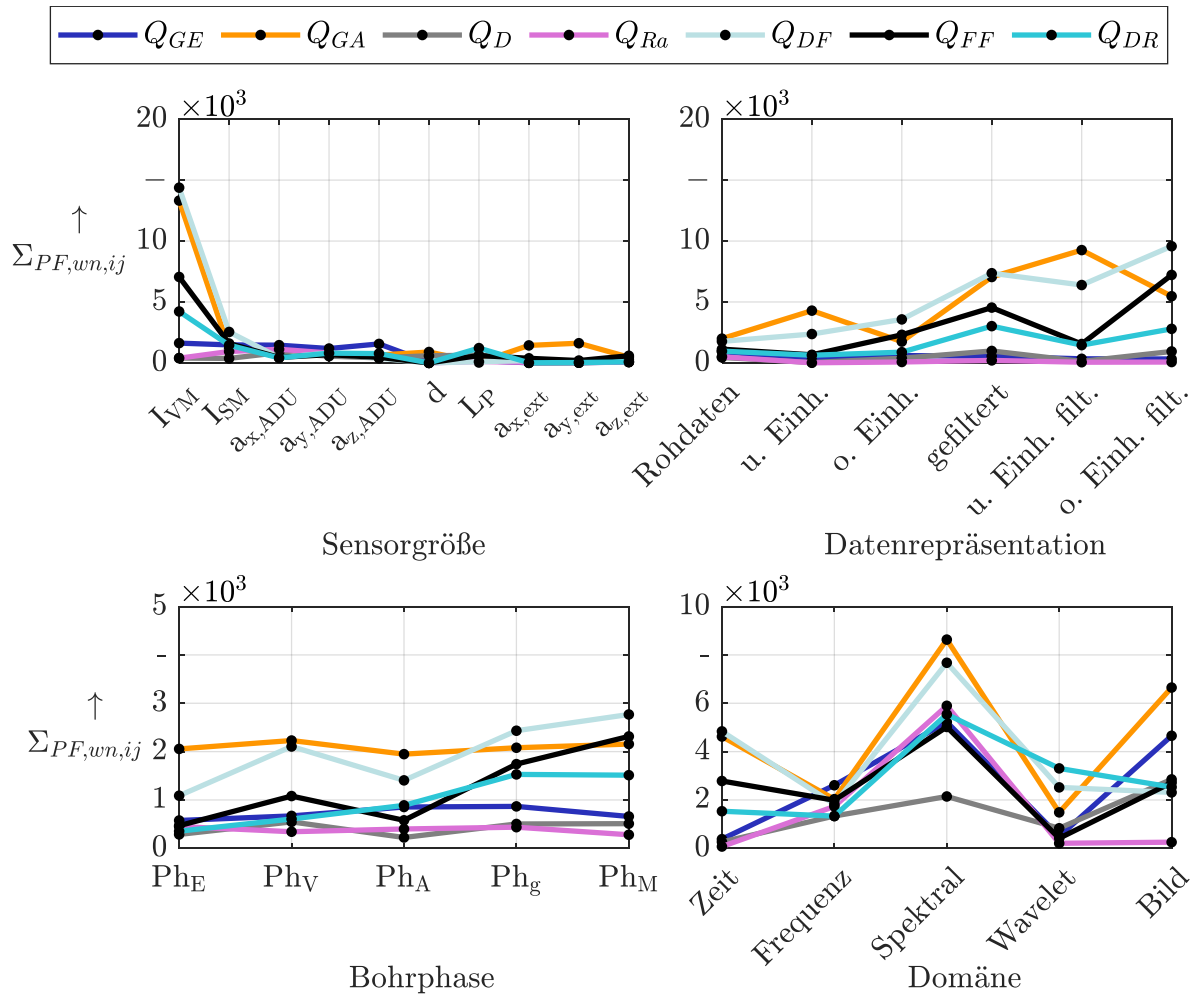


Abbildung A.21: Werkstückqualität: Feature-Signifikanz bei überwachter Regression (Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor; $\Sigma_{PF,wn,ij}$ = gewichtete Summe der normierten Feature-Signifikanzwerte (nur innerhalb jedes einzelnen Diagramms vergleichbar), I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, d = Distanz Werkstück, L_P = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, u./o. Einh. = untere/obere Einhüllende, u./o. Einh. filt. = untere/obere Einhüllende gefiltert, Ph_E = Eintritt, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

In den Tabellen A.37 und A.38 sind die Eigenschaften sowie exemplarische Evaluations-Kennzahlen der generell am besten eingestuftten Klassifikationsmodelle für die Zielgrößen der Werkstückqualität aufgeführt.

Tabelle A.37: Werkstückqualität: beste Modelle der überwachten Klassifikation, Teil 1 (Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, TPR_E = True Positive Rate, MCC_E = Matthew Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
Q_{GE}	K-Fold / Chi-Quadrat-Ranking / K-Nearest Neighbour / F-Score <i>ML-Algorithmus-Hyperparameter:</i> Anzahl Nachbarn: 278; Distanz-Metrik: Korrelation; Distanz-Gewichtung: quadriert-invers						
Q_{GA}	Hold-Out / Chi-Quadrat-Ranking / K-Nearest Neighbour / F-Score <i>ML-Algorithmus-Hyperparameter:</i> Anzahl Nachbarn: 13; Distanz-Metrik: Korrelation; Distanz-Gewichtung: quadriert-invers						
Q_D	K-Fold / Chi-Quadrat-Ranking / Boosted Tree / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 1040; Mindestanzahl an Beobachtungen je Blattknoten: 2; Split-Kriterium: Kreuzentropie; Anzahl Features an jedem Split: 14						
Q_{Ra}	Hold-Out / Neighbourhood Component Analysis / K-Nearest Neighbour / F-Score <i>ML-Algorithmus-Hyperparameter:</i> Anzahl Nachbarn: 5; Distanz-Metrik: cityblock; Distanz-Gewichtung: keine						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	FSc_E [-]	GM_E [-]	$BAcc_E$ [-]	TPR_E [-]	MCC_E [-]
Q_{GE}	5,24	0,27	0,93	0,36	0,57	0,95	0,34
Q_{GA}	3,78	0,16	0,80	0,66	0,71	0,82	0,48
Q_D	4,02	0,08	0,92	0,89	0,89	0,91	0,74
Q_{Ra}	0,43	0,02	0,99	0,99	0,99	0,98	0,99

Tabelle A.38: Werkstückqualität: beste Modelle der überwachten Klassifikation, Teil 2 (Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor, H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, TPR_E = True Positive Rate, MCC_E = Matthew Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
Q_{DF}	Resubstitution / Neighbourhood Component Analysis / Boosted Tree / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 8; Mindestanzahl an Beobachtungen je Blattknoten: 1; Split-Kriterium: „twoing“; Anzahl Features an jedem Split: 68						
Q_{FF}	Hold-Out / Neighbourhood Component Analysis / Naive Bayes / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> Datenverteilung: Normalverteilung; Kernel-Funktion: Gauß; Kernel-Glättungsfenster: 0,14						
Q_{DR}	Hold-Out / Principal Component Analysis / Support Vector Machine / Markedness <i>ML-Algorithmus-Hyperparameter:</i> multi-Klassen-Ansatz: „one-vs-all“; box constraint: 679,7; Kernel-Skala: 112,1; Kernel-Funktion: Gauß						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	FSc_E [-]	GM_E [-]	$BAcc_E$ [-]	TPR_E [-]	MCC_E [-]
Q_{DF}	0,18	0,01	0,96	0,95	0,95	0,90	0,90
Q_{FF}	0,51	0,05	0,61	0,77	0,79	0,55	0,55
Q_{DR}	0,28	0,002	1	1	1	1	1

In der Tabelle A.39 werden die Modelleigenschaften sowie exemplarische Evaluations-Kennzahlen für die 2-Klassen-Modellierungs-Pipelines, die zu der besten True Positive Rate TPR_E bei dem Test-Datensatz führen, im Rahmen der Werkstückqualität-Vorhersage gelistet. Sollten die allgemein besten Modelle (siehe Tabellen A.37 und A.38) bereits die beste True Positive Rate TPR_E vorweisen, werden die Ergebnisse für diese Zielgrößen in der Tabelle A.39 nicht mehr ausgewiesen.

Tabelle A.39: Werkstückqualität: 2-Klassen-Modelle Modelle der überwachten Klassifikation mit der besten True Positive Rate TPR_E , falls diese mit dem generell bestem Modell laut den Tabellen A.37 und A.38 nicht erreicht wird (Q_{Ra} = Mittenrauwert, Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, TPR_E = True Positive Rate, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthew Correlation Coefficient)

Modelleigenschaften						
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)					
Q_{Ra}	Resubstitution / Neighbourhood Component Analysis / Boosted Tree / F-Score <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 557; Mindestanzahl an Beobachtungen je Blattknoten: 7; Split-Kriterium: Diversitätsindex; Anzahl Features je Split: 2					
Q_{DF}	Hold-Out / Principal Component Analysis / Naive Bayes / Markedness <i>ML-Algorithmus-Hyperparameter:</i> Kernel-Glättungsfenster: 0,0088; Kernel-Funktion: Gauß; Datenverteilung: Kerndichteschätzer					
Q_{FF}	Bootstrapping / Relieff / Naive Bayes / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> Kernel-Glättungsfenster: 0,31; Kernel-Funktion: Box; Datenverteilung: Kerndichteschätzer					
wichtigste Evaluations-Kennzahlen						
Zielgröße	TPR_E	FSc_E	GM_E	$BAcc_E$	$Mark_E$	MCC_E
	[-]	[-]	[-]	[-]	[-]	[-]
Q_{Ra}	0,99	0,99	0,99	0,99	0,99	0,99
Q_{DF}	1	0,86	0,7	0,74	0,72	0,61
Q_{FF}	1	0,38	0,72	0,76	0,24	0,35

In den Tabellen A.40 und A.41 sind die Eigenschaften sowie exemplarische Evaluations-Kennzahlen der generell am besten eingestuftten Regressionsmodelle für die Zielgrößen der Werkstückqualität aufgeführt.

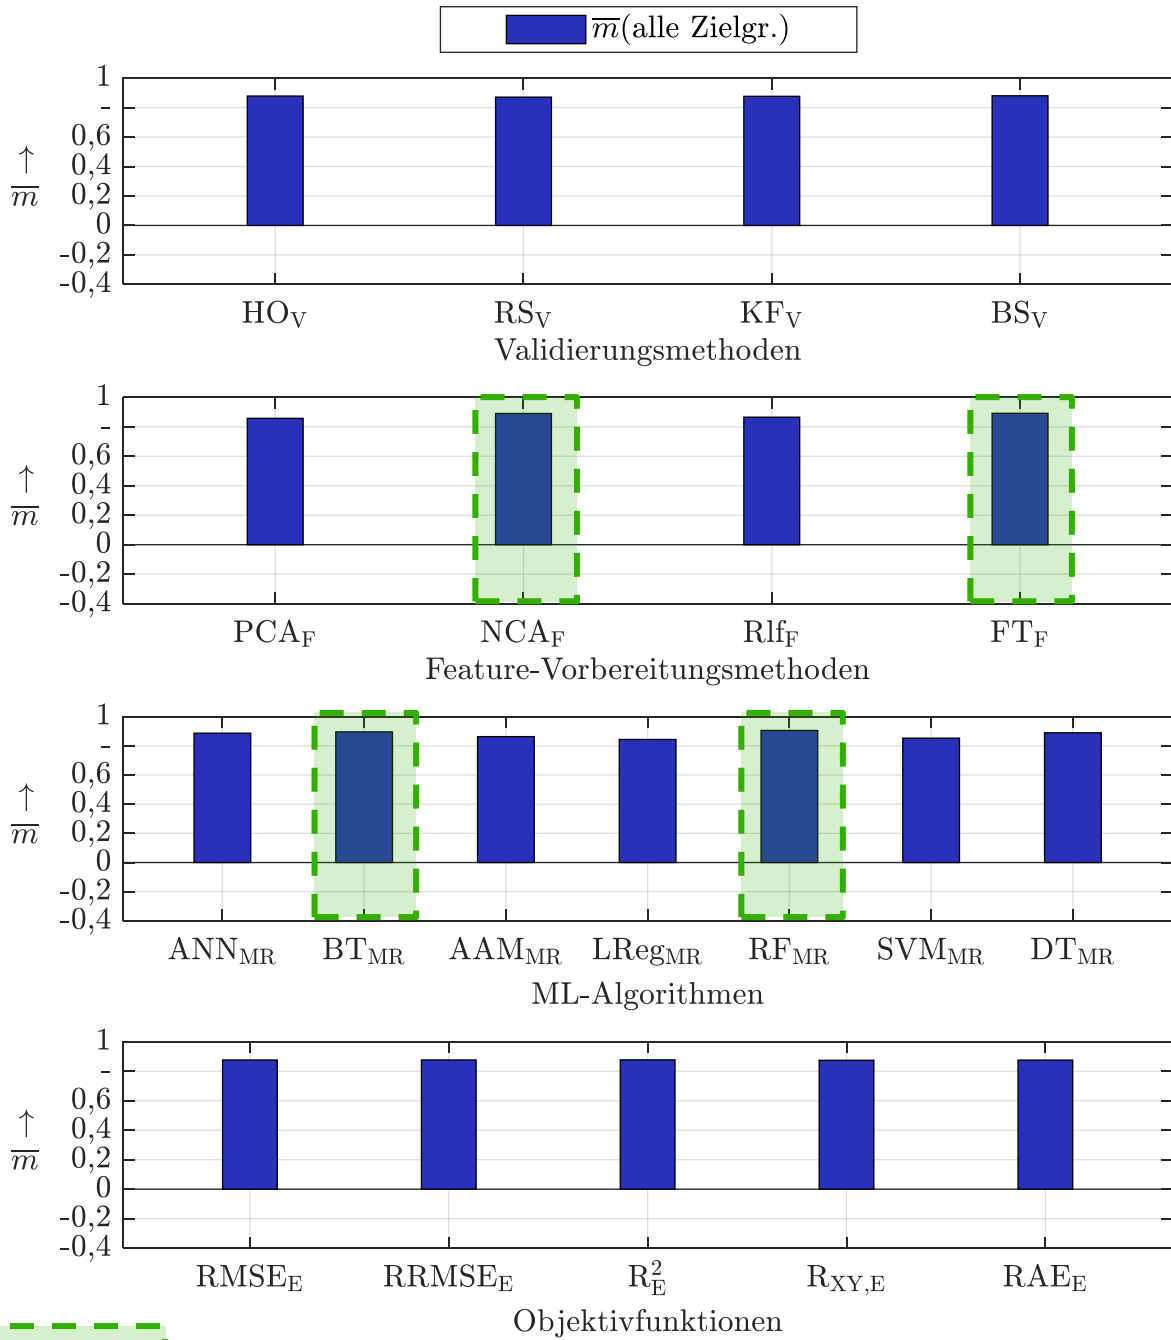
Tabelle A.40: Werkstückqualität: beste Modelle der überwachten Regression, Teil 1 (Q_{GE} = Grat Eintritt, Q_{GA} = Grat Austritt, Q_D = Durchmesser, Q_{Ra} = Mittenrauwert, H = Modellgröße, t_V = Dauer der Vorhersage, $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers, $RRMSE_E$ = Wurzel des relativen mittleren quadratischen Fehlers, R_E^2 = Bestimmtheitsmaß, $R_{XY,E}$ = Pearson-Korrelationskoeffizient, RAE_E = relativer absoluter Fehler)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
Q_{GE}	Bootstrapping / Relief-Algorithmus / Random Forest / Wurzel des relativen mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 371; Mindestanzahl an Beobachtungen je Blattknoten: 4; Anzahl Features je Split: 136						
Q_{GA}	K-Fold / F-Test / Random Forest / Bestimmtheitsmaß <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 148; Mindestanzahl an Beobachtungen je Blattknoten: 13; Anzahl Features je Split: 42						
Q_D	K-Fold / F-Test / Random Forest / Bestimmtheitsmaß <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 1230; Mindestanzahl an Beobachtungen je Blattknoten: 2; Anzahl Features je Split: 13						
Q_{Ra}	Hold-Out / F-Test / künstliches neuronales Netz / relativer absoluter Fehler <i>ML-Algorithmus-Hyperparameter</i> : Anzahl versteckte Schichten: 7; Neuronen pro versteckte Schicht: 34 / 211 / 17 / 10 / 2 / 40 / 7 ; Aktivierungs-Funktion: sigmoid; initiale Schicht-Gewichtung: He-Initialisierung; Stärke Regularisierung: $3,5 \cdot 10^{-5}$						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	$RMSE_E$ [variabel]	$RRMSE_E$ [-]	R_E^2 [-]	$R_{XY,E}$ [-]	RAE_E [-]
Q_{GE}	0,9	0,013	0,03 mm	0,03	0,41	0,64	0,41
Q_{GA}	1,8	0,022	0,05 mm	0,04	0,33	0,57	0,79
Q_D	0,8	0,007	0,01 mm	$9,3 \cdot 10^{-5}$	0,82	0,91	0,41
Q_{Ra}	0,45	0,05	0,21 μm	0,001	0,94	0,97	0,18

Tabelle A.41: Werkstückqualität: beste Modelle der überwachten Regression, Teil 2 (Q_{DF} = Delaminations-Faktor, Q_{FF} = Faserüberstand-Faktor, Q_{DR} = Delaminationsradius-Faktor, H = Modellgröße, t_V = Dauer der Vorhersage, $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers, $RRMSE_E$ = Wurzel des relativen mittleren quadratischen Fehlers, R_E^2 = Bestimmtheitsmaß, $R_{XY,E}$ = Pearson-Korrelationskoeffizient, RAE_E = relativer absoluter Fehler)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
Q_{DF}	Bootstrapping / F-Test / Random Forest / Wurzel des mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 114; Mindestanzahl an Beobachtungen je Blattknoten: 4; Anzahl Features je Split: 375						
Q_{FF}	Bootstrapping / F-Test / Random Forest / Wurzel des mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter:</i> max. Anzahl Verzweigungen: 12; Mindestanzahl an Beobachtungen je Blattknoten: 2; Anzahl Features je Split: 158						
Q_{DR}	Resubstitution / F-Test / künstliches neuronales Netz / Wurzel des relativen mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter:</i> Anzahl versteckte Schichten: 4; Neuronen pro Schicht: 2 / 36 / 2 / 3; Aktivierungs-Funktion: ReLu; initiale Schicht-Gewichtung: Glorot-Initialisierung; Stärke Regularisierung: 0,0033						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	$RMSE_E$ [variabel]	$RRMSE_E$ [-]	R_E^2 [-]	$R_{XY,E}$ [-]	RAE_E [-]
Q_{DF}	2	0,03	0,07	0,007	0,91	0,95	0,3
Q_{FF}	0,6	0,01	0,078	0,02	0,68	0,82	0,58
Q_{DR}	0,07	0,009	0,2	0,012	0,51	0,62	0,73

In der Abbildung A.22 wird die Performance der Modellierungsstufen für die überwachte Regression analysiert. Das Vorgehen findet Anwendung in der bereits vorgestellten Anomalie-detektion (Abschnitt 8.3.3) und Prozesszustand-Überwachung (Abschnitt 9.2.3) und wird in den dazugehörigen Abschnitten näher erläutert.



Optimum

Abbildung A.22: Werkstückqualität: Modellierungsstufen bei überwachter Regression; die Markierung des Optimums jeder Modellierungsstufe erfolgt falls die beste(n) Option(en) ein um $\approx 0,01$ höheres \bar{m} als die zweitbeste vorweist (\bar{m} = Durchschnitt des gewichteten Gesamtpunktwerts für die vorliegende Methode einer Modellierungsstufe über aller Modellierungs-Pipelines hinweg; zur Symbol-Kennzeichnung der Zielgrößen, Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie der Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.3 und die Anhänge A.1.3 und A.10.2 verwiesen)

A.13.4 Werkzeugverschleiß-Überwachung

Die Abbildung A.23 stellt die Signifikanzen der einzelnen Ausprägungen der Feature-Extraktionspfade für die überwachte Regression des Werkzeugverschleißes dar. Zu beachten ist dabei, dass die Signifikanzwerte nur innerhalb eines Diagramms untereinander vergleichbar sind. Es sei darauf hingewiesen, dass für die überwachte Klassifikation in Summe 720 und für die überwachte Regression 560 Modellierungs-Pipelines entwickelt sind.

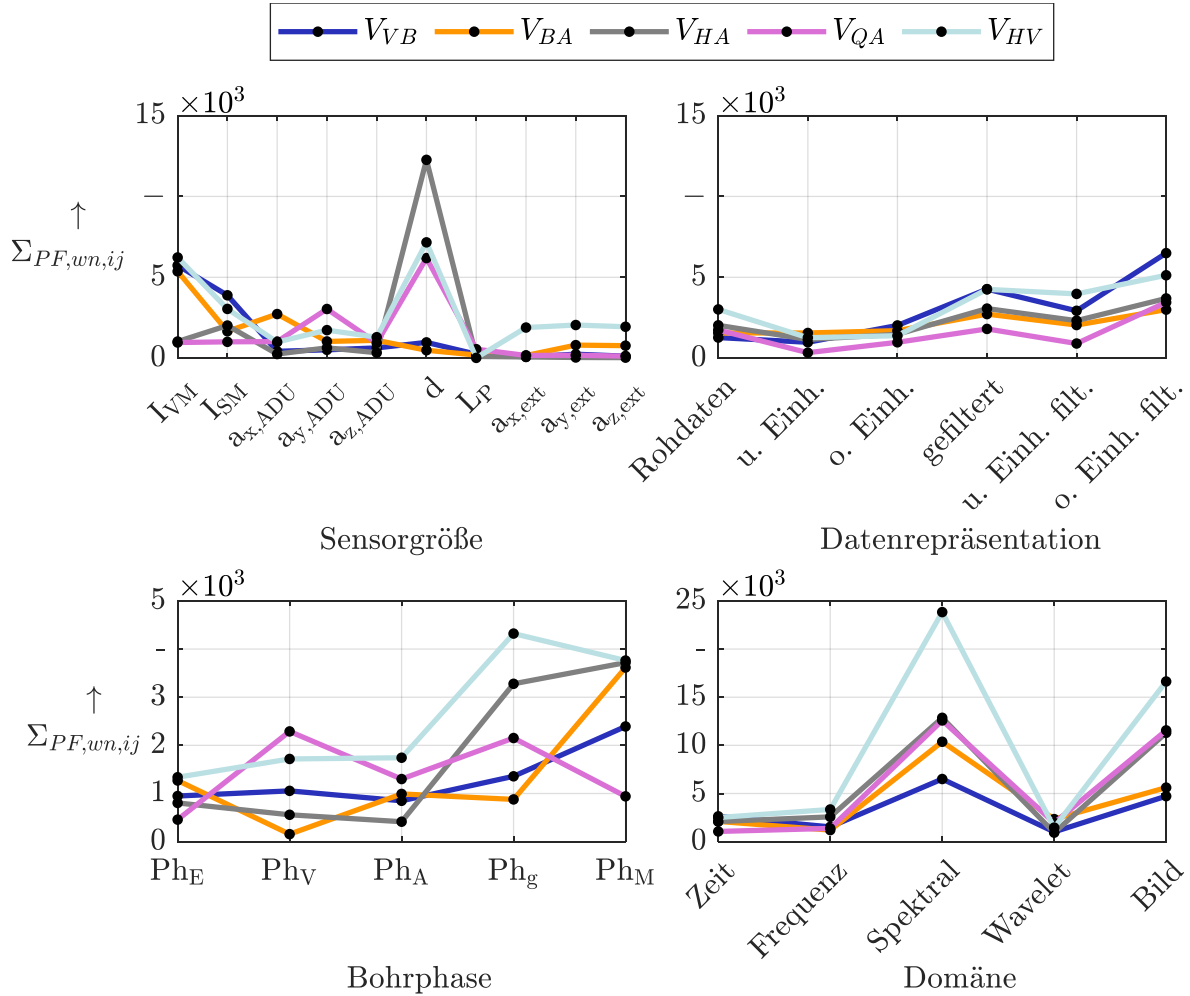


Abbildung A.23: Werkzeugverschleiß: Feature-Signifikanz bei überwachter Regression (V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen; $\Sigma_{PF,wn,ij}$ = gewichtete Summe der normierten Feature-Signifikanzwerte (nur innerhalb jedes einzelnen Diagramms vergleichbar), I_{VM} = Vorschubmotorstrom, I_{SM} = Spindelmotorstrom, $a_{x/y/z,ADU}$ = Beschleunigung in x/y/z-Richtung des SmartADU-internen G-Sensors, d = Distanz Werkstück, L_P = Schalldruck, $a_{x/y/z,ext}$ = Beschleunigung in x/y/z-Richtung des externen G-Sensors, u./o. Einh. = untere/obere Einhüllende, u./o. Einh. filt. = untere/obere Einhüllende gefiltert, Ph_E = Eintritt, Ph_V = Vollschnitt, Ph_A = Austritt, Ph_g = Gesamtbohrung, Ph_M = Gesamtmessung)

In der Tabelle A.42 sind die Eigenschaften und exemplarische Evaluations-Kennzahlen der generell am besten eingestuftten Klassifikationsmodelle für die Zielgrößen des Werkzeugverschleißes aufgeführt.

Tabelle A.42: Werkzeugverschleiß: beste Modelle der überwachten Klassifikation (V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchsfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen, H = Modellgröße, t_V = Dauer der Vorhersage, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, TPR_E = True Positive Rate, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
V_{VB}	K-Fold / Chi-Quadrat-Ranking / Support Vector Machine / Matthews Correlation Coefficient <i>ML-Algorithmus-Hyperparameter</i> : multi-Klassen-Ansatz: „one-vs-all“; box constraint: 724,67; Kernel-Skala: 23,4; Kernel-Funktion: Gauß						
V_{BA}	Bootstrapping / Neighbourhood Component Analysis/ K-Nearest Neighbour / Markedness <i>ML-Algorithmus-Hyperparameter</i> : Anzahl Nachbarn: 7; Distanz-Metrik: Cityblock; Distanz-Gewichtung: quadriert-invers						
V_{HA}	Resubstitution / Chi-Quadrat-Ranking / Boosted Tree / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 143; Mindestanzahl an Beobachtungen je Blattknoten: 1; Split-Kriterium: Diversitätsindex; Anzahl Features je Split: 10						
V_{QA}	Bootstrapping / Chi-Quadrat-Ranking / K-Nearest Neighbour / F-Score <i>ML-Algorithmus-Hyperparameter</i> : Anzahl Nachbarn: 1; Distanz-Metrik: Cityblock; Distanz-Gewichtung: invers						
V_{HV}	Bootstrapping / Neighbourhood Component Analysis / Boosted Tree / Matthews Correlation Coefficient <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 20; Mindestanzahl an Beobachtungen je Blattknoten: 1; Split-Kriterium: Diversitätsindex; Anzahl Features je Split: 5						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H [MB]	t_V [s]	FSc_E [-]	GM_E [-]	$BAcc_E$ [-]	TPR_E [-]	MCC_E [-]
V_{VB}	0,2	0,06	0,91	0,91	0,91	0,95	0,83
V_{BA}	0,3	0,02	0,97	0,98	0,98	0,97	0,96
V_{HA}	0,5	0,02	0,93	0,98	0,98	1	0,92
V_{QA}	0,6	0,04	0,60	0,73	0,77	0,56	0,59
V_{HV}	0,2	0,01	1	1	1	1	1

In der Tabelle A.43 werden die Modelleigenschaften sowie exemplarische Evaluations-

Kennzahlen für die 2-Klassen-Modellierungs-Pipelines, die zu der besten True Positive Rate TPR_E bei dem Test-Datensatz führen, im Rahmen der Werkzeugverschleiß-Vorhersage gelistet. Sollten die allgemein besten Modelle (siehe Tabelle A.42) bereits die beste True Positive Rate TPR_E aufweisen, werden sie nicht mehr in der Tabelle A.43 aufgeführt.

Tabelle A.43: Werkzeugverschleiß: Modelle der überwachten Klassifikation mit der besten True Positive Rate TPR_E , falls diese mit dem generell bestem Modell lt. Tabelle A.42 nicht erreicht wird (V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, H = Modellgröße, t_V = Dauer der Vorhersage, TPR_E = True Positive Rate, FSc_E = F-Score, GM_E = Geometric Mean, $BAcc_E$ = Balanced Accuracy, $Mark_E$ = Markedness, MCC_E = Matthews Correlation Coefficient)

Modelleigenschaften						
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)					
V_{VB}	Hold-Out / Relieff / K-Nearest Neighbour / Markedness <i>ML-Algorithmus-Hyperparameter:</i> Anzahl Nachbarn: 1; Distanz-Metrik: Korrelation; Distanz-Gewichtung: keine					
V_{BA}	K-Fold / Neighbourhood Component Analysis / künstliches neuronales Netz / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> Anzahl versteckte Schichten: 3; Neuronen pro Schicht: 2 / 4 / 2; Aktivierungs-Funktion: tanh() initiale Schicht-Gewichtung: He-Initialisierung; Stärke Regularisierung: $3 \cdot 10^{-7}$					
V_{QA}	Hold-Out / Principal Component Analysis / Diskriminanzanalyse / Balanced Accuracy <i>ML-Algorithmus-Hyperparameter:</i> Schwellwert Linearkoeffizient: 0; Diskriminanztyp: pseudo-quadratisch; Regularisierungs-Gewicht: 0					
wichtigste Evaluations-Kennzahlen						
Zielgröße	TPR_E	FSc_E	GM_E	$BAcc_E$	$Mark_E$	MCC_E
	[-]	[-]	[-]	[-]	[-]	[-]
V_{VB}	0,98	0,94	0,94	0,94	0,88	0,88
V_{BA}	0,98	0,97	0,99	0,98	0,96	0,96
V_{QA}	1	0,3	0,7	0,75	0,18	0,29

In der Tabelle A.44 sind die Eigenschaften und exemplarische Evaluations-Kennzahlen der generell am besten eingestuftten Regressionsmodelle für die Zielgrößen des Werkzeugverschleißes aufgeführt.

Tabelle A.44: Werkzeugverschleiß: beste Modelle der überwachten Regression (V_{VB} = maximale Verschleißmarkenbreite, V_{BA} = Ausbruchfläche an der Freifläche, V_{HA} = Hauptschneiden-Abflachung, V_{QA} = Querschneide-Abflachung, V_{HV} = Hauptschneiden-Volumen, H = Modellgröße, t_V = Dauer der Vorhersage, $RMSE_E$ = Wurzel des mittleren quadratischen Fehlers, $RRMSE_E$ = Wurzel des relativen mittleren quadratischen Fehlers, R_E^2 = Bestimmtheitsmaß, $R_{XY,E}$ = Pearson-Korrelationskoeffizient, RAE_E = relativer absoluter Fehler)

Modelleigenschaften							
Zielgröße	Modellierungs-Pipeline (Validierungsmethode / Feature-Vorbereitung / ML-Algorithmus / Objektivfunktion)						
V_{VB}	Hold-Out / F-Test / Support Vector Machine / Wurzel des relativen mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter</i> : box constraint: 853,4; Toleranzspanne: 27; Kernel-Skala: 10,3; Kernel-Funktion: Gauß						
V_{BA}	Hold-Out / F-Test / Random Forest / relativer absoluter Fehler <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 81; Mindestanzahl an Beobachtungen je Blattknoten: 1; Anzahl Features je Split: 6						
V_{HA}	Hold-Out / Relief / Random Forest / Wurzel des mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 43; Mindestanzahl an Beobachtungen je Blattknoten: 8; Anzahl Features je Split: 76						
V_{QA}	K-Fold / Relief / Boosted Tree / Bestimmtheitsmaß <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 6; Mindestanzahl an Beobachtungen je Blattknoten: 1; Anzahl Features je Split: 24						
V_{HV}	Hold-Out / Principal Component Analysis / Random Forest / Wurzel des relativen mittleren quadratischen Fehlers <i>ML-Algorithmus-Hyperparameter</i> : max. Anzahl Verzweigungen: 79; Mindestanzahl an Beobachtungen je Blattknoten: 4; Anzahl Features je Split: 91						
wichtigste Evaluations-Kennzahlen							
Zielgröße	H	t_V	$RMSE_E$	$RRMSE_E$	R_E^2	$R_{XY,E}$	RAE_E
	[MB]	[s]		[-]	[-]	[-]	[-]
V_{VB}	0,1	0,01	33,6 μm	0,05	0,87	0,94	0,31
V_{BA}	0,8	0,01	0,05 mm^2	0,017	0,92	0,96	0,13
V_{HA}	0,4	0,01	5,28 μm	0,03	0,87	0,93	0,3
V_{QA}	1	0,02	1,62 μm	0,06	0,46	0,65	0,86
V_{HV}	0,1	0,02	6 · 10 ⁻⁴ mm^3	0,009	0,66	0,8	0,47

In der Abbildung A.24 ist der Durchschnitt des gewichteten Gesamt-Punktwerts \bar{m} über alle Zielgrößen der Werkstückqualität hinweg für jede Modellierungs-Pipeline aufgetragen. Zu beachten ist, dass für die Regression 560 und für die Klassifikation 720 Modellierungs-Pipelines untersucht werden.




Abbildung A.24: Werkzeugverschleiß: zielgrößenübergreifende Auswertung der überwachten Klassifikation und Regression in Form einer Übersicht über die Gesamtbewertung der Modellmenge (\bar{m} = Durchschnitt des gewichteten Gesamt-Punktwerts über alle Zielgrößen der Werkstückqualität hinweg)

In der Abbildung A.25 wird die Performance der Modellierungsstufen für die überwachte Regression bei der Vorhersage vom Werkzeugverschleiß analysiert. Das Vorgehen findet Anwendung in der bereits vorgestellten Anomaliedetektion (Abschnitt 8.3.3) und Prozesszustand-Überwachung (Abschnitt 9.2.3) und wird in den dazugehörigen Abschnitten näher erläutert.

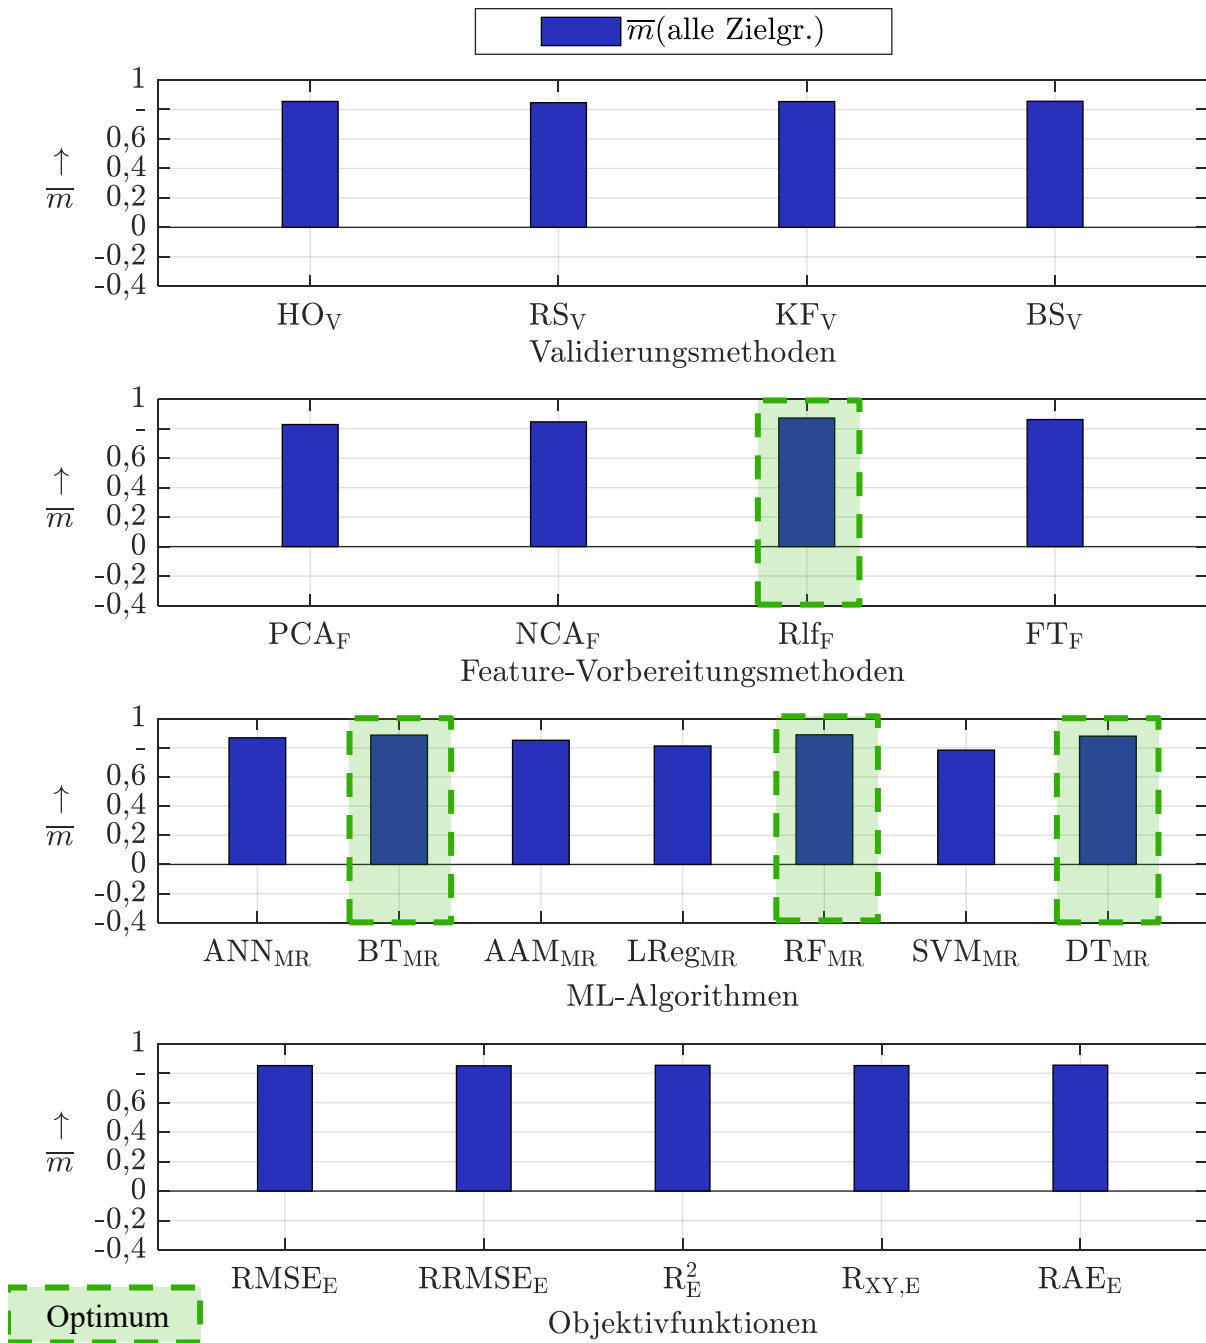


Abbildung A.25: Werkzeugverschleiß: Modellierungsstufen und Überanpassung bei überwachter Regression; die Markierung des Optimums jeder Modellierungsstufe erfolgt, falls die beste(n) Option(en) ein um $\approx 0,01$ höheres \bar{m} als die zweitbeste vorweist (\bar{m} = Durchschnitt des gewichteten Gesamt-Punktwerts für die vorliegende Methode einer Modellierungsstufe über alle Modellierungs-Pipelines hinweg; zur Symbol-Kennzeichnung der Zielgrößen, Validierungsmethoden, Feature-Vorbereitungsmethoden, ML-Algorithmen sowie der Objektivfunktionen sei auf die Definitionen im Abschnitt 6.3.4 und die Anhänge A.1.3 und A.10.2 verwiesen)

Schriftenreihe

Band 1

Koch, Jens Bodo: Unterstützung der schiffbaulichen Projektierung durch Repräsentation von Erfahrungswissen, 2004.

Band 2

Meyer, Sven: Flexible Gruppenarbeit in der Auftragsfertigung, 2004.

Band 3

Joswig, Dirk: Untersuchungen zum Zerspanverhalten weicher Elastomerwerkstoffe, 2005.

Band 4

Kerse, Nils: Unterstützung der schiffbaulichen Produktentstehung durch Einsatz von Virtual Reality (VR)-Technologien, 2007.

Band 5

Kurzewitz, Mathias: Kompetenzentwicklung als Element erfolgreicher Strategieumsetzung – dargestellt am Beispiel des Schiffbaus, 2007.

Band 6

Dauids, Niko: Workflow-Management in Produktentwicklungsprojekten der Investitionsgüterindustrie, 2008.

Band 7

Möller, Carsten: Untersuchungen zum Drehen von gesinterten WC-Co-Hartmetallwalzringen, 2009.

Band 8

Gotsch, Falko: Untersuchungen zum Zerspanverhalten von Elastomerschäumen mit dem Ziel einer wirtschaftlichen Fertigung von Feder-Dämpfer-Bauteilen, 2009.

Band 9

Neumann, Lutz: Risikomanagement bei der Gestaltung von Unternehmenskooperationen – untersucht am Beispiel der Investitionsgüterindustrie, 2009.

Band 10

Sellmer, Dirk: Untersuchungen zur Verbesserung des Arbeitsergebnisses beim Vollbohren unter besonderer Berücksichtigung der Prozesskräfte und der Spannbildung, 2009.

Band 11

Eggers, Daniel: Entwicklung von Dienstleistungsportfolios bei Investitionsgüterherstellern – dargestellt am Beispiel der maritimen Industrie, 2009.

Band 12

Kindler, Jörg: Werkstückqualität und Standzeitoptimierung von Zerspanwerkzeugen bei der Umrissbearbeitung von kohlenstofffaserverstärkten Kunststoffen, 2010.

Band 13

Frömming, Hanno: Zerspanung von WC-Co-Hartmetall im unterbrochenen Schnitt, 2011.

Band 14

Schweitzer, Thomas: Nutzungsgradsteigerung verketteter Produktionslinien, 2011.

Band 15

Wagner, Lars Arne: Szenariobasierte Planung und Steuerung mit Simulation im Schiffbau, 2011.

Band 16

Schäfer, Christoph: Einsatzmodell zur systematischen Nutzung von Virtueller Realität, 2012.

Band 17

Hartmann, Dirk: Delamination an Bauteilkanten beim Umrissfräsen kohlenstofffaserverstärkter Kunststoffe, 2012.

Band 18

Kuyumcu, Arif: Modellierung der Termintreue in der Produktion, 2013.

Band 19

Czumanski, Thomas: Handlungsorientierte Analyse der Arbeitsproduktivität in der Serienproduktion, 2013.

Band 20

Schütte, Christoph: Bohren und Hobeln von kohlenstofffaserverstärkten Kunststoffen unter besonderer Berücksichtigung der Schneide-Faser-Lage, 2014.

Band 21

Wandt, Robert: Modellgestützte Fertigungssteuerung in der Unikatfertigung am Beispiel des Schiffbaus, 2014.

Band 22

Eichenseer, Christiane: Beschichtung, thermomechanische Charakterisierung und Spannungsanalyse von Schneidkeramik, 2014.

Band 23

Heinig, Martin: Nutzung von Virtuellen Technologien für die Montageplanung von Unikaten, 2015.

Band 24

Körkel, Gregor K.: Zerspanbarkeitsbewertung von Faserverbundkunststoffen bei der Fräsbearbeitung dünnwandiger Bauteile in der Großserie, 2015.

Band 25

Ramirez Martinez, Juan A.: Flexible Automated Assembly Systems for Large CFRP-Structures using Geometrical and Force Information, 2015.

Band 26

Dose, Frank: Methode zur wissensbasierten Prozessentwicklung - Ein Ansatz für die Berücksichtigung sich wandelnder Teilsysteme beim Bohren von Schichtverbunden, 2015.

Band 27

Trzyna, Daniel: Modellierung und Steuerung von Eilaufträgen in der Produktion, 2015.

Band 28

Griefahn, Dominik: Geometrieprüfung innerer Strukturen von Faserverbund-Sandwichbauteilen, 2015.

Band 29

Borrmann, Christof: Adaptive Montageprozesse für CFK-Großstrukturen mittels Offline-Programmierung von Industrierobotern, 2016.

Band 30

Klingelhöller, Christian: Trennschleifen von CFK-Schalenbauteilen mit räumlich gekrümmten Konturen, 2016.

Band 31

Titov, Fedor: Technologiegestützte Angebotserstellung für den Umbau komplexer Investitionsgüter, 2016.

Band 32

Tietze, Florian: Analyse und Verbesserung der Arbeitsproduktivität in der Unikatproduktion, 2017.

Band 33

Geis, Tobias: Bearbeitungsstrategien zur Zerspanung von Faser-Verbund-Honeycomb-Sandwich, 2017.

Band 34

Koppold, Nico: Kapazitätsplanung und -steuerung in der Instandhaltungsproduktion von Investitionsgütern, 2017.

Band 35

Halata, Philipp S.: Augmented-Reality-gestützte Informationsbereitstellung für die Unikatproduktion, 2018.

Band 36

Brügmann, Felix: Bauteilqualität und Werkzeugverschleiß beim Fräsen von CFK-Gelege unter räumlichen Eingriffsbedingungen, 2018.

Band 37

Benter, Martin: Analyse von Bewegungsabläufen mit 3D-Kameras, 2018.

Band 38

Koch, Christoph: Wertstromanalyse und -design für Auftragsfertiger, 2018.

Band 39

Cordes, Marcel: Modellierung von Bahnengenauigkeit und dynamischer Stabilität beim robotergeführten Fräsen, 2019.

Band 40

Piontek, Andreas: Modellierung der Termintreue im Auftragsdurchlauf, 2020.

Band 41

Grabner, Constantin: Methodengestütztes Produktivitätsmanagement. Entwicklung eines datenbasierten Vorgehens, 2020.

Band 42

Glöckner, Robert: Entwicklung eines Gesamtmodells der Arbeitsproduktivität und der logistischen Zielgrößen, 2020.

Band 43

Schröder, Henrik: Kompetenzentwicklung in der Montage mit Hilfe virtueller Technologien, 2020.

Band 44

Engehausen, Friederike: Modellierung und Auslegung der Reihenfolgebildung mit Rüstfamilien, 2021.

Band 45

Sikorra, Jan Niklas: Frühzeitige Aufwands- und Termineinschätzung der schiffbaulichen Unikatproduktion, 2021.

Band 46

Haux, Moritz A.: Modellierung von Unsicherheiten in der Planung der Unikatproduktion, 2021.

Band 47

von Wenserski, Robert: Helixfräsen und Bohren von laseradditiv gefertigten Bauteilen aus Titan für Luftfahrtanwendungen, 2021.

Band 48

Meluzov, Nikolaj: Informationsmanagement für ein digitales Instandhaltungsassistenzsystem, 2022.

Band 49

Rost, Jan Robert: Digitale Assistenzsysteme für kollaboratives Arbeiten in der Unikatproduktion, 2023.

Band 50

Steenwerth, Philipp: Analyse und Optimierung von Suchvorgängen in der industriellen Produktion, 2023.

Band 51

Brosche, Justus: Nutzung von Motion-Capture-Technologien zur individuellen Ergonomieanalyse in der Produktion, 2023.

Band 52

Mehnen, Jan: Modellgestützte Berechnung der thermischen Belastung bei der Zerspannung von unidirektionalem CFK, 2023.

Band 53

Mundt, Christopher: Modellbasierte Auftragsannahme und -terminierung, 2024.

Band 54

Winter, Michael: Logistische Modellierung von Chargenarbeitssystemen, 2024.

Band 55

Elzalabany, Ahmed: A Digital Assistance System for Maritime Commissioning Processes, 2024.

Band 56

Breitzke, André: Modellbasierte Identifikation und Korrektur umgebungstemperaturabhängiger thermoelastischer Verlagerungen dreiachsiger Portalfräsmaschinen, 2024.

Band 57

Köttner, Lars Stephan: Zerspankraftmodellierung und Prozessgrenzen der Umrissbearbeitung von FKV-Bauteilen mit scheibenförmigen Werkzeugen, 2025.

Band 58

Rana, Pulkit: Efficient optimization of turning processes for powertrain components using multi model-based simulation, 2025.

Band 59

Romanenko, Denys: Maschinelles Lernen zur Überwachung semi-automatischer Bohrprozesse im Flugzeugbau, 2025.