

Datengetriebene Methoden zur Qualitäts- und Verschleißbestimmung beim Scherschneiden

Von der Fakultät für Ingenieurwissenschaften,
Abteilung Maschinenbau und Verfahrenstechnik der
Universität Duisburg-Essen
zur Erlangung des akademischen Grades

eines

Doktors der Ingenieurwissenschaften

Dr.-Ing.

genehmigte Dissertation

von

Maximilian Lorenz
aus
Memmingen

Gutachter: Prof. Dr. rer. nat. habil. Robert Martin
Prof. Dr. sc. ETH Zürich Bernd Pinzer
Prof. Dr.-Ing. Dirk Söffker

Tag der mündlichen Prüfung: 07.07.2023

Danksagungen

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Forschungszentrum Allgäu der Hochschule für angewandte Wissenschaften Kempten.

Zunächst danke ich Herrn Prof. Dr. rer. nat. Johannes Gottschling und Herrn Prof. Dr. rer. nat. habil. Robert Martin für die fachlichen Anreize, die menschlich stets überaus freundliche Unterstützung und die investierte Zeit bei der Betreuung der vorliegenden Arbeit.

Für die Unterstützung an der Hochschule Kempten ergeht ein besonderer Dank an Herrn Prof. Dr. sc. Bernd Pinzer und Herrn Prof. Dr.-Ing. Christian Donhauser, die mich nicht nur fachlich, sondern auch im persönlichen Bereich unterstützt und damit wesentlich zum Gelingen dieser Arbeit beigetragen haben.

Herrn Prof. Dr.-Ing Dirk Söffker danke ich für die Übernahme des dritten Gutachtens.

Herrn Prof. Dr. rer. nat. Michael Layh und Herrn Prof. Dr. rer. nat. Tobias Windisch, die mir während meiner Dissertation mit Rat und Tat zur Seite standen, danke ich ebenfalls.

Allen Mitarbeitern und ehemalige Mitarbeiter des Labors für optische 3D-Messtechnik und Computer Vision der Hochschule Kempten danke ich für die Unterstützung, insbesondere Herrn Korbinian Prause.

Meinen Kollegen Herrn Daniel Städele, Matthias Strauß, Josef Driendl und Johannes Epple, die die Arbeitstage so vielfältig gestaltet haben, danke ich.

Ein besonderer Dank ergeht an meinen ehemaligen Kollegen und verlässlichen Freund Herrn Matthias Menzl. Für die unzähligen fachlichen Diskussionen, die Unterstützung und Zeit, aber auch die persönlichen Gespräche. Seine Erfahrung war unerlässlich für das Gelingen dieser Arbeit.

Meinen Freunden danke ich für die gemeinsam verbrachte Freizeit und Sonntage. Meinen Eltern und Geschwistern bin ich besonders dankbar, einfach für alles.

Memmingerberg, im Juli 2023

Maximilian Lorenz

Kurzfassung

In der vorliegenden Arbeit werden Methoden zur datengetriebenen Qualitäts- und Verschleißbestimmung beim Scherschneiden entwickelt. Zunächst wird ein optisches Überwachungssystem in einen Scherschneidprozess integriert und eine Inline-Überwachung in Bezug auf die Schnittflächenkenngrößen ermöglicht. Für die automatische Qualitätsbestimmung wird am Beispiel der Glattschnitthöhe ein Algorithmus zur automatisierten Bildverarbeitung gezeigt. Die neuen Möglichkeiten, die durch diese Entwicklung entstehen, werden anhand einer Fallstudie analysiert. Um die Schwächen des entwickelten Algorithmus mit Blick auf die Verarbeitungszeit auszugleichen, werden ebenfalls neuronale Netzwerke zur Bildverarbeitung untersucht. Zunächst wird hierzu eine Datenmenge aus dem Fertigungsprozess aufgezeichnet und ein manuelles Labelling sowie eine künstliche Datenerweiterung durchgeführt. Beruhend auf Normen und Expertenwissen, wird eine Methode zur Bewertung der Prognosegüte entwickelt. Diese beinhaltet eine Bewertung anhand von verschiedenen Koeffizienten, die sowohl konturbasierte als auch regionenbasierte Ansätze kombinieren. Durch einen Vergleich unterschiedlicher Netzwerkarchitekturen zur Bildsegmentierung und deren Optimierung wird eine Netzwerkarchitektur ermittelt, die die Qualitätsbewertung im Hinblick auf die Glattschnitthöhe innerhalb des Fertigungsprozesses ermöglicht.

Abschließend wird ein Sensornetzwerk bestehend aus unterschiedlichen Sensoren und dem entwickelten Überwachungssystem an einem Scherschneidprozess installiert. In einer Versuchsreihe werden Daten der unterschiedlichen Datenquellen über die Lebensdauer eines Schneidstempels aufgezeichnet. Zusätzlich wird zu definierten Intervallen der vorliegende Schneidstempelverschleiß ermittelt. Die Daten werden in Verschleißklassen eingeteilt und durch unterschiedliche Datenvorverarbeitung entstehen mehrere Merkmalsräume. Diese unterscheiden sich zum einen durch die Kombination der Datenquellen als auch durch die angewendete Datenreduzierung. Die unterschiedlichen Merkmalsräume dienen zum Training von sowohl klassischen Algorithmen des maschinellen Lernens als auch neuronalen Netzwerken. Eine Bewertung und Analyse erfolgt anhand der jeweiligen Konfusionsmatrix und mittels SHAP-Werten. Es zeigte sich, dass durch eine Vorhersage der Verschleißklassen beruhend auf den Bildaufnahmen der Glattschnittfläche nur minimal schlechtere Ergebnisse erzielt werden als durch ein Sensornetzwerk beruhend auf einer Kombination aller Datenquellen.

Abstract

In this thesis, methods for data-driven quality and wear determination during punching are developed. First, an optical monitoring system is integrated into a punching process and thereby an inline monitoring of the burnish part is established. For automatic quality determination, an image processing for the measurement of the burnish part is developed. The new possibilities created by this development are examined through a case study. In order to compensate for the drawbacks of the developed algorithm regarding processing time, neural networks for image processing are investigated. Foremost, a dataset from the manufacturing process is recorded and a manual labelling and an artificial data augmentation are carried out. Based on standards and expert knowledge, a method for evaluating the prediction quality of the neural network is developed. This includes an evaluation based on different coefficients, combining both contour-based and region-based approaches. Through the comparison of various network architectures for image segmentation and employing hyperparameter optimization, a specific network architecture has been identified. This architecture allows for the evaluation of the quality of the burnish part in the manufacturing process.

Finally, a sensor network consisting of multiple sensors and the monitoring system is installed on a punching process. In a test series, data from the various data sources are recorded over the lifetime of a punch. In addition, the existing punch wear is determined at defined intervals. The data is labelled into different wear stages and several feature spaces are created through different data pre-processing. These differ, on the one hand, by the combination of data sources and, on the other hand, by the applied data reduction. The different feature spaces are used to train both classical machine learning algorithms and neural networks. An evaluation and analysis of the created models is performed using the confusion matrix and SHAP-values. It is shown that a prediction of the wear classes based on the images of the cutting surface achieved only minimally worse results than a sensor network based on a combination of all data sources.

Inhaltsverzeichnis

Abbildungsverzeichnis	XIII
Tabellenverzeichnis	XVI
Abkürzungsverzeichnis	XVII
1 Einleitung	1
1.1 Motivation und Problemstellung	1
1.2 Zielsetzung	2
1.3 Aufbau der Arbeit	3
2 Stand der Technik	5
2.1 Scherschneiden	5
2.1.1 Grundbegriffe nach DIN 8588	5
2.1.2 Fertigungsverfahren Scherschneiden	5
2.1.3 Schnittflächenkenngrößen	11
2.1.4 Einflussgrößen auf das Scherschneiden	15
2.1.5 Qualitätskriterium Verschleiß	16
2.1.6 Stanzbiegeautomat und Werkzeugaufbau	18
2.1.7 Messtechnik	20
2.2 Maschinelles Lernen	23
2.2.1 Grundlagen der datengetriebenen Vorhersage	23
2.2.2 Methoden des maschinellen Lernens	24
2.2.3 Merkmalsauswahl	29
2.2.4 Kreuzvalidierung	30
2.2.5 Gütemaße zur Modellbewertung	30
2.2.6 Merkmalsanalyse mittels Shapley-Werten	32
2.3 Triangulation und Bildsegmentierung	33
2.3.1 Triangulation	33
2.3.2 Segmentierung	34
2.3.3 Aktive Konturen	35

2.3.4	Methoden des maschinellen Lernens zur Segmentierung	36
2.4	Ermittlung der Bauteilqualität und Prozessüberwachung beim Scherschneiden	37
2.4.1	Messung der Bauteilqualität beim Scherschneiden	37
2.4.2	Prozessüberwachung beim Scherschneiden	40
2.5	Abgrenzung der Arbeit	42
3	Schnittflächenanalyse durch klassische Bildverarbeitung	43
3.1	Schneidwerkzeug und Stanzbiegeautomat	43
3.2	Optisches Überwachungssystem	44
3.2.1	Bildaufnahmeverfahren	46
3.2.2	Lichtschnittverfahren	47
3.2.3	Komponenten des Überwachungssystems	47
3.2.4	Steuerung des Überwachungssystems	48
3.2.5	Kalibrierung des Triangulationsaufbau	49
3.2.6	Einfluss des Anstellwinkels	50
3.3	Bildverarbeitung zur Überwachung der Bauteilqualität	50
3.3.1	Bildverarbeitung für die Bildaufnahmen	50
3.3.2	Bildverarbeitung für das Lichtschnittverfahren	54
3.4	Verifizierung des Überwachungssystems	56
3.4.1	Verifizierung der Bildaufnahmen	56
3.4.2	Verifizierung des Lichtschnittverfahrens	57
3.4.3	Spezifikation des Überwachungssystems	59
3.5	Fallstudie: Nutzen in der Produktion	61
3.6	Zusammenfassung des Überwachungssystems	65
4	Schnittflächenanalyse durch neuronale Netzwerke	67
4.1	Expertenumfrage	68
4.2	Datenvorverarbeitung	68
4.3	Modellbildung	70
4.3.1	Ähnlichkeitskoeffizient und Loss-Funktion	71
4.3.2	Netzwerkarchitektur	76
4.3.3	Hardware und Training	77
4.4	Bewertung der Prognosegüte	78
4.4.1	Vergleich der unterschiedlichen Architekturen	78
4.4.2	U-Net++-Optimierung	78
4.4.3	Hyperparameter	80
4.4.4	Backbone	82
4.4.5	Zusammenfassung der untersuchten Architekturen	84
4.5	Evaluierung der Architektur anhand von Transferdaten	84
4.6	Zusammenfassung	87
5	Sensornetzwerk beim Scherschneiden	91
5.1	Sensornetzwerk und Datenaufzeichnung	91
5.1.1	Maschinenparameter	92

5.1.2	Aufzeichnung der abhängigen Variable	93
5.1.3	Aufzeichnung der unabhängigen Variablen	93
5.2	Versuchsdurchführung	98
5.3	Vorverarbeitung der Datenmenge	100
5.3.1	Vorverarbeitung der unabhängigen Variablen	102
5.3.2	Vorverarbeitung der abhängigen Variable	102
5.3.3	Datenreduzierung	105
5.4	Modellbildung	107
5.5	Evaluierung der Modelle	108
5.5.1	Sensormerkmale (Referenz)	108
5.5.2	Sensormerkmale und Bildmerkmale	110
5.5.3	Sensormerkmale und Bauteilqualitätsmerkmale	111
5.5.4	Bauteilqualitätsmerkmale	111
5.5.5	Bildmerkmale	112
5.6	Diskussion der Ergebnisse	112
5.7	Zusammenfassung	115
6	Zusammenfassung und Ausblick	117
6.1	Zusammenfassung	117
6.2	Ausblick	120
	Literaturverzeichnis	123
	Normen und Richtlinien	135
A	Anhang	137
A.1	Technische Daten der verwendeten Komponenten für das Überwachungs- system	137
A.2	Technische Daten der verwendeten Messinstrumente	138
A.3	Ablaufdiagramm der Algorithmen zur Bildverarbeitung	139
A.4	Gesamtübersicht der trainierten Architekturen	140
A.5	Auswertung der Netzwerke zur Bildverarbeitung	142
A.6	Technische Daten der verwendeten Sensoren für das Sensornetzwerk . . .	144
	Publikationsliste	145

Inhaltsverzeichnis

Abbildungsverzeichnis

2.1	Einteilung der Fertigungsverfahren	6
2.2	Unterteilung der Verfahren Abschneiden, Lochen und Ausschneiden . . .	7
2.3	Begriffe am Scherschneidwerkzeug	8
2.4	Phasen des Schneidvorgangs	9
2.5	Kraftverlauf eines Normalschneidvorganges	10
2.6	Profilschnitt einer Schnittfläche und Kenngrößen nach VDI-Richtlinie 2906	12
2.7	Schnittflächenbildung beim Scherschneiden	13
2.8	Unterschiedliche Ausbildung der Schnittfläche	14
2.9	Auswahl unterschiedlicher Einflussgrößen auf die Schnittflächenkenngrößen	16
2.10	Unterschiedliche Verschleißformen am Schneidstempel	17
2.11	Verschleiß-Zeit-Diagramm	18
2.12	Stanzbiegeautomat der Otto Bihler Maschinenfabrik GmbH & Co. KG . .	19
2.13	Aufbau des in dieser Arbeit verwendeten Säulenführungswerkzeugs . . .	20
2.14	Funktion des piezoelektrischen Effekts und Aufbau eines Beschleunigungssensors	21
2.15	Verarbeitung des Körperschallsignals (AE-Signal), mittels Bandpassfilter und quadratische Mittelwert (engl. root mean square) (RMS) zum AE-RMS-Signal.	22
2.16	Überblick der vorgestellten Bereiche der Künstlichen Intelligenz	24
2.17	Künstliches Neuron und künstliches neuronales Netz.	26
2.18	Darstellung der Funktionsweise von Faltungsschichten (engl. Convolution Layer)	28
2.19	Darstellung unterschiedlicher Netzwerkschichten	28
2.20	Darstellung eines convolutional neural network (CNN) zur Klassifizierung	29
2.21	Grundprinzip der Triangulation	34
2.22	Funktionsprinzip des Lichtschnittverfahrens	35
2.23	Vorrichtung zur Ermittlung der Schnittflächenkenngrößen	39
2.24	Anzahl der wissenschaftlichen Studien im Zeitraum ab 1960. Die verwendeten Suchbegriffe sind in der Abbildung dargestellt	40

3.1	Bauteilgeometrie, die in dieser Arbeit verwendet wird.	44
3.2	Aufbau des Stanzbiegeautomaten an dem das Überwachungssystem angebracht wird	45
3.3	Funktionsprinzip der Bildaufnahme und der Triangulation mit einer Kamera mit Anstellwinkel γ und Triangulationswinkel φ	46
3.4	Aufbau und Montageposition des Überwachungssystems am Stanzbiegeautomaten	48
3.5	Ablaufdiagramm der Bildaufnahme und des Lichtschnittverfahrens innerhalb eines Fertigungstakts bei 250 Hub pro Minute (240 ms pro Hub).	49
3.6	Kalibrierung des Überwachungssystems auf dem Messtisch	51
3.7	Feature Image für den Algorithmus der Aktiven Kontur zur Ermittlung der Übergangslinien zwischen Glattschnitt- und Bruchfläche	52
3.8	Selektion des Glattschnittanteils	53
3.9	Bildaufnahmen des Überwachungssystems und Segmentierung der Glattschnittfläche durch den entwickelten Algorithmus aus dem Produktionsprozess für zwei unterschiedlicher Materialien	55
3.10	Daten des Lichtschnittverfahrens aus dem Produktionsprozess	56
3.11	Verifizierung der Lichtschnittdaten mit Mikroskopdaten	60
3.12	Schneidkantenmessung am Schneidstempel während der Versuchsreihe	62
3.13	Entwicklung der Schnittfläche aufgrund von Verschleiß durch Aufnahmen aus dem Überwachungssystem	63
3.14	Entwicklung der Glattschnitthöhe über die Lebensdauer des Schneidtempels	64
4.1	Ergebnisse der Expertenbefragung	69
4.2	Eigene Definition der Abschnitte der Glattschnittfläche auf Basis der Expertenbefragung	69
4.3	Analyse der Ähnlichkeitsmaße	73
4.4	Beispiel einer Vierer-/Achter-Nachbarschaft und Ermittlung separater Komponenten	74
4.5	Architektur von U-Net++ und exemplarischer Trainingsverlauf der Loss-Funktion.	77
4.6	Bewertung der Architektur U-Net++ mit dem kombinierten Koeffizient.	80
4.7	Prognosen verschiedener Netzwerkarchitekturen zur Segmentierung des Glattschnittanteils. Tatsächliche Kontur in grün.	81
4.8	Architektur des U-Net++ mit Dense-Backbone	85
4.9	Evaluierung der entwickelten Netzwerkarchitekturen auf dem Transferdatensatz	87
4.10	Aufteilung der Auswertung der Transferdaten für die Architektur <i>U-Net++ mit 64 Feature Maps</i>	88
5.1	Vermessung des Schneidtempels mit dem konfokalen Mikroskop an acht Messstellen (links) und Bestimmung der 45°-Verschleißlänge (rechts).	94
5.2	Sensoren am Schneidwerkzeug, die in dieser Arbeit verwendet werden	95
5.3	Erweiterung der Presseneinheit zur Kalibrierung des Kraftsensors im eingebauten Zustand	96

5.4	Ablauf der Datenaufzeichnung im Stanzbiegeautomat.	98
5.5	Sensorsignale während der durchgeführten Datenaufzeichnung	99
5.6	Aufnahmen durch das Überwachungssystem aus der Versuchsdurchführung	100
5.7	Übersicht über den angewandten Prozess zur Modellbildung.	101
5.8	Messkurven der Kraft-, Beschleunigungs- und Körperschallmessung für eine Bauteil	103
5.9	Entwicklung einzelner Messgrößen infolge des Verschleißes über die Le- bensdauer des Schneidstempels	104
5.10	Schneidstempel am Ende seiner Lebensdauer	106
5.11	SHAP-Werte und Konfusionsmatrix für die Light Gradient Boosting Ma- chine trainiert auf dem Merkmalsraum <i>Sensormerkmale</i>	109
5.12	SHAP-Werte und Konfusionsmatrix für die Logistic Regression trainiert auf dem Merkmalsraum <i>Sensormerkmale und Bildmerkmale</i>	110
5.13	SHAP-Werte und Konfusionsmatrix für die Light Gradient Boosting Ma- chine trainiert auf dem Merkmalsraum <i>Sensormerkmale und Bauteilquali- tätsmerkmale</i>	111
5.14	SHAP-Werte und Konfusionsmatrix für die Logistic Regression trainiert auf dem Merkmalsraum <i>Bildmerkmale</i>	113
A.1	Ablaufdiagramm der Algorithmen zur Bildverarbeitung	139
A.2	Vollständige Bewertung des Referenznetzwerks U-Net++, aufgeteilt nach den Kategorien der künstlichen Datenerweiterung. Teil 1	142
A.3	Vollständige Bewertung des Referenznetzwerks U-Net++, aufgeteilt nach den Kategorien der künstlichen Datenerweiterung. Teil 2	143

Abbildungsverzeichnis

Tabellenverzeichnis

2.1	Begriffsdefinitionen für das Scherschneiden	5
2.2	Optisches Erscheinungsbild der Schnittflächen	12
2.3	Konfusionsmatrix für zwei Klassen	31
3.1	Fertigungsparameter an der Bihler GRM-NC	58
3.2	Gewichtungsfaktoren für die Bildverarbeitung	58
3.3	Vergleich der ermittelten Glattschnitthöhe zwischen Überwachungssystem und Mikroskop. Die Mikroskopdaten stellen die Vergleichswerte dar. . . .	59
3.4	Vergleich der Referenzoberfläche mit der erstellten Punktwolke in μm . .	61
4.1	Struktur der Datenerweiterung für die Trainings- und Testdaten. (Die Farben werden für die Bewertungsdiagramme festgelegt.)	70
4.2	Trainingsparameter für die Bildverarbeitungsnetzwerke	78
4.3	Vergleich der ausgewählten Architekturen	79
4.4	Mittelwert und Standardabweichung von fünf Trainingsdurchläufen der U-Net++ Architektur	79
4.5	Vergleich der Hyperparametervariation der U-Net++ Architektur	82
4.6	Vergleich der Backbone-Variation	83
4.7	Vergleich der verschiedener Netzwerkarchitekturen anhand der Transfer- datenmenge	86
5.1	Fertigungsparameter der Versuchsreihe	92
5.2	Mittelwert und Standardabweichung der Banddicke der verwendeten Bandmaterial-Coils	100
5.3	Einteilung der Klassen des Verschleißverhaltens. Die Merkmale beziehen sich unter anderem auf die visuelle Begutachtung der Bildaufnahmen der Schnittfläche.	105
5.4	Untersuchte Hyperparameter für die neuronalen Netzwerke	108
5.5	Ergebnisse zum Merkmalsraum Sensormerkmale	109
5.6	Ergebnisse zum Merkmalsraum Sensormerkmale und Bildmerkmale . . .	110
5.7	Ergebnisse zum Merkmalsraum Sensormerkmale und Bauteilqualitäts- merkmale	111

Tabellenverzeichnis

5.8	Ergebnisse zum Merkmalsraum Bauteilqualitätsmerkmale	112
5.9	Ergebnisse zum Merkmalsraum Bildmerkmale	112
A.1	Übersicht der verwendeten Komponenten für das Überwachungssystem .	137
A.2	Technische Daten des Profilprojektor Keyence IM6020	138
A.3	Technische Daten des konfokalen 3D Laserscanning-Mikroskop Keyence VK-X100	138
A.4	Vergleich der erzielten Ergebnisse aller untersuchten Netzwerkarchitek- turen mit den Testdaten	140
A.5	Vergleich der erzielten Ergebnisse aller untersuchten Netzwerkarchitek- turen mit den Transferdaten	141
A.6	Übersicht der verwendeten Versuchskomponenten für das Sensornetzwerk	144

Abkürzungsverzeichnis

AE	Körperschall (engl. acoustic emission)
AUC	area under the curve
ASUM-DM	Analytics Solutions Unified Method for Data Mining/Predictive Analytics
BG	Hintergrund (engl. background)
CM	kombinierter Koeffizient
CNN	convolutional neural network
COM	Schwerpunktsberechnung (engl. center of mass)
CRISP-DM	Cross Industry Standard Process for Data Mining
DICEBD	dice boundary
DSC	dice similarity coefficient
FC	fully connected
FG	Vordergrund (engl. foreground)
FN	false-negativ
FP	false-positiv
IoU	Intersection over Union
KDD	knowledge discovery in databases
LR	Learning-Rate
MLP	multilayer Perceptron
NSD	normalized surface distance
PCA	Hauptkomponentenanalyse (engl. Principal Component Analysis)
RELU	Rectified Linear Unit
RMS	quadratische Mittelwert (engl. root mean square)
ROC	receiver operating characteristics
ROI	Region of Interest

Tabellenverzeichnis

SHAP	Shapley Additive Explanations
TN	true-negativ
TP	true-positiv
UP	unterer Umkehrpunkt

1.1 Motivation und Problemstellung

Die Fertigungstechnik sieht sich heutzutage mit immer kürzeren Entwicklungszeiten, höheren Qualitätsanforderungen sowie kundenspezifischen Produkten konfrontiert. Hinzu kommen die steigenden Energiepreise, die im Vergleich zum Vorjahr um durchschnittlich 32,2 % gestiegen sind und die Situation zusätzlich erschweren (Statistisches Bundesamt 2023). Angesichts dieser Zunahme und unter ökologischen Gesichtspunkten betrachtet, muss eine wirtschaftliche und ressourceneffiziente Prozessführung gewährleistet werden (Bauernhansl 2020, S. V).

Auch das Scherschneiden, als Fertigungsverfahren für die wirtschaftliche Massenproduktion von qualitativ hochwertigen Bauteilen, insbesondere für die Automobilindustrie und die Herstellung von elektronischen Kontaktelementen, sieht sich diesen Herausforderungen ausgesetzt (Schomaker 1994). Die Glattschnittfläche ist dabei von entscheidender Bedeutung, da auf ihr die Bauteilspezifikation beruht und diese als qualitäts- und prozessbestimmender Faktor betrachtet wird (Hoogen 1999; Hernández et al. 2006; J. D. Kim et al. 2012; Behrens und Jocker 2013).

Allerdings führt der Verschleiß der Schneidstempel innerhalb seiner Lebensdauer zu degradierender Teilequalität und damit zu Kosten durch Stillstandszeiten und Werkzeuginstandsetzung (Volk et al. 2019, S. 21). Um diese Kosten zu reduzieren, ist die Kenntnis des Verschleißverhaltens erforderlich. Derzeit basiert diese Kenntnisse häufig auf Expertenwissen und der Trial-and-Error-Methode und den damit verbundenen Schwankungen. Unter Berücksichtigung der genannten Herausforderung ist es wünschenswert, diese Methodik zu ersetzen. Hierzu ist eine genaue Kenntnis über die Wirkmechanismen und deren Einfluss auf die Bauteilqualität und den Verschleiß erforderlich.

Die große Vielfalt an Maschinen-, Werkzeug-, Material- und Prozessparametern und ihre gegenseitigen Abhängigkeiten gestalten die Interpretierbarkeit von Prozesseinflüssen allerdings als schwierig (Hambli 2002a; Hambli 2003; Hernández et al. 2006). In zahlreichen Studien wurde der Einfluss einzelner Parameter auf den Scherschneidprozess untersucht (beispielsweise Beschleunigung (Breitling et al. 1997), Schneidkraft (Hohmann et al. 2017) oder Schallemission (Wadi et al. 1999)). Darüber hinaus wurden verschiedene Ansätze für Expertensysteme (Mardapittas et al. 1992), Feature-Engineering (Hernández et al. 2006; Klingenberg und Boer 2008; Hoppe et al. 2019; Kubik 2021) oder künstliche neuronale Netze (Hambli 2002b; Al-Momani et al. 2011; Trauth et al. 2018; Molitor et al. 2022) zur Vorhersage der Prozessqualität angewendet. Trotz aller Fortschritt kann der Scherschneidprozess noch immer nicht vollständig von einem umfassenden Prozessmodell erfasst werden (Klingenberg und Boer 2008; Hoppe et al. 2019).

Zusätzlich erfolgt die Bestimmung der Bauteilqualität (Schnittflächenparameter) häufig über die Korrelation mit indirekt gemessenen Parametern oder technischen Merkmalen anhand von Stichproben. Die Daten des Prozessergebnisses liegen daher in einer abweichenden Datendichte im Vergleich zu ihren Einflussparametern vor. Darüber hinaus werden diese Studien in der Regel unter kontrollierten Laborbedingungen durchgeführt, wodurch Abweichungen der genannten Parameter innerhalb ihrer Toleranzgrenzen in Verbindung mit einem degradierenden Prozess während dessen Lebensdauer ausgeschlossen werden. Angesichts des großen Parameterraumes ist es erforderlich, die Schnittfläche kontinuierlich unter realistischen Bedingungen zu ermitteln (Wolfschläger et al. 2022; Molitor et al. 2022). Die Datendichte des Prozessergebnisses wird somit erhöht und eine verbesserte Datenbasis in Bezug auf ein Prozessmodell gewährleistet.

1.2 Zielsetzung

Ziel dieser Arbeit ist es, datengetriebene Methoden für die Qualitäts- und Verschleißbestimmung beim Scherschneidprozess zu untersuchen. Hierzu soll zunächst eine Methode zur Qualitätsbestimmung innerhalb des Fertigungsprozesses entwickelt werden. Die in vielen industriellen Anwendungen qualitätsbestimmenden Kenngrößen der Schnittflächen, im Besonderen die Glattschnittfläche, sollen automatisch bestimmt werden. Angesichts der industriell eingesetzten Produktionsgeschwindigkeiten von bis zu 2000 Bauteilen pro Minute eignet sich vor allem ein optisches Messverfahren zur Aufzeichnung der Daten. Ein Konzept zur Aufnahme der Daten und zur automatisierten Bildverarbeitung soll entwickelt, verifiziert und in einer Stanzbiegeautomaten getestet werden. Mit diesem Prototyp soll gezeigt werden, dass eine kontinuierliche Qualitätsbestimmung im Scherschneidprozess möglich ist. Es soll untersucht werden, inwieweit dabei Methoden der klassischen Bildverarbeitung verwendet werden können.

Nachfolgend soll dann die Bildverarbeitung mittels künstlicher neuronaler Netzwerke untersucht werden. Im Fokus steht hierbei die Auswahl und Optimierung einer geeigneten Netzwerkarchitektur. Zunächst soll ein Gütemaß zur Bewertung der Netzwerkvorhersagen definiert und eine passende Loss-Funktion gefunden werden. Weiterhin soll eine Datenbasis für das Netzwerktraining geschaffen werden. Es soll aufgezeigt werden, anhand welcher Netzwerkparameter sich die besten Vorhersageergebnisse erzielen lassen und inwieweit eine Vorhersage innerhalb des Fertigungstaktes möglich ist.

Eine Methode zur Qualitätsbestimmung innerhalb des Fertigungsprozesses erweitert bisherige Prozessmodelle durch eine erhöhte Datendichte zum Prozessergebnis. Mit dieser neuen Datenbasis sollen datengetriebene Methoden zur Verschleißbestimmung der Aktivelemente untersucht werden. Im Besonderen sollen bekannte Methoden der Schneidprozessüberwachungen durch die Qualitätsbestimmung erweitert werden. Zunächst sollen bekannte Überwachungen in den Stanzbiegeautomaten integriert werden. Durch eine Versuchsreihe zum Schneidstempelverschleiß sollen dann Daten von diesen Überwachungsmethoden und der Qualitätsüberwachung gesammelt werden. Eine geeignete Datenvorverarbeitung soll ausgewählt werden. In der nachfolgenden Mo-

dellbildung soll untersucht werden, welche Methoden des maschinellen Lernens eine Verschleißbestimmung ermöglichen. Durch die Variation der Merkmalsräume und geeignete Analysen der gelernten Repräsentationen der Wirkmechanismen soll der Einfluss der einzelnen Merkmale auf die Vorhersagegüte und somit den Verschleißprozess gezeigt werden.

1.3 Aufbau der Arbeit

Der Ausgangspunkt dieser Arbeit wird in der Einleitung und im Stand der Technik erörtert. Der Handlungsbedarf wird mit Blick auf die gegenwärtigen Herausforderungen zur Gewährleistung einer wirtschaftlichen, agilen Produktion für den Bereich des Scherschneidens abgeleitet. Hierbei steht, in Abgrenzung zu anderen Arbeiten, die datengetriebene Inline-Qualitäts- und Verschleißbestimmung beim Scherschneiden im Fokus. In Kapitel 3 wird ein optisches Überwachungssystem zur Inline-Aufzeichnung der Schnittflächenkenngrößen an einem Stanzbiegeautomaten gezeigt. Auch wenn der Automat in der industriellen Anwendung Schneidprozesse mit Biegeprozessen kombiniert, wird in dieser Arbeit ausschließlich der Prozess des Scherschneidens durch die Schneidpresse analysiert.

Untersucht wird, wie eine automatisierte Bildverarbeitung die Glattschnitthöhe der gefertigten Bauteile ermitteln kann. Hierzu wird ein Algorithmus zur Segmentierung mittels aktiver Konturen angewendet. Weiterhin werden die Grundlagen für die Erweiterung des Überwachungssystems durch ein Lichtschnittverfahren geschaffen und ein Kalibrierungsprozess hierfür aufgezeigt. Anhand von Vergleichsmessungen und einer Fallstudie werden die Möglichkeiten des Überwachungssystems bewertet.

Durch die unterschiedlichen Ausprägungen der Schnittfläche ist eine Inline-Auswertung erschwert. Daher wird in Kapitel 4 die Segmentierung der Glattschnittfläche durch künstliche neuronale Netzwerke untersucht. Zunächst werden aus einer Bilddatenmenge, die vom Überwachungssystem aufgezeichnet wurde, manuell tatsächliche Segmentierungen erstellt. Eine anwendungsbezogene Loss-Funktion wird gezeigt und, basierend auf Expertenwissen, verschiedene Ähnlichkeitsmaße zur Bewertung der Segmentierung definiert. Unterschiedliche Netzwerkarchitekturen werden betrachtet und bewertet, um anschließend die Architektur mit der höchsten Performanz einer Optimierung zu unterziehen. Diese optimierte Architektur ermöglicht eine Inline-Segmentierung.

Basierend auf der entwickelten Qualitätsbestimmung in den Kapiteln 3 und 4 wird in Kapitel 5 ein Sensornetzwerk für den Scherschneidprozess an einem Stanzbiegeautomaten aufgebaut. Nachfolgend werden in einer Versuchsreihe Daten über die komplette Lebensdauer eines Stempels aufgezeichnet und eine manuelle Klassifizierung für die Modellbildung durchgeführt. In der Datenvorverarbeitung werden unterschiedliche Methoden zur Dimensionsreduzierung eingesetzt. Es werden sowohl klassische Methoden des maschinellen Lernens als auch tiefe neuronale Netzwerke auf die mit ihnen erreichbare Vorhersagegüte hin geprüft. Zusätzlich wird durch eine Einflussanalyse anhand von SHAP-Werten die Bedeutung der einzelnen Merkmale analysiert. Resultierend aus

Kapitel 1. Einleitung

diesen Analysen wird eine Aussage getroffen, welche Datenmenge die höchste Datendichte bezogen auf den Verschleißprozess von Aktivelementen beim Scherschneiden besitzt.

Abschließend werden in Kapitel 6 die Untersuchungen zusammengefasst und die erweiterten Kenntnisse mit Blick auf den Stand der Technik und die in der Einleitung formulierten Zielsetzungen bewertet. Der mögliche Nutzen für die Industrie wird beleuchtet, die Übertragbarkeit der Vorgehensweise auf artverwandte Prozesse gezeigt und ein Ausblick auf zukünftige Forschungsarbeiten gegeben.

2.1 Scherschneiden

2.1.1 Grundbegriffe nach DIN 8588

Um die Vorgänge des Scherschneidens eindeutig zu benennen, werden folgende Definitionen herangezogen:

„Bei den Verfahren des Scherschneidens und des Keilschneidens werden die Benennungen am Werkzeug von der Stammsilbe ‚Schneid‘ abgeleitet, im Gegensatz zu denen an einem durch Schneiden hergestellten Werkstück, die mit der Stammsilbe ‚Schnitt‘ gebildet werden.“ (DIN 8588 2013)

„Bei den Verfahren des Reißens und Brechens werden die Benennungen am Werkzeug von der Stammsilbe ‚Reiß‘ bzw. ‚Brech‘ abgeleitet, im Gegensatz zu denen am Werkstück, die mit der Stammsilbe ‚Riss‘ bzw. ‚Bruch‘ gebildet werden.“ (DIN 8588 2013)

Die Begrifflichkeiten werden in Tabelle 2.1 zusammengefasst:

Tabelle 2.1: Begriffsdefinitionen für das Scherschneiden (nach DIN 8588)

Begriffe am Werkzeug	Begriffe am Werkstück
Schneide/Schneidkante	Schnittkante
Schneidfläche	Schnittfläche
Brechfläche/-kante	Bruchfläche/-kante

2.1.2 Fertigungsverfahren Scherschneiden

Die Scherschneidverfahren (siehe Abbildung 2.1) gehören zu der Untergruppe der Zerteilverfahren und sind nach *DIN 8580* ein trennendes Fertigungsverfahren, das in die Untergruppen Scherschneiden, Messerschneiden, Beißschneiden, Spalten, Reißen und Brechen unterteilt ist (*DIN 8580* 2022). Vor allem das Scherschneiden besitzt innerhalb der metallverarbeitenden Industrie ein großes Anwendungsspektrum und ist ein Herstellungsverfahren für Blecherzeugnisse (Klocke 2017, S. 488). Zumeist werden die Werkstücke aus Halbzeugen aus Bandmaterial gefertigt (Siegert 2015, S. 226). Die

Kapitel 2. Stand der Technik

Teilevielfalt der Erzeugnisse reicht dabei von Kleinstteilen für die Schmuck- und Uhrenindustrie, über Steckverbinder für die Elektroindustrie hin zu Karosserieteilen für die Automobilbranche (Kolbe 2020, S. 1 f.). Übliche Werkstoffe sind niedrig legierte Stähle, Kupfer, Messing oder auch hochfeste Stähle (Kolbe 2020, S. 19 f.).

Wie in *DIN 8588* festgehalten wird, ist das Scherschneiden ein trennendes Fertigungsverfahren:

„Scherschneiden ist mechanisches Zerteilen von Werkstücken zwischen zwei Schneiden, die sich aneinander vorbeibewegen ohne Entstehen von formlosem Stoff.“ (*DIN 8588* 2013)

Hierzu zählen unter anderem Verfahren wie Ausschneiden, Lochen und Abschneiden. Zumeist erfolgt die Werkstofftrennung in einem durchgehenden Hub, kann aber auch in mehreren Hübten erfolgen. Weiterhin wird nicht nur anhand einer offenen oder geschlossenen Schnittlinie unterschieden, sondern auch danach, inwieweit der ausgeschnittene Anteil als Abfall oder Werkstück definiert wird (siehe Abbildung 2.2). Es ist zu erwähnen, dass in der Industrie der Abfall als Butzen bezeichnet wird (Hoffmann, Neugebauer et al. 2012, S. 681). (Siegert 2015, S. 224–226)

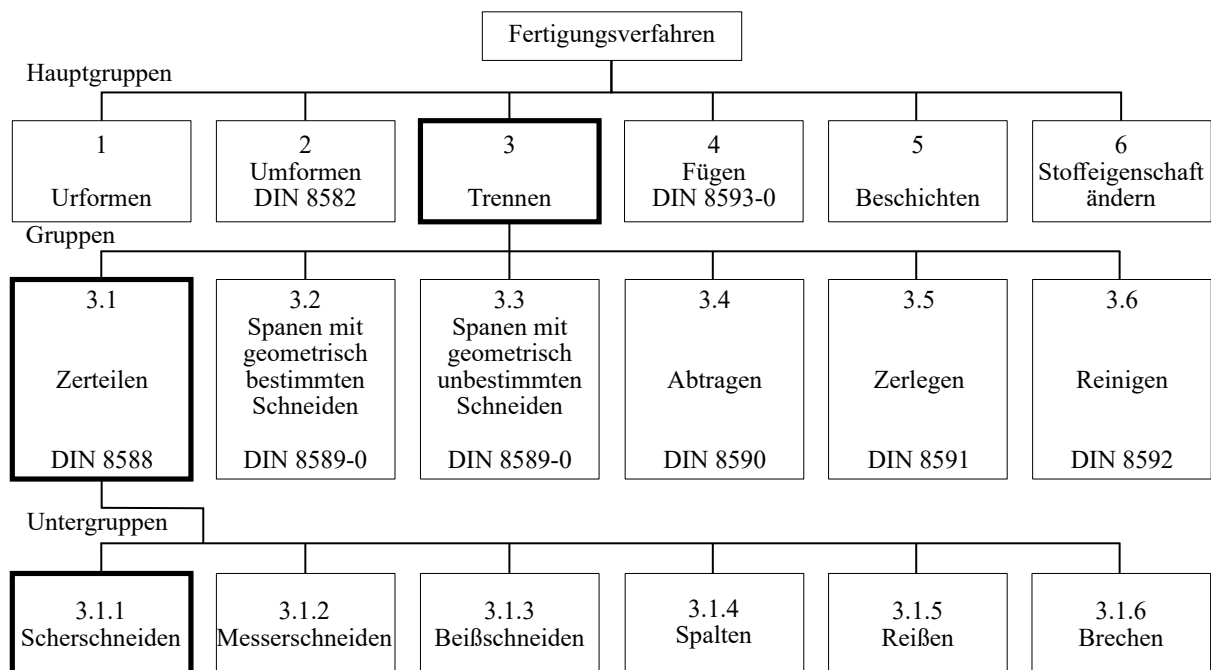


Abbildung 2.1: Einteilung der Fertigungsverfahren (*DIN 8588* 2013)

Für den Vorgang des (Scher-)Schneidens wird ein Schneidstempel und eine Schneidplatte, umgangssprachlich häufig Matrize genannt, benötigt; sie bilden das Schneidwerkzeug. Die Kanten des Schneidstempels und der Schneidplatte ergeben die Schneiden. Die Geometrie des Schneidstempels muss in der Schneidplatte in einem definierten Abstand äquidistant freigestellt sein, da der Stempel in die Schneidplatte eintaucht und den Werkstoff abtrennt. Dieser definierte Abstand wird als Schneidspalt u bezeichnet

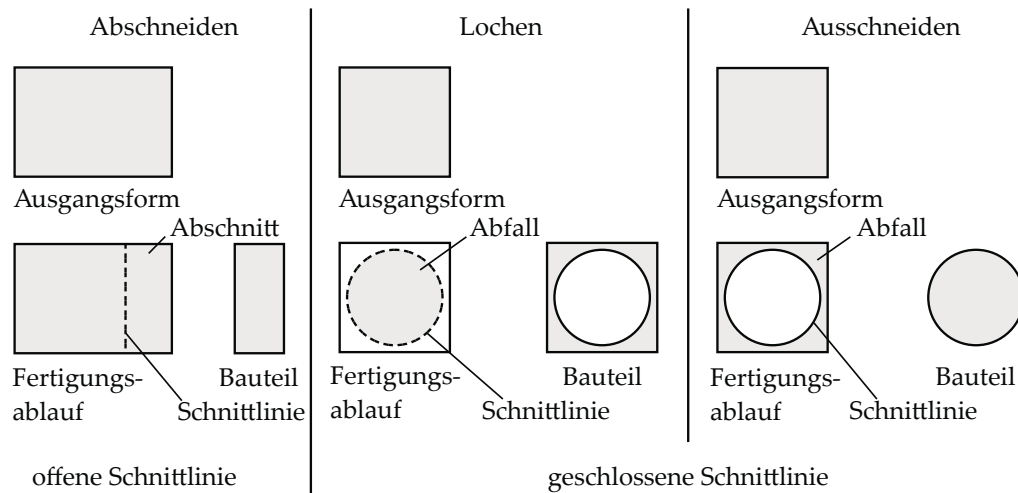


Abbildung 2.2: Unterteilung der Verfahren Abschneiden, Lochen und Ausschneiden (Siegert 2015, S. 226)

und ist abhängig von der Materialpaarung Werkstoff/Werkzeug und der zu erzeugenden Geometrie auszuwählen. Häufig ist in der Praxis zusätzlich noch ein Niederhalter vorgesehen, dessen Aufgabe darin besteht, das Blechmaterial daran zu hindern von der Schneidplatte abzuheben, und beim Rückzug des Stempels das Bandmaterial von selbigem abzustreifen. Der schematische Aufbau eines Scherschneidwerkzeuges ist in Abbildung 2.3 dargestellt. Da das Rohmaterial häufig als Halbzeug von Coils abgewickelt wird, spricht man auch vom Stanzstreifen, Streifen- oder Bandmaterial. (Hoffmann, Neugebauer et al. 2012, S. 681–683)

Im Folgenden wird vertiefend auf den Schneidvorgang eingegangen. Dabei wird der Prozess und die sich hierdurch ausbildenden Schnittflächen beschrieben. Die vorliegende Arbeit beschränkt sich auf den Bereich des Scherschneidens.

Ablauf des Schneidvorganges

Der Schneidvorgang kann in mehrere Phasen unterteilt werden (siehe Abbildung 2.4). In der Literatur finden sich hierzu unterschiedliche Angaben. Während in manchen Arbeiten nur die Phasen der reinen Materialverformungen (3 Phasen) betrachtet werden (Klocke 2017, S. 493; Kolbe 2020, S. 23 f.), finden in anderen Arbeiten auch die Spann- und Rückzugbewegungen (5 Phasen) Berücksichtigung (Hoffmann, Neugebauer et al. 2012, S. 681–683; Siegert 2015, S. 227–229). Für diese Arbeit erweist sich die ausführlichere Aufteilung als sinnvoll, da in den gesondert genannten Phasen wichtige Verschleißmechanismen vorliegen. Die Phasen nach Hoffmann (Hoffmann, Neugebauer et al. 2012, S. 681–683) und Siegert (Siegert 2015, S. 227–229) und die in ihnen ablaufende Prozesse lassen sich exemplarisch an einem Ausschneidevorgang darstellen.

Phase 1: Aufsetzen des Schneidstempels auf der Materialoberfläche

Das Bandmaterial wird durch den Niederhalter geklemmt und nachfolgend die Schneid-




Abbildung 2.3: Begriffe am Scherschneidwerkzeug (nach Hoffmann, Neugebauer et al. 2012, S. 681).

bewegung des Schneidstempels initialisiert. Der Schneidstempel trifft mit einer definierten Geschwindigkeit auf die Bandoberfläche.

Phase 2: Elastische Werkstoffverformung

Durch den Aufsetzvorgang des Schneidstempels und die gegenseitige Abstützung durch die Schneidplatte und den Niederhalter wird die Schneidkraft auf das Bandmaterial übertragen. Es wird ein Biegemoment um die Schneidkanten aufgebaut, das zu einer elastischen Durchbiegung des Bandmaterials im Kontaktbereich des Schneidstempels führt. Dabei treten ausgehend von der Schneidkanten stark belastete Ringzonen auf.

Phase 3: Plastische Werkstoffverformung

In den Ringzonen bilden sich Spannungen aus. Übertreffen diese Spannungen die Schubfließgrenze des Werkstoffes, beginnt der Werkstoff zu fließen und verformt sich fortan plastisch. Der Bereich, in dem die Fließprozesse in Schneidrichtung als auch senkrecht zu dieser stattfinden, wird Scherzone genannt und führt zu einer Materialverschleppung in den Schneidspalt hinein; dies ist der sogenannte Kanteneinzug. Mit zunehmendem Fortschritt der Schneidbewegung entsteht ein Übergang des Kanteneinzuges in eine glatte Scherfläche. Sie wird als Glattschnittzone bzw. -fläche bezeichnet und im Allgemeinen durch das Umformvermögen des Bandmaterials bestimmt. Die elastische Durchbiegung bleibt weiterhin erhalten und es liegt noch keine Materialtrennung vor.

Phase 4: Rissbildung und Werkstofftrennung

Im weiteren Prozess taucht der Schneidstempel immer weiter in das Material ein, bis eine maximale Schubspannung in der Scherzone aufgebaut ist. Diese werkstoffabhän-




Abbildung 2.4: Phasen des Schneidvorgangs. Die Stempelkraft wird durch den Pfeil angedeutet (nach Siegert 2015, S. 229).

gige Größe ist die Scherbruchgrenze und bedeutet, dass das Formänderungsvermögen des Werkstoffes erreicht ist. Durch die anhaltend anliegende Stempelkraft kommt es zur Werkstofftrennung in Form der Risseinleitung und –ausbreitung. Es entsteht die Bruchzone, die in verschiedenen Modifikationen vorliegen kann.

Phase 5: Werkstoffrückfederung und Stempelrückzug

Nach vollzogener Werkstofftrennung wird der reversible Verformungsanteil frei. Die unmittelbare Folge hieraus ist eine Rückfederung des Werkstoffes im Schnittbereich, die zu Maß- und Formänderungen führt. Diese geometrischen Änderungen erschweren den Stempelrückzug, da sich Schubspannungen zwischen der Mantelfläche des Schneidstempels und den Schnittflächen bilden. Hierdurch werden abrasive und adhäsive Verschleißmechanismen an der Schneidplatte und dem Schneidstempel begünstigt (Hoogen 1999, S. 11).

Die beschriebenen Mechanismen wirken sich ebenfalls auf die benötigte Schneidkraft aus. In der Literatur wird ein zeitabhängiger Verlauf der Schneidkraft abgeleitet und den einzelnen Schneidphasen zugeordnet (Hoffmann, Neugebauer et al. 2012, S. 681–683; Siegert 2015, S. 227–229).

Schneidkraft

Der Verlauf der Schneidkraft über die Zeit kann ebenfalls den oben genannten 5 Phasen zugeordnet werden (siehe Abbildung 2.5). In Phase 1 ist die Durchbiegung des Bandmaterials durch den aufsetzenden Schneidstempel dargestellt und durch den Übergang zu Phase 2 erfolgt die Annäherung an eine Hooke'sche Gerade. Weiterhin wird Energie im Schneidwerkzeug und Pressengestell gespeichert. Den Übergang zu Phase 3 bezeichnet die Schubfließgrenze des jeweiligen Werkstoffes. Durch die fortschreitende Stempelbewegung bilden sich der Kanteneinzug und die Glattschnittfläche aus. Durch die Formänderung und die dadurch bedingte Kaltverfestigung steigt der Schneidwi-




Abbildung 2.5: Kraftverlauf eines Normalschneidvorganges (Schmütsch 1990, S. 81; Doege und Behrens 2016, S. 361)

derstand des Werkstoffs und wirkt bis zum Scheitelpunkt der Kraftkurve. Nachfolgend nimmt der kraftübertragende Querschnitt in der Scherzone infolge der plastischen Verformung ab und die Schneidkraft sinkt. Wenn das Formänderungsvermögen des Werkstoffs erschöpft ist, bilden sich Risse im Werkstoff aus; die Trennphase 4 ist erreicht. Ein schlagartiges Absinken der Schneidkraft ist zu erkennen. Dieser sogenannte Schnittschlag setzt die in Maschine und Werkzeug gespeicherte potenzielle Energie frei und das System beginnt zu schwingen. In Phase 5 wird der Butzen zunächst in die Schneidplatte gedrückt und danach der Schneidstempel zurückgezogen. Infolge der Schwingungen und durch die Rückfederung des Bandmaterials kann es zu Berührungen von Schneidstempel und Schneidplatte kommen, wodurch der Stempel geklemmt wird. Hieraus resultiert ein verstärkter, abrasiver Verschleiß der Aktivelemente. (Hoffmann, Neugebauer et al. 2012, S. 687 ff.)

Die maximale Schneidkraft

$$F_{s,max} = l \cdot s \cdot k_s \quad (2.1.1)$$

wird kurz vor der Risseinleitung erreicht, wobei l die Gesamtlänge der Schnittlinie in mm, s die Banddicke in mm und k_s der Schneidwiderstand in N/mm^2 ist (Hoffmann, Neugebauer et al. 2012, S. 685 f.; Siegert 2015, S. 231 ff.; Kolbe 2020, S. 30 ff.).

Der Schneidwiderstand k_s stellt hierbei einen empirisch ermittelten Faktor dar. Er wird vor allem beeinflusst durch (Klocke 2017, S. 491 ff.):

- Größe des Schneidspalts u
- Werkzeugverschleiß
- Materialdicke s
- Schnittliniengeometrie
- Werkstoffeigenschaften
- Schmierung
- Schneidgeschwindigkeit
- geschlossene/offene Schnittliniengeometrie

So erfordert insbesondere der Werkzeugverschleiß eine Erhöhung des Schneidwiderstands über die Lebensdauer des Schneidstempels. Das Schneidkanten stumpfen infolge der immer wiederkehrenden Belastung ab, was mit einer Schneidkantenverrundung gleichzusetzen ist. Hierdurch entsteht eine größere Kontaktfläche während des Schneidprozesses. Da die Fließspannung des Werkstoffs konstant bleibt, bedingt dies ebenfalls eine Krafterhöhung. (Hoffmann, Neugebauer et al. 2012, S. 686 ff.)

Die Vielzahl an Einflussfaktoren erschwert die Bestimmung des Schneidwiderstands immens. Unter der Bedingung, dass das Verhältnis von Stempeldurchmesser zu Banddicke größer als 2 ist, kann jedoch vereinfacht angenommen werden

$$k_s = 0,8 \cdot R_m, \quad (2.1.2)$$

wobei R_m die Zugfestigkeit des Bandmaterials in N/mm^2 ist (Schuler GmbH 1996, S. 274).

Der Einflussfaktor der Zugfestigkeit wird auch von Loibl (Loibl 2003) herausgestellt. Diese Arbeit erforscht keramischen Schneidstempeln und zeigt, dass die Zugfestigkeit des zu schneidenden Bandmaterials als Einflussfaktor auf die Schneidkraft überwiegt.

2.1.3 Schnittflächenkenngößen

Um eine einheitliche geometrische Bewertung und Vergleichsmaße für die Qualität der Schnittflächen zu schaffen, werden in der VDI-Richtlinie 2906 (VDI 2906 Blatt 2 1994) die Kenngrößen der Schnittfläche definiert (siehe Abbildung 2.6). Hervorzuheben sind hierbei der Kanteneinzug h_E , die Glattschnittfläche h_S , die Bruchfläche h_B , welche die Glattschnittfläche unter einem abweichenden Winkel schneidet, der Bruchflächenwinkel β bzw. der Ergänzungswinkel β' und die Schnittgrathöhe h_G . Die Kenngrößen sind sowohl am Werkstück als auch am Butzen zu finden. Ergänzend sind neben den genannten Bezeichnungen auch der Glattschnittanteil h_S/s und der Bruchflächenanteil h_B/s als Kenngrößen angegeben. (VDI 2906 Blatt 2 1994)

Anwendungsbezogen sind die Qualitätsanforderungen an die Schnittflächen der Werkstücke unterschiedlichster Art und vom späteren Einsatz abhängig (Siegert 2015, S. 229 ff.). Die Schnittfläche kann als Träger für Dichtungen vorgesehen sein, ein Schnittgrat könnte insofern zur Beschädigung der Dichtung führen. Wenn die Schnittfläche als Führungsfläche oder Lagersitz dient, kann ein erhöhter Bruchflächenanteil zu erhöhtem Spiel




Abbildung 2.6: Profilschnitt einer Schnittfläche und Kenngrößen nach VDI-Richtlinie 2906 (nach VDI 2906 Blatt 2)

und zu einem größeren Verschleiß im Betrieb führen. Sind die gefertigten Löcher für Schraubenverbindungen vorgesehen, kann ein Schnittgrat die Schraubenverbindung beeinträchtigen; zwischen Schraubenkopf und Bauteil bildet sich durch den Grat ein Spalt aus, was im späteren Verlauf zu erhöhtem Setzen und einem Verlust von Vorspannkraft der Schraubverbindung führt. Auch bei der späteren Handhabung im Fertigungsprozess und im Gebrauch entsteht durch den Grat eine Verletzungsgefahr für den Menschen. (Behrens und Jocker 2013, S. 17)

Die entstehenden Schnittflächen weisen Charakteristika auf, die sich schon in der optischen Wahrnehmung unterscheiden lassen. Grundsätzlich ist das optische Erscheinungsbild mit den von Proben aus Zugversuchen vergleichbar und die vorliegenden Mechanismen übertragbar (siehe Tabelle 2.2 und Abbildung 2.7). Die unterschiedlichen Bereiche sind je nach Stärke des Bandmaterials mit dem menschlichen Auge zu erkennen und erscheinen klar getrennt. (Kolbe 2020, S. 24)

Tabelle 2.2: Optisches Erscheinungsbild der Schnittflächen (Kolbe 2020, S. 24)

Kenngröße	optisches Erscheinungsbild
Glattschnittbereich	glänzend, glatt mit Strukturen in Schneidrichtung
Bruchbereich	matt, körnig, Bruchfläche mit Kerbrissen und Abrissgrat

Kanteneinzug

Der Kanteneinzug ist aufgeteilt in Kanteneinzugshöhe und -breite (siehe Abbildung 2.6) und entsteht durch Nachfließen des Blechwerkstoffes in den Schneidspalt. Eine Abhängigkeit besteht zur Beschaffenheit der Schneidstempelschneidkante. Durch Brechen

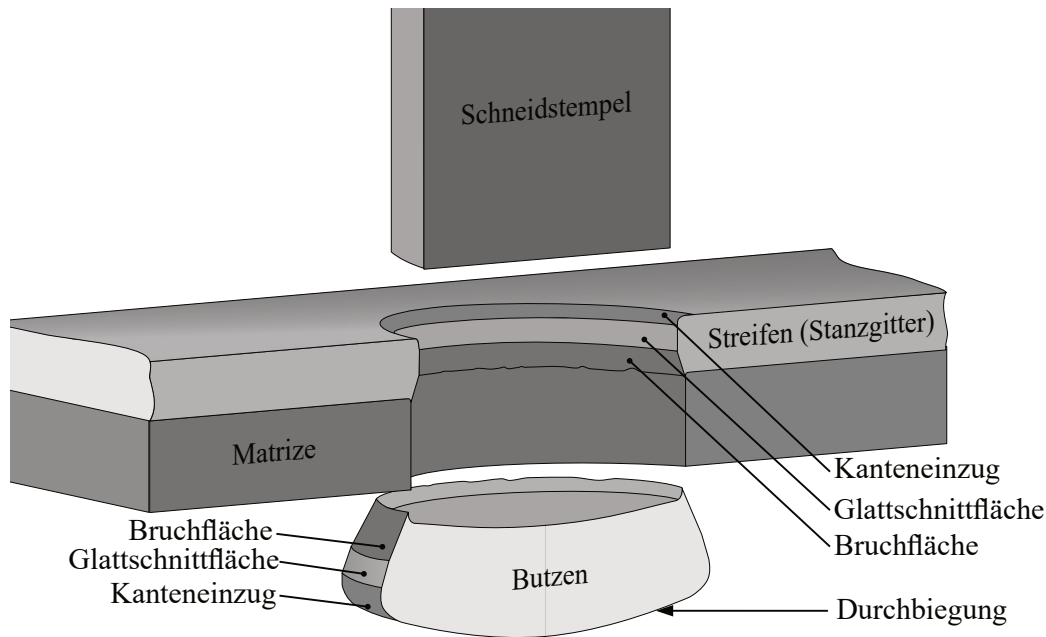


Abbildung 2.7: Schnittflächenbildung beim Scherschneiden (nach Klocke 2017, S. 490)

dieser Kante, durch Verrundung oder Fase, entsteht ein vergrößerter relativer Schneidspalt. In der Folge steht mehr Werkstoff zur Verfügung, der nachfließen kann; der Einzugsbereich vergrößert sich. Der Kanteneinzug ist nur bei kreisrunden Schnittliniengeometrien konstant. Weichen die Geometrien davon ab, ist mit einem variierendem Kanteneinzug zurechnen. Im Allgemeinen nimmt dieser mit wachsender Krümmung der Schnittliniengeometrie zu. An Vorsprüngen in der Schnittgeometrie kann er bis zu 30 % der Blechdicke betragen, während er an Einschnitten mit kleinen Radien ganz verschwinden kann. (Lange 1990, S. 143–147; Hoffmann, Neugebauer et al. 2012, S. 683–685)

Glattschnittfläche und Bruchfläche

Eine Glattschnittfläche entsteht, solange plastisches Fließen in der Schneidzone aufrechterhalten wird. Erst, wenn das Umformvermögen des Bandmaterials überschritten ist, beginnt die Rissausbreitung und die Bruchfläche entsteht. Das Umformvermögen ist nicht nur werkstoffabhängig, sondern auch vom Spannungszustand innerhalb des Werkstoffs beeinflusst. Der Einfluss dieses Parameters und der des Schneidspaltes wird von Hörmann (Hörmann 2008) dargestellt. Ebenso wird in dieser Arbeit beschrieben, dass der Einfluss der Schnittkantengeometrie dem des Schneidspaltes, der Niederhaltkraft und Ringzackenordnung überzuordnen ist. (Hoffmann, Neugebauer et al. 2012, S. 683–685)

Schnittgrat

Als ideal wird eine Schnittfläche ohne Schnittgrat mit maximalem Glattschnittanteil angesehen, allerdings zeigen die fertigmässigen Schnittfläche für gewöhnlich Abweichungen hiervon auf. Gründe hierfür sind eine Vielzahl an prozess-, maschinen- und werkstoffbedingten Einflussgrößen, die die Kenngrößen beeinflussen und sich unmittelbar auf die Qualität der Schnittfläche auswirken. Deshalb sind stets Schritte der Nachbearbeitung zu veranlassen, falls gratfreie Schnittkanten gefordert sind. Einen Überblick über die zu erwartenden Schnittgrathöhen gibt *DIN 9830*, es wird jedoch darauf hingewiesen, dass es sich hierbei ausschließlich um Anhaltswerte handelt. (Hoffmann, Neugebauer et al. 2012, S. 683–685; Klocke 2017, S. 508–511)

Zipfelbildung und Einriss

Die Risseinleitung und -ausbreitung kann laut Literatur (Kienzle et al. 1959) abhängig vom Schneidspalt und den Werkstoffeigenschaften in verschiedenen Modifikationen der Bruchzone vorliegen. Bei optimal gewähltem Schneidspalt breiten sich Risse ausgehend von Schneidstempel- und Schneidplattenkante aus. Im Weiteren läuft die Rissausbreitung aufeinander zu und die Bruchfläche wird ausgebildet. Bei einem zu kleinen Schneidspalt laufen die Risse aneinander vorbei und die letztendliche Trennung des Werkstoffes wird durch Scheren der nicht durchtrennten Stege hervorgerufen. Es kommt zur sogenannten Zipfelbildung (Abbildung 2.8a), die dadurch charakterisiert ist, dass mitunter mehrere Glattschnittflächen von schmalen Bruchflächen unterbrochen sind. Die Ausprägung erfolgt zumeist über die ganze Schnittliniengeometrie. (Hoffmann, Neugebauer et al. 2012, S. 683–685)

Im Unterschied dazu kann es zu Unterbrechungen der Glattschnittfläche durch sogenannte Einrisse kommen, siehe Abbildung 2.8b (VDI 2906 Blatt 2 1994). Hierbei handelt es sich um zufällige Erscheinungen, die unter anderem abhängig von den lokalen Fertigungsparametern sind.




Abbildung 2.8: Unterschiedliche Ausbildung der Schnittfläche. (a) Mechanismus der Zipfelbildung bei unterschiedlichem Schneidspalt (Hoffmann, Neugebauer et al. 2012, S. 684) (b) Schnittfläche mit einem Einriss und schalenförmigen Abriss (nach VDI 2906 Blatt 2)

2.1.4 Einflussgrößen auf das Scherschneiden

Die Untersuchung der Einflussgrößen auf das Schneidwerkzeug und das Schneidergebnis ist seit Jahren immer wieder Gegenstand wissenschaftlicher Untersuchungen (Kienzle et al. 1959; Pfaff 1971; Doege und Ulrich 1995). Die meisten dieser Arbeiten stützen sich auf empirisch ermittelte Werte (Hoffmann, Hoogen et al. 1999; Sachnik 2017). Im Fokus steht vorrangig der Verschleiß der Werkzeugschneidkanten und die Gratbildung an der entstehenden Schnittfläche bei verschiedensten Materialien (Toussaint 2000; Hirsch 2012). Untersucht werden zudem die Veränderungen der Schnittflächenanteile durch eine Variation des Schneidspaltes, der Kraft- und Arbeitsbedarfes beim Scherschneiden und die daraus resultierenden Spannungen im Werkstoff (Nothhaft 2014; Neumayer 2020).

Weiter werden Untersuchungen mittels der Finiten-Element-Methode zur Beurteilung der Kantenbelastung durchgeführt (Hörmann 2008; Panico 2012). Hierbei handelt es sich in den überwiegenden Arbeiten um Untersuchungen einzelner Prozesspunkte und nicht um eine Betrachtung über die komplette Standzeit des Schneidstempels. Erschwert wird eine Vergleichbarkeit der Schneidversuche durch die unterschiedlichen Schnittliniengeometrien von 5 mm bis 20 mm Durchmesser. Unterschiedliche Schneidspalte, Schnittgeschwindigkeiten, Werkzeug- und Werkstückwerkstoffe sowie Messfahren zur Bestimmung des Verschleißes und der Gratbildungen beeinflussen die Vergleichbarkeit ebenfalls. Die gegenseitige Wechselwirkung der Einflussparameter innerhalb des hochdimensionalen Parameterraum erschwert die Übertragbarkeit zusätzlich. Einen Überblick über die Einflussparameter auf den Scherschneidprozess und die Schnittflächenqualität gibt Abbildung 2.9. In der Literatur werden über 40 Einflussparameter auf den Prozess genannt (Kubik 2021). (Hoogen 1999, S. 16; Schmütsch 1990, S. 7–10; Hoffmann, Neugebauer et al. 2012, S. 686 f.; Nothhaft 2014)

Für technische Prozesse bietet es sich zusätzlich an, den zeitlichen Verlauf der jeweiligen Größe zu betrachten. Einflussgrößen wie das statische Verhalten der Maschine oder die Konstruktionsweise des Schneidwerkzeuges können über einen Fertigungstakt oder sogar über Lebensdauer eines Schneidstempels als konstant angesehen werden. Diese Einflussgrößen können als *Prozessparameter* und die Prozess steuernden, zeitlich veränderlichen Variablen als *Prozesseingaben* bezeichnet werden. (Reinhart et al. 2018, S. 86)

Bezogen auf den Glattschnittanteil sind Prozessparameter zumeist durch das Herstellungsverfahren oder die Konstruktion vorgegeben. Hierzu zählen unter anderem die Lieferklasse des Bandmaterials, die Steifigkeit der Maschine, die Führungstoleranzen des Werkzeugs und viele andere. Die Problematik dieser Größen ist, dass nicht alle Prozesseingaben durch entsprechende Messmethoden direkt messbar sind und eine wechselseitige Beeinflussung vorliegt. Eine solche Messgröße stellt die resultierende Schneidkraft dar.

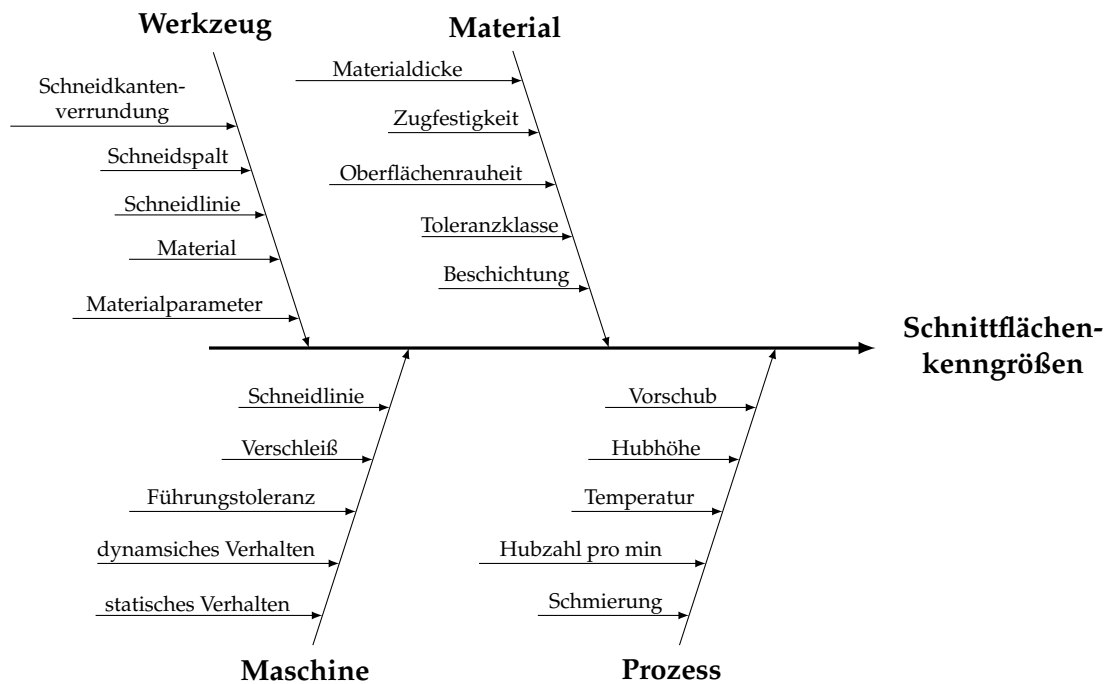


Abbildung 2.9: Auswahl unterschiedlicher Einflussgrößen auf die Schnittflächenkenngrößen (nach Hoogen 1999; Lange 1990; Kubik 2021)

2.1.5 Qualitätskriterium Verschleiß

Durch die tribologischen Vorgänge während des Schneidprozesses resultieren Verschleißerscheinungen an den Schneidelementen. Verschleiß ist gekennzeichnet durch anhaltenden Materialverlust aus Oberflächen eines Körpers, durch den Kontakt oder die Relativbewegung eines Gegenkörpers. In diesem Zusammenhang werden sowohl Schmierstoffe als auch Wechselwirkungen zwischen Festkörpern und zwischen Festkörpern und Flüssigkeiten/Gasen berücksichtigt. (Gesellschaft der Tribologie 2002)

Verschleißmechanismen sind Adhäsion, Abrasion, tribochemische Reaktion sowie Oberflächenzerrüttung (Czichos et al. 2015, S. 133). Adhäsion wird verursacht durch einen hohen Kontaktdruck zwischen chemisch ähnlichen Kontaktpartnern. Die entstehenden Haftbrücken werden durch Relativbewegung der Kontaktpartner zerstört (Sommer et al. 2018, S. 19–20). Abrasion resultiert aus Mikrobrechen, Mikrozerspanen sowie Mikrospalten (Czichos et al. 2015, S. 137 ff.). Ein härterer Körper dringt hierbei in einen weicheren Körper auf Mikroebene ein und erzeugt Materialabtrag (Sommer et al. 2018, S. 21 ff.). Chemische Reaktionen zwischen Grund- und Gegenkörper mit dem Umgebungsmedium oder Schmierstoff sind tribochemische Reaktionen (Czichos et al. 2015, S. 142). Hierbei wird durch Relativbewegung anhaltend Reaktionsprodukte abgerieben und erzeugt (Czichos et al. 2015, S. 142). Durch zyklischen Kontakt zweier Körper mit einer Mindestkraftamplitude entsteht Oberflächenzerrüttung (Sommer et al. 2018, S. 23 ff.). Die hierdurch entstehenden Spannungen führen zur Werkstoffermüdung, die durch Risse der Oberfläche gekennzeichnet ist (Czichos et al. 2015, S. 133 ff.).




Abbildung 2.10: Unterschiedliche Verschleißformen am Schneidstempel (oben); verschlissener Schneidstempel mit Verschleißgrößen (unten) (nach Lange 1990, S. 136 ff.; Toussaint 2000, S. 13 ff.)

Am Schneidstempel unterscheidet man je nach Verschleißort zwischen Mantelverschleiß, Stirnflächenverschleiß und Kolkverschleiß. *Stirnflächenverschleiß* als auch *Kolkverschleiß* entstehen beim Schneiden dünner Bleche; sie resultieren aus der horizontalen Fließbewegung des Blechmaterials innerhalb der Scherzone. *Mantel(flächen)verschleiß* entsteht durch Reibung in Schneidrichtung, folglich während des fortschreitenden Schnitts und des Stempelrückzugs. Hauptsächlich tritt er bei Blechen mit größerer Materialstärke auf. In Summe führen die Verschleißarten zu einem verschlissenen, abgenutzten Schneidstempel. In der Regel vergrößert sich die Schnittgrathöhe am Werkstück hierdurch; wie in Kapitel 2.1.3 belegt ist, ist dies jedoch nicht immer eindeutig vorhersehbar. Der Verschleiß am Schneidstempel wird durch die Messgrößen Mantelverschleißlänge, Stirnflächenverschleißlänge und die 45°-Verschleißlänge ermittelt (Abbildung 2.10) (Toussaint 2000, S. 13 ff.). (Lange 1990, S. 136 ff.; Klocke 2017, S. 496–498)

Der Verschleiß selbst folgt dabei dem in der Literatur bekannten Verlauf, siehe Abbildung 2.11. Es wird zwischen den Phasen Einlaufverschleiß, Verschleiß im Beharrungszustand und progressiver Verschleißverlauf unterschieden. Nach der degressiven Einlaufphase folgt im Beharrungszustand eine lineare Verschleißzunahme. Der progressive Verschleiß erfolgt beschleunigt und führt zum Schaden. Allerdings finden sich in

der Literatur nahezu nur Verschleiß-Zeit-Diagramme von kleinen Lebensdauerbereichen beim Scherschneidprozess. (Volk et al. 2019, S. 31 f.; Czichos et al. 2015, S. 167 f.)

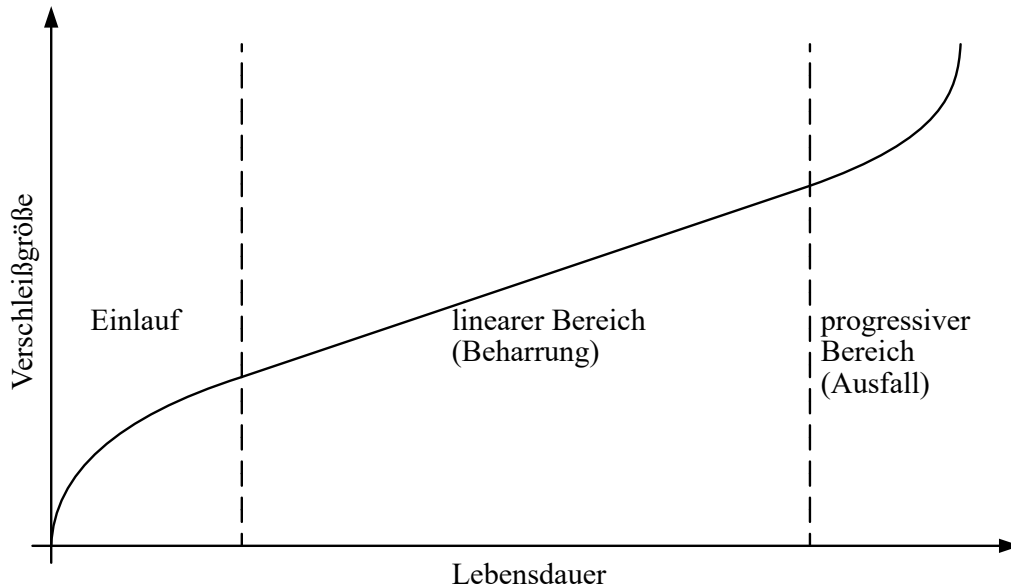


Abbildung 2.11: Verschleiß-Zeit-Diagramm (nach Czichos et al. 2015, S. 167 f.; Volk et al. 2019, S. 31; Groover 2021, S. 518)

2.1.6 Stanzbiegeautomat und Werkzeugaufbau

Stanzbiegeautomat

In diesem Abschnitt soll der schematische Aufbau eines Stanzbiegeautomaten und der Ablauf des Fertigungsprozesses dargestellt werden. Da die spätere Integration auf einem Stanzbiegeautomaten der Otto Bihler Maschinenfabrik GmbH & Co. KG erfolgen soll, wird dieser als Exempel herangezogen (siehe Abbildung 2.12).

Innerhalb eines Stanzbiegeautomaten wird kontinuierlich zugeführtes metallisches Bandmaterial durch gezielte Vorbearbeitung in einzelne flächige Werkstücke geschnitten. Anschließend werden diese einer Vielzahl von Bearbeitungsschritten unterzogen, wie z. B. Biegen. In dieser Arbeit wird ausschließlich der Scherschneidprozess durch die Presse analysiert.

Das metallische Bandmaterial wird von externen Coils der Maschine zugeführt und betritt die Maschine durch ein Eintrittsfenster. Zunächst durchläuft es einen Richtapparat und anschließend eine Beölungseinheit, in der es mit Schneidöl versehen wird und tritt in die Vorschubeinheit ein. Diese Einheit sorgt für den getakteten Vorschub des Materials innerhalb des gesamten Automaten. Nachgelagert zur Vorschubeinheit ist die Presseneinheit. In ihr ist das Schneidwerkzeug montiert, das aufgrund der Steifigkeits-

und Genauigkeitsanforderungen sehr massiv ausgelegt ist. Innerhalb des Schneidwerkzeugs erfolgen Vorformprozesse und durch den Schneidvorgang (siehe Kapitel 2.1.2) wird die definierte Materialtrennung vollzogen. Durch die kontinuierliche Taktung wird das Bauteil aus dem Schneidwerkzeug heraustransportiert und den nachfolgenden Bearbeitungsaggregaten übergeben. Je nach Anwendung erfolgen verschiedene Bearbeitungsschritte wie Biegen, Bohren, Räumen, Schweißen und Abtrennen. (Kolbe 2020, S. 275-278, S. 371-373)




Abbildung 2.12: Stanzbiegeautomat der Otto Bihler Maschinenfabrik GmbH & Co. KG mit schematischer Einteilung der Prozessschritte in den einzelnen Teilbereichen. Eigene Zusammenstellung nach Otto Bihler Maschinenfabrik GmbH & Co. KG 2023.

Werkzeugaufbau

Die konstruktive Auslegung eines Schneidwerkzeugs ergibt sich aus der Geometrie und den Qualitätsanforderungen des Werkstücks, der eingesetzten Presse und der geforderten Stückzahl. In der Industrie sind Säulenwerkzeuge die am weitesten verbreitete Bauweise, daher wird diese Bauweise auch in dieser Arbeit eingesetzt. Der grundsätzliche Aufbau eines Säulenführungswerkzeugs ist in Abbildung 2.13 dargestellt. Die Hauptfunktion der Führungen besteht darin, ein Aufsetzen von Schneidstempelschneidkante auf der Schneidplattenschneidkante zu vermeiden, einen über den Prozess kontinuierlichen Schneidspalt zu gewährleisten und eine Verkipfung bzw. einen Versatz der

Schneidstempel zu vermeiden. Zur Gewährleistung einer ausreichenden Steifigkeit auch unter hohen Schnittkräften werden die Einzelteile zusätzlich mit sehr großen volumetrischen Ausdehnungen im Vergleich zur Schnittgeometrie ausgelegt. Weiterhin werden die Schneidelemente nach Möglichkeit komplett geführt und jede Beeinflussung der Steifigkeit durch Freimachungen, Bohrungen oder Ähnliches vermieden. (Hoffmann, Neugebauer et al. 2012, S. 692–695)

Für Details zum weiteren Funktionsprinzip wird auf Kolbe 2020, S. 55 ff., S. 275-278 verwiesen.




Abbildung 2.13: Aufbau des in dieser Arbeit verwendeten Säulenführungswerkzeugs. Geteilte Darstellung in Schneidwerkzeugober- und -unterteil; Stempelhalteplatte (1), Führungsplatte (2), Stempelhalter (3), Schneidstempel (4), Niederhalter (5), Bandmaterial (6), Schneidplatte (7)

2.1.7 Messtechnik

Piezoelektrische Kraft-, Beschleunigungs- und Körperschallmessung

Wirkt auf einen Piezokristall eine Kraft, wird sein Kristallgitter verzerrt und die negativ geladenen Gitterpunkte bewegen sich relativ zu den positiv geladenen Gitterpunkten. Durch Kontaktierung der Kristalloberfläche kann der hierbei entstehende Ladungsunterschied abgenommen und in ein elektrisches Signal umgewandelt werden, siehe Abbildung 2.14.

Dieser piezoelektrische Effekt wird sowohl für Kraft-, Beschleunigungs- und Körperschallsensoren genutzt. Für eine Messung muss dieses Signal durch einen Ladungsverstärker in ein messtechnisch stabiles Spannungssignal transformiert werden. Im Vergleich mit der Kraftmessung mit Dehnmessstreifen bieten Piezokristalle einige Vorteile. Sie besitzen eine deutlich höhere Steifigkeit, da keine bewegten Bauteile eingesetzt werden. Hieraus lässt sich auch ableiten, dass keine Alterungserscheinungen durch Kriechen vorliegen. Ein weiterer Vorteil ist, dass Piezokristalle in niedrigen bis zu hochdynamischen Bereichen eingesetzt werden können. Nachteilig bei Piezokristallen ist die Notwendigkeit einer Kalibrierung. (Serridge et al. 1990, S. 13–32; Gevatter et al. 2006, 65 ff., S. 129-146)

Bekannte Materialien für Piezokristalle sind Einkristalle wie Quarz, Rochellesalz oder aus verschiedenen Komponenten zusammengesetzte künstlich polarisierte ferroelektrische Keramiken. Durch Druck- oder Scherbelastung werden Ladungen proportional zur Belastung an den Oberflächen frei. Kraftmessungen können direkt mit dem Sensor ermittelt werden. Für Beschleunigungssensoren werden die resultierenden Kräfte durch die Beschleunigung eines Massekörpers im Sensor ermittelt. (Serridge et al. 1990, S. 13–32; Gevatter et al. 2006, 65 ff., S. 129-146)

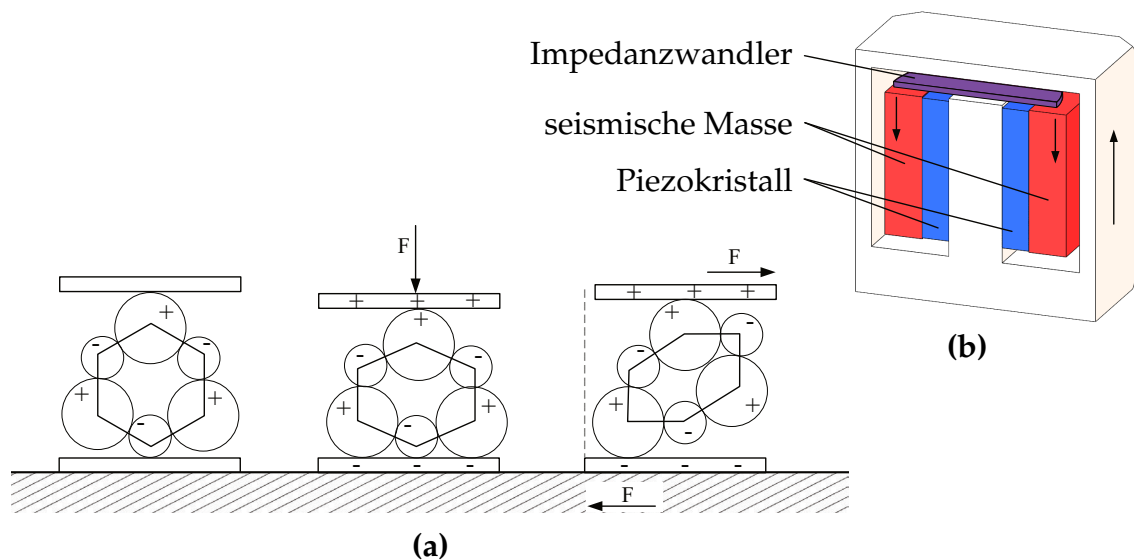


Abbildung 2.14: Funktion des piezoelektrischen Effekts und Aufbau eines Beschleunigungssensors (a) Darstellung des piezoelektrischen Effekts im Ausgangszustand (links), unter Druckbelastung (mittig) sowie unter Scherbelastung (rechts) (nach Serridge et al. 1990, S. 23) (b) Schnittdarstellung eines Beschleunigungssensors in Scherbelastung (nach Kistler Instrumente AG 2016)

Körperschall Körperschall (engl. acoustic emission) (AE) wird dem Gebiet der Akustik zugeordnet. Untersucht werden Anregung und Übertragung von Festkörperschwingungen im Frequenzbereich von 16 Hz bis 16 kHz. Dieser Frequenzbereich wird aber häufig auf den Ultraschallbereich erweitert. Anwendungsgebiete sind die Geräuschbekämpfung im Schallschutz, die Optimierung von Konstruktionen bezüglich ihrer

Schallemission, die Zustandsüberwachung und Schadensfrüherkennung an Maschinen und die Materialspezifikation. Emitter für Körperschall sind periodische oder stoßartige Arbeitsvorgänge, also kraftwechselnde Vorgänge. Für die Zustandsüberwachung sind primär stoßartige Burst-Signale von Bedeutung, die etwa bei Werkzeugbrüchen auftreten. (Scheer 2000, S. 4–9; Möser et al. 2010, S. 1–3)

Die Schallemissionen werden in kontinuierliche und impulsartige Emission unterschieden. Die kontinuierliche Emission ist meist die Folge von Fließ- und Reibvorgängen oder einer stetigen Rissausbreitung. Eine impulsartige Emission wird von schlagartigen Ereignissen erzeugt. Häufig lässt sich die Art der Emission bei Messvorgängen in der Praxis nicht derartig unterscheiden, sie dienen vielmehr der Einordnung während der Versuchsauswertung. Die Ausbreitung der Wellen im Festkörper ist ein komplexer Vorgang. Am Aufnehmer trifft entsprechend eine Mischung verschiedener Wellenmoden auf. Die theoretisch ideale kugelförmige Ausbreitung wird durch die reale Festkörperstrecke beeinflusst. Oberflächen, Materialübergänge und Inhomogenitäten des Materials führen zu Verzerrungen der Ausgangswelle. Zusätzlich überlagern sich häufig die Signale mehrerer Schallquellen. Veränderliche Signale können folglich nur aufgezeichnet werden, eine exakte Zuordnung von Signalanteilen zu einem verursachenden Ereignis ist hingegen schwer möglich. Für die Signalaufzeichnung sind oft Abtastfrequenzen im MHz-Bereich notwendig. Dies erzeugt nicht nur einen erheblichen finanziellen Mehraufwand, ebenfalls steigt die zu verarbeitende Datenmenge an. Bei prozessbegleitenden Messungen wird daher häufig der *quadratische Mittelwert* (engl. *root mean square*) (RMS) des Signales aufgezeichnet. Für kontinuierliche Signale ergibt sich der AE-RMS-Wert

$$AE_{\text{RMS}} = \sqrt{\frac{1}{\tau_{\text{RMS}}} \int_0^{\tau_{\text{RMS}}} AE^2(t) dt}, \quad (2.1.3)$$

wobei das Quadrat der zeitlichen Amplitude $AE(t)$, über eine geeignete Integrationslänge τ_{RMS} integriert wird (Kistler Instrumente AG 2020, S. 21–24). Dieser Wert ist ein Maß für die Signalenergie pro Zeiteinheit. Die Wahl der geeigneten Integrationslänge ist hierbei bedeutend. Die Verarbeitung des Körperschallsignals ist in Abbildung 2.15 gezeigt. Zur Aufzeichnung des AE-Signals werden häufig piezoelektrische Beschleunigungssensoren verwendet. (Scheer 2000, S. 4–9; Möser et al. 2010, S. 1–3)




Abbildung 2.15: Verarbeitung des Körperschallsignals (AE-Signal), mittels Bandpassfilter und quadratische Mittelwert (engl. *root mean square*) (RMS) zum AE-RMS-Signal. (nach Scheer 2000, S. 7)

2.2 Maschinelles Lernen

Maschinelles Lernen ist als Teildisziplin der Künstlichen Intelligenz zugeordnet. Ziel ist vorhandene Daten im Hinblick auf Muster zu analysieren sowie aus diesen Mustern Modelle zu erstellen, die Erkenntnisse aufdecken und so den Menschen bei seinen Handlungen unterstützen (Runkler 2015, S. 2; Kirste 2019, S. 60; Cleve et al. 2020, S. 16). Im Unterschied zu deterministischen Algorithmen wird durch eine Rückkopplung der Ergebnisse eine iterative Anpassung der Modelle erreicht (Kirste und Schürholz 2019, S. 24).

Daten sind kodierte speicherbare Aufzeichnungen von Beobachtungen. Durch die Einordnung der Daten in einen Kontext (Semantik) wird ihnen eine Bedeutung zugeordnet (Bodendorf 2006, S. 1), es entstehen Informationen. Durch die zweckgebundene Vernetzung von Informationen unter Berücksichtigung ihrer Zusammenhänge (Pragmatik) entsteht Wissen (Bodendorf 2006, S. 2; Cleve et al. 2020, S. 42). Erkenntlich aus den oberen Definitionen ist die fundamentale Bedeutung der Daten.

Als Teilgebiet der *Datenwissenschaften* (engl. *Data Science*) ist das *Data-Mining* bekannt. Ziel ist es, aus Massendaten Wissen zu extrahieren (Cleve et al. 2020, S. 2). Allein diese Definitionen zeigen, dass die Überlappungsbereiche zwischen Data-Mining und maschinellem Lernen groß sind (siehe Abbildung 2.16a). Weiterhin ist ohne eine geeignete Datenanalyse die Ableitung von intelligentem Verhalten und Wissen in vielen Bereichen nicht denkbar (Cleve et al. 2020, S. 11). Dieses Paradigma verhindert eine klare Trennung der Bereiche und führt zu Vermischungen. Im Kontext dieser Arbeit wird Data-Mining durch Methoden des maschinellen Lernens durchgeführt.

2.2.1 Grundlagen der datengetriebenen Vorhersage

Zur Strukturierung der Vorgehensweise von Data-Mining-Projekten wurden verschiedene Vorgehensweisen zur Wissensentdeckung entwickelt. Zunächst ist hier das *knowledge discovery in databases* (KDD) zu nennen (Fayyad et al. 1996a; Fayyad et al. 1996b). Hieraus wurde der *Cross Industry Standard Process for Data Mining* (CRISP-DM)-Prozess entwickelt, der in der Industrie weitverbreitet ist (Chapman et al. 2000; Otte et al. 2020, S. 34). CRISP-DM repräsentiert die industriebezogene Sicht des KDD insbesondere durch die Einbeziehung von Metawissen durch Prozessexperten (Cleve et al. 2020, S. 7). Hierin wird die Vorgehensweise in die Teilschritte Aufgaben- und Prozessverständnis, Datenverständnis, Datenvorverarbeitung, Modellierung, Evaluation und Anwendung aufgeteilt, siehe Abbildung 2.16b. Als Weiterentwicklung ist *Analytics Solutions Unified Method for Data Mining/Predictive Analytics* (ASUM-DM) von IBM bekannt (IBM Analytics 2023). Allerdings finden sich in der Praxis wenig Anhaltspunkte, dass ASUM-DM den CRISP-DM-Prozess abgelöst hat.

Als *Merkmale* (engl. *Features*) werden die einzelnen Größen einer Datenmenge bezeichnet. Die Gesamtheit der Merkmale, die für die Wissensgenerierung verwendet wird, wird häufig als *Feature-Space* oder *Merkmalsraum* bezeichnet (Cleve et al. 2020, S. 43; Otte et al. 2020, S. 35). Durch Verarbeitung der Daten mittels gewisser Algorithmen erlernt in der

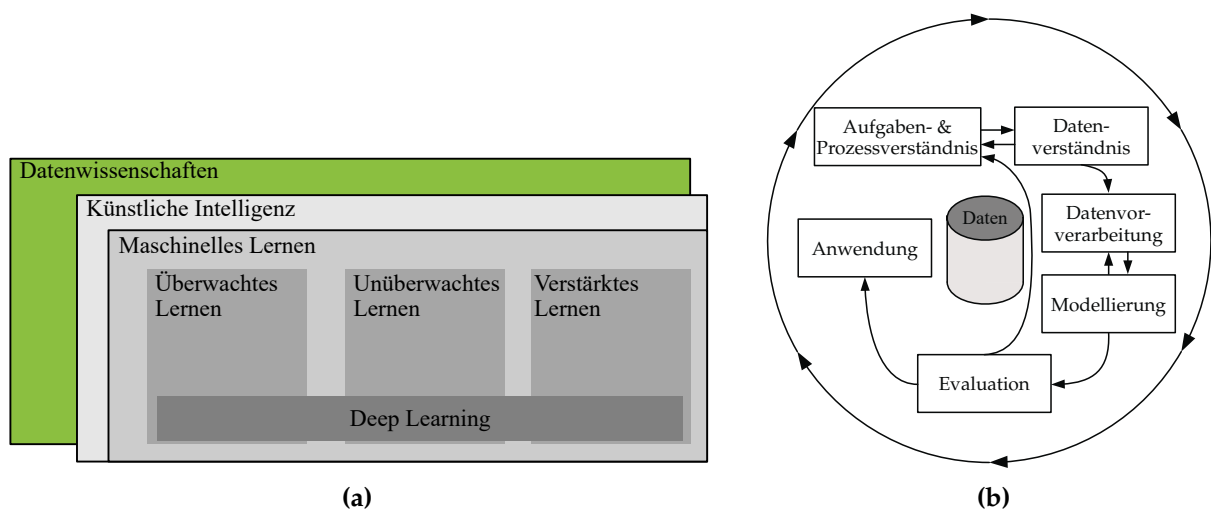


Abbildung 2.16: Überblick der vorgestellten Bereiche der Künstlichen Intelligenz (a) Einordnung der in dieser Arbeit verwendeten Begrifflichkeiten. Eigene Darstellung nach Waschneck 2020 (b) Darstellung des CRISP-DM-Modells (nach Chapman et al. 2000)

Modellierungsphase ein Computerprogramm eine vorgegebene Aufgabe (Frochte 2021, S. 14 f.). Die Abbildung durch das Computerprogramm wird als *Modell* bezeichnet. Das Modell verarbeitet Informationen und kann als Abbildung der Realität auf der Basis der vorhandenen Daten angesehen werden. Die einzelnen Merkmale können mathematisch als unabhängige Variable verstanden werden, während die Zielgröße als abhängige Variable angesehen wird. Durch eine geeignete Einstellung der Modellparameter bilden die unabhängigen Variablen die abhängige Variable ab. Im Kontext des überwachten Lernens beschreibt die Zielgröße das Resultat. (Hastie et al. 2009, S. 1–11)

2.2.2 Methoden des maschinellen Lernens

Maschinelles Lernen kann in drei Hauptkategorien unterteilt werden (Awad et al. 2015, S. 6–8; Kirste und Schürholz 2019, S. 24–29; Mockenhaupt 2021, S. 138–147):

- *Überwachtes Lernen* (engl. *supervised learning*): Die Daten enthalten sowohl die Eingangsgrößen als auch die tatsächliche Zielgröße, das *Label*. Für jeden Trainingsvorgang wird der Prognosewert des Modells mit der tatsächlichen Zielgröße verglichen und iterativ angepasst. Nach Abschluss des Trainingsprozesses können die Modelle auf unbekannte Eingangsdaten angewendet werden und neue Zielgrößen prognostizieren. Verfahren des überwachten Lernens sind beispielsweise Regression und Klassifizierung (Frochte 2021, S. 22).
- *Unüberwachtes Lernen* (engl. *unsupervised learning*): Die Daten enthalten die tatsächliche Zielgröße nicht. Der zu erlernende Wirkmechanismus ist nicht vorgegeben. Ausschließlich anhand der Daten werden unter anderem Klassifikationen abgeleitet. Verfahren des unüberwachten Lernens sind Clustering und Dimensionsreduktion (Awad et al. 2015, S. 7; Cleve et al. 2020, S. 59).

- *Bestärktes Lernen* (engl. *reinforcement learning*): Bei diesem Verfahren erfolgt die Wissensgenerierung über die Interaktion eines Agenten mit der Umgebung durch positive Bewertung. Bei anhaltendem Lernen werden die gewünschten Ergebnisse verstärkend eingepreßt. Dieser Methode wird in der vorliegenden Arbeit nicht verwendet, für weitere Details wird daher auf Alpaydin 2022, S. 581 ff. verwiesen.

Es existiert eine Vielzahl von Algorithmen für das maschinelle Lernen, die zusätzlich ständige erweitert werden. Algorithmen des klassischen maschinellen Lernens sind *Entscheidungsbäume* (engl. *decision trees*), *lineare und logische Regression* (engl. *linear und logistic Regression*) sowie *Support Vector Maschinen* (Deike 2020, S. 25–31).

Künstliche neuronale Netze

Die nachfolgenden Ausführungen zu künstlichen neuronalen Netzen, Training und Convolutional Neural Networks orientieren sich an Alpaydin (Alpaydin 2022), sofern keine gesonderten Verweise erfolgen.

Künstliche neuronale Netze haben sich gegenwärtig als eines der vielversprechendsten Gebiete innerhalb der Künstlichen Intelligenz gezeigt (Retkowitz 2021, S. 209). Inspiriert sind künstliche neuronale Netzwerke durch das menschliche Gehirn. Die kleinsten Verarbeitungseinheiten sind die künstlichen Neuronen (Abbildung 2.17a). Als Eingangsgrößen erhalten diese die Einträge x_1, x_2, \dots, x_n des Merkmalsvektors x . Diese werden mit Gewichten ω_i multipliziert und aufsummiert. Die Ausgabe

$$h(x) = \sum_{i=1}^n \omega_i x_i \quad (2.2.1)$$

ist wiederum Eingangswert in eine Aktivierungsfunktion g . Abhängig von der Ausgabe h wird durch g eine Aktivität des Neurons erreicht. Unter Hinzunahme einer Verzerrungseinheit ω_0 (engl. *bias*) ergibt sich das einlagige Perzeptron

$$y = g\left(\sum_{i=1}^n \omega_i x_i + \omega_0\right) \quad (2.2.2)$$

(Alpaydin 2022, S. 289 ff.). (Frochte 2021, S. 169–175)

Um eine Aufgabe durch ein Netz oder Perzeptron abzubilden, muss ein Trainingsprozess vollzogen werden, in dem die Gewichte anwendungsbezogen trainiert werden. Mit einem Perzeptron lassen sich keine nichtlinearen Regressionen abbilden. Durch die Einführung einer *Zwischenschicht* (engl. *hidden layer*) zwischen Eingabe und Ausgabeschicht gilt diese Einschränkung nicht, siehe Abbildung 2.17b. Sind mehrere Zwischenschichten vorhanden werden diese Netze auch multilayer Perceptron (MLP) genannt (Alpaydin 2022, S. 298). Sind alle Neuronen mit der in der darauffolgenden Schicht verbunden, nennt man diese *vollvermascht* (engl. *fully connected (FC)*). Weiterhin handelt es sich um ein FeedForward-Netz, da alle Neuronen nur mit der jeweiligen nächsten Schicht verbunden sind. Netze mit mehr als zwei Zwischenschichten sind sogenannten *tiefe neuronalen*

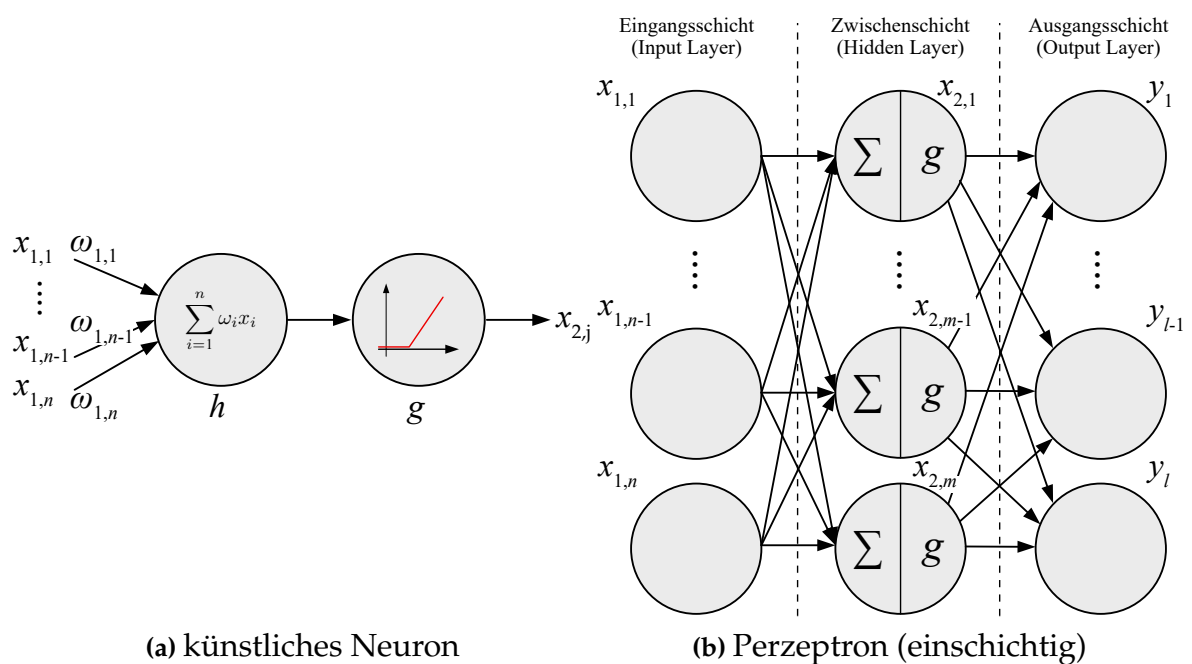


Abbildung 2.17: Künstliches Neuron und künstliches neuronales Netz (nach Frochte 2021, S. 169; Klocke et al. 2017).

Netzen (engl. *Deep Neural Networks*). Hieraus leitet sich auch der Begriff *deep learning* ab. (Frochte 2021, S. 178–181)

Training

Der Trainingsprozess erfolgt durch Gradientenabstieg auf den Trainingsdaten häufig aufgeteilt in Teilmengen (engl. *batches*). Zu dieser Datenmenge sind deren zugehörige tatsächliche Zielgröße bekannt. Die Eingangsgrößen werden durch das Netzwerk in den Prognosewert transformiert. Die Abweichung von der tatsächlichen Zielgröße wird über die *Verlustfunktion* (engl. *loss function*) berechnet und bewertet. Durch den Backpropagation-Algorithmus werden die Gradienten in Bezug auf die einzelnen Parameter des Netzwerks ermittelt. Ausgehend von der letzten Netzwerkschicht werden die Gradienten in umgekehrter Reihenfolge durch die Schichten propagiert. Abschließend werden alle Netzwerkparameter durch Subtraktion ihrer Gradienten, multipliziert mit einer *Lernrate* (engl. *learning rate*), aktualisiert. Methoden wie der Gradientenabstieg konvergieren allerdings nur langsam. Daher werden auch modifizierte Optimierungsfunktionen wie *Adam* genutzt, die diesen Vorgang beschleunigen (Kingma et al. 2014). Durch mehrfache Trainingsläufe, sogenannte *Epochen*, werden die Netzwerkparameter iterativ angepasst. Die Repräsentation der Entscheidung wird daher vom Netzwerk datengetrieben abgeleitet. Somit verschiebt sich das Hauptaugenmerk bei der Problemlösung von der vormaligen Implementierung von Expertenwissen und der manuellen Merkmalsextraktion hin zur richtigen Auswahl der Netzwerkarchitektur (Alpaydin 2022, S. 329). (Alpaydin 2022, S. 293–296)

Lernt ein Modell die Trainingsdaten nahezu optimal, ist es übertrainiert (*engl. overfitting*), was zur Folge hat, dass neue Prognosen nicht mehr richtig verarbeitet werden können (Tetzner et al. 2021, S. 237).

Netzwerkparameter, die vor dem Trainingsprozess festgelegt werden und zur Steuerung des Trainingsalgorithmus dienen, werden als *Hyperparameter* bezeichnet. Neben den Parametern aus der Netzwerkarchitektur bestehen diese unter anderem aus der Batchgröße, der Lernrate und den Faltungsparemtern. Die Auswahl dieser Parameter hat einen signifikanten Einfluss auf die erreichbare Netzwerküte und ist von entscheidender Bedeutung. Aufgrund der Menge der Hyperparameter, ihrer wechselseitigen Beeinflussung und der Trainingszeiten gestaltet sich die Auswahl eines optimalen Satzes von Hyperparametern als arbeitsintensiver Prozess. Durch eine Hyperparameteroptimierung in Form von *Rastersuche* (*engl. gridsearch*), *Zufallssuche* (*engl. random search*) oder mittels Expertenwissen können diese gefunden werden.

Convolutional Neural Networks

MLPs erzeugen für Bildverarbeitungsaufgaben sehr große Schichten. Die Netzwerke besitzen für jedes Pixel, die in diesem Fall die Merkmale sind, einen Eingang. Durch die Bildgröße und Anzahl an Bildkanälen entsteht eine große Anzahl an Parametern, die mitunter die Kapazität des Arbeitsspeichers überschreiten. Die daraus folgende Anzahl an Gewichten führt zu sehr langen Rechenzeiten. Zusätzlich besitzt das Netzwerk eine sehr hohe Speicherfähigkeit (Cleve et al. 2020, S. 137). Zur Anwendung dieser Methoden muss die Anzahl an Parametern verringert werden. Dies wird durch den Einsatz von *Faltungsoperationen* (*engl. convolution*) erreicht, siehe Abbildung 2.18a (Ertel 2021, S. 325). Weiterhin können hierdurch lokale Strukturen wie Kanten oder Ecken berücksichtigt werden (Alpaydin 2022, S. 346). Netze dieser Art werden Convolutional Neural Networks genannt.

Die Bilddaten und damit Eingangsdaten liegen zumeist als zwei- oder dreidimensionale Matrizen vor. Es wird eine diskrete Faltung für jedes Perzeptron berechnet. Hierbei handelt es sich um das innere Produkt des Faltungskerns mit dem aktuell betrachteten *Bildausschnitt oder Filterbereich* (*engl. rezeptiv field*), der sich über die Eingangsdaten bewegt, siehe Abbildung 2.18b. Gepaart mit der Aktivierungsfunktion ergibt sich eine neue Netzwerkschicht, die auch als *Feature Maps* bezeichnet werden. Abhängig von der Anzahl der Faltungskerne werden unterschiedliche Anzahl an Feature Maps erzeugt.

Nachfolgend auf einen Convolutional Layer werden sogenannte Pooling-Schichten angewendet. Für einen definierten Filterbereich wird das Maximum oder der Mittelwert ermittelt und über den *Versatz* (*engl. stride*) die Größe der Skalierung der Feature Maps bestimmt (siehe Abbildung 2.19a). Diese Operationen werden als nicht lernbar festgelegt. Für einen effektiven Trainingsvorgang werden zusätzlich Regularisierungsschichten eingeführt. Am häufigsten verwendet wird hierfür die Batch Normalization (BN), die die Neuronenausgaben auf einen Mittelwert von 0 und eine Standardabweichung von 1 anpasst und somit die Hyperebene für das Gradientenabstiegsverfahren glättet. Dies führt zu einer besseren Konvergenz des Trainingsprozesses. Weiter werden Dropout-Layer

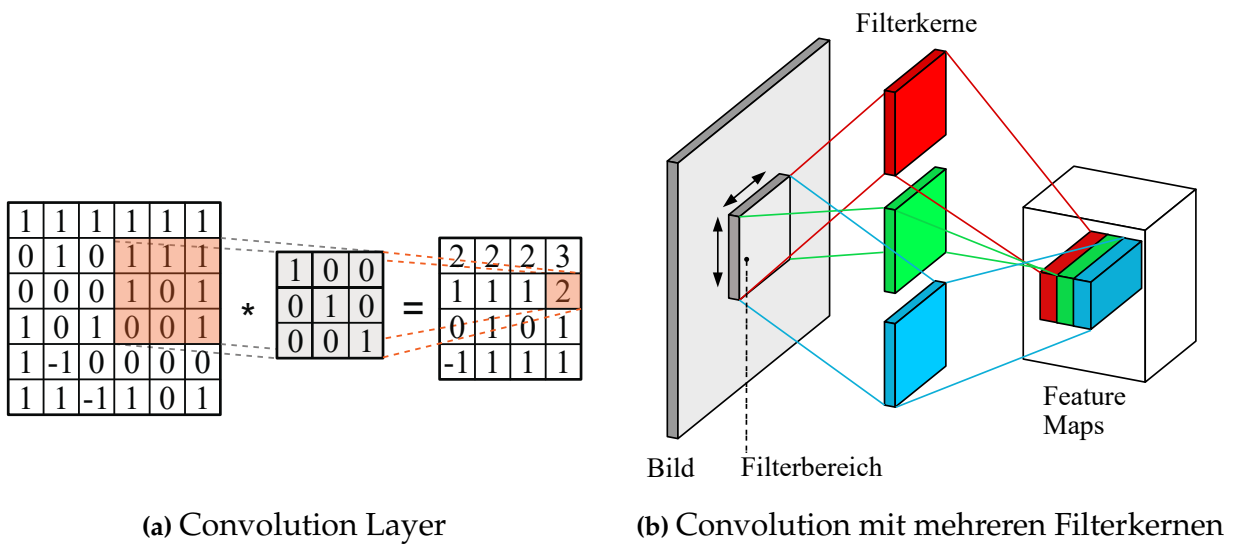


Abbildung 2.18: Darstellung der Funktionsweise von Faltungsschichten (engl. Convolution Layer)

angewendet (siehe Abbildung 2.19b), bei denen ein bestimmter Anteil der Perzeptronausgaben gelöscht wird und dadurch robustere Modelle erzeugt werden. Wie erwähnt,




Abbildung 2.19: Darstellung unterschiedlicher Netzwerkschichten

werden Aktivierungsfunktionen nach Convolutional Layern angewendet. Diese berechnen gewichtete Summen des Bias. Die am häufigsten verwendete Aktivierungsfunktion ist die Rectified Linear Unit (ReLU). Im Vergleich zu anderen Aktivierungsfunktionen erweist sie sich aufgrund ihrer kurzen Rechenzeit als vorteilhaft. Weitere Layerarten in neuronalen Netzen sind Flating-Layer und Softmax-Layer. Flating-Layer transformieren ihre Eingaben in 1-D-Vektoren und Softmax-Layer werden zur Normalisierung in eine Wahrscheinlichkeitsverteilung verwendet. Durch eine Verschaltung von mehreren Netzwerkschichten mit dazwischen liegenden Aktivierungsschichten entsteht die Netzwerkarchitektur. Man spricht daher von CNN, siehe Abbildung 2.20. Gewöhnlicherweise

nimmt pro Netzwerkschicht die Auflösung des Bildes ab und die Kanalzahl oder Anzahl der Feature Maps nimmt zu. Als abschließende Schicht erfolgt eine vollständig verbundene Schicht (Minaee et al. 2022). Zusätzlich benötigen CNNs für eine hohe Prognosegüte eine entsprechende Trainingsdatenmenge, die für den Prozess angefertigt werden muss. (Alpaydin 2022, S. 327–350)

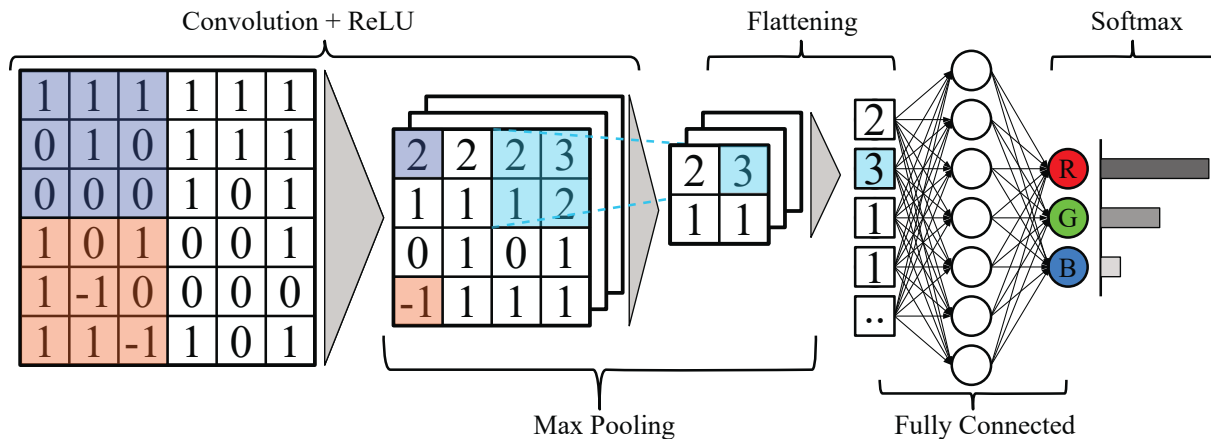


Abbildung 2.20: Darstellung eines CNN zur Klassifizierung (nach Gonzalez et al. 2018, S. 965)

2.2.3 Merkmalsauswahl

Zumeist hängt die Komplexität des Lernverfahrens von der Anzahl der Eingangsgrößen und der Größe der Datenmenge ab (Alpaydin 2022, S. 125 f.). Mit zunehmender Anzahl an Merkmalen steigt der benötigte Speicherplatz wie auch der Rechenaufwand zur Entscheidungsfindung (Runkler 2015, S. 80 f.). Da der vorhandene Speicherplatz begrenzt ist, muss die Dimensionalität der Daten häufig reduziert werden, um einen Trainingsprozess abzubilden. Hierzu sind die Methoden *Merkmalsselektion* und *Merkmalsextraktion* bekannt.

- Ziel der *Merkmalsselektion* ist die Auswahl von Merkmalen, die die meisten Informationen bezogen auf die aktuelle Aufgabe enthalten. Die übrigen Merkmale werden verworfen.
- Ziel der *Merkmalsextraktion* ist es, die kleinstmögliche neue Menge von Dimensionen zu finden oder zu erstellen, die zur besten Modellgüte führt und dabei die vorliegenden Wirkmechanismen des Prozesses erhält.

Neben der Beschleunigung des Trainings- und Evaluationsprozesses wird die Gefahr der Überanpassung reduziert. Zusätzlich erhöht sich die menschliche Interpretierbarkeit der erlernten Ursache-Wirkungs-Mechanismen mit reduzierter Merkmalsanzahl. Allgemein ist eine Vielzahl von Verfahren zur Merkmalsauswahl bekannt; in dieser Arbeit wird die Methode der Hauptkomponentenanalyse verwendet. (Alpaydin 2022, S. 125 f.)

Hauptkomponentenanalyse

Die *Hauptkomponentenanalyse* (engl. *Principal Component Analysis*) (PCA) ist eine Projektionsmethode, die eine Projektion der Eingaben im ursprünglichen d -dimensionalen Raum in einen neuen Raum der Dimension ($k < d$) findet. Der Informationsverlust wird dabei minimal gehalten. Das zu maximierende Kriterium der PCA ist die Varianz der Eingabedaten (Alpaydin 2022, S. 131). Zugrunde liegt hierbei die Annahme, dass die Richtungen mit der größten Varianz zugleich die meisten Informationen abbilden (Frochte 2021, S. 302). Ziel ist es, die Vektoren und somit die Richtungen mit maximaler Varianz innerhalb eines hochdimensionalen Raums zu finden. Diese Richtungen dienen als Basisvektoren der Projektion. Da es sich um ein Eigenwertproblem handelt, werden sie auch Eigenvektoren genannt und besitzen einen Eigenwert. Für weitere Details siehe (Runkler 2015, S. 39 ff.; Frochte 2021, S. 302 ff.; Alpaydin 2022, S. 131 ff.). Durch Auswahl einer bestimmten Anzahl von Eigenvektoren und Eigenwerte kann das erklärte Verhältnis der Varianz berechnet werden (Alpaydin 2022, S. 131 ff.).

2.2.4 Kreuzvalidierung

Bei kleinen Datenmengen wird häufig das Verfahren der Kreuzvalidierung angewendet, um eine gesteigerte Validität der Modellgüte bei überwachten Lernverfahren zu erreichen. Die vorhandenen Trainingsdaten werden in k -Subdatenmengen unterteilt und der Trainingsprozess erfolgt k mal. Es wird jeweils eine Teilmenge für das Testen verwendet, während das Training mit $k - 1$ Teilmengen durchgeführt wird. Anschließend lassen sich der Mittelwert und die Standardabweichung für alle Güte- und Ähnlichkeitsmaße ermitteln. Anhand dieser gemittelten Bewertung wird die Generalisierbarkeit des jeweiligen Modells gesteigert. (Frochte 2021, S. 97 ff.)

2.2.5 Gütemaße zur Modellbewertung

Die Beschreibung der erreichten Modellqualität und die Vergleichbarkeit der Modelle untereinander erfolgt häufig durch eine Reihe an Ähnlichkeits-/Gütemaßen. Diese werden in Bezug auf die Prognosegüte berechnet. Hierbei werden unterschiedliche Maße für Regressions- und Klassifikationsmodelle angewendet. In dieser Arbeit liegt der Fokus auf Klassifikationsmodellen, daher werden diese im Folgenden erläutert.

Durch Klassifikationsmodelle werden Daten unterschiedlichen Klassen zugeordnet oder prognostiziert (Runkler 2015, S. 89). Bei der Klassifizierung sind vier Fälle möglich. Diese lassen sich an Beispiel einer binären Klassifikation (positiv/negative) verdeutlichen. Wird für eine positive Dateninstanz ein positives Label prognostiziert, ergibt sich eine *true-positiv* (TP) Entscheidung. Ergibt sich eine Prognose als negativ bei einer positiven Instanz, ist sie *false-negativ* (FN). Ist die Prognose bei einer negativen Instanz negativ, handelt es sich um *true-negativ* (TN). Eine positive Prognose bei negativer Instanz nennt man *false-positiv* (FP). Die relative Häufigkeit dieser Fehler kann durch statistische Gütemaße ermittelt werden. Zur Darstellung der Bewertung von Klassifikationsmodell wird häufig die sogenannte Konfusionsmatrix gewählt. In ihr werden alle Klassen mit zugehörigen

Tabelle 2.3: Konfusionsmatrix für zwei Klassen (nach Alpaydin 2022, S. 633)

tatsächliche Klasse	prognostizierte Klasse		Σ
	Positiv	Negativ	
Positiv	TP: richtig-positiv	FN: falsch-negativ	p
Negativ	FP: falsch-positiv	TN: richtig-negativ	n
Σ	p'	n'	N

Prognosen mit den tatsächlichen Werten aufgetragen. Eine allgemeine Darstellung für zwei Klassen ist in Tabelle 2.3 zu sehen. (Alpaydin 2022, S. 632 ff.)

Beruhend auf der Konfusionsmatrix können die Bewertungskriterien *Genauigkeit* (engl. *accuracy*), *Präzision* (engl. *precision*) und *Sensitivität* (engl. *recall*) bestimmt werden.

Die *Accuracy* oder auch Korrektklassifikationsrate beschreibt die Anzahl der richtigen Prognosen in Bezug auf alle Prognosen. Durch sie ist es möglich, die Gesamtgüte des Modells mit einer Kennzahl

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{N} \quad (2.2.3)$$

zu bewerten. Die *Precision*

$$Precision = \frac{TP}{TP + FP} = \frac{TP}{p'} \quad (2.2.4)$$

bestimmt wie gut die vom Modell prognostizierten Klassen tatsächlich zu dieser Klasse gehören. Der *Recall*

$$Recall = \frac{TP}{TP + FN} = \frac{TP}{p} \quad (2.2.5)$$

oder auch Trefferquote drückt aus, in welchem Ausmaße positive Prognosen korrekt sind. Zur Bewertung von Klassifikationsmodellen werden meist mehrere dieser Bewertungskriterien betrachtet. (Runkler 2015, S. 89–93)

Für weitere Gütemaße wird auf Runkler (Runkler 2015) und Cleve und Lämmel (Cleve et al. 2020) verwiesen.

Eine visuelle Bewertung der Modellgüte kann anhand einer Grenzwertoptimierungskurve (engl. *receiver operating characteristics* (ROC)) erfolgen (Alpaydin 2022, S. 634). Im Diagramm werden auf der Ordinate die *true-positiv-rate* gegen die *false-positiv-rate* auf

der Abszisse aufgetragen. Die *false-positiv-rate*

$$\text{false} - \text{positiv} - \text{rate} = \frac{FP}{FP + TN} = \frac{FP}{n}, \quad (2.2.6)$$

ergibt sich aus der Anzahl der false-positiv Prognosen, bezogen auf die Summe der false-positiv und der true-negativ Prognosen. Die *true-positiv-Rate*

$$\text{true} - \text{positiv} - \text{rate} = \frac{TP}{TP + FN} = \frac{TP}{p}, \quad (2.2.7)$$

ergibt sich aus der Anzahl der true-positiv Prognosen, bezogen auf die Summe der false-positiv und true-negativ Prognosen.

Wenn zwei Klassifikatoren mit ihren ROC-Kurven in das Diagramm eingetragen werden, ist jene zu bevorzugen, deren Kurve über der anderen liegt. Diese Information kann durch die Ermittlung der Fläche unter der ROC-Kurve (*engl. area under the curve (AUC)*) auf eine Kennzahl reduziert werden. Es gilt ebenfalls, dass ein höherer AUC-Wert für eine bessere Modellgüte steht. (Alpaydin 2022, S. 634 f.)

2.2.6 Merkmalsanalyse mittels Shapley-Werten

Die Interpretierbarkeit von Modellen ist eine der größten Hürden des maschinellen Lernens. In den vergangenen Jahren ist dies ein sehr aktiver Forschungsbereich. Zunächst wird in dieser Arbeit die Definition der Interpretierbarkeit als der Grad, in dem ein Mensch die Ursache einer Entscheidung verstehen kann, oder der Grad, in dem ein Mensch die Ergebnisse eines Modells konsistent vorhersagen kann, verwendet. (B. Kim et al. 2016; Miller 2019; Molnar 2019, Chapter 3)

Weiterhin werden globale und lokale Methode unterschieden. Globale Methoden erzeugen Aussagen über die Gesamtstruktur eines Modells, lokale Methoden hingegen erzeugen Aussagen über einzelne Trainingsinstanzen. Ziel ist es, die Prognose eines Modells dahingehend zu analysieren, dass die Auswirkungen eines einzelnen Merkmals auf die Gesamtprognose verstanden werden. (Molnar 2019, Chapter 9)

Eine Methode für neuronale Netze sind die sogenannten *Shapley Additive Explanations (SHAP)*-Werte (Lundberg et al. 2017). Es handelt sich um eine Methode, die nach dem Training angewendet wird. Sie entstammt ursprünglich aus der kooperativen Spieltheorie und beruht auf den Shapley-Werten (Shapley 1953). Diese geben den gerechten Anteil am kooperativen Gewinn eines jeden Spieler bezogen auf seine Fähigkeiten an. Wenn von Spielern X, Y ausgegangen wird, müssen zunächst alle möglichen Kooperationen mit und ohne Spieler X aufgestellt werden. Nachfolgend wird der marginale Betrag berechnet. Dieser bestimmt die Differenz zwischen dem Wert, den eine Koalition mit einem Spieler erzielt, und dem Wert, den eine Koalition ohne den Spieler erreicht. Der Mittelwert aller marginalen Beträge ergibt den Shapley-Wert. (Molnar 2019, Chapter 9; Holzinger et al. 2022)

Übertragen auf maschinelles Lernen wird jedes Merkmal als ein Spieler, eine Prognose durch das Modell als Spiel und der Gewinn als Prognosewert angesehen. Da die Anzahl an Merkmalen in Modellen sehr hoch ist und jene der möglichen Kooperationen exponentiell zunimmt, ist eine exakte Berechnung der Shapley-Werte nicht sinnvoll. Um dies zu umgehen, wurden Approximationsmethoden über SHAP-Werte eingeführt. Hierfür wurde von Lundberg et al. (Lundberg et al. 2017) Kernel-Shap entwickelt. Kernel-Shap stellt eine gewichtete lineare Regression dar, wobei die Koeffizienten den Shapley-Werten entsprechen und weniger Funktionsauswertungen benötigen. Der Kernel-Shap-Algorithmus ist modellagnostisch und daher auf jedes Modell anwendbar. Zusätzlich sind andere Kernel vorhanden, die die Berechnung der SHAP-Werte beschleunigen. Aus den SHAP-Werten kann der *Merkmalseinfluss* (engl. *Feature Importance*) interpretiert werden. Merkmal mit einem hohen SHAP-Wert werden als einflussreich angesehen. In Feature-Importance-Diagramm werden die absolut gemittelten SHAP-Werte sortiert und absteigend sortiert. (Molnar 2019, Chapter 9; Holzinger et al. 2022)

2.3 Triangulation und Bildsegmentierung

Optische Messverfahren zeichnen sich durch hohe Verarbeitungsgeschwindigkeiten aus (Beyerer et al. 2016, S. 2–6). Durch eine geeignete Kombination mit bildverarbeitenden Systemen wird zudem ein hoher Grad an Automatisierbarkeit und auch Reproduzierbarkeit der Messergebnisse sichergestellt (Beyerer et al. 2016, S. 2–6; Hering et al. 2017, S. 494 f.). Weiterhin vereinen alle optischen Messverfahren die Anforderungen an hohe Genauigkeit und eine berührungslose Prüfung der Bauteile (Bretschneider et al. 2020, S. 385 f.). Andererseits müssen optische Messverfahren häufig sehr genau an den Prozess angepasst werden, da die optischen Eigenschaften von einer Vielzahl von Faktoren wie Materialzusammensetzung, Oberflächenbeschaffenheit und Wellenlänge der Beleuchtung abhängig sind oder beeinflusst werden (Beyerer et al. 2016, S. 14, S. 18; Hering et al. 2017, S. 494 f.). Ein weitverbreitetes Verfahren zur optischen Abstandsmessung und Längenmessung ist die Triangulation (Bretschneider et al. 2020, S. 419).

2.3.1 Triangulation

Das Triangulationsverfahren dient zur Abstandsmessung und beruht auf ebener Geometrie: Durch die Kenntnis der Länge einer Dreiecksseite und der daran anliegenden Winkel können die übrigen Parameter bestimmt werden. Das Funktionsprinzip der Triangulation ist in Abbildung 2.21 dargestellt. Häufig werden als Beleuchtungseinheit Laser eingesetzt, die auf ein Objekt gerichtet sind. Durch die Konstruktion wird ein Winkel zwischen Laser und Aufnahmesensor erzeugt. Über eine Abbildungsoptik wird das von der Objektoberfläche gestreute Licht mittels eines Sensors detektiert. Abhängig von der Entfernung des Objekts zur Beleuchtungseinheit trifft das gestreute Licht auf unterschiedliche Sensorelemente. Wenn eine Laserdiode mit punktförmigem Beleuchtungsprofil eingesetzt wird, wird der Abstand eines einzigen Punkts vermessen. Zur Vermessung des Oberflächenprofils muss das Objekt abgetastet werden. (Beyerer et al. 2016, S. 315–320)




Abbildung 2.21: Grundprinzip der Triangulation

Eine reduzierte Anzahl an Abtastpunkten kann durch den Einsatz eines Linienprofils erzielt werden; man spricht dann vom *Lichtschnittverfahren* (Abbildung 2.22). Das Linienprofil kann als Aneinanderreihung vieler Laserpunkte angesehen werden und erzeugt, abhängig von der Oberflächentopografie des Messobjekts, auf dem Sensor ein verzerrtes Linienprofil. Durch Ermittlung der Verzerrungen d in der Sensorebene kann über Triangulationsschritte mit dem Triangulationswinkel φ die Oberflächentopografie des Messobjekts h mit

$$h = \frac{d}{\tan \varphi} \quad (2.3.1)$$

berechnet werden. Hierzu ist allerdings eine genaue Kalibrierung erforderlich, sodass Verzerrungen der Linie nur noch in der Zeilenebene der Kamera stattfinden. Die erreichbare laterale Auflösung richtet sich nach den Kenngrößen des Sensors. Die erreichbare Höhenauflösung wird durch den Triangulationswinkel, die numerische Apertur des Objektivs und die Wellenlänge der Beleuchtung beeinflusst (Hering et al. 2017, S. 517). Durch eine Relativbewegung von Messobjekt zum Lichtschnittsensor ist es möglich, dreidimensionale Scans des Messobjekts zu erstellen. (Beyerer et al. 2016, S. 315–323)

2.3.2 Segmentierung

Durch Segmentierung werden Bildaufnahmen in getrennte, bedeutungsvolle Bereiche unterteilt (Beyerer et al. 2016, S. 683). Eine Trennung der Bereiche *Hintergrund* und *Prüfobjekt* ist hierfür ein Beispiel. Ebenfalls erleichtert die Datenreduzierung durch die Segmentierung in Form von binären Bildern die automatische Weiterverarbeitung (Gonzalez et al. 2018, S. 42). Unterschieden werden Segmentierungsaufgaben zwischen pixelbasierter, regionenbasierter, kantenbasierter oder modellbasierter Segmentierung. Die drei erst-




Abbildung 2.22: Funktionsprinzip des Lichtschnittverfahrens (nach Beyerer et al. 2016, S. 322)

genannten verwenden lokale, auf den einzelnen Pixel bezogene Informationen (Jähne 2012, S. 541 f.). Häufig führt dies zu unzulänglichen Segmentierungen, da aufgrund von Rauschen, inhomogenen Aufnahmebedingungen oder starker Variation der Intensitäten innerhalb von Objekten, Pixel zu anderen Objekten (falsch) zugeordnet werden (Beyerer et al. 2016, S. 684). Modellbasierte Methoden, wie die Auswertung mittels aktiver Konturen, gleichen diese Nachteile aus, da Nachbarschaftsbeziehungen der einzelnen Pixel berücksichtigt werden und führen häufig zu besseren Ergebnissen (Kass et al. 1988; Chan et al. 2001).

2.3.3 Aktive Konturen

Aktive Konturen, auch als *Snakes* bezeichnet, beschreiben eine Kontur, welche sich abhängig von lokalen Bildeigenschaften, durch eine Energieminimierung, verändert. Im Snake-Modell nach Kass et al. (Kass et al. 1988) wird ein Energiefunktional für die Kontur $v : [0, 1] \rightarrow \mathbb{R}^2$, $v(s) = (x(s); y(s))$, $s \in [0, 1]$, $v(0) = v(1)$ definiert, das sich aus der inneren Energie E_{int} und äußeren Energie E_{ext} zusammensetzt:

$$E_{\text{Snake}}(v(s)) = \int_0^1 (E_{\text{int}}(v(s), s) + E_{\text{ext}}(v(s))) ds \longrightarrow \min_v. \quad (2.3.2)$$

Der innere Anteil

$$E_{\text{int}}(v(s), s) = \underbrace{\frac{1}{2} \omega_{\zeta}(s) \left\| \frac{d}{ds} v(s) \right\|^2}_{\text{Elastizität}} + \underbrace{\frac{1}{2} \omega_{\eta}(s) \left\| \frac{d^2}{ds^2} v(s) \right\|^2}_{\text{Glattheit}} \quad (2.3.3)$$

bestimmt die Elastizitäts- und Glattheitseigenschaften der Kontur, wobei kurze und glatte Konturen bevorzugt werden. Um die Elastizität und Glattheit der Kontur zu steuern, können die Gewichte ω_ζ und ω_η gesetzt werden.

Für die äußere Energie

$$E_{\text{ext}}(v(s)) = \omega_{\text{pot}} P_{\text{Image}}(v(s)) + E_{\text{Feature}}(v(s)) \quad (2.3.4)$$

wird eine mit den Bilddaten assoziierte Potenzialfunktion $P_{\text{Image}}(v(s))$ aufgestellt. In dieser Funktion werden die Merkmale beschrieben, von denen die Kontur angezogen wird. Sie sind als lokale Minima des Potentials auszuführen und können ebenfalls mit ω_{pot} gewichtet werden. Zusätzlich kann eine anwendungsspezifische Nebenbedingung $E_{\text{Feature}}(v(s))$ eingebracht werden.

Die Kontur wird durch eine endliche Anzahl n von Punkten beschrieben. Das Minimierungsproblem wird iterativ gelöst. In jedem Iterationsschritt wird die Konturenergie berechnet. Eine Minimierung der Energie erfolgt durch das Gradientenabstiegsverfahren. Jeder Punkt wird entlang des Gradienten der Energie verschoben und die Energie wird berechnet und mit ihrem Vorgänger verglichen. Der Prozess wird nach einer bestimmten Anzahl von Iterationsschritten oder nachdem die Energieänderung eine Konvergenzschwelle unterschreitet, gestoppt. Details hierzu finden sich in Kass et al. 1988.

Für eine erfolgreiche Segmentierung ist die Initialkontur möglichst nahe an der zu segmentierenden Region zu wählen. Ebenfalls muss die Gewichtung für die Potenzialfunktion ausreichend hoch gewählt werden, damit über konstante Bereiche eine Anpassung an die relevanten Bereiche gewährleistet werden kann. Auch die Anzahl der Punkte muss als Kompromiss zwischen einer guten Approximation der Kurve und der Geschwindigkeit der Segmentierung betrachtet werden. Auch wenn verschiedene Verallgemeinerungen der Snake existieren, wird die Topologie der relevanten Struktur durch das verwendete Modell eingeschränkt (Kobbelt et al. 2004; Chan et al. 2001). Beispielsweise wird in der Version von Kass et al. (Kass et al. 1988) immer eine geschlossene Kontur gefordert. (Beyerer et al. 2016, S. 722–731)

2.3.4 Methoden des maschinellen Lernens zur Segmentierung

Seit die AlexNet-Architektur (Krizhevsky et al. 2012) die ImageNet Challenge (Deng et al. 2009) im Jahr 2012 mit großem Vorsprung gewonnen hat, sind neuronale Netzwerke die Methode der Wahl bei komplexen Bildverarbeitungsaufgaben (Isensee 2020, S. 12). Diese umfassen mittlerweile nicht nur die Bildklassifizierung, sondern auch die Objekterkennung und Segmentierung (Bhatt et al. 2021). Segmentierungen werden häufig in semantische und Instanz-Segmentierung unterteilt. Bei der semantischen Segmentierung werden alle gefundenen Pixel einer Klasse einem Objekt (Instanz) zugeordnet. Bei der Instanz-Segmentierung werden alle gefundenen Pixel unterschiedlichen Objekten (Instanzen) zugeordnet. (Minaee et al. 2022)

Eine Segmentierung mit neuronalen Netzwerken wird vor allem in der medizinischen Bildverarbeitung angewendet (Isensee 2020, S. 19). Für eine exakte Segmentierung

2.4. Ermittlung der Bauteilqualität und Prozessüberwachung beim Scherschneiden

werden neben den semantischen Informationen, welche Objekte sich im Bild befinden, auch die spatialen Informationen benötigt. CNNs zur Bildverarbeitung müssen aufgrund ihrer Architektur die spatiale Auflösung zugunsten der semantischen Informationen reduzieren. Durch verschiedene Methoden kann die spatiale Auflösung wieder erhöht werden, nachdem die semantischen Informationen erzeugt wurden. Diese Methoden sind begrenzt und limitieren die CNNs in der erreichbaren Netzwerkgröße. Um diese Nachteile zu überwinden, wurde die U-Net-Architektur entworfen (Ronneberger et al. 2015).

U-Net ist ein Encoder-Decoder-Netzwerk. Im Encoder oder Backbone werden über mehrere Schichten die semantischen Informationen verstärkt und die Auflösung verringert. Danach werden im Decoder die spatialen Informationen rekonstruiert. Der Decoder spiegelt dabei die Schritte des Encoders in umgekehrter Reihenfolge und erreicht so die ursprüngliche Auflösung des Bildes. Dem Decoder ist dies nur durch die eingeführten Skip Connections möglich. Diese stellen dem Decoder die Feature Maps des Encoders auf den jeweiligen Netzwerkebenen zur Verfügung. Sukzessive wird die semantische Information mit den spatialen Informationen angereicht. Eine präzise Segmentierung von Objekten, gepaart mit einer hohen Kantengenauigkeit, kann somit erreicht werden (Ronneberger et al. 2015; Isensee 2020). Durch den Aufbau als *Encoder-Decoder-Netzwerk* zeigt sich die Flexibilität dieser Architektur. Die Gestaltung des Encoders kann anwendungsspezifisch ausgetauscht werden, sofern der Decoder gleichermaßen angepasst wird. Daher wurden seit Einführung viele verschiedene Architekturen basierend auf der U-Net-Architektur entworfen. Beispielsweise wurde von Zhou et al. (Zhou et al. 2018) eine Architektur eingeführt, die durch eine erhöhte Anzahl an Skip Connections zu besseren Ergebnissen führen kann. Ein weiterer Vorteil der Architektur ist, dass sie speziell für eine geringe Menge an Trainingsdaten entwickelt und auf eine kurze *Verarbeitungszeit* (engl. *inference time*) optimiert wurde. Daher stehen auch heute noch viele U-Net-basierte Architekturen an der Spitze vieler Wettbewerbe zur medizinischen Bildsegmentierung (Isensee 2020, S. 22 ff.). (Ronneberger et al. 2015)

2.4 Ermittlung der Bauteilqualität und Prozessüberwachung beim Scherschneiden

2.4.1 Messung der Bauteilqualität beim Scherschneiden

Zur Messung der Bauteilqualität für schergeschnittene Bauteile sind verschiedenen Verfahren bekannt. Eine Zusammenstellung hiervon ist bei Kolbe (Kolbe 2020, S. 345 ff.) zu finden. Prüfmerkmale sind hauptsächlich tolerierte Geometrien, die Prüfung von Oberflächenbeschaffenheiten (Kratzer) oder das Vorhandensein von Geometrien oder Schweißpunkten. Diese kann im Werkzeug oder nach dem Werkzeug durch indirekte Messung beispielsweise mittels Kraftsensoren oder durch den Einsatz von Bildverarbeitung erfolgen. (Kolbe 2020, S. 345 ff.)

Wenn die Schnittflächenkenngrößen als qualitätsbestimmend definiert sind, sind unterschiedliche Messverfahren bekannt. Vor allem in älteren Untersuchungen werden metal-

lografische Schliffbilder verwendet. Ein Abschnitt der Schnittgeometrie wird abgetrennt und in Kunstharz eingegossen. Nach dem Aushärtvorgang wird der eingegossene Querschnitt geschliffen und angeätzt (Pfaff 1971, S. 18). Durch Auswertung mit einem Mikroskop ist eine Bestimmung der Kenngrößen möglich. Der zeitliche Aufwand beträgt aufgrund der Aushärtedauer des Kunstharzes mehr als einen Tag. Ein weiteres häufig angewendetes Verfahren ist die Ermittlung der Kenngrößen im Tastschnittverfahren, beispielsweise bei Hörmann (Hörmann 2008, S. 68 f.). Nach der Entnahme von Probekörpern aus dem Fertigungsprozess wird das Prüfobjekt eingespannt und eine auslenkbare Tastnadel wird über das Messobjekt geführt. Abhängig von der Oberflächentopografie entsteht ein Abbild der Schnittflächengeometrie und die Kenngrößen können ermittelt werden. Allerdings werden durch den taktilen Messvorgang feine Strukturen wie Grate verformt und nicht korrekt vermessen. Weiterhin ist die erreichbare Genauigkeit des Verfahrens von der Größe der Tastnadel abhängig.

Zur berührungslosen Messung der Schnittflächengeometrie haben Behrens et al. (Behrens und Jocker 2013) eine Messvorrichtung entwickelt, welche von Behrens und Krimm (Behrens, Krimm et al. 2018) weiterentwickelt und automatisiert wurde. Die Messvorrichtung (siehe Abbildung 2.23) basiert auf dem konfokal chromatischen Prinzip. Zur Durchführung einer Messung muss das Messobjekt dem Fertigungsprozess entnommen und die geschlossene Schnittlinie geöffnet werden, sodass ein freier Zugang zu den Schnittflächen entsteht. Das Messobjekt wird auf einem Drehtisch eingespannt und durch Relativbewegung des Sensors zum Objekt, wird in mehreren Scans, das Profil der Schnittfläche erstellt. Die einzelnen Profilschnitte werden über Curve-Matching-Algorithmen zu einem Gesamtprofil zusammengefügt und über die bereitgestellte Auswertesoftware werden die Schnittflächenkenngrößen automatisch ermittelt. Hierzu wird ein deterministischer Algorithmus genutzt. Zusätzlich wird eine Klassifizierung der Schnittflächen mittels eines neuronalen Netzwerks gezeigt. Unterschieden werden die Klassen, bei denen die Kenngrößen ermittelt werden sollen, von Bauteilen mit 100 % Glattschnittfläche und 100 % Bruchfläche, bei denen keine Bestimmung erfolgen muss. Im ersten Fall werden die Blechdicke, die Kanteneinzugsbreite, die Kanteneinzugsgröße, die Glattschnitthöhe, die Bruchflächenhöhe und die Schnittgrathöhe und -breite ermittelt. Der Klassifikator mit 30 Schichten erreicht eine Gesamtgenauigkeit von 83 %. Als Trainingsdaten dienen 600 Schliffbilder. In einer Vorverarbeitung durch elliptische Fourier-Deskription wird die Datenmenge reduziert und in einen Merkmalsraum überführt, der gegenüber Rotation, Skalierung und Translation invariant ist (Behrens, Krimm et al. 2018).

Zusätzlich wird dieser Arbeit auch ein Konzept zur Inline-Vermessung der Schnittflächenkenngrößen untersucht. Nachfolgend zum Schneidwerkzeug wird ein Messmodul mit einem chromatisch konfokalen Sensor auf dem Pressentisch montiert. Die Bewegungen von Messmodul und Schneidwerkzeug sind somit synchron. Der Sensor wird in die Ausstanzung bewegt und vermisst die Schnittfläche. Die Messsignale zeigen allerdings unzureichende Ergebnisse aufgrund der Fertigungsgeschwindigkeit, der Sensorcharakteristik und des Einbauraums. Daher kann keine vollständige Aufzeichnung und Vermessung der Schnittfläche erzielt werden. (Behrens, Krimm et al. 2018; Behrens, Krimm et al. 2017)

2.4. Ermittlung der Bauteilqualität und Prozessüberwachung beim Scherschneiden

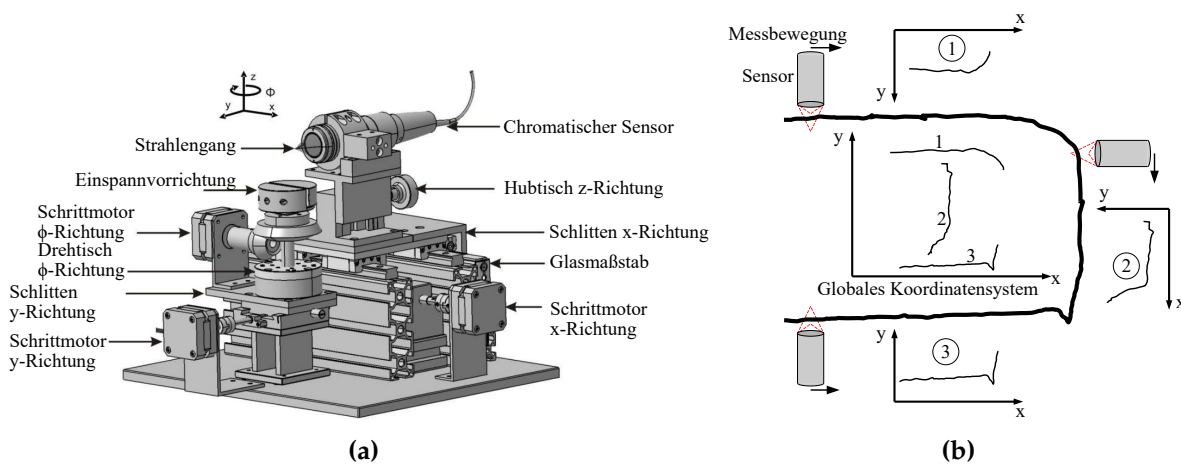


Abbildung 2.23: Vorrichtung und Messablauf zur Ermittlung der Schnittflächenkenngrößen. (a) Messvorrichtung mit steuerbaren Achsen. Das Bauteil wird dem Prozess entnommen und automatisiert vermessen. (b) Messablauf der Messvorrichtung zur Schnittflächenmessung. Die Messprofile 1,2 und 3 werden aufgezeichnet und durch Zuordnung zum Gesamtprofil zusammengestellt. (Behrens, Krimm et al. 2017)

Ebenso werden die konfokale Mikroskopie oder Profilprojektoren angewendet, um die Schnittflächen aufzuzeichnen und deren Größe zu ermitteln. Für die Messung müssen ebenfalls Bauteile aus dem Fertigungsprozess entnommen werden. Eine Prüfung erfolgt daher zumeist in einzelnen Losgrößen zu vorgegebenen Intervallen. (Behrens und Jocker 2013)

Weiter sind Messverfahren bekannt, die nur einzelne Kenngrößen ermitteln. Von der Firma Burghardt+Schmidt GmbH wird ein Schnittgrat-Messgerät (Burghardt+Schmidt GmbH 2023) in verschiedenen Ausführungen angeboten, das mit einem chromatisch konfokalen Sensor ausgestattet ist. Zur Vermessung muss das Messobjekt aus dem Fertigungsprozess entnommen, in das Messgerät eingelegt und geklemmt werden. Danach überstreicht der konfokale Messkopf das Messobjekt und die Messdaten werden generiert. Laut Herstellerangaben ist eine Messdatenaufzeichnung mit einer Genauigkeit von $1\ \mu\text{m}$ möglich. Weiter werden Laser-Triangulationssensoren zur Inline-Gratmessung verwendet (Micro-Epsilon Messtechnik GmbH & Co. KG 2023).

Wolfschläger et al. (Wolfschläger et al. 2022) haben auf dem Konzept von Trauth et al. (Trauth et al. 2018) eine U-Net-basierte Segmentierung von Feinschneidbauteilen entwickelt und kommen zu dem Ergebnis, dass eine Inline-Bildaufnahme notwendig ist, um die Auswirkungen des Fertigungsprozesses auf die Bauteilqualität aufzuzeichnen.

Zusammenfassend zeigt sich, dass Verfahren zur Vermessung geometrischer Merkmale oder Qualitätsbestimmung von Schnittflächen bekannt sind. Mit Blick auf die Bestimmung der Schnittflächenkenngrößen allerdings keines der beschriebenen Verfahren eine in den Prozess integrierte Bestimmung der Schnittflächenkenngrößen zulässt.

2.4.2 Prozessüberwachung beim Scherschneiden

Die Notwendigkeit der Prozessüberwachung beim Scherschneiden besteht bereits seit Jahrzehnten. Die hohen Verarbeitungsgeschwindigkeiten wie auch die geschlossene Bauweise der Schneidwerkzeuge infolge der Prozessanforderungen erschweren eine direkte Überwachung der Signale am Entstehungsort (Kolbe 2020, S. 345 ff.). Ebenfalls beeinträchtigen die komplexen Bedingungen aufgrund der Vielzahl der Einflussparameter und ihrer Toleranzen Rückschlüsse auf den Prozess. Weiter sind Ausfälle und Stillstandszeiten innerhalb von Scherschneidprozessen häufig durch den vorliegenden Verschleiß der Schneidelemente bedingt. Zunächst wurden daher in verschiedenen Studien die Auswirkungen des Verschleißes auf den Scherschneidprozess untersucht. Aufgrund der vielen unterschiedlichen Anforderungen an Scherschneidbauteile und des großen Parameterraumes ergibt sich eine Vielzahl von Studien. Dies lässt sich anhand von Online-Datenbank-Recherchen nachvollziehen: Eine Suchanfrage bei ScienceDirect ergibt 236 Ergebnisse. Die genauen Suchbegriffe sind der Abbildung 2.24 zu entnehmen. Zum Vergleich wurden ähnliche Ergebnisse mit Lens.org (Lens.org 2023) erzielt. Hier konnten 209 relevante Ergebnisse gefunden werden. Die folgende Beschreibung erhebt daher keinen Anspruch auf Vollständigkeit, sondern stellt vielmehr die Vielfalt der Forschung bezogen auf die Verschleißermittlung und Prozessüberwachung beim Scherschneiden dar.




Abbildung 2.24: Anzahl der wissenschaftlichen Studien im Zeitraum ab 1960. Die verwendeten Suchbegriffe sind in der Abbildung dargestellt (nach Lens.org 2023).

Eine der ersten Studien, die den Einfluss des Verschleißes auf die Schnittflächenkenngrößen untersuchte, wurde von Maeda et al. (Maeda et al. 1967) durchgeführt. Weitere

2.4. Ermittlung der Bauteilqualität und Prozessüberwachung beim Scherschneiden

Untersuchungen zeigten den Einfluss verschiedener Prozessparameter und analysierten deren Auswirkungen auf den Verschleißzustand und die Qualität der Schnittfläche (Hoffmann, Hoogen et al. 1999; Cheung et al. 2001; Krinninger et al. 2017). Kopp (Kopp 2017) betrachtet das Verschleißverhalten in Bezug auf die Werkzeugsteifigkeit im offenen Schnitt. Volk und Hammer untersuchten das Verhalten von Verschleißkurven anhand eines Vergleichsprüfstands (Volk et al. 2019). Tröber et al. (Tröber et al. 2017) zeigen, dass eine Methode zur Reduzierung von adhäsivem Verschleiß durch thermoelektrische Ströme möglich ist. Klingenberg und Singh (Klingenberg und Singh 2004) geben einen Überblick über analytische, experimentelle und auch numerische Modellierungen des Verschleißprozesses. Weiter zeigt die Studie den Einfluss von Verschleiß auf die Schnittfläche. Ott et al. (Ott et al. 2019) analysiert den Verschleiß in Bezug auf die Herstellung der Schneidelemente. Kubik et al. (Kubik 2021) analysiert die Auswirkungen der Prozessparameter Schneidspalt und Schneidkantenradius. Monteil et al. (Monteil et al. 2008) zeigten die Überwachung des Verschleißvolumens durch radioaktive Dünnschichtaktivierung und durch Messung der resultierenden Schneidstempel Aktivität infolge des Verschleißes.

Simulationen zur Verschleißvorhersage durch die Finite-Element-Methode wurden ebenfalls untersucht. Hambil (Hambli 2001) zeigte ein Modell zur Vorhersage der Grathöhe und des Verschleißprofils. Cheon und Kim (Cheon et al. 2016) erstellten ein Finite-Element-Methode-Modell und implementierten sich selbstaktualisierende Geometrien des Schneidstempels anhand eines modifizierten Arachard-Verschleißmodells, zur Abbildung des Verschleißes. Cha et al. (Cha et al. 2017) erstelle eine Vorhersage im offenen Schnitt anhand der Übertragung eines Finite-Elemente-Modells aus einer Umformsimulation. Falconnet et al. (Falconnet et al. 2012) und Husson et al. (Husson et al. 2008) simulierten das Verschleißverhalten bei der Verarbeitung von dünnen Kupfermaterialien. Aufgrund des großen Anwendungsfelds und der damit einhergehenden unterschiedlichen Bedingungen sind die Resultate nur bedingt übertragbar.

Aus diesem Grund wurden verstärkt datengetriebene Methoden untersucht und zur Prozessüberwachung eingesetzt. In der Industrie werden häufig Überwachungssysteme zur statistischen Prozesskontrolle eingesetzt. Hierbei werden Hüllkurvenüberwachungen bzw. Schwellwerte eingesetzt (MARPOSS Monitoring Solutions GmbH 2019). Breitling (Breitling et al. 1997) zeigte, dass die Überwachung der Schneidkraft unmittelbar am Schneidstempel ein leistungsstarkes Verfahren ist, um die Produktion zu überwachen. Aus Änderungen in den aufgezeichneten Signalen kann auf veränderte Prozessparameter geschlossen werden. Eine der ersten Überwachungen, die zwischen einem funktionsfähigen und verschlissenen Schneidstempel unterscheidet, wurde von Lee et al. (Lee et al. 1997) vorgestellt. Hierbei wird die maximale Schneidkraft mittels eines Autoregressionsmodells verarbeitet und durch eine lineare Diskriminanzfunktion klassifiziert. In der Folge konnten verschiedene Studien zeigen, dass Wavelet- (Koh et al. 1999; Jin et al. 2001; Ge, G. C. Zhang et al. 2002) oder Fourier-Transformationen (G. Zhang et al. 2002), die auf Kraft- und Beschleunigungssignalen basieren, für die Prozessüberwachung geeignet sind. Kim (B. S. Kim 1983) sowie Mardapittas und Au (Mardapittas et al. 1989) zeigten, dass eine Überwachung anhand der Körperschallsignale möglich ist. Diese wurde ebenfalls von Neugebauer et al. (Neugebauer et al. 2000) nachgewiesen.

Methoden des maschinellen Lernens sind in der Lage, anhand von Daten, Prozesse detaillierter zu klassifizieren als die genannten Methoden. Daher wurden überwachte Lernmethoden durch PCA-Merkmale aus Kraftsignalen von Jin et al. (Jin et al. 2000) verwendet. In der Arbeit wurde ein Entscheidungsbaum trainiert, der veränderte Fertigungsbedingungen erkennt. Ebenfalls wurden Hidden-Markov Modelle (Ge, Du und Xu 2004) und Support Vector Machines (Ge, Du, G. Zhang et al. 2004a) genutzt, um zwischen unterschiedlichen Fehlerarten im Produktionsprozess zu unterscheiden. Unüberwachte Lernmethoden sind ebenfalls Gegenstand unterschiedlicher Studien (Ge, Du, G. Zhang et al. 2004b; Bergs et al. 2020).

Tiefe Lernmethoden zur Prozessüberwachung bei Schneidprozessen auf der Basis von künstlichen neuronalen Netzwerken sind Gegenstand aktueller Forschung. Übersichten zu bisheriger Forschung finden sich bei (Liewald et al. 2022; Molitor et al. 2022; Kubik, Becker et al. 2022). Hierbei gewinnt die Berücksichtigung der Bauteilqualität in Form von Bildaufnahmen zunehmend an Bedeutung, da diese die Fertigungs- und Verschleißzustände in Form der geometrischen Ausprägung der Bauteile repräsentieren (Molitor et al. 2022). Molitor et al. (Molitor et al. 2022) untersuchten ein CNN zur Verschleißbestimmung, das auf 7440 Aufnahmen von Bauteilen basiert. Diese wurden mit 16 unterschiedlich gefertigten Schneidkantenradien, welche den Verschleiß des Stempels simulieren, erstellt. Sowohl ein MobileNet als ein selbst erstelltes CNN konnten hierbei eine Klassifizierung mit einer Genauigkeit von 99 % in 16 Verschleißklassen vornehmen. Trauth et al. (Trauth et al. 2018) präsentiert ein Konzept zur Anlagenvernetzung unter Berücksichtigung von Daten aus Bildaufnahmen. Beide Veröffentlichungen schließen, dass eine in den Prozess integrierte und automatisierte Bildaufnahme der Bauteilqualität ein höheres Prozessverständnis ermöglicht.

2.5 Abgrenzung der Arbeit

Zusammenfassend zeigt sich, dass die Prozessüberwachung auch mittels künstlicher neuronaler Netze im Fokus vieler Studien steht. Der Bauteilqualität, die aus den aktuellen Fertigungs- und Verschleißbedingungen resultiert, wird hierbei eine große Bedeutung zugesprochen. Gemeinsam haben die Studien vor allem, dass sie häufig unter Laborbedingungen stattfinden und die Verschleißprozesse anhand von manuellen Bearbeitungen - durch Schneidkantenverrundung - simuliert werden. Auch die Datenaufzeichnung erfolgt häufig manuell und vom Prozess getrennt in Form von Stichproben. Durch diese mitunter aufwendigen Vorgänge entstehen zumeist kleine Datenmengen, die den natürlichen Verschleißprozess in der Serienfertigung nur unzureichend abbilden.

Ziel dieser Arbeit ist daher, ein in den Prozess integriertes System zur automatisierten Bestimmung der Bauteilqualität beim Scherschneiden zu untersuchen. Dieses System soll in Verbindung mit anderen Fertigungsparametern die Grundlage für ein Sensornetzwerk zur Verschleißvorhersage im laufenden Fertigungsprozess bilden. Dieses Netzwerk soll an einer Stanzbiegeautomaten aufgebaut und der Informationsgehalt der Bauteilaufnahmen im Vergleich zu aktuellen Verfahren geprüft werden.

Schnittflächenanalyse durch klassische Bildverarbeitung

Die Beschreibungen im vorhergehenden Kapitel haben gezeigt, dass eine durchgehende Qualitätsaufzeichnung innerhalb des Scherschneidprozess bisher nur an externen Stichproben möglich ist. Eine Qualitätsbestimmung im Prozess reduziert nicht nur die aktuellen Durchlaufzeiten für Messergebnisse, sondern sorgt auch für eine Reduktion von Folgekosten, indem Störungen unmittelbar erkannt werden. In dieser Arbeit werden als Qualitätsmerkmale die Kenngrößen der Schnittfläche, im Besonderen die Glattschnittfläche und deren Höhe, festgelegt. Zunächst wird das Schneidwerkzeug und die in dieser Arbeit verwendete Stanzbiegeautomaten beschrieben. Anhand der in (Lorenz 2017) untersuchten Konzepte, wird ein Prototyp eines optischen Überwachungssystems in einen Stanzbiegeautomaten integriert. Weiterhin wird die Bildverarbeitung zur Qualitätsbestimmung untersucht.

3.1 Schneidwerkzeug und Stanzbiegeautomat

Für die Untersuchungen in dieser Arbeit wird ein Schneidwerkzeug mit gefedertem Niederhalter und drei quadratischen Schneidstempeln ausgewählt, siehe Abbildung 2.13. Das Schneidwerkzeug ist für die Bandbreite 35 mm und die Banddicke $s = 0,5$ mm ausgelegt. Die Schneidstempel sind aus pulvermetallurgischem Stahl gefertigt, wobei die geschlossene Schneidgeometrie einen quadratischen Querschnitt $5 \text{ mm} \times 5 \text{ mm}$ und einen Eckradius von 0,5 mm besitzt. Die Schneidplatten sind aus Hartmetall K40 (CF-H40S+) mit einem Schneidspalt von 5 % der Banddicke, $25 \mu\text{m}$ umlaufend, gefertigt. Die Kombination aus Schneidstempel- und Schneidplattenmaterial begünstigt einen Schneidstempelverschleiß gegenüber dem Schneidplattenverschleiß und wird im Hinblick auf Kapitel 5 ausgewählt. Die gefertigte Schnittgeometrie ist in Abbildung 3.1 gezeigt. In dieser Arbeit wird nur eine Kante einer Schnittgeometrie überwacht. Für die Versuche wird das Schneidwerkzeug allerdings immer vollständig bestückt. Zum einen dienen die weiteren Schneidstempel zur statistischen Absicherung der ermittelten Werte. Zum anderen sind diese für das Kräftegleichgewicht im Schneidwerkzeug notwendig.

Schneidwerkzeuge (siehe Kapitel 2.1.6) sind produktbezogene hochgenaue Baugruppen mit Toleranzen im μm -Bereich. Die hohen resultierenden Schneidkräfte aus dem Schneidprozess führen zu erhöhten Steifigkeits- und Genauigkeitsanforderungen an die Konstruktion und Fertigung. Die Schneidstempel befinden sich im Inneren des Werkzeugs. Durch eine ausreichende Dimensionierung der Bauteile im Werkzeugober- und -unterteil werden Verformungen im Werkzeug minimiert. Zusätzlich resultieren

hieraus die geforderten Führungslängen für die Schneidstempel, die Stempelbrüchen und Verformungen der Schneidstempel entgegenwirken.

Die Qualitätsbestimmung von Bauteilen direkt am Entstehungsort ist mit Blick auf die Nachfolgekosten und die Reaktionszeit vorteilhaft. Eine Messung direkt im Schneidwerkzeug wird als nicht sinnvoll angesehen, da die Integration von Messtechnik zu Materialschwächungen führt und die Steifigkeit des Schneidwerkzeugs reduziert. Zusätzlich steigt zum einen die Komplexität des Konstruktions-, Fertigungs- und Montageprozesses. Zum anderen wird die Bauteilqualität auf ungewisse Weise beeinflusst und muss kritisch geprüft werden. Ebenso können bestehende Schneidwerkzeuge nicht oder nur mit erhöhtem Arbeitsaufwand nachgerüstet werden, was auf die hohe Genauigkeit der abgestimmten Einzelteile und die gehärteten Komponenten zurückzuführen ist. Zusätzlich wird in dieser Bauweise für jedes Schneidwerkzeug eine gesonderte Einheit benötigt. Eine Beurteilung der Bauteilqualität direkt nach dem Schneidwerkzeug ist daher vorteilhaft, da bestehende Schneidwerkzeuge und Konstruktionen nicht beeinflusst werden. Die Anzahl der notwendigen Überwachungssysteme wird reduziert, da dieses unabhängig vom Schneidwerkzeug wird. Die Zugänglichkeit der Messstelle und des Überwachungssystems wird ebenfalls erhöht. Allerdings erfolgt eine Datenaufzeichnung nicht direkt am Entstehungsort der Schnittfläche, was zu Verzögerungen bei der Fehlerdetektion führt.

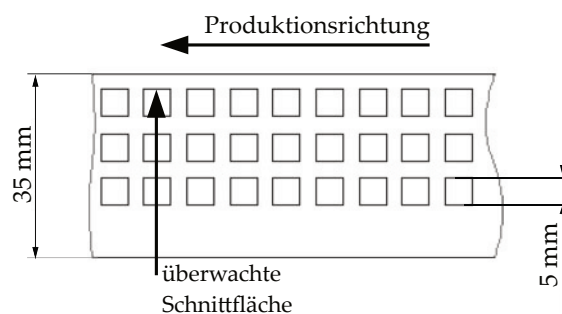


Abbildung 3.1: Bauteilgeometrie, die in dieser Arbeit verwendet wird.

Die Integration des Überwachungssystems erfolgt an einem Stanzbiegeautomaten Bihler GRM-NC unmittelbar nach der Presseneinheit, siehe Abbildung 3.2. Die maximale Fertigungsgeschwindigkeit der Maschine beträgt 250 Hub pro Minute. Die Pressenbewegung erfolgt sinusförmig mit einer Hubhöhe von 16 mm. Weitere Prozessparameter sind der Tabelle 3.1 zu entnehmen. Zum Datenaustausch mit der Maschine wird die vorhandene OPC-UA-Schnittstelle (OPC Foundation 2023) genutzt.

3.2 Optisches Überwachungssystem

Die Überwachung durch ein optisches System ist für diese Aufgabe besonders geeignet. Optische Verfahren gewährleisten hohe Verarbeitungsgeschwindigkeiten und durch die Kombination mit einer Bildverarbeitung einen hohen Grad an Automatisierung und Reproduzierbarkeit der Messergebnisse. Ebenso vereinen alle optischen Messverfahren

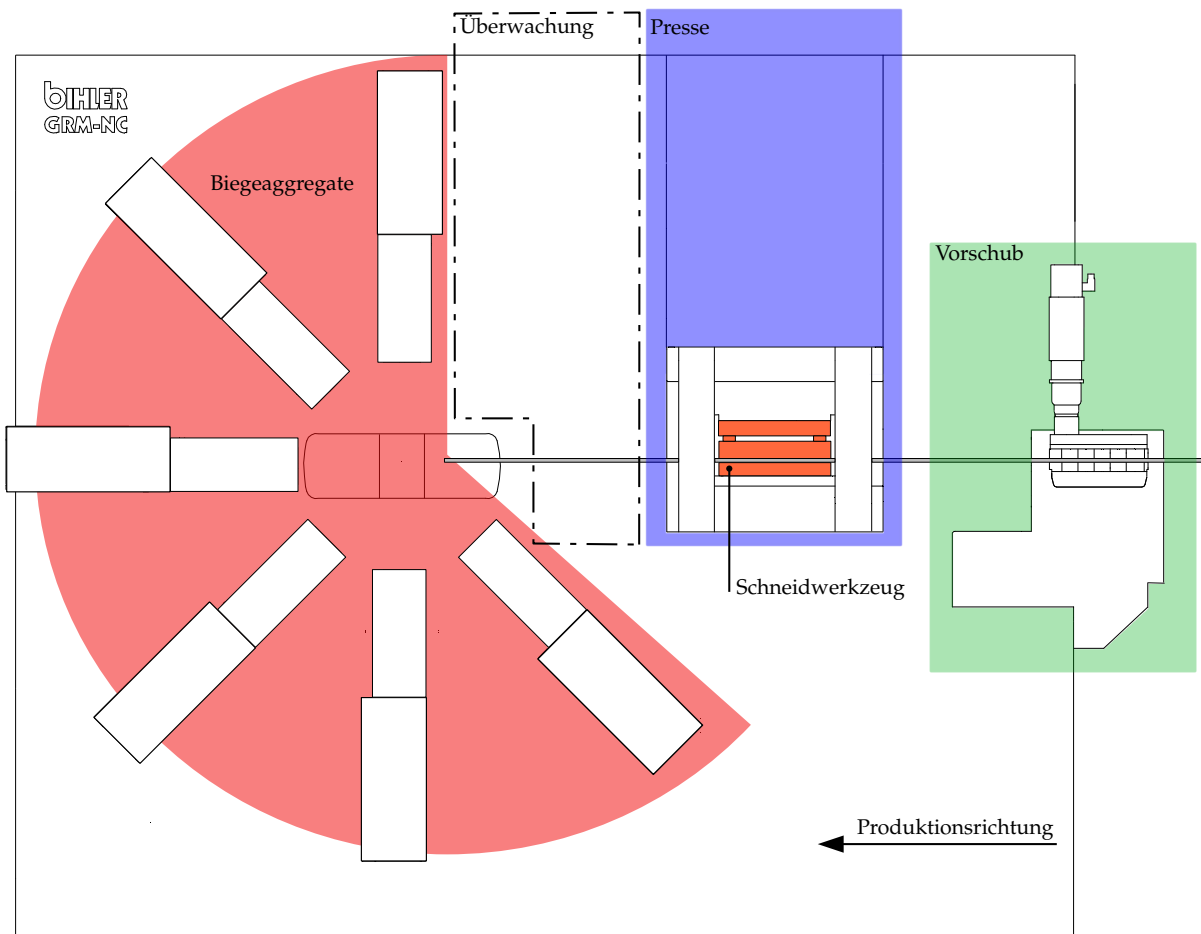


Abbildung 3.2: Aufbau des Stanzbiegeautomaten an dem das Überwachungssystem angebracht wird. Das Schneidwerkzeug ist in Orange dargestellt. Der für die Überwachung vorgesehene Einbauraum befindet sich direkt nach dem Schneidwerkzeug.

die Eigenschaften der hohen Genauigkeit und der berührungslosen Prüfung. (Beyerer et al. 2016, S. 2–6; Bretschneider et al. 2020, S. 385 f.)

Das entwickelte System erfasst prozessbegleitend für jedes Bauteil die Daten der Schnittfläche. Dabei werden ein Bildaufnahme- und ein Lichtschnittverfahren kombiniert. Durch diese Kombination werden sowohl zweidimensionale Messgrößen als auch dreidimensionale Messgrößen aufgezeichnet. Beide Verfahren nutzen den gleichen CMOS-Sensor und ein telezentrisches Objektiv (siehe Abbildung 3.3). Weiter wird durch die Bildaufnahme die Analyse vom bis dato üblichen Profilschnitt der Schnittfläche zu einer Flächenansicht der Schnittfläche erweitert. Hinsichtlich der Genauigkeit der gemessenen Schnittflächenparameter wird eine Genauigkeit von $\pm 5 \mu\text{m}$ für alle Längenmaße gefordert. Änderungen sind daher mit $\pm 1 \%$ der in dieser Arbeiten verwendeten Banddicke und $\pm 1,3^\circ$ der Winkelmaße erkennbar. Im Folgenden werden die einzelnen Verfahren und Komponenten beschrieben.




Abbildung 3.3: Funktionsprinzip der Bildaufnahme und der Triangulation mit einer Kamera mit Anstellwinkel γ und Triangulationswinkel φ .

3.2.1 Bildaufnahmeverfahren

Die Bilderfassung liefert 2D-Aufnahmen der Schnittfläche und wird zur Bestimmung der Längenmaße, wie der Glattschnitthöhe, verwendet. Die erforderliche Genauigkeit der Längenmaße von $5\ \mu\text{m}$ entspricht einer Auflösung von 200 Linienpaare/mm in der Ebene der Schnittfläche. Um diese Anforderung zu erfüllen, wird ein telezentrisches Objektiv mit dem Abbildungsmaßstab $M = 2$ verwendet. Nach dem Nyquist-Abtasttheorem muss die Bildabtastauflösung in der Sensorebene kleiner als $2,5\ \mu\text{m}$ sein, weshalb ein Sensor mit dem Pixelabstand $p = 4,8\ \mu\text{m}$ gewählt wird. Das gewählte Objektiv kann Strukturen mit einer Auflösungsanforderung 200 Linienpaare/mm in der Objektebene mit einem Kontrast von 50 % abbilden und besitzt somit eine ausreichende optische Abbildungsqualität.

Die geschlossene Kontur der Schneidgeometrie verhindert eine orthogonale Ausrichtung der optischen Achse des Objektivs zur Schnittfläche. Deshalb wird das gesamte System in Bezug zur horizontalen Ebene um den Anstellwinkel γ rotiert (siehe Abbildung 3.3). In der Folge wird die Schnittflächenaufnahme perspektivisch verzerrt und die erreichbare Auflösung in vertikaler Richtung verringert. Durch den Pixelabstand p , unter Einhaltung der Auflösungsanforderung, ergibt sich die Obergrenze für den Anstellwinkel $\gamma_{\text{max}} = \arccos(p/5\ \mu\text{m}) = 16,3^\circ$. Aufgrund von Störkonturen wird konstruktionstechnisch ein Anstellwinkel $\gamma = 20^\circ$ gewählt. Die erzielbare Auflösung ergibt 195 Linienpaare/mm in der Ebene der Schnittfläche. Der Anstellwinkel wird mechanisch sichergestellt.

3.2.2 Lichtschnittverfahren

Das Lichtschnittverfahren ist in der Lage, die 3D-Topografie der Schnittfläche zu messen und wird beispielsweise zur Bestimmung des Bruchwinkels β oder der Grathöhe verwendet. Verfügbare Laser-Lichtschnittsensoren besitzen einen erhöhten Platzbedarf, besitzen zu geringe Arbeitsabstände oder sind unter dem notwendigen Anstellwinkel nicht funktionsfähig. Daher wird der Bildaufnahmesensor ebenfalls für das Lichtschnittverfahren verwendet. Nach der Triangulationsmethode wird eine Laserlinienbeleuchtung hinzugefügt. Der Linienlaser (siehe Abbildung 3.3) wird so ausgerichtet, dass

- der Triangulationswinkel φ zwischen der Laserachse und der optischen Achse des Objektivs $\varphi = 30^\circ$ beträgt,
- die Laserlinie entlang der y_M -Richtung ausgerichtet ist und
- die Laserlinie nahe der Mitte des CMOS-Sensors in x -Richtung abgebildet wird.

Die Laserlinie wird auf die Schnittfläche projiziert und vom Sensor als zweidimensionale Aufnahme wiedergegeben. Mit dem Triangulationswinkel φ werden die Daten in das x_M, y_M, z_M -Koordinatensystem transformiert. Diese nun dreidimensionalen Daten werden auf die y_M, z_M -Ebene projiziert und die Kontur der Schnittfläche wird extrahiert.

3.2.3 Komponenten des Überwachungssystems

Das Überwachungssystem (siehe Abbildung 3.4a) besteht aus einem telezentrischen Objektiv mit einem Abbildungsmaßstab $M = 2$, einem Arbeitsabstand $wd_{\text{Objektiv}} = 75 \text{ mm}$ und einer numerischen Apertur $NA = 0,164$. Es wird eine monochrome Industriekamera (CMOS-Sensor) mit einem Pixelabstand $p = 4,8 \mu\text{m}$, einer Auflösung von 1280×1024 Pixel (Sichtfeld: $3,072 \text{ mm} \times 2,457 \text{ mm}$) und einer Aufnahmezeit 170 Bildern pro Sekunde (fps) verwendet. Für das Lichtschnittverfahren wird ein Lasermodul (Z-LASER Z30M18H3-F-450-lp45) mit einer Wellenlänge von 470 nm ausgewählt. Das Lasermodul verfügt über einen einstellbaren Fokus mit einem Arbeitsabstand $wd_{\text{Laser}} = 100 \text{ mm}$.

Alle Komponenten werden auf einer Grundplatte befestigt. Eine verstellbare Halterung ermöglicht es, die Laserlinie in ihrer eigenen Achse zu rotieren, den Triangulationswinkel einzustellen und die Laserposition entlang der x -Achse zu verschieben. Zur Montage am Stanzbiegeautomaten wird ein Trägerrahmen an dieser befestigt. In diesem Trägerrahmen wird das Überwachungssystem durch Zylinderstifte positioniert und eine wiederholgenaue Messposition gewährleistet (siehe Abbildung 3.4b). Das Stanzgitter wird durchgängig in einem Führungstunnel geführt und mit gefederten Stiften fixiert. Einzig im Aufnahmebereich befindet sich eine Freimachung. Am Trägerrahmen sind die beiden einstellbaren Blitzbeleuchtungen (470 nm) für die Bildaufnahme befestigt. Eine Blitzbeleuchtung wird oberhalb der horizontalen Ebene montiert.

Der Winkel zwischen dem ausgesendeten Licht der Beleuchtung und der Normalen auf die Glattschnittfläche sollte nahezu gleich dem Winkel zwischen dieser Normalen und der optischen Achse sein. Dadurch wird sichergestellt, dass die Glattschnittfläche hell beleuchtet wird (siehe Abbildung 3.4c). Aufgrund der unterschiedlichen Oberflächen-

Kapitel 3. Schnittflächenanalyse durch klassische Bildverarbeitung

rauheit der Bruchfläche und der durch den Bruchwinkel erzeugten Winkeländerung wird ein prägnanter Übergang zwischen diesen Kenngrößen erzeugt. Der Übergang zwischen Bruchfläche und Bandunterseite wird von der zweiten Blitzbeleuchtung, die Bandunterseite beleuchtet, erzeugt.

Durch diese konstruktive Ausführung ist eine Aufnahme der Schnittfläche 42 Hub nach ihrer Entstehung im Schneidwerkzeug möglich. Eine vollständige Aufstellung aller verwendeten Komponenten findet sich im Anhang, siehe Tabelle A.1.

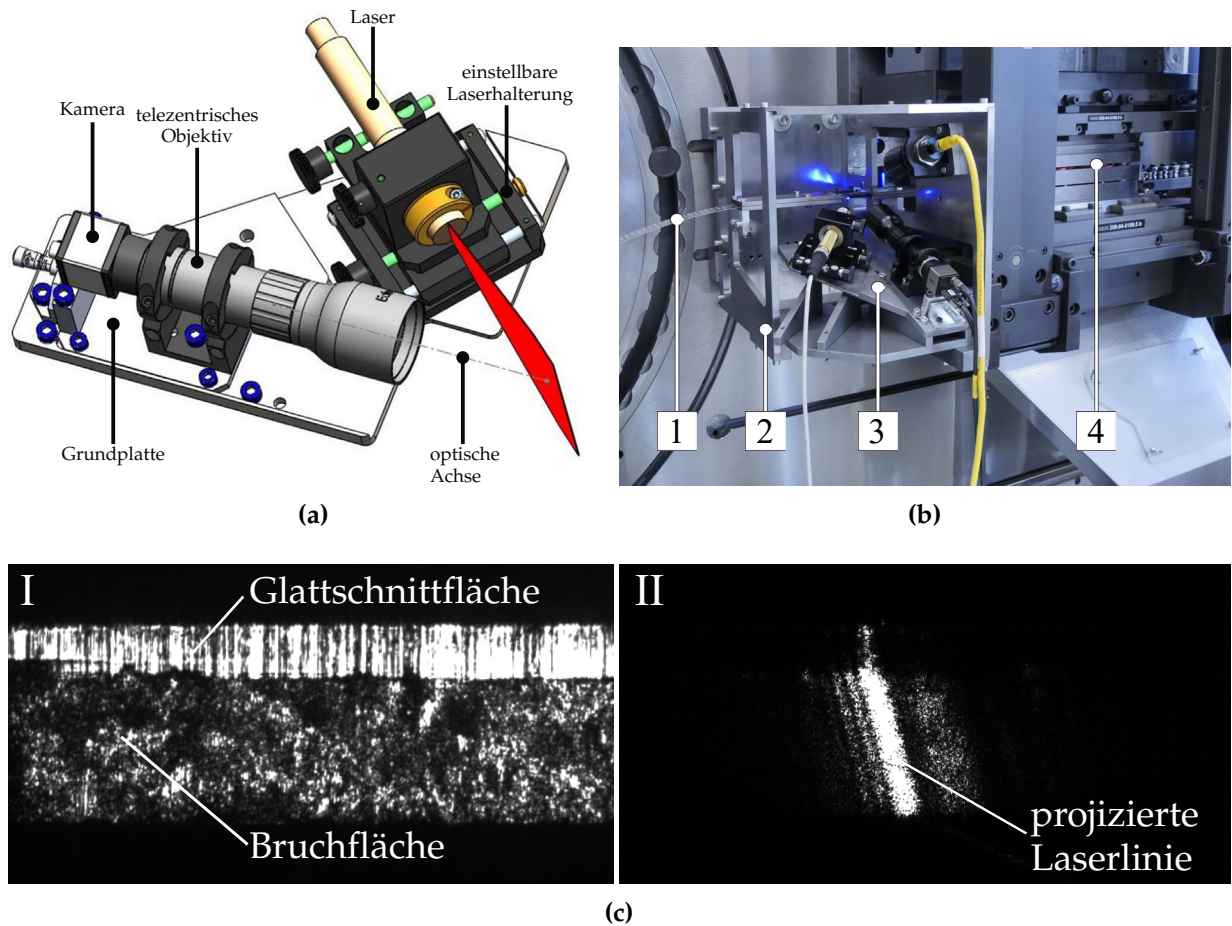


Abbildung 3.4: Aufbau und Montageposition des Überwachungssystems am Stanzbiegeautomaten; (a) optisches Überwachungssystem mit Kamera, Objektiv und Laser, montiert auf der Grundplatte; (b) optisches Überwachungssystem, montiert am Stanzbiegeautomaten; Stanzgitter (1), Trägerrahmen (2), Überwachungssystem (3), Schneidwerkzeug (4); (c) Aufnahmen des Überwachungssystems; Bildaufnahme (I), Lichtschnittaufnahme (II)

3.2.4 Steuerung des Überwachungssystems

Zur Steuerung des Aufnahmeprinzips werden die Beleuchtung und das Lasermodul an die Kamera angeschlossen. Weiterhin wird ein Triggersignal aus der Maschine mit der

Kamera verbunden. Das Lasermodul und die Beleuchtung werden mit einer Spannung von 24 V versorgt. Die Kamera wird an einen Laptop angeschlossen und von diesem versorgt. Das Triggersignal der Maschine löst den Aufnahmeprozess aus. Zur Steuerung der Belichtungszeiten und zur Datenspeicherung wird ein Python-Skript eingesetzt. Innerhalb des Skripts wird das Triggersignal registriert und über die OPC-UA-Verbindung von Laptop und Maschine wird der in der Maschine vorhandene Hubzähler ausgelesen. Durch den bekannten Versatz der Messstelle zum Schneidstempel kann die Aufnahme einer eindeutigen Schnittfläche zugeordnet werden. Zur Minimierung von Vibrationen während der Aufnahmen wird der Zeitpunkt gewählt, an dem die maximale Niederhalterkraft anliegt. Der entworfene Arbeitsablauf ist in Abbildung 3.5 dargestellt.




Abbildung 3.5: Ablaufdiagramm der Bildaufnahme und des Lichtschnittverfahrens innerhalb eines Fertigungstakts bei 250 Hub pro Minute (240 ms pro Hub).

3.2.5 Kalibrierung des Triangulationsaufbau

Präzise Daten aus dem Triangulationsaufbau können nur durch eine genaue Kenntnis des Triangulationswinkels φ erreicht werden. Dieser lässt sich durch einen Kalibriervorgang berechnen. Zunächst wird hierzu ein Stufenkörper (siehe Abbildung 3.6b) mit dem konfokalen Mikroskop (siehe Anhang, Tabelle A.3) vermessen. Die Höhe der Stufen z_c ist dadurch mit hoher Präzision bekannt.

Der Kalibriervorgang selbst, findet außerhalb der Maschine auf einem Messtisch statt. Das Überwachungssystem wird dem Trägerrahmen entnommen und auf einem Messtisch vor einer Verfahrereinheit befestigt. Der Stufenkörper wird auf der Verfahrereinheit innerhalb des Arbeitsabstands des Objektivs fixiert (siehe Abbildung 3.6a). Es wird sichergestellt, dass die optische Achse des Überwachungssystems und die Flächennormale des Stufenkörpers übereinstimmen. Der parallel zu den Pixelspalten des CMOS-Sensors ausgerichtete Laser wird auf den Stufenkörper projiziert und die Aufnahme ausgelöst. In den Bilddaten sind die verschiedenen Höhenstufen des Stufenkörpers als Liniensegmente zu erkennen (siehe Abbildung 3.6c). Mit einer zeilenweisen *Schwerpunktsberechnung* (engl. *center of mass*) (COM) der Intensitätswerte werden die durchschnittlichen x -Positionen für jedes Liniensegment und die Differenzen Δx zwischen selbigen bestimmt. Mit den be-

kannten Höhenwerten z_c wird der Triangulationswinkel φ berechnet (siehe Kapitel 2.3.1).

3.2.6 Einfluss des Anstellwinkels γ

Durch die Montage im Trägerrahmen wird das Überwachungssystem um den Anstellwinkel $\gamma = 20^\circ$ zur horizontalen Ebene rotiert. Eine ebene Schnittfläche ist parallel zur x_W, y_W -Ebene ausgerichtet. Die Sensorebene und die x_W, y_W -Ebene spannen ebenfalls den Winkel γ auf. Durch die Kalibrierung werden nur zur Sensorebene parallel Ebenen als senkrechte Linie abgebildet. Die Schnittflächenebene weicht hiervon ab. Durch die Position des Lasermoduls wird die Laserlinie um die z_W -Achse mit $\gamma = 20^\circ$ rotiert. Bei der Montage im Trägerrahmen unter dem Anstellwinkel γ wird eine exakt ebene Schnittfläche um den Winkel γ zur Bildsenkrechten abgebildet. Dies muss beachtet werden, um den Bruchwinkel β der gemessenen Triangulationsdaten entlang der projizierten Laserlinie korrekt zu berechnen.

3.3 Bildverarbeitung zur Überwachung der Bauteilqualität

Programmablaufpläne für die hier beschriebenen Bildverarbeitungsalgorithmen befinden sich im Anhang, siehe Abbildung A.1.

3.3.1 Bildverarbeitung für die Bildaufnahmen

Für die Bildverarbeitung wird das OpenCV-Paket (Bradski 2000) für Python (Van Rossum et al. 2009) verwendet. Ziel ist es, die Übergänge der Glattschnittfläche nach deren Definition in *VDI 2906 Blatt 2* möglichst exakt zu segmentieren. Zunächst wird die Charakteristik der Bildaufnahmen analysiert. Die ausgerichtete Beleuchtung erleuchtet einen vertikal strukturierten, mit inhomogenen Grauwerten versehenen Bereich, der als Glattschnittfläche identifiziert wird (siehe Abbildung 3.4c). Die Kontur des Bereichs fluktuiert über die Bildlänge. Aufgrund dieser Schwankung kann eine zusammenhängende Segmentierungslinie entlang des Übergangs zwischen Glattschnitt- und Bruchfläche durch lokale Filteroperationen nicht gewährleistet werden. Aktive Kontur-Methoden hingegen ermöglichen es, trotz dieser Fluktuationen und auch bei fehlenden Datenpunkten eine zusammenhängende Übergangslinie zu erzeugen (Ngan et al. 1999; Chan et al. 2001).

Aktive Konturen oder Snakes (siehe Kapitel 2.3.3) bezeichnen ein iteratives Energieminimierungsverfahren, das eine Kontur unter dem Einfluss von Energieanteilen wie Konformität mit dem zugrunde liegenden Bild und lokaler Krümmung der Kontur verformt (Kass et al. 1988). Für den Anteil der externen Energie wird eine Potenzialfunktion des Bildes, das sogenannte Feature Image, aus dem Originalbild abgeleitet und auf die jeweilige Anwendung abgestimmt.

3.3. Bildverarbeitung zur Überwachung der Bauteilqualität

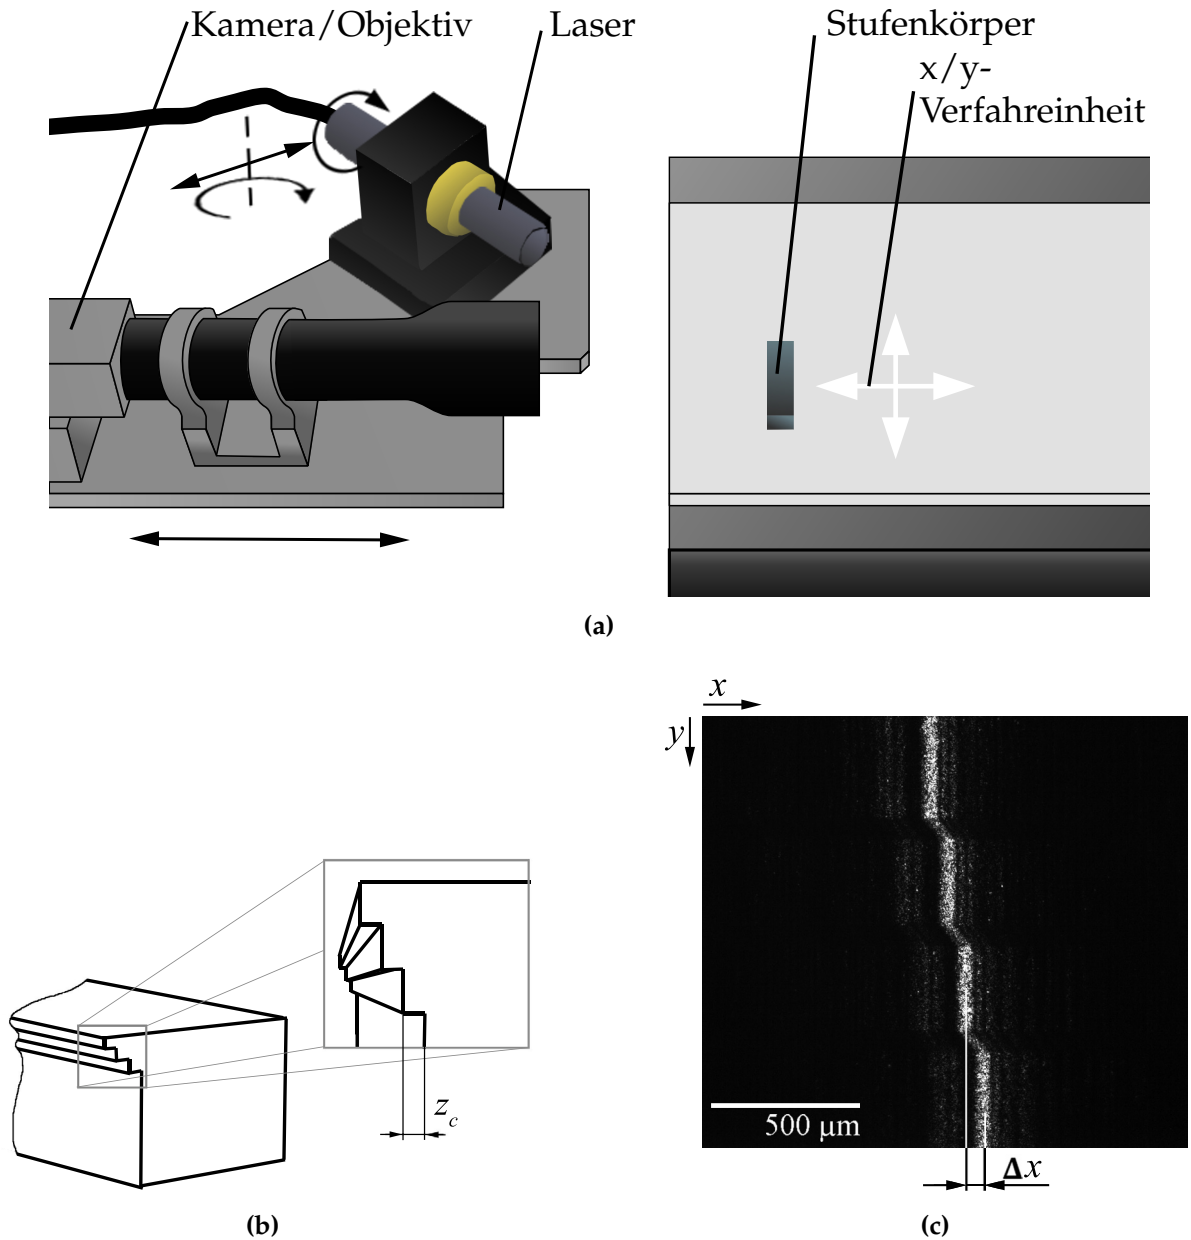


Abbildung 3.6: Kalibrierung des Überwachungssystems auf dem Messtisch: (a) Kalibrierungsaufbau auf dem Messtisch (Pfeile zeigen die Freiheitsgrade an); (b) Geometrie des Stufenkörpers; (c) Aufnahme des Stufenkörpers mit projizierter Laserlinie.

Feature Image Für die vorliegende Anwendung ist der Zweck des Feature-Image (siehe Abbildung 3.7) absteigende Werte in Richtung der Schnittstellen zwischen Glattschnitt- und Bruchfläche, mit Minima an den unbekanntem Übergängen, zu erzeugen. Durch das iterative Gradientenabstiegsverfahren, welches innerhalb der Aktiven Kontur-Methode genutzt wird, wird die Kontur auf diese Übergänge optimiert. Zunächst wird durch eine Abstandstransformation ein Hintergrundbild erzeugt, dessen Intensitätswerte vom Zentrum der Glattschnittfläche hin zu den Bildrändern ansteigen. Zur Ermittlung des Zentrums werden die Intensitätswerte des Originalbildes entlang der x -Achse projiziert und kumuliert. Die maximale Intensität der kumulierten Projektionslinie wird bestimmt, und diejenigen Werte ausgewählt, deren kumulierter Wert über 90 % dieser Intensität liegen (siehe Abbildung 3.8a). Die Zentrumsordinate wird als Mittelwert der beiden Randwerte des Schwellwerts bestimmt. Durch die Abstandstransformation wird das Bild P_{Ramp} mit einer Intensitätssenne hin zu dieser Koordinate erzeugt. Zur Verstärkung der Kanteninformation wird das normierte Gradientenbild P_{grad} , das mit einer Sobel-Operation des Originalbildes P_{Image} gewonnen wird, subtrahiert. Es entstehen die in

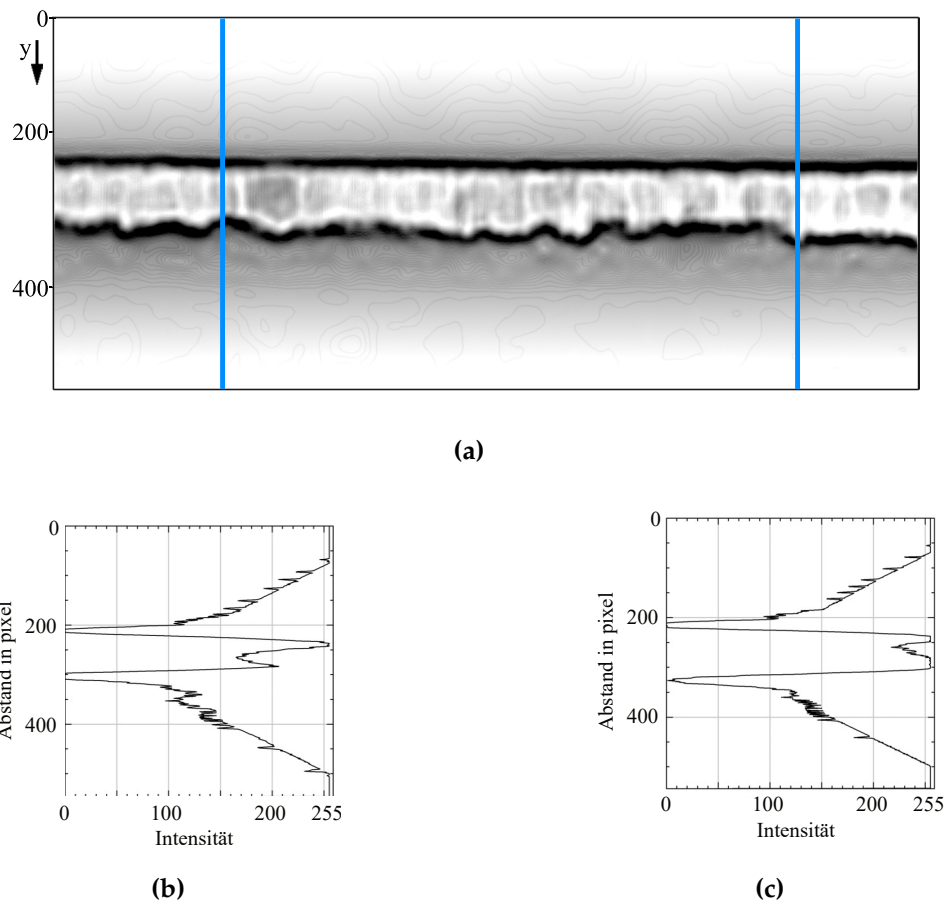


Abbildung 3.7: Feature Image für den Algorithmus der Aktiven Kontur zur Ermittlung der Übergangslinien zwischen Glattschnitt- und Bruchfläche: (a) Feature Image, (b) Intensitätsverlauf der linken vertikalen Linie sowie (c) Intensitätsverlauf der rechten vertikalen Linie.

3.3. Bildverarbeitung zur Überwachung der Bauteilqualität

Abbildung 3.7b-c gezeigten Profile. Daraus ergibt sich das Feature Image und die äußere Energie laut Gleichung 2.3.4

$$E_{\text{Feature}} = \left[\omega_{\kappa} P_{\text{Ramp}} - \omega_{\chi} P_{\text{grad}} \right], \quad (3.3.1)$$

$$E_{\text{ext}} = \left[\omega_{\text{pot}} P_{\text{Image}} + \omega_{\kappa} P_{\text{Ramp}} - \omega_{\chi} P_{\text{grad}} \right], \quad (3.3.2)$$

$$(3.3.3)$$

wobei $\omega_{\text{pot}}, \omega_{\kappa}, \omega_{\chi}$ Gewichtungsfaktoren sind.

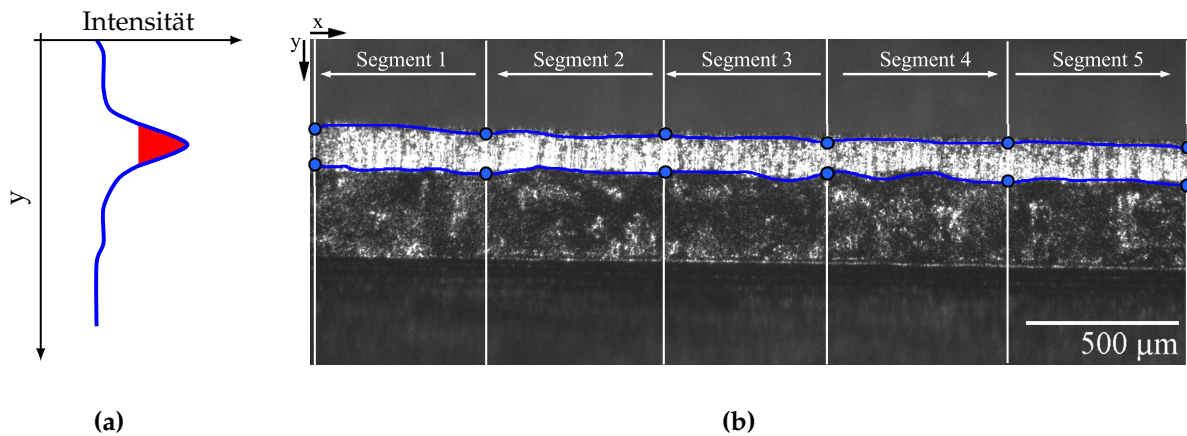


Abbildung 3.8: (a) Selektion der Glattschnittfläche mit normierter kumulativer Intensität entlang der x -Achse zur Erstellung des Feature-Images. Die rote Fläche überschreitet einen Schwellenwert und kennzeichnet die Zeilen, die ausgewählt werden. (b) Segmente für die Initialkontur. Jedes Segment führt eine kumulative Projektion der Intensität entlang seiner Länge (in Pfeilrichtung) durch, wie in Bild (a) zu sehen. Der Abstand der y -Koordinaten, die unter y_{height} liegen, werden ausgewählt und als blaue Punkte dargestellt. Die Anfangskonturen (blaue Kurven) werden auf der Grundlage der blauen Punkte berechnet.

Initialkontur Die Glattschnittfläche unterteilt das Bild horizontal, daher ist eine geschlossene Kontur nicht erforderlich. Mit zwei offenen Konturen kann sowohl der Übergang zwischen Einzug- und Glattschnittfläche als auch der Übergang zwischen Glattschnitt- und Bruchfläche ermittelt werden. Aktive Konturen hängen stark von der Initialkontur und dem Verhältnis der Gewichte $\omega_{\text{pot}}, \omega_{\zeta}, \omega_{\eta}, \omega_{\kappa}, \omega_{\chi}$ ab. Mit einer Kontur zu beginnen, die nahe an der Segmentierung liegt, ist mit Blick auf die Verarbeitungszeit vorteilhaft. Die Bestimmung der Initialkontur wird ebenfalls als automatisiert iterativer Prozess durchgeführt.

Zunächst wird ein Schwellenwert y_{height} festgelegt. Dieser dient als Schätzwert für die Glattschnitthöhe und kann zumeist direkt aus der Bauteilzeichnung übernommen werden. In einem ersten Schritt wird das Originalbild entlang der x -Achse in gleiche Flächen-segmente unterteilt (siehe Abbildung 3.8b). Für jedes Segment wird eine kumulative Intensitätsprojektion innerhalb seiner Länge durchgeführt, siehe Abbildung 3.8a. Für jedes Segment werden die y -Koordinaten mit einem Intensitätsniveau über einem bestimmten Schwellenwert ausgewählt. Der maximale Abstand zwischen diesen y -Koordinaten wird berechnet und mit dem Pixelabstand, der Vergrößerung und dem Anstellwinkel p, M, γ wird ein Vergleichswert berechnet. Liegt der Vergleichswert unter y_{height} , werden diese Randpunkte ausgewählt. Ist der Vergleichswert größer als y_{height} , wird der Schwellenwert erhöht, bis die erste Bedingung erfüllt ist. Mit den Randpunkten aller Bereiche werden zwei Kurven berechnet: eine für die obere und eine für die untere Kontur. Durch die strukturierte Oberfläche erweist sich eine Initialkontur innerhalb der Glattschnittfläche im Vergleich zu einer innerhalb der unregelmäßigen Bruchfläche als vorteilhaft.

Abbildung 3.9 zeigt die Ergebnisse der Bildverarbeitung. Die Ausgangskontur wird als blaue Linien und das Ergebnis der Segmentierung als rote Linien dargestellt. Die Glattschnitthöhe kann in Abhängigkeit von Pixelabstand, Vergrößerung und Kippwinkel p, M, γ aus dem Abstand der Linien berechnet werden.

3.3.2 Bildverarbeitung für das Lichtschnittverfahren

Die Lichtschnittaufnahme (Abbildung 3.10a) zeigt die auf die Schnittfläche projizierte Laserlinie, im Koordinatensystem des CMOS-Sensors. Die Aufnahme ist überwiegend dunkel und nur die Laserlinie erscheint hell. Ziel ist es, den Verlauf der Laserlinie automatisiert zu berechnen.

Zunächst wird die Aufnahme mit einem Gauß-Filter geglättet und mit einer Region of Interest (ROI) der Bildbereich, der die Laserlinie enthält, ausgewählt. Hierzu wird eine Schwellenwertmethode genutzt, die alle Pixel unterhalb eines gewissen Intensitätswerts auf den Wert Null setzt. Beruhend auf dieser ROI wird der Schwerpunkt der Laserlinie (COM-Algorithmus) zeilenweise ermittelt, siehe Abbildung 3.10b. Dies ist möglich, da vom Lasermodul eine Linie mit einem definiertem Profil ausgesendet wird. Zur Optimierung der Verarbeitungsgeschwindigkeit wird eine 5-Punkte-Nachbarschaft um das Maximum verwendet. Einzelheiten finden sich in Fisher et al. 2001 (Fisher et al. 2001).


Die Schwerpunktkoordinaten im Bildraum x_{δ}, y_{δ} werden in den Objektraum mit

$$x_W = x_{\delta} \cdot \frac{p}{M} + r, \quad (3.3.4)$$


$$y_W = y_{\delta} \cdot \frac{p}{M \cdot \cos(\gamma)}, \quad (3.3.5)$$

$$z_W = x_{\delta} \cdot \frac{p}{M \cdot \tan(\varphi)} + y_{\delta} \cdot \sin(\gamma) \quad (3.3.6)$$


3.3. Bildverarbeitung zur Überwachung der Bauteilqualität




(a) Stahl



(b) Kupfer



(c) Segmentierung Stahl



(d) Segmentierung Kupfer

Abbildung 3.9: Bildaufnahmen des Überwachungssystems und Segmentierung der Glattschnittfläche durch den entwickelten Algorithmus aus dem Produktionsprozess für zwei unterschiedlicher Materialien; Initialkontur (blaue Linie), Segmentierungsergebnis (rote Linie).

projiziert. Dabei sind x_W, y_W, z_W die Weltkoordinaten der abgetasteten Oberflächenpunkte und r die Wegstrecke zwischen den Aufnahmen, die vom Material oder der Verfahreinheit zurückgelegt wird. Mehrere Bilder fügen sich zu einem Scan der Schnittfläche zusammen, wodurch die dreidimensionalen Kenngrößen, wie der Bruchwinkel β , gemessen werden können.




Abbildung 3.10: Lichtschnittaufnahme aus dem Produktionsprozess (a) projizierte Laserlinie auf eine Schnittfläche (b) ermittelter Schwerpunkt der Laserlinie durch den beschriebenen Algorithmus.

3.4 Verifizierung des Überwachungssystems

Um das Überwachungssystem zu verifizieren, werden mehrere Tests durchgeführt und deren Ergebnisse mit bekannten Werten abgeglichen. Die Verifizierung der 2D-Bildverarbeitung erfolgt anhand von Aufnahmen, die im Fertigungsprozess vom Überwachungssystem aufgenommen und vom entwickelten Algorithmus verarbeitet wurden. Die Fertigungsparameter können der Tabelle 3.1 entnommen werden. Der Test der Lichtschnittdaten findet auf einem Messtisch statt. Für die Erfassung der tatsächlichen Werte wird das konfokale Mikroskop verwendet, siehe Anhang, Tabelle A.3.

3.4.1 Verifizierung der Bildaufnahmen

Jeweils drei Bauteile aus Stahl und Kupfer wurden hergestellt und mit dem Überwachungssystem erfasst, siehe Abbildung 3.9. Diese Bauteile wurden dem Produktionsprozess entnommen und mit dem konfokalen Mikroskop vermessen. Aufgrund der fehlenden Definition der Schnittflächenparameter in der Flächenansicht existiert kein eindeutiges Merkmal für einen Abgleich. Trotz vorhandener menschlicher Heuristiken

wird ein manueller Punkt-zu-Punkt-Vergleich der Glattschnitthöhen – zwischen den Mikroskopdaten und den Daten aus dem entwickelten Algorithmus – als Näherung verwendet.

Für jedes Bauteil werden drei Positionen analysiert. Besonders markante Stellen an der Schnittfläche, wie Erhöhungen oder Absenkungen im Übergang zwischen Glattschnitt und Bruchfläche, werden aus Zuordnungsgründen ausgewählt. Die Einstellungen für die Bildverarbeitung können Tabelle 3.2 entnommen werden. Die Initialkontur wird aus 20 Bildsegmenten berechnet. Die maximal zulässigen Iterationen wurden auf 80 und die Konvergenzgrenze auf $1 \cdot 10^{-4}$ festgelegt.

Die Ergebnisse der Verifizierung sind in Tabelle 3.3 dargestellt. Die Daten zeigen eine gute Genauigkeit mit einer Abweichungsspanne von 4,28 % bis –2,70 % und einer mittleren Abweichung von 1,43 % (2,2 μm) gegenüber den Daten des Mikroskops. Diese Werte liegen innerhalb der gewünschten Genauigkeit von $\pm 5 \mu\text{m}$. Die Verarbeitungszeit pro Bild beträgt 40 Sekunden bis 60 Sekunden.

3.4.2 Verifizierung des Lichtschnittverfahrens

Zur Überprüfung des Lichtschnittverfahrens werden drei Schnittflächen aus Stahl ausgewählt. Zur eindeutigen Beurteilung werden Referenzmarken in Form von Kerben angebracht. Die Datenaufzeichnung erfolgt auf dem Messtisch. Hierzu werden die Schnittflächen auf einer motorisierten Verfahreinheit aufgebracht. Die Industriekamera und der Schrittgeber der Verfahreinheit, welcher als Auslöser der Aufnahmen dient, werden verbunden. Nachfolgend werden 200 Bilder aufgenommen und gespeichert. Zwischen jeder Aufnahme verfährt das Bauteil $r = 5 \mu\text{m}$ in Richtung der x -Achse; es entsteht ein Flächenscan. Die Aufnahmen werden durch den entwickelten Algorithmus verarbeitet und die Punktwolke wird berechnet. Die Verarbeitung aller 200 Bilder dauerte etwa 20 Sekunden. Für die Referenzmessung werden die gekerbten Schnittflächen mit dem konfokalen Mikroskop aufgenommen. Die dreidimensionale Messtechnik ermittelt die Topologie des Messobjekts und die gemessene Oberfläche kann direkt exportiert werden.

Für den Vergleich der Daten werden die exportierten Oberflächen und die Punktwolke aus dem Lichtschnittverfahren in die Software CloudCompare (CloudCompare 2019) importiert. Zunächst wird eine manuelle Ausrichtung durch die Auswahl von Punktpaaren durchgeführt. Danach erfolgt eine automatische Registrierung mit dem iterativen Closest-Point-Algorithmus. Nachfolgend wird der Abstand zwischen Oberfläche und Punktwolke berechnet. Um einen Quervergleich durchzuführen, wird das gleiche Vorgehen in der kostenlosen Version von GOM-Inspect (Carl Zeiss GOM Metrology GmbH 2019) durchgeführt. Durch die unterschiedlichen Implementierungen der Verarbeitungsschritte in den Programmen können sich Abweichungen ergeben.

Die mittlere Abweichung und die Standabweichung des Abstands zwischen Punktwolke und Oberfläche für die drei Bauteile ist in Tabelle 3.4 zu sehen. Die visuelle Ausgabe der Software für den Oberflächen-Punktwolken-Abstand für Bauteil 1 ist in Abbildung 3.11 zu sehen. Beide Softwareprodukte liefern vergleichbare Ergebnisse. Die

Tabelle 3.1: Fertigungsparameter an der Bihler GRM-NC

Fertigungs- geschwindigkeit	250 Hub pro Minute
Banddicke s	0,5 mm
Bandmaterial	X10CrNi18-10 CuSn6
Zugfestigkeit R_m	1700 MPa 670 MPa
Beölung	keine
Schneidspalt	0,025 mm (5%)
Schneidstempelmaterial	pulvermetallurgischer Werkzeugstahl
Schneidgeometrie	5 mm \times 5 mm
Schneidkantenradius	20 μ m
Niederhalterkraft	23,6 kN

Tabelle 3.2: Gewichtungsfaktoren für die Bildverarbeitung

Übergang	ω_ζ	ω_η	ω_κ	ω_χ	ω_{pot}
Einzug/Glattschnitt	0,15	0,8	1,5	1,0	1,0
Glattschnitt/Bruch	0,01	0,18	1,5	1,0	1,0

mittlere Abweichung der durch die Bildverarbeitung erzeugten Daten liegt unterhalb von 2 μ m bei einer Standardabweichung von 10 μ m. Die Kerben sind in allen Daten deutlich sichtbar. Die größten Abweichungen finden sich an den stark verformten Graten und den starken Oberflächenveränderungen im Bereich der Kerben. Hierdurch entstehen Veränderungen im Reflexionsverhalten und starke Singularitäten in den Lichtschnittaufnahmen, die zu Artefakten führen. Abweichend vom Überwachungssystem korrigiert das konfokale Mikroskop dieses Verhalten automatisch und erzeugt in diesen Bereichen bereinigte Daten. Zusätzlich konnten einige Geometrien aufgrund von Abschattungen infolge des Triangulationswinkels nicht aufgenommen werden. Für vergleichbare Ergebnisse werden diese Daten daher ausgeschlossen. Die Ergebnisse zeigen, dass die gewünschte Genauigkeit von $\pm 5 \mu$ m nicht erreicht wurde. Allerdings sind alle Abweichungen in einem vergleichbaren Bereich verteilt. Hieraus zeigt sich ein hohes Vertrauen in die ermittelten Daten.


Tabelle 3.3: Vergleich der ermittelten Glattschnitthöhe zwischen Überwachungssystem und Mikroskop. Die Mikroskopdaten stellen die Vergleichswerte dar.

Bauteil	Überwachungssystem in μm	Mikroskop in μm	Abweichung in μm (%)
Stahl 1	151,678	155,890	-4,212 (-2,70)
	133,234	130,545	+2,689 (+1,02)
	138,097	139,541	+1,444 (+0,99)
Stahl 2	138,852	133,148	+5,704 (+4,28)
	133,560	134,507	-0,947 (-0,70)
	154,533	151,391	+3,142 (+2,08)
Stahl 3	136,259	134,156	+1,752 (+1,30)
	161,619	160,030	+1,289 (+0,81)
	135,242	131,534	+3,708 (+2,82)
Kupfer 1	194,982	193,002	+1,980 (+1,03)
	205,210	203,003	+2,207 (+1,09)
	176,508	175,883	+0,625 (+0,35)
Kupfer 2	170,842	170,067	+0,775 (+0,46)
	173,656	174,101	-0,445 (-0,26)
	171,291	173,201	-1,910 (-1,10)
Kupfer 3	175,270	173,260	+2,010 (+1,16)
	146,591	144,894	+1,697 (+1,17)
	189,461	192,739	-3,278 (-1,70)
Mittelwert			+2,232 (+1,43)


3.4.3 Spezifikation des Überwachungssystems

In der beschriebenen Konfiguration ist das System in der Lage, die Glattschnitthöhe bei Blechdicken von 0,5 mm bis 1 mm über eine Sichtfeldbreite von 3 mm mit einer Genauigkeit von $\pm 5 \mu\text{m}$ zu messen. Die Schärfentiefe beträgt $80 \mu\text{m}$, was einen maximalen Bruchwinkel von $\beta = 30^\circ$ ermöglicht. Ferner ist das System in der Lage, 3D-Daten mit einer Genauigkeit von $\pm 10 \mu\text{m}$ ($\Delta\beta = \pm 2,3^\circ$) zu erzeugen.


Theoretisch ist die Aufnahmezeit der Kamera, die bei 170 Bildern pro Sekunde liegt, erreichbar. Im Überwachungssystem ist der begrenzende Parameter die Belichtungszeit für die Lichtschnittaufnahmen. Bei den untersuchten Materialien wird die Belichtungszeit 6,7 ms festgelegt, woraus eine Aufnahmegeschwindigkeit von 150 fps folgt. Eine Datenerfassung bei einer Fertigungsgeschwindigkeit von 250 Hub pro Minute ist daher problemlos möglich. Zur Datenübertragung verfügt die Kamera über einen Ringspeicher.




(a)



(b)



(c)



(d)

Abbildung 3.11: Verifizierung der Lichtschnittdaten mit Mikroskopdaten für Bauteil 1 mit CloudCompare. Der Pfeil zeigt die handgefertigte Kerbe zur eindeutigen Zuordnung. (a) Mikroskopiebild, (b) exportierte Oberfläche aus den Mikroskopdaten, (c) ausgerichtete Punktwolke aus den Lichtschnittdaten (rot-gelb), ausgerichtet auf der Oberfläche b) (grün), (d) Verteilung der Abstandsmaße zwischen exportierter Oberfläche und Punktwolke.

Tabelle 3.4: Vergleich der Referenzoberfläche mit der erstellten Punktwolke in μm

	Mittelwert und Standardabweichung (CloudCompare)	Mittelwert und Standardabweichung (GOM-Inspect)
Bauteil 1	$1,0 \pm 5,0$	$4,0 \pm 3,1$
Bauteil 2	$2,0 \pm 9,2$	$1,9 \pm 3,1$
Bauteil 3	$0,2 \pm 15,3$	$0,2 \pm 12,9$
Mittelwert	$1,1 \pm 9,8$	$2,0 \pm 6,4$

Falls die Verarbeitungseinheit die Aufnahmen nicht sofort verarbeiten kann, werden diese im Ringspeicher abgelegt und sequenziell vom Algorithmus analysiert.

Die Bildverarbeitung mit Aktiven Konturen benötigt 40 Sekunden bis 60 Sekunden. Daher kann momentan nicht jede gefertigte Schnittfläche im Prozess vermessen werden. Losgelöst vom Fertigungsprozess ist dies möglich. Zusätzlich ist die entwickelte Bildverarbeitung nicht auf eine minimale Verarbeitungszeit optimiert, sondern als Konzept zu verstehen. Durch Optimierung und Parallelisierung des Codes könnte eine Segmentierung in Echtzeit erreicht werden. Außerdem ist eine Leistungssteigerung durch die Umstellung der Implementierung von Python auf C++ zu erwarten.

3.5 Fallstudie: Nutzen in der Produktion

Die Möglichkeiten des Überwachungssystems lassen sich anhand einer Fallstudie veranschaulichen. Während eines Materialtests, bei dem Ausbrüche an der Schneidstempelkante auftraten, zeichnete das Überwachungssystem 17.000 Schnittflächen auf. Dies ist ein Novum, da es sich um die ersten kontinuierlichen Daten der Schnittfläche innerhalb eines Prozesses handelt. Die genannten Fertigungsparameter wurden dabei beibehalten. Die Schneidstempelkanten wurden für die Verschleißbestimmung zu festgelegten Intervallen (5000 Hub, 10.000 Hub, 25.000 Hub) mit dem konfokalen Mikroskop vermessen. Hierzu musste jeweils eine Demontage und Montage der Schneidstempel erfolgen. Abbildung 3.12 zeigt die mit dem Mikroskop aufgenommenen Zustände der Schneidstempelkante. Nach 5000 Hub und 10.000 Hub wird eine voll funktionsfähige Schneidkante festgestellt. Nach 25.000 Hub hingegen ist die Schneidkante beschädigt. Anhand dieser Daten lässt sich innerhalb eines Intervalls von 15.000 Hub der Schadenzeitpunkt nicht näher spezifizieren.

Allerdings ist durch die Mikroskopaufnahmen der Schadensort am Schneidstempels bekannt, dieser besitzt auch im Schneidwerkzeug eine eindeutige Position. Diese Position kann auf die Aufnahmen übertragen werden und erscheint auf der linken Seite des Bildes.

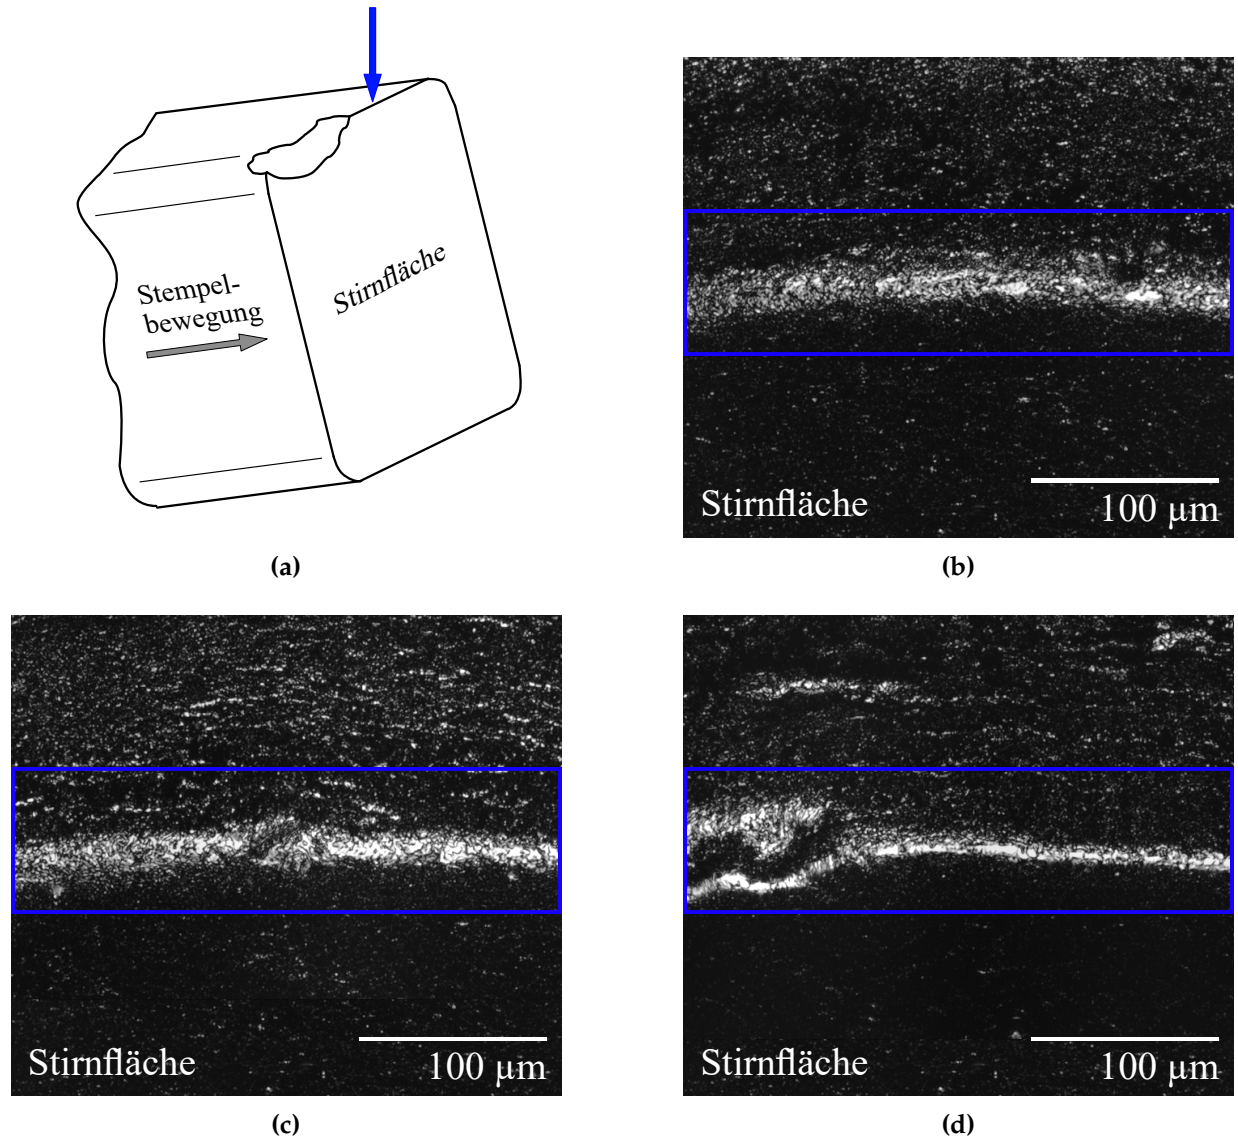


Abbildung 3.12: Schneidkantenmessung am Schneidstempel während der Versuchsreihe durch das konfokale Mikroskop. Innerhalb des blauen Bereichs ist die Schneidkante zu sehen. (a) Aufnahmeposition und Blickrichtung (blauer Pfeil) des konfokalen Mikroskops, (b) funktionsfähige Schneidkante bei 5000 Hub, (c) funktionsfähige Schneidkante bei 10.000 Hub, (d) ausgebrochene Schneidkante bei 25.000 Hub.

3.5. Fallstudie: Nutzen in der Produktion

Durch manuelle Sichtung der Aufnahmen kann der Zeitpunkt des Schadens eingegrenzt werden. Zunächst wird dieser Zeitpunkt nach 13.500 Hub lokalisiert. Abbildung 3.13 zeigt eine Auswahl von Aufnahmen aus dem Überwachungssystem mit markiertem Fehlerbereich.




Abbildung 3.13: Entwicklung der Schnittfläche aufgrund von Verschleiß durch Aufnahmen aus dem Überwachungssystem. Der hervorgehobene Bereich zeigt die Position und Entwicklung des Stempelverschleißes: (a) Schnittfläche bei 10.000 Hub, (b) Schnittfläche bei 13.000 Hub, (c) Schnittfläche bei 13.500 Hub, (d) Schnittfläche bei 25.000 Hub.

Zusätzlich werden alle Aufnahmen vom entwickelten Algorithmus verarbeitet und die Glattschnitthöhe zur jeweiligen Hubzahl bestimmt. Um zusätzliche Informationen über die Entwicklung des Verschleißes zu erhalten, erfolgt ein Vergleich der Glattschnitthöhen aus zwei Bildbereichen pro Aufnahme. Bei diesen Bereichen handelt es sich um den bekannten Fehlerbereich (linkes Ende des Bildes) und einen Bereich mit voll funktionsfähige Schnittfläche (rechtes Ende des Bildes). Um die Vorschubtoleranz des Stanzbiegeautomaten von $\pm 0,1$ mm zu berücksichtigen, werden die Glattschnitthöhen

über eine Länge von 0,2 mm in x -Richtung gemittelt. Das Ergebnis für die untersuchten Schnittflächen im Intervall von 7000 Hub bis 25.000 Hub ist in Abbildung 3.14 dargestellt.

Obwohl die Schneidkante des Stempels auf Basis der Daten des konfokalen Mikroskops bei 10.000 Hub als voll funktionsfähig angesehen wird, ist in dieser Auswertung ersichtlich, dass die Glattschnitthöhe schon ab der Hubzahl 7000 abnimmt. Die Glattschnitthöhe im Bereich der Schadstelle nimmt dabei stärker ab und unterliegt insgesamt größeren Schwankungen, während die Glattschnitthöhe im rechten Bildbereich, trotz der durch Material- und Prozesstoleranzen verursachten Schwankungen, auf einem konstanten Niveau verweilt. Basierend auf diesen Daten beginnt die Entwicklung des Schadens bei etwa 7000 Hub.




Abbildung 3.14: Entwicklung der Glattschnitthöhe über die Lebensdauer des Schneidstempels. Vergleich des linken Bildbereichs (schadhafter Bereich) mit dem rechten Bildbereich (funktionsfähig). Der graue Wiederanstieg zeigt die Artefakte, die durch mehrere Schnittflächen infolge des Stempelausbruchs entstehen.

Der Versagenszeitpunkt wird ebenfalls bei 13.500 Hub erreicht. Die folgende Wiederannäherung (grau) an die Kurve der funktionsfähigen Schneidkante ist irreführend. Die erzeugte Schnittfläche eines verschlissenen Schneidstempels erzeugt immer noch einzelne Abschnitte der Glattschnittfläche, die vom Algorithmus erkannt werden. Diese Abschnitte sind zum eigentlichen Glattschnittanteil verschoben oder nicht durchgängig und entsprechen damit nicht den Qualitätsanforderungen bzw. der Definition der Schnittflächenparameter, auf denen der entwickelte Algorithmus basiert. Daher wird dieser Verlauf nicht berücksichtigt.

Im Vergleich zu Intervallprüfungen der Schneidstempel erlaubt das Überwachungssystem eine frühere Erkennung des Schadens. Im Sinne einer vorausschauenden Instandhaltung zeigt diese Fallstudie vielversprechende Resultate. Die Ergebnisse aus dem

Überwachungssystem könnten für eine bessere Planungssicherheit und die Folgeprozesse genutzt werden. Eine schnellere Bildverarbeitung würde es ermöglichen, die Grafik während der Produktion zu analysieren.

3.6 Zusammenfassung des Überwachungssystems

Das entwickelte kombinierte optische Überwachungssystem und die entwickelte Bildverarbeitung ermöglichen die automatisierte Bestimmung der Glattschnitthöhe für eine Schneidstempelkante. Im Banddickenbereich von 0,5 mm bis 1 mm werden sowohl Bildaufnahmen als auch Lichtschnittaufnahmen aufgezeichnet. Im Gegensatz zu aktuellen Methoden, bei denen Bauteile aus dem Produktionsprozess entnommen werden müssen, erfasst das Überwachungssystem die Schnittflächen innerhalb des Produktionsprozesses bei einer Geschwindigkeit von 250 Hub pro Minute. Die Aufnahmen erfolgen nach dem Schneidwerkzeug mit einem Versatz von 42 Hub. Die entwickelte Bildverarbeitung benötigt eine Verarbeitungszeit von 40 Sekunden bis 60 Sekunden und ist deshalb noch nicht im Fertigungstakt (240 ms) möglich. Die Glattschnitthöhe kann mit einer Genauigkeit von $\pm 5 \mu\text{m}$ und Winkel mit einer Genauigkeit von $\pm 2,3^\circ$ vermessen werden.

Im Rahmen der ersten Fallstudie konnte gezeigt werden, wie dieses System zur vorausschauenden Instandhaltung eingesetzt werden kann. Zudem zeigt sich aber, dass der entwickelte Algorithmus bei Schnittflächen mit mehreren oder versetzt auftretenden Schnittflächen keine exakten Ergebnisse liefert.

Zusätzlich wurde das Lichtschnittverfahren zur dreidimensionalen Vermessung durch das Überwachungssystem auf dem Messtisch verifiziert. Einzelaufnahmen mit dem Lichtschnittfahren sind im Prozess bereits möglich. Während des Materialvorschubs sind Oberflächenscans im Prozess denkbar. Hierzu muss das Überwachungssystem mit dem Vorschub synchronisiert werden.

Es nun möglich, Daten für die Qualitätsbestimmung der gefertigten Bauteile über die Lebensdauer des Schneidstempels im Prozess zu generieren. Hierbei beeinflusst der externe Aufbau des Überwachungssystems das Schneidwerkzeug nicht und kann daher auch für bestehende Werkzeuge angewendet werden. Falls mehrere Schneidstempel überwacht werden sollen, muss das Überwachungssystem mehrfach vorhanden sein oder durch Verfahreinheiten erweitert werden. Eine flexible Anpassung an unterschiedliche Schneidwerkzeuge ist durch die gewählte Bauweise möglich.

Im nächsten Schritt soll die Bildverarbeitung mittels neuronaler Netzwerke optimiert werden.

Schnittflächenanalyse durch neuronale Netzwerke

Die Untersuchungen im vorhergehenden Kapitel haben gezeigt, dass eine durchgehende Datenaufzeichnung im Fertigungsprozess durch das Überwachungssystem anhand von Bildaufnahmen möglich ist. Der entwickelte Algorithmus segmentiert die in der VDI-Richtlinie 2906 (VDI 2906 Blatt 2 1994) definierte Glattschnittfläche zuverlässig. Die Bildaufnahmen aus dem Fertigungsprozess zeigen allerdings Charakteristiken, die nicht in der Richtlinie berücksichtigt werden. Da der entwickelte Algorithmus auf dieser Richtlinie basiert, ist eine Funktionsfähigkeit der Segmentierung nicht gewährleistet. Die Ausbildung eines versetzten Glattschnittanteils oder mehrerer Teilflächen sind einige dieser Charakteristiken. In der Bildaufnahme erscheinen diese im Hinblick auf Form und Position willkürlich und resultieren aus den Fertigungsparametern und deren Streuungen. Die Abbildung dieser höheren Komplexität durch einen regelbasierten Algorithmus erscheint nicht sinnvoll.

Künstliche neuronale Netzwerke zur Bildverarbeitung, beispielsweise in medizinischen Anwendungen, haben gezeigt, dass sie diese komplexen Zusammenhänge erlernen und abbilden können. Zusätzlich wird in vielen Fällen eine Echtzeitfähigkeit erreicht (Minaee et al. 2022), welche durch den in Kapitel 3 entwickelten Algorithmus aktuell nicht möglich ist. Auch in industriellen Anwendungen werden neuronale Netzwerke verstärkt untersucht. Wolfschläger et al. (Wolfschläger et al. 2022) zeigten die Anwendung neuronaler Netze für die Segmentierung von Bauteilaufnahmen aus dem Feinschneidprozess. Hierbei wird der Rissanteil der Schnittfläche automatisch segmentiert. Die Charakteristiken dieser Aufnahmen unterscheiden sich allerdings sehr zu den Aufnahmen aus dem Überwachungssystem. Zum einen wird durch die vielfach höhere Materialdicke beim Feinschneiden eine abweichende Bildauflösung und Vergrößerung verwendet. Detailreiche Strukturen im Glattschnittanteil werden daher geringer aufgelöst als durch das Überwachungssystem. Zum anderen werden die Aufnahmen für die Trainingsdaten vom Prozess getrennt vor einem homogenen Hintergrund aufgenommen (Trauth et al. 2018). Die Aufnahmen des Überwachungssystems hingegen entstehen unter industriennahen Bedingungen direkt im Fertigungsprozess und unterliegen einer Vielzahl von Schwankungen durch Ölfilme oder Abschattungen von Peripheriegeräten. Diese beeinflussen die Aufnahmen und führen zu Inhomogenitäten in diesen. Eine Übertragbarkeit mit Blick auf die geforderte Genauigkeit unter Berücksichtigung der unterschiedlichen Aufnahmen wird daher infrage gestellt.

Im Folgenden wird die Anwendung von neuronalen Netzwerken zur Segmentierung der Glattschnittfläche untersucht. Die Datenbasis wird durch Aufnahmen aus dem Über-

wachungssystem geschaffen. Zunächst wird in einer Expertenumfrage das industrielle Verständnis der Schnittflächenkenngößen erfragt.

4.1 Expertenumfrage

In einer nicht repräsentativen Umfrage wurden 12 Branchenexperten mehrere Aufnahmen von Schnittflächen vorgelegt. Die Aufgabe bestand darin, alle Bereiche einzuzeichnen, die sie nach ihrer Expertise der Glattschnittfläche zuordnen würden. Hierbei wurden keine weiteren Vorgaben oder Restriktionen in der Aufgabe gegeben. Exemplarisch werden die Ergebnisse für die Übergangslinie zwischen Glattschnitt- und Bruchfläche in Abbildung 4.1 dargestellt. Die Streuung der Linien zeigt, dass keine allgemeine Richtlinie angewendet wurde. Die Ergebnisse legen daher nahe, dass die persönliche Definition der Glattschnittfläche stark vom Bauteil und der Anwendung abhängt und nicht einheitlich ist. Aus den vorhandenen Übereinstimmungen kann jedoch eine Erweiterung der Definition des Glattschnittanteils abgeleitet werden. Zusätzlich zu den in *VDI 2906 Blatt 2* genannten Merkmalen ist die Glattschnittfläche

- in den Aufnahmen hell erleuchtet,
- fluktuierend über die Bildlänge,
- mit vertikalen Rillen strukturiert,
- mit Einrissen (Löchern) versehen,
- mitunter durch mehrere geteilte Teilflächen gekennzeichnet,
- variabel über die Lebensdauer des Schneidstempels.

Bezogen auf die Bauteilqualität werden Bauteile ohne oder mit nur einer kleinen Anzahl an Einrissen und einer durchgehenden Glattschnittfläche höher bewertet.

4.2 Datenvorverarbeitung

Die Daten der Fallstudie aus Kapitel 3.5 werden erneut verwendet. Diese Aufnahmen sind besonders geeignet, da in ihnen neben den Fluktuationen der Fertigungsparameter auch die Lebensdauer eines Schneidstempels codiert ist. In den Aufnahmen sind daher viele der resultierenden Charakteristika aufgezeichnet.

Der Trainingsprozess benötigt tatsächliche Werte zum Abgleich der Prognosen. Ein korrespondierendes Bild der tatsächlichen Segmentierung muss erstellt werden. Dieses Bild wird im Folgenden als *Maske* bezeichnet. Die Erstellung der Maske erfolgt manuell. Sie ist die pixelweise Klassifizierung der Aufnahmen in die Klassen *Glattschnittanteil* und *Hintergrund*, die sich an den oben genannten Kriterien orientiert (siehe Abbildung 4.2).

Eine disjunkte Teilmenge der Aufnahmen wird für die Trainings- und Testdaten ausgewählt. Die Auswahl basiert auf der Abbildung des Verschleißprozesses des Schneidstempels. Insgesamt werden 415 Aufnahmen, die sich aus 245 Aufnahmen vor dem






Abbildung 4.1: Ergebnisse der Expertenbefragung. Die Aufgabe bestand darin, die Übergangslinie zwischen der Glattschnitt- und der Bruchfläche einzuzeichnen. Die Streuung der Linien zeigt, dass es keine allgemeine Richtlinie, sondern vielmehr eine anwendungsbezogene Vorgehensweise gibt.

Stempelschaden und 170 Aufnahmen nach dem Stempelschaden zusammensetzen, ausgewählt.



(a) Originalaufnahme



(b) Manuell erstellte *Maske*

Abbildung 4.2: Eigene Definition der Abschnitte der Glattschnittfläche auf Basis der Expertenbefragung: (a) Bildaufnahme aus dem Prozess, (b) manuell segmentierte Glattschnittfläche: Hauptabschnitt (1), Teilabschnitte (2), ausgeschlossene Abschnitte (3). Die römischen Ziffern bezeichnen die verschiedenen Komponenten, die für die metrische Bewertung verwendet werden.

Da alle Bauteile – und damit alle Aufnahmen – mit demselben Schneidwerkzeug und denselben Fertigungsparametern hergestellt wurden, besteht ein hohes Risiko der Überanpassung an Merkmale aus diesem Prozess. Idealerweise sollte die Segmentierung jedoch ohne erneutes Training auf Aufnahmen aus verschiedenen Fertigungsprozessen anwendbar sein. Durch eine künstliche Datenerweiterung kann eine solche Überanpassung vermieden werden. Jede Aufnahme und die dazugehörige Maske werden dupliziert

und mit verschiedenen Operationen modifiziert. Diese bestehen in der Veränderung der Helligkeitswerte, um verschiedene Materialkombinationen darzustellen, in der vertikalen Spiegelung, um die Lage von Rissen oder Defekten zu variieren, und in der Skalierung der Aufnahmen, um verschiedene Materialdicken darzustellen. Für kleinere Materialdicken wurden die Aufnahmen entlang der Höhenachse komprimiert und in ein Bild mit gleichen Hintergrundrauschen eingefügt, um die Dimensionen zu erhalten. Aufnahmen für größere Materialdicken werden mit den Faktoren 1,5 und 3 skaliert und nach dem Zufallsprinzip entlang der Schnittfläche beschnitten. Das gleiche Verhältnis von Pixeln unter- und oberhalb der Glattschnittfläche wird dabei so erhalten, wie es durch Aufnahmen des Überwachungssystems zu erwarten wäre. Die vollständige Struktur der Datenerweiterung ist in Tabelle 4.1 dargestellt. Da jede Erweiterung unterschiedliche Materialeigenschaften simuliert, wird in der Auswertung jede dieser Erweiterungen separat betrachtet, wodurch Rückschlüsse von der Architektur auf bestimmte Strukturen ermöglicht werden.

Durch die Erweiterung vergrößern sich die Daten auf 10.086 Aufnahmen. Die vor der Datenerweiterung erfolgte Aufteilung in Trainings- und Testdaten führt zu folgenden Datenmenge:

- Die Trainingsdaten erweitern sich zu 6052 Trainingsaufnahmen und 2017 Validierungsaufnahmen.
- Die Testdaten erweitern sich zu 2017 Testaufnahmen.

Um die Trainingszeit zu verkürzen, werden schließlich alle Aufnahmen auf eine Auflösung von 256×256 Pixel skaliert. Obwohl eine höhere Auflösung für präzise Messaufgaben besser geeignet ist, kann die Segmentierungsfunktionalität auch mit dieser reduzierten Bildgröße analysiert werden.

Tabelle 4.1: Struktur der Datenerweiterung für die Trainings- und Testdaten. (Die Farben werden für die Bewertungsdiagramme festgelegt.)

Skalierungsfaktor	1,0 (blau)	0,5 (orange)	1,5 (rot)	2,0 (grün)	3,0 (violett)
Erweiterung			heller (brighter)	dunkler (dunkler)	unverändert (plain)
			heller gespiegelt (brighter mirrored)	dunkler gespiegelt (darker mirrored)	unverändert gespiegelt (plain mirrored)

4.3 Modellbildung

In der Modellbildung werden die Hyperparameter des neuronalen Netzwerks untersucht und festgelegt. Das Verhältnis zwischen Hintergrund (engl. background) (BG)

und Vordergrund (engl. foreground) (FG) in der Datenmenge, das die Wahl der Netzarchitektur und der Loss-Funktion beeinflusst, zeigt mit einem Verhältnis von 9 : 1 ein moderates Ungleichgewicht (Fernandez et al. 2018, S. 40), das sich in Anwendungen bis zu 20 : 1 erhöhen kann (Ma et al. 2021).

4.3.1 Ähnlichkeitskoeffizient und Loss-Funktion

Die Bewertung der Prognosegüte soll anhand der oben genannten Kriterien erfolgen. Im Idealfall stimmen die Bewertungsansätze, der Prognosegüte und der Loss-Funktion überein. Durch übereinstimmende Ansätze dieser Funktionen kann das gewünschte Lernverhalten überprüft werden. Dies ist nicht immer umsetzbar, da der Backpropagation-Algorithmus auf differenzierbaren Loss-Funktionen basiert. Zunächst wird eine Bewertungsmöglichkeit der Prognosegüte geschaffen.

Bewertung der Prognosegüte

Zur Bewertung der Prognosegüte des auf neuronalen Netzwerken basierenden Bildverarbeitungsansatzes wird die *Genauigkeit* der vom Netzwerk prognostizierten Schnittfläche mit der tatsächlichen Maske gemessen. Zu diesem Zweck wird ein kombinierter Koeffizient erstellt.

Wie gezeigt wurde, ist die Größe der Glattschnittfläche und insbesondere die Ermittlung der Glattschnitthöhe ein wichtiger Indikator für die Bauteilqualität. Für die Quantifizierung der Glattschnitthöhe muss eine präzise Segmentierung ihrer Grenze/Übergangslinien zwischen den unterschiedlichen Schnittflächenkenngrößen erfolgen. Außerdem sollte eine Gewichtung auf der Grundlage der Größe und der Anzahl der gefundenen Glattschnittflächen ermöglicht werden, die ebenfalls eine hohe Relevanz bei der Bewertung der Bauteilqualität besitzen.

Die Bewertung wird daher in einen regionenbasierten und einen konturbasierten Anteil aufgeteilt. Für den regionenbasierten Anteil wird der *dice similarity coefficient* (DSC)

$$\text{DSC}(G, S) = \frac{2|G \cap S|}{|G| + |S|} \quad (4.3.1)$$

ausgewählt. Hier und im Folgenden stehen G und S für die Glattschnittfläche gemäß der Maske bzw. des Segmentierungsalgorithmus, wobei $|A|$ die Anzahl der Pixel vom Wert 1 in einer Bilduntermenge A bezeichnet. Zu beachten ist, dass $0 \leq \text{DSC}(G, S) \leq 1$ ist und der Maximalwert 1 nur dann erreicht wird, wenn die vorhergesagte Fläche S und die Maskenregion G identisch sind.

Für den konturbasierten Anteil wird die *normalized surface distance* (NSD)

$$\text{NSD}(G, S, \tau) = \frac{|\partial G \cap \partial S^{(\tau)}| + |\partial S \cap \partial G^{(\tau)}|}{|\partial G| + |\partial S|} \quad (4.3.2)$$

gewählt, wobei $\partial G, \partial S$ die Grenzen der Maske und der Segmentierungsfläche (Prognose) bezeichnen und $\partial S^{(\tau)}, \partial G^{(\tau)}$ die Grenzregionen mit der Toleranz τ darstellen, also die Menge der Pixel, deren Abstand von der Grenze kleiner oder gleich τ ist. Man beachte, dass für $\tau = 0$ nur die vorhergesagten Grenzpixel berücksichtigt werden, die mit der Grundwahrheitsgrenze genau übereinstimmen. Ebenfalls unterscheiden höhere Toleranzwerte nicht zwischen einer ungefähren und einer genauen Grenzübereinstimmung.

Der kombinierte Koeffizient

$$\begin{aligned} \text{CM}(G, S, \tau) = & \alpha \text{ DSC}(G, S) + \beta \text{ NSD}(G, S, \tau_1) \\ & + \gamma \text{ NSD}(G, S, \tau_2) \end{aligned} \quad (4.3.3)$$

berücksichtigt sowohl den regionenbasierten DSC als auch den konturbasierten NSD. Durch die Auswahl der Gewichtungsfaktoren α, β, γ und der Toleranzen τ_1, τ_2 priorisiert dieser Koeffizient entweder die Überlappung zwischen der prognostizierten Fläche und der Maskenfläche (für höhere Werte von α) oder die Genauigkeit der prognostizierten Kontur der Fläche. Im Folgenden werden die Toleranzen $\tau_1 = 0, \tau_2 = 1$ gewählt. Hierdurch wird sowohl eine positive Bewertung für die prognostizierte Kontur nahe der tatsächlichen Kontur als auch eine zusätzliche Unterscheidung zwischen einer ungefähren und einer exakten Konturübereinstimmung erzeugt. Die Gewichte ermöglichen eine Anpassung der Bewertung an den Anwendungsfall. In der vorliegenden Arbeit wird ein möglichst allgemeingültiger Anwendungsfall fokussiert. Mit den Gewichten $\alpha = 0,5, \beta = 0,45, \gamma = 0,05$ wird somit das gleiche Gewicht auf die mit DSC gemessene Regionenübereinstimmung und die Konturübereinstimmung mittels NSD gelegt.

Der Verlauf des kombinierten Koeffizienten ist in Abbildung 4.3 dargestellt. Die Kurven werden auf Basis der Abbildung 4.3(c) erstellt, wobei Bild 0 den tatsächlichen Wert darstellt und die Erosion und Dilatation dieses Bildes durch die Zahl in der Beschriftung bezeichnet werden.

Der aktuelle kombinierte Koeffizient berücksichtigt die Anzahl der Glattschnittflächen pro Aufnahme nicht, sondern berechnet diese für jede Glattschnittfläche separat. Daher muss die Gesamtglattschnittfläche in Komponenten aufgeteilt werden. Als zugehörig zu einer Komponente werden Pixel gewertet, wenn sie in einer Vierer-Nachbarschaft liegen, siehe Abbildung 4.4b. Ausgehend von einem Pixel muss ein anderer Pixel desselben Wertes durch einen Schritt nach oben, unten, rechts oder links erreichbar sein (Gonzalez et al. 2018). Im Falle von überschneidenden Glattschnittflächen in der prognostizierten Segmentierung und Maske werden diese zu einer Komponente zusammengefasst. Der kombinierte Koeffizient wird dann für jede der gefundenen Komponenten separat berechnet. Anschließend werden die einzelnen Komponenten im Verhältnis zur Fläche der jeweiligen Komponenten gewichtet und aufsummiert, sodass größere Glattschnittflächen einen größeren Einfluss auf den gesamten kombinierten Koeffizient haben als kleinere. Nicht zugeordnete Komponenten werden ignoriert.

Während diese Metrik bereits eine allgemeine Bewertung der Genauigkeit der Prognose ermöglicht, werden einige topologische Informationen (beispielsweise Glattschnittflächen, die entweder fehlen oder neu in die Prognose aufgenommen werden) nicht einbezo-

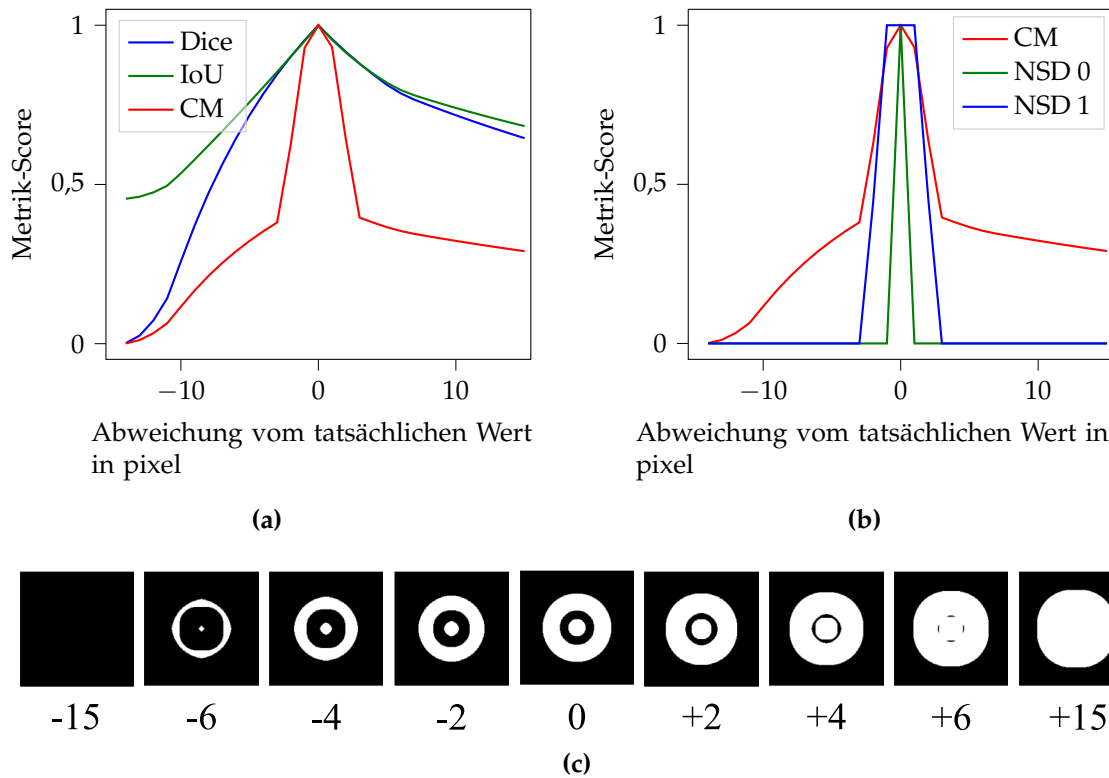


Abbildung 4.3: Analyse der Ähnlichkeitsmaße: Die Diagramme wurden aus den Bildern in (c) generiert, um das Verhalten verschiedener Ähnlichkeitsmaße zu analysieren. (a) DSC, Intersection over Union (IoU), kombinierter Koeffizient (CM); (b) NSD mit $\tau = 0$, NSD mit $\tau = 1$, CM; (c) Bilder der Übersegmentierung und Untersegmentierung, die zur Erstellung der Diagramme verwendet wurden. Bild 0 kennzeichnet die tatsächliche Segmentierung.

gen. Diese Informationen werden jedoch durch die folgenden zusätzlichen Koeffizienten berücksichtigt:

- Anteil s/G der prognostizierten Glattschnittfläche an der Maske,
- Anteil

$$\frac{1}{|C_G|} \sum_{j=1}^{C_G} \frac{1}{|C_S|} \sum_{k=1}^{C_S} \frac{|g_j \cap s_k|}{|g_j|} \quad (4.3.4)$$

der prognostizierten Komponenten, die auf Komponenten der Maske abgebildet werden, wobei C_G und C_S die Gesamtanzahl der Komponenten in Maske und Prognose und g_j, s_k die entsprechende Menge an Pixeln in der Komponente bezeichnen.




Abbildung 4.4: Beispiel einer (a) Vierer-Nachbarschaft, (b) einer Achter-Nachbarschaft und (c) Ermittlung separater Komponenten anhand einer Vierer-Nachbarschaft.

- Verhältnis C_S/C_G der prognostizierten Komponenten im Vergleich zur Maske
- Verhältnis t_S/t_G der prognostizierten Einrisse im Vergleich zur Maske, wobei t_S und t_G die Anzahl an Einrisen in Prognose und Maske sind. Mit

$$\frac{t_S}{t_G} = \begin{cases} 1 & \text{für } t_G = 0 \text{ und } t_S = 0, \\ 0 & \text{für } t_G = 0 \text{ und } t_S > 0. \end{cases} \quad (4.3.5)$$

Hier wird der Begriff *Einriss* als eine Achter-Nachbarschaft definiert, die von Pixeln umgeben ist, die zu einer anderen Klasse gehören, siehe Abbildung 4.4. Diese vier Erweiterungen sind für diese Arbeit gut geeignet, um die verschiedenen Eigenschaften der Prognose auszudrücken. Der Endanwender, der eine Segmentierungsmethode (beispielsweise ein neuronales Netz) für eine bestimmte Aufgabe bewertet, kann sein Vorgehen auf der Grundlage aller oben genannten Kriterien anwendungsbezogen anpassen. Für eine vollautomatische Hyperparameter-Optimierung wäre es jedoch notwendig, die einzelnen Scores zu einer einzigen Metrik zu aggregieren, beispielsweise durch eine gewichtete Summe.

Loss-Funktion

Während des Trainings des neuronalen Netzes bei gegebenen Hyperparametern werden die Parameter des Netzes so verändert, dass eine *Loss-Funktion* über die Datenmenge minimiert wird. Die Auswahl einer geeigneten Loss-Funktion ist daher grundlegend, um eine Übereinstimmung der Prognose des neuronalen Netzes mit der Maske zu erhalten.

In einer vorangegangenen Studie haben Ma et al. (Ma et al. 2021) eine Vielzahl an Loss-

Funktionen für vier Segmentierungsaufgaben verglichen. Für einen Datensatz mit Leber- und Lebertumor-Bildern, der aufgrund des BG:FG-Verhältnisses als ähnlich zu unseren Daten angesehen werden kann, erwies sich eine kombinierte Loss-Funktion mit Dice-Anteil als Segmentierungsaufgaben geeignet. Der *Dice-Loss* ist eine regionenbasierte Loss-Funktion, die die nicht übereinstimmenden Regionen zwischen der Maske und der Prognose ähnlich dem DSC bestraft. Für den allgemeinen Fall von Bildern mit N Pixeln und C verschiedenen Klassen kann der Dice-Loss

$$L_{Dice} = 1 - \frac{2 \sum_{c=1}^C \sum_{i=1}^N g_i^c s_i^c}{\sum_{c=1}^C \sum_{i=1}^N g_i^c + \sum_{c=1}^C \sum_{i=1}^N s_i^c} \quad (4.3.6)$$

definiert werden (Ma et al. 2021; Drozdal et al. 2016). Dabei ist g_i^c der binäre Indikator der Klasse c für Pixel i in der Grundwahrheit und s_i^c das entsprechende Konfidenzniveau des neuronalen Netzes. Bei binärer Ausgabe des Netzes s und ausschließlicher Betrachtung der Klasse der Glattschnittfläche in der Maske g kann der Dice-Loss vereinfacht werden zu

$$L_{Dice} = 1 - \frac{2 \sum_{i=1}^N g_i^c s_i^c}{\sum_{i=1}^N g_i^c + \sum_{i=1}^N s_i^c} = 1 - \frac{2|G \cap S|}{|G| + |S|} = 1 - \text{DSC}(G, S), \quad (4.3.7)$$

wobei DSC den dice similarity coefficient (DSC) gemäß Gleichung 4.3.1 bezeichnet.

Während der *DiceTopK-Loss* in der Studie von Ma et al. (Ma et al. 2021) vielversprechende Ergebnisse zeigte, erfordert die Segmentierung der Glattschnittfläche aufgrund der Bedeutung des Übergangs zwischen Glattschnitt- und Bruchanteil einen anderen Ansatz. Um die Kontur der Glattschnittfläche gegenüber ihrer Flächenverteilung zu betonen, wird der *DiceBD-Loss* (Wu et al. 2016; Ma et al. 2021)

$$L_{DiceBD} = L_{Dice} + L_{BD}, \quad (4.3.8)$$

der den Dice-Loss mit dem *Boundary-Loss*

$$L_{BD} = \sum_{i=1}^N \phi_i s_i \quad (4.3.9)$$

kombiniert, ausgewählt. ϕ_i ist hierbei die Level-Set-Darstellung der Grenze ∂G der Maske, definiert durch

$$\phi_i = \begin{cases} -\text{dist}(i, \partial G) & \text{wenn } i \in G, \\ \text{dist}(i, \partial G) & \text{wenn } i \notin G, \end{cases} \quad (4.3.10)$$

wobei $\text{dist}(i, \partial G)$ der Abstand zwischen einem Pixel i und der Kontur ∂G ist (Kervadec et al. 2018; Ma et al. 2021).

Somit wird ein ähnlicher Aufbau der Terme für die Loss-Funktion und des kombinierten Koeffizienten erreicht. Über die Gewichtungsfaktoren kann anwendungsabhängig einer

der beiden Terme schon während des Trainings priorisiert und anschließend die erreichte Modellgüte mit ähnlicher Priorisierung bewertet werden.

4.3.2 Netzwerkarchitektur

Für die Auswahl einer Architektur werden zunächst bestehende Architekturen analysiert, die im Bereich der medizinischen Bildsegmentierung entwickelt wurden. In diesem Bereich werden häufig monochrome Bilder verwendet, die anhand ihrer Charakteristik ähnlich zu den Aufnahmen aus dem Überwachungssystem erscheinen. Zu Beginn werden bestehende Architekturen ausgewählt, trainiert und deren Prognosegüte bewertet. Anschließend wird die am besten geeignete Architektur optimiert und weiterentwickelt.

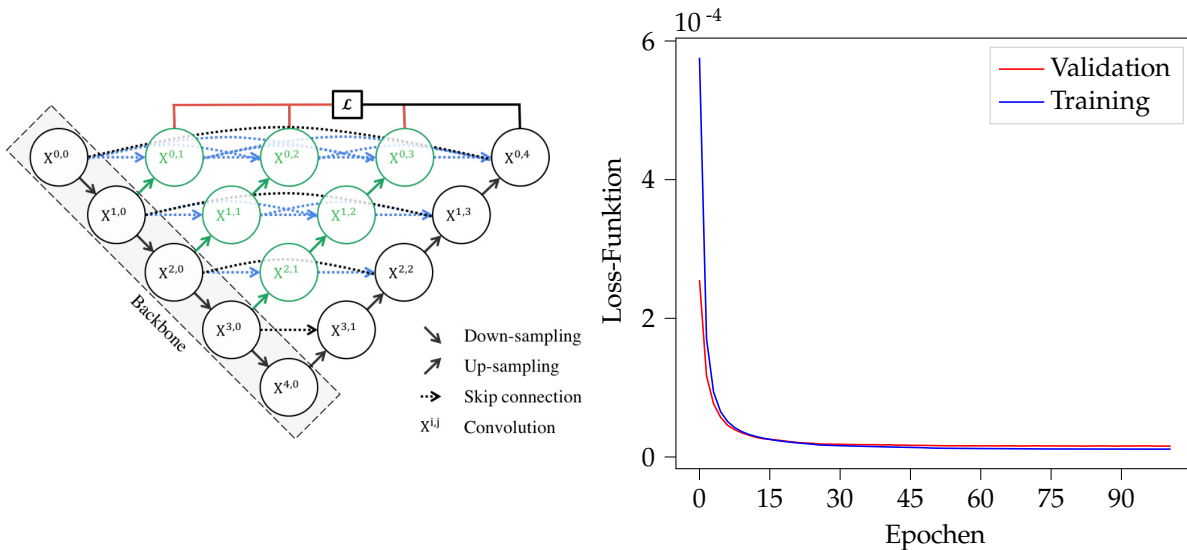
Die gewählten Architekturen sind SegNet (Badrinarayanan et al. 2017), U-Net++ (Zhou et al. 2018), MedT (Valanarasu et al. 2021) und nnU-Net (Isensee et al. 2021). SegNet, U-Net++ und nnU-Net sind Encoder-Decoder-Netzwerke. MedT hingegen verwendet Convolutional Layers und Gated-Axial-Attention Layers. SegNet wurde für Straßenszenen mit Fokus auf einen geringen Speicherverbrauch und eine effiziente Rechenzeit entwickelt.

U-Net++ (Zhou et al. 2018) ist eine Erweiterung der U-Net-Architektur (siehe Kapitel 2.3.4). U-Net wurde entwickelt, um auf kleinen Datenmengen in Verbindung mit einer künstlichen Datenerweiterung effektiv zu lernen (Ronneberger et al. 2015). Hierzu werden Skip Connections eingesetzt. Das klassische U-Net++ besteht aus fünf Netzwerkschichten, siehe Abbildung 4.5a. U-Net++ übernimmt den Encoder, der als *Backbone* bezeichnet wird, der U-Net-Architektur. Jedoch werden zusätzliche Skip Connections in Form einer Pyramidenstruktur im Decoder hinzugefügt. Die nun mehrstufigen Skip Connections erhöhen den übertragenen Informationsgehalt vom Encoder an den Decoder. (Zhou et al. 2018)

MedT besteht aus einem globalen Teilnetz mit zwei Schichten und einem lokalen Teilnetz mit fünf Schichten. Das globale Teilnetz verarbeitet die gesamte Eingabe, während für das lokale Teilnetz die Eingabebilder in 16 Teile aufgeteilt werden. Die Teilbilder werden einzeln verarbeitet und nachträglich wieder zusammengesetzt. MedT wurde explizit als Alternative zu klassischen CNN-Ansätzen gewählt, da diese Architektur nicht nur aus Faltungsschichten besteht. Als Hauptverarbeitungseinheiten werden Gated-Axial-Attention-Schichten eingesetzt. Überdies gewährleistet die Zusammensetzung aus einem globalen und einem lokalen Teilnetzwerk, dass das lokale Teilnetz effektiv mit mehr Bildern trainiert wird. Für kleinere Datenmengen, wie die hier betrachteten, kann dies von Vorteil sein. Darüber hinaus wird durch die Aufteilung der Eingabe im lokalen Teilnetz die Positionsvarianz des Bildinhalts automatisch in den Trainingsprozess einbezogen. Ebenfalls wird das Netzwerk mit Bildern mit unterschiedlichen Helligkeitsgradienten konfrontiert. Für weitere Details siehe Valanarasu et al. 2021.

nnU-Net ist ein selbstkonfigurierendes Verfahren zur medizinischen Bildsegmentierung, welches auf U-Net beruht. Die Datenerweiterung, die Hyperparameter, der Trainingsprozess und das Post-Processing werden automatisch auf der Basis abhängiger Regeln erstellt. nnU-Net ist öffentlich verfügbar und wird in vielen biomedizinischen Segmen-

tierungswettbewerben eingesetzt. Weiterführende Details finden sich in Isensee et al. 2021.



(a) Architektur von U-Net++ (Zhou et al. 2018)

(b) Entwicklung der Loss-Funktion

Abbildung 4.5: Architektur von U-Net++ und exemplarischer Trainingsverlauf der Loss-Funktion. Der Verlauf der Loss-Funktion zeigte sich in ähnlicher Form für alle trainierten Netzwerke.

4.3.3 Hardware und Training

Training, Loss-Funktion und Bewertung werden in Python (Van Rossum et al. 2009) und PyTorch (Paszke et al. 2019) implementiert. Das Training wird auf einer NVIDIA Quadro RTX 5000 mit mixed precision durchgeführt. Aufgrund des unterschiedlichen Speicherbedarfs der Netzwerke mussten verschiedene Batch-Größen verwendet werden. Die Lernrate beginnt bei $3 \cdot 10^{-4}$ und wird mit 0,2 multipliziert, wenn der gleitende Durchschnitt des Trainings für 20 Epochen stagniert, bis eine minimale Lernrate von $1 \cdot 10^{-6}$ erreicht ist. Eine Übersicht der Trainingsparameter ist in Tabelle 4.2 dargestellt. Das Training von nnU-Net wurde in seinem eigenen Framework durchgeführt. Für vergleichbare Ergebnisse orientieren sich die ausgewählten Werte an diesem Framework. Als Loss-Funktion wird der dice boundary (DiceBD) verwendet. Zur Bewertung werden alle entwickelten Koeffizienten verwendet.

Tabelle 4.2: Trainingsparameter für die Bildverarbeitungsnetzwerke

Loss-Funktion	DiceBD
Optimizer	Adam
Learning rate	$3 \cdot 10^{-4}$
Stopping Learning rate	$1 \cdot 10^{-6}$
Patience	20 Epochen
max. Epochen	100
Training	mixed precision
Framework	PyTorch
GPU	NVIDIA Quadro RTX 5000

4.4 Bewertung der Prognosegüte

4.4.1 Vergleich der unterschiedlichen Architekturen

Zunächst wird eine SegNet-, U-Net++-, MedT- und nnU-Net-Architektur trainiert und bewertet. Jedes Netzwerk wird 100 Epochen trainiert. Die Entwicklung der Loss-Werte wird exemplarisch in Abbildung 4.5b dargestellt und zeigt einen erfolgreichen Trainingsprozess. nnU-Net wird in seinem eigenen Framework trainiert. Die Epoche mit dem geringsten Loss-Wert wird für die Bewertung anhand der Testdaten ausgewählt. Zunächst werden alle Testdaten von den Architekturen prognostiziert und eine Gesamtbewertung durchgeführt. Zusätzlich wird die Bewertung in die einzelnen Unterklassen der Datenerweiterung aufgeteilt. Die durchschnittliche Verarbeitungszeit t_{inf} für eine Bildaufnahme wird ebenfalls ermittelt.

Die Ergebnisse sind in Tabelle 4.3 dargestellt. U-Net++ erzielt in Bezug auf den kombinierten Koeffizienten um 17,94 Prozentpunkte höhere Werte als SegNet, um 5,68 Prozentpunkte höhere Werte als MedT und um 3,25 Prozentpunkte höhere Werte als nnU-Net. U-Net++ erweist sich auch bei den übrigen Koeffizienten der Gesamtbewertung als besser. Die Analyse für die einzelnen Unterkategorien (siehe Abbildung 4.6) zeigt, dass U-Net++ im Vergleich zu nnU-Net, MedT und SegNet am besten auf die dreifach vergrößerten Bilder reagiert. Durch Sichtung der Prognosebilder (siehe Abbildung 4.7) zeigt sich, dass die beiden letztgenannten Architekturen mehr Einrisse prognostizieren. Auf der Grundlage dieser Daten ist U-Net++ am besten für die Segmentierung geeignet und wird optimiert. Die vollständige Aufwertung für das U-Net++ befindet im Anhang, siehe Abbildung A.2 und Abbildung A.3.

4.4.2 U-Net++-Optimierung

Zu Beginn des Trainings werden die Initialgewichte der Netzwerkparameter zufällig gewählt. Hieraus können Abweichungen der Bewertung bei unterschiedlichen Trainingsprozessen mit denselben Hyperparametern entstehen. Durch mehrmaliges Durchführen des Trainings mit derselben Netzwerkarchitektur werden die zu erwartenden Mittelwerte und deren Standardabweichungen auf Basis der zufälligen Initialisierung ermittelt.

Tabelle 4.3: Vergleich der ausgewählten Architekturen

	SegNet	U-Net++	MedT	nnU-Net
Trainingsdauer	30 h	28 h	288 h	25 h
Verarbeitungszeit t_{inf} in ms	5,84	4,29	91,24	4,52
kombinierter Koeffizient	81,14	99,08	93,41	95,83
Anteil der prognostizierten Fläche in %	97,32	99,64	96,68	92,51
Anteil der zugeordneten Komponenten in %	95,32	99,21	94,42	89,16
Komponentenverhältnis	2,20	2,19	2,86	2,57
Einrissverhältnis	1,70	1,06	1,45	0,84

Aus diesen Werten wird eine Architektur geschaffen die als Referenz dient. Verlassen die Bewertungswerte einer Test-Architektur den Bereich der Standardabweichung der Referenz, kann dies auf die vorliegende Hyperparameteränderung zurückgeführt und eine Bewertung der Test-Architektur abgeleitet werden. Für die Referenzarchitektur werden fünf Trainingsläufe durchgeführt. Die Ergebnisse der Bewertung sind in Tabelle 4.4 zu sehen.

Tabelle 4.4: Mittelwert und Standardabweichung von fünf Trainingsdurchläufen der U-Net++ Architektur

	Mittelwert	Standardabweichung
kombinierter Koeffizient	98,72	$\pm 0,38$
Anteil der prognostizierten Fläche in %	99,56	$\pm 0,07$
Anteil der zugeordneten Komponenten in %	98,75	$\pm 0,42$
Komponentenverhältnis	2,20	$\pm 0,01$
Einrissverhältnis	1,14	$\pm 0,05$

Architekturen, deren Werte innerhalb des Intervalls der Standardabweichung der Referenzarchitektur liegen, gelten als gleichwertig. Ein Bezug zu einer Parameteränderung kann nicht hergestellt werden. Architekturen, bei denen mindestens ein Bewertungswert über der oberen Intervallgrenze liegt und die übrigen Bewertungswerte sich innerhalb des Intervalls der Standardabweichung liegen, gelten als besser. Architekturen, bei denen mindestens ein Bewertungswert unter der unteren Intervallgrenze liegt und die übrigen Bewertungswerte innerhalb des Intervalls der Standardabweichung verbleiben, gelten als schlechter. Architekturen mit mindestens einem Bewertungswert oberhalb der Intervallgrenze und mindestens einer Punktzahl unterhalb der Intervallgrenze müssen genauer analysiert werden. In diesem Fall ist mit oberhalb und oberer Intervallgrenze nicht der mathematisch höhere Wert gemeint, sondern der bessere Wert.

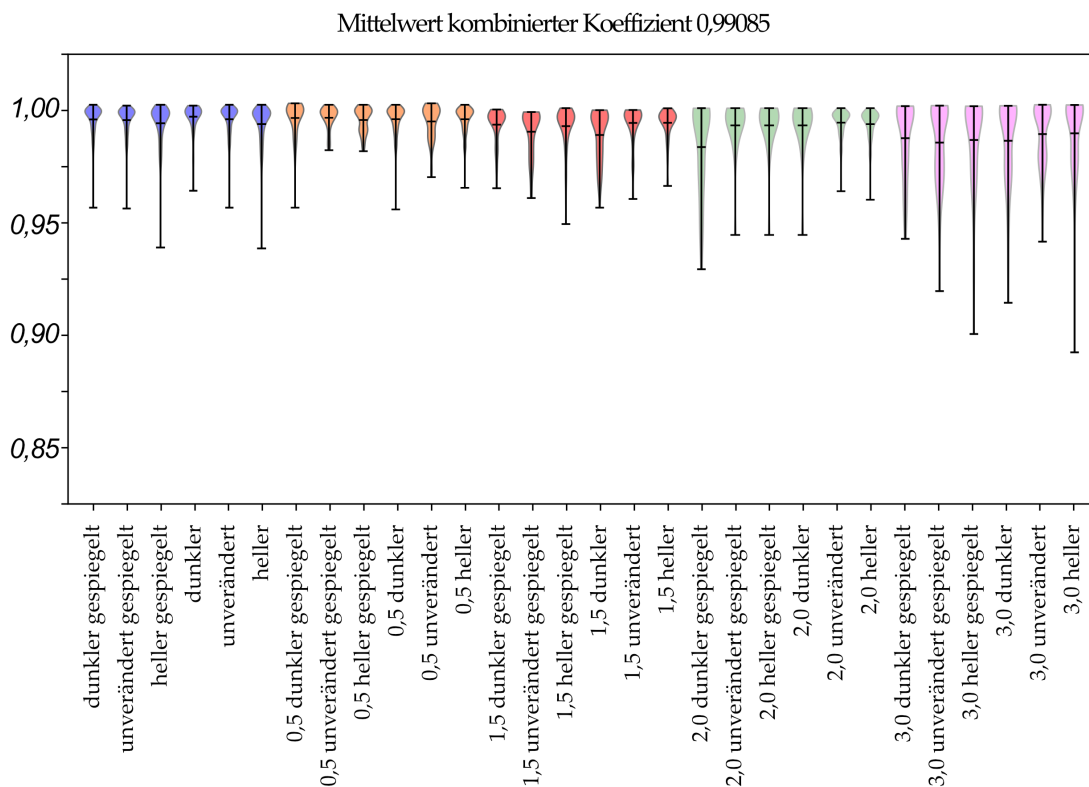


Abbildung 4.6: Bewertung der Architektur U-Net++ mit dem kombinierten Koeffizient. Für die Definition der Farben siehe Tabelle 4.1.

4.4.3 Hyperparameter

Die in dieser Arbeit analysierten Hyperparameter sind die Anzahl der Feature Maps, der Netzwerkschichten und der Blöcke pro Netzwerkschicht, die als Blocktiefe bezeichnet werden. Ein Block besteht aus einer Batch-Normalisierungsschicht und einer Faltungsschicht mit Aktivierungsfunktion. Die Referenzarchitektur verwendet 32 Feature Maps in der ersten Netzwerkschicht und verdoppelt die Anzahl pro Netzwerkschicht. Die fünfte und letzte Netzwerkschicht im Encoder verwendet 512 Feature Maps. Die Blocktiefe der Referenzarchitektur beträgt 2. Durch Variation eines Hyperparameters mit anschließendem Training und nachfolgender Bewertung werden die Auswirkungen auf die Prognosegüte ermittelt.

Feature Maps Zur Analyse der Beziehung zwischen der Anzahl der Feature Maps und der Prognosegüte, wurden Netze mit 8, 16 und 64 Feature Maps verglichen. Die Verdoppelung der Feature Maps pro Schicht wird dabei beibehalten. Die Ergebnisse (siehe Tabelle 4.5) zeigen, dass eine Änderung der Anzahl der Feature Maps pro Schicht zu einer Verbesserung der Ergebnisse führen. Die Architektur mit 64 Feature Maps erzielt in Bezug auf den kombinierten Koeffizienten einen um 0,67 Prozentpunkte höheren Prognosewert als die Referenzarchitektur. Weiterhin erhöhen sich alle anderen Koeffizi-

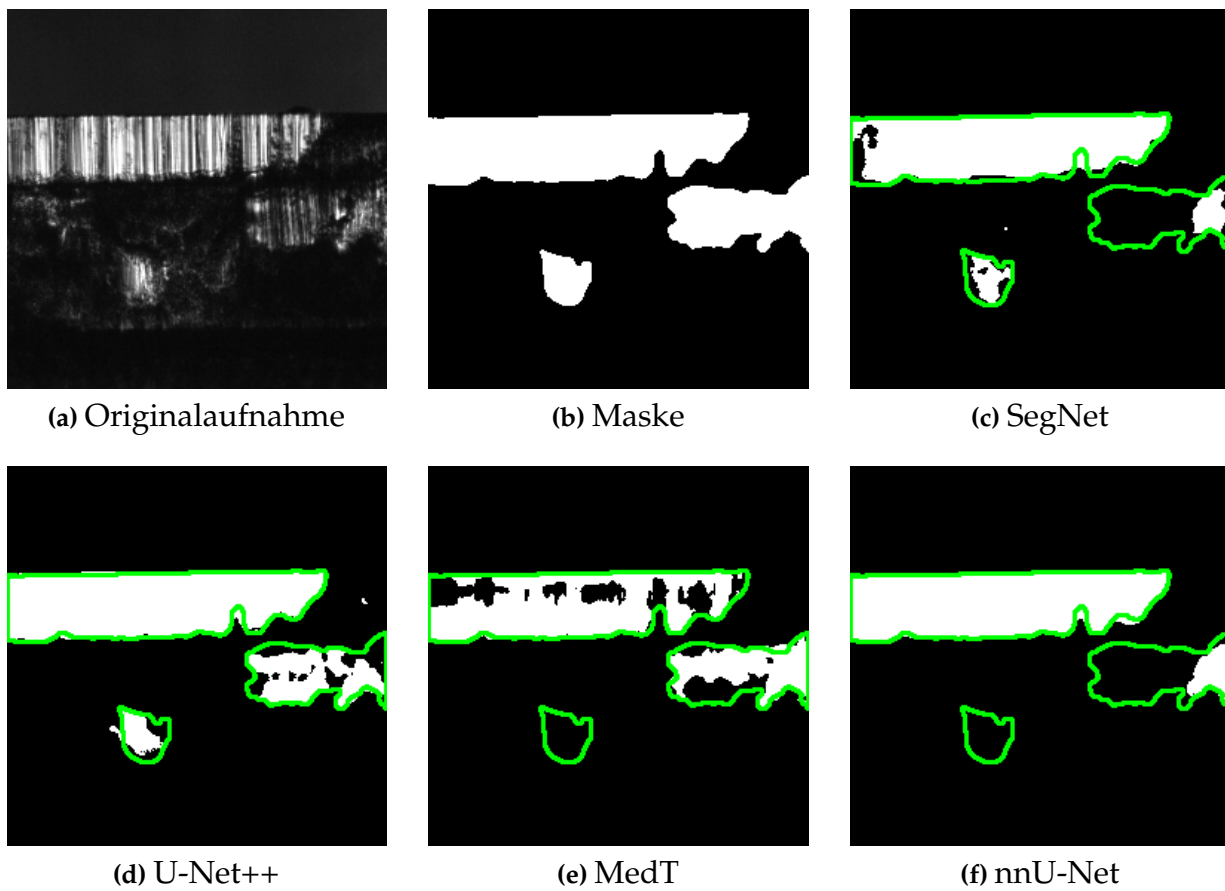


Abbildung 4.7: Prognosen verschiedener Netzwerkarchitekturen zur Segmentierung des Glattschnittanteils. Tatsächliche Kontur in grün.

enten mit dieser Konfiguration. Die übrigen Architekturen erzielen erwartungsgemäße Prognosen. Eine geringe Anzahl an Feature Maps erzeugt eine kleinere Anzahl an erlernbaren Parametern. Im Netzwerk können daher weniger Details aus den Strukturen im Bild extrahiert und erlernt werden. Wenn keine ausreichende Anzahl an Parametern zur Verfügung steht, verschlechtert sich die Prognose. Dieses Verhalten zeigt sich an der Architektur mit 8 Feature Maps. Die Auswertung und Betrachtung der Prognosen zeigt dies vor allem bei dreifach vergrößerten Aufnahmen. Die Verarbeitungszeit steigt mit zunehmender Anzahl an Feature Maps an.

Blocktiefe Weiter werden Architekturen mit den Blocktiefen 1 und 3 trainiert und bewertet, siehe Tabelle 4.5. Die Änderung der Anzahl der Faltungsschichten pro Block ändert die Menge der Daten, die pro Netzwerkschicht verarbeitet wird. Hieraus resultieren für die Architektur mit Blocktiefe 1 eine deutlich geringe Verarbeitungszeit, allerdings werden auch geringfügig schlechteren Ergebnis erzielt. Mehr Schichten hingegen führen zwar zu einem um 0,08 Prozentpunkte verbesserten kombinierten Koeffizienten im Vergleich zur Referenzarchitektur, benötigen aber eine höhere Verarbeitungszeit.

Anzahl der Netzwerkschichten Tabelle 4.5 zeigt die Ergebnisse für die Architekturen mit unterschiedlicher Anzahl an Schichten. Es werden Architekturen mit 2 bis 6 Netzwerkschichten untersucht. Die Ergebnisse zeigen, dass Netze mit weniger Netzwerkschichten schlechteren Ergebnisse in Bezug auf den kombinierten Koeffizienten liefern und dabei kürzere Verarbeitungszeit benötigen. Mehr Netzwerkschichten hingegen führen zwar zu einer ansteigenden Verarbeitungszeit, aber auch zu besseren Ergebnissen mit Blick auf das Komponenten- und Einrissverhältnis. Dies deutet darauf hin, dass tiefere Schichten und Architekturen für komplexeren Merkmale, wie Einrisse, besser geeignet sind.

Tabelle 4.5: Vergleich der Hyperparametervariation der U-Net++ Architektur. Legende zur Bewertung: besserer Wert (Δ), schlechterer Wert (∇) oder vergleichbarer Wert (=).

Architektur	t_{inf} in ms	kombinierter Koeffizient	Anteil der prognostizierten Fläche in %	Anteil der zugeordneten Komponenten in %	Komponentenverhältnis	Einrissverhältnis
8 Feature Maps	4,02	97,87 (∇)	98,63 (∇)	96,24 (∇)	2,20 (=)	1,10 (=)
16 Feature Maps	4,11	98,69 (=)	99,84 (Δ)	99,12 (=)	2,19 (Δ)	1,03 (=)
64 Feature Maps	4,43	99,39 (Δ)	99,78 (Δ)	99,33 (Δ)	2,20 (=)	1,05 (Δ)
Blocktiefe 1	2,78	98,73 (=)	99,30 (∇)	98,01 (∇)	2,19 (Δ)	1,07 (=)
Blocktiefe 3	5,71	99,19 (Δ)	99,98 (Δ)	99,59 (Δ)	2,19 (Δ)	1,06 (=)
3 Schichten	1,75	97,70 (∇)	99,59 (=)	99,01 (=)	2,20 (=)	1,21 (∇)
4 Schichten	2,90	98,02 (∇)	100,16 (Δ)	99,92 (Δ)	2,21 (=)	1,21 (∇)
6 Schichten	6,14	99,26 (Δ)	99,92 (Δ)	99,68 (Δ)	2,19 (Δ)	1,06 (Δ)

Synthese der Hyperparameter In Anbetracht der Ergebnisse wird eine Architektur mit den leistungsstärksten Hyperparametern erstellt. Diese Architektur besitzt 64 Feature Maps in der ersten Schicht, eine Blocktiefe 3 und insgesamt 6 Netzwerkschichten. Wie Tabelle 4.6 gezeigt, ergibt sich eine Verbesserung um 0,66 Prozentpunkte in Bezug auf den kombinierten Koeffizienten. Zusätzlich verbessern sich alle anderen Koeffizienten, mit Ausnahme dem Einrissverhältnis. Allerdings wird die Verarbeitungszeit, aufgrund der komplexeren Architektur, mehr als verdoppelt.

4.4.4 Backbone

Die vorangegangene Analyse hat gezeigt, dass vergleichbare Prognosen, in Bezug auf den kombinierten Koeffizient, mit Blocktiefe 1 erreicht werden können. Allerdings führt diese Architektur zu schlechteren Ergebnissen für Aufnahmen mit einer größeren Anzahl an Komponenten und Einrissen, aufgrund der komplexeren Anforderungen. Weiterhin führte die Erhöhung der Anzahl der Schichten über 5 hinaus zu erheblichen Verbesserungen, erhöht aber die Verarbeitungszeit des Netzwerks. Als Kompromiss zwischen einer kürzeren Verarbeitungszeit und einer genaueren Prognose wird eine Architektur

mit zunehmender Blocktiefe pro Schicht vorgeschlagen. Das bedeutet, dass die erste Netzwerkschicht mit Blocktiefe 1, die zweiten Netzwerkschicht mit Blocktiefe 2 gebildet wird. Dies wird abhängig von der Gesamtanzahl der Netzwerkschichten fortgesetzt.

Dieser Architektur liegt die Annahme zugrunde, dass die Verarbeitung der weniger komplexen Eigenschaften in den oberen Schichten erfolgt, die der Eigenschaften mit erhöhter Komplexität hingegen in den unteren Schichten. Bezogen auf die Bilddaten sind weniger komplexe Eigenschaften, unter anderem die Position und die Helligkeit eines Pixels; es handelt sich um eher lokale Strukturen. Komplexere Eigenschaften berücksichtigen beispielsweise Nachbarschaftsbeziehungen. Hier könnten unter anderem relevant sein, inwieweit ein Pixel innerhalb einer größeren Gruppe von hellen Pixeln liegt, wie groß diese Gruppe ist, wie der Rand dieser Gruppe ausgeprägt ist oder inwieweit die Gruppe eine entsprechende Struktur enthält.

Die in Tabelle 4.6 dargestellten Ergebnisse für eine Architektur mit ansteigender Blocktiefe zeigen, dass eine Erhöhung der Blocktiefe in den unteren Schichten nicht zu besseren Ergebnissen in Bezug auf die unterschiedlichen Koeffizienten führt und die Verarbeitungszeit ansteigt. Die getroffene Annahme kann von dieser Architektur nicht bestätigt werden.

Eine weitere Methode, die Datenmenge in tieferen Schichten zu erhöhen und somit die getroffene Annahme zu bestätigen, ist die Einführungen von *Dense Connections* im Encoder. Zu diesem Zweck wird der bisherige Encoder durch ein DenseNet (Huang et al. 2017) ersetzt. Der Aufbau erfolgt ähnlich zu Chen et al. 2020 und Cai et al. 2020 und wird auf die U-Net++-Struktur erweitert, siehe Abbildung 4.8. Durch die eingeführten Dense Connections, erhält jede Netzwerkschicht zusätzlich die unverarbeitete Eingabe der Vorgängerschicht. Informationen über komplexe Eigenschaften sollen durch die wiederholte Kombination dieser Eigenschaften verdichtet werden (Cai et al. 2020).

Die Ergebnisse des Dense-Backbone sind in Tabelle 4.6 aufgeführt. Die Modifikation führt zu vergleichbaren oder bessere Ergebnisse in Bezug auf die Koeffizienten der zugeordneten Fläche und der zugeordneten Komponenten. Das Komponenten- und das Einrissverhältnis bleiben jedoch unverändert. Im Allgemeinen sind die Ergebnisse vergleichbar mit denen ansteigenden Blocktiefe, allerdings ist die Erhöhung der Verarbeitungszeit deutlich geringer.

Tabelle 4.6: Vergleich der Backbone-Variation. Legende zur Bewertung: besserer Wert (Δ), schlechterer Wert (∇) oder vergleichbarer Wert (=).

Architektur	t_{inf} in ms	kombinierter Koeffizient	Anteil der prognostizierten Fläche in %	Anteil der zugeordneten Komponenten in %	Komponentenverhältnis	Einrissverhältnis
optimierte Hyperparameter	10,97	99,14 (Δ)	99,87 (Δ)	99,66 (Δ)	2,16 (Δ)	1,07 (=)
Blocktiefe ansteigend	9,24	98,62 (=)	99,16 (∇)	98,15 (∇)	2,20 (=)	1,11 (=)
Dense-Backbone	4,95	98,39 (=)	100,98 (Δ)	100,34 (Δ)	2,20 (=)	1,08 (=)

4.4.5 Zusammenfassung der untersuchten Architekturen

Die vorangegangene Analyse der Hyperparameter und der unterschiedlichen Backbones kann folgendermaßen zusammengefasst werden:

- Architekturen mit weniger als 16 Feature Maps erzielen schlechtere Ergebnisse bei geringerer Verarbeitungszeit.
- Architekturen mit mehr Feature Maps erzielen bessere Ergebnisse bei höherer Verarbeitungszeit.
- Architekturen mit geringerer Blocktiefe erzielen vergleichbare Ergebnisse bei einer geringeren Verarbeitungszeit.
- Architekturen mit höherer Blocktiefe erzielen geringfügig bessere Ergebnisse bei einer höheren Verarbeitungszeit.
- Architekturen mit weniger Netzwerkschichten erzielen schlechtere Ergebnisse bei einer geringeren Verarbeitungszeit.
- Architekturen mit mehr Netzwerkschichten erzielen bessere Ergebnisse bei einer höheren Verarbeitungszeit.
- Architekturen mit optimierten Hyperparametern erzielen bessere Ergebnisse, aber verdoppeln die Verarbeitungszeit.
- Architekturen mit ansteigender Blocktiefe erzielen schlechtere Ergebnisse und verdoppeln die Verarbeitungszeit.
- Architekturen mit Dense-Backbone erzielt vergleichbare oder bessere Ergebnisse und benötigen eine höhere Verarbeitungszeit.

Auf der Grundlage dieser Zusammenfassung wird eine Architektur *U-Net++ mit 64 Feature Maps* ausgewählt. Auch wenn die Architektur mit 6 Netzwerkschichten in manchen Koeffizienten noch höhere Werte erzielt, benötigt die gewählte Architektur eine geringere Verarbeitungszeit und wird daher mit Blick auf die Verarbeitung innerhalb des Fertigungstakts favorisiert.

Eine Gesamtauswertung aller Architekturen findet sich im Anhang (siehe Anhang, Tabelle A.4).

4.5 Evaluierung der Architektur anhand von Transferdaten

Die Bewertungen der unterschiedlichen Architekturen variieren nur geringfügig. Eine weitere Optimierung wird wahrscheinlich zu einer Überanpassung an die Daten führen. Eine Erweiterung der Trainingsdaten kann dies verhindern. Diese wurde in Form einer künstlichen Datenerweiterung bereits vollzogen. Die Erweiterung noch zu erhöhen, wird als nicht sinnvoll angesehen. Die durch die künstliche Datenerweiterung eingeführten

4.5. Evaluierung der Architektur anhand von Transferdaten

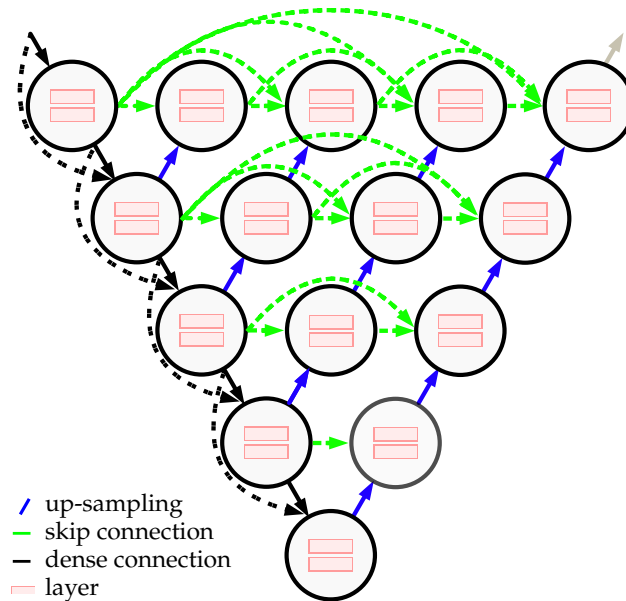


Abbildung 4.8: Architektur des U-Net++ mit Dense-Backbone

Informationen spiegeln nur bedingt die Realität wider und bieten selbst Ansatzpunkte für ein Overfitting. Weitere Daten sollten daher durch das Überwachungssystem hinzugefügt werden. Zur Steigerung der Datenvielfalt sollte diese Erweiterung mit unterschiedlichen Fertigungsparametern erzeugt werden. Allerdings ist die Erzeugung dieser Daten mit einem erhöhten Aufwand verbunden. Zum einen ist die vorliegende Maschine die Einzige, die mit dem Überwachungssystem ausgestattet ist. Zum anderen müsste zur Änderung des Fertigungsparameters der Banddicke ein zweites Schneidwerkzeug konstruiert und gefertigt werden. Zusätzlich müssten die tatsächlichen Masken erstellt werden. Diese Erweiterung ist in dieser Arbeit nicht abbildbar. Daher werden für die Evaluierung der Architekturen alleinstehender Transferdaten angefertigt. Neben der Bestätigung der Prognosegüte soll anhand dieser Daten eine Aussage über die allgemeine Anwendbarkeit der ausgewählten Architekturen erfolgen. Zusätzlich werden erneut die Möglichkeiten gezeigt, die durch die entwickelte Gesamtbewertung entstehen.

Die Transferdaten bestehen aus 60 Aufnahmen von Glattschnittflächen mit zugehöriger Maske. Unterteilt sind die Daten in 40 Aufnahmen von Schnittflächen aus Kupfer mit den Materialdicken 0,5 mm und 0,64 mm und Stahl mit einer Materialdicke 0,5 mm. Zusätzlich werden zehn Aufnahmen hinzugefügt, die während der Fertigung mit Beölung aufgezeichnet wurden. Alle diese Aufnahmen wurden mit dem Überwachungssystem aufgenommen. Für die verbleibenden Aufnahmen wurden Schnittflächen mit konfokalen Mikroskop aufgezeichnet und exportiert. Durch die Wahl unterschiedlicher Aufnahmegeräte und veränderter Fertigungsbedingungen kann die allgemeine Anwendbarkeit geprüft werden. Die Aufnahmen aus dem Mikroskop werden ausgewählt, da es sich um ein derzeit eingesetztes System zur Schnittflächenermittlung handelt. Die definierten Anforderungen an die Charakteristika der Glattschnittfläche sind anwendbar und auf die Aufnahmen übertragbar. Zusätzlich weisen die Aufnahmen durch die Mikroskop-

Tabelle 4.7: Vergleich der verschiedenen Netzwerkarchitekturen anhand der Transferdatemenge

Architektur	t_{inf} in ms	kombiniertes Koeffizient	Anteil der prognostizierten Fläche in %	Anteil der zugeordneten Komponenten in %	Komponentenverhältnis	Einrissverhältnis
64 Feature Maps	5,23	82,49	106,14	102,06	7,75	4,38
6 Schichten	7,21	81,19	108,58	104,27	5,92	3,28
Referenz U-Net++	5,67	80,67	106,43	100,66	7,28	5,00
optimierte Hyperparameter	10,28	79,24	98,73	93,73	5,72	3,62


vergrößerung einen höheren Detailgrad auf. Die Masken zu den Aufnahmen werden wiederum durch den manuellen Prozess erstellt.

Die Transferdaten werden von der Architektur *U-Net++ mit 64 Feature Maps*, der Architektur mit 6 Netzwerkschichten, der Architektur der optimierten Hyperparameter und der Referenzarchitektur prognostiziert und bewertet.

Zusammenfassend wird das beste Ergebnis (siehe Tabelle 4.7) durch Architektur *U-Net++ mit 64 Feature Maps* erzielt. Die Verarbeitungszeit steigt auf 5,23 ms. Im Vergleich mit den Testdaten sind die erzielten kombinierten Koeffizienten mindestens 16,9 Prozentpunkte geringer und erreichen 82,49 %. Vor allem das Komponenten- und Einrissverhältnis erhöht sich. Die zugeordneten Komponenten ändern sich hingegen nur geringfügig. Ohne eine visuelle Betrachtung der Prognosen ist aus der Gesamtbewertung ersichtlich, dass in den Prognosen mehr Einrisse und eine größere Anzahl an Glattschnittflächen vorhanden sind. Diese Aussagen werden durch die visuelle Betrachtung bestätigt (Abbildung 4.9).

Die Auswertung der Transferdaten wird zusätzlich aufgeteilt betrachtet, siehe Abbildung 4.10. Die Aufteilung erfolgt dabei anhand der Fertigungs- oder Aufnahmebedingungen in die Kategorien Kupfer $s = 0,5$ mm, Kupfer $s = 0,64$ mm, Stahl, Beölung und Mikroskop. Die Aufnahmen mit Beölung zeigen dabei einen hohen Anteil der prognostizierten Fläche. Bezogen auf diese Eigenschaft segmentiert die Architektur zu große Glattschnittflächen und zeigt eine erhöhte Anzahl an Einrissen. Im Vergleich erzeugen Aufnahmen aus dem konfokalen Mikroskop eine geringere Anzahl an Einrissen, erhöhen aber die Anzahl an Komponenten. Die Bilder der Kupfermaterialien liefern bei Banddicke $s = 0,5$ mm vergleichbare Ergebnisse. Bei erhöhter Materialdicke verschlechtern sich die Ergebnisse allerdings. Dies kann nicht ausschließlich auf die Erhöhung der Banddicke zurückgeführt werden. Das vorliegende Kupfermaterial weicht auch in seiner Bruchcharakteristik von den Trainingsdaten ab, siehe Abbildung 3.9. Die Aufnahmen des Stahlmaterials hingegen liefern vergleichbare Ergebnisse zu den Trainingsdaten.

Die beschriebene Auswertung bestätigt die Auswahl des *U-Net++ mit 64 Feature Maps*. Eine Aussage über die allgemeine Anwendbarkeit kann nur qualitativ getroffen werden. Die Architektur zeigt vielversprechende Ergebnisse mit unterschiedlichen Aufnahmen.




(a) Aufnahme durch das Mikroskop




(b) Prognose von (a) durch das U-Net++ mit 64 Feature Maps




(c) Prognose von (a) durch das U-Net++ mit optimierten Hyperparametern



(d) Aufnahme mit Beölung



(e) Prognose von (d) durch das U-Net++ mit 64 Feature Maps



(f) Prognose von (d) durch das U-Net++ mit 6 Netzwerkschichten

Abbildung 4.9: Evaluierung der entwickelten Netzwerkarchitekturen auf dem Transferdatensatz. Tatsächliche Kontur in grün.

Eine Gesamtauswertung aller Architekturen mit den Transferdaten befindet sich im Anhang, siehe Tabelle A.5.

4.6 Zusammenfassung

In diesem Kapitel wurde die erste Trainingsdatenmenge, die die Entwicklung einer Glattschnittfläche über die Lebensdauer eines Schneidstempels enthält, erstellt. Die Trainingsdaten wurden manuell segmentiert und künstlich erweitert. Eine Methode zur Gesamtbewertung der prognostizierten Ergebnisse wurde vorgestellt. Diese basiert auf der Expertise von Branchenexperten. Die Gesamtbewertung erfolgte anhand der Betrachtung mehrere Kennzahlen. Der darin enthaltene entwickelte kombinierte Koeffizient ermöglicht die direkte Bewertung der Prognosegüte. Durch die Bereitstellung

Kapitel 4. Schnittflächenanalyse durch neuronale Netzwerke

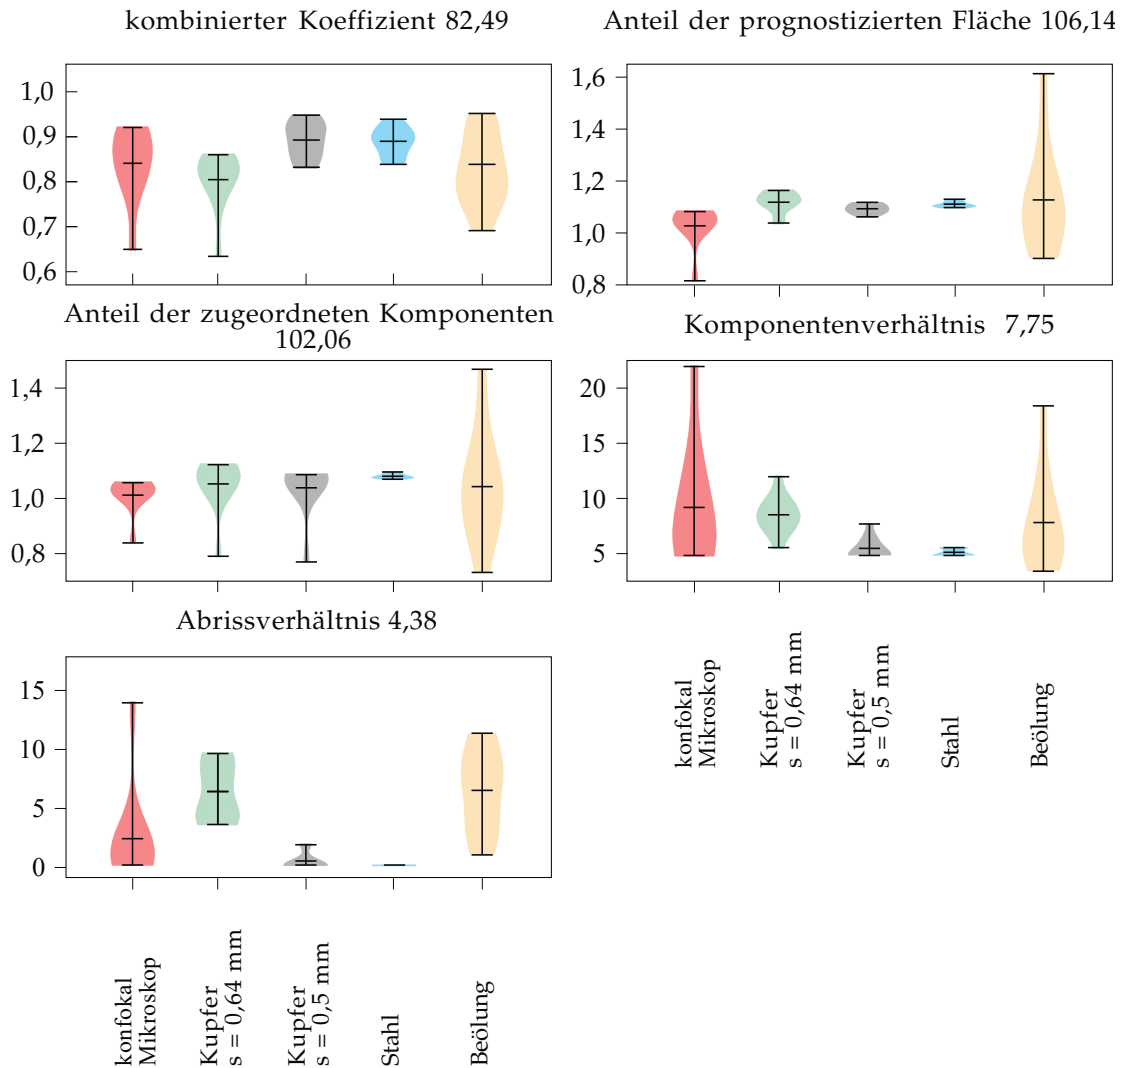


Abbildung 4.10: Aufteilung der Auswertung der Transferdaten für die Architektur *U-Net++ mit 64 Feature Maps*

weiterer Kennzahlen konnte eine genauere Analyse der Prognose erfolgen. Der gezeigte kombinierte Koeffizient und der für das Training verwendete DiceBD-Loss bestehen aus vergleichbaren Anteilen. Diese bewerten die Übereinstimmung sowohl der Kantengenauigkeit als auch der Fläche zwischen Prognose und Maske. Durch die Bereitstellung von Gewichtungsfaktoren können Anwender die Gewichtung dieser Eigenschaften anwendungsbezogen sowohl in der Bewertung als auch in der Loss-Funktion anpassen.

Durch die Untersuchung unterschiedlicher Netzwerkarchitekturen und eine Hyperparameteroptimierung wurde eine Netzwerkarchitektur für die Segmentierung des Glattschnittanteils gezeigt. Die erstellte Architektur *U-Net++ mit 64 Feature Maps* wurde anhand von Transferdaten evaluiert. Die Ergebnisse sind vielversprechend im Hinblick auf eine allgemeine Anwendbarkeit, wenn die Trainingsdaten erweitert werden können. Durch die geringere Verarbeitungszeit wird eine Möglichkeit zur Bestimmung der

Glattschnittfläche innerhalb des Fertigungstaktes geschaffen.

Für den Einsatz in der Qualitätsüberwachung muss sich weitere Forschung auf die Übertragbarkeit der entwickelten Architektur, mit Blick auf eine höhere Bildauflösung, fokussieren. In dieser Untersuchung wurde eine reduzierte Auflösung verwendet, um die Trainingszeiten zu reduzieren. Die verwendete Auflösung von 256×256 Pixel verhindert die Anwendung in Messaufgaben. Überdies müssen die Trainingsdaten mit realen Aufnahmen sowie mit Aufnahmen mit unterschiedlichen Fertigungsparametern, beispielsweise für die Banddicke und das Material erweitert, werden. Ferner sollten Daten aus anderen Messgeräten hinzugefügt werden. Die allgemeine Anwendbarkeit der Architektur sollte hierdurch gesteigert werden.

Im Hinblick auf die vorausschauende Wartung sollte weitere Forschung den Schwerpunkt auf die Klassifizierung des Bildes nach der Segmentierung legen. Mögliche Klassen könnten eine Einteilung in Gut- oder Schlechteile oder in die Phasen des Verschleißdiagramms wie Einlauf, gleichmäßiger Zustand und zunehmender Verschleiß sein.

Sensornetzwerk beim Scherschneiden

Die Aufnahme und Segmentierung der Glattschnittfläche im Fertigungstakt ermöglicht eine Erweiterung der bisherigen Methoden zur datengetriebenen Prozessüberwachung. Daten zur Bauteilqualität sind erstmals in derselben Dichte vorhanden, wie Daten der beeinflussenden Faktoren. Ziel dieses Kapitels ist es, anhand der Qualitätsbestimmung der Glattschnittfläche den Verschleißzustand des Schneidstempels zu bestimmen und mit aktuellen Methoden zu vergleichen. Dies wird durch den Aufbau eines Sensornetzwerks an einem Scherschneidprozess und Methoden des maschinellen Lernens erreicht. Der Verschleißzustand wird anhand von Prozessdaten als Klassifikation prognostiziert. Die gewählte Vorgehensweise orientiert sich an der Vorgehensweise des CRISP-DM. Zunächst wird ein Sensornetzwerk am Stanzbiegeautomaten Bihler GRM-NC aufgebaut. In einer Messreihe werden Daten über die komplette Lebensdauer eines Schneidstempels aufgezeichnet. Anschließend wird in der Datenvorverarbeitung die Datenmenge reduziert und zugehörigen Labels erstellt. Nachfolgend werden in der Modellbildung klassische Algorithmen des maschinellen Lernens mit Methoden des Deep Learning verglichen. Weiterhin wird der Einfluss der unterschiedlichen Merkmale mittels SHAP-Werten untersucht.

5.1 Sensornetzwerk und Datenaufzeichnung

Die Eingangsgrößen oder unabhängigen Variablen wurden mithilfe des Ursache-Wirkungs-Diagramms definiert (siehe Kapitel 2.1.4, Abbildung 2.9). Als abhängige Variable wird der Zustand des Schneidstempels definiert. Als unabhängige Variablen werden die folgenden, aus Veröffentlichungen bekannten, Einflussgrößen festgelegt; die Schneidkraft, die Beschleunigung des Schneidstempels, der durch den Schneidstempel erzeugte Körperschall, die Banddicke und die entstandene Schnittfläche (siehe ebenfalls Kapitel 2.4). Die Banddicke wird aufgenommen, um den Einfluss des Materials zu berücksichtigen. Das Bandmaterial unterliegt bei seinem Fertigungsprozess wechselnden Bedingungen, die seine mechanischen Kenngrößen beeinflussen. Die Art der Lagerung, in Form eines Coils, beeinflusst die Parameter des Materials ebenfalls. Bandschichten nahe am Coilinnenradius erhalten daher eine höhere Vorspannung als Bandschichten nahe der Außenseiten. Ebenfalls erlauben die Toleranzfenster innerhalb der Lieferklassengüte Schwankungen innerhalb der Zugfestigkeit des Materials und damit veränderte Schneidbedingungen (Held et al. 2009; Kebe et al. 2011; Trauth et al. 2018).

Durchgeführt wird die Datenaufzeichnung am beschriebenen Stanzbiegeautomaten Bihler GRM-NC mit der Produktionsgeschwindigkeit von 250 Hub pro Minute. Als Bandmaterial wird der Stahl 1.4310 (X12CrNi177) der Toleranzklasse „fein“ nach DIN

EN ISO 9445-1, mit einer Zugfestigkeit R_m von 1600 MPa bis 1800 MPa, gewählt. Die Bandbreite beträgt $b = 35$ mm und die Banddicke $s = 0,5$ mm. Als Material für die Schneidstempel wird ein pulvermetallurgischer Werkzeugstahl (SPM30) und für die Schneidplatten ein Hartmetall K40 (CF-H40S+) gewählt. Der Schneidspalt u beträgt 5 % der Banddicke. Die Abmessungen der quadratischen Schneidstempel betragen erneut $5 \text{ mm} \times 5 \text{ mm}$. In dieser Arbeit werden nur Daten für eine Kante der Schnittgeometrie durch das Überwachungssystem aufgezeichnet. Für die Versuche wird das Schneidwerkzeug allerdings immer vollständig bestückt. Dies dient sowohl zur statistischen Absicherung der Messergebnisse als auch zur Aufrechterhaltung der Gleichgewichtsbedingung innerhalb des Schneidvorgangs. Tabelle 5.1 zeigt eine Übersicht der Fertigungsparameter.

Tabelle 5.1: Fertigungsparameter der Versuchsreihe

Fertigungsgeschwindigkeit	250	Hub pro Minute
Bandbreite b	35 mm	
Banddicke s	0,5 mm	
Bandmaterial	X12CrNi177	
Zugfestigkeit R_m	1600 - 1800 MPa	
Toleranzklasse	fein	
Beölung	keine	
Schneidspalt u	0,025 mm (5%)	
Schneidstempelmaterial	pulvermetallurgischer Werkzeugstahl (SPM30)	
Schneidplattenmaterial	Hartmetall K40 (CFH40S+)	
Schneidgeometrie	$5 \text{ mm} \times 5 \text{ mm}$	
Schneidkantenradius	20 μm	
Niederhalterkraft	23,6 kN	

5.1.1 Maschinenparameter

Die entstehenden Daten müssen eindeutig einander zugeordnet werden, hierzu wird die Hubzahl genutzt. Sie ist zu jedem gefertigten Bauteil in der Maschinensteuerung bekannt. Zur Übertragung der Steuerungsdaten ist in der Maschine ein OPC-UA-Server integriert. Allerdings besitzt dieser eine zu geringe Abtastrate, sodass Daten nicht im Fertigungstakt übertragen werden können. Durch den Einbau einer zusätzlichen Steuerungseinheit (Slave-SPS) mit OPC-UA-Server konnten die Steuerungsdaten im Steuerungstakt (μs -Bereich) bereitgestellt werden. Durch Zugriff der einzelnen Netzwerkklienten auf den Server können die aktuell vorliegenden Daten abgerufen werden. Zusätzlich stellt

die Slave-SPS den Zeitserver zur Synchronisation der unterschiedlichen Geräte. Dieser Aufbau gewährleistet zum einen eine Synchronisierung der Netzwerkklienten mit der Maschine. Zum anderen werden die Abläufe in der Maschinensteuerung durch die anfallenden Daten nicht unterbrochen oder verzögert. Aus der Maschinensteuerung werden die aktuelle Hubzahl, die Produktionsgeschwindigkeit und der jeweilige Zeitstempel übertragen.

5.1.2 Aufzeichnung der abhängigen Variable

Als abhängige Variable wird die 45° -Verschleißlänge, als Messgröße für den Verschleiß, herangezogen. Zu deren Bestimmung muss der Fertigungsprozess unterbrochen und das Schneidwerkzeug demontiert werden. Die Bestimmung erfolgt mit dem konfokal Mikroskop (siehe Anhang, Tabelle A.3). Die Vermessung erfolgt bei den definierten Hubzahlen 0, 5000, 10.000, 25.000, 50.000, 75.000, 100.000, 150.000 und 200.000. Zu jedem Intervall werden alle drei Schneidstempel, wie in Abbildung 5.1 gezeigt, an 8 Stellen vermessen. Es erfolgt jeweils eine Messung an den vier Stempelgeraden und je eine Messung an den vier Stempellecken. Nach erfolgter Messung wird das Schneidwerkzeug erneut montiert. Zusätzlich werden gefertigte Bauteile zu den entsprechenden Zeitpunkten entnommen und die geometrischen Abmessungen des Ausschnitts (Kantenlänge) mittels Profilprojektor (siehe Anhang, Tabelle A.2) bestimmt. Weiter wird die Glattschnitthöhe zu jedem entnommenen Bauteil am konfokalen Mikroskop bestimmt.

Zur Vermessung der 45° -Verschleißlänge wird der jeweilige Schneidstempel im 45° -Winkel mit dem konfokalen Mikroskop aufgezeichnet. Zur Auswertung wird jeweils eine Gerade an die Stirnfläche und an die Mantelfläche gelegt. Der Schnittpunkt dieser beiden Geraden bildet den Punkt der theoretisch ideal scharfen Schneidkante ab. Der eingeschlossene Winkel zwischen beiden Geraden beträgt 90° . Eine Senkrechte wird durch den Schnittpunkt der Geraden gelegt. Der Abstand zwischen diesem Schnittpunkt und dem Schnittpunkt der Senkrechten mit der Messgeometrie kann ermittelt werden, siehe Abbildung 5.1, rote Linie.

5.1.3 Aufzeichnung der unabhängigen Variablen

Die Summe der einzelnen unabhängigen Variablen, die pro Hub aufgezeichnet wird, wird im Folgenden als Datenpaket bezeichnet.

Schneidkraftmessung

Die Schneidkraftmessung erfolgt unmittelbar am Schneidstempel. Um die Steifigkeit des Stanzwerkzeugs so gering wie möglich zu beeinflussen, wird ein Piezosensor eingesetzt. Dieser benötigen im Vergleich zu Kraftmessdosen einen sehr geringen Bauraum und besitzt eine sehr hohe Dynamik. Es werden DiskFlex-Sensoren der Firma Schwer+Kopka eingesetzt. Der rechteckige piezoelektrische Sensor besitzt die Abmessungen $12\text{ mm} \times 3\text{ mm}$ und eine Höhe von 1 mm . Für die Montage wird eine Nut in die Stempelhalteplatte eingebracht. Der Sensor wird in diese eingeklebt und die Nut mit




Abbildung 5.1: Vermessung des Schneidstempels mit dem konfokalen Mikroskop an acht Messstellen (links) und Bestimmung der 45°-Verschleißlänge (rechts).

Kleber aufgefüllt. Hierzu wird der auf diesen Anwendungsfall angepasste SK-EASY-mix-Epoxy-Kleber der Firma Schwer+Kopka eingesetzt. Der Sensor befindet sich somit direkt im Kraftfluss des Schneidstempels. Die Stempelhalteplatte wird zusätzlich segmentiert. Für jeden Schneidstempel wird ein eigenes Segment erstellt (siehe Abbildung 5.2a). Eine gegenseitige Beeinflussung der Kräfte aus den einzelnen Schneidstempeln wird daher unterbunden. Für die Aufzeichnung der Messergebnisse wird der Piezosensor mit einem Ladungsverstärker (Firma Kistler Type 5007) verbunden. Der Sensor muss durch diese Einbauart kalibriert werden.

Kalibrierungsprozess

Der Kalibrierungsprozess erfolgt mit montiertem Schneidwerkzeug auf dem Stanzbiegeautomaten, siehe Abbildung 5.3. Durch die Auswahl dieser Position werden fertigungsnahe Bedingungen erreicht und alle Steifigkeitsbedingungen des Fertigungsprozesses abgebildet. Der Prozess erfolgt in Anlehnung an die Richtlinie DKD-R 3-9 (Physikalisch-Technische Bundesanstalt 2018).

Zunächst wird das Bandmaterial in die Maschine eingebracht, ein Schneidvorgang durchgeführt und der Schneidstempel im unteren Umkehrpunkt (UP) der Pressenbewegung gestoppt. Der Schneidstempel ist in dieser Position in die Schneidplatte eingetaucht. Der entstandene Ausschnitt (Butzen) wird entfernt. Ein Messdorn wird durch den Pressentisch und das Schneidwerkzeugunterteil geführt. Der Messdorn besitzt dieselben Abmessungen wie der Schneidstempel und wird in der Schneidplatte geführt, bis seine Stirnfläche die Stirnfläche des Schneidstempels kontaktiert. Die gegenüberliegende Seite des Messdorns liegt auf der Kraftmessdose K-C9C (20 kN) der Firma HBM und diese wiederum auf einem hydraulischen Hubzylinder auf. Durch den Hubzylinder ist es möglich,

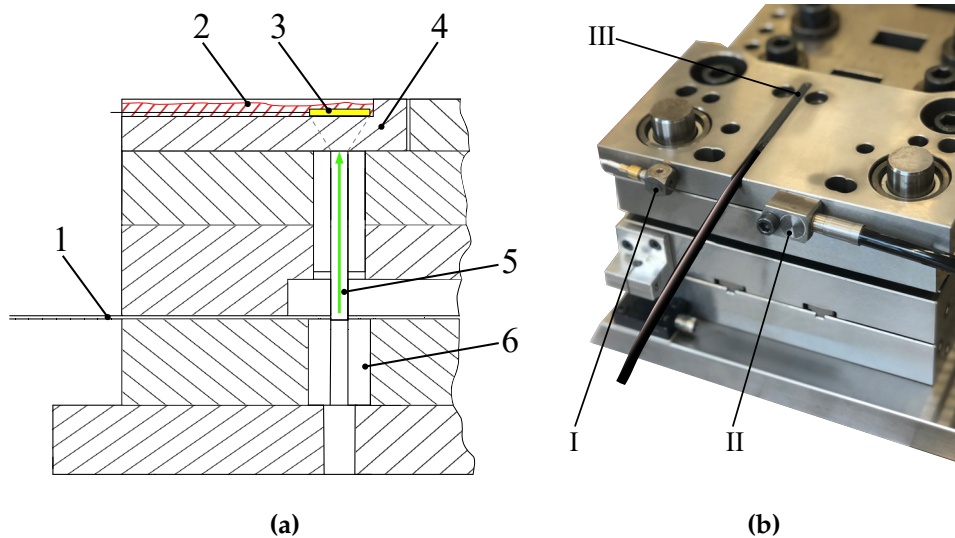


Abbildung 5.2: Sensoren am Schneidwerkzeug, die in dieser Arbeit verwendet werden; (a) Schneidwerkzeug in der Schnittdarstellung; Bandmaterial (1), Kleber (2, rot), Piezosensor (3, gelb), Stempelhalteplattensegment (4), Schneidstempel (5), Schneidplatte (6), Kraftfluss (grün), (b) Schneidwerkzeug mit einem Stempelhalteplattensegment und angebrachten Sensoren; Beschleunigungssensor (I), Körperschallsensor (II), Piezosensor (III)

eine definierte Kraft auf den Schneidstempel aufzubringen und den Schneidprozess zu simulieren. Zur Abstützung des Hubzylinders wird ein zusätzlicher Tisch an der Anlage montiert. Dieser wird durch massive Zuganker mit der Presse verbunden. Zusätzlich richten diese Zuganker den Tisch zum Pressentisch parallel aus. Durch die Konstruktion wird eine minimale Verformung während des Kalibrierungsprozess gewährleistet. Durch die Führung des Messdorns in der Schneidplatte besitzt dieser minimales Spiel. Für den Kalibriervorgang selbst wird der Hubzylinder mit einer steigenden Kraft beaufschlagt. Die entstehenden Signale werden sowohl von der Kraftmessdose als auch vom Piezosensor aufgezeichnet. Die Werte der kalibrierten Kraftmessdose werden genutzt, um einen Kalibrierungsfaktor für den Piezosensor zu ermitteln.

Beschleunigungsmessung

Die Beschleunigungsmessung ermittelt die Beschleunigungswerte des Schneidstempels während des Schneidvorgangs. Das Schneidwerkzeugoberteil bewegt sich durch die Pressenbewegung und Konstruktion als eine Einheit. Deshalb ist es möglich, die Messung an der Außenseite des Stempelhalteplattensegments durchzuführen. Der gewählte Beschleunigungssensor 8616A500 der Firma Kistler besitzt eine vernachlässigbare Masse im Vergleich zum Schneidwerkzeug und beeinflusst daher den Prozess nicht. Der nach dem piezoelektrischen Prinzip aufgebaute Sensor wird mittels Wachs auf der Stempelhalteplatte aufgebracht und zusätzlich gesichert (siehe Abbildung 5.2b). Der bereits kalibrierte Sensor wird direkt an den Datenlogger angeschlossen.




Abbildung 5.3: Erweiterung der Presseneinheit zur Kalibrierung des Kraftsensors im eingebauten Zustand. Das Schneidwerkzeug ist in orange dargestellt; links Einbaulage an der Presse, rechts Schnittansicht durch die Ebene des zu kalibrierenden Schneidstempels. Der rote Rahmen zeigt den zusätzlichen Tisch, der mit massiven Zugankern befestigt ist. Die Detailansicht zeigt die Beaufschlagung des Schneidstempels durch den Hubzylinder. Eine Vergleichskalibrierung wird durch Aufzeichnung der Signale der Kraftmessdose und des Kraftsensors (Piezo) ermöglicht.

Körperschallmessung

Die Messung detektiert Körperschallsignale, die vom Schneidstempel erzeugt werden. Abhängig vom Verschleißzustand der Schneidstempel und den Fertigungsparametern verändern sich die Emissionsbedingungen und veränderte Signale werden vom Sensor aufgezeichnet. Der Sensor wird an die Außenfläche der Stempelhalteplatte montiert (siehe Abbildung 5.2b), wodurch die Steifigkeit des Schneidwerkzeugs nicht beeinflusst wird. Der verwendete piezoelektrischen Sensor 8152A (Firma Kistler) mit dem AE-Piezocoupler 5125A (Firma Kistler) ermittelt das AE-RMS-Signal mit der Zeitkonstante $\tau_{\text{RMS}} = 1,2 \text{ ms}$. Die verbauten Filter erzeugen einen Bandpassfilter im Bereich 50 kHz bis 1000 kHz. Der Sensor übersetzt die entstehenden elastischen Wellen infolge der Schallemissionen in elektrische Spannung. Aufgrund der Verarbeitung zum RMS-Signal wird ausschließlich der zeitliche Verlauf des Sensorsignals dargestellt. Rückschlüsse auf den Frequenzbereich, in denen gewisse Wirkmechanismen erscheinen, sind daher ausgeschlossen, allerdings können relative Unterschiede zwischen den Signalen erkannt werden. Der Sensor wird extern mit Spannung versorgt und direkt an den Datenlogger angeschlossen.

Banddickenmessung

Für die Banddickenmessung wird das System thicknessGauge C.LP 8/200 der Firma Micro-Epsilon verwendet. Dieses System verwendet zwei gegenüberliegende Lasertriangulationssensoren zur Bestimmung der Banddicke. Die Banddickenmessung erfolgt mit einer Genauigkeit von $\pm 0,75 \mu\text{m}$. Das System wird vor dem Richtapparat des Stanzbiegeautomaten montiert. Die Datenaufzeichnung erfolgt im internen Messrechner.

Schnittflächenmessung

Zur Datenaufzeichnung der Schnittfläche wird das in dieser Arbeit vorgestellte Überwachungssystem genutzt. Der Aufnahmeprozess wird, wie in Kapitel 3.2.4 beschrieben, gesteuert.

Eine Aufstellung aller verwendeten Komponenten für das Sensornetzwerk findet sich im Anhang, siehe Tabelle A.6.

Datenaufzeichnung

Zur Datenaufzeichnung werden zwei Datenlogger MX410 der Firma HBM mit einer Abtastrate von 200kHz verwendet. Die beiden Logger werden mittels Ethernet sowohl ans Maschinennetzwerk als auch an einen Messlaptop angeschlossen. Jeweils ein Messkanal für die Kraft-, die Beschleunigungs- und die Körperschallmessung wird verwendet. Ein weiterer Messkanal dient zur Aufnahmesteuerung, die abhängig von der Pressenbewegung erfolgt. Die Zeitpunkte zur Aufnahmesteuerung werden in den Werten des Maschinenwinkels ausgedrückt, siehe Abbildung 5.4. Der untere Umkehrpunkt der Pressenbewegung, der sogenannte untere Umkehrpunkt (UP) bei dem sich der Schneidstempel an seinem tiefsten Punkt befindet, wird bei einem Maschinenwinkel von 90° erreicht.

Als Startbedingung zur Datenaufzeichnung wird ein Triggersignal des Stanzbiegeautomaten zwischen den Maschinenwinkeln 50° bis 110° erzeugt. Das Triggersignal des Stanzbiegeautomaten erfolgt vor dem Aufsetzen des Niederhalters. Die Datensteuerung und -speicherung erfolgen über die Software DIAdem und das DAC-Paket (National Instruments Corp. 2018). Über einen Treiber werden die HBM-Datenlogger eingebunden und zusätzlich auf die Daten des OPC-UA-Servers der Maschine zugegriffen. Wenn ein Trigger-Signal ausgelöst wird, werden die aktuellen Maschinendaten vom OPC-UA-Server angefordert; zusätzlich beginnt die Aufzeichnung über die Datenlogger. Nach Ende des Triggersignals werden die Daten gespeichert. Der Speichervorgang nimmt eine gewisse Zeit in Anspruch, daher ist es nicht möglich, für jeden Hub Datenpakete zu erzeugen. Die größte Datendichte, die mit diesem Aufbau erreicht werden konnte, sind Datenpakete alle 12 Hub. Durch Austausch der Hardware könnte diese Datendichte weiter erhöht werden.

Die Daten des Überwachungssystems werden mit einem separaten Laptop aufgezeichnet. Die Synchronisation der Rechnerzeit orientiert sich an der Maschine. Durch Auslösen des Triggersignals greift ein OPC-UA-Client auf die aktuelle Hubzahl zu. Der Versatz

zwischen der Schneidposition und der Messposition in Höhe von 42 Hub wird von der aktuellen Hubzahl subtrahiert, und die Aufnahme mit dem zugehörigen Zeitstempel und der tatsächlichen Hubzahl gespeichert.

Das Banddickenmesssystem und der mitgelieferte Messcomputer werden ebenfalls synchronisiert und können über die feste Differenz zwischen Messposition und Schneidprozess (299 Hub) zugeordnet werden. Für eine möglichst lückenlose Aufzeichnung der Sensordaten werden diese anhand ihrer Mittelwerte überwacht.

Das aufgebaute Sensornetzwerk am Stanzbiegeautomaten ist in Abbildung 5.4 dargestellt.

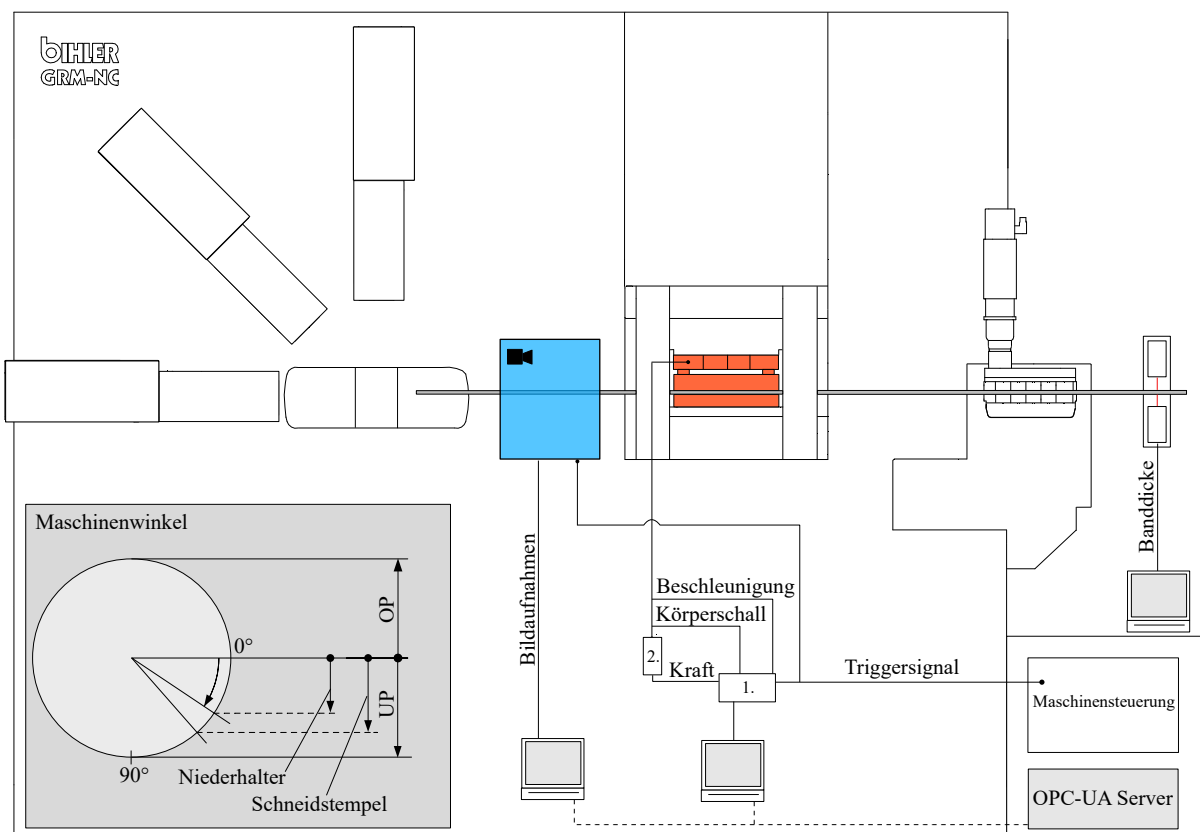


Abbildung 5.4: Ablauf der Datenaufzeichnung im Stanzbiegeautomat. Schaubild des Maschinenwinkels (links) zeigt die einzelnen Prozesszeitpunkte mit den unteren und oberen Umkehrpunkten der Pressenbewegung während des Schneidprozesses. Die übrigen Bereiche zeigen die Anordnung der Sensoren zur Datenaufzeichnung; Datenlogger (1.), Ladungsverstärker (2.), Schneidwerkzeug (orange), Überwachungssystem (türkis).

5.2 Versuchsdurchführung

Während der Versuchsdurchführung werden 200.000 Hub und somit die gleiche Zahl an Schnittflächen pro Schneidstempel produziert. Der Richtapparat wird während der

Versuchsdurchführung ausschließlich zur Führung des Bandmaterials verwendet. Eine Verformung des Materials und Beeinflussung der Materialparameter durch diesen wird somit ausgeschlossen. Die Abdeckung der Messsignale ist in Abbildung 5.5 dargestellt. Für die Versuchsreihe werden zwei Bandmaterial-Coils benötigt.




Abbildung 5.5: Sensorsignale während der durchgeführten Datenaufzeichnung. Einige Signale konnten nicht aufgezeichnet werden (rot).

Trotz der Mittelwertüberwachung konnten keine zuverlässigen Messsignale für die Schneidkraft in den ersten beiden Intervallen aufgezeichnet werden. Als Grund hierfür konnten Kabelbrüche identifiziert werden, die nicht sofort entdeckt werden konnten, da die beobachteten Mittelwerte des fehlerhaften Signals innerhalb der Toleranzgrenzen lagen. Zudem konnte ein Sensorschaden des Beschleunigungssensors zwischen 100.000 Hub bis 150.000 Hub nicht erkannt werden. Der Beschleunigungssensor wurde ab der Hubzahl 150.000 durch den Sensor 8763B2K0AB der Firma Kistler ersetzt.

Zusätzlich führten weitere Maschinenstopps aufgrund von Fehlermeldungen zu Datenlücken, als Grund hierfür ist das Nachfüllen von Betriebsmitteln zu nennen. Weitere Auffälligkeiten sind die unterschiedlichen optischen Charakteristiken unterschiedlicher Bandmaterialcoils. Ein Austausch des Materials bei gleichbleibenden Aufnahmebedingungen führt zu einer veränderten Darstellung, welche auf den Fertigungsprozess des Bandmaterials zurückzuführen ist. Zusätzlich werden unterschiedliche Mittelwerte und Werte der Standardabweichungen der Banddicke je Coil beobachtet (siehe Tabelle 5.2).

Für die abhängige Variable werden alle Daten pro Versuchsintervall aufgezeichnet. Zusätzlich wird für jedes Versuchsintervall eine Kalibrierungskurve für den Kraftsensor erstellt. Insgesamt wurden Daten für 15.000 Bauteile aufgezeichnet. Während der

Versuchsreihe wurde bewusst bis zum Schaden am überwachten Schneidstempel und darüber hinaus produziert. Die Entwicklung des Schadens wird in Abbildung 5.6 gezeigt.




Abbildung 5.6: Aufnahmen durch das Überwachungssystem aus der Versuchsdurchführung. Die Bildunterschrift bezeichnet die jeweilige Hubzahl. Der Schaden an der Schnittfläche entwickelt sich vom rechten Bildrand und ist gekennzeichnet durch die Abnahme des hell erleuchteten Glattschnittanteils.

Tabelle 5.2: Mittelwert und Standardabweichung der Banddicke der verwendeten Bandmaterial-Coils

	Banddicke in μm	Hubzahl	
		von	bis
Coil 1	501,580 \pm 1,568	0	78.840
Coil 2	499,252 \pm 4,017	78.840	200.000

5.3 Vorverarbeitung der Datenmenge

Zur Übersicht werden die folgenden Schritte in Abbildung 5.7 zusammengefasst.

Zur Generierung der Datenmenge für die Modellbildung wurden die aufgezeichneten Daten zunächst manuell gesichtet. Hierzu wurden die Messkurven der Kraft-, der Beschleunigungs- und der Körperschallmessung exportiert. Während des Exports erfolgte ebenfalls die Kalibrierung der Kraftkurve.

Betrachtet man die Messkurven für ein gefertigtes Bauteil (siehe Abbildung 5.8), zeigt sich der zu erwartende Verlauf der Schneidkraftkurve. Ein erster Ausschlag der Kurven wird durch das Aufsetzen des Niederhalters erzeugt. In der Folge werden die Federn zwischen Niederhalter und Führungsplatte komprimiert. Der Schneidstempel setzt

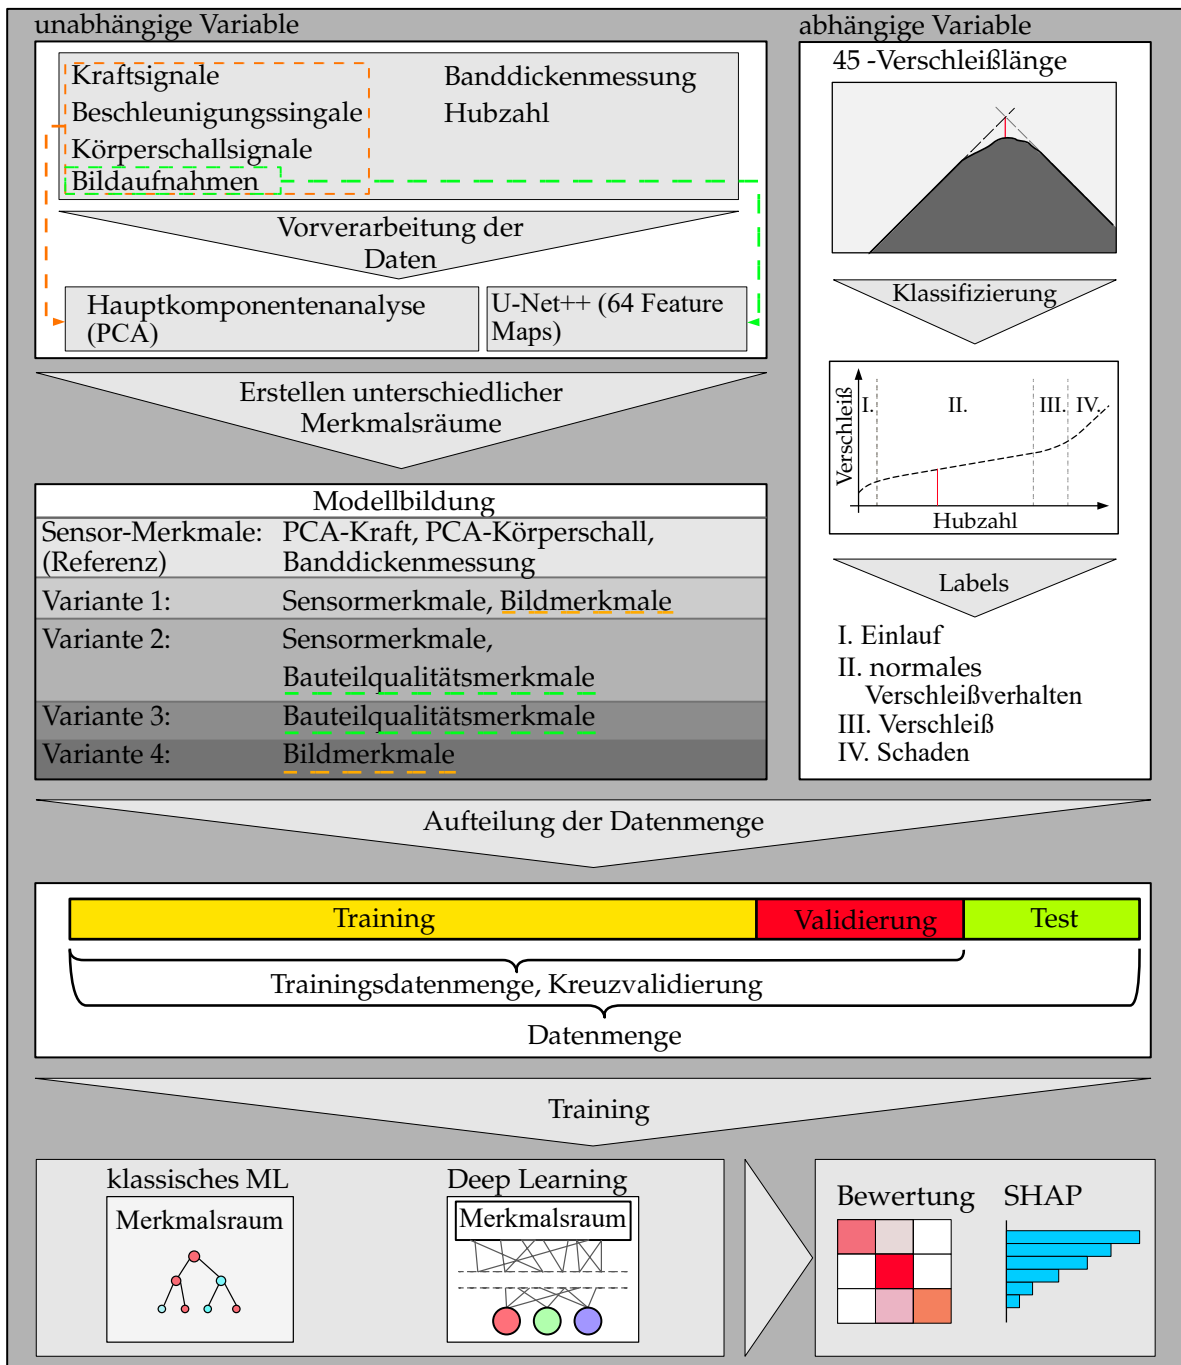


Abbildung 5.7: Übersicht über den angewandten Prozess zur Modellbildung.

auf der Bandoberfläche auf und der Schneidvorgang beginnt. Der Materialabriss führt zu einer starken Änderung und es folgt die Schwingungsphase. Der Abfall wird in die Abfallsicherung bewegt und in dieser verformt. Hieraus ergibt sich der Wiederanstieg der Messkurven. Der Schneidstempel befindet sich im UP, infolgedessen wird der Schneidstempel entlastet. An den Zeitpunkten, an denen der Niederhalter und auch der Schneidstempel auf das Bandmaterial auftreffen, zeigen sich Signale sowohl in der Beschleunigungskurve als auch in der Körperschallkurve. Während des Materialabrisses und der Verformung des Abfalls zeigen diese beiden Kurven erneut Ausschläge.

Die manuelle Sichtung der Messkurven lässt eine veränderte Kraftkurve zu Beginn jedes Fertigungsintervalls erkennen. Die Komponenten der Kraftkurve, die das Einbringen in die Abfallsicherung kennzeichnen, zeigen sich deutlich verändert gegenüber dem vorangegangenen Intervallende. In der Abfallsicherung werden mehrere Abfälle durch plastische Verformung gehalten und somit eine Beschädigung oder Störung des Prozesses durch diese verhindert. Jeder neue Abfall wird von oben auf den Stapel aufgebracht und das komplette Abfallpaket in die Abfallsicherung gedrückt. Hierbei muss der Verformungswiderstand des kompletten Abfallpakets überwunden werden. Durch den Kalibrierungsprozess ist es notwendig, die Abfallsicherung bei jedem Intervallbeginn zu leeren. Je nach Füllgrad der Abfallsicherung variiert daher dieser Kraftanteil in der Messkurve. Hieraus ergibt sich kein Eingriff in den Prozess, vielmehr wird die Realität abgebildet. Wenn ein Schneidwerkzeug überholt wird, wird ebenfalls die Abfallsperre geleert.

Weiterhin zeigt sich, dass der Schneidprozess mit Aufsetzen des Niederhalters und dem Durchdrücken des Abfalls aufgenommen wurde, der Rückhub jedoch nicht. Dies sollte in weiteren Versuchen berücksichtigt werden, da wichtige Daten im Rückhub liegen.

5.3.1 Vorverarbeitung der unabhängigen Variablen

Die Messdatenaufnahme wird vor dem Aufsetzen des Niederhalters gestartet und nach dem Eindrücken des Abfalls gestoppt. Diese Bereichsgröße wurde aus Sicherheitsgründen gewählt. Allerdings beinhalten die Daten somit Messwerte, die nicht relevant für den Schneidprozess sind. Die Daten werden daher auf die den Schneidstempel betreffenden Menge reduziert (siehe Abbildung 5.8; roter Rahmen). Die Menge beinhaltet Messwerte zwischen den Zeitpunkten kurz bevor der Schneidstempel das Bandmaterial berührt und kurz nach dem UP des Schneidstempels. Für jedes Signal ergeben sich auf diese Weise 5300 Messpunkte.

5.3.2 Vorverarbeitung der abhängigen Variable

Im Folgenden werden nur die Werte des mit dem Aufnahmesystem überwachten Schneidstempels dargestellt. Die während der Versuchsreihe ermittelten Werte für die 45°-Verschleißlänge, die Kantenlänge der Ausstanzung und die Glattschnitthöhe werden in Abbildung 5.9 zusammengefasst. Am Verlauf der Werte ist eine Veränderung ab 75.000 Hub zu erkennen. Die Standardabweichung der Verschleißlänge nimmt ab diesem Zeitpunkt zu und deren Werte steigen an. Bei 200.000 Hub zeigt sich eine Absenkung.




Abbildung 5.8: Messkurven der Kraftmessung (blau), Körperschallmessung (grün) und der Beschleunigungsmessung (orange) für ein Bauteil. Die roten Rahmen kennzeichnen den weiterverwendeten Datenbereich für die Hauptkomponentenanalyse (engl. Principal Component Analysis) (PCA). Weitere Zeitpunkte: Aufsetzen des Niederhalter (I), Aufsetzen des Schneidstempels (II), Verformung des Abfalls (III), Rückzug des Schneidstempels (IV)

Berücksichtigt man zusätzlich die Daten der Kantenlänge der Ausstanzung und der Glattschnitthöhe zeigen sich ebenfalls Veränderungen in diesen Intervallen. Die Zunahme der Standardabweichung der 45° -Verschleißlänge bei 150.000 Hub macht deutlich, dass mindestens eine Schneidkante einen Ausbruch aufweist. Dies wird auch durch die Mikroskop-Aufnahmen bestätigt.

Anhand der gezeigten Daten ist keine genaue Einordnung in Verschleißzustände möglich, da zwischen den einzelnen Messpunkten eine zu hohe Anzahl an Hübem liegt. Eine manuelle Sichtung der Aufnahmen aus dem Überwachungssystem unter Berücksichtigung der Daten ermöglicht dies. Eine automatisierte Bestimmung der Entwicklung der Glattschnitthöhe durch das Netzwerk *U-Net++-64-Features Maps* ist aufgrund der reduzierten Auflösung nicht möglich. Die Aufnahmen werden daher manuell gesichtet und bewertet. Dies ist wiederum nur möglich, weil die Schadstelle direkt an der überwachten Stelle auftrat.

Die Klassifizierung für die Modellbildung erfolgt in die Klassen *Einlauf*, *normales Schneidverhalten*, *Verschleiß* und *Schaden*. Die bekannten Verschleißklassen (siehe Kapitel 2.1.5) werden durch die Klasse *Verschleiß* erweitert. Die Klasse enthält Daten, bei denen sich




Abbildung 5.9: Entwicklung einzelner Messgrößen infolge des Verschleißes über die Lebensdauer des Schneidstempels; 45°-Verschleißlänge (blau), Kantenlänge der Ausstanzung (grün), Glattschnitthöhe (rot). Die Verbindungslinien der Messpunkte dienen zur Darstellung.

ein Verschleiß deutlich abzeichnet, aber noch kein Schaden vorliegt. Als *Schaden* wird in diesem Kontext eine unwiderrufliche Deformierung der Schneidkante angesehen. Das ist beispielsweise bei einem Stempelbruch der Fall. Ziel der Klasse *Verschleiß* ist eine frühzeitige Erkennung einer Entwicklung hin zum Schaden. Die Schneidkante ist in diesem Stadium noch produktionsfähig, degradiert aber zunehmend. Durch die frühzeitige Erkennung entsteht ein größeres Prozessfenster für die Einleitung von Maßnahmen, beispielsweise die Einplanung von Instandsetzungen. Weiterhin steigt die Möglichkeit, den Schneidstempel durch einen Schleifvorgang zu überarbeiten, anstatt ihn im Schadensfall komplett auszutauschen. Die vorgenommene Klassifizierung der Daten ist in Tabelle 5.3 zu sehen. Diese ist durch die manuelle Sichtung mit Expertenwissen versehen. Einige der Merkmale jeder Klasse sind zur Orientierung aufgeführt.

Obwohl 200.000 Hub aufgenommen wurden, wird der Datensatz auf 175.000 Hub reduziert. Zum einen zeigt sich ein Abfall der Werte der 45°-Verschleißlänge nach 175.000 Hub. Daher wird davon ausgegangen, dass die Stempelmantelfläche über die gesamte Eingriffstiefe verschlissen ist und der Abfall der Werte dadurch verursacht wird. Eine Betrachtung der Schneidstempelmantelfläche bestätigt dies, siehe Abbildung 5.10. Die

Tabelle 5.3: Einteilung der Klassen des Verschleißverhaltens. Die Merkmale beziehen sich unter anderem auf die visuelle Begutachtung der Bildaufnahmen der Schnittfläche.

Klasse	Merkmale	von	bis
Einlauf	gleichmäßige Struktur der Glattschnittfläche	0	10.000
Normales Schneidverhalten	gleichmäßige Struktur der Glattschnittfläche	10.000	50.000
Verschleiß	erhöhter Verschleiß, höhere Standardabweichungen, unregelmäßigkeiten in den Aufnahmen	50.000	90.000
Schaden	unwiderruflicher Schaden, unvollständige Glattschnittfläche	90.000	175.000

genaue Hubzahl zu diesem Ereignis kann allerdings nicht festgestellt werden, daher wird anhand der Messwerte eine Teilung des Intervalls 150.000 Hub bis 200.000 Hub durchgeführt. Zusätzlich müssen die Daten der Klasse *Einlauf* entfernt werden, da in diesem Bereich keine Werte zu Kraftmessung vorhanden sind. Diese Reduzierungen führen zusätzlich zu einer uniformen Verteilung der Klassen.

Der Sensorausfall des Beschleunigungssensors bewegt sich nahe an der Grenze zwischen den Klassen *Verschleiß* und *Schaden*. In der Modellbildung besteht daher das Risiko einer Anpassung an diesen Ausfall. Im Folgenden werden die Beschleunigungsdaten aus den Daten ausgeschlossen, um diese Fehlerquelle zu vermeiden.

5.3.3 Datenreduzierung

Bei Verwendung aller unverarbeiteten Daten ergibt sich ein Merkmalsraum von 1,06 Mio Werten pro Bauteil (je 5300 für die Kraft-, Beschleunigungs- und Körperschallmessung, 1024×1024 Pixel für die Bildaufnahme, Banddickenmessung, Hubzahl). Dieser hochdimensionale Merkmalsraum erschwert die Auswahl als auch das Training der Modelle. Für ein effizientes Training muss die Anzahl der Merkmale auf geeignete Weise reduziert werden.

Zusätzlich werden zur Bewertung des Informationsgehaltes der unterschiedlichen Daten fünf Trainingsdatensätze, im Folgenden Merkmalsräume genannt, erstellt. Die Aufteilung erfolgt in Merkmalsräume aus den Sensordaten (Kraft-, Beschleunigungs- und Körperschallmessung zuzüglich der Daten der Banddickenmessung), den Bilddaten und den Bauqualitätsdaten. Zusätzlich werden die Kombinationen aus den Sensordaten und

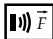


Abbildung 5.10: Schneidstempel am Ende seiner Lebensdauer (200.000 Hub). Der Verschleiß ist über die komplette Eingrifftiefe ersichtlich (rote Rahmen).


den Bilddaten, als auch den Sensordaten und den Bauteilqualitätsdaten betrachtet. Die einzelnen Merkmalsräume unterscheiden sich durch die jeweilige Datenvorverarbeitung und ermöglicht Bewertung des Informationsgehalts bezüglich der Verschleißklassifizierung.


Merkmalsräume

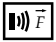

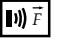

Im Folgenden wird die Zusammensetzung der jeweiligen Merkmalsräume und deren Datenreduzierung beschrieben. Zur visuellen Zuordnung erhalten die Merkmalsräume jeweils ein Piktogramm.

Sensormerkmale Dieser Merkmalsraum wird als Referenz für die Modellbildung herangezogen und orientiert sich zum einen an den Ergebnissen von Kubik et al. (Kubik, Knauer et al. 2022; Kubik, Becker et al. 2022) zum anderen am Stand der Technik (siehe Kapitel 2.4). Die Daten der Kraft- und der Körperschallmessung werden mittels Hauptkomponentenanalyse (engl. Principal Component Analysis) (PCA) reduziert. Hierbei wird der Schwellwert 99 % der kumulierten Varianz gewählt. Dies reduziert die Merkmalsanzahl für die Kraftmessung auf 36 von vorher 5300 Merkmalen und für die Körperschallmessung auf 406 von ehemals 5300 Merkmalen. Die Merkmale *Banddicke* und *Hubzahl* werden nicht angepasst, da es sich jeweils um Einzelwerte handelt. Da allerdings nur eine Versuchsreihe zur Verfügung steht und eine starke Korrelation zwischen der *Hubzahl* und den tatsächlichen Klassifizierungen herrscht, muss dieses Merkmal ausgeschlossen werden. Falls ein Training mit mehreren Versuchsreihen vollzogen wird, sollte dies erneut bewertet werden. Der Merkmalsraum der Sensormerkmale reduziert sich somit von 10.601 Merkmalen auf 443 Merkmale. Zusammengefasst werden diese Merkmale unter dem Begriff *Sensormerkmale* .

Bauteilqualitätsmerkmale Inwieweit die Daten der in der Richtlinie *VDI 2906 Blatt 2* definierten Maße der Bauteilqualität Informationen über den Verschleiß beinhalten, wird

mit diesem Merkmalsraum überprüft. Hierzu werden die Aufnahmen aus dem Überwachungssystem durch das entwickelte Netzwerk *U-Net++-64-Features Maps* verarbeitet und auf deren Basis die Größe der jeweiligen Glattschnittfläche und der jeweiligen gemittelten Glattschnitthöhe ermittelt. Zusätzlich werden die Anzahl der Glattschnittflächen, die Länge des größten Glattschnittanteils und die Verteilung zwischen Hintergrundpixel und Segmentierung berücksichtigt. Die so reduzierten Daten werden mittels ihrer Hubzahl zugeordnet und als *Bauteilqualitätsmerkmale*  bezeichnet.

Bildmerkmale Da die definierten Qualitätsmaße die Aufnahmedaten stark reduzieren und auch verschleißbestimmende Informationen durch diese ausgeschlossen werden können, wird ein zweiter Merkmalsraum auf Basis der Bilddaten erstellt. Zunächst wird die Bildgröße auf 256×256 Pixel reduziert und somit eine vergleichbare Datenmenge für beide Merkmalsräume gewählt. Nachfolgend wird zur Datenreduzierung der Bildaufnahmen ebenfalls die PCA angewendet. Als Schwellenwert der Eigenbilder, die berücksichtigt werden, werden 90 % der kumulierten Varianz gewählt, was einer Beschränkung auf die ersten 2087 Merkmale/Eigenbilder entspricht. Dieser Merkmalsraum wird im Folgenden als *Bildmerkmale*  bezeichnet.

Weitere Merkmalsräume Zusätzlich werden Kombinationen der eingeführten Merkmalsräume erstellt. Für eine Bewertung, inwieweit die bestehenden Methoden durch die Bildmerkmale oder Bauteilqualitätsmerkmale verbessert werden, werden die Merkmalsräume *Sensormerkmale und Bildmerkmale*  +  und *Sensormerkmale und Bauteilqualitätsmerkmale*  +  erstellt.

5.4 Modellbildung

Zur Modellbildung werden sowohl klassische Algorithmen des maschinellen Lernens als auch neuronale Netze untersucht. Zum einen wird die erreichbare Prognosegüte untersucht. Zum anderen wird untersucht, welche Merkmale den größten Informationsgehalt mit Blick auf den Verschleißklassifizierung aufweisen. Hierzu werden die SHAP-Werte der trainierten Modelle untersucht. Implementiert werden Training und die Optimierung der jeweiligen Modelle in Python (Van Rossum et al. 2009). Für die klassischen Methoden des maschinellen Lernens wird die Bibliothek *PyCaret* (Ali 2022) genutzt. Unter anderem sind hierin die Modelle Logistic Regression, Light Gradient Boosting, Ada Boosting Classifier, Random Forest Classifier, Support Vector Machine, Decision Tree Classifier implementiert.

Für die tiefen neuronalen Netzwerke werden Modelle in PyTorch (Paszke et al. 2019) aufgebaut. Es werden jeweils neuronale Netzwerke mit zwei, drei und vier Schichten aufgebaut. Die Vorgehensweise für das Training und die Optimierung setzt sich aus mehreren Einzelschritten zusammen, die für jeden Merkmalsraum separat durchlaufen werden. Zunächst wird ein Merkmalsraum für das jeweilige Experiment ausgewählt, die jeweiligen Merkmale normalisiert und die klassischen Methoden des maschinellen Lernens trainiert und bewertet. Als Nächstes wird eine Optimierung der Hyperparameter

der neuronalen Netzwerke durchgeführt. Hierbei werden für die drei Netzwerkarchitekturen jeweils die Parameter der Filtergrößen, die Learning-Rate (LR) und die Dropout-Rate optimiert. Für jede Netzwerkarchitektur werden 40 Konfigurationen geprüft. Die gesammelten Hyperparameterkonfigurationen sind in Tabelle 5.4 aufgeführt. Nachfolgend wird die jeweils beste Konfiguration der Hyperparameter ausgewählt und für 50 Epochen trainiert. Für jedes Modell werden die Accuracy, der Recall und die area under the curve (AUC) der ROC-Kurve bestimmt, siehe Kapitel 2.2.5. Weiterhin werden eine Konfusionsmatrix und ein SHAP-Diagramm erstellt (siehe Kapitel 2.2.6).

Tabelle 5.4: Untersuchte Hyperparameter für die neuronalen Netzwerke

Architekturen	2 Schichten (L2), 3 Schichten (L3), 4 Schichten (L4)
Filtergrößen	32, 64, 128, 256, 512, 1024, 2048
Dropout-Rate	0,2, 0,4
Learning-Rate (LR)	$1 \cdot 10^{-3}$ bis $1 \cdot 10^{-6}$
Epochen	50
Anzahl der getesteten Konfigurationen pro Schicht	40

Für die Trainingsdatenmenge (Training und Validierung) werden 90 % der Daten verwendet. Diese teilen sich erneut in 80 % Trainings- und 20 % Validierungsdaten auf. Zusätzlich wird eine fünffache Kreuzvalidierung durchgeführt. Die vorgestellten Werte basieren auf den Testdaten.

5.5 Evaluierung der Modelle

5.5.1 Sensormerkmale (Referenz)

Die Ergebnisse in Tabelle 5.5 zeigen einen Accuracy-Score von 99,75 % für die klassischen Modelle (Light Gradient Boosting Maschine). Die Ergebnisse aus den optimierten neuronalen Netzwerken zeigen sich vergleichbar. Die Parameter des verwendeten neuronalen Netzes sind in Tabelle 5.5 aufgeführt und beruhen auf der Hyperparameter-Optimierung. Im Diagramm der SHAP-Werte werden die 20 einflussreichsten Merkmale gezeigt (siehe Abbildung 5.11). Hierbei besitzen die Kraft-Eigenvektoren den größten Einfluss auf die Prognose. Die *Banddicke* zeigt ebenfalls einen deutlichen Einfluss. Körperschallmerkmale werden ebenfalls aufgeführt, besitzen aber einen geringen Einfluss. Anhand der Konfusionsmatrix zeigt sich, dass die größte Ungenauigkeit durch die Klasse *Schaden* entsteht.

Tabelle 5.5: Ergebnisse zum Merkmalsraum *Sensormerkmale*

Model	Accuracy	AUC	Recall
Light Gradient Boosting Machine	0,9875	0,9995	0,9875
neuronaales Netzwerk 4 Schichten	0,9870	0,9988	0,9872

Konfiguration des CNN: dropout=0,4; l1=512; l2=1024; l3=128; l4=128; lr=0,026

Einflussreiche Merkmale anhand des SHAP-Werts
 Kraft-Eigenvektor 0, Kraft-Eigenvektor 5, Banddicke,
 Kraft-Eigenvektor 6, Kraft-Eigenvektor 1,
 Kraft-Eigenvektor 2




Abbildung 5.11: SHAP-Werte und Konfusionsmatrix für die Light Gradient Boosting Machine trainiert auf dem Merkmalsraum *Sensormerkmale*.

Im Folgenden wird auf die vollständige Darstellung der SHAP-Diagramme verzichtet, stattdessen werden nur noch die Merkmale mit den höchsten SHAP-Werten gezeigt. Zusätzlich ist zu erwähnen, dass die Reihenfolge der SHAP-Werte zwischen den klassischen

Algorithmen und den neuronalen Netzwerken größtenteils übereinstimmt.

5.5.2 Sensormerkmale und Bildmerkmale $\bar{F} + \text{PCA}$

Die Ergebnisse für den Merkmalsraum *Sensormerkmale und Bildmerkmale* in Tabelle 5.6 zeigen einen Accuracy-Score von 99,45 % für die klassischen Algorithmen des maschinellen Lernens. Im Vergleich zum Merkmalsraum der *Sensormerkmale* ergibt dies eine Steigerung um 0,7 Prozentpunkte. Die SHAP-Werte in Abbildung 5.12 enthalten größtenteils Bild-Eigenvektoren, zusätzlich wird die *Banddicke* berücksichtigt. In der Konfusionsmatrix zeigt sich eine erhöhte Genauigkeit für die Klasse *Schaden* im Vergleich zum Merkmalsraum der *Sensormerkmale*.

Tabelle 5.6: Ergebnisse zum Merkmalsraum *Sensormerkmale und Bildmerkmale* $\bar{F} + \text{PCA}$

Model	Accuracy	AUC	Recall
Logistic Regression	0,9945	0,9996	0,9945
neuronales Netzwerk 3 Schichten	0,9901	0,9994	0,9901

Konfiguration des CNN: dropout=0,2, l1=2048, l2=2048, l3=64, lr=0,0003

Einflussreiche Merkmale anhand des SHAP-Werts
 Bild-Eigenvektor 1, Bild-Eigenvektor 6,
 Bild-Eigenvektor 0, Bild-Eigenvektor 5,
 Bild-Eigenvektor 4, Bild-Eigenvektor 3,
 Bild-Eigenvektor 12, Banddicke, Kraft-Eigenvektor 0



Abbildung 5.12: SHAP-Werte und Konfusionsmatrix für die Logistic Regression trainiert auf dem Merkmalsraum *Sensormerkmale und Bildmerkmale*.

5.5.3 Sensormerkmale und Bauteilqualitätsmerkmale +

In Tabelle 5.7 werden die Ergebnisse für den Merkmalsraum der *Sensormerkmale und Bauteilqualitätsmerkmalen* dargestellt. Die Ergebnisse sind vergleichbar mit denen der *Sensormerkmale*. Dies ist anhand der Betrachtung der SHAP-Werte (siehe Abbildung 5.13) nachvollziehbar. Auch wenn die Reihenfolge nicht identisch ist, zeigen dieselben Merkmale die höchsten SHAP-Werte. Hieraus kann geschlossen werden: Die in dieser Auswertung verwendeten Bauteilqualitätsmerkmale besitzen keinen signifikanten Einfluss auf die Prognosegüte.

Tabelle 5.7: Ergebnisse zum Merkmalsraum *Sensormerkmale und Bauteilqualitätsmerkmale*



Model	Accuracy	AUC	Recall
Light Gradient Boosting Machine	0,9875	0,9995	0,9875
neuronaales Netzwerk 4 Schichten	0,9901	0,9994	0,9901

Konfiguration des CNN: dropout=0,4, l1=2048, l2=2048, l3=2048, l4=64 , lr=0,0005

Einflussreiche Merkmale anhand des SHAP-Werts

Kraft-Eigenvektor 0, Kraft-Eigenvektor 5, Banddicke,
Kraft-Eigenvektor 6, Kraft-Eigenvektor 1,
Kraft-Eigenvektor 2




Abbildung 5.13: SHAP-Werte und Konfusionsmatrix für die Light Gradient Boosting Machine trainiert auf dem Merkmalsraum *Sensormerkmale und Bauteilqualitätsmerkmale*.

5.5.4 Bauteilqualitätsmerkmale

Die oben getroffene Aussage wird zusätzlich durch ein Training ausschließlich mit den Bauteilqualitätsmerkmalen bestätigt (siehe Tabelle 5.8). Es kann kein Modell erstellt,

das eine verwendbare Prognosegüte erzeugt. Sowohl von den klassischen Algorithmen des maschinellen Lernens als auch von den neuronalen Netzen wird ein Accuracy-Score von 49 % erreicht. Folglich liegen innerhalb der Bauteilqualitätsmerkmale wenige Informationen zur Verschleißbestimmung vor.

Tabelle 5.8: Ergebnisse zum Merkmalsraum *Bauteilqualitätsmerkmale* 

Model	Accuracy	AUC	Recall
Logistic Regression	0,4979	0,3814	0,3388
neuronales Netzwerk 4 Schichten	0,5065	0,3498	0,3358

5.5.5 Bildmerkmale

Aus den SHAP-Werten des Merkmalsraums *Sensormerkmale und Bildmerkmale* geht ein erhöhter Einfluss der Bildmerkmale hervor. Der Einfluss der Bildmerkmale allein auf die Prognosegüte soll daher geprüft werden. Tabelle 5.9 zeigt die Ergebnisse der Modellbildung. Sowohl klassische Modelle des maschinellen Lernens als auch die neuronalen Netze erreichen vergleichbare Ergebnisse. Der erreichbare Accuracy-Score 99,07 % liegt 0,32 Prozentpunkte über dem der *Sensormerkmale* und im Vergleich zum Merkmalsraum *Sensor- und Bildmerkmale* um 0,38 Prozentpunkte niedriger. Die SHAP-Werte in Abbildung 5.14 zeigen ebenfalls Übereinstimmungen zu diesem Merkmalsraum. Aus der hohen Prognosegüte und den SHAP-Werten wird daher abgeleitet, dass die Koeffizienten der Bildeigenvektoren einen vergleichbaren Anteil an Informationen über Verschleiß enthalten.

Tabelle 5.9: Ergebnisse zum Merkmalsraum *Bildmerkmale* 

Model	Accuracy	AUC	Recall
Logistic Regression	0,9907	0,9995	0,9907
neuronales Netzwerk 4 Schichten	0,9870	0,9988	0,9872

Konfiguration des CNN: dropout=0,4, l1=512, l2=128, l3=2048, l4=32, lr=4e-05

Einflussreiche Merkmale anhand des SHAP-Werts

Bild-Eigenvektor 1, Bild-Eigenvektor 6,
Bild-Eigenvektor 0, Bild-Eigenvektor 5,
Bild-Eigenvektor 4

5.6 Diskussion der Ergebnisse

Die Ergebnisse zeigen, dass eine Klassifizierung des Verschleißzustandes des Schneidstempels mittels maschinellen Lernens möglich ist. Dabei weisen die Untersuchungen




Abbildung 5.14: SHAP-Werte und Konfusionsmatrix für die Logistic Regression trainiert auf dem Merkmalsraum *Bildmerkmale*.

einen Accuracy-Score von bis zu 99,45 % auf. Die Ergebnisse der klassischen Algorithmen des maschinellen Lernens wie auch der neuronalen Netze sind sehr ähnlich und unterscheiden sich im Mittel um 0,15 Prozentpunkte. Zusätzlich zeigen die SHAP-Werte der einzelnen Merkmalsräume eine hohe Informationsdichte hinsichtlich der Verschleißklassifizierung sowohl in den *Bildmerkmalen* als auch in den *Sensormerkmalen*. Innerhalb der abgeleiteten Merkmale der Bauteilqualität konnten keine Informationen zur Verschleißklassifizierung erlernt werden. Die in dieser Arbeit getroffene Annahme, dass die aktuellen Richtlinien VDI 2906 Blatt 2 zur Qualitätsbestimmung nicht ausreichend zur Verschleißbeurteilung sind, kann anhand der Ergebnisse bestätigt werden. Konkret liegen die Ergebnisse der *Bildmerkmale* bezogen auf den Accuracy-Score um 0,32 Prozentpunkte über dem Wert der *Sensormerkmale*, im Vergleich zum Merkmalsraum *Sensor- und Bildmerkmale* hingegen um 0,38 Prozentpunkte niedriger.

Die Bildmerkmale werden mittels PCA erstellt und Visualisierungen der hieraus entstehenden Eigenbilder sind möglich. Anhand der generierten SHAP-Werte zeigen diese Eigenbilder einen hohen Informationsgehalt mit Blick auf die Verschleißklassifizierung. In Abbildung 5.15 wird eine Auswahl von Eigenbildern dargestellt. Die hellen Bereiche in den Bildern zeigen Bereiche hoher Varianz. Anhand der Aufnahmen ist ersichtlich, dass vor allem die Übergangsbereiche zwischen den einzelnen Kenngrößen Informationen über den Verschleißzustand enthalten. Der durch die Expertenbefragung in Kapitel 4.1 vorgeschlagene Annahme, den Verlauf der Übergänge über die Länge der betrachteten Glattschnittfläche zu bewerten, wird hiermit bestätigt.

Setzt man die gestiegene Prognosegüte durch die Sensormerkmale in Relation zu den konstruktiven Aufwänden, zeigt sich das Überwachungssystem, auf dem die Bildmerkmale beruhen, als vorteilhaft. Das Überwachungssystem ist anlagenspezifisch, während der Einbau von Sensorik Schneidstempel-spezifisch ist: Für jedes Schneidwerkzeug werden pro Schneidstempel alle Sensoren benötigt. Das Überwachungssystem kann




Abbildung 5.15: Eigenbilder der durch die Hauptkomponentenanalyse (engl. Principal Component Analysis) (PCA) reduzierten Bildaufnahmen. (I) zeigt den Bereich der Glattschnittfläche, (II) den Bereich der Bruchfläche (a) Bild-Eigenvektor 0 (b) Bild-Eigenvektor 5 (c) Bild-Eigenvektor 1 (d) Bild-Eigenvektor 6

hingegen mehrere Schneidwerkzeuge abdecken.

5.7 Zusammenfassung

In diesem Kapitel wurde der Aufbau eines Sensornetzwerks zur Überwachung des Schneidprozesses an einem Stanzbiegeautomat dargelegt. Die aufgezeichneten Messsignale sind die Schneidstempelkraft, die Beschleunigung des Schneidstempels und der infolge des Schneidprozesses emittierte Körperschall. Zusätzlich werden Daten des Überwachungssystems und der Banddicke im Prozess erfasst. Die Zuordnung der Daten erfolgt durch die jeweilige Hubzahl. Anschließend wurde eine Versuchsreihe zur Aufzeichnung der beschriebenen Datenmenge über die Lebensdauer eines Schneidstempels durchgeführt. Die Schneidstempel wurden bewusst bis zum Ende ihrer Lebensdauer verwendet. Die aufgezeichnete Datenmenge enthält daher Daten zur Entwicklung schadhafte Zustände unter industrienahen Bedingungen. Zur tatsächlichen Bestimmung des Verschleißes wurden die Schneidstempel zu definierten Zeitpunkten demontiert und vermessen.

Nachfolgend erfolgte anhand einer Datenvorverarbeitung die Klassifizierung des Verschleißzustands zur jeweiligen Hubzahl. Weiterhin wurde die Datenreduzierung mittels PCA gezeigt. Die durch einen Sensorschaden verzerrten Daten der Beschleunigungsmessung wurden ausgeschlossen. Zur Modellbildung wurden unterschiedliche Merkmalsräume erstellt. Als Referenz diente ein Merkmalsraum, der aus den PCA-Komponenten der Kraft- und Körperschallmessung und dem Banddicken-Merkmal besteht. Zusätzlich wurde ein Merkmalsraum aus Maßen zur Bauteilqualität und aus den Bildaufnahmen mittels PCA erstellt. Diese Merkmalsräume durchliefen die Modellbildung. Es zeigte sich, dass der Verschleißzustand mit einer Accuracy von maximal 99,45 %, bezogen auf die vorliegende Datenmenge, bestimmt werden kann. Durch die Ermittlung der SHAP-Werte der Modelle wurde der jeweilige Merkmalseinfluss abgeleitet. Besonders die Merkmale der Bildaufnahme und aus den Sensormerkmalen wiesen eine hohe Gewichtung auf. Den Merkmalen der Bauteilqualität wurde keine Korrelation zugesprochen. Abschließend wurden aus den Eigenbildern, die aus der PCA der Bildaufnahmen stammen, die einflussreichsten Bereiche auf die Verschleißbestimmung analysiert. Es zeigte sich, dass vor allem die Übergänge der Glattschnittfläche berücksichtigt werden. Bezogen auf den konstruktiven und finanziellen Aufwand erscheint ein Merkmalsraum, der ausschließlich auf den Bildmerkmalen basiert, als vorteilhaft.

Vor diesem Hintergrund sollten weitere Versuchsreihen durchgeführt werden, um die in der vorliegenden Arbeit gezeigten Ergebnisse zu bestätigen. Ebenso ist dabei der Merkmalseinfluss erneut zu prüfen, wenn Daten aus dem Beschleunigungssensor vorliegen. Weiterhin ist zu analysieren, inwieweit sich der Einfluss der Merkmale zur Feststellung der Bauteilqualität ändert, wenn diese in höherer Genauigkeit vorliegen. Bedingt durch die verwendbare Auflösung mussten skalierte Bilddaten verwendet werden. In der Folge wurde mit den Merkmalen der Bauteilqualität eine geringe Genauigkeit erreicht.

Zusammenfassung und Ausblick

6.1 Zusammenfassung

Die aufgeführten Herausforderungen für produzierende Unternehmen innerhalb der Scherschneidtechnik zeigen, dass eine kundenorientierte Fertigung mit maßgeschneiderten Bauteilen gefordert ist. Zusätzlich sind diese Anforderungen mit einem steigenden Kostendruck am Markt zum Erhalt der Wettbewerbsfähigkeit verbunden. Hierzu muss die traditionelle Massenproduktion angepasst und auf eine innovative Prozessführung ausgerichtet werden, um zusätzlich auf die immer kürzer werdenden Durchlaufzeiten bei mindestens gleichbleibenden oder steigenden Qualitätsanforderungen zu reagieren. Angesichts dieser Herausforderungen und dem hochdimensionalen Parameterraum stoßen Prozessführung, die auf Expertenwissen oder Trial-and-Error-Methoden beruhen an ihre Grenzen. Datenbasierte Verfahren ermöglichen den Ersatz der bisherigen Methoden und eine Steigerung der Ressourceneffizienz. Von zentraler Bedeutung für diese Verfahren ist eine fundierte Datenbasis. Für den in dieser Arbeit betrachteten Prozess des Scherschneidens werden die aktuellen Methoden zur Qualitäts- und Verschleißbewertung aufgezeigt, die zur Erstellung einer solchen Datenbasis genutzt werden können. Diese Verfahren bestimmen die Bauteilqualität derzeit allerdings nur indirekt oder nicht innerhalb der Zykluszeit des Fertigungsprozesses und führen zu unterschiedlichen Datendichte zwischen Fertigungsparametern und Qualitätsparametern.

Ziel dieser Arbeit ist es, diesen Befund mit Verfahren zur Qualitäts- und Verschleißbestimmung mithilfe von datengetriebenen Methoden zu erweitern. Zunächst wird der Ausgangspunkt der Arbeit im Stand der Technik zum Scherschneiden und die Methoden der bisherigen Qualitäts- und Verschleißbestimmung dargelegt. Als Qualitätsmaß für Bauteile werden die Schnittflächenkenngrößen, im Besonderen der Glattschnittanteil, identifiziert. Die für die Bauteilqualität maßgeblichen Prozessgrößen werden analysiert und aktuelle Kriterien zur Bewertung anhand des Schneidstempelverschleißes dargelegt. Diese Arbeit verfolgt den Ansatz, mittels einer Inline-Überwachung der Schnittflächenkenngrößen eine breitere Datenbasis für datengetriebene Methoden zu ermöglichen. Die Überwachung besteht hierbei aus einer optischen Überwachungseinheit mit nachgeschalteter Bildverarbeitung zur Bewertung der Bauteilqualität. Hierzu und auch zu den Methoden des maschinellen Lernens werden Grundlagen im Stand der Technik dargelegt.

In Kapitel 3 wird die Funktionsweise eines optischen Überwachungssystems und der zugehörigen automatisierten Bildverarbeitung untersucht. Der gewählte Ansatz einer Kamera, die Bildaufnahmen und Aufnahmen eines Lichtschnittverfahrens vereint, wird

anhand von Testaufnahmen und einer Verifizierung bestätigt. Am Beispiel der Glattschnitthöhe wird eine automatische Segmentierung einer Schnittflächenkenngröße mittels Aktiver Konturen gezeigt. Die Bestimmung dieses Parameters ist mit einer Genauigkeit von $\pm 5 \mu\text{m}$ möglich, allerdings verhindert die notwendige Prozesszeit eine Überwachung im Fertigungsprozess. Zusätzlich wird ein Konzept zur Flächenrekonstruktion der Schnittfläche durch ein Lichtschnittverfahren erstellt. Eine erste Fallstudie an einem Stanzbiegeautomaten zeigt den potenziellen Mehrwert des Überwachungssystems.

In Kapitel 4 folgt die Untersuchung zur automatisierten Segmentierung des Glattschnittanteils mittels neuronaler Netzwerke. Zunächst wird eine Datenmenge als Grundlage für die Modellbildung geschaffen. Bildaufnahmen, die während einer Versuchsreihe durch das Überwachungssystem aufgenommen wurden, werden hierzu manuell segmentiert und eine künstliche Datenerweiterung durchgeführt. Weiterhin wird zunächst die Definition des Glattschnittanteils aus industrieller Sichtweise untersucht und Gütemaße zur Bewertung der Segmentierung erstellt. Diese setzen sich aus einem entwickelten kombinierten Koeffizienten, dem prozentualen Anteil der vorhergesagten Glattschnittfläche, dem prozentualen Anteil der Pixel, die einer Glattschnittfläche zugeordnet werden konnten, und den Faktoren für die Anzahl der Glattschnittflächen und Anzahl der Einrisse im Verhältnis zur tatsächlichen Segmentierung zusammen. Der kombinierte Koeffizient kann als Gesamtbewertung der Segmentierungsgüte gesehen werden und setzt sich aus einem regionenbasierten und einem kantenbasierten Anteil zusammen. Diese Anteile werden auch in der Loss-Funktion verwendet, wodurch sichergestellt ist, dass diese Aspekte durch den Trainingsprozess optimiert werden. Da die Bauteile der Scherschneidtechnologie anwendungsbezogen diese Aspekte unterschiedlich priorisieren, sind Gewichte in die Loss-Funktion und das Gütemaß integriert. Eine anwendungsbezogene Anpassung dieser Gewichte ist daher möglich.

Weiterhin werden unterschiedliche Netzwerkarchitekturen mit den definierten Trainings- und Bewertungskriterien trainiert und ausgewertet. Hierbei zeigt sich die U-Net++-Architektur als besonders vielversprechend. Über Hyperparameteroptimierungen und Architekturanpassungen wird eine Netzwerkarchitektur gefunden, welche eine Segmentierungsgüte innerhalb der Zykluszeit des Fertigungsprozesses vornehmen kann. Zusätzlich wird gezeigt, dass auch Bildaufnahmen von anderen Geräten segmentiert werden können, wenn auch mit niedrigerer Performanz. Auch wenn die Bildaufnahmen noch nicht in hoher Auflösung verarbeitet werden können, ist die Möglichkeit der Überwachung der Schnittflächen im Fertigungsprozess gegeben.

Die Ergebnisse aus Kapitel 3 und 4 schaffen die Grundlage zur Untersuchung eines datengetriebenen Sensornetzwerks zur Verschleißklassifizierung. Ziel ist es die Auswirkung des neu geschaffenen Überwachungssystems auf die Verschleißklassifizierung zu analysieren. Neben dem optischen Überwachungssystem werden die weiteren Messgrößen bestehend aus einer Schneidkraftmessung unmittelbar am Schneidstempel, einer Beschleunigungs- und Körperschallmessung am Schneidwerkzeugeteil, sowie eine Banddickenmessung definiert. Nach dem hier vorgestellten und getesteten Konzept werden die Messgrößen durch die entsprechenden Sensoren in einer Stanzbiegeautomaten erhoben. Zusätzlich werden Daten aus der Maschinensteuerung übertragen. Mit dem

so entstandene Netzwerk wird in einer Versuchsreihe der Lebenszyklus eines Schneidstempels aufgezeichnet. Dabei wurden bewusst Daten ausgezeichnet, die nach Erreichen der Lebensdauer des Schneidstempels entstehen. Für die Schneidstempel wurden in Intervallprüfungen die bestimmende 45° -Verschleißlänge ermittelt.

Die aufgezeichnete Datenmenge wird anschließend aufbereitet. Anhand der Entwicklung des 45° -Verschleißlänge über die Stempellebensdauer und durch manuelle Sichtung der Bildaufnahmen erfolgt eine Aufteilung in die Klassen Einlauf, normales Schneidverhalten, Verschleiß und Schaden über die Versuchsdauer. Die aufgezeichneten Sensordaten aus der Kraft-, Beschleunigungs- und Körperschallmessung sowie aus dem optischen Überwachungssystem werden durch Datenvorverarbeitungen reduziert. Die Sensordaten werden durch eine Hauptkomponentenanalyse transformiert und reduziert. Sie dienen als Referenz für die Modellbildung und Bewertung. Zur Berücksichtigung der Bilddaten werden unterschiedliche Varianten getestet. Einerseits werden die unverarbeiteten Bildaufnahmen in ihrer Auflösung verringert und zudem durch eine Hauptkomponentenanalyse (Bildmerkmale) reduziert. Andererseits werden die unverarbeiteten Bildaufnahmen durch das entwickelte Bildverarbeitungsnetz segmentiert und die aus der VDI-Richtlinie bekannten Qualitätsmaße abgeleitet.

In der folgenden Modellbildung zur Verschleißklassifizierung werden die unterschiedlichen Konfigurationen der Daten jeweils von klassischen Algorithmen des maschinellen Lernens und neuronalen Netzen angeleitet. Die Bewertung der Modelle erfolgt anhand ihrer Accuracy-Scores; zusätzlich wird über SHAP-Werte der Einfluss des jeweiligen Merkmals analysiert. Es zeigt sich, dass die Vorhersage der Verschleißlabels mit der geschaffenen Datenbasis realisierbar ist. Zugleich zeigen die Bildmerkmale einen hohen Informationsgehalt über die unterschiedlichen Datenmengen. Im Vergleich zur Referenzdatenmenge aus den Sensordaten wird ein besseres Ergebnis erzielt. Die Kombination der Referenzdatenmenge mit den Bildmerkmalen erzielt wiederum ein geringfügig besseres Ergebnis. Zusammenfassend kann der Mehrwert, der durch die Sensormerkmale entsteht, gemessen am finanziellen Aufwand, hinterfragt werden.

Die Forschungsziele dieser Arbeit konnten somit erreicht und der Stand der Technik erweitert werden. Dabei wurde in dieser Arbeit

- eine Methode zur Inline-Überwachung bei Scherschneidprozessen bezogen auf die Schnittflächenkenngrößen gezeigt;
- eine Methode zur Inline-Qualitätsbewertung der Schnittflächen durch Segmentierung mittels neuronaler Netzwerke vorgestellt;
- eine datengetriebene Methode zur Prozessüberwachung anhand unterschiedlicher Merkmalsräume gezeigt, die eine Verschleißklassifizierung ermöglicht.

Weiterhin wird, durch hohe Prognosegüte und Analyse der SHAP-Werte der jeweiligen Modelle, den Bilddaten ein großer Nutzen für die Verschleißklassifizierung zugesprochen. Zusätzlich erlauben die Untersuchungen im Laborumfeld unter industrienahen Bedingungen eine hohe Übertragbarkeit in reale Prozesse.

6.2 Ausblick

Mit Blick auf nachfolgende Tätigkeiten ergibt sich basierend auf dieser Arbeit eine Vielzahl an Möglichkeiten in unterschiedlichen Bereichen. Bezogen auf das optische Überwachungssystem sollten zunächst weitere Schnittflächenkenngrößen automatisiert ermittelt werden. Durch das integrierte Lichtschnittverfahren wurden die Aufzeichnung dreidimensionaler Daten der Schnittfläche und eine erste Verifizierung gezeigt. Eine schnelle und effiziente Methode zur Bildverarbeitung wird eine dreidimensionale Vermessung der Schnittfläche während des Fertigungsprozesses erlauben. Die ableitbaren Daten können dann ebenfalls das Prozessnetzwerk und die Verschleißklassifizierung verbessern. Weiterhin kann das Überwachungssystem als Echtzeit-Überwachungssystem zur Qualitätsbestimmung eingesetzt werden, um in Verbindung mit Handlingsystemen oder der Maschinensteuerungen gezielt Bauteile als fehlerhaft zu kennzeichnen. Hierzu muss allerdings noch eine Rückkopplung in die entsprechende Maschineneinheit erfolgen.

Momentan gestatten die Spezifikationen des Überwachungssystems nur einen kleinen Anwendungsbereich. Aktuell muss daher für jede Ausstanzung eine Einheit verbaut und es kann nur ein Ausschnitt der Schnittfläche aufgenommen werden. Durch die Montage des Überwachungssystems auf einem Roboterarm und durch steuerbare Flüssiglinienobjektive können diese Spezifikationen allerdings erheblich erweitert werden. Weiterhin lässt sich der Aufnahmebereich durch optische Umlenkungen erweitern. Zu untersuchen sind dabei zunächst entstehende Störkonturen und daraus folgende Abschattungen. Bezogen auf eine Prozessüberwachung kann das Überwachungssystem dabei helfen zu untersuchen, inwieweit die Überwachung eines singulären Punktes der Schneidgeometrie, beispielsweise des kleinsten Radius, aussagekräftige Ergebnisse liefert.

Bezogen auf die Bildverarbeitungsnetzwerke sollte zunächst die Datenbasis verbreitert und die künstliche Datenerweiterung reduziert werden. Hierzu sind begleitende Bildaufnahmen aus Fertigungsprozessen mit anderen Materialien, Banddicken, Schneidgeometrien, aber auch aus anderen Aufnahmegeräten notwendig. Nach einer manuellen Segmentierung kann hieraus ein allgemeingültiges Modell zur Segmentierung entstehen. Weiterhin ist es denkbar andere Schnittflächenkenngrößen, wie den Bruchanteil, in den Segmentierungsprozess zu integrieren. Zusätzlich sind die Netzwerke auf eine aussagekräftige Auflösung bezüglich der Genauigkeit anzupassen.

Bezogen auf das Sensornetzwerk ist in dieser Arbeit die Basis für eine Echtzeit-Prozessüberwachung des Scherschneidprozesses geschaffen worden. Zunächst gilt es, die Ergebnisse durch eine weitere Versuchsreihe zu bestätigen. Hierbei ist eine Variation der Fertigungsparameter im Hinblick auf Material und Banddicke anzustreben. Die Verifizierung der trainierten Modelle kann unter Umständen bereits in Echtzeit während der Produktion erfolgen. Auf dieser Basis können nachfolgend Aussagen zur allgemeinen Gültigkeit der Modelle getroffen werden. Die in dieser Arbeit erstellten Modelle wiederum könnten an jeder Maschine unabhängig von den Fertigungsparametern als Ausgangszustand dienen, um durch Transfer Learning die Besonderheit der jeweili-

gen Anwendung zu erlernen. Der Prozess wird somit erheblich beschleunigt und die Schaffung einer gesonderten breiten Trainingsbasis vermieden.

Weitere Forschungsaktivitäten sollten in die Festlegung der Übergangsbereiche der Verschleißlabels fließen. Dies ist im Hinblick auf eine vorausschauende Wartung besonders bedeutend. Wenn zusätzlich eine höhere Datenabdeckung der Verschleißdaten gegeben ist, kann die Methode der Verschleißklassifizierung auf ein Regressionsverfahren geändert und somit das Verschleißmaß des Schneidstempels vorhergesagt werden. Zusätzlich ist eine Erweiterung der Sensordaten denkbar. Weiter sollte zum einen bei der nächsten Versuchsreihe der Rückhub des Schneidstempels aufgezeichnet werden. Hieraus kann ein erweiterter Informationsgewinn, bezogen auf den Schneidstempelverschleiß bzw. Stempelbruch, erzeugt werden. Zum anderen sollten Sensoren zur Temperaturmessung im Werkzeug nach Demmel (Demmel 2014) getestet werden.

Weiterhin können die gezeigten Metadaten aus der Hauptkomponentenanalyse für weitere Varianzanalysen herangezogen werden. Die vom Modell als signifikant ausgewählten Eigenbilder zeigen eine deutliche Varianz unterhalb des Glattschnittanteils, gleichzeitig lassen die mit den Bauteilqualitätsmaßen trainierten Modelle keinen Einfluss dieser Merkmale erkennen. Dies deutet auf andere Wirkzusammenhänge als eine reine Zu- oder Abnahme eines Längenmaßes hin. Daher sollten weitere Maße, wie die Fluktuation der Übergänge, berücksichtigt werden. Eine tiefere Vernetzung über das Internet of Things könnte die Produktivität ebenfalls erhöhen, beispielsweise durch Einbindung von Produktionsdaten des Bandmaterials. Fertigungsdaten des Bandmaterials könnten etwa in die Maschine und das Prozessnetzwerk einbezogen werden. Abschließend ließe sich die Mehrzahl der festgelegten Methoden unter Anpassung auf andere Schneidprozesse übertragen, so unter anderem auf den artverwandten Feinschneidprozess.

Zusammenfassend ist festzuhalten, dass die vorliegende Arbeit die Scherschneidtechnologie durch eine Qualitätskontrolle im Fertigungsprozess erweitert und Möglichkeiten zur datengetriebenen Zustandsüberwachung zeigt und eröffnet. Komplexe Ursachen-Wirkungszusammenhänge können zum Zweck der Verschleißklassifizierung nun durch künstliche Intelligenz abgebildet und Trial-and-Error-Methodiken durch datenbasierte und somit messbare Prozesse ersetzt werden.

Kapitel 6. Zusammenfassung und Ausblick

Literaturverzeichnis

- Ali, M., 2022. *PyCaret - An open-source, low-code machine learning library in Python*. PyCaret version 3.0. URL: <https://pycaret.org/> (besucht am 28. 12. 2022).
- Alpaydin, E., 2022. *Maschinelles Lernen*. Berlin, Boston: De Gruyter Oldenbourg. DOI: 10.1515/9783110740196.
- Awad, M. und Khanna, R., 2015. *Efficient Learning Machines*. Berkeley, CA: Apress Berkeley. DOI: 10.1007/978-1-4302-5990-9.
- Badrinarayanan, V., Kendall, A. und Cipolla, R., Dez. 2017. „SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation“. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39 (12). S. 2481–2495. DOI: 10.1109/TPAMI.2016.2644615.
- Bauernhansl, T., Hrsg., 2020. *Fabrikbetriebslehre 1*. Berlin, Heidelberg: Springer Vieweg. DOI: 10.1007/978-3-662-44538-9.
- Behrens, B.-A. und Jocker, J., 2013. *Optische Schnittkantenmessung und automatisierte Kenngrößenermittlung: Ergebnisse eines Vorhabens der Industriellen Gemeinschaftsforschung (IGF)*. Bd. Nr. 385. EFB-Forschungsbericht. Hannover: EFB.
- Behrens, B.-A., Krimm, R. und Nguyen, Q. T., Okt. 2017. „Motorized measurement device for automatic registration of cutting edges“. *Engineering for a Changing World: Proceedings; 59th IWK, Ilmenau Scientific Colloquium, Technische Universität Ilmenau, September 11-15, 2017* 59, 2017.1.3.02.
- Behrens, B.-A., Krimm, R. und Nguyen, Q. T., 2018. *EFB-Forschungsbericht Nr. 494 Robuste Schnittflächencharakterisierung und prozessbegleitende Schnittgratmessung Europäische Forschungsgesellschaft für Blechverarbeitung e. V.* Hannover: Europäische Forschungsgesellschaft für Blechverarbeitung e.V.
- Bergs, T., Niemietz, P., Kaufman, T. und Trauth, D., 2020. „Punch-to-Punch Variations in Stamping Processes“. *SAMI 2020 - IEEE 18th World Symposium on Applied Machine Intelligence and Informatics, Proceedings*. S. 213–218. DOI: 10.1109/SAMI48414.2020.9108761.
- Beyerer, J., León, F. P. und Frese, C., 2016. *Automatische Sichtprüfung: Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*. Berlin, Heidelberg: Springer Vieweg. DOI: 10.1007/978-3-662-47786-1.

- Bhatt, D. et al., Okt. 2021. „CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope“. *Electronics* 10 (20). S. 2470. DOI: 10.3390/electronics10202470.
- Bodendorf, F., 2006. *Daten- und Wissensmanagement*. Berlin, Heidelberg, New York: Springer. DOI: 10.1007/3-540-28682-9.
- Bradski, G., 2000. „The OpenCV Library“. *Dr. Dobb's Journal of Software Tools*.
- Breitling, J., Pfeiffer, B., Altan, T. und Siegert, K., Nov. 1997. „Process control in blanking“. *Journal of Materials Processing Technology* 71.1. S. 187–192. DOI: 10.1016/s0924-0136(97)00167-2.
- Bretschneider, J., Keinath, M. und Löffler-Mang, M., 2020. „Optoelektronische Sensorik“. *Handbuch Bauelemente der Optik*. München: Carl Hanser, S. 383–423. DOI: 10.3139/9783446461260.012.
- Burghardt+Schmidt GmbH, 2023. *EP-Schnittgratmessgerät*. URL: <https://b-s-germany.de/portfolio/ep-messgeraet/> (besucht am 02.01.2023).
- Cai, S. et al., 2020. „Dense-UNet: a novel multiphoton in vivo cellular image segmentation model based on a convolutional neural network“. *Quantitative Imaging in Medicine and Surgery* 10.6. S. 1275–1285. DOI: 10.21037/qims-19-1090.
- Carl Zeiss GOM Metrology GmbH, 2019. *GOM Inspect 2019 [Software]*. Version 2.0.1. URL: <https://www.gom.com/de-de/produkte/zeiss-quality-suite/gom-inspect-pro>.
- Cha, W. G. et al., 2017. „Adaptive wear model for shear-cutting simulation with open cutting line“. *Wear* 386-387. S. 17–28. DOI: 10.1016/j.wear.2017.05.019.
- Chan, T. F. und Vese, L. A., 2001. „Active contours without edges“. *IEEE Transactions on Image Processing* 10.2. S. 266–277. DOI: 10.1109/83.902291.
- Chapman, P. et al., 2000. *CRISP-DM 1.0 Step-by-step data mining guide*. SPSS Inc.
- Chen, P., Su, X., Liu, M. und Zhu, W., Mai 2020. „Lensless Computational Imaging Technology Using Deep Convolutional Network“. *Sensors* 20. S. 2661. DOI: 10.3390/s20092661.
- Cheon, S. und Kim, N., 2016. „Prediction of tool wear in the blanking process using updated geometry“. *Wear* 352-353. S. 160–170. DOI: 10.1016/j.wear.2016.01.024.
- Cheung, C. F., Lee, W. B. und Chiu, W. M., März 2001. „Effect of Tool Wear on Force and Quality in Dam-Bar Cutting of Integrated Circuit Packages“. *Journal of Electronic Packaging* 123 (1). S. 34–41. DOI: 10.1115/1.1322564.
- Cleve, J. und Lämmel, U., 2020. *Data Mining*. Berlin, Boston: De Gruyter Oldenbourg. DOI: 10.1515/9783110676273.
- CloudCompare 2019. *CloudCompare [Software]*. Version 2.10.2. URL: <http://www.cloudcompare.org>.
- Czichos, H. und K.-H. Habig, Hrsg., 2015. *Tribologie-Handbuch: Tribometrie, Tribomaterialien, Tribotechnik*. 4., vollst. überarb. u. erw. Aufl. 2015. Wiesbaden: Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-8348-2236-9.
- Deike, L., 2020. „Kontinuierliche Qualitätsoptimierung von Produktionsprozessen durch maschinelle Lernverfahren“. Dissertation. Duisburg: Universität Duisburg-Essen. DOI: 10.17185/DUEPUBLICO/71560.

- Demmel, P., 2014. „In-situ Temperaturmessung beim Scherschneiden“. Dissertation. München: Technische Universität München.
- Deng, J. et al., 2009. „ImageNet: A large-scale hierarchical image database“. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, S. 248–255. DOI: 10.1109/CVPR.2009.5206848.
- Doege, E. und Behrens, B.-A., 2016. *Handbuch Umformtechnik*. Berlin, Heidelberg: Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-43891-6.
- Doege, E. und Ulrich, L., 1995. *Schnittflächenqualität und Schneidkraftbedarf beim Scherschneiden von Tiefziehblechen*. Bd. 68. Hannover: Europäische Forschungsgesellschaft für Blechverarbeitung e.V.
- Drozdal, M., Vorontsov, E., Chartrand, G., Kadoury, S. und Pal, C., 2016. „The Importance of Skip Connections in Biomedical Image Segmentation“. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10008 LNCS. S. 179–187. DOI: 10.1007/978-3-319-46976-8_19.
- Ertel, W., 2021. *Grundkurs Künstliche Intelligenz*. Wiesbaden: Springer Fachmedien. DOI: 10.1007/978-3-658-32075-1.
- Falconnet, E., Makich, H., Chambert, J., Monteil, G. und Picart, P., 2012. „Numerical and experimental analyses of punch wear in the blanking of copper alloy thin sheet“. *Wear* 296 (August). S. 598–606. DOI: 10.1016/j.wear.2012.07.031.
- Fayyad, U., Piatetsky-Shapiro, G. und Smyth, P., 1996a. „From Data Mining to Knowledge Discovery in Databases“. *AI Magazine* 17.3. S. 37. DOI: 10.1609/aimag.v17i3.1230.
- Fayyad, U., Piatetsky-Shapiro, G. und Smyth, P., 1996b. „The KDD Process for Extracting Useful Knowledge from Volumes of Data“. *Communications of the ACM* 39.11. S. 27–34. DOI: 10.1145/240455.240464.
- Fernandez, A. et al., 2018. *Learning from Imbalanced Data Sets*. Cham: Springer International Publishing. DOI: 10.1007/978-3-319-98074-4.
- Fisher, R. und Naidu, D., 2001. „A Comparison of Algorithms for Subpixel Peak Detection“. *Image Technology, Advances in Image Processing, Multimedia and Machine Vision*. DOI: 10.1007/978-3-642-58288-2-15.
- Frochte, J., 2021. *Maschinelles Lernen : Grundlagen und Algorithmen in Python*. 3. Aufl. München: Carl Hanser. DOI: 10.3139/9783446457058.
- Ge, M., Du, R. und Xu, Y., März 2004. „Hidden Markov Model based fault diagnosis for stamping processes“. *Mechanical Systems and Signal Processing* 18 (2). S. 391–408. DOI: 10.1016/S0888-3270(03)00076-1.
- Ge, M., Zhang, G. C., Du, R. und Xu, Y., Juli 2002. „Feature Extraction From Energy Distribution of Stamping Processes Using Wavelet Transform“. *Journal of Vibration and Control* 8 (7). S. 1023–1032. DOI: 10.1177/107754602029577.
- Ge, M., Du, R., Zhang, G. und Xu, Y., Jan. 2004a. „Fault diagnosis using support vector machine with an application in sheet metal stamping operations“. *Mechanical Systems and Signal Processing* 18 (1). S. 143–159. DOI: 10.1016/S0888-3270(03)00071-2.
- Ge, M., Du, R., Zhang, G. und Xu, Y., Jan. 2004b. „Fault diagnosis using support vector machine with an application in sheet metal stamping operations“. *Mechanical Systems and Signal Processing* 18 (1). S. 143–159. DOI: 10.1016/S0888-3270(03)00071-2.

- Gevatter, H.-J. und U. Grünhaupt, Hrsg., 2006. *Handbuch der Mess- und Automatisierungstechnik in der Produktion*. Berlin, Heidelberg: Springer. DOI: 10.1007/3-540-34823-9.
- Gonzalez, R. C. und Woods, R. E., 2018. *Digital image processing*. Fourth Edition. New York: Pearson Education.
- Groover, M. P., 2021. *Fundamentals of Modern Manufacturing: Materials, Processes and Systems, SI Version*. 7. Aufl. Singapore: John Wiley & Sons.
- Hambli, R., Sep. 2001. „Blanking tool wear modeling using the finite element method“. *International Journal of Machine Tools and Manufacture* 41 (12). S. 1815–1829. DOI: 10.1016/S0890-6955(01)00024-4.
- Hambli, R., 2002a. „Design of experiment based analysis for sheet metal blanking processes optimisation“. *International Journal of Advanced Manufacturing Technology* 19.6. S. 403–410. DOI: 10.1007/s001700200041.
- Hambli, R., 2002b. „Prediction of burr height formation in blanking processes using neural network“. *International Journal of Mechanical Sciences* 44.10. S. 2089–2102. DOI: 10.1016/S0020-7403(02)00168-6.
- Hambli, R., 2003. „BLANKSOFT: A code for sheet metal blanking processes optimization“. *Journal of Materials Processing Technology* 141. S. 234–242. DOI: 10.1016/S0924-0136(03)00161-4.
- Hastie, T., Tibshirani, R. und Friedman, J., 2009. *The elements of statistical learning: data mining, inference and prediction*. New York, NY: Springer New York. DOI: 10.1007/978-0-387-84858-7.
- Held, C., Liewald, M. und Sindel, M., 2009. „Untersuchungen zum Einfluss werkstofflicher Schwankungen innerhalb eines Coils auf die Umformbarkeit - Ergebnisse experimenteller Werkstoffcharakterisierung an Blechwerkstoffen an unterschiedlichen Positionen im Coil und Auswirkungen auf den Umformprozess“. *wt Werkstattstechnik online* 99.10. S. 732–739.
- Hering, E. und R. Martin, Hrsg., 2017. *Optik für Ingenieure und Naturwissenschaftler*. München: Carl Hanser. DOI: 10.3139/9783446445093.
- Hernández, J. J., Franco, P., Estrems, M. und Faura, F., 2006. „Modelling and experimental analysis of the effects of tool wear on form errors in stainless steel blanking“. *Journal of Materials Processing Technology* 180.1-3. S. 143–150. DOI: 10.1016/j.jmatprotec.2006.05.015.
- Hirsch, M. J., 2012. „Einfluss von Leichtbauwerkstoffen in schnelllaufenden Stanzwerkzeugen auf das Verschleißverhalten“. Dissertation. München: Technische Universität München.
- Hoffmann, H., Hoogen, M., Ulbricht, V. und Pytell, T., 1999. *Optimierung der Schneidparameter beim Zerteilen von Aluminiumblechen zur Reduzierung der Gratbildung*. Bd. 135. Hannover: Europäische Forschungsgesellschaft für Blechverarbeitung e.V. (EFB).
- Hoffmann, H., Neugebauer, R. und Spur, G., 2012. *Handbuch Umformen*. Edition Handbuch der Fertigungstechnik. München: Carl Hanser. DOI: 10.3139/9783446430044.
- Hohmann, J., Schatz, T. und Groche, P., 2017. „Intelligent Wear Identification Based on Sensory Inline Information for a Stamping Process“. *Proceedings of 5th International Conference on Advanced Manufacturing Engineering and Technologies*. Springer, S. 285–295.

- Holzinger, A., Saranti, A., Molnar, C., Biecek, P. und Samek, W., 2022. „Explainable AI Methods - A Brief Overview“. *xxAI - Beyond Explainable AI: International Workshop, Held in Conjunction with ICML 2020, July 18, 2020, Vienna, Austria, Revised and Extended Papers*. Hrsg. von A. Holzinger et al. Cham: Springer International Publishing, S. 13–38. DOI: 10.1007/978-3-031-04083-2_2.
- Hoogen, M., 1999. „Einfluß der Werkzeuggeometrie auf das Scherschneiden und Reißen von Aluminiumfeinblechen“. Dissertation. München: Technische Universität München.
- Hoppe, F., Hohmann, J., Knoll, M., Kubik, C. und Groche, P., 2019. „Feature-based supervision of shear cutting processes on the basis of force measurements: Evaluation of feature engineering and feature extraction“. *Procedia Manufacturing* 34. S. 847–856. DOI: 10.1016/j.promfg.2019.06.164.
- Hörmann, F., 2008. „Einfluss der Prozessparameter auf einstufige Scherschneidverfahren zum Ausschneiden mit endkonturnaher Form“. Dissertation. München: Technische Universität München.
- Huang, G., Liu, Z., Maaten, L. V. D. und Weinberger, K. Q., 2017. „Densely connected convolutional networks“. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017* 2017-Januar. S. 2261–2269. DOI: 10.1109/CVPR.2017.243.
- Husson, C., Correia, J., Daridon, L. und Ahzi, S., Apr. 2008. „Finite elements simulations of thin copper sheets blanking: Study of blanking parameters on sheared edge quality“. *Journal of Materials Processing Technology* 199 (1-3). S. 74–83. DOI: 10.1016/j.jmatprotec.2007.08.034.
- IBM Analytics, 2023. ASUM-DM. URL: http://i2t.icesi.edu.co/ASUM-DM_External/index.htm (besucht am 11.01.2023).
- Isensee, F., 2020. „From Manual to Automated Design of Biomedical Semantic Segmentation Methods“. Dissertation. Heidelberg: Ruprecht-Karls-Universität Heidelberg. DOI: 10.11588/heidok.00029345.
- Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J. und Maier-Hein, K. H., Feb. 2021. „nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation“. *Nature Methods* 18 (2). S. 203–211. DOI: 10.1038/s41592-020-01008-z.
- Jähne, B., 2012. *Digitale Bildverarbeitung und Bildgewinnung*. Berlin und Heidelberg: Springer Berlin Heidelberg. DOI: 10.1007/978-3-642-04952-1.
- Jin, J. und Shi, J., Mai 2000. „Diagnostic Feature Extraction From Stamping Tonnage Signals Based on Design of Experiments“. *Journal of Manufacturing Science and Engineering* 122 (2). S. 360–369. DOI: 10.1115/1.538926.
- Jin, J. und Shi, J., 2001. „Automatic feature extraction of waveform signals for in-process diagnostic performance improvement“. *Journal of Intelligent Manufacturing* 12.3. S. 257–268. DOI: 10.1023/a:1011248925750.
- Kass, M., Witkin, A. und Terzopoulos, D., 1988. „Snakes: Active Contour Models“. *International Journal of Computer Vision* 1. S. 321–331. DOI: 10.1007/BF00133570.
- Kebe, T., Dürr, W., Goureev, D. und Reimann, G., 2011. „Einsatz des IMPOC-Verfahrens zur Bestimmung mechanisch-technologischer Eigenschaften von Stahlband“. *Deutsche Gesellschaft für Zerstörungsfreie Prüfung e.V. - Jahrestagung 2011*.

- Kervadec, H. et al., Dez. 2018. „Boundary loss for highly unbalanced segmentation“. *Medical Image Analysis*. DOI: 10.1016/j.media.2020.101851.
- Kienzle, O., Timmerbeil, W. und Jordan, T., 1959. *Forschungsberichte des Landes Nordrhein-Westfalen: Einige Untersuchungen über das Schneiden von Blechen: Nr. 693*. Köln, Opladen: Westdeutscher Verlag.
- Kim, B. S., Okt. 1983. „Punch Press Monitoring with Acoustic Emission (AE) Part II: Effects of Process Variables“. *Journal of Engineering Materials and Technology* 105 (4). S. 301–306. DOI: 10.1115/1.3225662.
- Kim, B., Khanna, R. und Koyejo, O. O., 2016. „Examples are not enough, learn to criticize! Criticism for Interpretability“. *Advances in Neural Information Processing Systems*. Hrsg. von D. Lee, M. Sugiyama, U. Luxburg, I. Guyon und R. Garnett. Bd. 29. Curran Associates, Inc.
- Kim, J. D., Kim, H. K., Heo, Y. M. und Chang, S. H., 2012. „A study on die roll height of special automobile seat recliner gear according to die chamfer shape in fine blanking tool“. *Applied Mechanics and Materials* 121-126. S. 3694–3699. DOI: 10.4028/www.scientific.net/AMM.121-126.3694.
- Kingma, D. P. und Ba, J., 2014. „Adam: A Method for Stochastic Optimization“. *ArXiv*. DOI: 10.48550/ARXIV.1412.6980.
- Kirste, M., 2019. „Augmented Intelligence – Wie Menschen mit KI zusammen arbeiten“. *Künstliche Intelligenz: Technologie | Anwendung | Gesellschaft*. Hrsg. von V. Wittpahl. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 58–71. DOI: 10.1007/978-3-662-58042-4_4.
- Kirste, M. und Schürholz, M., 2019. „Einleitung: Entwicklungswege zur KI“. *Künstliche Intelligenz: Technologie - Anwendung - Gesellschaft*. Hrsg. von V. Wittpahl. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 21–35. DOI: 10.1007/978-3-662-58042-4_1.
- Kistler Instrumente AG, 2016. *Instruction Manual: Ceramic Shear Triaxial IEPE Accelerometers Types*. Winterthur.
- Kistler Instrumente AG, 2020. *Instruction Manual: Non-hazardous and hybrid/mixed area system: AE-Piezotron sensor and coupler*. Winterthur.
- Klingenberg, W. und Boer, T. W. de, 2008. „Condition-based maintenance in punching/blanking of sheet metal“. *International Journal of Machine Tools and Manufacture* 48.5. S. 589–598. DOI: 10.1016/j.ijmactools.2007.08.013.
- Klingenberg, W. und Singh, U. P., 2004. „Principles for on-line Monitoring of Tool Wear During Sheet Metal Punching“. *Proceedings of the 34th International MATADOR Conference*. S. 169–174. DOI: 10.1007/978-1-4471-0647-0_25.
- Klocke, F., Stanke, J., Trauth, D. und and, P. M., 2017. „Künstliche neuronale Netze für das Feinschneiden“. *wt Werkstattstechnik online* 107.10. S. 719–724. DOI: 10.37544/1436-4980-2017-10-41.
- Klocke, F., 2017. *Fertigungsverfahren 4: Umformen*. Berlin, Heidelberg: Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-54714-4.
- Kobbelt, L. P. und Bischoff, S., Juni 2004. „Parameterization-free active contour models with topology control“. *The Visual Computer* 20 (4). S. 217–228. DOI: 10.1007/s00371-003-0228-9.

- Koh, C. K. H., Shi, J., Williams, W. J. und Ni, J., Mai 1999. „Multiple Fault Detection and Isolation Using the Haar Transform, Part 2: Application to the Stamping Process“. *Journal of Manufacturing Science and Engineering* 121 (2). S. 295–299. DOI: 10.1115/1.2831219.
- Kolbe, M., 2020. *Stanztechnik: : Grundlagen Werkzeuge Maschinen*. Wiesbaden: Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-658-30401-0.
- Kopp, T. M., 2017. „Einfluss der Werkzeugsteifigkeit auf Scherschneidprozess und Werkzeugverschleiß beim offenen Schnitt“. Dissertation. München: Technische Universität München.
- Krinninger, M., Steinlehner, F., Opritescu, D., Golle, R. und Volk, W., 2017. „On the Influence of Different Parameters on the Characteristic Cutting Surface when Shear Cutting Aluminum“. *Procedia CIRP* 63. S. 230–235. DOI: 10.1016/j.procir.2017.03.156.
- Krizhevsky, A., Sutskever, I. und Hinton, G. E., 2012. „ImageNet Classification with Deep Convolutional Neural Networks“. *Advances in Neural Information Processing Systems*. Hrsg. von F. Pereira, C. Burges, L. Bottou und K. Weinberger. Bd. 25. Curran Associates, Inc.
- Kubik, C., 2021. „Exploitation of force displacement curves in blanking—feature engineering beyond defect detection“. *The International Journal of Advanced Manufacturing Technology*. S. 261–278. DOI: 10.1007/s00170-020-06450-z.
- Kubik, C., Becker, M., Molitor, D.-A. und Groche, P., Aug. 2022. „Towards a systematic approach for wear detection in sheet metal forming using machine learning“. *Production Engineering* 2022 1. S. 1–16. DOI: 10.1007/s11740-022-01150-x.
- Kubik, C., Knauer, S. M. und Groche, P., Juni 2022. „Smart sheet metal forming: importance of data acquisition, preprocessing and transformation on the performance of a multiclass support vector machine for predicting wear states during blanking“. *Journal of Intelligent Manufacturing* 33.1. S. 259–282. DOI: 10.1007/s10845-021-01789-w.
- Lange, K., Hrsg., 1990. *Umformtechnik: Handbuch für Industrie und Wissenschaft*. Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-10686-0.
- Lee, W. B., Cheung, C. F., Chiu, W. M. und Chan, L. K., 1997. „Automatic supervision of blanking tool wear using pattern recognition analysis“. *International Journal of Machine Tools and Manufacture* 37.8. S. 1079–1095. DOI: 10.1016/S0890-6955(97)88104-7.
- Lens.org, 2023. *Lens Scholarly Search: (punching AND wear) OR (wear AND blanking) NOT hot NOT deep drawing NOT stamping*. URL: <https://link.lens.org/ghnI3Pxxgmdi> (besucht am 10.01.2023).
- Liewald, M. et al., Okt. 2022. „Perspectives on data-driven models and its potentials in metal forming and blanking technologies“. *Production Engineering* 16 (5). S. 607–625. DOI: 10.1007/s11740-022-01115-0.
- Loibl, D., 2003. „Standzeit und Teilequalität beim Lochen von Feinblechen mit keramischen Schneidstempeln“. Dissertation. Technische Universität München.
- Lorenz, M., 2017. „Konzeptentwicklung eines optischen Messverfahrens zur Inline-Qualitätsüberwachung eines Stanz-Biege-Prozesses“. Masterarbeit. Kempten: Hochschule für angewandte Wissenschaften Kempten.

- Lundberg, S. M. und Lee, S.-I., 2017. „A Unified Approach to Interpreting Model Predictions“. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. NIPS'17. Long Beach, California, USA: Curran Associates Inc., S. 4768–4777.
- Ma, J. et al., 2021. „Loss odyssey in medical image segmentation“. *Medical Image Analysis* 71. DOI: 10.1016/j.media.2021.102035.
- Maeda, T. und Matsuno, K., 1967. „Wear on Shearing Tools : (Wear on Cutting Edges of Blanking Tool for Square Parts)“. *Bulletin of JSME* 10 (37). S. 197–205. DOI: 10.1299/jсме1958.10.197.
- Mardapittas, A. S. und Au, Y. H. J., 1992. „BETS: An Expert System for Tool condition Monitoring in Blanking“. *Proceedings of the International Conference of Sheet Metal*. London: IOP Publishing, S. 141–150.
- Mardapittas, A. S. und Au, Y. H. J., 1989. *Blanking Process Characterization Using Acoustic Emission*. Boston, MA: Springer US, S. 170–174. DOI: 10.1007/978-1-4684-8905-7_28.
- MARPOSS Monitoring Solutions GmbH, 2019. *Produktspezifikation: Prozessüberwachung Stanzen*. Egestorf: MARPOSS Monitoring Solutions GmbH.
- Micro-Epsilon Messtechnik GmbH & Co. KG, 2023. *Inline-Gratmessung an Blechkanten im Karosseriebau*. URL: <https://www.micro-epsilon.de/applications/branch/Automotive/Inline-Gratmessung-Blechkanten/> (besucht am 02.01.2023).
- Miller, T., 2019. „Explanation in artificial intelligence: Insights from the social sciences“. *Artificial Intelligence* 267. S. 1–38. DOI: 10.1016/j.artint.2018.07.007.
- Minaee, S. et al., 2022. „Image Segmentation Using Deep Learning: A Survey“. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 44.7. S. 3523–3542. DOI: 10.1109/TPAMI.2021.3059968.
- Mockenhaupt, A., 2021. *Maschinelles Lernen*. Wiesbaden: Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-658-32773-6_6.
- Molitor, D. A., Kubik, C., Hetfleisch, R. H. und Groche, P., Aug. 2022. „Workpiece image-based tool wear classification in blanking processes using deep convolutional neural networks“. *Production Engineering* 16 (4). S. 481–492. DOI: 10.1007/s11740-022-01113-2.
- Molnar, C., 2019. *Interpretable Machine Learning A Guide for Making Black Box Models Explainable*. Raleigh, North Carolina: Lulu.com.
- Al-Momani, E. S., Mayyas, A. T., Rawabdeh, I. und Alqudah, R., 2011. „Modeling Blanking Process Using Multiple Regression Analysis and Artificial Neural Networks“. *Journal of Materials Engineering and Performance* 21.8. S. 1611–1619. DOI: 10.1007/s11665-011-0079-x.
- Monteil, G., Gréban, F. und Roizard, X., 2008. „In situ punch wear measurement in a blanking tool, by means of thin layer activation“. *Wear* 265.5-6. S. 626–633. DOI: 10.1016/j.wear.2007.12.014.
- Möser, M. und Kropp, W., 2010. *Körperschall*. Berlin, Heidelberg: Springer Berlin Heidelberg. DOI: 10.1007/978-3-540-49048-7.
- National Instruments Corp., 2018. *DIAdem 2018 [Software]*. Version 18.0.0.7097. URL: <https://www.ni.com/de-de/shop/data-acquisition-and-control/ap>

- plication-software-for-data-acquisition-and-control-category/what-is-diadem.html.
- Neugebauer, R. und Fischer, J., Feb. 2000. *Vorstudie zur Erkennung von Ausbrüchen an Stempel- und Matrizenkanten von Schneidwerkzeugen mittels Kraft- und Schallemissionsmessungen*. 1. Aufl. EFB-Forschungsbericht. Hannover: Europäische Forschungsgesellschaft für Blechverarbeitung e.V. (EFB).
- Neumayer, F. F., 2020. „Ermittlung und Auswirkung der Durchbruchkraft beim Scherschneiden“. Dissertation. München: Technische Universität München.
- Ngan, K. N., Meier, T. und Chai, D., 1999. „Chapter 4 - Model-Based Coding“. *Advanced Video Coding: Principles and Techniques*. Hrsg. von K. N. Ngan, T. Meier und D. Chai. Bd. 7. *Advances in Image Communication*. Elsevier, S. 183–249. DOI: [https://doi.org/10.1016/S0928-1479\(99\)80006-0](https://doi.org/10.1016/S0928-1479(99)80006-0).
- Nothhaft, K., 2014. „Scherschneiden höchstfester Blechwerkstoffe im offenen Schnitt“. Dissertation. München: Technische Universität München.
- OPC Foundation, 2023. *Unified Architecture - OPC Foundation*. URL: <https://opcfoundation.org/about/opc-technologies/opc-ua/> (besucht am 10.01.2023).
- Ott, A. und Biermann, D., 2019. „Experimental Investigation of the Cutting Edge Microshape to Improve the Wear Resistance of Punch and Die Tools for Sheet Metal Punching“. *Advances in Production Research*. S. 391–401. DOI: 10.1007/978-3-030-03451-1_39.
- Otte, R., Wippermann, B. und Otte, V., 2020. *Von Data Mining bis Big Data*. München: Carl Hanser Verlag. DOI: 10.3139/9783446457171.
- Otto Bihler Maschinenfabrik GmbH & Co. KG, 2023. *Servo-Stanzbiegeautomat GRM-NC - Die Universalmaschine*. URL: <https://www.bihler.de/de/magazin/artikel/kompatibel-und-flexibel.html> (besucht am 02.01.2023).
- Panico, T., 2012. „Beurteilung der Kantenbelastung beim Scherschneiden höchstfester Stahlbleche mit Hilfe der Finiten-Element-Methode“. Dissertation. München: Technische Universität München.
- Paszke, A. et al., 2019. „PyTorch: An Imperative Style, High-Performance Deep Learning Library“. *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., S. 8024–8035.
- Pfaff, K. O., 1971. „Über das Lochn austenitischerrostfreier Feinbleche: Ein Beitrag zum Lochn von dünnen Blechen aus austenitischem Chrom-Nickel-Stahl mit Stempeln kleiner Durchmesser“. Dissertation. Darmstadt: Technische Hochschule Darmstadt.
- Reinhart, F., Neumann, K., Aswolinskiy, W., Steil, J. und Hammer, B., 2018. „Maschinelles Lernen in technischen Systemen“. *Steigerung der Intelligenz mechatronischer Systeme*. Hrsg. von A. Trächtler und J. Gausemeier. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 73–118. DOI: 10.1007/978-3-662-56392-2_4.
- Retkowitz, D., 2021. „Datenbasierte Algorithmen zur Unterstützung von Entscheidungen mittels künstlicher neuronaler Netze“. *Data Science: Konzepte, Erfahrungen, Fallstudien und Praxis*. Hrsg. von D. Frick et al. Wiesbaden: Springer Fachmedien Wiesbaden, S. 209–224. DOI: 10.1007/978-3-658-33403-1_13.
- Ronneberger, O., Fischer, P. und Brox, T., 2015. „U-Net: Convolutional Networks for Biomedical Image Segmentation“. *Medical Image Computing and Computer-Assisted*

- Intervention – MICCAI 2015*. Hrsg. von N. Navab, J. Hornegger, W.M. Wells und A. F. Frangi. Cham: Springer International Publishing, S. 234–241.
- Runkler, T. A., 2015. *Data Mining*. Wiesbaden: Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-8348-2171-3.
- Sachnik, P., 2017. „Methodik für gratfreie Schnittflächen beim Scherschneiden“. Dissertation. München: Technische Universität München.
- Scheer, C., 2000. „Überwachung des Zerspanungsprozesses mit geometrisch bestimmter Schneide durch Schallemissionsmessung“. Dissertation. Zürich: ETH Zurich. DOI: 10.3929/ethz-a-003861556.
- Schmütsch, H.-H., 1990. *Einflussgrößen auf das Schneidergebnis beim Scherschneiden von Feinblechen*. Bd. Nr. 196. Düsseldorf: VDI Verlag GmbH.
- Schomaker, K.-H., 1994. *Prozessüberwachung und Diagnose mit optoelektronischen Messeinrichtungen an Schneidpressen*. Hannover: VDI Verlag GmbH.
- Schuler GmbH, 1996. *Handbuch der Umformtechnik*. Berlin, Heidelberg: Springer Berlin Heidelberg. DOI: 10.1007/978-3-662-07703-0.
- Serridge, M. und Licht, T., 1990. *Piezoelektrische Beschleunigungsaufnehmer und Vorversträrker*. Naerum: Brüel & Kjaer.
- Shapley, L. S., 1953. „A Value for n-Person Games“. *Contributions to the Theory of Games (AM-28), Volume II*. Hrsg. von H. W. Kuhn und A. W. Tucker. Princeton: Princeton University Press, S. 307–318. DOI: doi:10.1515/9781400881970-018.
- Siegert, K., Hrsg., 2015. *Blechumformung: Verfahren, Werkzeuge und Maschinen*. VDI-Buch. Berlin: Springer Vieweg. DOI: 10.1007/978-3-540-68418-3.
- Sommer, K., Heinz, R. und Schöfer, J., 2018. *Verschleiß metallischer Werkstoffe*. Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-658-17851-2.
- Statistisches Bundesamt, 2023. *Pressemitteilung Nr. 065 vom 17. Februar 2023: Erzeugerpreise Januar 2023: +17,6 % gegenüber Januar 2022*. Wiesbaden. URL: https://www.destatis.de/DE/Presse/Pressemitteilungen/2023/02/PD23_065_61241.html (besucht am 02. 03. 2023).
- Tetzner, A., Kühne, T., Gluchowski, P. und Pfoh, M., 2021. „Künstliche Neuronale Netze – Aufbau, Funktion und Nutzen“. *Data Science: Konzepte, Erfahrungen, Fallstudien und Praxis*. Hrsg. von D. Frick et al. Wiesbaden: Springer Fachmedien Wiesbaden, S. 225–239. DOI: 10.1007/978-3-658-33403-1_14.
- Toussaint, A., 2000. „Einfluss des Werkzeugverschleißes auf die Teilequalität beim Scherschneiden von Elektroblechen“. Dissertation. München: Technische Universität München.
- Trauth, D. et al., 2018. „A characterization of quality of sheared edge in fine blanking using edge-computing approach“. *Procedia Manufacturing* 15. S. 578–583. DOI: 10.1016/J.PROMFG.2018.07.280.
- Tröber, P., Weiss, H. A., Kopp, T., Golle, R. und Volk, W., Aug. 2017. „On the correlation between thermoelectriaddress and adhesive tool wear during blanking of aluminum sheets“. *International Journal of Machine Tools and Manufacture* 118-119. S. 91–97. DOI: 10.1016/j.ijmactools.2017.03.005.
- Valanarasu, J. M. J., Oza, P., Hacihaliloglu, I. und Patel, V. M., Feb. 2021. „Medical Transformer: Gated Axial-Attention for Medical Image Segmentation“. S. 1–18. DOI: 10.48550/arxiv.2102.10662.

- Van Rossum, G. und Drake, F. L., 2009. *Python 3 Reference Manual*. Scotts Valley, CA: CreateSpace.
- Volk, W. und Hammer, T., 2019. *EFB-Forschungsbericht Nr. 505 - Verschleißkurven von Schneidstempeln durch gezieltes Ermüden*. Hannover: Europäische Forschungsgesellschaft für Blechverarbeitung e.V. (EFB).
- Wadi, I. und Balendra, R., 1999. „Using neural networks to model the blanking process“. *Journal of Materials Processing Technology* 91.1. S. 52–65. DOI: 10.1016/S0924-0136(98)00426-9.
- Waschneck, B., 2020. *Autonome Entscheidungsfindung in der Produktionssteuerung komplexer Werkstattfertigungen*. Hrsg. von T. Bauernhansl et al. Stuttgart: Fraunhofer Verlag. DOI: 10.18419/opus-10986.
- Wolfschläger, D., Woltersmann, J.-H., Montavon, B. und Schmitt, R. H., Mai 2022. „Sheared edge defect segmentation using a convolutional U-Net for quantified quality assessment of fine blanked workpieces“. *Precision Engineering* 75. S. 129–141. DOI: 10.1016/j.precisioneng.2022.01.010.
- Wu, Z., Shen, C. und Hengel, A. van den, Mai 2016. „Bridging Category-level and Instance-level Semantic Image Segmentation“. *ArXiv*. DOI: 10.48550/arXiv.1605.06885.
- Zhang, G., Ge, M., Tong, H., Xu, Y. und Du, R., Feb. 2002. „Bispectral analysis for on-line monitoring of stamping operation“. *Engineering Applications of Artificial Intelligence* 15 (1). S. 97–104. DOI: 10.1016/S0952-1976(02)00007-6.
- Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N. und Liang, J., 2018. „UNet++: A Nested U-Net Architecture for Medical Image Segmentation“. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 11045 LNCS. S. 3–11. DOI: 10.1007/978-3-030-00889-5-1.

Literaturverzeichnis

Normen und Richtlinien

- Deutsches Institut für Normung e.V., Juni 2010. *DIN EN ISO 9445-1:2010-06, Kontinuierlich kaltgewalzter nichtrostender Stahl - Grenzabmaße und Formtoleranzen - Teil 1: Kaltband und Kaltband in Stäben*. Berlin: Beuth Verlag. DOI: 10.31030/1619922.
- Deutsches Institut für Normung e.V., Okt. 2011. *DIN 9830:2011-10 - Schnittgrathöhen an Stanzteilen*. Berlin: Beuth Verlag.
- Deutsches Institut für Normung e.V., Aug. 2013. *DIN 8588:2013-08 - Fertigungsverfahren Zerteilen – Einordnung, Unterteilung, Begriffe*. Berlin: Beuth Verlag.
- Deutsches Institut für Normung e.V., Dez. 2022. *DIN 8580:2022-12 - Fertigungsverfahren Begriffe, Einteilung*. Berlin: Beuth Verlag.
- Gesellschaft der Tribologie, 2002. *GTF Arbeitsblatt 7 - Tribologie: Verschleiß, Reibung: Definitionen, Begriffe, Prüfung*. Gesellschaft der Tribologie.
- Physikalisch-Technische Bundesanstalt, Sep. 2018. *Richtlinie DKD-R 3-9: Kontinuierliche Kalibrierung von Kraftaufnehmern nach dem Vergleichsverfahren*. Braunschweig und Berlin: Physikalisch-Technische Bundesanstalt (PTB). DOI: 10.7795/550.20180823J.
- Verein Deutscher Ingenieure e. V., Mai 1994. *VDI-Richtlinie 2906 Blatt 2 - Schnittflächenqualität beim Schneiden, Beschneiden und Lochen von Werkstücken aus Metall Scherschneiden*. Berlin: Beuth Verlag.

A.1 Technische Daten der verwendeten Komponenten für das Überwachungssystem

Tabelle A.1: Übersicht der verwendeten Komponenten für das Überwachungssystem

Komponente	Technische Daten	
Kamera	Hersteller	Teledyne FLIR LLC
	Bezeichnung	BFS-U3-13Y3M-C
Sensor	Sensorbezeichnung	ON Semi PYTHON 1300
	Sensortyp	CMOS
	Sensorgroße	1/2"
	Chroma	Monochrom
	Auflösung	1280 pixel×1024 pixel
	Pixelgröße	4,8 µm
	Bildrate	170 fps
	Schnittstelle	USB 3.0
Objektiv	Objektiv-Mount	C-Mount
	Hersteller	Edmund Optics Inc
	Bezeichnung	2,0x SilverSeries Telecentric Lens
	Vergrößerung	2,0
	Arbeitsabstand	75 mm
	Schärfentiefe	± 0,13 mm
	Blendenzahl numerische Aperatur	6 - geschlossen 0,164
Lasereinheit	Hersteller	Z-LASER Optoelektronik GmbH
	Bezeichnung	Z30M18H3-F-450-lp45
	Wellenlänge	450 nm
	Linienprofil	homogenes Linienprofil
Beleuchtung	Hersteller	Smart Vision Lights
	Bezeichnung	ODSXA30 Prox Light

A.2 Technische Daten der verwendeten Messinstrumente

Tabelle A.2: Technische Daten des Profilprojektor Keyence IM6020

Bildsensor	CMOS 1", 6,6 Megapixel
Messbereich	25 mm
Wiederholgenauigkeit	$\pm 0,5 \mu\text{m}$
Messgenauigkeit	$\pm 2 \mu\text{m}$

Tabelle A.3: Technische Daten des konfokalen 3D Laserscanning-Mikroskop Keyence VK-X100

Bildsensor	CCD 1/3", 7 Megapixel
Messbereich x,y	100 mm
Messbereich z	7 mm
Wiederholgenauigkeit x,y	$0,05 \mu\text{m}$
Wiederholgenauigkeit z	$0,02 \mu\text{m}$
Auflösung z	$0,005 \mu\text{m}$

A.3 Ablaufdiagramm der Algorithmen zur Bildverarbeitung

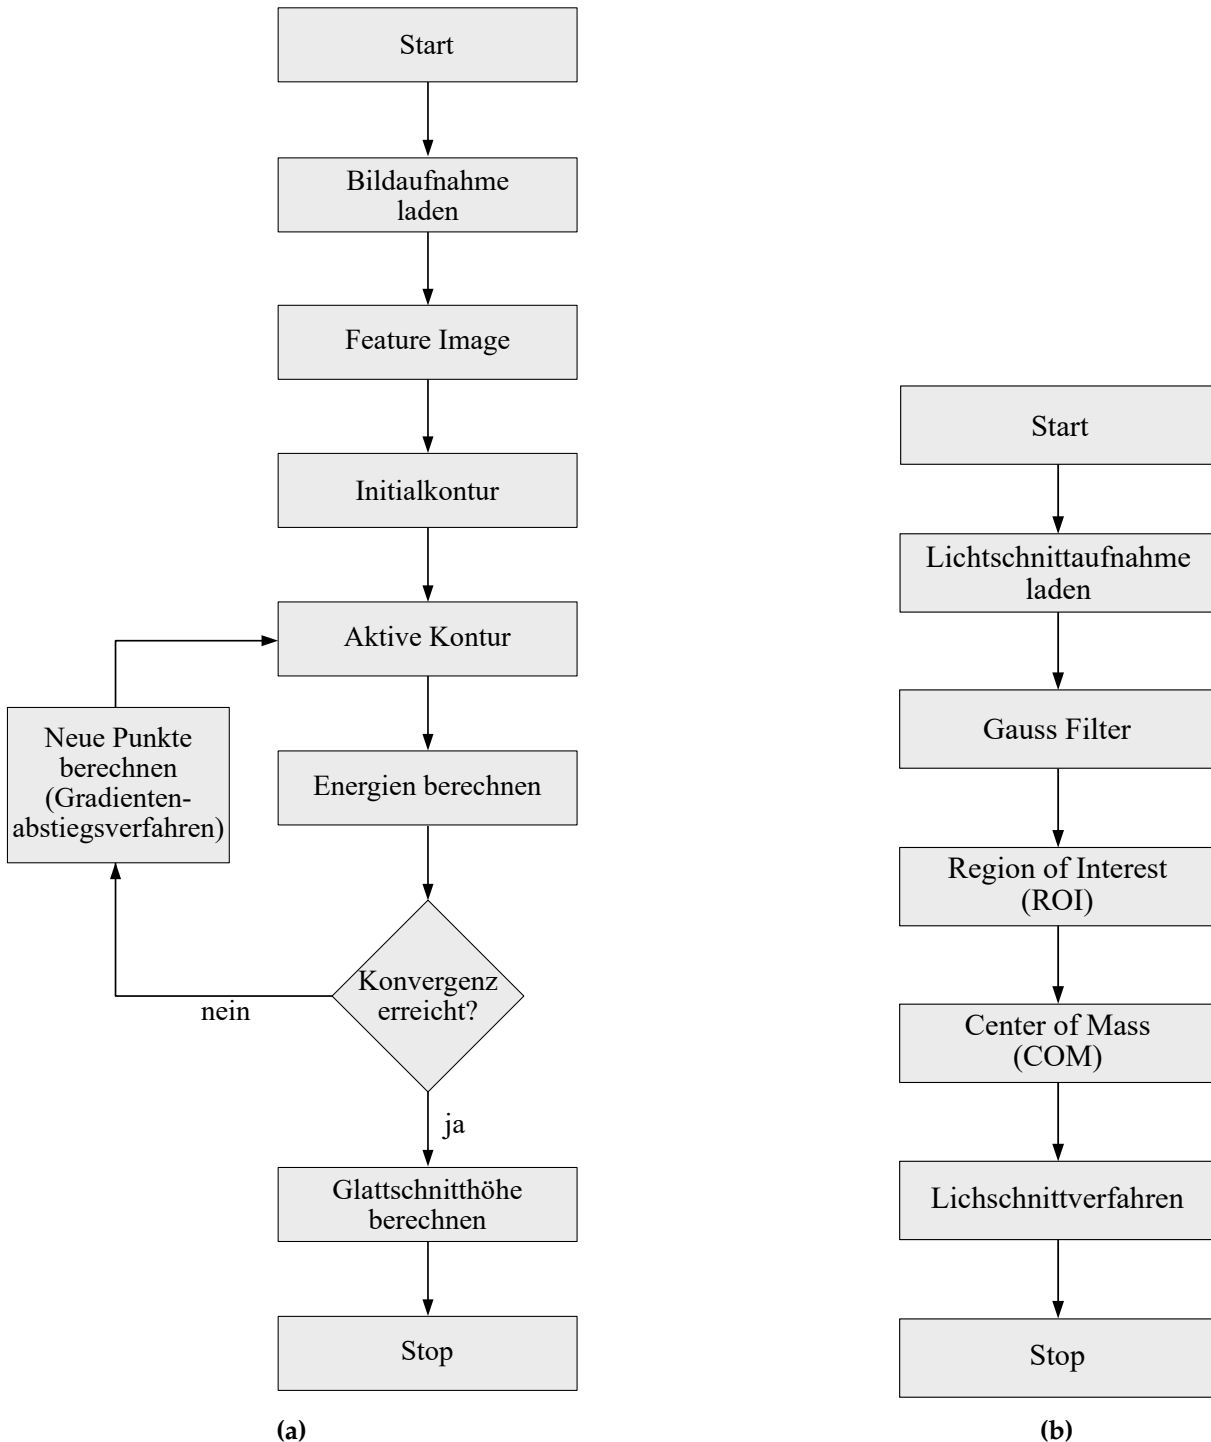


Abbildung A.1: Ablaufdiagramm der Algorithmen zur Bildverarbeitung (a) Aktive Konturen (b) Lichtschnittverfahren

A.4 Bewertungstabellen der trainierten Architekturen mit den entwickelten Ähnlichkeitskoeffizienten

Tabelle A.4: Vergleich der erzielten Ergebnisse aller untersuchten Netzwerkarchitekturen mit den Testdaten (Verarbeitungszeit pro Aufnahme t_{inf}).

Architektur	kombinierter Koeffizient	Anteil der prognostizierten Fläche in %	Anteil der zugeordneten Komponenten in %	Komponentenverhältnis	Einrissverhältnis	t_{inf} in ms
64 Feature Maps	99,39	99,78	99,33	2,19	1,05	4,43
6 Netzwerkschichten, Blocktiefe 3, 64 Feature Maps	99,38	99,94	99,83	2,19	1,04	5,99
6 Netzwerkschichten	99,26	99,92	99,68	2,19	1,06	6,14
Blocktiefe 3	99,19	99,98	99,59	2,19	1,06	5,71
Referenz	99,08	99,64	99,21	2,19	1,06	4,29
Blocktiefe 1	98,73	99,30	98,01	2,19	1,07	2,78
16 Feature Maps	98,69	99,84	99,12	2,18	1,08	4,11
nnU-Net	95,83	92,51	89,16	2,57	0,84	4,52
Blocktiefe ansteigend	98,62	99,16	98,15	2,20	1,11	9,24
Dense-Backbone	98,39	100,98	100,34	2,20	1,08	4,95
4 Netzwerkschichten	98,02	100,16	99,92	2,20	1,21	2,90
8 Feature Maps	97,87	98,63	96,24	2,20	1,10	4,02
3 Netzwerkschichten	97,70	99,59	99,01	2,20	1,21	1,75
MedT	93,41	96,68	94,42	2,86	1,45	91,24
SegNet	81,14	97,32	95,32	2,20	1,70	5,84

Tabelle A.5: Vergleich der erzielten Ergebnisse aller untersuchten Netzwerkarchitekturen mit den Transferdaten (Verarbeitungszeit pro Aufnahme t_{inf}).

Architektur	kombinierter Koeffizient	Anteil der prognostizierten Fläche in %	Anteil der zugeordneten Komponenten in %	Komponentenverhältnis	Einrissverhältnis	t_{inf} in ms
64 Feature Maps	82,49	106,14	102,06	7,75	4,38	5,23
Blocktiefe 3	81,65	112,02	106,36	6,94	3,55	6,39
6 Netzwerkschichten	81,19	108,58	104,27	5,92	3,28	7,21
Referenz	80,67	106,43	100,66	7,28	5,00	5,67
3 Netzwerkschichten	80,40	106,78	100,03	5,29	6,82	2,12
16 Feature Maps	80,12	111,55	106,84	6,37	2,54	5,15
Blocktiefe 1	79,98	108,54	102,22	8,75	4,77	3,22
4 Netzwerkschichten	79,95	112,34	109,10	5,80	4,88	3,34
Blocktiefe ansteigend	79,90	106,40	103,12	8,24	4,43	8,12
Dense-Backbone	79,32	111,56	108,02	6,46	2,46	6,85
6 Netzwerkschichten, Blocktiefe 3, 64 Feature Maps	79,24	98,30	93,73	5,72	3,62	10,28
8 Feature Maps	78,52	121,62	112,06	6,40	5,85	4,60
nnU-Net	78,43	108,34	106,21	5,32	2,98	6,42
SegNet	70,87	109,74	106,08	7,26	6,62	13,26
MedT	69,88	104,10	102,82	7,12	4,78	185,10

A.5 Auswertung der Netzwerke zur Bildverarbeitung

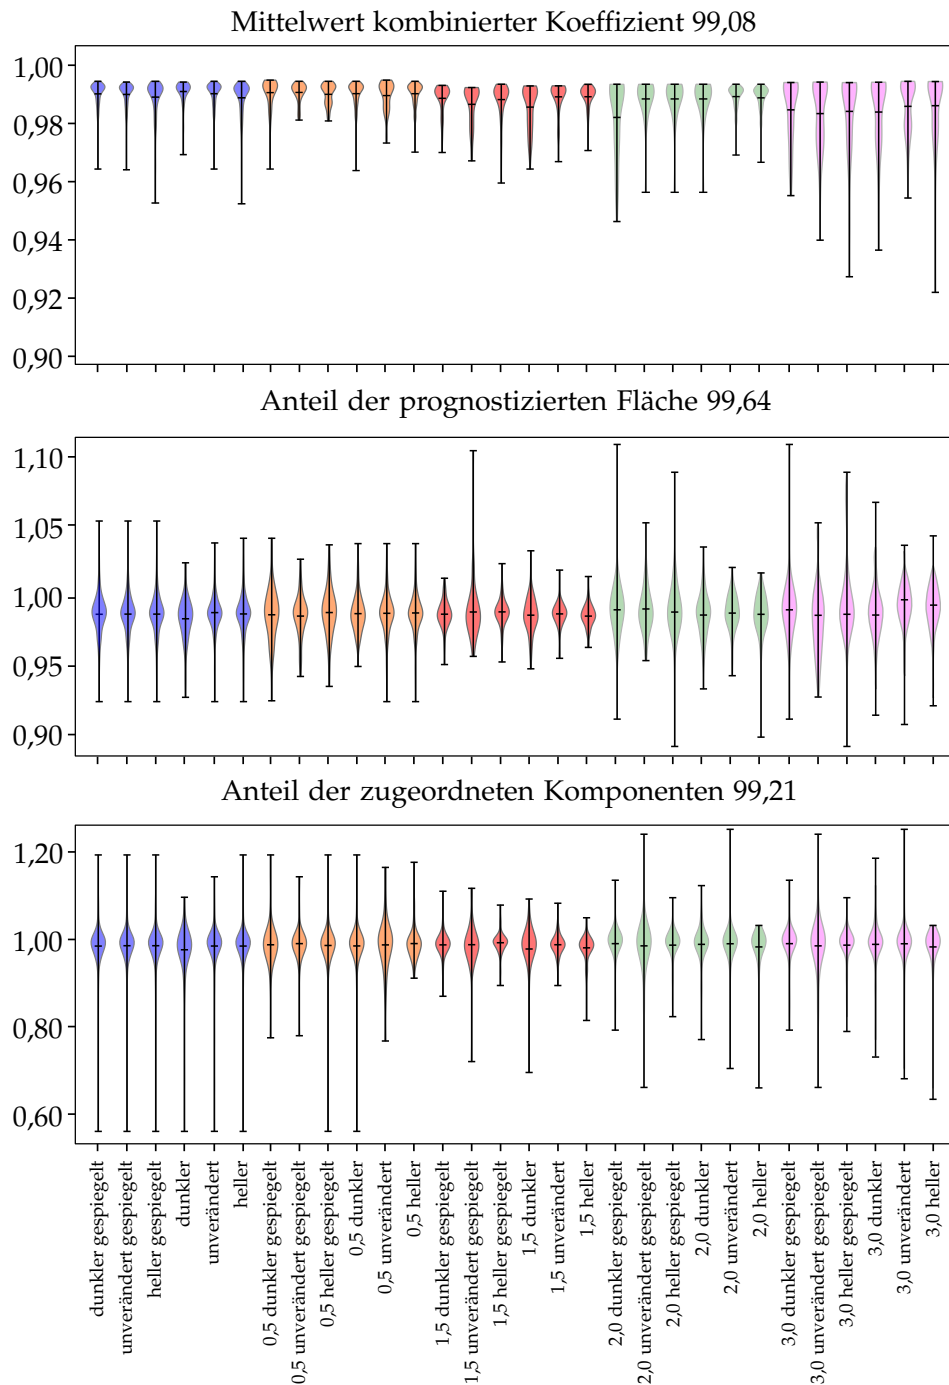


Abbildung A.2: Vollständige Bewertung des Referenznetzwerks U-Net++, aufgeteilt nach den Kategorien der künstlichen Datenerweiterung. Teil 1

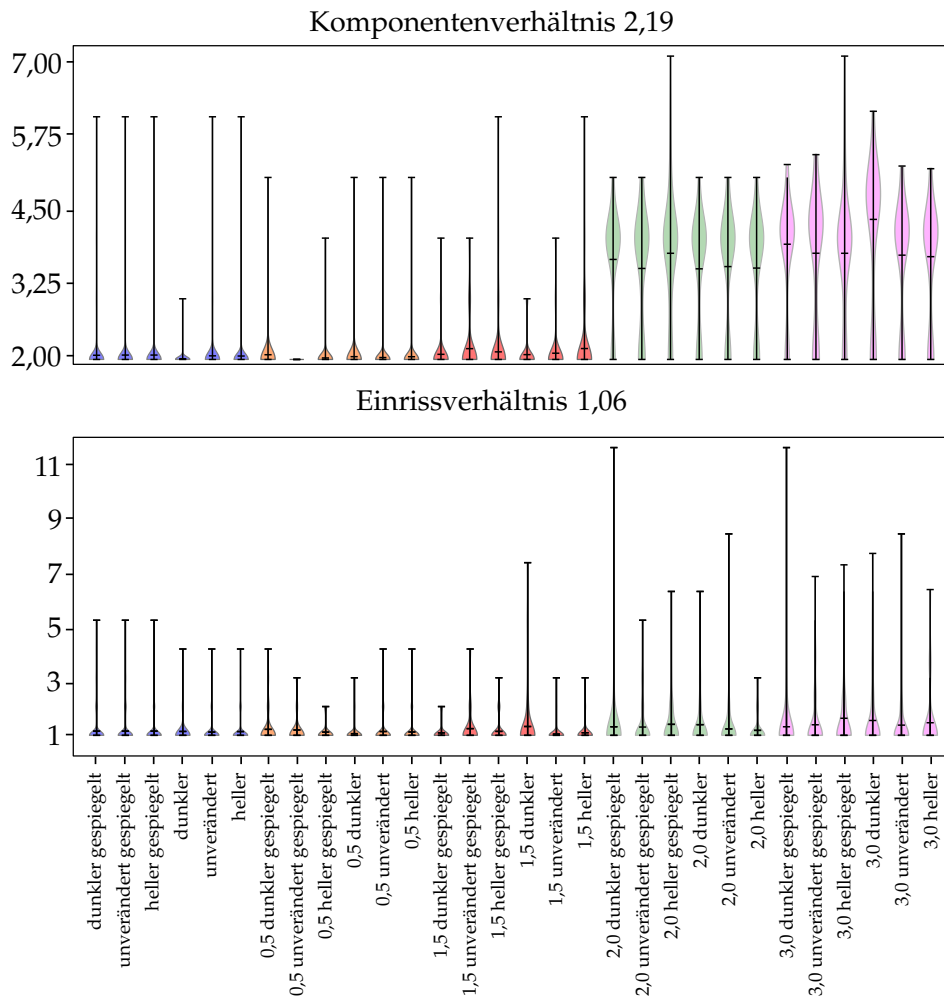


Abbildung A.3: Vollständige Bewertung des Referenznetzwerks U-Net++, aufgeteilt nach den Kategorien der künstlichen Datenerweiterung. Teil 2

A.6 Technische Daten der verwendeten Sensoren für das Sensornetzwerk

Tabelle A.6: Übersicht der verwendeten Versuchskomponenten für das Sensornetzwerk

Komponente	Technische Daten	
Datenlogger	Hersteller	Hottinger Brüel & Kjaer GmbH
	Bezeichnung	MX410
Ladungsverstärker	Hersteller	Kistler Instrumente AG
	Bezeichnung	Type 5007
Kraftsensor	Hersteller	Schwer + Kopka GmbH
	Sensortyp	DiskFlex-Sensoren
	Sensorgroße	12 mm × 3 mm
Beschleunigungssensor	Hersteller	Kistler Instrumente AG
	Sensortyp	8616A500, 8763B2K0AB
Körperschallsensor	Hersteller	Kistler Instrumente AG
	Sensortyp	8152A
	Piezocoupler	5125A
	Zeitkonstante τ_{RMS}	1,2 ms
Banddickenmesssystem	Hersteller	Micro-Epsilon Messtechnik GmbH & Co. KG
	Bezeichnung	thicknessGauge C.LP 8/20

Publikationsliste

Teilergebnisse der vorliegenden Arbeit sind Gegenstand folgender Publikationen:

M. Lorenz, M. Menzl, C. Donhauser, M. Layh und B. R. Pinzer, „Optical inline monitoring of the burnish surface in the punching process“, *The International Journal of Advanced Manufacturing Technology* 118 (11-12 Feb. 2022), S. 3585–3600, ISSN: 0268-3768. DOI: 10.1007/s00170-021-07922-6

M. Lorenz, M. Menzl, C. Donhauser, M. Layh und B. R. Pinzer, „Optische Inline-Überwachung der Schnittflächenparameter innerhalb des Stanzprozesses“, *Pressen, Systeme, Prozesse der Zukunft: Effizienz + Digitalisierung: Tagungsband des 40. EFB-Kolloquiums Blechverarbeitung 2022 am 29. und 30. März als Webkolloquium*, ISBN: 978-3-86776-586-2

M. Lorenz, R. J. Martin, T. Bruecklmayr, C. Donhauser und B. R. Pinzer, „Neural networks for inline segmentation of image data in punching processes“, *The International Journal of Advanced Manufacturing Technology* (2023), DOI: 10.1007/s00170-023-11784-5

Im Rahmen dieser Arbeit betreute studentische Abschlussarbeit:

T. Brücklmayr, „Analyse und Optimierung von neuronalen Netzwerken zur Inline-Segmentierung von Bilddaten aus dem Stanzprozess“. Bachelorarbeit. Kempten: Hochschule für angewandte Wissenschaften Kempten, 2021.

DuEPublico

Duisburg-Essen Publications online

UNIVERSITÄT
DUISBURG
ESSEN

Offen im Denken

ub | universitäts
bibliothek

Diese Dissertation wird via DuEPublico, dem Dokumenten- und Publikationsserver der Universität Duisburg-Essen, zur Verfügung gestellt und liegt auch als Print-Version vor.

DOI: 10.17185/duepublico/78770

URN: urn:nbn:de:hbz:465-20230821-151037-7



Dieses Werk kann unter einer Creative Commons Namensnennung - Nicht kommerziell - Keine Bearbeitungen 4.0 Lizenz (CC BY-NC-ND 4.0) genutzt werden.