

Technische Universität München
TUM School of Computation, Information and Technology

Prozessorientierter Digitaler Zwilling für die Additive Fertigung mittels Lichtbogenauftragschweißen

Raven Thomas Reisch

Vollständiger Abdruck der von der TUM School of Computation, Information and Technology der Technischen Universität München zur Erlangung eines

Doktors der Ingenieurwissenschaften (Dr.-Ing.)

genehmigten Dissertation.

Vorsitz: Prof. Dr. Rüdiger Westermann

Prüfer*innen der Dissertation:

1. Prof. Dr.-Ing. habil. Alois C. Knoll
2. Prof. Dr. Peter Mayr

Die Dissertation wurde am 25. Oktober 2022 bei der Technischen Universität München eingereicht und durch die TUM School of Computation, Information and Technology am 17. April 2023 angenommen.

Danksagung

Mein zutiefst empfundener Dank gilt meinem Doktorvater Herrn Prof. Dr.-Ing. habil. Alois Christian Knoll, Inhaber des Lehrstuhls für Robotik, Künstliche Intelligenz und Echtzeitsysteme der Technischen Universität München, für das uneingeschränkte Vertrauen in meine Arbeit und das Ermöglichen der Promotion.

Meinen ausdrücklichen Dank möchte ich zudem Herrn Prof. Dr. Peter Mayr, Inhaber des Lehrstuhls für Werkstofftechnik der Additiven Fertigung der Technischen Universität München, für die Übernahme der Rolle des Zweitgutachters aussprechen.

Ganz besonders möchte ich mich bei meinem Teamleiter und Mentor Dr.-Ing. Tobias Kamps bedanken. Er stand mir stets persönlich und fachlich mit Rat und Tat zur Seite und hielt mir den Rücken frei, wenn es nötig war. Ohne seine Unterstützung wäre das Erreichte nicht möglich gewesen.

Darüber hinaus gilt mein Dank meinen Promotionskollegen M.Sc. Philipp Breese, M.Sc. Benjamin Lutz, Ph.D. Tobias Hauser, M.Sc. Matteo Pantano, M.Sc. Alexander Schmidt, M.Sc. Marius Breuer und M.Sc. Lucas Janisch. Wir haben uns gegenseitig nicht nur durch gemeinsames Brainstorming, lange Paperabende und gegenseitiges Korrekturlesen zu aufschlussreichen wissenschaftlichen Ergebnissen getrieben, sondern sind im Laufe der Zeit auch gute Freunde geworden.

Weiterhin gilt mein Dank all jenen, mit denen ich während meiner Doktorarbeit bei der Siemens AG und an der Technischen Universität München zusammen arbeiten durfte: den Studierenden, mit denen ich gemeinsam die Ideen meiner Dissertation umgesetzt habe; meinen KollegInnen am Lehrstuhl, mit denen stets ein Austausch zu diversen Themen möglich war und die einem bei Bedarf mit helfender Hand zur Seite standen; meinen KollegInnen bei der Siemens T AMM FMP-DE, mit denen ich in den letzten Jahren viele spannende Unterhaltungen geführt und interessante Projekte bearbeitet habe und die mich nun auch auf dem nächsten Abschnitt meiner beruflichen Reise begleiten. Dank gebührt zudem Dr. Carsten Schuh, der das Promotionsvorhaben und die anschließende Übernahme bei Siemens erst möglich machte. Ich will mich zudem herzlich bei allen Freunden bedanken, die mich auf meinem akademischen Weg und privat begleitet haben, die stets ein offenes Ohr hatten und die mir immer wieder zeigten, dass es auch eine Welt außerhalb der Dissertation gibt.

Ganz besonders möchte ich mich bei M.Sc. Hannah Doleski bedanken. Deine Unterstützung, dein Zuspruch, deine Geduld und dein Verständnis lassen sich nicht in Worte fassen und haben mir gezeigt, dass ich immer auf dich zählen kann.

Zuletzt möchte ich mich zutiefst bei meinen Eltern Regierungsdirektorin Dr.-Ing. Anke Weisbrodt-Reisch und Prof. Dr.-Ing. Manfred Reisch sowie bei meinen Schwestern Dr.-med. Myriam/Mydima Reisch und M.A. Kaiya Reisch bedanken. Auf eure vorbehaltlose Unterstützung kann ich mich stets verlassen. Ohne euch wäre all das nicht möglich gewesen.

Durch die Zusammenarbeit und den Austausch mit den genannten Personen und vielen weiteren hatte ich stets das Gefühl, dass mir sowohl in den Höhen als auch den Tiefen im Laufe des Promotionsvorhabens immer jemand zur Seite stand - Danke!

Ich bedanke mich darüber hinaus für die finanzielle Unterstützung beim Bayerischen Verbundforschungsprogramm (BayVFP Förderlinie Digitalisierung / FuE –Programm) im Rahmen des Projekts „VALIDAD“ (*VALIDierung ADDitiver Fertigungstechniken für die Anwendung in der Metallverarbeitung*; Nr.: IUK-1905-0013) sowie beim Europäischen Institut für Innovation und Technologie im Rahmen des Projekts „SAMOA“ (*Sustainable Aluminium additive Manufacturing for high performance Applications*, Nr.: 18079) als Teil der Förderlinie EIT RawMaterials.

Abstract

Wire Arc Additive Manufacturing (WAAM) enables the production of large-scale metal parts. It represents an alternative to conventional manufacturing processes and enables a more sustainable production thanks to cost and time savings as well as lower material usage. With regard to the industrialization of this manufacturing technology, various obstacles arise along the value chain. Process planning is complex and requires expert knowledge, the process can exhibit instabilities and requires extensive support by a machine operator, and quality assurance is cost-intensive and time-consuming. These challenges can be met by extensive digitalization and automation of the process. As the central information carrier, process data is of particular importance. The information derived from the process data can be used to optimize process planning and to improve the manufacturing process. Additionally, it can supplement quality assurance. However, there is a lack of WAAM-compliant methods for processing, evaluating and using process data to exploit its full potential for the industrialization of the process.

This thesis presents a holistic concept to prepare, evaluate and utilize WAAM process data. A process-oriented context-aware, autonomous and adaptive digital twin is designed and methods for processing data in the areas of digital part and process representation, process monitoring and data-driven process interventions are presented.

Within the digital part and process representation, concepts for providing system context, spatial context and temporal context are investigated. The system context is provided via an OPC UA information model as well as a process state model. The temporal context can be obtained using temporal indexing of all data instances. The spatial context is retrievable using an octree and is linked to the temporal context by means of spatio-temporal indexing. In order to realize a connection to the upstream and downstream steps of the value chain, a methodology for the spatial annotation of time series is presented. The obtained annotations are used to train and evaluate process monitoring methods.

Process monitoring analyzes the WAAM process in a data-driven manner and provides quality and process information in real time. The process is first digitally modeled and a cause-and-effect analysis is performed with respect to irregularities in the sensor signals. Based on the time series characteristics, a suitable anomaly detector is assigned to the process data. Using a parameterizable autoencoder with conditional external memory module, PR AUC scores of up to 0.963 were realized in anomaly detection. Using meta learning and appropriate initialization methods of the memory entries, a PR AUC score of 0.850 was achieved with only ten training data items. The defect classification is designed to be context-aware. This resulted in an improvement in classification precision of up to 22.2 percentage points for oxidation defects. The use of meta learning improved classification precision by 14.8 percentage points for discontinuity defects. Finally, methods for measuring the distance between the welding torch and the component are investigated. Spectrometer data show near-linear correlation with the distance at a wavelength of 905 nm. However, the measurements depend on process parameters and the geometry of the part despite data preprocessing. The analysis of welding camera images using a convolutional neural network enables distance measurements which are

independent of the welding direction and of the process parameter and don't require layerwise manufacturing.

The proposed process interventions autonomously correct deviations from the target state in real time. A closed-loop control is designed which adjusts the welding speed to influence the weld bead height and to keep the distance between the welding torch and the component constant. Based on an analytical model of the weld bead geometry, the wire feed speed is adjusted to keep the weld bead width as well as the energy input per unit length constant. The omnidirectional, layer-invariant distance control allowed complex components with multi-axis operations to be successfully built without prior process parameter optimization. In addition, a methodology for prescriptive process parameter adaption is presented to compensate for defects and to avoid subsequent defects. A prediction of the tool center point position is performed and the future spatial context is evaluated to initiate a process intervention. The concept is evaluated by compensating discontinuity defects. A statistically significant reduction in defect group size was achieved.

The data-driven process interventions, the process monitoring and the digital representation represent the core elements of the digital twin for WAAM. The digital twin is investigated within an industrial manufacturing scenario. For this purpose, a prototype of the digital twin is implemented and validated by manufacturing two WAAM parts. Both the overall system and the individual elements meet the requirements for an industry-appropriate, context-aware, adaptable and autonomous digital twin for WAAM. The digital twin can be used for process optimization and serves as an information source for quality assurance and process planning.

Zusammenfassung

Die additive Fertigung mittels Lichtbogenauftragschweißen (WAAM) ermöglicht die Fertigung großvolumiger, metallischer Bauteile. Sie stellt damit eine Alternative zu konventionellen Fertigungsverfahren dar und ermöglicht durch Kosten- und Zeitersparnisse sowie einen geringeren Materialeinsatz eine nachhaltigere Produktion. Im Hinblick auf die Industrialisierung dieser Fertigungstechnologie ergeben sich verschiedene Hindernisse entlang der digitalen Wertschöpfungskette. Die Prozessplanung ist aufwändig und erfordert Fachwissen, der Prozess kann Instabilitäten aufweisen und benötigt eine umfassende Betreuung und die Qualitätssicherung ist kostenintensiv und zeitaufwendig. Diesen Herausforderungen kann durch eine umfassende Digitalisierung und Automatisierung des Prozesses begegnet werden. Als zentralem Informationsträger kommt dabei den Prozessdaten eine besondere Bedeutung zu. Die aus ihnen abgeleiteten Informationen können zur Optimierung in der Prozessplanung und zur Verbesserung des Fertigungsprozesses genutzt werden und die Qualitätssicherung ergänzen. Um das volle Potential der Prozessdaten für die Industrialisierung des Prozesses auszuschöpfen, fehlt es jedoch an WAAM-gerechten Methoden zur Aufbereitung, Auswertung und Nutzung dieser Daten.

Innerhalb dieser Arbeit wird ein ganzheitliches Konzept zur Aufbereitung, Auswertung und Nutzung der WAAM-Prozessdaten vorgestellt. Dazu werden ein kontextwahrnehmender, autonomer und anpassungsfähiger Digitaler Zwilling konzipiert und Methoden zur Datenverarbeitung in den Bereichen digitale Bauteil- und Prozessrepräsentation, Prozessüberwachung und datengestützter Prozesseingriff vorgestellt.

Innerhalb der digitalen Repräsentation von Bauteil und Prozess werden Konzepte zur Bereitstellung von Systemkontext, räumlichen sowie zeitlichen Kontext dargelegt. Der Systemkontext wird über ein OPC UA Informationsmodell sowie über ein Prozesszustandsmodell bereitgestellt. Die Untersuchung des zeitlichen Kontexts gelingt über die zeitliche Indexierung aller Dateninstanzen. Der räumliche Kontext wird unter Nutzung eines Octrees analysiert und mithilfe einer Raumzeitindexierung mit dem zeitlichen Kontext in Verbindung gebracht. Um eine Anbindung an die vor- und nachgelagerten Schritte der Produktentstehung zu realisieren, wird eine Methodik zur räumlichen Annotation von Zeitreihen vorgestellt. Die erhaltenen Annotationen werden für das Training und die Evaluierung der Methoden der Prozessüberwachung genutzt.

Die Prozessüberwachung analysiert den WAAM-Prozess datengetrieben und stellt prozessparallel Qualitäts- und Prozessinformationen bereit. Dazu wird der Prozess zunächst modelliert und eine Ursachen-Wirkungs-Analyse hinsichtlich der Unregelmäßigkeiten in den gemessenen Prozessdaten vorgenommen. Die Auswahl eines geeigneten Anomaliedetektors wird auf ein Klassifikationsproblem zurückgeführt, bei dem die Zeitreihenmerkmale der Prozessdaten mit den Detektionsleistungen der Anomaliedetektoren in Verbindung gesetzt werden. Mithilfe eines parametrisierbaren Autoencoders mit konditionierbarem, externen Speichermodul wurden PR AUC-Werte von bis zu 0.963 bei der Anomaliedetektion realisiert. Durch Metalernen und eine geeignete Initialisierung der Speichereinträge wurde mit lediglich zehn Trainingsdatenelementen ein PR AUC-Wert von 0.850 erreicht. Die Defektklassifikation ist kontextwahrnehmend

gestaltet. Dadurch wurde eine Verbesserung der Klassifikationsgenauigkeit um bis zu 22.2 Prozentpunkte für Oxidationsdefekte erreicht. Durch die Nutzung von Metalernen wurde die Klassifikationsgenauigkeit für Unstetigkeitsdefekte um bis zu 14.8 Prozentpunkte verbessert. Abschließend werden Methoden zur Messung des Abstands zwischen Schweißbrenner und Bauteil vorgestellt. Die Spektrometerdaten zeigen bei einer Wellenlänge von 905 nm eine nahezu lineare Korrelation mit dem Abstand. Sie sind jedoch trotz Datenvorverarbeitung prozessparameter- und richtungsabhängig. Die Analyse von Schweißkamerabildern mithilfe eines faltenden neuronalen Netzes ermöglicht eine schicht-, richtungs- und prozessparameter-invariante Abstandsmessung.

Der datengestützte Prozesseingriff korrigiert autonom Abweichungen vom Sollzustand im Prozess. Es wird eine Abstandsregelung konzipiert, welche die Schweißgeschwindigkeit anpasst, um Einfluss auf die Schweißnahthöhe zu nehmen und so den Abstand zwischen Schweißbrenner und Bauteil konstant zu halten. Auf Basis eines analytischen Modells der Schweißnahtgeometrie wird die Drahtvorschubgeschwindigkeit angepasst, um die Schweißnahtbreite sowie die Streckenenergie konstant zu halten. Durch die omnidirektionale, schichtinvariante Abstandsregelung wurden komplexe Bauteile mit Multiachsoperationen ohne vorherige Prozessparameteroptimierung beim ersten Versuch erfolgreich aufgebaut. Darüber hinaus wird eine Methodik zur präskriptiven Prozessparameteranpassung vorgestellt, mit der Defekte kompensiert und Folge-defekte vermieden werden. Es wird eine Positionsvorhersage vorgenommen und der zukünftige räumliche Kontext ausgewertet, um einen Prozesseingriff zu initiieren. Das Konzept wurde anhand der Kompensation eines Unstetigkeitsdefekts evaluiert und eine statistisch signifikante Reduktion der Defektgruppengröße erreicht.

Der datengestützte Prozesseingriff, die Prozessüberwachung und die digitale Bauteil- und Prozessrepräsentation bilden die Kernelemente des Digitalen Zwilling für die additive Fertigung mittels Lichtbogenauftragschweißen. Dieser wird schließlich innerhalb eines industriellen Fertigungsszenarios untersucht. Dazu wird er als Gesamtsystem konzipiert, prototypisch umgesetzt und anhand der Fertigung zweier WAAM-Bauteile validiert. Sowohl das Gesamtsystem als auch die drei Kernelemente erfüllten die Anforderungen an einen industriegerechten, kontextwahrnehmenden, anpassungsfähigen und autonomen Digitalen Zwilling für die Additive Fertigung mittels Lichtbogenauftragschweißen. Der Digitale Zwilling kann für die Prozessoptimierung eingesetzt werden und als Informationsquelle für die Qualitätssicherung und die Prozessplanung dienen.

Abbildungsverzeichnis

1.1	Vergleich von subtraktiver Fertigung und additiver Fertigung	1
1.2	Phasen der Produktentstehung eines WAAM-Bauteils	2
1.3	Aufbau der Arbeit	3
2.1	Vergleich verschiedener Technologien für die additive Fertigung	7
2.2	Schweißnahtgeometrien im WAAM-Prozess	9
2.3	Visualisierung des modellagnostischen Metalernens	26
2.4	Speichererweiterter Autoencoder	30
2.5	Precision-Recall Kurve für binäre Klassifizierungsmodelle	32
3.1	Zustandsdiagramm für den Digitalen Zwilling des WAAM-Prozesses	41
3.2	Zusammenspiel des räumlichen und zeitlichen Datenmanagements	42
3.3	Doppelellipsoid zur Modellierung eines Schweißbads	44
3.4	Latenzen für prozessparallele Octree-Abfragen	49
3.5	Kontextintegrierende Qualitätsmetriken	49
3.6	Octreediskretisierung zur Darstellung der lokalen Anomaliedichte	50
3.7	Räumliche Annotation von Defekten	51
3.8	Vergleich der zeit- und raumbasierten Defektannotation	51
4.1	Schematische Darstellung der Schweißregion	55
4.2	Ishikawa-Diagramm der WAAM-Einflussgrößen	56
4.3	Aufnahmen des CMT-Prozesses mit einer Hochgeschwindigkeitskamera	59
4.4	Strom- und Spannungsdaten für einen WAAM-Referenzprozess	59
4.5	Struktur- und Luftschallemissionen für einen WAAM-Referenzprozess	60
4.6	Spektrum eines WAAM-Referenzprozesses	60
4.7	Aufbau des konditionierten, speichererweiterten Autoencoders	65
4.8	Multivariate Anomaliedetektion mittels Mahalanobisdistanz	67
4.9	Datenfluss für die Drahtlängenbestimmung	72
4.10	Verteilung der PR AUC-Werte für die Anomaliedektoren	73
4.11	Zeitreihenmerkmale der genutzten öffentlichen Datensätze	73

4.12	Korrelationen zwischen Detektionsleistungen und Zeitreihenmerkmalen	74
4.13	Konturdiagramm für die Hyperparameteroptimierung des MemAEs	76
4.14	Entwicklung des PR AUC-Werts bei der Modellanpassung	77
4.15	Korrelation der Spektraldaten mit dem Schweißbrenner-Bauteil-Abstand	81
4.16	Darstellung der extrahierten Merkmale über den Abstand	82
4.17	Histogramme der extrahierten Merkmale bei konstantem Abstand	83
4.18	Abstandsmessung entlang des Aufbaus zweier Testkörper	84
5.1	Entscheidungsbaum zur Auswahl des erforderlichen Prozesseingriffs	88
5.2	Zusammenhang zwischen Schweißparametern und Schweißnahtgeometrie	90
5.3	Blockdiagramm des WAAM MIMO Systems	91
5.4	Systemkomponenten der Abstandsregelung im WAAM-Prozess	92
5.5	Schema der Abstands- und Schweißnahtbreitenregelung	93
5.6	Prozessparameteranpassung mittels präskriptiver Analytik	94
5.7	Zuordnung vom realen zum geplanten Werkzeugweg	95
5.8	Musterbauteile zur Evaluierung der Abstandsregelung	99
5.9	Lagenweise Entwicklung des Unstetigkeitsdefekts im Laufe des Aufbaus	101
6.1	Intelligentes WAAM-Fertigungssystem als mechatronisches System	104
6.2	Schema der WAAM-Zelle zur Erprobung	105
6.3	Mikroservicearchitektur des Digitalen Zwillinges	106
6.4	Benutzeroberfläche der Webapplikation	107
6.5	Maschinensimulation der WAAM-Fertigungsanlage	108
6.6	Multiaxialer WAAM-Prozess und Validierungsbauteile	110
6.7	Digitaler Zwilling des Verbindungselements	110
6.8	Digitaler Zwilling der bionisch inspirierten Leichtbaustruktur	111
A.1	Systemarchitektur des Cyber-Physischen-Systems	126
A.2	Benutzeroberfläche - Sensordatenansicht	127
A.3	Benutzeroberfläche - Anomalieerkennungsansicht	128
A.4	Benutzeroberfläche - Defektklassifikationsansicht	128
A.5	Benutzeroberfläche - Druckauftragsmanageransicht	129
A.6	Benutzeroberfläche - Systemzustand	129
B.1	Fotos von Defekten beim WAAM-Prozess	131
C.1	Parallelkoordinaten für die Hyperparameteroptimierung des Autoencoders	141

Tabellenverzeichnis

2.1	Analytische Modelle der Schweißnahtgeometrie	9
2.2	Wahrheitsmatrix zur Zuordnung von realen und vorhergesagten Klassen . . .	31
2.3	Forschungsbedarf des Digitalen Zwillings für den WAAM-Prozess	34
2.4	Einordnung des Forschungsbedarfs	35
3.1	OPC UA Informationsmodell für WAAM	39
4.1	Prozessparameter für den WAAM-Referenzprozess	58
4.2	Lösungsraum der Autoencoderhyperparameteroptimierung	64
4.3	Lösungsraum der Hyperparameteroptimierung für die Defektklassifikation . .	70
4.4	Evaluierung der Detektorauswahl mittels Klassifikation	75
4.5	Anomaliedetektoren für die WAAM-Sensordaten	75
4.6	Vergleich von AE, MemAE und C-MemAE	77
4.7	Evaluierung der Defektklassifikation ohne Metalernansatz	78
4.8	Evaluierung der Defektklassifikation mit Metalernansatz	79
4.9	Korrelation der Spannungsmerkmale mit dem Abstand	80
4.10	Korrelation ausgewählter Merkmale mit dem Abstand	82
5.1	Korrelationen zwischen Schweißparametern und Schweißnahtgeometrie	89
5.2	Übertragungsfunktionen für den WAAM-Prozess	91
5.3	Evaluierung der Abstandsregelung ohne Breitenmodul	97
5.4	Evaluierung der Abstandsregelung mit Breitenmodul	98
5.5	Charakteristiken des Prozesses mit und ohne Abstandsregelung	99
5.6	Evaluierung der präskriptiven Prozessparameteranpassung	101
6.1	Prozessparameter für die Validierung des Digitalen Zwillings	109
6.2	Anforderungen an den Digitalen Zwilling und zugehörige Lösungen	113
6.3	Anforderungen an die digitale Repräsentation und zugehörige Lösungen . . .	115
6.4	Anforderungen an die Prozessüberwachung und zugehörige Lösungen	116
6.5	Anforderungen an den Prozesseingriff und zugehörige Lösungen	117

7.1	Übertragbarkeit der vorgestellten Methoden	121
A.1	Sensoren der Prozessüberwachung	126
B.1	Zusammenhang zwischen Defekten und Folgedefekten	132
B.2	Datensätze für die Defektklassifikation	133
C.1	Datensätze für die Anomaliedetektion	135
C.2	Catch22 Zeitreihenmerkmale	136
C.3	Rekonstruktionsbasierte Anomaliedetektoren	137
C.4	Wahrscheinlichkeits- und distanzbasierte Anomaliedetektoren	138
C.5	Vorhersagebasierte Anomaliedetektoren	139
C.6	Hyperparameter der drei Klassifikationsmodelle zur Detektorauswahl	140

Abkürzungsverzeichnis

AE Autoencoder

AM Additive Manufacturing

AR Auto-Regressive

ARIMA Auto-Regressive Integrated Moving Average

ARMA Auto-Regressive Moving Average

AUC Area Under Curve

BJT Binder Jetting

CAD Computer Aided Design

CAx Computer Aided Tools

CAM Computer Aided Manufacturing

C-MemAE Conditional Memory Augmented Autoencoder

CMT Cold Metal Transfer

CMT-ADV Cold Metal Transfer Advanced Mode

CMT-P Cold Metal Transfer Pulse Mode

CMT-PADV Cold Metal Transfer Pulse Advanced Mode

CNN Convolutional Neural Network

CPS Cyber-Physische System

CRISP-DM Cross Industry Standard Process for Data Mining

CT Computertomographie

DED Directed Energy Deposition

DTW Dynamic Time Warping

ES Exponential Smoothing

FDM Fused Deposition Modelling

FN Falsch-Negativ-Einteilung

FP Falsch-Positiv-Einteilung

FPR	Falsch-Positiv-Rate
FPY	First Pass Yield
GAN	Generative Adversarial Network
GMAW	Gas Metal Arc Welding
GRU	Gated Recurrent Unit
GTAW	Gas Tungsten Arc Welding
HMI	Human Machine Interface
HTM	Hierarchical Temporal Memory
KNN	Künstliche Neuronale Netze
LMD	Laser Metal Deposition
LOF	Local Outlier Factor
L-PBF	Laser-Powder Bed Fusion
LSTM	Long Short-Term Memory
MA	Moving Average
MAE	Mean Absolute Error
MAG	Metall-Aktivgas
MAML	Model-Agnostic-Meta-Learning
MANN	Memory-Augmented Neural Network
MemAE	Memory-Augmented Autoencoder
MEX	Material Extrusion
MIG	Metall-Inertgas
MJT	Material Jetting
MIMO	Multi Input Multi Output
MLP	Multilayer Perceptron
MPC	Model Predictive Control
MQTT	Message Queuing Telemetry Transport
MSE	Mean Squared Error
MSG	Metall-Schutzgas
NC	Numerical Control
OC-SVM	One Class Support Vector Machine
OPC UA	Open Platform Communications Unified Architecture

PAW Plasma Arc Welding

PTAW Plasma Transferred Arc Welding

PBF Powder Bed Fusion

PR Precision-Recall

PR AUC Area Under the Precision Recall Curve

ReLU Rectified Linear Units

REST Representational State Transfer

RMSE Root Mean Squared Error

ROC Receiver Operating Characteristic

ROI Region of Interest

RNN Recurrent Neuronal Network

SARIMA Seasonal Auto-Regressive Integrated Moving Average

SES Simple Exponential Smoothing

SHL Sheet Lamination

SMS Smart Manufacturing System

SPS Speicherprogrammierbare Steuerung

SVM Support Vector Machine

TCP Tool Center Point

TIG Tungsten Inert Gas

TN Richtig-Negativ-Einteilung

TNR Richtig-Negativ-Rate

TP Richtig-Positiv-Einteilung

TPR Richtig-Positiv-Rate

umati universal machine technology interface

UML Unified Modeling Language

UDP User Datagram Protocol

VPP Vat Photopolymerization

WAAM Wire Arc Additive Manufacturing

WIG Wolfram Inertgas

Symbolverzeichnis

Symbol	Einheit	Beschreibung
α	◦	Rollwinkel
α_{MAML}		Lernrate der inneren MAML-Schleife
β	◦	Nickwinkel
β_F		Faktor des F_β -Werts
β_{MAML}		Lernrate der äußeren MAML-Schleife
δ		Grenzwert
ϵ		Fehlerwert für den MA- und den AR-Algorithmus
γ	◦	Gierwinkel
ν		Effizienzfaktor der Energieübertragung beim Schweißen
$\rho_{X,Y}$		Pearson'scher Korrelationskoeffizient für die Verteilung X und Y
σ		Standardabweichung
θ		Parameter eines Modells
θ^*		Durch Fehlerwertfunktion optimierter Parameter eines Modells
θ_e		Modellparameter des Encoders
θ_d		Modellparameter des Decoders
θ_M		Modellparameter des externen Speichers des Autoencoders
A		Ereignis
\mathbf{A}		Matrix der Matrixnorm
$A_{DE-v,h}$		Matrix zur Beschreibung des vorderen bzw. hinteren Bereichs des Dopelellipsoids
A_S	mm ²	Analytisch ermittelter Schweißnahtquerschnitt
A_V	mm ²	Mittlerer Schweißnahtquerschnitt
ACC		Treffergenauigkeit
a		Hilfsvariable für das Modell der Schweißnahtgeometrie
a_{DE-h}	mm	Ausdehnung der hinteren Halbachse des Dopelellipsoids in x-Richtung
a_{DE-v}	mm	Ausdehnung der vorderen Halbachse des Dopelellipsoids in x-Richtung
B		Ereignis
B_i		Batch für den MAML-Algorithmus
b		Hilfsvariable für das Modell der Schweißnahtgeometrie
b_{DE}	mm	Ausdehnung der Halbachse des Dopelellipsoids in y-Richtung
b_i		Bias für die Funktion eines Neurons
b_S	mm	Schweißnahtbreite
b_{S-ref}	mm	Referenzschweißnahtbreite

c		Kondition
\mathcal{C}		Räumlicher Kontext
c_{AR}		Konstante des AR-Algorithmus
c_{DE}	mm	Ausdehnung der Halbachse des Ellipsoids in z-Richtung
cov		Kovarianzmatrix
\mathcal{D}		Datensatz
\mathcal{D}^{train}		Trainingsdatensatz
D_i		Aufgabendatensatz
D_i^{train}		Trainingsdatensatz der Aufgabe i
D_i^{test}		Testdatensatz der Aufgabe i
\mathcal{D}^{train}		Metatrainingdatensatz
\mathcal{D}^{test}		Metatestdatensatz
$\mathbf{D}_{DE-v,h}$		Diagonalmatrix
d_{ARIMA}		Parameter des ARIMA-Algorithmus
d_h	mm	Hatchingdistanz
d_l	mm	Schichthöhe
d_{Mahal}		Mittels Mahalanobisdistanz kombinierter Anomaliewert
$d_{Messung}$	Pixel	Detektierte Länge des sichtbaren Drahts
$\bar{d}_{Messung}$	mm	Gemittelte, detektierte Länge des sichtbaren Drahts
d_{NtW}	mm	Abstand zwischen Schweißbrenner und Bauteil
$d_{NtW-ref}$	mm	Referenzabstand zwischen Schweißbrenner und Bauteil
$d_{Unschärfe}$	mm	Unschärfeparameter bei der räumlichen Annotation von Zeitreihen
$d_{Verdeckung}$	mm	Durch den Schweißbrenner verdeckter Abschnitt des herausstehenden Drahts
$d_{Versatz}$	mm	Mittlerer Abstand des Drahtendes zum Bauteil
d_w	mm	Drahtdurchmesser
$d(\mathbf{x}, \mathbf{y})$		Distanz zwischen \mathbf{x} und \mathbf{y}
E_S	J mm^{-1}	Streckenenergie
F_β		Wert der F_β -Evaluierungsmetrik
FPR		Falsch-Positiv-Rate
f_θ		Funktion des Modells in MAML
$f_e(\mathbf{x}; \theta_e)$		Funktion des Encoders mit Eingangsgröße \mathbf{x} und Parametern θ_e
$f_d(\mathbf{z}; \theta_d)$		Funktion des Decoders mit Eingangsgröße \mathbf{z} und Parametern θ_d
f_g	L min^{-1}	Gasfluss
f_{TCP}	Hz	Aufzeichnungsfrequenz der TCP-Positionen
f_s	Hz	Abtastrate eines Sensorsignals
G_{xy}		Übertragungsfunktion
H_i	mm	Höhe der Wand i
H_{Soll}	mm	Sollhöhe der Wand
$\Delta \bar{H}$	mm	Durchschnittliche Abweichung von der Sollwandhöhe
$h(\theta)$		Generalisierende Funktion zur Abbildung von X auf Y
$h_i(x)$		Funktion eines Neurons i
h_S	mm	Schweißnahthöhe
I	A	Strom
\bar{I}		Gemittelte Intensität des Spektrums
I_i		Spektrale Intensität für die Wellenlänge i
I_{i-rel}		Spektrales Verhältnis von I_i zu \bar{I}

i		Zählindex
$i(t)$	A	Zeitlicher Verlauf des Schweißstroms
j		Zählindex
j_{Octree}		Anzahl der Ebenen im Octree
k		Zählindex
$k_{K-Means}$		Anzahl der Cluster beim K-means Algorithmus
k_{sp}		Proportionalfaktor zur Anpassung des Modells der symmetrischen Parabel an einen mehrlagigen Aufbau
\mathcal{L}		Fehlerwertfunktion
l		Anomaliewertstrom
l_{Octree}	mm	Kantenlänge des Octrees
l_{Kubus}	mm	Kantenlänge des Kubus
l_{Voxel}	μm	Kantenlänge eines Octreevoxels
M_n		n .tes Speichermodul
$\mathbf{m}_{c,q}$		q .ter Speichermoduleintrag des c -ten Speichermoduls des C-MemAEs
n		Länge einer Zeitreihe
n_{Octree}		Anzahl der Elemente im Octree
p		Verteilung einer Menge
p_{AR}		Parameter des AR-Algorithmus
$PREC$		Genauigkeit
q		Zählindex
q_{MA}		Parameter des MA-Algorithmus
$q(r)$	W m^{-2}	Wärmefluss
\mathbf{R}		Rotationsmatrix
$\mathbf{R}_x(\alpha)$		Rotationsmatrix für eine Rotation um die x-Achse
$\mathbf{R}_y(\beta)$		Rotationsmatrix für eine Rotation um die y-Achse
$\mathbf{R}_z(\gamma)$		Rotationsmatrix für eine Rotation um die z-Achse
r_s		Rangkorrelationskoeffizient nach Spearman
$r_{Zyklusphasen}$		Verhältnis der CMT-Kurzschlusszeit zur gesamten CMT-Zykluszeit
s		Anzahl der Speichermoduleinträgen
$s(x)$		Aktivierungsfunktion eines Neurons
$s(\mathbf{x}, \mathbf{y})$		Kosinusähnlichkeit der Elemente \mathbf{x} und \mathbf{y}
\mathbf{T}		Zeitreihe
\bar{T}		Mittelwert der Zeitreihe
$\mathbf{T}_{TCP-soll}$		Zeitreihe der interpolierten, im Maschinencode hinterlegten TCP-Positionen
$\mathbf{T}_{TCP-ist}$		Zeitreihe der bereits angefahrenen TCP-Positionen
TNR		Spezifität
TPR		Sensitivität
t	s	Zeit
$t_{CMT-Zyklus}$	s	Dauer des CMT-Zyklus
$t^{(i)}$	s	Zeitpunkt i
t_k		Element einer Zeitreihe
t_k^{norm}		Normalisiertes Element einer Zeitreihe
t_k^l		Standardisiertes Element einer Zeitreihe
$t_{Kurzschluss}$	s	Dauer der CMT-Kurzschlussphase
t_{max}		Maximaler Wert einer Zeitreihe
t_{min}		Minimaler Wert einer Zeitreihe

t_{System}	s	Eingeplante Reaktionszeit des Systems
$t_{Vorhersage}$	s	Vorhersagezeitraum für die präskriptive Prozessparameteranpassung
U	V	Spannung
u		Dimension des Elements einer Zeitreihe
$u(t)$	V	Zeitlicher Verlauf der Schweißspannung
v		Dimension des Elements einer Zeitreihe
\mathbf{v}_{TCP}		Richtungsvektor der Schweißbewegung
v_{TCP}	mm min^{-1}	Schweißgeschwindigkeit
$v_{TCP-ref}$	mm min^{-1}	Referenzschweißgeschwindigkeit
v_{WF}	m min^{-1}	Drahtvorschubgeschwindigkeit
v_{WF-ref}	m min^{-1}	Referenzdrahtvorschubgeschwindigkeit
w_{ij}		Gewichtungsfaktor zwischen zwei Neuronen i und j
\mathbf{w}		Vektor mit den Kosinusähnlichkeiten der Speichermoduleinträge von MemAE/CMemAE
\mathbf{w}_c		Konditionierter Vektor mit den Kosinusähnlichkeiten der Speichermoduleinträge von CMemAE
$\hat{\mathbf{w}}$		Gewichtungsvektor des MemAEs nach Anpassung mittels Spärlichkeitsgrenzwert
$\hat{\mathbf{w}}_c$		Konditionierter Gewichtungsvektor des C-MemAEs nach Anpassung mittels Spärlichkeitsgrenzwert
\mathbf{X}		Verteilung
\bar{X}		Mittelwert der Elemente der Verteilung \mathbf{X}
\mathbf{x}		Eingangsgröße des Modells
$\hat{\mathbf{x}}$		Rekonstruktion der Eingangsgröße des Modells
\bar{x}		Mittelwert von \mathbf{x}
$\mathbf{x}_{i,k}$		k -tes Element des Aufgabendatensatzes D_i
\mathbf{x}_k		Element der Verteilung \mathbf{X}
x_k, y_k und z_k		Positionskoordinaten des Datenpunktes \mathbf{x}_k
$x^{(k)}$		Element des Vektors \mathbf{x}
$\hat{x}^{(k)}$		Rekonstruiertes oder vorhergesagtes Element des Vektors \mathbf{x}
$\mathbf{x}_{Messung}$		Messwerte und Zeitreihenmerkmale der letzten zwei CMT-Zyklen
$\mathbf{x}_{Kondition}$		Systemkontext zur Konditionierung des Modells
\mathbf{x}_{TCP}		Aktuelle TCP-Position
$\mathbf{x}_{Umgebung}$		Räumlicher Kontext des Schweißprozesses
$\mathbf{x}_{Vorhersage}$		Vorhersagte TCP-Position für die präskriptive Prozessparameteranpassung
\mathbf{x}_0		Mittelpunkt einer geometrischen Form mit den Koordinaten x_0, y_0 und z_0
x_0, y_0 und z_0		Koordinaten des Mittelpunkts einer geometrischen Form
\mathbf{Y}		Verteilung
\mathbf{y}_k		Vektoriell Element der Verteilung Y
$y^{(k)}$		Element des Vektors \mathbf{y}
\mathbf{z}		Repräsentation des Eingangsvektors \mathbf{x} im latenten Bereich
$\hat{\mathbf{z}}$		Repräsentation des Eingangsvektors \mathbf{x} im latenten Bereich nach dem Speichermodul

Inhaltsverzeichnis

Abkürzungsverzeichnis	xiii
Symbolverzeichnis	xvii
1 Einleitung	1
1.1 Problemstellung	2
1.2 Beitrag der Arbeit	3
1.3 Aufbau der Arbeit	3
2 Grundlagen und Stand der Technik	5
2.1 Wire Arc Additive Manufacturing	5
2.1.1 Einordnung und Begriffsdefinition nach ISO ASTM 52900	6
2.1.2 Prozessbeschreibung	7
2.1.3 Qualitätssicherung	10
2.1.4 Prozesseingriff	15
2.2 Digitaler Zwilling im Fertigungssystem	16
2.2.1 Einordnung und Begriffsdefinition	16
2.2.2 Elemente des Digitalen Zwillings	17
2.2.3 Digitaler Zwilling in der Additiven Fertigung	19
2.3 Datenanalytik und datengetriebene Entscheidungsfindung	20
2.3.1 Datenverständnis und -vorbereitung	21
2.3.2 Modellierung und Maschinelles Lernen	23
2.3.3 Evaluierungsmetriken	31
2.4 Ableitung des Forschungsbedarfs	33
2.4.1 Forschungsbedarf	33
2.4.2 Abgrenzung, Zielsetzung und Vorgehensweise	34
3 Digitale Bauteil- und Prozessrepräsentation	37
3.1 Systemkontext	38
3.1.1 OPC UA Informationsmodell	38
3.1.2 Prozesszustandsbeschreibung	39
3.2 Räumlicher und zeitlicher Kontext	40
3.2.1 Räumliche und zeitliche Indexierung	40
3.2.2 Initialisierung	43
3.2.3 Kontextbereitstellung	43
3.3 Räumliche Annotation von Zeitreihen	47
3.4 Evaluierung	48
3.4.1 Latenzen im Aufbau des Octrees	48
3.4.2 Evaluierung der kontextintegrierenden Qualitätsmetriken	49
3.4.3 Evaluierung der räumlichen Zeitreihenannotation	50
3.5 Zusammenfassung	51

4	Prozessmodellierung und -überwachung	53
4.1	Prozessanalyse und -modellierung	54
4.1.1	Prozessbeschreibung	54
4.1.2	Sensorauswahl	57
4.1.3	Referenzprozess und Sensordaten	58
4.2	Detektion von Prozessanomalien	60
4.2.1	Detektorauswahl	61
4.2.2	Autoencoder zur Anomaliedetektion	63
4.2.3	Multivariate Anomaliebewertung	67
4.3	Klassifizierung von Prozessdefekten	67
4.3.1	Datenvorverarbeitung	68
4.3.2	Modellbildung	69
4.4	Bestimmung des Abstands zwischen Bauteil und Schweißbrenner	70
4.5	Evaluierung	72
4.5.1	Evaluierung der Anomaliedetektion	72
4.5.2	Evaluierung der Defektklassifikation	78
4.5.3	Evaluierung der Abstandsmessung	80
4.6	Zusammenfassung	85
5	Datengestützter Prozesseingriff	87
5.1	Abstandsregelung	89
5.1.1	Systemidentifikation	89
5.1.2	Regelkreis	91
5.2	Präskriptive Prozessparameteranpassung	94
5.2.1	Positionsprädiktion	95
5.2.2	Kontextspezifische Prozessparameteranpassung	96
5.3	Evaluierung	96
5.3.1	Evaluierung der Abstandsregelung	97
5.3.2	Evaluierung der präskriptiven Prozessparameteranpassung	100
5.4	Zusammenfassung	102
6	Erprobung in der industriellen Fertigung	103
6.1	Definition eines industriellen Fertigungsszenarios	103
6.1.1	Systemarchitektur	103
6.1.2	Validierungsbauteile	108
6.2	Erprobung des Systems	109
6.3	Anforderungsbezogene Bewertung	112
6.3.1	Bewertung des Gesamtsystems	112
6.3.2	Bewertung der Module des Digitalen Zwillings	115
6.4	Zusammenfassung	118
7	Schlussfolgerung und Ausblick	119
7.1	Zusammenfassung und Beitrag der Arbeit	119
7.2	Übertragbarkeit	121
7.3	Ausblick	122
A	Zusatzinformationen zum intelligenten Fertigungssystem	125
A.1	Systemaufbau des Cyber-Physischen-Systems	125
A.2	Sensoren der Prozessüberwachung	125
A.3	Ansichten der Benutzeroberfläche	127
A.4	Kommerzielle, prozessorientierte Digitalisierungslösungen	130

B	Zusatzinformationen zu Prozessdefekten	131
B.1	Fotos der WAAM-Defekte	131
B.2	Defekte und Folgedefekte	132
B.3	Datensätze für die Defektklassifikation	132
C	Zusatzinformationen zur Anomaliedetektion	135
C.1	Datensätze für die Anomaliedetektion	135
C.2	Catch22 - Merkmale	136
C.3	Hyperparameter für die Detektorauswahl	137
C.4	Hyperparameteroptimierung des Autoencoders	141
	Literatur	143
	Verzeichnis der Publikationen	163
	Verzeichnis der Studienarbeiten	165

Kapitel 1

Einleitung

1.1	Problemstellung	2
1.2	Beitrag der Arbeit	3
1.3	Aufbau der Arbeit	3

Im Zuge der vierten industriellen Revolution werden Fertigungsprozesse zunehmend digitalisiert und automatisiert. Dabei ist es das Ziel, den Schritt von der angebotsgetriebenen Massenfertigung hin zu einer nachfrageorientierten Massenpersonalisierung zu gehen [1]. Diese Entwicklung geht mit einer geringeren Losgröße bei zunehmender Bauteilkomplexität einher und stellt konventionelle Fertigungsverfahren vor Herausforderungen. Die additive Fertigung (engl. Additive Manufacturing (AM)) bietet hier neue Perspektiven und ermöglicht die bedarfsgerechte Fertigung individualisierter Bauteile. Im Gegensatz zur subtraktiven Fertigung wird bei der additiven Fertigung Material nicht ab- sondern aufgetragen, um das finale Bauteil zu erzeugen (s. Abbildung 1.1).

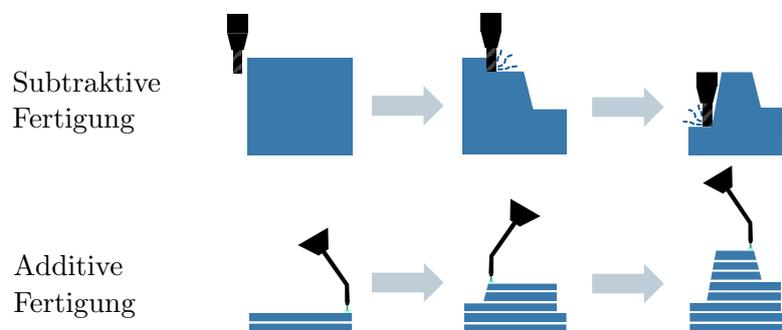


Abbildung 1.1: Vergleich von subtraktiver Fertigung und additiver Fertigung

Dadurch können komplexere Geometrien realisiert, die Flexibilität in der Fertigung gesteigert und die Ressourceneffizienz erhöht werden [2]. Auch bei großvolumigen Metallbauteilen ergeben sich dadurch massive Material-, Kosten- und Zeiteinsparungen [3]. Beispielsweise sind in der Luft- und Raumfahrttechnik konventionell mittels subtraktiver Fertigung Netto-Brutto-Massenverhältnisse (engl. fly-to-buy-ratio) von 10 % üblich. Das bedeutet, dass das finale Bauteil lediglich ein Zehntel des Rohmaterials ausmacht und 90 % des Ausgangsmaterials nicht wertschöpfend eingesetzt werden [4, 5]. Die additive Fertigung mittels Lichtbogenauftragschweißen (engl. Wire Arc Additive Manufacturing (WAAM)) ermöglicht hingegen die flexible Fertigung von endkonturnahen, großvolumigen Bauteilen. Dies resultiert in einer Reduktion der Fertigungszeiten um bis zu 60 % und der Fertigungskosten um bis zu 54 % [3, 4]. Im Vergleich zu konventionellen generativen Fertigungsverfahren wie beispielsweise Druckguss ist WAAM flexibler und ermöglicht komplexere Bauteilstrukturen. Besonders bei geringeren Stückzahlen

können Kosten eingespart werden. [5] WAAM ist eine additive Fertigungstechnologie, die sich durch hohe Auftragsraten, geringe Rohmaterialkosten und geringe Maschinenstundensätze auszeichnet [6].

Bei der Produktentstehung eines WAAM-Bauteils sind, wie in Abbildung 1.2 visualisiert, verschiedene Schritte zu durchlaufen. Zunächst erfolgt in der Designphase die Bauteil- und Prozessmodellierung mithilfe einer computergestützten Konstruktions- und Fertigungsplanungsumgebung (engl. Computer Aided Design (CAD) und Computer Aided Manufacturing (CAM)). Der dabei generierte Prozessplan wird an die Fertigungsmaschine übergeben und die Fertigung gestartet. Im Anschluss erfolgt die Qualitätssicherung, die die Einhaltung aller relevanten Spezifikationen sicherstellt.

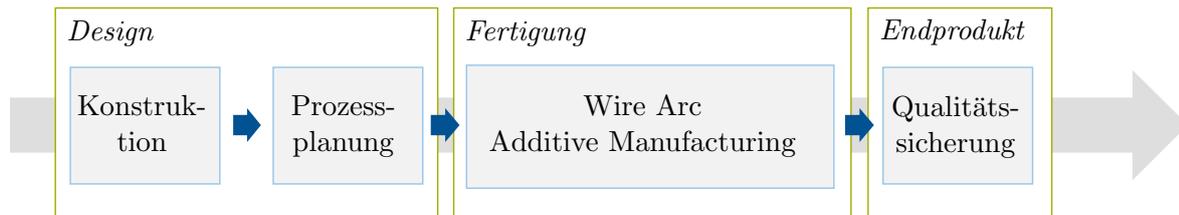


Abbildung 1.2: Phasen der Produktentstehung eines WAAM-Bauteils

1.1 Problemstellung

Bei der Produktentstehung ist es stets das Ziel, einen erfolgreichen Druck des Bauteils beim ersten Versuch (engl. *first time right printing*) und eine hohe Erstaussbeute (engl. First Pass Yield (FPY)) in der Produktion zu erreichen. Dieses Ziel ist essentiell für die Industrialisierung von WAAM und kann einerseits durch umfangreiches Prozesswissen und andererseits durch einen hohen Grad an Automatisierung und Digitalisierung in der Produktentstehung realisiert werden. Prozesswissen ist jedoch personengebunden und kann deshalb lediglich mithilfe von Digitalisierung umfangreich skaliert werden.

Eine digitale Werkzeugkette für WAAM ist zum heutigen Stand lediglich in Teilen verfügbar. Im Bereich des Designs sind diverse CAD- und CAM-Softwarelösungen erhältlich, die vereinzelt bereits Erweiterungen für WAAM beinhalten [7]. Ihre Nutzung erfordert ein hohes Maß an Prozesswissen, um geeignete Werkzeugpfade zu wählen. Für jedes Bauteil wird eine bauteilspezifische Prozessparameteroptimierung mittels umfangreicher Parameterstudien durchgeführt [6]. In der Fertigung werden zur Überwachung und Regelung Methoden aus der Schweißtechnik genutzt, welche den dreidimensionalen Aspekt von WAAM jedoch nicht berücksichtigen. Zur Qualitätssicherung werden kostenintensive, nichtzerstörende Prüfmethode verwendet. Bei Tests zur Herstellung des Flüssigkeitsverteilers der Triebwerksstufe der Ariane-6-Trägerrakete Vulcan-2 mittels WAAM war die Qualitätssicherung aufgrund der aufwendigen Prüfmethode beispielsweise für eine Verachtfachung der Fertigungskosten verantwortlich [8].

Bei jedem Schritt entlang der digitalen Werkzeugkette fallen unzählige Daten an, welche jedoch nur begrenzt in vor- und nachgelagerte Schritte einbezogen werden. Als verknüpfendes Element zwischen der Designphase, der Fertigung und der Qualitätssicherung kommt den Prozessdaten dabei eine besondere Bedeutung zu. Die aus den Prozessdaten abgeleiteten Informationen können Rückverfolgbarkeit ermöglichen, zur Verbesserung des Prozesses genutzt werden, die nachgelagerte Qualitätssicherung ergänzen und zur Optimierung des Designprozesses eingesetzt werden. Um das Potenzial der Fertigungsdaten zu nutzen, fehlt es jedoch an WAAM-gerechten Methoden zur Aufbereitung, Auswertung und Nutzung dieser Daten.

1.2 Beitrag der Arbeit

Im Rahmen der vorliegenden Arbeit werden Verfahren und Methoden untersucht, um die WAAM-Fertigungsdaten aufzubereiten, auszuwerten und zu nutzen. Dazu wird ein prozessorientierter Digitaler Zwilling für WAAM erstellt, der kontextwahrnehmend, autonom und anpassungsfähig ist und dessen Kernelemente die Prozessüberwachung, die digitale Bauteil- und Prozessrepräsentation und der Prozesseingriff sind. Während die Prozessüberwachung darauf abzielt, den Prozess und seine Qualität zu quantifizieren, ermöglicht der Prozesseingriff eine Verbesserung der Qualität, indem der Prozess fehlertoleranter gestaltet wird. Die Bauteil- und Prozessrepräsentation stellt Informationen für die Prozessüberwachung und den Prozesseingriff bereit und schließt die zuvor beschriebene Lücke in der digitalen Werkzeugkette, indem sie als ergänzendes Element der Qualitätssicherung dient sowie eine Rückführung der Prozessinformationen in die Designphase ermöglicht. Die Elemente des in dieser Arbeit vorgestellten, prozessorientierten Digitalen Zwillings für WAAM stellen damit einen wichtigen Schritt in Richtung des erfolgreichen Drucks eines Bauteils beim ersten Versuch sowie zur Erhöhung der FPY dar.

1.3 Aufbau der Arbeit

Die vorliegende Arbeit besteht, wie in Abbildung 1.3 dargestellt, aus sieben Kapiteln.

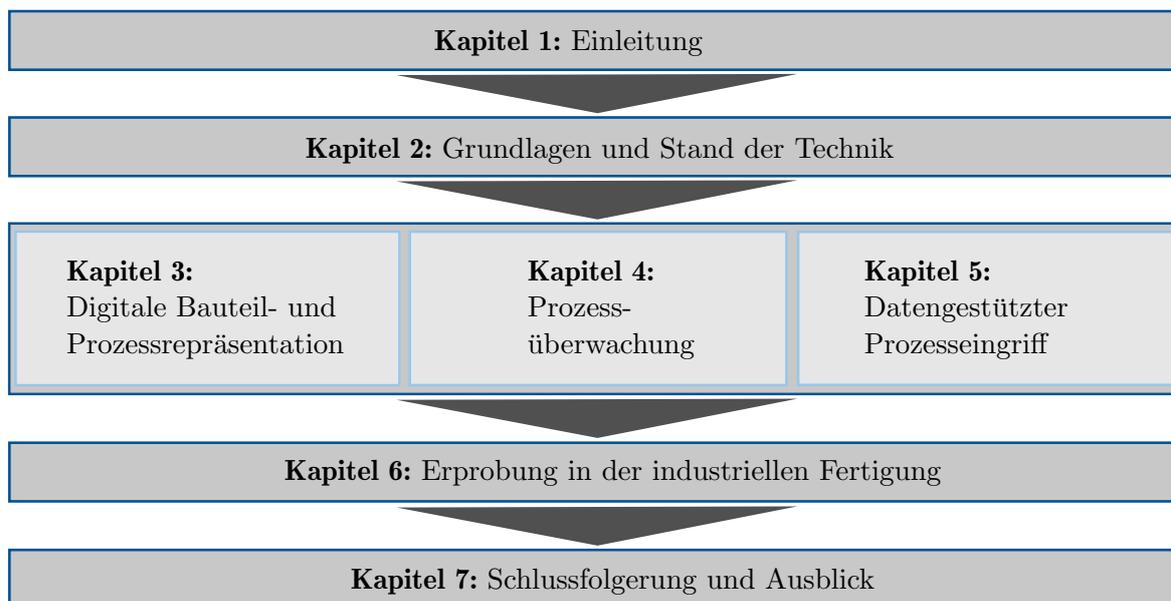


Abbildung 1.3: Aufbau der Arbeit

In Kapitel 2 werden Grundlagen und der Stand der Technik in den für diese Arbeit relevanten Bereichen vorgestellt. Zunächst wird auf den WAAM-Prozess und dort umgesetzte Methoden zur Qualitätssicherung und für den Prozesseingriff eingegangen. Es folgt eine Vorstellung des Konzepts des Digitalen Zwillings, seiner Elemente sowie seiner Umsetzungen in der additiven Fertigung. Zuletzt werden Methoden in der Datenanalytik und datengetriebenen Entscheidungsfindung mit einem Fokus auf Zeitreihendaten dargelegt. Aus dem beschriebenen Stand der Technik wird der Forschungsbedarf und die Forschungsfrage dieser Arbeit abgeleitet. Der Hauptteil der Arbeit orientiert sich am Aufbau des Digitalen Zwillings. Kapitel 3 befasst

sich mit der digitalen Bauteil- und Prozessrepräsentation. Es werden Methoden vorgestellt, um den Systemkontext, den zeitlichen und den räumlichen Kontext im Prozess zu repräsentieren und diesen Kontext für die Prozessüberwachung und den Prozesseingriff bereitzustellen. Weiterhin wird eine Methodik dargelegt, mittels derer zeitbasierte AM-Prozessdaten für Datenanalysen räumlich annotiert werden können. Die Prozessüberwachung wird in Kapitel 4 vorgestellt. Der WAAM-Prozess wird zunächst analysiert und digital modelliert. Anschließend erfolgt die Auswahl eines geeigneten Anomaliedetektors, eine Optimierung der Autoencoderarchitektur hinsichtlich der Sensitivität und Anpassbarkeit auf neue Prozessparameter sowie die Vorstellung einer Methodik zur Klassifikation von Prozessdefekten. Abschließend werden Methodiken zur Messung des Abstands zwischen Schweißbrenner und Bauteil auf Basis unterschiedlicher Sensordaten betrachtet. In Kapitel 5 wird der datengestützte Prozesseingriff und damit der Informationsrückfluss des Digitalen Zwillings zum Prozess vorgestellt. Basierend auf einer Systemidentifikation wird eine Abstandsregelung konzipiert, welche zusätzlich um ein Modul zur Schweißnahtbreitenanpassung ergänzt wird. Darüber hinaus wird eine Methodik zur präskriptiven Prozessparameteranpassung erläutert, welche die Kompensation von Defekten und Vermeidung von Folgedefekten ermöglicht.

Während in jedem der Kapitel 3, 4 und 5 bereits eine Evaluierung der Methoden stattfindet, wird in Kapitel 6 das Gesamtsystem des Digitalen Zwillings validiert. Dazu wird es in einem industriellen Fertigungsszenario anhand des Aufbaus zweier Anwendungsbauteile erprobt und anforderungsbezogen bewertet.

Abschließend werden in Kapitel 7 die Arbeit zusammengefasst, eine Betrachtung der Übertragbarkeit der Methoden vorgenommen und zukünftige Forschungsthemen vorgeschlagen. Teile der Arbeit wurden bereits in der Fachöffentlichkeit vorgestellt (siehe Verzeichnis der Publikationen). Zudem wurden vom Autor dieser Schrift Studienarbeiten zu einzelnen Aspekten dieser Arbeit ausgeschrieben und betreut (siehe Verzeichnis der Studienarbeiten).

Kapitel 2

Grundlagen und Stand der Technik

2.1	Wire Arc Additive Manufacturing	5
2.1.1	Einordnung und Begriffsdefinition nach ISO ASTM 52900	6
2.1.2	Prozessbeschreibung	7
2.1.3	Qualitätssicherung	10
2.1.4	Prozesseingriff	15
2.2	Digitaler Zwilling im Fertigungssystem	16
2.2.1	Einordnung und Begriffsdefinition	16
2.2.2	Elemente des Digitalen Zwillings	17
2.2.3	Digitaler Zwilling in der Additiven Fertigung	19
2.3	Datenanalytik und datengetriebene Entscheidungsfindung	20
2.3.1	Datenverständnis und -vorbereitung	21
2.3.2	Modellierung und Maschinelles Lernen	23
2.3.3	Evaluierungsmetriken	31
2.4	Ableitung des Forschungsbedarfs	33
2.4.1	Forschungsbedarf	33
2.4.2	Abgrenzung, Zielsetzung und Vorgehensweise	34

In diesem Kapitel werden relevante Grundlagen sowie der Stand der Technik für die im Rahmen dieser Arbeit behandelte Thematik vorgestellt. Zunächst wird eine Einführung in den WAAM-Prozess gegeben sowie die zugehörige Qualitätssicherung und Methoden für den Prozesseingriff bei WAAM vorgestellt. Es folgt eine Einordnung des Konzepts des Digitalen Zwillings sowie eine Erläuterung von Anwendungsfeldern, Eigenschaften und Elementen des Digitalen Zwillings. Zudem wird eine Übersicht über Umsetzungen im Bereich der additiven Fertigung gegeben. Anschließend werden Grundlagen der Datenanalytik vorgestellt und auf Maschinelles Lernen und Anomaliedetektion in Zeitreihen eingegangen. Zuletzt folgt eine Zusammenfassung des Stands der Technik und eine Ableitung des Forschungsbedarfs.

2.1 Wire Arc Additive Manufacturing

Wire Arc Additive Manufacturing (WAAM) ist ein Prozess zur additiven Fertigung metallischer Bauteile mittels Lichtbogenauftragschweißens. Im Folgenden wird der Begriff eingeordnet, der der Fertigung zugrunde liegende Prozess beschrieben sowie auf Defekte und Methoden der Qualitätssicherung und des Prozesseingriffs eingegangen.

2.1.1 Einordnung und Begriffsdefinition nach ISO ASTM 52900

Die additive Fertigung ist nach ISO/ASTM 52900 [9] ein Verfahren zum generativen Aufbau dreidimensionaler Bauteile auf Basis digitaler 3D-Modelle. Die Norm unterteilt die additive Fertigung in sieben Prozesskategorien.

- Freistrah-Bindemittelauftrag (engl. Binder Jetting (BJT))
- Materialauftrag mit gerichteter Energieeinbringung (engl. Directed Energy Deposition (DED))
- Materialextrusion (engl. Material Extrusion (MEX))
- Freistrah-Materialauftrag (engl. Material Jetting (MJT))
- Pulverbettbasiertes Schmelzen (engl. Powder Bed Fusion (PBF))
- Schichtlaminiierung (engl. Sheet Lamination (SHL))
- Badbasierte Photopolymerisation (engl. Vat Photopolymerization (VPP))

PBF weist mit einem Marktanteil von 85 % die höchste Relevanz für die additive Fertigung metallischer Bauteile auf [10]. Verfahren dieser Kategorie, wie beispielsweise Laser-Powder Bed Fusion (L-PBF), nutzen ein Pulverbett, in welchem mittels eines thermischen Energieeintrags eine stoffschlüssige Verbindung mit der lokalen Umgebung erreicht wird. Durch den wiederholten, schichtweisen Pulverauftrag und die gerichtete Verschmelzung je Schicht entsteht das Bauteil [10].

DED-Verfahren zeigten im Jahr 2020 mit 8 % den zweitgrößten Marktanteil, wobei dieser bis 2024 in einem wachsenden AM-Markt auf 11 % ansteigen soll [10]. Im Gegensatz zu den PBF-Verfahren basiert DED nicht notwendigerweise auf einem schichtweisen Aufbau. Stattdessen findet der Material- und Energieauftrag gerichtet und gegebenenfalls mittels Multiachsoperationen statt. Aus diesem Grund wird die Technologie als voll 3D-fähig bezeichnet [11]. Um ein Bauteil endkonturnah aufzubauen, werden mehrere Werkzeugwege mit Materialauftrag über- und nebeneinander gelegt. DED-Verfahren unterscheiden sich im verwendeten Ausgangsmaterial (Draht oder Pulver) sowie in der genutzten Energiequelle (Laser, Elektronenstrahl, Lichtbogen). Besonders verbreitete DED-Verfahren sind Laser Metal Deposition (LMD) und WAAM. LMD nutzt Metallpulver als Ausgangsmaterial, welches im Fokus einer Düse durch einen Laserstrahl aufgeschmolzen wird. WAAM zeichnet sich durch den Einsatz von Draht als Materialquelle und von einem Lichtbogen als Energiequelle aus. Die Technologie wurde erstmals 1920 in einem Patent des Unternehmens *Westinghouse Electric and Manufacturing Co* zur Verzierung von Bauteilen vorgestellt [12].

Wie im Netzwerkdiagramm in Abbildung 2.1 dargestellt, weist WAAM im Vergleich zu L-PBF und LMD eine hohe Auftragsrate und geringe Fertigungskosten auf [13, 14]. Damit ist WAAM besonders gut für den Aufbau großvolumiger Bauteile geeignet. WAAM-Bauteile zeigen sehr gute Materialeigenschaften, welche vergleichbar mit denen von Guss- und Schmiedebauteilen sind [16]. Für Stahl mit mittlerem Kohlenstoffgehalt (Güte XC-45) wurden für WAAM-Proben beispielsweise eine Zugfestigkeit von bis zu 710 MPa (Guss: 683 MPa) und eine Zugdehnung von bis zu 11.0 % (Guss: 10.2 %) gemessen [17]. Der WAAM-Prozess weist zudem ein hohes Maß an Materialnutzung auf und kann sowohl kartesische als auch roboterbasierte Systeme zur Schweißbrennerpositionierung nutzen [5, 6, 18]. Da statt Metallpulver Draht verwendet wird, ist kein geschlossener Bauraum erforderlich.

Durch die hohen Auftragsraten ist die erreichbare Bauteilkomplexität und Prozessgenauigkeit

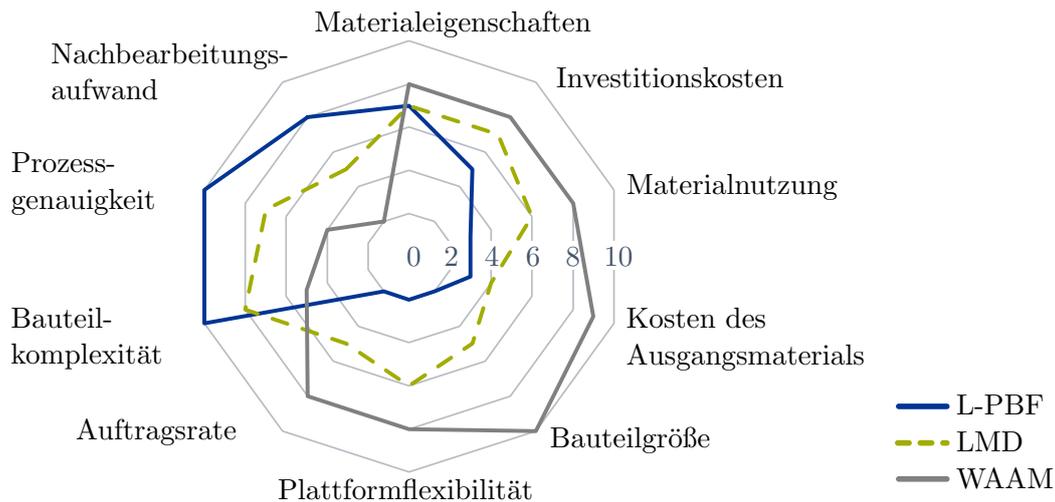


Abbildung 2.1: Netzdiagramm für den Vergleich der Merkmale von WAAM, LMD und L-PBF in Anlehnung an Fischer et al. [15]. Eine Ausprägung von 10 stellt ein optimales Verhalten der Technologie in dem jeweiligen Bereich dar.

geringer als bei anderen AM-Technologien [14]. Dadurch genügt die erzielbare Oberflächenqualität nicht den Präzisionsanforderungen von Funktionsflächen, sodass der Nachbearbeitungsaufwand vergleichsweise groß ist [19, 20].

2.1.2 Prozessbeschreibung

In erster Hinsicht handelt es sich bei WAAM um die additive Fertigung auf Basis eines Schweißprozesses. Üblicherweise werden für WAAM drei Schutzgasschweißverfahren eingesetzt [21, 22]:

- **Metall-Schutzgas (MSG)** (engl. Gas Metal Arc Welding (GMAW)): Dieser Gruppe werden das Metall-Inertgas (MIG)-Schweißen mit einem nicht-reaktiven Schutzgas und das Metall-Aktivgas (MAG)-Schweißen mit einem reaktionsfreudigen Schutzgas zugeordnet. Die Elektrode dient einerseits der Generierung des Lichtbogens und andererseits als Materialquelle für den Prozess, sodass sie während des Prozesses abschmilzt. Es sind Auftragsraten von bis zu 4 kg h^{-1} zu erreichen, jedoch weist der Prozess Spritzerbildung und eine geringe Lichtbogenstabilität auf. Eine Weiterentwicklung dieser Verfahren ist der sogenannte Cold Metal Transfer (CMT) Prozess, welcher durch einen geringeren Energieeintrag weniger Eigenspannungen im Bauteil induziert und Auftragsraten von bis zu 3 kg h^{-1} mit wenigen Spritzern ermöglicht [23].
- **Wolfram Inertgas (WIG)-Schweißen** (engl. Tungsten Inert Gas (TIG) oder Gas Tungsten Arc Welding (GTAW)): Durch die nicht abschmelzende Wolframelektrode ist beim WIG-Schweißen eine Trennung von Materialzufuhr und Energieeintrag möglich. Die Trennung führt zu einer Richtungsabhängigkeit des Prozesses und resultiert damit in einer komplexen Bahnplanung für Multiachsbauteile. Es werden Auftragsraten von bis zu 2 kg h^{-1} erreicht [23].
- **Plasmaschweißen** (engl. Plasma Arc Welding (PAW) oder Plasma Transferred Arc Welding (PTAW)): Der Lichtbogen erzeugt ein Plasma mit erhöhten Energiedichten im Vergleich zu WIG oder MSG, sodass hohe Abschmelzleistungen von bis zu 4 kg h^{-1} mög-

lich sind [23]. Durch die nicht abschmelzende Elektrode ist eine zusätzliche Materialzufuhr erforderlich, welche zu einer Richtungsabhängigkeit des Prozesses führt.

Für weiterführende schweißtechnische Themen wird auf die Schweißfachliteratur verwiesen [24, 25]. CMT ist nach Treutler et al. [21] der am häufigsten genutzte Prozess für MSG-basiertes WAAM und wird aufgrund des vergleichsweise geringen Energieeintrags bevorzugt für den Aufbau großvolumiger Bauteile verwendet [23]. Der geringe Energieeintrag wird durch einen oszillierenden Draht ermöglicht, dessen Bewegung die Metalltropfenablösung unterstützt. Der CMT-Prozess gehört damit nach ISO/TR 18491 [26] zu den wellenförmig kontrollierten Schweißverfahren, welche die Strom- und Spannungsverläufe modifizieren, um Eigenschaften wie die Tropfenform, den Einbrand oder die Form der Schweißraupe zu steuern. Der Prozess lässt sich in folgende drei Phasen einteilen [27, 28]. In der Spitzenstromphase führt eine konstante Lichtbogenspannung zum Zünden des Lichtbogens. Es folgt die Hintergrundstromphase, in welcher der Draht in Richtung der Schmelze bewegt wird und sich ein Tropfen am Drahtende wegen der Erhitzung durch den Lichtbogen formt. In der Kurzschlussphase wird der Tropfen abgelegt und der Lichtbogen erlischt. Zur Unterstützung wird eine Rückziehbewegung des Drahtes eingeleitet. Abschließend wird die Schweißspannung angehoben, um den nächsten CMT-Zyklus einzuleiten. Angepasste Versionen des CMT-Prozesses sind Cold Metal Transfer Pulse Mode (CMT-P), Cold Metal Transfer Advanced Mode (CMT-ADV) und Cold Metal Transfer Pulse Advanced Mode (CMT-PADV), bei denen dem CMT-Prozess ein niederfrequenter Strom- und Spannungspuls beigefügt beziehungsweise die Elektrodenpolarität umgedreht wird [29].

Als Ausgangsmaterialien können für WAAM alle schweißbaren Materialien genutzt werden. Besonders verbreitet sind Stahl, Aluminium-, Magnesium-, oder Nickellegierungen sowie Titan [6, 21, 23, 30]. Für jedes Material unterscheiden sich die Prozesscharakteristiken. So benötigt die Verarbeitung von Titan eine vollständige Argonatmosphäre während Stahl mit Kohlenstoffdioxid oder Helium als Zusatz im Schutzgas verarbeitet werden kann [31]. Die Wahl der Prozessparameter ist komplex und materialspezifisch. Gonzalez et al. [32] identifizierten mit dem Lichtbogenstrom, der Schweißgeschwindigkeit, der Lichtbogenlängenkorrektur sowie der Dynamik des Drahtvorschubs vier Hauptprozessparameter für den CMT-Prozess. Liberini et al. [33] betonten die Relevanz von Schweißgeschwindigkeit und Lichtbogenspannung. Auch die Orientierung des Schweißbrenners hat einen Einfluss auf die Schweißbadgeometrie. Pattanayak et al. [31] zeigten die Einflüsse von Elektrodenpolarität, Metalltransfermodi, Inertgas und Elektrodentyp auf den Prozess. Die Schweißbadgeometrie wird primär durch den Energieeintrag sowie durch das Auftragsvolumen entlang des Pfades beeinflusst [34, 35]. Die Streckenenergie E_S wird nach Jaeschke et al. [36] für wellenförmig kontrollierte Schweißverfahren durch Gleichung 2.1 berechnet, wobei v_{TCP} die Schweißgeschwindigkeit, ν die Effizienz beim Energieübertrag und $u(t)$ und $i(t)$ die Schweißspannung beziehungsweise den Schweißstrom über die Zeit darstellen.

$$E_S = \nu \cdot \frac{1}{t^{(1)} - t^{(2)}} \int_{t^{(1)}}^{t^{(2)}} u(t) \cdot i(t) dt \quad (2.1)$$

Standardmäßig wird $\nu = 0.8$ für MSG-Schweißverfahren gesetzt [36]. Wie Hälsig [37] anführte, verringert sich ν bei einer Reduktion der Schweißgeschwindigkeit, da sich die Beschaffenheit und damit die Wärmeleitfähigkeit des Schweißuntergrunds mit der Schweißgeschwindigkeit ändert. Der Volumeneintrag entlang des Werkzeugpfades A_V ist in Gleichung 2.2 festgehalten und basiert auf der Schweißgeschwindigkeit v_{TCP} , der Drahtvorschubgeschwindigkeit v_{WF} sowie dem Drahtdurchmesser d_w . Er entspricht dem zu erwartenden mittleren Schweißnahtquerschnitt.

$$A_V = \frac{v_{WF} \cdot \pi \cdot \left(\frac{d_w}{2}\right)^2}{v_{TCP}} \quad (2.2)$$

Um optimale Schweißergebnisse zu erzielen findet bei modernen Schweißgeräten eine Kopplung der Drahtvorschubgeschwindigkeit mit Schweißspannung und -strom über materialspezifische Kennlinien statt.

Für die Industrialisierung des WAAM-Prozesses stellen besonders das Temperaturmanagement und die Prozessstabilität Herausforderungen dar [20, 38]. Der dauerhafte Energieeintrag führt zu einer erschwerten Kontrolle der Schweißbadgeometrie, zu komplexen metallurgischen Effekten und zu einer erhöhten Wahrscheinlichkeit Defekte zu erzeugen [39].

Die Komplexität und die Dynamik des Materialauftrags erschweren zudem die Modellierung des Systems. Schweißbadmodelle beschreiben den Bereich, der als Schmelze vorliegt und damit durch eine viskose Phase gekennzeichnet ist. In vielen numerischen Schweißsimulationen wird auf das Modell eines Dopelellipsoids nach Goldak et al. [40] zurückgegriffen. Einflussgrößen zur Beschreibung des Schweißbads sind die Substrattemperatur, der Energieeintrag und das Material [41, 42, 43]. Modellierungen des Schweißbads mithilfe des Dopelellipsoids für den WAAM-Prozess wurden beispielsweise von Graf et al. und Prajadhiama et al. genutzt [44, 45, 46]. Schweißnahtmodelle bilden die geometrischen Abmessungen der Schweißnaht wieder. Analytisch werden dazu bei einem einspurigen, einlagigen Schweißvorgang (Abbildung 2.2 a)) die drei in Tabelle 2.1 genannten Modelle verwendet [14, 47]. Experimente zur Untersuchung

Tabelle 2.1: Modelle für die Schweißnahtgeometrie bei einem einspurigen, einlagigen Schweißvorgang unter Nutzung der Hilfsvariablen a und b nach Suryakumar et al. und Ding et al. [14, 47]

Modell	Funktion	Schweißnaht- höhe h_S	Schweißnaht- breite b_S	Schweißnahtquerschnitt A_S
Parabel	$a + b \cdot x^2$	a	$2 \cdot \sqrt{-\frac{a}{b}}$	$\frac{4}{3} \cdot a \cdot \sqrt{-\frac{a}{b}}$
Kosinus- modell	$a \cdot \cos(b \cdot x)$	a	$\frac{2}{b}$	$2 \cdot \frac{a}{b}$
Bogen- modell	$\sqrt{a^2 - x^2} + b$	$a - b$	$2 \cdot \sqrt{a^2 - b^2}$	$\arccos\left(-\frac{b}{a}\right) - b \cdot \sqrt{a^2 - b^2}$

der Schweißnahtgeometrie wurden unter anderem bei WIG [48] und CMT [47] für einlagige und -spurige Schweißnähte (Abbildung 2.2 a)), bei MAG [49] für einlagige, mehrspurige Schweißvorgänge (Abbildung 2.2 c)) sowie bei MAG [14, 50] für mehrlagige und -spurige Schweißvorgänge (Abbildung 2.2 d)) durchgeführt. Wang et al. schlugen ein numerisches

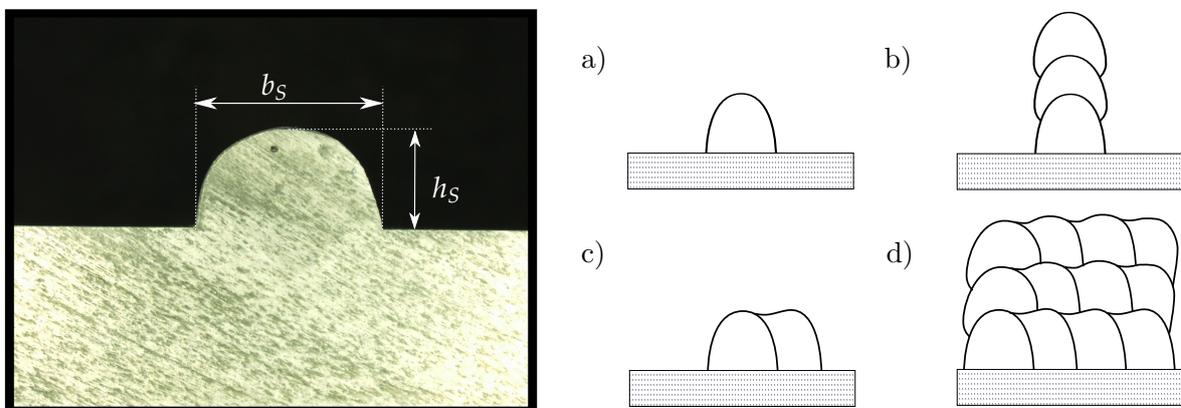


Abbildung 2.2: Schweißnahtgeometrien beim WAAM-Prozess: a) einlagig, einspurig; b) mehrlagig, einspurig; c) einlagig, mehrspurig; d) mehrlagig, mehrspurig

Modell für den einspurigen, einlagigen MSG-Prozess vor, das unter anderem auf der Enthalpie, der Viskosität und dem Auftragsvolumen basiert. Das Modell konnte in Experimenten validiert werden [51]. Zhang et al. nutzten ein Modell der Unschärfelogik zur Abschätzung der Schweißbadbreite beim einspurigen, einlagigen WIG-Prozess [52]. Geng et al. entwickelte ein prädiktives Modell unter Verwendung der *Response Surface* Methode. Das erstellte Modell konnte mittels Strom, Drahtvorschub und Schweißgeschwindigkeit die Geometrie einer einzelner WIG-Schweißbraupe mit einer statistischen Sicherheit von 95 % vorhersagen [48]. Xiong et al. sagten unter Nutzung eines Regressionsmodells zweiter Ordnung sowie eines neuronalen Netzes die Schweißnahtgeometrie auf Basis von Drahtvorschub, Schweißgeschwindigkeit, Schweißspannung und Abstand von Schweißbrenner zum Bauteil für einen MSG-Prozess voraus [53]. Li et al. modellierten die Schweißnahtgeometrie für mehrspurige MAG-Schweißnähte und verwendeten ein neuronales Netz um den optimalen Spurabstand herauszufinden [54]. Xiao et al. sagten die Schweißnahtbreite, -höhe und -penetrationstiefe eines einspurigen, einlagigen MIG-Prozesses mithilfe eines neuronalen Netzes unter Nutzung von Schweißspannung, -strom und -geschwindigkeit als Eingangsgrößen voraus [55].

2.1.3 Qualitätssicherung

Die Qualitätssicherung unterteilt sich in die prozessbezogene Qualitätsüberwachung (Prozessüberwachung) und die Qualitätsüberwachung des fertigen Bauteils [39, 56]. Nachfolgend wird zunächst auf Defekte eingegangen, welche zu einer Beeinträchtigung der Bauteilqualität führen. Es folgt eine Beschreibung der Methoden zur Qualitätsüberwachung des fertigen Bauteils sowie der Konzepte zur WAAM-Prozessüberwachung.

Defekte

Beim WAAM-Prozess kann es zu Defekten kommen. Defekte werden wie folgt definiert (Definition 1):

Definition 1 Defekt: *Ein Defekt ist eine Unregelmäßigkeit im Bauteil, welche die Qualität des Bauteils negativ beeinflusst.*

Defekte können zu Nachbearbeitungsbedarf oder Fertigungsausschuss führen. Sie sind deshalb zu vermeiden. Defekte im WAAM-Prozess haben vielfältige Ursachen wie beispielsweise eine ungeeignete Prozessplanung oder instabile Umgebungsbedingungen [57]. Im Allgemeinen ähneln Defekte im WAAM-Prozess denen beim Schweißen. Viele der Unregelmäßigkeiten finden sich aus diesem Grund auch bei Lichtbogenschweißverbindungen beispielsweise aus Aluminium und seinen Legierungen, welche in der Norm DIN EN ISO 10042 [58] beschrieben sind. Zusätzlich führt der räumliche Aufbau bei WAAM auf Grund des höheren Energieeintrags zu Herausforderungen im Prozess und zu einer erhöhten Wahrscheinlichkeit, Defekte zu erzeugen [39, 57]. Defekte können in Kombination auftreten und sich zudem über mehrere Lagen hinweg ausbreiten [39, 59]. Chen et al. unterschieden zwischen Qualitätsdefekten und Profildefekten [39]. Qualitätsdefekte umfassen innere Unregelmäßigkeiten:

- **Porosität:** Poren sind Gaseinschlüsse im erstarrten Schweißbad. Sie können abhängig von ihrem Entstehungsmechanismus in prozess- oder materialinduzierte Poren unterteilt werden. Bei materialbedingten Poren liegt der Ursprung in Verunreinigungen im Schutzgas, auf dem Substrat oder auf dem Draht. Prozessinduzierte Poren entstehen hingegen

auf Grund von ungeeigneten Prozessparametern und starken Temperaturänderungen. [23, 30, 39]

- **Risse:** In Folge von Eigenspannungen im Bauteil bricht die Bindung im Material auf, sodass ein Riss entsteht. Bei WAAM sind vor allem Heißrisse wegen unterschiedlicher Abkühlraten und Kaltrisse in Folge von Zugspannungen im Bauteil zu beobachten. [23, 39]
- **Schlacke und Schlackeeinschlüsse:** Nichtmetallische Feststoffeinschlüsse im Schweißgut werden als Schlackeeinschlüsse bezeichnet. Ursachen sind beispielsweise Verschmutzungen des Substrats oder des Drahts. [25]
- **Oxidation:** Oxidation findet statt, wenn die Schutzgasatmosphäre nicht ausreicht, um eine chemische Reaktion des erhitzten Metalls mit Sauerstoff zu unterbinden [60]. Dies kann beispielsweise der Fall sein, wenn das Schutzgas verunreinigt ist, die Umgebungsbedingungen zu einer instabilen Schutzgasatmosphäre führen oder wenn der Abstand zwischen Schweißbrenner und Bauteil zu groß wird. [23]
- **Bindefehler:** Eine unvollständige Anbindung des Schweißbads an dessen Umgebung führt zu kleinen Hohlräumen im Bauteil zwischen den Schweißnähten beziehungsweise zwischen der Schweißnaht und dem Substrat. In Kombination mit Eigenspannungen kann es infolgedessen zu Delamination kommen. [6, 25, 39]

Profildefekte betreffen Geometrieabweichungen im Aufbau:

- **Eigenspannungen und Verzug:** Durch die wiederholte Einbringung von Wärme in das Material werden Eigenspannungen im Bauteil erzeugt, welche zu Verzug und Rissen führen können [30, 23]. Durch eine geeignete Prozessparameterauswahl, eine angepasste Pfadplanung sowie zusätzliche Prozessschritte wie Zwischenlagenwalzen oder Wärmehinbehandlungen können Eigenspannungen vermindert werden. [46, 30] In Kombination mit Anbindungsfehlern kann es zu Delamination kommen.
- **Humping-Effekt:** Auf Grund von prozessinduzierten Strömungen im flüssigen Schmelzbad kann es zu wellenförmigen Materialansammlungen in Form von Buckeln entlang der Schweißnaht kommen. Der Humping-Effekt ist ein Zeichen für ein ungeeignetes Temperaturmanagement im Bauteil und tritt abhängig vom Drahtvorschub besonders bei hohen Schweißgeschwindigkeiten auf [61].
- **Durchschweißung und Seitenkollaps:** Durchschweißungen und Seitenkollaps treten bei Hitzeansammlungen wegen zu geringer Wärmeabfuhr beispielsweise infolge eines Bindefehlers auf [6]. Sie sind durch eine plötzliche Änderung der Schweißbadgeometrie zu erkennen.
- **Formabweichungen:** Im Laufe des Aufbaus ändert sich das Temperaturprofil im Bauteil. Da die Temperatur einen hohen Einfluss auf die Schweißnahtgeometrie hat, kann es zu Abweichungen von der definierten Schichthöhe und damit mittelfristig zu Abweichungen von der geplanten Bauteilgeometrie kommen. Die prozessvorgelagerte Wahl geeigneter Prozessparameter ist großen Unsicherheiten unterworfen, sodass es zu falschen Vorhersagen der Schichthöhe in der Pfadplanung kommen kann [21].
- **Unstetigkeiten:** Unstetigkeiten sind Unterbrechungen in der Schweißnaht. Sie gehen unter anderem auf einen instabilen Lichtbogen, auf einen stark ausgeprägten Humping-Effekt und auf Geometrieänderungen in der unmittelbaren Nähe des Schweißprozesses zurück. [62, 63]

Stark ausgeprägte Geometrieabweichungen führen zu einem instabilen Schweißprozess oder zu Kollisionen zwischen dem Schweißbrenner und dem Bauteil.

Defekte sind für gewöhnlich unvorhersehbar und müssen experimentell identifiziert werden [64]. Gleiche Prozessparameter können beim gleichen Bauteil aufgrund unterschiedlicher Umgebungsbedingungen zu anderen Ergebnissen führen [65]. Viele der genannten Defekte wie starker Verzug, Risse, oder Hitzeansammlungen resultieren aus einem ungeeigneten Wärmemanagement. Die Temperatur verändert sich während des Prozesses dynamisch. Yang et al. konnten im Laufe des additiven Prozesses einen Temperaturanstieg im Bauteil infolge des Wärmeeintrags durch den Lichtbogen feststellen [66]. Wu et al. und Jafari et al. beschreiben die Entwicklung der Abkühlrate auf Grund von Konduktion, Konvektion und Wärmestrahlung im Laufe des Aufbauprozesses. Diese hat einen direkten Einfluss auf die Temperatur und damit auf das Schmelzbad und die Schweißnahtgeometrie [38, 57]. In der Prozessplanung werden deshalb Temperatursimulationen eingesetzt [45, 67, 68]. Eine Nutzung der Simulation zur WAAM-Prozessparameteroptimierung ist jedoch auf Grund der Prozesskomplexität durch den hohen Energieeintrag und die häufigen Abkühlzyklen nur im begrenzten Umfang möglich [57].

Nicht-zerstörende Qualitätssicherung

Zur Qualitätssicherung des gefertigten Bauteils stehen zerstörende und nicht zerstörende Prüfmethode zur Verfügung. Zerstörende Prüfmethode erfordern die Zerstörung des Bauteils, damit innenliegende Strukturen freigelegt und geprüft werden können. Es werden beispielsweise Schliffbilder von Querschnitten oder Zugproben erstellt, um die Gefügeeigenschaften zu untersuchen. Zerstörende Prüfmethode führen zu Ausschuss und sind deshalb für eine Serienfertigung von Bauteilen in Kleinserie nicht wirtschaftlich. Zerstörungsfreie Prüfmethode ermöglichen die Qualitätssicherung ohne eine Zerstörung des Bauteils. Bei WAAM-Bauteilen kommen folgende Methoden zum Einsatz [6, 56, 69]:

- **Sichtprüfung:** Das äußere Erscheinungsbild der Schweißnähte wird visuell überprüft, zum Beispiel in Anlehnung an die Norm ISO 19828. [20, 70]
- **Wirbelstromprüfung:** Am Prüfkopf wird ein Magnetfeld angelegt, dessen Rückkopplungen im Bauteil gemessen werden, um Unregelmäßigkeit aufzudecken. Messungen der elektrischen Leitfähigkeit des Bauteils basierend auf dem Wirbelstromprinzip zeigen zudem eine hohe Korrelation zur Mikrostruktur und zur Härte des Bauteils. [69]
- **Ultraschallprüfung:** Das Bauteil wird mittels Ultraschall durchleuchtet. Je nach Bauteil können Varianten wie beispielsweise eine Ultraschallprüfung im Tauchbad oder ein RasterScan genutzt werden. [69]
- **Durchstrahlungsprüfung:** Das Bauteil wird mittels Röntgenstrahlung durchleuchtet. Dichteunterschiede im Material sind in der Projektion ersichtlich, sodass beispielsweise auf Bindefehler, Schlackeeinschlüsse oder Poren geschlossen werden kann. Computertomographie (CT) ermöglicht die dreidimensionale Vermessung des Bauteils. Dazu werden Röntgenbilder aus verschiedenen Winkeln um eine Rotationsachse aufgenommen und zusammengesetzt, um Tiefeninformationen zur Bauteilstruktur zu erhalten. [64, 71]

Die aufgezeigten Prüfmethode sind in der Realität nur begrenzt einsetzbar [39]. Beim WAAM-Prozess werden großvolumige Bauteile aufgebaut, welche mittels CT und Röntgen zum Teil nicht mehr vermessen werden können. Durch die additive Fertigung weisen die Bauteile zudem eine vergleichsweise hohe Komplexität auf, sodass die Untersuchungen mittels

Wirbelstrom- und Ultraschallprüfung schwierig umzusetzen sind. Die Oberflächenrauheit führt zu Störsignalen, sodass vor der Prüfung eine Nachbearbeitung des Bauteils stattfinden muss. Innenliegende Strukturen sind im Anschluss an die Fertigung für die Prüfung nicht erreichbar. Die nachgelagerte Bauteilanalyse führt damit zu einem zeitlichen Mehraufwand und erfordert den Einsatz kostenintensiver Technologien. Nichtzerstörende Prüfmethoden erfüllen deshalb nicht den Bedarf der Industrie [39]. Abhilfe schafft die Qualitätssicherung mittels einer in-situ-Prozessüberwachung. Mit ihr können Einblicke in das Bauteil zu gewonnen werden, die nachgelagert sonst nur durch aufwendige Prüfmethoden möglich sind [6, 72].

Prozessüberwachung

Ziel der Prozessüberwachung bei WAAM ist die Ableitung von qualitäts- und prozessrelevanten Informationen im Prozess. Da Schweißen die Grundlage des WAAM-Prozesses bildet, betrachten auch die WAAM-Prozessüberwachungssysteme die dort üblichen Messgrößen wie Schweißgeschwindigkeit, Drahtvorschub, Schutzgasfluss sowie Schweißstrom und -spannung [6, 73, 74]. Zhu et al. nutzten die Schweißspannung um damit die Schweißbadhöhe im WIG-basierten WAAM-Prozess zu bestimmen [75]. Reisinger et al. trainierten ein neuronales Netz auf elektrischen Prozessdaten, um Abweichungen im MSG-Prozess zu detektieren [76]. Mazlan et al. verwendeten eine Audioanalysetechnik zur Auswertung des Schweißstroms, um die Qualität der Schweißnaht abzuleiten [77]. Huang nutzten ein Klassifikationsmodell, um auf Basis des Schweißstroms für einen MSG-Prozess die Schweißnahtqualität zu bestimmen [78].

Die Abmessungen des Schweißbads und der Schweißnaht werden mithilfe optischer Sensorik bestimmt. Purrio gewann beispielsweise Informationen zu Brennerfehlpositionierung, Lichtbogenverhalten und Schmelzbadbreite aus der optischen Überwachung mittels Kamera [79]. Zhang et al. führten eine geometrische Analyse des Schmelzbads durch, indem das Schweißbad mit einem Laser bestrahlt und dessen Reflexion mittels einer Kamera gemessen wurde [80]. Font-Comas et al. analysierten den WAAM-Prozess ebenfalls mit Kameras. Sie bestimmten die Schmelzbadbreite mittels computerbasierter Bildverarbeitung unter Nutzung des Canny-Algorithmus und der Hough-Transformation. [81] Xiong et al. nutzten zwei Kameras, um in Echtzeit die Schmelzbadhöhe und -breite für MSG-basiertes WAAM zu ermitteln [82]. Borovkov et al. stellten eine kamerabasierte Methoden zur prozessparallelen Höhenmessung für LMD und WAAM mittels einer Triangulation vor. Die Methodik benötigte einen Projektor und wurde lediglich zur Vermessung einspuriger Schweißnähte genutzt. [83] Xu et al. bestimmten die Abmessungen der Lage mithilfe eines Laserprofilometers in einem Zwischenlagenschritt [72]. Über eine optische Analyse des Schweißbads kann zudem auf die Schweißqualität geschlossen werden. Cho et al. detektierten den Humping-Effekt prozessparallel anhand der Auswertung von Kamerabildern mit einem faltenden neuronalen Netz [62]. Xia et al. klassifizierten mit Humping-Effekt bedingter Geometrieabweichungen, Roboterstillstand und starke Spritzerbildung aufgrund von Oxidation drei Typen von Unregelmäßigkeiten mithilfe faltender neuronaler Netze unter Nutzung von Kamerabildern. Die Defektklassifizierung wurde für eine einlagige, einspurige Schweißnaht durchgeführt. [84]

Wie bereits in Abschnitt 2.1.2 beschrieben ist die Bauteiltemperatur entscheidend für einen erfolgreichen Aufbau, da sie einen direkten Einfluss auf die Qualitätseigenschaften des Bauteils hat [85, 38]. Renil et al. untersuchten die Temperaturverteilung im CMT-Prozess für eine Kehlnaht mithilfe einer Infrarotkamera und konnten durch einen Vergleich mit Röntgenaufnahmen auf Porositäten schließen [86]. Yang et al. nutzen eine Infrarotkamera für die additive Fertigung mittels MSG-Schweißen um die Auswirkungen von Kühlzeiten auf die Temperatur und Formstabilität im Prozess zu untersuchen [66]. Xu et al. nutzten ein Pyrometer, um die Abkühlzeit zu bestimmen und die Temperatur des Bauteils als Entscheidungsvariable für den Start des nächsten Prozessschritts zu erhalten [72].

Darüber hinaus können die akustischen Emissionen des WAAM-Prozesses für die Prozessüberwachung genutzt werden. So geben akustische Signale in der Schweißzelle, im Konkreten die Frequenzen und Lautstärken, Informationen über die Intensität und Stabilität des Lichtbogens und damit über die Prozessstabilität und -qualität wie Horvat et al. für den MSG-Prozess zeigten [87]. Cudina et al. sowie Chen et al. leiteten eine Korrelation zwischen den akustischen Emissionen des Schweißprozesses und dem Schweißstrom sowie der Schweißspannung her [88, 89]. Polajnar et al. konnten mithilfe einer prozessparallelen Audiodatenanalyse auf Prozessinstabilitäten im MSG-Prozess für Stahl schließen [90]. Dong et al. schlossen durch Auswertung der akustischen Emissionen bei 3.16 kHz, 5.71 kHz und 6.00 kHz auf die Anbindungsgüte der Schweißnaht für einen WIG-Schweißprozess bei einer Al-Mg-Legierung [91].

Eine spektrale Analyse stellt weitere Informationen für die Bewertung der Prozessqualität bereit. Die spektralen Emissionen sind dabei hauptsächlich auf den Lichtbogen, das Bauteil und die Schlacke zurückzuführen [92]. Zhao et al. führten eine Spektralanalyse aus, um die Qualität des Schweißprozesses anhand der Lichtemissionen des Lichtbogens zu beurteilen [93]. Weglowski et al. zeigten für das WIG-Schweißen eine Abhängigkeit des Spektrum von diversen Prozessparametern wie Drahtmaterial, Lichtbogenlänge, Inertgas, Drahtvorschub und Strom. Besonders die Einflüsse von Strom, Inertgas und Lichtbogenlänge waren signifikant. [92] Nach Okuno et al. haben Schweißstrom und -spannung sowie der Drahtdurchmesser lediglich Einfluss auf die absolute Intensität des Spektrums. Alle weiteren Unterschiede sind primär dem Material geschuldet. So führt bei Aluminiumlegierungen der Magnesiumanteil zu einer erhöhten Intensität im Bereich 200 nm bis 300 nm. [94] Zhang et al. untersuchten einen einspurigen WAAM-Prozess mittels Spektrometer. Sie fanden Korrelationen im Spektrum für durch Verunreinigungen künstlich eingebrachte Porosität [95]. Beim WIG-Schweißen konnten zudem mittels Spektroskopie fünf Defekte, darunter Verunreinigungen und Bindefehler, detektiert werden [96, 97].

Die verschiedenen Sensordaten bilden jeweils lediglich einen Teilaspekt des WAAM-Prozesses ab. Für ein vollständiges digitales Abbild ist ein Multisensoransatz erforderlich [89]. Rodrigues et al. verwiesen deshalb darauf, dass die Entwicklung von multiparameterbasierten, nicht-zerstörenden Testsystemen notwendig ist, um die Defektentstehung zu identifizieren und die Verlässlichkeit der Fehlererkennung zu erhöhen [6]. Um die verschiedenen Eigenschaften der Sensorsysteme zu kombinieren, bauten Artaza et al. ein multivariates Prozessüberwachungssystem auf, welches neben einem Pyrometer, einer Schweißkamera und einem Laserscanner über ein Sauerstoffmessgerät verfügte, mit dem der Sauerstoffgehalt während des Prozesses analysiert wurde [98]. Chen et al. kombinierten Strom- und Spannungswerte, akustische Emissionen und optische Daten einer Kamera mithilfe einer fuzzy-basierten Methode, um den Status des Schweißinbrands zu bewerten [89]. Zhao et al. kombinierten optische Sensoren mit elektrischer Sensorik, indem sie eine Spektralanalyse mit den Daten einer bildgebenden Kamera und eines Stromsensors für die Qualitätsüberwachung zusammenführten. Dadurch konnten sie für eine einzelne Schweißnaht Defekte infolge von Oxidation und Ölrückständen nachweisen. [93] Xu et al. stellten ein Konzept vor, welches Strom- und Spannungssensoren sowie zwei Laserprofilometer nutzte. Weiterhin wurde der Sauerstoffgehalt der Umgebung sowie die akustischen Emissionen in die Auswertung mit einbezogen, um den Prozesszustand zu überwachen [72]. Reisgen et al. nutzten Strom- und Spannungsdaten sowie Intensitätsdaten von drei Fotodioden zur Detektion von künstlich erzeugten Defekten im MSG-Prozess mithilfe eines neuronalen Netzes [76]. Kommerzielle Lösungen zur WAAM-Prozessüberwachung sind bei den Start-Ups WAAM3D, Ramlab und MX3D zu finden (siehe Anhang A.4) [99, 100, 101].

2.1.4 Prozesseingriff

Die Dynamik im Aufbau und Prozessinstabilitäten führen dazu, dass es ohne Prozesseingriffe zu Abweichungen zwischen dem realen Fertigungsprozess und der Prozessplanung kommt. Besonders die korrekte Vorhersage der Schichthöhe in der Pfadplanung ist aufgrund von Prozessinstabilitäten und komplexen thermomechanischen Phänomenen herausfordernd [21]. Aus diesem Grund sind Prozessregelungen erforderlich. Im Gegensatz zu Steuerungen nutzen Regelungen eine Messeinrichtung, um Informationen über den Zustand der Regelstrecke zu erhalten und bei Störungen entsprechend reagieren zu können.

Für den WAAM-Prozess werden Regelungsstrategien untersucht, die eine gleichmäßige Schweißnahtgeometrie sowie Prozessstabilität gewährleisten sollen. In Grenzen sind somit auch Regelungen konventioneller Schweißapplikationen übertragbar. Kwak et al. vermaßen beispielsweise die Schweißnaht eines MSG-Prozesses mittels zweier Laserlinienscanner und passten den Wärmeeintrag an, um die Schmelzbadbreite konstant zu halten. Mithilfe eines prädiktiven Algorithmus wurde unter Nutzung der Messungen des einen Laserlinienscanners ein Kontext für die Regelung generiert. Das Ergebnis des Prozesseingriffs wurde mit dem zweiten Laserlinienscanner untersucht. Die Übertragbarkeit auf formgebende Schweißverfahren wurde postuliert. [102] Lü et al. ermittelten mithilfe einer Kamera die Schmelzbadgeometrie. Der Schweißstrom wurde als Stellgröße genutzt, um für einen einspurigen, einlagigen WIG-Prozess die Schweißbadgeometrie zu beeinflussen [103]. Xiong et al. untersuchten einen richtungsabhängigen, selbstlernenden Regler für gerade, dünnwandige WAAM-Bauteile, der die Schweißnahtbreite als Messgröße und die Schweißgeschwindigkeit als Stellgröße verwendete. Die Schweißnahtbreite wurde mit einem Positionsabstand von 18 mm vom aktuellen Schweißpunkt durch Auswertung eines Kamerabilds gemessen. Die erreichte maximale Abweichung zwischen Ist- und Sollbreite der Schweißnaht lag bei 0,5 mm. [104] Xia et al. regelten die Schweißnahtbreite mithilfe einer modellprädiktiven Regelung (engl. Model Predictive Control (MPC)) für einspurige Wände. Die Schweißnahtbreite wurde prozessparallel mithilfe einer Schweißkamera gemessen. [105] Han et al. setzten mithilfe eines Laserlinienscanners eine richtungsabhängige WAAM-Schmelzbadregelung für mehrlagige, mehrspurige Bauteile mit geraden, parallelen Schweißnähten um. Ein selbstlernender Regler mit Proportional- und Integralanteil regelte die Schmelzbadbreite und ein regelbasierter Algorithmus die Schmelzbadhöhe. Es konnte eine Genauigkeit von 0,25 mm in der Breite und 0,1 mm in der Höhe erreicht werden. [106] Zhu et al. schlugen einen Fuzzy-PID-Regler für einen WIG-basierten WAAM-Prozess vor, bei dem die Spannung als Messgröße für den Abstand zwischen Schweißbrenner und Bauteil diente. In der nachfolgenden Lage wurde der Drahtvorschub angepasst, um eine konstante Höhe der Wand zu erreichen. Abschließend merkten sie an, dass der Abstand bei MSG-basierten Prozessen nicht auf die gleiche Weise gemessen werden kann und weitere Forschung erfordert. [75] Tang et al. legten einen Ansatz zur Modellierung des Schweißbads mithilfe eines neuronalen Netzes dar. Als Eingangssignale nutzten sie die Schweißgeschwindigkeit, den Schweißstrom und die Schweißspannung, die Temperatur und den Drahtvorschub. Zur Umsetzung einer Regelung für eine gerade Wand maßen sie nach jedem abgeschlossenen Schweißvorgang die Oberflächentopologie mithilfe eines Laserlinienscanners. [107] Li et al. stellten eine Höhenregelung für mehrlagige WAAM-Bauteilen mit geraden, parallelen Schweißnähten vor. Vor Beginn einer neuen Schicht wurde die vorherige Lage mithilfe eines Laserlinienscanners vermessen und die Prozessparameter der nächsten Schicht entsprechend angepasst. [108] Chabot et al. maßen mittels eines Mikrofons die akustischen Emissionen des CMT-Prozesses, um über eine gesamte Lage gemittelt auf den Abstand zwischen Schweißbrenner und Bauteil zu schließen und die Prozessparameter der nächsten Lage anzupassen. Dadurch konnte für eine einspurige Wand ein konstanter Abstand gewährleistet werden. [109] Xiong et al. regelten einen WIG-basierten WAAM-Prozess für gerade Wände mithilfe einer visuellen Auswertung der Lagenhöhe. Der

PID-Regler nutzte als Messgrößen sowohl die Höhe der aktuellen als auch die der vorherigen Schicht. [110] Tang et al. schlugen ein hybrides Fertigungssystem vor, das nach jeder Schicht die Höhe der Schweißnähte mithilfe eines Laserprofilometers auswertet und bei Überhöhungen Fräsoperationen und bei Lücken zusätzliche Operationen für den Materialauftrag generierte [19]. Scetinec et al. stellten eine Regelung vor, welche bei Bedarf die Lagenhöhe im Maschinenprogramm anpasste oder eine zusätzliche Lage einfügte. Zur Berechnung der realen Schichthöhe nutzten sie den durchschnittlichen Strom des MSG-Prozesses in der vorangegangenen Lage. [111]

Um Unterschiede in der Geschwindigkeit des Roboters beim roboterbasierten WAAM-Prozess auszugleichen wurden zudem Regelungen untersucht, mit denen die Drahtvorschubgeschwindigkeit flexibel angepasst wird. Dadurch konnten Materialansammlungen in Ecken, die durch eine verminderte Geschwindigkeit des Schweißpunktes (engl. Tool Center Point (TCP)) entstanden, und damit Formabweichungen vermieden werden [54, 112].

Darüber hinaus kann für den WAAM-Prozess eine Temperaturregelung umgesetzt werden, indem eine Zwischenlagenabkühlzeit eingeführt wird, in welcher die Bauteiltemperatur absinkt [57]. Die Zeitdauer kann entweder in der Prozessplanung fest definiert werden oder im Prozess abhängig von Temperaturmesswerten beispielsweise eines Pyrometers oder einer Infrarotkamera angepasst werden [38, 113]. Die Kühlung erfolgt passiv oder aktiv beispielsweise durch Nutzung gerichteter Druckluft oder eines Aerosols [38, 114, 115]. Auch der Einsatz einer Kühlplatte oder eines Wasserbads ist möglich [115].

2.2 Digitaler Zwilling im Fertigungssystem

Der Digitale Zwilling dient der Darstellung einer physischen Instanz im digitalen Raum. Das Konzept wurde 2002 von Grieves et al. im Rahmen seiner Arbeit zum Produktlebenszyklus eingeführt [116, 117]. Seitdem nimmt die Bedeutung des Digitalen Zwillings stetig zu. So soll der Markt im Vergleich zu 3.1 Milliarden US-\$ im Jahr 2020 auf eine Größenordnung von 48.2 Milliarden US-\$ im Jahr 2026 wachsen [118]. Die Anwendungsbereiche sind vielfältig. Digitale Zwillinge finden sich beispielsweise in der Luft- und Raumfahrt, dem Energiesektor oder im Gesundheitsbereich [119]. Besonders weit sind Digitale Zwillinge jedoch in der industriellen Fertigung verbreitet [119]. Sie werden dort zu Simulations-, Monitoring- und Regelungszwecken eingesetzt [1, 119]. Im Folgenden werden zunächst eine Begriffsdefinition gegeben und eine Einordnung des Digitalen Zwillings in den Bereich Industrie 4.0 vorgenommen. Anschließend folgt eine Vorstellung der Eigenschaften und Elemente des Digitalen Zwillings sowie der Norm DIN ISO 23247. Der Abschnitt schließt mit einer Beschreibung von Umsetzungen des Digitalen Zwillings in der additiven Fertigung.

2.2.1 Einordnung und Begriffsdefinition

Nach Grieves et al. erfordert ein Digitaler Zwilling drei Elemente: eine physische Entität im echten Raum, eine virtuelle Entität im virtuellen Raum und eine Datenanbindung, über die die physische und die virtuelle Entität miteinander gekoppelt sind [117, 120]. Die Abgrenzung zu den Begriffen *Digitales Modell* und *Digitaler Schatten* findet nach Kritzinger et al. anhand der Datenanbindung statt [121].

Definition 2 *Digitales Modell*: Ein *Digitales Modell* beschreibt das statische digitale Abbild einer physischen Entität.

Das Digitale Modell (Definition 2) wird nicht von der Außenwelt beeinflusst und verändert sich nach seiner Erstellung nicht mehr.

Definition 3 *Digitaler Schatten:* *Ein Digitaler Schatten beschreibt das sich dynamisch verändernde digitale Abbild einer physischen Entität mit unidirektionaler Datenanbindung.*

Der Digitale Schatten (Definition 3) erfasst Daten des physischen Objekts, gibt aber keine Daten zurück. Damit liegt lediglich ein unidirektionaler Datenfluss vor.

Definition 4 *Digitaler Zwilling:* *Ein Digitaler Zwilling beschreibt das sich dynamisch verändernde digitale Abbild einer physischen Entität mit bidirektionaler Datenanbindung.*

Der Digitale Zwilling (Definition 4) beinhaltet hingegen Daten und Algorithmen, mit denen die reale Welt abgebildet wird. Die enthaltenen Informationen dienen als Entscheidungsgrundlage für die Interaktion mit der physischen Entität, sodass sich ein bidirektionaler Datenverkehr zwischen physischem Objekt bzw. Prozess und Digitalem Zwilling ergibt. Die virtuelle Entität nimmt damit einerseits einen Datenfluss aus der Außenwelt auf und gibt andererseits einen Informationsfluss an die Außenwelt zurück, um diese gezielt zu beeinflussen. [121, 122, 123] Für den Aufbau des Digitalen Zwillings spielen die während der Produktion gesammelten Daten eine elementare Rolle. Sie sind multimodal und müssen entsprechend verwaltet werden. Dazu sind nach Uhlemann et al. keine standardisierten Datenbanken für Fertigungsunternehmen verfügbar. Für die Auswertung der Daten werden Methoden wie beispielsweise neuronale Netze für maschinelles Sehen eingesetzt. Auf Grundlage der Auswertungsergebnisse erfolgt eine automatisierte Ableitung von Optimierungsmaßnahmen für den Prozess. [124, 125] Der Digitale Zwilling kann in weitere Konzepte eingebettet werden, darunter das Cyber-Physische System (CPS), die Intelligente Fertigung und Industrie 4.0. Industrie 4.0 bezeichnet eine Agenda der deutschen Bundesregierung zur umfassenden Digitalisierung der Industrieproduktion durch intelligente Vernetzung von Maschinen und Abläufen. Das Ziel ist die Entwicklung eines Intelligenten Fertigungssystems (engl. Smart Manufacturing System (SMS)) wie beispielsweise von Vater et al. vorgestellt [126]. Das Konzept des CPS wird neben dem Internet der Dinge, dem Internet der Dienstleistungen und der intelligenten Fabrik als eines der vier Kernelemente der Industrie 4.0 genannt und basiert auf einer Kombination von physischen Hardware- und informationstechnischen Softwarekomponenten [127]. Es setzt den Fokus auf die Sensorik und Aktorik [127, 128]. Die Hauptbestandteile eines Digitalen Zwillings sind hingegen Modelle und Daten [128]. Nach Uhlemann et al. stellt der Digitale Zwilling eine Voraussetzung zur Entwicklung eines CPS dar [125].

2.2.2 Elemente des Digitalen Zwillings

Ein Digitaler Zwilling muss nach Hribernik et al. über Kontextwahrnehmung verfügen sowie autonom und anpassungsfähig sein [129]. Diese Eigenschaften werden nachfolgend erläutert, um dann auf wesentliche Elemente eines Digitalen Zwillings einzugehen.

Kontextwahrnehmung: Kontextwahrnehmung ist nach Abowd et al. die Nutzung von Kontext um aufgabenrelevante Informationen oder Dienstleistungen bereitzustellen [130]. Kontext wird dabei wie folgt definiert [130]:

Definition 5 *Kontext:* *Kontext ist implizite situationsabhängige Information.*

Kontext ist damit jegliche Information, die genutzt werden kann, um die Situation einer Entität zu charakterisieren, wobei die Entität Person, Ort, physisches oder virtuelles Objekt sein kann. Nach Rosenberg et al. kann Kontext in die Kategorien Nutzer, Umgebung, System, Informationsgewinnung und Mustererkennung eingeteilt werden [131]. Ein kontextwahrnehmendes System verfügt über die Möglichkeit, Informationen abzurufen und zu verarbeiten um implizite situationsabhängige Information für eine Nutzerentität zu erhalten [129, 132]. Beispielhafte Umsetzungen kontextwahrnehmender Systeme sind bei Alexopoulos et al. [133] zur Herstellung von Haushaltsgeräten oder bei Lee et al. [134] zur Erweiterungen eines industriellen Prozessüberwachungssystems um eine anwenderspezifische Nutzeroberfläche zu sehen. Für den Digitalen Zwilling sah Mittal et al. Kontext als gegeben an, wenn das System sich seiner Identität, seines Ortes, seines Status und der Zeit bewusst war [135].

Autonomie: Autonomie impliziert einen Grad an Unabhängigkeit, der von der Umgebung beeinflusstes, selbstständiges Handeln ermöglicht [136]. Dadurch kann der Bedarf nach a-priori Planung vermindert und Prozesse lokal durch situationsabhängige Entscheidungsfindung optimiert werden [129]. Diese situationsabhängige Entscheidungsfindung kann unter Nutzung einer Regelung oder von prädiktiver und präskriptiver Analytik erreicht werden [137]. Letztere zeichnet sich dadurch aus, dass sie im Gegensatz zur diagnostischen und beschreibenden Analytik zukunftsorientiert ist. Während sich die prädiktive Analytik auf die Vorhersage beispielsweise von Leistungsmerkmalen beschränkt, betrachtet die präskriptive Analytik die Wirkungen von zukünftigen Aktionen [138]. Präskriptive Analytik wurde beispielsweise von Vater et al. genutzt, um sensordatenbasiert Entscheidungen beim Hairpin-Schweißen in der Elektromotorherstellung herbeizuführen [139].

Anpassungsfähigkeit: Anpassungsfähigkeit beschreibt die Fähigkeit eines Digitalen Zwillings, sich an eine neue Situation anzupassen [129]. Dazu muss der Digitale Zwilling über adaptive Algorithmen verfügen und kontextabhängig auf die Entität einwirken [140], sodass Flexibilität hinsichtlich verschiedener Fertigungsszenarien erreicht wird. Anpassungsfähigkeit erfordert damit implizit auch Kontextwahrnehmung.

Wie zuvor beschrieben geht der Aufbau eines Digitalen Zwillings mit SMS und CPS einher, welche Elemente der Automatisierungstechnik und des Internets der Dinge nutzen [141]. Es können dezentralisierte Architekturen unter Nutzung sogenannter Edge-Geräte oder zentralisierte Architekturen unter Nutzung eines Servers realisiert werden [1, 142]. Dezentrale Architekturen weisen dabei Vorteile hinsichtlich der Latenzzeiten auf, wohingegen zentralisierte Architekturen wartungsärmer sind [1]. Verbreitete Kommunikationsprotokolle für CPS sind MQTT (engl. Message Queuing Telemetry Transport) oder OPC UA (engl. Open Platform Communications Unified Architecture) [141]. OPC UA ist eine in der Normenreihe IEC 62541 standardisierte Schnittstelle, welche ein Informationsmodell inklusive semantischer Dienste umfasst. Sie ist herstellerunabhängig und plattformneutral. [143] Zur einfachen Maschinenintegration von OPC UA kommen standardisierte Schnittstellen wie beispielsweise umati (engl. Universal Machine Technology Interface) zum Einsatz, welche den Datenaustausch zwischen Maschinen vereinfachen [144]. Eine beispielhafte Implementierung eines Digitalen Zwillings unter Nutzung von OPC UA wurde durch Liu et al. zur Generierung einer Umgebung mit erweiterter Realität für die subtraktive Fertigung vorgestellt [145].

Darüber hinaus gibt es Bemühungen zur Standardisierung von Digitalen Zwillingen in der Fertigung, welche im Standardisierungsentwurf ISO/DIS 23247 festgehalten wurden [146].

Das Dokument besteht aus vier Teilen (Überblick und allgemeine Prinzipien; Referenzarchitektur; Digitale Repräsentation von Fertigungselementen; Informationsaustausch). Innerhalb der Referenzarchitektur werden drei Subentitäten als Hauptbestandteile der Kernentität für den Digitalen Zwilling definiert. In der Subentität für Operabilität und Management werden alle verwaltenden Funktionalitäten wie beispielsweise zur Synchronisation oder zur digitalen Modellierungen gesammelt. Es werden Informationen über beobachtbare Fertigungselemente vorgehalten, welche in den anderen Entitäten benötigt werden. In der Subentität für Applikationen und Services werden Funktionalitäten zum Beispiel zur Analyse von Daten oder zur Simulation zusammengefasst. Zuletzt stellt die Subentität für Ressourcenzugang und -austausch Zugangsmöglichkeiten für alle Funktionalitäten der Kernentität bereit.

Gesondert wird die digitale Repräsentation von beobachtbaren Fertigungselementen betrachtet, zu denen das Personal, die Ausrüstung, das Material, der Prozess, die Einrichtung, die Umwelt, das Produkt sowie unterstützende Dokumente zählen. Für jedes Element stehen Attribute zur Verfügung, welche unter Nutzung von Technologien wie beispielsweise STEP (ISO 10303), ISA-95 (IEC 62264) oder OPC UA (IEC 62541) repräsentiert werden können. Im vierten Teil der ISO/DIS 23247 wird der Informationsaustausch beschrieben. Das Nutzernetzwerk wird beispielsweise über ein privates Intranet aufgebaut, über das der Nutzer mit der Kernentität kommunizieren kann. Innerhalb der Kernentität wird ein Servicenetzwerk genutzt, welches den Austausch zwischen den Subentitäten ermöglicht. Der Informationsaustausch mit der Sensorik und Aktorik geschieht über das Zugangsnetzwerk.

2.2.3 Digitaler Zwilling in der Additiven Fertigung

Der Digitale Zwilling und die additive Fertigung ergänzen sich in ihren Anforderungen und Möglichkeiten. Während die additive Fertigung wegen kundenindividueller Bauteile mit geringer Stückzahl durch einen hohen Faktor an Unsicherheit charakterisiert ist, kann der Digitale Zwilling Struktur und Kontext bereitstellen. [147] Die Forschung von DebRoy und seiner Forschungsgruppe zielte darauf ab, den Herausforderungen im Bereich der Prozesswiederholbarkeit und Bauteilqualität in der additiven Fertigung mithilfe des Digitalen Zwillings zu begegnen [148, 149, 150, 151]. Nach DebRoy et al. und Knapp et al. haben Digitale Zwillinge auf drei Arten einen signifikanten Einfluss auf die additive Fertigung:

- Reduktion kosten- und zeitintensiver Iterationszyklen zur Optimierung von Prozessparametern
- Detektion von Prozessdefekten durch die Kombination theoretischer Vorhersagen und realer Echtzeitsensordaten
- Reduktion der Anforderungen an die Rechenleistung für Multiskalenmodelle

Der Digitale Zwilling wird als nächster Schritt in Richtung eines erfolgreichen Drucks beim ersten Versuch gesehen. Es ergeben sich Vorteile wie eine erhöhte Prozesswiederholbarkeit, eine höhere Produktintegrität, ein geringerer Bedarf an zerstörenden Prüfmethode und eine vereinfachte Zertifizierung neuer Bauteile, eine Reduktion oder Vermeidung von Iterationen zur Prozessparameteroptimierung, verbesserte Nachhaltigkeit durch weniger Ausschuss sowie eine höhere Kapazität der Fertigungsanlagen wegen einer geringeren Menge an Ausschuss [151]. Nach Adams und Mayr können Digitale Zwillinge zudem das Verständnis für den Prozess erhöhen und Nutzung von DED in der Produktion ermöglichen [152]. Mukherjee et al. stellten einen Ausblick auf einen umfassenden Digitalen Zwilling für die additive Fertigung vor und zählten verschiedene Aufgaben zu Erstellung eines solchen auf, darunter die Einführung von

physikalischen Modellen mit geringen Anforderungen an die Rechenleistung, eine Verbesserung der Sensordatenakquirierung sowie eine verbesserte Software für das Datenmanagement, die Datenanalyse und die Entscheidungsfindung [150]. In einer 2020 veröffentlichten Studie von Zhang et al. wurde festgehalten, dass die erste Generation von Digitalen Zwillingen für die additive Fertigung noch nicht existiert und noch Arbeit im Bereich Modellierung, Algorithmen und Datenbanken erfolgen muss [153]. Erste Ansätze werden nachfolgend vorgestellt.

Knapp et al. stellten ein simulationsbasiertes Teilelement eines Digitalen Zwillinges für den LMD-Prozess vor. Es wurde eine Geometrieabschätzung der Schweißraupe auf Basis verschiedener Prozessparameter vorgenommen, mit deren Hilfe die Anzahl der anfänglichen Iterationsschleifen reduziert werden sollte [149]. Gaikwad et al. erstellten einen Digitalen Schatten für L-PBF und LMD. Sie nutzen Temperaturdaten einer Simulation und verglichen diese mit realen Messwerten, um auf Erstarrungsdefekte im Bauteil zu schließen [154]. Stavropoulos et al. legten eine Methodik für eine robuste Regelung auf Basis eines Digitalen Zwillinges für den L-PBF-Prozess vor. Der Digitale Zwilling wurde genutzt um mithilfe einer Echtzeittemperatursimulation Systemunsicherheiten auszugleichen. [65] Yang et al. erstellten für die Prozessparameterauswahl des L-PBF-Prozesses ein *Black Box*-Modell auf Basis von statistischen Methoden sowie ein *White Box*-Modell auf Basis von Prozesswissen. Die beiden Modelle führten sie in einem *Grey Box*-Modell zusammen. Dadurch entstand ein Digitaler Schatten, mit dem Prozessparameter für andere Metallpulver vorhergesagt werden konnten. [155, 156]

Darüber hinaus gibt es erste Ausführungen von Digitalen Zwillingen für die kunststoffbasierte Materialeextrusion. So stellten Hu et al. einen cloud-basierten Digitalen Zwilling für Fertigungssysteme vor, der ein Modell für einen Fused Deposition Modelling (FDM)-Drucker beinhaltet [157]. Mourtzis et al. schlugen eine Architektur für den Informationsfluss in einem Digitalen Zwilling zur Prozessüberwachung für FDM-Prozesse vor. Vor zukünftigen Druckaufträgen konnte eine Prozessparameteroptimierung durchgeführt werden. [158]

Die meisten der vorhandenen Konzepte für Digitale Zwillinge in der additiven Fertigung befassen sich lediglich mit Simulationsaspekten [153]. Digitale Zwillinge des Prozesses wurden bisher kaum untersucht. Dabei handelt es sich um eine Forschungslücke, welche nach Gunasegaram et al. im nächsten Jahrzehnt gefüllt werden muss, um die genannten Vorteile des Digitalen Zwillinges für den Prozess nutzen zu können und damit die additive Fertigung in der Industrie attraktiver zu gestalten. [151]

2.3 Datenanalytik und datengetriebene Entscheidungsfindung

Nach Tao et al. sind die Hauptbestandteile des Digitalen Zwillinges Daten und Modelle [128]. Die Auswertung der Daten erfolgt unter Nutzung der Modelle mit dem Ziel, Zusammenhänge aufzudecken, Wissen abzuleiten und Entscheidungen zu treffen. In der Datenauswertung werden verschiedene Phasen durchlaufen, wobei in industriellen Anwendungen die Aufteilung in die sechs Phasen der Cross Industry Standard Process for Data Mining (CRISP-DM)-Methode Verbreitung findet [159, 160]. Nach CRISP-DM beginnt der Datenanalyseprozess mit dem Geschäfts- sowie dem Datenverständnis. Es folgen die Phasen für die Datenvorbereitung, die Modellierung und die Evaluierung der Modelle. Abschließend werden die Modelle bereitgestellt und für den Anwendungsfall nutzbar gemacht.

Nachfolgend werden Grundlagen für die Phasen des Datenverständnisses und der Datenvorbereitung, der Modellierung sowie der Evaluierung vorgestellt. Der Fokus des Stands der Technik liegt auf Zeitreihendaten, welchen in der Prozessüberwachung und -regelung eine besondere Bedeutung zukommt.

2.3.1 Datenverständnis und -vorbereitung

Daten werden in nominale, ordinale und kardinale Daten unterteilt. Nominale Daten weisen keine Rangordnung auf und können lediglich durch einen Test auf Gleichheit miteinander in Relation gesetzt werden. Ordinale Daten lassen sich in eine Rangfolge bringen, wobei die Abstände zwischen den Elementen nicht interpretierbar sind. Für kardinale Daten lässt sich eine Rangordnung mit interpretierbaren Abständen nutzen.

Zeitreihenanalyse

Daten liegen als Zeitreihe vor, wenn sie der Definition 6 nach Keogh et al. entsprechen [161].

Definition 6 *Zeitreihen*: *Zeitreihen sind sequentielle Daten, deren Elemente in einem zeitlichen Bezug zueinander stehen. Eine Zeitreihe \mathbf{T} ist damit ein zeitlich geordneter Satz von n Elementen t_k ($k \in 1, \dots, n$) gemäß Gleichung 2.3.*

$$\mathbf{T} = \{t_1, \dots, t_n\} \quad (2.3)$$

In der Prozessüberwachung handelt es sich bei t_k üblicherweise um Skalare ($t_k \in \mathbb{R}^1$), Vektoren ($\mathbf{t}_k \in \mathbb{R}^u$) oder Matrizen ($\mathbf{t}_k \in \mathbb{R}^{u \times v}$), wobei u und v den Dimensionen der Vektoren beziehungsweise der Matrizen entsprechen. Digitale Zeitreihendaten sind wert- und zeitdiskret. Kardinale Zeitreihendaten werden mittels Normalisierung (Gleichung 2.4) unter Nutzung des minimalen Werts t_{min} und des maximalen Werts t_{max} der Zeitreihe in einen Wertebereich von $[0, 1]$ gebracht.

$$t_k^{norm} = \frac{t_k - t_{min}}{t_{max} - t_{min}} \quad (2.4)$$

Bei der Standardisierung (Gleichung 2.5) wird von jedem Wert der Mittelwert der Verteilung \bar{T} (Gleichung 2.6) abgezogen und die Daten skaliert, so dass die Standardabweichung σ (Gleichung 2.7) bei einem Wert von 1 liegt.

$$t'_k = \frac{t_k - \bar{T}}{\sigma} \quad (2.5)$$

$$\bar{T} = \frac{1}{n} \sum_{k=1}^n t_k \quad (2.6)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (t_k - \bar{T})^2} \quad (2.7)$$

Normalisierung und Standardisierung erleichtern die Modellierung und den Vergleich unterschiedlicher Zeitreihen.

Zeitreihen können stationär sein, eine Saisonalität oder einen Trend aufweisen [162]. Saisonalität kann beispielsweise durch eine Fouriertransformation oder eine Untersuchung der Autokorrelation quantifiziert werden. Fulcher et al. extrahierten insgesamt mehr als 7700 relevante Zeitserienmerkmale, um auf Zusammenhänge zwischen Zeitreihen und der zugehörigen Klasse zu schließen [163, 164]. Lubba et al. kondensierten diese Merkmale auf eine *Catch22* genannte Untermenge von 22 Zeitserienmerkmale, welche trotz der reduzierten Anzahl über einen hohen Informationsinhalt verfügte. Die *Catch22*-Merkmale können unabhängig von der Länge des bereitgestellten Datensatzes berechnet werden.[165]

Zeitreihen können einer Konzeptverschiebung nach Definition 7 unterworfen sein [166].

Definition 7 Konzeptverschiebung: *Konzeptverschiebung liegt vor, wenn sich die statistischen Eigenschaften einer Variablen über die Zeit hinweg auf unvorhergesehene Weise verändern.*

In Folge einer Konzeptverschiebung können sich die Ausprägungen der Zeitreihenmerkmale verändern.

Distanz- und Ähnlichkeitsmaße

Zur quantitativen Bestimmung von Unterschieden und Gemeinsamkeiten von Dateninstanzen werden Distanz- und Ähnlichkeitsmaße eingesetzt. Verbreitete Distanzmaße zur Berechnung der Distanz zwischen zwei Elementen $\mathbf{x}, \mathbf{y} \in \mathbb{R}^u$ (Gleichung 2.8) sind der Gruppe der Matrixnormen nach Gleichung 2.9 zuzuordnen [159].

$$d(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\| \quad (2.8)$$

$$\|\mathbf{x}\|_A = \sqrt{\mathbf{x} \mathbf{A} \mathbf{x}^T} \quad (2.9)$$

Die euklidische Distanz wird mit \mathbf{A} gemäß Gleichung 2.10 berechnet.

$$\mathbf{A} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{pmatrix} \quad (2.10)$$

Die Matrix A der skaleninvarianten Mahalanobisdistanz lässt sich mithilfe der inversen Kovarianzmatrix cov_X^{-1} des Datensatzes $X = \{\mathbf{x}_1, \dots, \mathbf{x}_n\} \subseteq \mathbb{R}^u$, wie in Gleichung 2.11 gezeigt, bestimmen. \bar{x} stellt das arithmetische Mittel der Elemente von X dar. [159, 167]

$$\mathbf{A} = \text{cov}_X^{-1} = \left(\frac{1}{n-1} \sum_{k=1}^n (\mathbf{x}_k - \bar{\mathbf{x}})^T (\mathbf{x}_k - \bar{\mathbf{x}}) \right)^{-1} \quad (2.11)$$

Die Ähnlichkeit zweier Elemente \mathbf{x} und \mathbf{y} mit $\mathbf{x}, \mathbf{y} \in \mathbb{R}^u$ lässt sich mithilfe der Kosinusähnlichkeit $s(\mathbf{x}, \mathbf{y})$ nach Gleichung 2.12 bestimmen. [159]

$$s(\mathbf{x}, \mathbf{y}) = \frac{\sum_{k=1}^u x^{(k)} y^{(k)}}{\sqrt{\sum_{k=1}^u (x^{(k)})^2 \cdot \sum_{k=1}^u (y^{(k)})^2}} \quad (2.12)$$

Die vorgestellten Distanz- und Ähnlichkeitsmaße erfordern zwei Vektoren der gleichen Länge. Um auch Vektoren unterschiedlicher Länge miteinander zu vergleichen und dabei Stauchungen und Streckungen zu berücksichtigen, kann eine dynamische Zeitnormierung (engl. Dynamic Time Warping (DTW)) vorgenommen werden. Diese bildet zwei Vektoren aufeinander ab, indem die Zeitabstände zwischen den Vektoreinträgen gestaucht oder gestreckt werden, um eine minimale Distanz zwischen den Vektoren zu erreichen. [168]

Stochastische Abhängigkeit

Zwei Ereignisse A und B sind stochastisch unabhängig, wenn $P(A \cup B) = P(A) \cdot P(B)$ gilt. Andernfalls sind sie stochastisch abhängig. Stochastisch unabhängige Datensätze sind stets unkorreliert. Im Falle einer Korrelation zwischen den Datensätzen impliziert dies stochastische

Abhängigkeit. Um die Korrelation zwischen zwei Verteilungen \mathbf{X} und \mathbf{Y} zu untersuchen werden Zusammenhangsmaße genutzt. Lineare Zusammenhänge können mit dem Pearson'schen Korrelationskoeffizient $\rho_{\mathbf{X},\mathbf{Y}}$ aus Gleichung 2.13 überprüft werden. [159, 167]

$$\rho_{\mathbf{X},\mathbf{Y}} = \frac{\text{cov}_{\mathbf{X},\mathbf{Y}}}{\sigma_{\mathbf{X}} \cdot \sigma_{\mathbf{Y}}} \quad (2.13)$$

Dazu wird die Kovarianz $\text{cov}_{X,Y}$ der Verteilungen X und Y durch das Produkt der Standardabweichungen σ_X und σ_Y der Verteilungen X und Y geteilt. Der Korrelationskoeffizient ist symmetrisch und liegt in einem Wertebereich von $\rho_{X,Y} \in [-1; +1]$, wobei ein Wert ungleich Null auf eine positive bzw. negative lineare Korrelation hindeutet.

Zur Untersuchung beliebiger monotoner Zusammenhänge kann der Rangkorrelationskoeffizient von Spearman r_s genutzt werden. Dieser basiert auf dem Pearson'schen Korrelationskoeffizient, wobei jedem Element der Verteilungen zuvor abhängig von seinem Wert ein Rang zugewiesen wird, welcher anschließend für die Korrelationsanalyse genutzt wird.

Korrelation impliziert keine Kausalität. Der stochastische Zusammenhang kann beispielsweise zufallsbedingt oder die Korrelation durch den Zusammenhang beider Variablen mit einer dritten Variable verursacht sein. [159]

2.3.2 Modellierung und Maschinelles Lernen

Algorithmen des Maschinellen Lernens werden in überwachte und unüberwachte Algorithmen unterteilt. Beim überwachten Lernen liegen für Werte des Eingangsraums X korrespondierende Zielwerte im Ausgangsraum Y vor. Für diese Wertepaare soll eine generalisierende Funktion $h(\theta) : X \rightarrow Y$ mit den dazugehörigen Parametern θ erlernt werden. Der Lernvorgang ist ein Minimierungsproblem, bei dem eine Fehlerfunktion \mathcal{L} üblicherweise innerhalb mehrerer Iterationszyklen minimiert wird. Beim unüberwachten Lernen liegen keine Zielwerte vor. Stattdessen sollen Muster und Abhängigkeiten in den Daten aufgedeckt und erlernt werden. [169] Die Funktion $h(\theta)$ kann durch verschiedene Algorithmen modelliert werden. Eine Auswahl solcher Algorithmen wird im Folgenden vorgestellt. Anschließend erfolgt eine Darstellung des Stands der Forschung im Bereich des Metalernens und Lernens mittels weniger Datenelemente. Abschließend wird die Thematik Anomaliedetektion für Zeitreihendaten beleuchtet.

Algorithmen des maschinellen Lernens

Entscheidungsbäume [170] sind sequentielle Modelle, bei denen in jeder Sequenz die eingehende Größe mit einem Grenzwert verglichen und so eine Klassifikation vorgenommen wird. Bei Regressionsaufgaben mit kontinuierlichen Zielwerten, wird von Regressionsbäumen gesprochen. Algorithmen auf Basis von Entscheidungsbäumen sind der von Quinlan et al. vorgeschlagene ID3-Algorithmus [170], CART [171] sowie C4.5 [172] und C5.0 [173]. Random Forest ist ein Algorithmus zur Klassifikation und Regression, welcher auf der Kombination mehrere Entscheidungsbäumen in innerhalb des Merkmalsraums zufällig ausgewählten Subbereichen beruht [174, 175]. Durch Mehrheitsentscheidung basierend auf den Ergebnissen der einzelnen Entscheidungsbäume wird das Gesamtergebnis des Algorithmus ermittelt [175]. Den Vorgang, die Vorhersagen mehrerer Modelle zu kombinieren um ein Ergebnis mit geringerer Varianz zu erhalten, nennt sich *Bagging* und wurde von Breiman entwickelt [176]. *Boosting* wurde von Schapire eingeführt und kombiniert mehrere schwache Klassifikatoren zu einem starken Klassifikator [177]. Boosting Methoden wurden beispielsweise für die Algorithmen XGBoost [178] oder AdaBoost [179] genutzt.

Eine Support Vector Machine (SVM) definiert Hyperebenen im Raum um Daten in Gruppen einzuteilen [180, 181]. Die Elemente, welche der Hyperebene am nächsten sind, werden Stützvektoren genannt. Für nicht-lineare Lösungen werden Kernelfunktionen genutzt, welche die Daten in einen mehrdimensionalen Raum projizieren, in welchem eine optimale Hyperebene gefunden werden kann [159]. SVMs können sowohl zur Regression als auch zur Klassifikation eingesetzt werden.

Künstliche Neuronale Netze (KNN) weisen einen biologisch inspirierten Aufbau auf und bestehen aus miteinander verbundenen künstlichen Neuronen. Durch Kombination mehrerer Neuronen lassen sich komplexe mathematische Funktionen abbilden. Jede Verbindung zwischen zwei Neuronen i und j weist einen Gewichtungsfaktor $w_{ij} \in \mathbb{R}$ auf. Die Funktion $h_i(x)$ des Neurons i basiert auf einer Aktivierungsfunktion $s : \mathbb{R} \rightarrow \mathbb{R}$, deren Operand die Summe des Produkts der Gewichtungsfaktoren w_{ij} der eingehenden Verbindungen und der Ausgangswerte der zugehörigen Neuronen x_j sowie des Schwellenwerts $b_i \in \mathbb{R}$ ist.

$$h_i(x) = s \left(\sum_j w_{ij} \cdot x_j + b_i \right) \quad (2.14)$$

Verbreitete Ausprägungen der Aktivierungsfunktion s sind die Sigmoidfunktion (Gleichung 2.15), die gleichrichtende Funktion (engl. Rectified Linear Units (ReLU)) (Gleichung 2.16) [182] und die hyperbolische Tangensfunktion (Gleichung 2.17). Durchlässige, gleichrichtende Funktionen erlauben auch für negative Eingangswerte Ergebnisse ungleich Null, wobei die Steigung ein Hyperparameter (engl. leaky ReLU) oder ein Netzwerkparameter (engl. parametric ReLU) sein kann.

$$s(x) = \frac{1}{1 + e^{-x}} \in (0, 1) \quad (2.15)$$

$$s(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \in [0, \infty) \quad (2.16)$$

$$s(x) = \tanh x \in (-1, 1) \quad (2.17)$$

Bei einem schichtweisen Aufbau des KNNs führt Gleichung 2.14 zu Gleichung 2.18, wobei k die Schichtnummer des KNNs und \mathbf{w} die Gewichtungen, \mathbf{b} die Schwellenwerte und \mathbf{x} die Ausgangswerte der Schichten darstellen:

$$\mathbf{x}_k = s(\mathbf{w}_k \mathbf{x}_{k-1} + \mathbf{b}_k) \quad (2.18)$$

Das Ergebnis des gesamten KNNs kann durch Kombination der einzelnen Schichten ermittelt werden. Der Unterschied zwischen dem Ergebnis und dem Zielwert wird durch die Fehlerwertfunktion \mathcal{L} (engl. *loss function*) berechnet. Verbreitete Fehlerwertfunktionen basieren auf der Kreuzentropie und auf der mittleren quadratischen Abweichung (engl. Mean Squared Error (MSE)). Das Training des KNNs geschieht durch die Rückführung (engl. *backpropagation*) des Fehlers. Die Modellparameter θ werden unter Nutzung gradientenbasierter Optimierungsmethoden wie beispielsweise RMSProp, Adam oder AdamW [169, 183, 184] mit dem übergeordneten Ziel einer Minimierung der Fehlerwertfunktion \mathcal{L} für den Trainingsdatensatz D^{train} angepasst (θ^*):

$$\theta^* = \arg \min_{\theta} \mathcal{L}(D^{train}, \theta) \quad (2.19)$$

Die Netzwerkarchitektur wird abhängig vom Anwendungsfall gewählt. Mehrlagige Perzeptrone (engl. Multilayer Perceptron (MLP)) bestehen aus einer Abfolge mehrerer der zuvor genannten Neuronenschichten. Die Neuronen der einzelnen Schichten sind sequentiell miteinander verbunden. Faltende neuronale Netze (engl. Convolutional Neural Network (CNN)) reduzieren die

Anzahl der Modellparameter zur Darstellung der Gewichtungen, indem alle Neuronen einer Lage gemeinsame Gewichtungsfaktoren teilen [185]. Abgesehen von der ersten Schicht stammen die Eingangsgrößen jedes Neurons von Neuronen eines kleinen benachbarten Bereichs der vorherigen Schicht ab [186]. Üblicherweise folgt im Anschluss an die Aktivierungsfunktion eine Zusammenführungsschicht (engl. *pooling*), in welcher Informationen eines Bereichs beispielsweise durch Mittelwert- oder Maximalwertbildung (*Max Pooling*) zusammengefasst werden [169]. CNNs können sowohl für Bilddaten als auch für Zeitreihendaten eingesetzt werden [187]. Sie zeigen beispielsweise bei der Bestimmung der menschlichen Pose mithilfe der Gelenkwinkel in der Bildebene oder zur Klassifikation von Defekten beim Schweißen gute Ergebnisse [62, 84, 188]. Um explizit zeitliche Aspekte in den Daten zu erfassen, können rekurrente neuronale Netze (engl. Recurrent Neural Network (RNN)) verwendet werden. Diese basieren auf Neuronen mit einem internen Speicher, der die zeitliche Entwicklung des Datenstroms abbildet und damit die Erkennung zeitlicher Zusammenhänge ermöglicht. Verbreitete RNNs sind Long Short-Term Memory (LSTM) [189] und Gated Recurrent Unit (GRU) [190]. Eine Weiterentwicklung von LSTMs wurde von Neil et al. vorgestellt [191]. Sie ergänzten das LSTM-Konzept um eine Möglichkeit, asynchrone Eingangsgrößen zu verarbeiten.

Autoencoder

Autoencoder sind KNNs, welche ihre Eingangsgrößen rekonstruieren. Da die Eingangsgrößen den Ausgangsgrößen entsprechen sollen und keine separaten Zielgrößen vorliegen, handelt es sich um ein unüberwachtes Lernverfahren, welches jedoch die Eigenschaften eines überwachten Lernverfahrens aufweist. Autoencoder werden in Bereichen wie Dimensionsreduktion und Merkmalsextraktion, Bildaufarbeitung und Anomaliedetektion eingesetzt. [192, 193, 194] Ein Autoencoder besteht aus drei Elementen:

- Der Encoder $f_e(\mathbf{x}, \theta_e)$ extrahiert mittels einer Dimensionsreduktion eine informationshaltige Repräsentation \mathbf{z} der Eingangsgröße \mathbf{x} :

$$\mathbf{z} = f_e(\mathbf{x}; \theta_e) \quad (2.20)$$

Bei der im Encoder vorgenommenen Datenkompression gehen wegen der begrenzten Dimensionalität im latenten Bereich des Autoencoders Informationen verloren.

- Der Code stellt den latenten Bereich des Autoencoders dar und beinhaltet die informationshaltige Repräsentation \mathbf{z}
- Der Decoder $f_d(\mathbf{z}; \theta_d)$ erstellt anhand der komprimierten Repräsentation \mathbf{z} eine Rekonstruktion $\hat{\mathbf{x}}$ der ursprünglichen Eingangsgröße:

$$\hat{\mathbf{x}} = f_d(\mathbf{z}; \theta_d) \quad (2.21)$$

Beim Training von En- und Decoder soll für einen Trainingsdatensatz $D^{train} \subseteq \mathcal{D}$ der Satz an Modellparametern θ_e und θ_d gefunden werden, mit welchem folgende Fehlerwertfunktion \mathcal{L} minimiert wird:

$$\theta^* = \arg \min_{\theta_e, \theta_d} \sum_{\mathbf{x} \in D^{train}} \mathcal{L}(\mathbf{x}, f_d(f_e(\mathbf{x}; \theta_e); \theta_d)) \quad (2.22)$$

Beim Training von Autoencodern muss ein Kompromiss zwischen Rekonstruktionsfähigkeit und Generalisierung der Repräsentation getroffen werden. Um die Generalisierungsfähigkeit zu erhöhen werden Regularisierungsmethoden eingeführt, mit welchen verhindert wird, dass eine Identitätsfunktion, welche die Eingangswerte des Trainings auf die Ausgangsgrößen abbildet,

erlernt wird. Im Falle von Autoencodern kann es sich bei den Regularisierungsmethoden um die Reduktion der Dimensionalität der Repräsentation im latenten Bereich, um die Einführung eines spärlichkeitsinduzierenden Terms in der Fehlerwertfunktion, um das Hinzufügen von Datenrauschen oder um das gezielte Ausschalten (engl. *dropout*) einzelner Neuronen während des Trainings handeln. [192, 195, 196] Zum Aufbau des Autoencoders können CNN- und RNN-Elemente genutzt werden [197, 198].

Metlernen und Lernen mit wenigen Daten

Das Training von KNN-Modellen erfordert in der Regel eine große Menge an Daten. Metlernmethoden umgehen dieses Problem, indem Informationen aus anderen Datensätzen genutzt werden, um den Lernvorgang für einen neuen Datensatz bzw. eine neue Aufgabe zu beschleunigen. Falls nur wenige Datenelemente im neuen Datensatz vorliegen, kann Metlernen als Modellvorbereitung für das Lernen mit wenigen Daten (engl. *Few-Shot Learning*) dienen. [199, 200]

Mittels Metlernen soll also ein Modell generiert werden, das sich bei neuen Aufgaben als anpassbar erweist. Dazu werden während des Modelltrainings Daten ähnlicher Aufgaben genutzt. Jede dieser ähnlichen Aufgaben weist einen Aufgabendatensatz D_i auf. Dieser ist Bestandteil eines Metatrainingdatensatzes \mathcal{D}^{train} , sodass $D_i \subseteq \mathcal{D}^{train}$ mit $\mathcal{D}^{train} \subseteq \mathcal{D}$ gilt. Jeder Aufgabendatensatz D_i stellt einen Aufgabentrainingdatensatz D_i^{train} , welcher Unterstützungsdatsatz genannt wird, und einen Aufgabentestdatensatz D_i^{test} bereit. [201] Der Metatestdatensatz $\mathcal{D}^{test} \subseteq \mathcal{D}$ wird zur Prüfung der Anpassungsfähigkeit des Modells genutzt. Beim Lernen mit wenigen Daten erfolgt mit diesem die Modellanpassung an den Anwendungsfall.

Nach Oladosu et al. werden Metlernmethoden in drei Gruppen eingeteilt [199].

Optimierungsbasierte Methoden: Optimierungsbasierte Methoden zielen darauf ab, die gradientenbasierte Anpassung der Modellparameter auf eine Art und Weise zu optimieren, dass eine schnelle Anpassung an einen neuen Datensatz erfolgen kann. Finn et al. stellten dafür den Ansatz des modellagnostischen Metlernens (engl. Model-Agnostic-Meta-Learning (MAML)) vor [202]. Wie in Abbildung 2.3 dargestellt, wird ein Modell f_θ mit den Parametern θ mithilfe der Aufgabendatensätze von \mathcal{D}^{train} generalisiert. Anstatt die Fehlerfunktion \mathcal{L} durch Finden

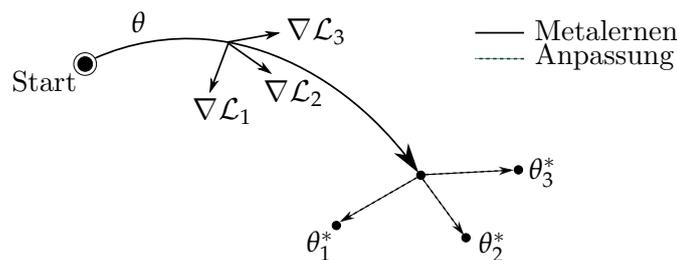


Abbildung 2.3: Visuelle Darstellung des MAML-Algorithmus von Finn et al. [202]

der optimalen Modellparameter für einen einzelnen Datensatz D_i zu reduzieren, werden die Parameter θ für eine Verteilung mehrerer Datensätze $p(\mathcal{D}^{train})$, wie in Gleichung 2.23 gezeigt, optimiert.

$$\theta^* = \arg \min_{\theta} \sum_{D_i \subseteq p(\mathcal{D}^{train})} \mathcal{L}(D_i, \theta) \quad (2.23)$$

Der MAML-Algorithmus erster Ordnung erfordert keine zweite Ableitung, sodass das Training eine geringere Komplexität aufweist. Er zeigte bei überwachtem Lernen vergleichbare Ergebnisse wie MAML [203]. Mittels MAML++ schlugen Antoniou et al. angepasste Versionen

von MAML vor, um Herausforderungen wie den Trainingsinstabilitäten und der zeitlichen Komplexität von MAML zu begegnen [204]. Reptile von Nichol et al. ist ein Metalernverfahren, welches ebenfalls modellagnostisch ist und auf MAML aufbaut. Im Gegensatz zu MAML weitet es die Parameteranpassung mittels Gradientenverfahren auf mehrere Aufgaben aus, um eine Generalisierung und hohe Anpassbarkeit zu erreichen [205].

Modellbasierte Methoden: Modellbasierte Methoden nutzen einen Modelltyp, der darauf ausgelegt ist, innerhalb weniger Schritte an neue Daten angepasst werden zu können. Dieser Vorgang kann entweder über eine entsprechende Modellarchitektur beispielsweise mit einem Speichermodul oder mithilfe eines angepassten Lernalgorithmus erfolgen. KNNs, welche um ein externes Speichermodul erweitert sind, nennen sich speichererweiterte neuronale Netze (engl. Memory-Augmented Neural Network (MANN)). RNNs gehören nicht zu den MANNs, da sie ohne Abänderungen lediglich über einen internen Speicher verfügen. Zur Generierung eines MANNs schlugen Santoro et al. die Nutzung einer neuronalen Turing-Maschine vor. Der Speicherzugriff wurde mithilfe der Kosinusähnlichkeit berechnet. Mithilfe des Speichermoduls konnten bei Trainingsaufgaben mit wenigen Datenelementen gute Ergebnisse für Klassifikations- und Regressionsaufgaben erreicht werden. [206] Munkhdalai et al. schlugen die Nutzung von zwei Netzwerken und einem Speichermodul vor. Ein Metalerner erfasste Metainformationen vom Modell, berechnete geeignete Parameterwerte und parametrisierte das Modell entsprechend. [207] Ein ähnlicher Ansatz wurde von Wu et al. unter Nutzung eines Autoencoders vorgestellt, dessen latenter Bereich die Parametrisierung eines Regressionsmodells repräsentierte [208]. Ravi et al. stellten einen LSTM-basierten Metalernalgorithmus vor, bei dem die Parameteroptimierung eines KNNs mithilfe eines LSTMs durchgeführt wurde. Das LSTM-Modell fungierte dabei als Metalerner, der das Modell innerhalb kurzer Zeit an einen neuen Datensatz anpasste. [201]

Repräsentations- und metriklernende Methoden: Repräsentations- und metriklernende Methoden extrahieren eine Funktion oder Metriken zur Repräsentation der Daten. Oladosu et al. schlugen einen repräsentationsbasierten Ansatz zur Ein-Klassen-Klassifizierung vor, bei dem eine Distanzmetrik angelernt und auf neue Aufgabendatensätze übertragen wurde [199]. Weitere Ausführungen metriklernender Metalernmethoden sind faltende, siamesische neuronale Netzwerke [209], prototypische Netzwerke [210], Verbindungsnetzwerke [211] und Matching Networks [212].

Anomaliedetektion in Zeitreihendaten

Anomalien sind wie folgt definiert:

Definition 8 *Anomalie:* *Eine Anomalie ist ein Datenpunkt oder ein Datenbereich, welcher durch ein ungewöhnliches Verhalten im Vergleich zum normalen Systemverhalten gekennzeichnet ist.*

Per Definition treten Anomalien selten auf. Nach Chandola et al. lassen sich Anomalien in Punktanomalien, kontextuelle Anomalien und kollektive Anomalien aufteilen. Eine Punktanomalie ist ein einzelner, abnormaler Datenpunkt. Kontextuelle Anomalien sind Datenbereiche, welche lediglich in einem speziellen Kontext abnormal sind. Dieser Kontext kann beispielsweise durch eine saisonale Entwicklung in der Zeitreihe oder durch Prozesszustände gegeben sein. Kollektive Anomalien sind Datenbereiche, welche lediglich durch einen Vergleich mit dem gesamten Datensatz als abnormal zu erkennen sind. [213, 214, 215]

Anomaliedetektion (engl. *anomaly detection/ outlier detection/ novelty detection* [216]) befasst sich mit der Erkennung von Anomalien. Sie findet in diversen - oftmals auch kritischen - Bereichen Anwendung, darunter beispielsweise im Gesundheitswesen zur Erkennung von Brustkrebs [217], in der industriellen Fertigung zur Prozess- und Systemüberwachung [194, 218], in Infrastrukturprojekten zur Überwachung der Strukturintegrität [219] oder im Finanzwesen zur Aufdeckung von Bankomatbetrug [220]. [221] Hodge und Austin unterscheiden zwischen drei Ansätzen zur Anomaliedetektion, die einer Einteilung in unüberwachte, semiüberwachte sowie überwachte Methoden folgen. Wenn kein vorheriges Wissen über den Datensatz vorliegt, werden unüberwachte Verfahren wie beispielsweise Clusteringmethoden genutzt. Bei vollständigem Wissen mit umfassender Annotation der Anomalien im Datensatz, können überwachte Methoden wie Klassifikation verwendet werden. Bei semiüberwachten Methoden ist lediglich bei einem Teil der Daten bekannt, ob Anomalien vorliegen oder nicht. Unter der Annahme, dass Anomalien selten auftreten, kann die normale Klasse oder in seltenen Fällen die abnormale Klasse modelliert werden. [221]

Die unüberwachte Anomaliedetektion ist aus verschiedenen Gründen herausfordernd und relevant für industrielle Anwendungen [222, 223]:

- **Heterogene Anomalieklassen:** Anomalien können verschiedene Ausprägungen mit unterschiedlichen statistischen Eigenschaften aufweisen, welche bei der Modellbildung nicht bekannt sind. [216, 223]
- **Datenungleichgewicht:** Anomalien sind im Vergleich zu Daten des normalen Verhaltens selten [223]. Gründe für die geringe Anzahl an abnormalen Daten sind in den hohen Kosten für die Annotation der Anomalien und für die Erzeugung solcher Anomalien bei industriellen Maschinen zu finden. Damit liegt bei industriellen Anwendungsfällen ein intrinsisches Ungleichgewicht im Datensatz vor [216, 224].
- **Keine Referenzsignale:** Daten aus der realen Applikation, welche für die Modellierung eines Anomaliedetektors genutzt werden, können bereits Anomalien aufweisen. [222]
- **Zuordnung:** Anomalien müssen nicht in Defekten resultieren, sodass die Bewertung detektierter Anomalien von Expertenwissen abhängt. [222]

Für gewöhnlich steht einer großen Menge an Daten der normalen Kondition eine geringe Menge an Daten der abnormalen Kondition entgegen. Unter Annahme der Seltenheit von Anomalien nach Definition 8 lässt sich die unüberwachte Anomaliedetektion als ein semiüberwachtes Problem definieren. Das normale Verhalten wird modelliert um Abweichungen von diesem als Anomalien einzuordnen. Die Anomaliedetektion lässt sich damit auch als eine Ein-Klassen-Klassifizierung interpretieren, bei der eine normale Klasse von abnormalen Klassen unterschieden werden soll [225]. Algorithmen für die un-/semiüberwachte Anomaliedetektion lassen sich in verschiedene Kategorien einteilen. Pimentel et al. unterscheiden fünf Kategorien (wahrscheinlichkeitsbasiert, distanzbasiert, rekonstruktionsbasiert, bereichsbasiert, informationstheoretisch) [216], Geiger et al. drei Kategorien (wahrscheinlichkeitsbasiert, vorhersagebasiert, rekonstruktionsbasiert) [222], Chandola et al. sechs Kategorien (Klassifikation, Nächste-Nachbarn, Clustering, statistisch, informationstheoretisch, spektral) [214] und Hodge et al. vier Kategorien (statistisch, Nächste-Nachbarn, maschinelles Lernen, hybrid) [221]. Nachfolgend wird ähnlich zu Geiger et al. eine Unterteilung in distanz- und wahrscheinlichkeitsbasierte, vorhersagebasierte und rekonstruktionsbasierte Algorithmen vorgenommen.

Distanz- und wahrscheinlichkeitsbasierte Methoden: Distanz- und wahrscheinlichkeitsbasierte Methoden nutzen eine definierte Metrik zur Berechnung der Distanz oder Ähnlichkeit

zwischen zwei Objekten. Objekte können Punkte oder Segmente einer Zeitreihe sein. Der *k-Means*-Algorithmus teilt eine Menge an Punkten in $k_{k-Means}$ Cluster ein. Die Einteilung zielt darauf ab, die Summe der Distanzen zwischen den Punkten und den Clustermittelpunkten zu reduzieren. Die Punkte mit den höchsten Distanzen zum nächsten Clustermittelpunkt sind Anwärter für Anomalien. [226] Unter Einbeziehung mehrerer Objekte kann die Distanzberechnung unter Nutzung einer Dichteberechnung erfolgen. Local Outlier Factor (LOF) ist eine Methode, welche mithilfe der lokalen Dichte auf die Wahrscheinlichkeit für eine Anomalie schließt [227]. Ein weiteres Beispiel für Clusteranalysen ist *DBSCAN*. Unter Nutzung eines definierten Radius wird untersucht, wie viele Punkte sich in der Umgebung jedes Punktes befinden. Wenn ein Grenzwert unterschritten wird und sich der Punkt nicht am Rande eines Clusters befindet, ist der betreffende Punkt ein Anwärter für eine Anomalie. [228, 229] Wahrscheinlichkeitsbasierte Methoden zur Detektion von Anomalien sind beispielsweise gaußsche Mischverteilungsmodelle, verborgene Markowmodelle, Kalmanfilter, Kastendiagramme oder Histogramme [216, 230]. *Isolation Forest* ist ein Algorithmus, der mittels Entscheidungsbäumen zwischen den normalen und den abnormalen Daten unterscheidet. Anomalien werden isoliert und detektiert, indem die Pfadlänge des Knotenpunktes, in dem das zu untersuchende Objekt liegt, mit der durchschnittlichen Pfadlänge von Objekten des Datensatzes verglichen wird. Ein kurzer Pfad ist ein Hinweis auf eine Anomalie. [231, 232] *OC-SVMs* sind SVMs zur Ein-Klassen-Klassifizierung, mit denen Anomalien basierend auf einer Abgrenzung zur Repräsentation der normalen Daten im mehrdimensionalen Raum detektiert werden. [226, 233]

Prädiktionsbasierte Methoden: Prädiktionsbasierte Methoden erlernen ein Modell, mit dessen Hilfe zukünftige Werte vorhergesagt werden. Der Anomaliewert entspricht der Distanz zwischen dem realen und dem vorhergesagten Wert x_t . Autoregressive Modelle (engl. Auto-Regressive (AR)) berechnen, wie in Gleichung 2.24 dargestellt, den Vorhersagewert t_{n+1} als Linearkombination der letzten p_{AR} , mittels θ_i ($i \in [0, p_{AR} - 1]$) gewichteten Werte zuzüglich einer Konstanten c_{AR} sowie des Fehlerwerts ϵ_n .

$$t_{n+1} = c_{AR} + \sum_{i=0}^{p_{AR}} \theta_i \cdot t_{n-i} + \epsilon_n \quad (2.24)$$

Der gleitende Durchschnitt (engl. Moving Average (MA)) bestimmt den Wert t_{n+1} , wie in Gleichung 2.25 gezeigt, aus dem Durchschnittswert \bar{x} zuzüglich einer Linearkombination der q_{MA} vergangenen Fehlerwerte ϵ_{n-i} mit $i \in [0, q_{MA} - 1]$ sowie des Fehlerwerts ϵ_{n+1} . Die Modellparameter sind θ_i mit $i \in [0, q_{MA} - 1]$.

$$t_{n+1} = \bar{x} + \sum_{i=0}^{q_{MA}} \theta_i \cdot \epsilon_{n-i} + \epsilon_{n+1} \quad (2.25)$$

Der autoregressive gleitende Durchschnitt (engl. Auto-Regressive Moving Average (ARMA)) ist eine Kombination aus AR und MA. Der autoregressive integrierende gleitende Durchschnitt (engl. Auto-Regressive Integrated Moving Average (ARIMA)) nutzt ein ARMA-Modell mit d_{ARIMA} -facher Differenzbildung. Dadurch kann einem Trend in den Daten entgegengewirkt werden. Das SARIMA-Modell (engl. Seasonal Auto-Regressive Integrated Moving Average) verfügt zusätzlich zu den Elementen des ARIMA-Modells über einen Parameter zur Berücksichtigung von Saisonalität in den Daten. [162] Simple Exponential Smoothing (SES), Exponential Smoothing (ES) und die Holt-Winters-Methode basieren auf der exponentiellen Glättung der vergangenen Zeitreihe zur Vorhersage der zukünftigen Werte [226, 234].

Darüber hinaus können Verfahren des maschinellen Lernens zur Vorhersage genutzt werden. Bei der Anomaliedetektion mittels hierarchischer Temporalspeicher (engl. Hierarchical Temporal Memory (HTM)) wird das Signal mithilfe eines Encoders komprimiert und mit

einer sequenziellen Speicherkomponente modelliert um eine Vorhersage zu treffen [235, 236]. Vorhersagen für Zeitreihen können zudem unter Nutzung von LSTMs [237, 238] oder mit CNNs [239] erfolgen.

Rekonstruktionsbasierte Methoden: Rekonstruktionsbasierte Methoden komprimieren die Information und rekonstruieren die latente Repräsentation unter der Annahme, dass abnormale Datenpunkte im Gegensatz zu normalen Datenpunkten nicht exakt rekonstruiert werden. Ein höherer Rekonstruktionsfehler ist damit ein Indikator für eine Anomalie. Rekonstruktionsbasierte Methoden werden häufig für sicherheitskritische Bereiche eingesetzt [216]. Die Hauptkomponentenanalyse ermöglicht eine lineare Kompression der Daten. Zur Abbildung nichtlinearer Zusammenhänge in sequentiellen Daten sind Autoencoder (AE) mit nichtlinearen Aktivierungsfunktionen geeignet [215]. Exemplarische Umsetzungen von Autoencoder zur Anomaliedetektion in Zeitserien finden sich bei Ahmad et al. in Kombination mit LSTMs [197] und bei Thill et al. in Kombination mit CNNs [240]. Ohne ausreichende Regularisierung generalisieren Autoencoder auch bei der Rekonstruktion von Anomalien, sodass die Leistungsfähigkeit der Anomaliedetektion abnimmt [196, 222]. Zur Vermeidung können die in Abschnitt 2.3.2 vorgestellten Regularisierungsmethoden eingesetzt werden [196]. Eine weitere Methode zur Verhinderung der Abnahme des Anomaliedetektionsvermögens wurde von Gong et al. mit dem speichererweiterten Autoencoder (engl. Memory-Augmented Autoencoder (MemAE)) vorgestellt [241]. Diese Autoencoderarchitektur beinhaltet, wie in Abbildung 2.4 gezeigt, ein externes Speichermodul M im latenten Bereich. Die Auswahl geeigneter Speichereinträge geschieht auf Basis der Kosinusdistanz zwischen der Repräsentation $\mathbf{z} = f_e(\mathbf{x})$ und den Speichereinträgen m_i . Mithilfe eines Spärlichkeitsgrenzwerts wird die Anzahl der ausgewählten Speichereinträge beschränkt ($\mathbf{w} \rightarrow \hat{\mathbf{w}}$). Die Rekonstruktion des Eingangsvektors erfolgt auf Basis einer Linearkombination $\hat{\mathbf{z}}$ der ausgewählten, gewichteten Speichereinträge. Weiterhin

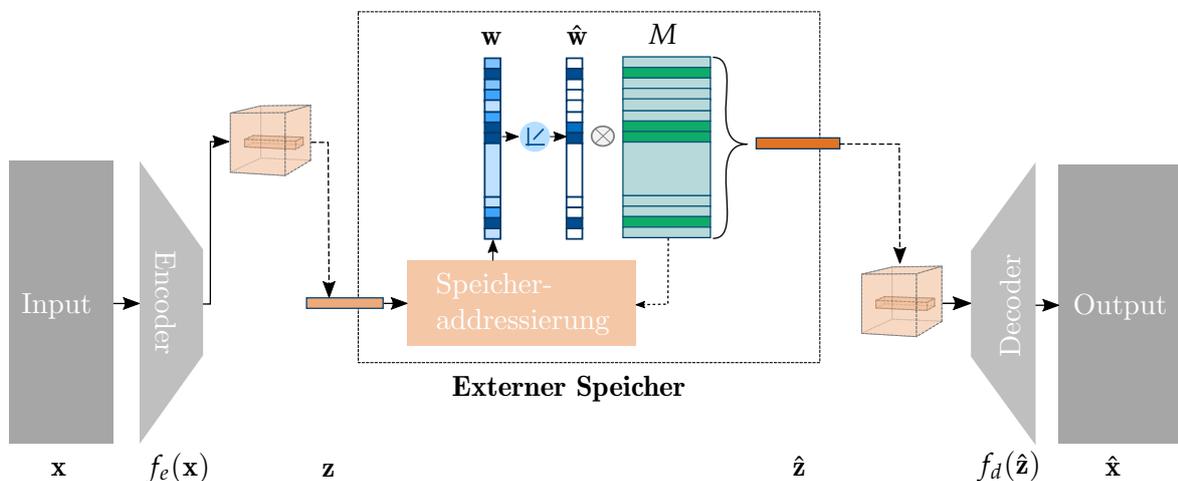


Abbildung 2.4: Schematische Darstellung des speichererweiterten Autoencoders (MemAE) nach Gong et al. [241]

wird der Rekonstruktionsfehler für Anomalien zusätzlich erhöht, indem ein Spärlichkeitsterm in der Fehlerwertfunktion den Einsatz weniger Speichereinträge für die Rekonstruktion fördert. Eine weitere Ausprägung rekonstruktionsbasierter Anomaliedetektion ist unter Nutzung von GANs (engl. Generative Adversarial Networks) zu sehen. GANs sind KNNs, welche unter anderem zur Generierung künstlicher Daten genutzt werden. Geiger et al. stellten mit *td-GAN* ein Modell vor, mit welchem das normale Verhalten von Zeitreihen reproduziert und Anomalien detektiert werden konnten [222].

Tabelle 2.2: Wahrheitsmatrix zur Zuordnung von realen und vorhergesagten Klassen

		Vorhergesagt		Gesamt
		Positiv	Negativ	
Real	Positiv	TP	FN	$TP + FN$
	Negativ	FP	TN	$FP + TN$
Gesamt		$TP + FP$	$FN + TN$	

2.3.3 Evaluierungsmetriken

Zur Bewertung der Datenanalysemethoden werden Evaluierungsmetriken verwendet. Die in dieser Arbeit genutzten Klassifizierungs- und Regressionsmetriken werden im Folgenden vorgestellt.

Klassifizierungsmetriken: Allgemein können Evaluierungsmetriken für die Anomaliedetektion und Klassifizierung in Grenzwertmetriken, rankbasierte Metriken und wahrscheinlichkeitsbasierte Metriken unterteilt werden [242]. Die in dieser Arbeit genutzten Metriken stützen sich auf eine Klasseneinteilung abhängig von der realen und der vorhergesagten Klasse. Eine daraus resultierende Wahrheitsmatrix ist in Tabelle 2.2 dargestellt, und zeigt eine Aufteilung der Daten in richtig-positive (TP), falsch-positive (FP), richtig-negative (TN) und falsch-negative (FN) Vorhersagen. Die Verhältnisse von TP, FP, TN und FN geben Auskunft über die Leistungsfähigkeit des Klassifikationsalgorithmus. Die Treffergenauigkeit ACC gibt den Anteil der korrekt klassifizierten Daten am gesamten Datensatz wieder (Gleichung 2.26). Die Sensitivität (Richtig-Positiv-Rate (TPR) oder engl. *recall*) gibt den Anteil von korrekt klassifizierten positiven Datenpunkten an allen tatsächlich positiven Datenpunkten wieder (Gleichung 2.27), wohingegen die Spezifität (Richtig-Negativ-Rate (TNR) oder engl. *specificity*) ein solches Verhältnis für alle TN Vorhersagen zu allen negativen Datenpunkten darstellt (Gleichung 2.28). Die Falsch-Positiv-Rate (FPR) gibt den Anteil an falsch klassifizierten negativen Datenpunkten an (Gleichung 2.29). Die Genauigkeit $PREC$ (engl. *precision*) gibt das Verhältnis von TP Vorhersagen zur Gesamtzahl der positiven Vorhersagen wieder (Gleichung 2.30).

$$\text{Treffergenauigkeit} \quad ACC = \frac{TP + TN}{TP + FP + FN + TN} \quad (2.26)$$

$$\text{Sensitivität} \quad TPR = \frac{TP}{TP + FN} \quad (2.27)$$

$$\text{Spezifität} \quad TNR = \frac{TN}{FP + TN} \quad (2.28)$$

$$\text{Falsch-Positiv-Rate} \quad FPR = \frac{FP}{FP + TN} \quad (2.29)$$

$$\text{Genauigkeit} \quad PREC = \frac{TP}{TP + FP} \quad (2.30)$$

Die Werte für Treffergenauigkeit, Sensitivität, Spezifität, Falsch-Positiv-Rate und Genauigkeit liegen im Intervall $[0, 1]$. Bei ausgewogenen Datensätzen, in denen beide Klassen eine ähnliche Häufigkeit aufweisen, ist die Treffergenauigkeit ein geeignetes Maß zur Modellbewertung. Bei unausgewogenen Datensätzen, wie sie in der Anomaliedetektion für gewöhnlich vorkommen, ist die Treffergenauigkeit für die Bewertung des Modells nicht ausreichend, da der Einfluss von falsch klassifizierten, seltenen positiven Daten auf die Treffergenauigkeit im Vergleich zum gesamten Datensatz marginal ist.

Um einen einzelnen, aussagekräftigen Wert in Form einer kombinierten Metrik zu erhalten, werden die Verhältnisse in Relation zueinander dargestellt. Der F_1 -Wert ist der harmonische Mittelwert zwischen Genauigkeit und Sensitivität mit $\beta_F = 1$. Er liegt im Intervall $[0, 1]$. Ein größeres β_F erhöht die Gewichtung der Sensitivität und somit der richtig klassifizierten positiven Daten.

$$F_{\beta_F} = (1 + \beta_F^2) * \frac{PREC \cdot TPR}{\beta_F^2 \cdot PREC + TPR} \quad (2.31)$$

Darüber hinaus können Kurven der relativen Entwicklung der einzelnen Verhältnisse bei Änderung des Detektorgrenzwerts erstellt werden. Die Isosensitivitätskurve (engl. Receiver Operating Characteristic (ROC)) gibt abhängig vom Grenzwert die TPR gegen die FPR an und ist monoton steigend. Sie ist für einen ausgewogenen Datensatz geeignet. Eine Gerade vom Ursprung nach $(1, 1)$ gibt den Verlauf für einen Detektor ohne Detektionsfähigkeit wieder. Die Fläche unter der ROC-Kurve (ROC-Area Under Curve (AUC)) gilt als skalare Metrik für die Leistungsfähigkeit des Detektors unabhängig vom Grenzwert. Ein ROC-AUC-Wert von 1 liegt im Falle eines perfekten Detektors vor.

Die Genauigkeits-Sensitivitäts-Kurve (PR-Kurve) gibt abhängig von einem Grenzwert, wie in Abbildung 2.5 blau dargestellt, den Verlauf von Genauigkeit zu Sensitivität wieder und ist für unausgewogene Datensätze geeignet, da der Fokus auf der positiven Klasse liegt. Der Verlauf für einen Zufallsdetektor entspricht einer horizontalen Linie (in grün), bei der die Genauigkeit proportional zur Anzahl an positiven Fällen ist. Die Fläche unter der PR-Kurve (engl. Area Under the Precision Recall Curve (PR AUC)) gilt als skalare Metrik für die Leistungsfähigkeit des Detektors unabhängig vom Grenzwert bei einem unausgewogenen Datensatz. Ein optimaler Detektor weist einen PR AUC-Wert von 1 auf.

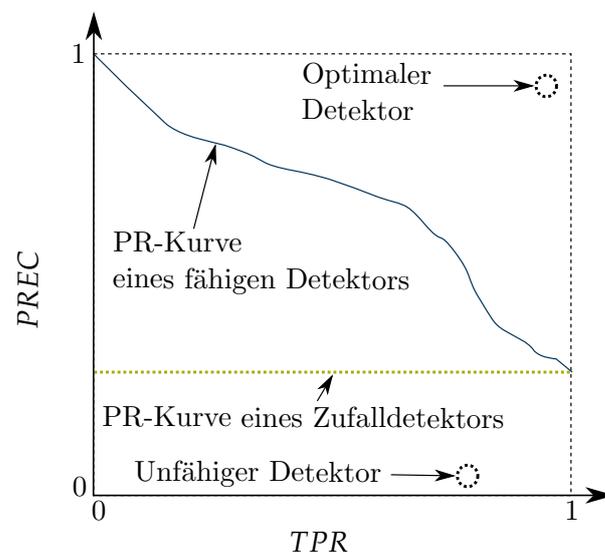


Abbildung 2.5: PR-Kurve für einen fähigen Detektor (blau) und einen Zufalldetektor (grün) nach Brownlee [242]

Regressionsmetriken: Zur Überprüfung der Leistungsfähigkeit von Regressionsmodellen werden die Elemente $x^{(k)}$ des Vektors \mathbf{x} mit den rekonstruierten oder vorhergesagten Werten $\hat{x}^{(k)}$ verglichen. Als Regressionsmetriken werden der mittlere absolute Fehler (engl. Mean Absolute Error (MAE); Gleichung 2.32), die mittlere quadratische Abweichung (engl. MSE; Gleichung 2.33) sowie die Wurzel der mittleren Fehlerquadratsumme (engl. Root Mean Squared

Error (RMSE); Gleichung 2.34) verwendet.

$$MAE = \frac{1}{n} \sum_{k=1}^n |x^{(k)} - \hat{x}^{(k)}| \quad (2.32)$$

$$MSE = \frac{1}{n} \sum_{k=1}^n (x^{(k)} - \hat{x}^{(k)})^2 \quad (2.33)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (x^{(k)} - \hat{x}^{(k)})^2} \quad (2.34)$$

MAE ist bei Ausreißern deutlich robuster als MSE und RMSE. Regressionsmetriken werden unter anderem zur Auswertung des Rekonstruktionsfehlers bei Autoencodern genutzt.

2.4 Ableitung des Forschungsbedarfs

Wie in Abschnitt 2.1 gezeigt, müssen für eine Industrialisierung und umfassende Marktdurchdringung von WAAM eine Vielzahl prozessbezogener Herausforderungen gelöst werden. Nachfolgend wird aus diesen Herausforderungen der Forschungsbedarf abgeleitet, eine zentrale Forschungsfrage formuliert und eine Abgrenzung zu bestehenden Lösungen vorgenommen. Der Abschnitt schließt mit einem Überblick über die anschließenden Kapitel ab.

2.4.1 Forschungsbedarf

Prozessbezogene Herausforderungen finden sich entlang der gesamten WAAM-Prozesskette aus Abbildung 1.2. Der abgeleitete Forschungsbedarf wird anhand einer Nummerierung in sieben Bereiche (B1 bis B7) eingeteilt.

In der Prozessplanung werden die Prozessparameter festgelegt. Deren Wahl basiert auf Expertenwissen sowie auf umfangreichen Testläufen. Optimale Prozessparameter können trotz Prozessmodellierung und -simulation nicht ohne iterative Tests an der Fertigungsanlage gefunden werden [21, 57]. Diese Optimierungsstrategie ist kosten- und zeitintensiv und ihr Einsatz ist kein Garant dafür, dass die gewünschten Bauteileigenschaften erreicht werden [149]. Optimierte Prozessparameter gelten für ein spezifisches Bauteil und sind nur bedingt auf andere Bauteile übertragbar [154]. Besonders die Schichthöhe ist auf Grund des komplexen Temperaturverhaltens schwer vorherzusagen [21]. Deshalb werden Regelungen eingesetzt, welche eine Messung der Schichthöhe oder des Abstands zwischen Schweißbrenner und Bauteil erfordern. Die Messung dieser Größen findet entgegen der Anforderungen an einen voll 3D-fähigen Prozess für CMT-basierte WAAM-Prozesse im Stand der Technik schichtgebunden statt, sodass die Untersuchung einer richtungs- und schichtinvarianten Abstandsmessung als Forschungsbedarf abgeleitet werden kann (B1). Die zugehörigen Regelungen sind dadurch ebenfalls schichtgebunden, sodass sie für komplexe Bauteile mit Mehrachsoperationen nur in Grenzen einsatzfähig sind [21, 108]. Es ist damit erforderlich, eine Regelung zu entwerfen, mit der omnidirektional und schichtinvariant einem variablen Abstand begegnet werden kann (B2). Der dreidimensionale Aufbau erfordert zudem neue Methoden für den Prozesseingriff, die auf einer autonomen Entscheidung über den weiteren Verlauf der Fertigung beruhen [72, 243]. Ein Konzept, wie ein solcher Prozesseingriff für einen voll 3D-fähigen Prozess aussehen kann, sollte erbracht und evaluiert werden (B3).

Selbst bei optimalen Prozessparametern treten aufgrund der Komplexität der physikalischen

Transformationen Prozessinstabilitäten auf, die zu einer fehlenden Wiederholbarkeit bei der metallbasierten additiven Fertigung führen [244]. Defekte, welche beispielsweise auf abweichende Rohmaterialeigenschaften oder instabile Umgebungsbedingungen zurückgehen, können kaum verhindert werden [39]. Um prozessparallel auf die Qualität des Bauteils schließen zu können, müssen diese Instabilitäten und Defekte datengetrieben erkannt werden [20]. Die Verfahren zur Defekterkennung müssen jedoch mit einer Vielfalt an Prozessparametern sowie an Prozesskonditionen im WAAM-Prozess zurechtkommen [59, 72, 154]. Eine Anpassbarkeit der Modelle an neue Prozessdaten muss deshalb explizit berücksichtigt werden (B4). Eine Voraussetzung für die Entwicklung solcher Algorithmen ist eine Methode, mit der Prozessdaten auch für komplexe Bauteile mit Qualitätsdaten korreliert werden können (B5).

In der Fertigung mittels AM kann ein Defekt zudem Auswirkungen auf die benachbarten Bauteilbereiche haben [39, 59, 72]. Der Informationsgehalt der lokalen Prozessumgebung im voll 3D-fähigen WAAM-Prozess für die Defekterkennung wurde bisher jedoch nicht betrachtet, sodass hier Forschungsbedarf besteht (B6). Ein AM-gerechtes Datenmanagement zur Bereitstellung solcher Informationen sowie zur Gewährleistung von Rückverfolgbarkeit ist zu untersuchen (B7).

In Tabelle 2.3 sind die Elemente des Forschungsbedarfs zusammengefasst festgehalten.

Tabelle 2.3: Elemente des aus den prozessbezogenen Herausforderungen abgeleiteten Forschungsbedarfs (B1-B7) für WAAM

ID	Forschungsbedarf
B1	Methodik zur richtungs- und schichtinvarianten Abstandsmessung
B2	Verfahren zur omnidirektionalen, schichtinvarianten Abstandsregelung
B3	Verfahren zur kontextabhängigen Prozessanpassung
B4	Methodik zur Modellanpassung mit wenigen Daten
B5	Verfahren zur Zuordnung der Qualitätsdaten zu den Prozessdaten
B6	Methodik zur kontextsensitiven Defekterkennung
B7	Konzept für ein voll 3D-fähiges Datenmanagement

Die Herausforderungen und der abgeleitete Forschungsbedarf zeigen, dass die weitere Forschung im Bereich der additiven Fertigung mittels Lichtbogenauftragschweißen einen ganzheitlichen Ansatz verfolgen muss, um die Wechselwirkungen zwischen Prozessparametern, Prozessdaten und Qualitätseigenschaften der hergestellten Teile besser zu verstehen und zu nutzen. Datengetriebene Ansätze unter Nutzung Digitaler Zwillinge (Definition 4) scheinen für diesen Zweck prädestiniert zu sein, da mittels Kontextwahrnehmung (Abschnitt 2.2.2), Autonomie (Abschnitt 2.2.2) und Anpassungsfähigkeit (Abschnitt 2.2.2) den zuvor beschriebenen Herausforderungen begegnet werden kann. Innerhalb dieser Arbeit wird dieser These nachgegangen und dafür folgende zentrale Forschungsfrage gestellt:

Wie können Kontextwahrnehmung, Autonomie und Anpassungsfähigkeit eines prozessorientierten Digitalen Zwillings für die additive Fertigung mittels Lichtbogenauftragschweißen erreicht werden?

2.4.2 Abgrenzung, Zielsetzung und Vorgehensweise

Die sieben abgeleiteten Elemente des Forschungsbedarfs lassen sich aus Perspektive des WAAM-Prozesses in die drei Bereiche Prozessüberwachung, Prozesseingriff und Datenmanagement einteilen. Diese Einteilung spiegelt sich im Aufbau dieser Arbeit wieder.

Abgrenzung

Wie in Abschnitt 2.1 sowie Abschnitt 2.2 beschrieben, werden die drei Bereiche bereits intensiv untersucht. Um eine Abgrenzung zum Stand der Technik vorzunehmen, wird dieser hinsichtlich des definierten Forschungsbedarfs in Tabelle 2.4 anhand ausgewählter Veröffentlichungen bewertet.

Tabelle 2.4: Bewertung ausgewählter Veröffentlichungen hinsichtlich des definierten Forschungsbedarfs aus Tabelle 2.3 sowie Abschnitt dieser Arbeit, in welchem der Forschungsbedarf bearbeitet wird

Forschungsbedarf	[72]	[93]	[108]	[110]	[154]	[65]	Abschnitt
B1	○	○	◐	◐	○	○	4.4
B2	○	○	◐	◐	○	◐	5.1
B3	○	○	◑	◑	○	◑	5.1, 5.2
B4	○	○	○	○	○	○	4.2, 4.3
B5	○	○	○	○	◐	○	3.3
B6	◐	◑	○	○	◑	○	3.1, 3.2, 4.2, 4.3
B7	○	○	◐	◐	◐	◐	3.1, 3.2

Im Bereich der Prozessüberwachung wurden von Xu et al. [72] und Zhao et al. [93] Entwicklungen aus dem Schweißbereich adaptiert und schichtgebundene, richtungsabhängige Methoden zur Defekterkennung vorgestellt. Der dreidimensionale Charakter des WAAM-Prozesses, der sich durch den Einfluss der vorhergehenden Schweißbahnen bemerkbar macht, wurde vernachlässigt. Es wurde keine kontextspezifische Interpretation der Messdaten umgesetzt.

Li et al. [108] und Xiong et al. [110] zeigten kontextintegrierende Abstandsmessungen und -regelungen, die jedoch schicht- und richtungsabhängig sind. Die Konzepte wurden lediglich für gerade, parallele Werkzeugpfade umgesetzt und sind für WAAM-typische, komplexe Werkzeugwege ungeeignet.

Gaikwad et al. zeigten einen Digitalen Schatten ohne bidirektionale Datenanbindung für den LMD-Prozess auf Basis einer Temperatursimulation, mit dem die Erkennung von temperaturbedingten Defekten möglich wurde [154]. Stavropoulos et al. ermöglichten die bidirektionale Anbindung für einen schichtenbasierten L-PBF-Prozess, bei dem der Energieeintrag reguliert wurde [65]. Ein Digitaler Zwilling mit bidirektionaler Datenanbindung für einen metallbasierten, multiaxialen Prozess wurde nicht betrachtet.

Prozessorientierte Digitale Zwillinge sind bisher kaum untersucht. Dabei handelt es sich um eine Forschungslücke, welche nach Gunasegaram et al. im nächsten Jahrzehnt gefüllt werden muss, um AM in der Industrie attraktiver zu gestalten. [151] Ein Digitaler Zwilling für den WAAM-Prozess, der als digitales Abbild des Bauteils und des Prozesses aufgrund der bidirektionalen Datenverbindung einen kontextspezifischen Eingriff in den Prozess sowie eine prozessparallele Qualitätssicherung ermöglicht, wurde in keiner dem Autor bekannten Veröffentlichung untersucht.

Zielsetzung und Vorgehensweise

Ziel der vorliegenden Arbeit ist die Untersuchung von Methoden und Verfahren, mit denen ein Digitaler Zwilling für den WAAM-Prozess aufgebaut werden kann. Der Digitale Zwilling soll einen kontextspezifischen Eingriff sowie eine prozessparallele Qualitätsüberwachung ermöglichen und dafür autonom, anpassbar und kontextwahrnehmend sein.

Die Elemente des Forschungsbedarfs (B1-B7) bilden die Anforderungen zur Erfüllung der Zielsetzung dieser Arbeit. Um den in dieser Arbeit entwickelten Digitalen Zwilling darüber hinaus als industriegerechte Lösung zu positionieren, sind weitere Anforderungen zu berücksichtigen. Der Digitale Zwilling muss flexibel einsetzbar sein, so dass mit geringem Zusatzaufwand Anpassungen und Erweiterungen vorgenommen werden können. Er muss auf andere Maschinen zu übertragen und kompatibel mit Industriehardware sein. Darüber hinaus müssen Softwareschnittstellen eingerichtet werden, über die andere Systeme mit dem Digitalen Zwilling interagieren können. Als Gesamtes soll der Digitale Zwilling den Anforderungen des Normentwurfs ISO 23247 entsprechen.

Die zur Beantwortung der Forschungsfrage sowie die zur Erreichung der Zielsetzung erforderlichen Methoden und Vorgehensweisen werden innerhalb dieser Arbeit drei Modulen zugeordnet. Dabei handelt es sich um das Modul für die Bauteil- und Prozessrepräsentation, das Modul zur Prozessüberwachung und das Modul für den datengestützten Prozesseingriff. In Kapitel 3 liegt der Fokus auf dem Modul Bauteil- und Prozessrepräsentation. Es werden Methoden zum Datenmanagement vorgestellt, um Kontextwahrnehmung im Prozess zu ermöglichen, und auf eine Vorgehensweise eingegangen, mit der die Annotation von Zeitreihendaten auf Basis von Qualitätsdaten erreicht werden kann. Kapitel 4 befasst sich mit der Auswertung der WAAM-Prozessdaten mithilfe von adaptiven Algorithmen zur Anomaliedetektion und Defektklassifikation. Darüber hinaus werden Methoden zur schicht- und richtungsunabhängigen Abstandsmessung im WAAM-Prozess vorgestellt. Kapitel 5 betrachtet datengestützte, autonome Prozesseingriffe. Es wird eine omnidirektionale, schichtinvariante Abstandsregelung sowie eine präskriptive Prozessparameteranpassung zur prozessparallelen Selbstreparatur vorgestellt, sodass ein fehlertoleranter Prozess erreicht wird.

Anschließend werden die vorgestellten Methoden im Rahmen des Digitalen Zwillings validiert (Kapitel 6). Dazu wird dieser als Teil eines intelligenten Fertigungssystems prototypisch konzipiert, implementiert und in der industriellen Praxis validiert. Auf Basis der Validierungsergebnisse wird eine kritische Diskussion der Zielerreichung vorgenommen. Zuletzt wird auf den Gültigkeitsbereich der Arbeit beziehungsweise auf die Übertragbarkeit der Methoden eingegangen (Kapitel 7).

Kapitel 3

Digitale Bauteil- und Prozessrepräsentation

3.1	Systemkontext	38
3.1.1	OPC UA Informationsmodell	38
3.1.2	Prozesszustandsbeschreibung	39
3.2	Räumlicher und zeitlicher Kontext	40
3.2.1	Räumliche und zeitliche Indexierung	40
3.2.2	Initialisierung	43
3.2.3	Kontextbereitstellung	43
3.3	Räumliche Annotation von Zeitreihen	47
3.4	Evaluierung	48
3.4.1	Latenzen im Aufbau des Octrees	48
3.4.2	Evaluierung der kontextintegrierenden Qualitätsmetriken	49
3.4.3	Evaluierung der räumlichen Zeitreihenannotation	50
3.5	Zusammenfassung	51

Die digitale Bauteil- und Prozessrepräsentation des Digitalen Zwillings in der Additiven Fertigung mittels Lichtbogenauftragschweißen stellt situationsabhängig Kontext für die Prozessüberwachung und den datengestützten Prozesseingriff bereit. Der Kontext dient der Charakterisierung des Fertigungsprozesses in Interaktion mit dessen Umgebung. Innerhalb dieser Arbeit werden dazu folgende drei Kontextkategorien definiert:

1. Der **Systemkontext** beschreibt den Prozess- sowie den Systemzustand. Die Angaben umfassen persistente Informationen über das System wie beispielsweise die Identifikationsnummer und den Standort der Fertigungsanlage, deren Aufbau (Kinematik, Prozesstechnik, Prozessüberwachungssystem) sowie Informationen über den Prozessablauf.
2. Der **räumliche Kontext** beschreibt die durch einen räumlich relevanten Bereich (engl. Region of Interest (ROI)) definierte Umgebung eines Punktes \mathbf{x}_0 , welche die diskreten Datenpunkte \mathbf{x}_i an den Positionen x_i , y_i und z_i inklusive der zugehörigen Prozessdaten beinhaltet. Die Geometrie und Größe des ROIs ist abhängig vom Verwendungszweck des angeforderten Kontexts.
3. Der **zeitliche Kontext** beschreibt die zeitliche Umgebung eines Punktes. Die Prozessdaten werden mithilfe eines Zeitstempels in einen zeitlichen Bezug zueinander gesetzt, sodass beispielsweise eine Abschätzung der Oberflächentemperatur auf Basis der Abkühlzeit oder eine zeitliche Einordnung eines Messwerts im Spannungsverlauf stattfinden kann.

Die während der Fertigung entstehende Bauteilrepräsentation ist als Informationsträger entlang des Produktlebenszyklus nutzbar. Sie dient als Ausgangsbasis für Untersuchungen in der Qualitätssicherung, ermöglicht Rückverfolgbarkeit und kann zur Optimierung in der Produktentwicklung und Fertigungsplanung genutzt werden. Durch eine situationsabhängige Bereitstellung des Kontexts kann eine kontextsensitive Prozessüberwachung (Kapitel 4) und ein datengestützter Prozesseingriff (Kapitel 5) realisiert werden.

Auf Basis dieser Überlegungen, der Anforderungen an den Digitalen Zwilling sowie des Forschungsbedarfs (B3, B5, B6 und B7) ergeben sich folgende Anforderungen an die digitale Bauteil- und Prozessrepräsentation:

1. Voll 3D-fähiges Datenmanagement
2. Situationsabhängige Kontextbereitstellung
3. WAAM-gerechte Qualitätsbewertung
4. Zuordnung von Qualitätsdaten, Prozessdaten und Prozessparametern
5. Anbindung an vor- und nachgelagerte Prozessschritte sowie übergeordnete Datenmanagementsysteme

In diesem Kapitel wird diesen Anforderungen begegnet. Dazu wird in den Abschnitten zum Systemkontext (Abschnitt 3.1) sowie zum räumlichen und zeitlichen Kontext (Abschnitt 3.2) auf die drei Kontextkategorien eingegangen. Zur Anbindung des Digitalen Zwillings an die Phasen des Produktlebenszyklus wird eine Vorgehensweise zur räumlichen Annotation zeitlicher Daten vorgestellt (Abschnitt 3.3). Dies ermöglicht den Austausch von Informationen zwischen dem Digitalen Zwilling und den CAD-/CAM-Systemen beziehungsweise der Qualitätssicherung. Abgeschlossen wird das Kapitel mit einer Evaluierung der vorgestellten Methoden (Abschnitt 3.4) sowie einer Zusammenfassung der Ergebnisse (Abschnitt 3.5). Teile dieses Kapitels wurden der Fachöffentlichkeit bereits in Publikationen [P1, P8, P10] vorgestellt. Einzelne Aspekte wurden in vom Autor betreuten Studienarbeiten [S12, S18] diskutiert.

3.1 Systemkontext

Der Systemkontext stellt Informationen auf Steuerungs-, Prozessleit- sowie Betriebsleitebene bereit. Die Anfragen der Prozess- sowie Betriebsleitebene werden durch ein OPC UA Informationsmodell bedient. Für die Steuerungsebene wird zusätzlich eine Prozesszustandsbeschreibung genutzt.

3.1.1 OPC UA Informationsmodell

Da ein umati-Informationsmodell für die additive Fertigung zum Zeitpunkt der Abfassung dieser Arbeit nicht vorlag, wird auf die Beschreibung der digitalen Repräsentation im dritten Teil des Normentwurfs ISO/DIS 23247 [146] für einen Digitalen Zwilling in der Fertigung zurückgegriffen. Die dort genannten Elemente werden für das WAAM-spezifische Maschineninformationsmodell adaptiert und in der hierarchischen Baumstruktur des OPC UA-Informationsmodells, wie in Tabelle 3.1 gezeigt, hinterlegt. Die betrachteten Kategorien umfassen das Personal, die Ausrüstung, das Material, die Einrichtung, die Umgebung, das

Tabelle 3.1: WAAM-spezifisches OPC UA-Maschineninformationsmodell unter Berücksichtigung der im Normentwurf ISO/DIS 23247-3 [146] genannten Kategorien

Kategorie	Elemente
Personal	Personalidentifikationsnummer, Aufgabenbezeichnung
Ausrüstung	Spezifikationen und Status von Kinematik, Steuerungs- und Prozesstechnik und Sensorik
Material	Art, Identifikationsnummer und Status von Substrat, Drahtmaterial und Schutzgas
Einrichtung	Standort, Identifikationsnummer und Status der Fertigungsanlage
Umgebung	Raumtemperatur, Luftfeuchtigkeit
Produkt	Geometrieabmessungen, Bauteilidentifikationsnummer
Prozess	Maschinenparameter, Prozesstyp, Prozessparameter, räumliche Aufzeichnungsgenauigkeit

Produkt sowie den Prozess. Innerhalb des Digitalen Zwillinges wird das Informationsmodell in einem Schlüsselwertspeicher hinterlegt, sodass die Module des Digitalen Zwillinges einen unmittelbaren Zugriff auf den Systemkontext haben. Komponenten, welche sich außerhalb des Digitalen Zwillinges befinden, haben nach dem Client-Server-Modell per OPC UA Zugriff auf das Informationsmodell.

3.1.2 Prozesszustandsbeschreibung

Die im OPC UA-Informationsmodell hinterlegten Informationen zum Prozess werden um eine Prozesszustandsbeschreibung ergänzt, welche die bei der Bauteilfertigung durchlaufenen Zustände darstellt. Als Eingabe nutzt die Prozesssteuerung einen angepassten Maschinencode auf Basis der ISO 6983. Dieser wird im Anschluss an die Prozessplanung und Maschinensimulation im CAD/CAM-System automatisiert generiert. Beispielhaft ist im Algorithmus 1 ein solcher Maschinencode dargestellt. Er besteht aus einer Abfolge von nummerierten Zeilen (z.B. $N10$, $N23030$). In jeder Zeile finden sich Steuerbefehle. Es handelt sich dabei beispielsweise um Bewegungsbefehle wie $G1$ in Zeile $N23040$, mit dem eine Linearbewegung des TCPs in Richtung der Absolutkoordinate $x_{N23040} = 20 \text{ mm}$, $y_{N23040} = 30 \text{ mm}$ und $z_{N23040} = 40 \text{ mm}$ mit einer Orientierung des Schweißbrenners $A = 0^\circ$, $B = 0^\circ$ und $C = 90^\circ$ sowie einer Orientierung des zweiachsigen Drehkipptisches $VA = 0^\circ$ und $VC = 90^\circ$ ausgeführt wird. Der angefügte F -Wert gibt die TCP-Geschwindigkeit in mm min^{-1} an. Kontextspezifisch werden binäre Entscheidungsvariablen in den Maschinencode eingefügt, mit welchen der Schweißprozess gesteuert wird. $R20$ ist beispielsweise ungleich Null im Falle eines laufenden Programms und $R25$ wählt einen Prozessparametersatz für den Schweißprozess an. In den Subroutinen $WAAMSTART$ und $WAAMENDE$ werden die Entscheidungsvariablen $R21$ und $R22$ gesetzt, welche den Schweißbefehl und den Zustand des realen Schweißprozesses widerspiegeln. Die Subroutinen $WAAMMONITORING$ und $WAAMMODE$ initialisieren die Kommunikation für die Prozessüberwachung und den Betriebsmodus der Schweißquelle. $M30$ beendet die Ausführung des Programms.

Die durchlaufenen Prozesszustände lassen sich in das in Abbildung 3.1 dargestellte Unified Modeling Language (UML)-Zustandsdiagramm einordnen. Abhängig vom aktuellen Zustand werden die Elemente des Digitalen Zwillinges (de-)aktiviert. Beispielsweise sind die Anomaliedetektion und die Prozessregelung lediglich bei einem aktiven Schweißprozess aktiv und im Falle einer Änderung des Prozessparametersatzes ($R25 \rightarrow R25'$) wird die Wahl eines passenden

Algorithmus 1 Exemplarischer Maschinencode mit WAAM-spezifischen Subroutinen und Entscheidungsvariablen

```

...
N10 R20 = 1
N20 WAAMMODE
N30 WAAMMONITORING
...
N23010 G1 X=20 Y=35 Z=40 A=0.00 B=0.00 C=90.00 VA=0.00 VC=90.00 F1000
N23020 R25 = 100
N23030 WAAMSTART
N23040 G1 X=20 Y=30 Z=40 A=0.00 B=0.00 C=90.00 VA=0.00 VC=90.00 F350
N23050 G1 X=25 Y=20 Z=40 A=0.00 B=0.00 C=90.00 VA=0.00 VC=90.00
N23060 G1 X=27 Y=15 Z=40 A=0.00 B=0.00 C=90.00 VA=0.00 VC=90.00
N23070 WAAMENDE
N23080 G1 X=27 Y=15 Z=45 A=0.00 B=0.00 C=90.00 VA=0.00 VC=90.00 F1000
...
N43060 G1 X=27 Y=15 Z=60 A=0.00 B=0.00 C=90.00 VA=0.00 VC=90.00
N43070 R20 = 0
M30

```

Detektionsmodells initiiert. Der Systemkontext dient damit der Konditionierung aller Module des Digitalen Zwillings.

3.2 Räumlicher und zeitlicher Kontext

Bei der additiven Fertigung haben sowohl Zeit als auch Raum einen Einfluss auf den Prozess, da sich die räumliche Umgebung des Arbeitspunktes entlang der Zeitachse einerseits aufgrund der Bewegung und andererseits auf Grund physikalischer Prozesse verändert. Die Indexierung der Dateninstanzen geschieht deshalb für die digitale Repräsentation des Bauteils räumlich und zeitlich simultan in Form einer Raumzeitindexierung, welche im nachfolgenden Abschnitt beschrieben wird. Im Anschluss folgen zwei Abschnitte zur Initialisierung der Datenstruktur sowie zur Bereitstellung des räumlichen Kontexts.

3.2.1 Räumliche und zeitliche Indexierung

Im Rahmen der räumlichen und zeitlichen Indexierung wird zwischen dynamischen und statischen Daten unterschieden. Dynamische Daten sind Prozessdaten, welche prozessparallel generiert werden. Bei erstmaliger Registrierung innerhalb des Digitalen Zwillings wird ihnen ein Zeitstempel zugeordnet. Es handelt sich beispielsweise um Sensordaten, von diesen abgeleitete Größen, aktive Prozessparameter und TCP-Positionswerte. Der Zeitstempel wird von einem zentralen Zeitserver vergeben, sodass alle Systemkomponenten dieselbe Zeitbasis haben und es zu keiner zeitlichen Abweichung zwischen den Steuerungsgeräten kommt.

Räumliche Daten, die bereits vor dem Start des Prozesses verfügbar sind, werden als statische Daten bezeichnet. Bei statischen Daten handelt es sich beispielsweise um den Maschinencode, um CAx-Prozessentwicklungsergebnisse wie Verzugs- und Temperatursimulationsdaten oder um Prozessdaten eines Referenzbauteils. Bei statischen Dateninstanzen ist sowohl der Zeitstem-

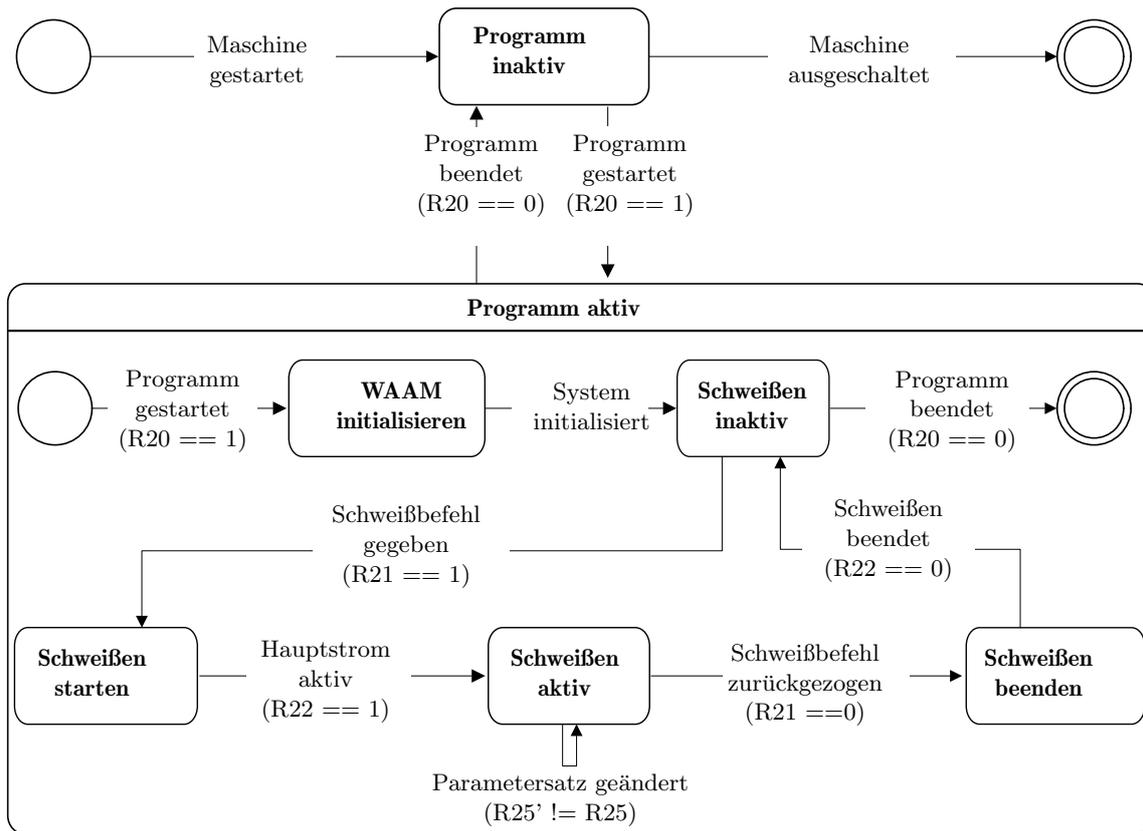


Abbildung 3.1: Schweißprozess orientiertes UML-Zustandsdiagramm für den Digitalen Zwilling des WAAM-Prozesses

pel als auch die Position für jedes Element bereits vor dem Prozess definiert. Durch Addition einer zeitlichen bzw. räumlichen Verschiebung wird eine Synchronisation des Startpunkts mit dem realen Prozess erreicht. Bei Prozessunterbrechungen oder -eingriffen beispielsweise aufgrund von Werkzeugverschleiß kann es jedoch zu Abweichungen zwischen dem simulierten und dem realen Prozess kommen. Eine Synchronisation mit den dynamischen Daten ist deshalb lediglich über die Position möglich.

Besondere Bedeutung für die digitale Repräsentation kommt den TCP-Positionsdaten zu. Die Position eines Punktes \mathbf{x}_k ist über die kartesischen Koordinaten x_k , y_k und z_k definiert. Für dessen räumliche Einordnung innerhalb des Prozessarbeitsraums wird ein Octree genutzt. Octrees zeichnen sich durch eine baumartige Struktur mit j_{Octree} Ebenen im dreidimensionalen Raum aus, wobei jeder Ebene acht Suboktanten zugewiesen werden. Die Octree-Datenstruktur ermöglicht durch die rekursive Unterteilung eine effiziente Suche nach relevanten Datenpunkten im Raum, deren Zeitkomplexität im Falle einer optimalen Raumnutzung bei $\mathcal{O}(\log n_{Octree})$ liegt [245, 246]. Im Gegensatz zum kd- und zum r-Baum wird beim Octree die erreichbare räumliche Auflösung bereits mit der Initialisierung definiert. Sie hängt maßgeblich von der Anzahl an Ebenen j_{Octree} im Octree ab. Jede zusätzliche Ebene erhöht die Auflösung um den Faktor zwei in jede Raumrichtung. Die Kantenlänge l_{Voxel} eines Oktanten auf der untersten Ebene wird mit Gleichung 3.1 berechnet. l_{Octree} entspricht der Kantenlänge des Octrees in [mm].

$$l_{Voxel} = \frac{l_{Octree}}{2^{j_{Octree}}} \quad (3.1)$$

Wie in Abbildung 3.2 gezeigt wird analog zur Einteilung der Daten ein dynamischer und ein statischer Octree aufgebaut. Der dynamische Octree füllt sich im Laufe des Prozesses auf Basis

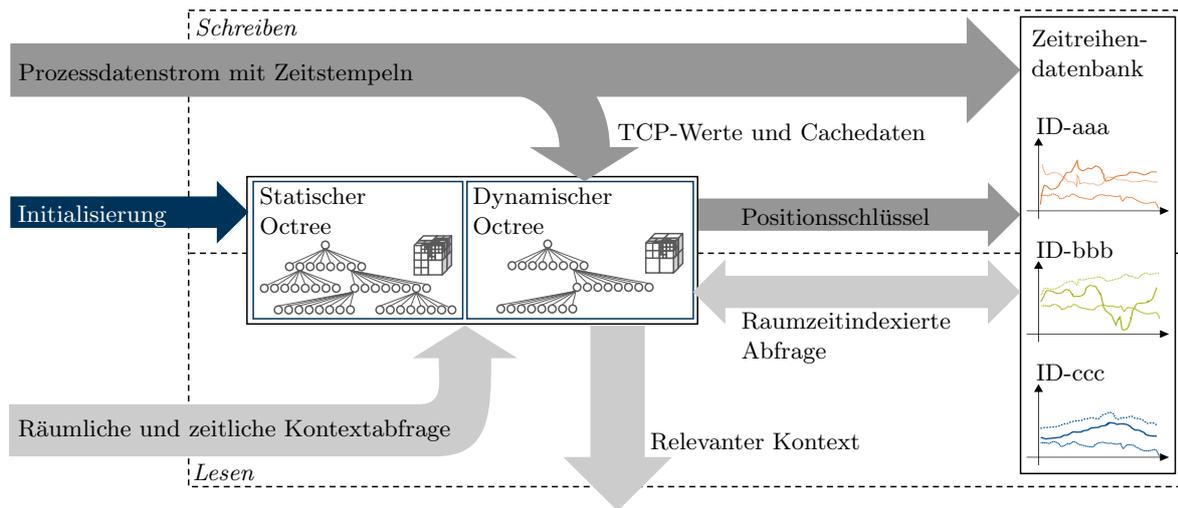


Abbildung 3.2: Zusammenspiel des räumlichen und zeitlichen Datenmanagements bei Lese- und Schreibzugriff unter Nutzung eines statischen und eines dynamischen Octrees sowie einer Zeitreihendatenbank

der im Prozess angefahrenen, diskretisierten TCP-Positionen und Prozessdaten und spiegelt damit den Fortschritt des Druckauftrags wieder. Jeder Positionswert wird auf der untersten Ebene des Octrees eingefügt, um eine Neuordnung des Octrees im Prozess zu vermeiden und so die zeitlichen Kosten zum Hinzufügen neuer Elemente gering zu halten. Ohne Rückführung von Informationen handelt es sich damit beim dynamischen Octree gemäß Definition 3 um einen Digitalen Schatten des Bauteils. Der statische Octree beinhaltet die statischen Daten und wird mit der Initialisierung der räumlichen Datenstruktur erstellt. Die Werte im statischen Octree sind als Referenzwerte im Prozess verfügbar. Der ausgefüllte, statische Octree ist nach Definition 2 ein Digitales Modell des Bauteils.

Der Octree wird im Arbeitsspeicher eines Edge-Geräts abrufbereit gehalten, um jederzeit räumlichen Kontext bereitstellen zu können. Da der Arbeitsspeicher begrenzt ist, wird lediglich ein Teil der Sensordaten mit den Positionswerten in der räumlichen Datenstruktur abgelegt. Dazu wird eine Unterscheidung in unmittelbar nutzbare Daten (Cachedaten), welche geringe Latenzen bei Anfragen ermöglichen, und mittelbar nutzbare Daten, für die keine kritischen Latenzanforderungen gelten, getroffen. Erstere werden einerseits im Octree als Zusatzinformationen zu jedem Punkt hinterlegt. Sie führen damit zu einem erhöhten Arbeitsspeicherbedarf. Andererseits werden sie in einer zeitbasierten Datenbank, wie in Abbildung 3.2 dargestellt, hinterlegt. Die Datenbank wird zur Reduktion des Arbeitsspeicherbedarfs auf einem persistenten Speichermedium abgelegt. Die mittelbar nutzbaren Daten werden lediglich in der zeitbasierten Datenbank hinterlegt. Die Ablage der Daten in der zeitbasierten Datenbank erfolgt unter Nutzung eines Zeit- und eines Raumindexes. Der Zeitindex entspricht dem Zeitstempel des jeweiligen Datenpunkts. Der Raumindex wird aus der Position des Suboktanten auf der untersten Ebene des Octrees abgeleitet, in dem der Datenpunkt anfällt. Dessen Mittelpunkt wird mithilfe eines an den Morton-Code angelehnten Algorithmus nach Warren et al. [247] in einen Positionsschlüssel überführt. Die räumliche Indexierung erlaubt die Serialisierung des Octrees, sodass eine persistente Speicherung möglich wird. Die abgelegten Daten werden mit der Bauteilidentifikationsnummer des Systemkontexts verknüpft, um Rückverfolgbarkeit zu erreichen.

3.2.2 Initialisierung

Mithilfe der statischen Daten wird der Octree initialisiert. Im Gegensatz zu L-PBF ist der Bauraum bei WAAM nicht durch die Abmessungen eines Pulverbetts begrenzt. Die Größe variiert in Abhängigkeit von dem zu fertigenden Bauteil. Die erforderliche Kantenlänge des Octrees wird aus dem Maschinencode abgeleitet, wobei zur Abdeckung von Ungenauigkeiten in der Positionierung eine leicht vergrößerte Kantenlänge genutzt wird. Die Anzahl an Ebenen des Octrees wird abhängig von der Leistungsfähigkeit des Edge-Geräts gewählt. Die Kantenlänge sowie die Anzahl an Ebenen des Octrees werden als Metainformationen im Schlüsselwertspeicher des Systemkontexts hinterlegt.

Der statische Octree wird bereits zu Beginn des Prozesses mit den statischen Daten befüllt. Eine Vorbelegung des dynamischen Octrees auf Basis des Maschinencodes bietet keinen Vorteil hinsichtlich der Latenzen für Punkteinfügeoperationen wie Untersuchungen [S12] zeigten.

3.2.3 Kontextbereitstellung

Die digitale Bauteil- und Prozessrepräsentation stellt der Prozessüberwachung und dem Prozesseingriff prozessparallel Kontext bereit. Während der zeitliche Kontext für jeden Datenpunkt durch die unmittelbare Vergangenheit definiert und der Systemkontext über den Schlüsselwertspeicher zugänglich ist, wird für den räumlichen Kontext zunächst die räumliche Relevanz als Parameter der Kontextbereitstellung benötigt. Die Bearbeitung der räumlichen Kontextabfrage kann anschließend, wie in Abbildung 3.2 im unteren Bereich dargestellt, auf drei Arten erfolgen:

1. Zugriff auf die Daten des statischen Octrees
2. Zugriff auf die Cachedaten im dynamischen Octree
3. Zugriff auf die Daten in der zeitbasierten Datenbank auf Basis der relevanten Zeit- und Raumindizes

Der dritte Fall tritt ein, wenn mittelbar verfügbare Daten oder Daten früherer Fertigungsprozesse angefragt werden. Es erfolgt eine kombinierte Abfrage an die zeitbasierte Datenbank unter Nutzung der relevanten Zeit- und Raumindizes. Um die relevanten Raumindizes zu erhalten, wird zunächst eine Abfrage des dynamischen Octrees auf Basis der räumlichen Relevanz durchgeführt. Mithilfe der räumlichen Relevanz können zudem voll 3D-fähige Qualitätsmetriken abgeleitet werden.

Räumliche Relevanz

Die räumliche Relevanz definiert, welche Dateninstanzen im Raum kontextuell von Interesse sind. Im Folgenden werden mit Kubus, Kugel und Doppelellipsoid drei geometrische Ausprägungen betrachtet.

Kubus: Der Octree unterteilt sich je Ebene in acht Oktanten. Jeder Oktant hat die geometrische Form eines Kubus, sodass diese geometrische Form implizit in der Octreedatenstruktur hinterlegt ist. Zur Suche nach relevanten Punkten innerhalb eines definierten Kubus im Octree wird eine Tiefensuche vorgenommen, welche aufgrund der rekursiven Unterteilung des

Suchraums effizient durchgeführt werden kann. Bei der Tiefensuche wird nach Überschneidungen der Oktanten entlang eines Octreepfades mit dem definierten Kubus gesucht. Sollte ein Oktant keine Überschneidung aufweisen, wird dieser gemeinsam mit allen darunter liegenden Suboktanten für die aktuelle Suche als irrelevant markiert. Bei Überschneidung werden die darunter liegenden Suboktanten in die Suche miteinbezogen. Alle weiteren geometrischen Formen nutzen ebenfalls diese Tiefensuche. Auch auf Basis der Positionsschlüssel lässt sich die Tiefensuche effizient umsetzen, da die übergeordneten Oktanten mittels Bitschiebeoperationen ausfindig gemacht werden können.

Kugel: Dateninstanzen einer Kugel können als Teilmenge aller Dateninstanzen eines Kubus gesehen werden, sofern die Mittelpunkte \mathbf{x}_0 mit den Koordinaten x_0 , y_0 und z_0 der beiden geometrischen Formen übereinstimmen und der Durchmesser der Kugel der Kantenlänge l_{Kubus} des Kubus entspricht. Ein Punkt mit den Koordinaten x_k , y_k und z_k liegt innerhalb der Kugel und ist damit relevant, wenn Gleichung 3.2 erfüllt ist.

$$\frac{\sqrt{(x_k - x_0)^2 + (y_k - y_0)^2 + (z_k - z_0)^2}}{l_{Kubus}} \leq 1 \quad (3.2)$$

Doppelellipsoid: Das Schweißbad bezeichnet den Bereich der noch nicht erstarrten Schmelze. Dessen Dimensionen sind sowohl in der Schweißtechnik als auch in WAAM wichtige Prozessgrößen und haben einen Einfluss auf die Prozessqualität. Zur Definition des Schweißbads als relevanten Bereich für eine sich bewegende Wärmequelle wird das Schweißbadmodell nach Goldak et al. [40] herangezogen. Dieses orientiert sich, wie in Abbildung 3.3 dargestellt, an der hitzebeeinflussten Zone, welche durch Grenzwerte für den Wärmefluss $q(r)$ beschränkt wird. Die Form dieser hitzebeeinflussten Zone wird mit einem Doppelellipsoid angenähert. Das

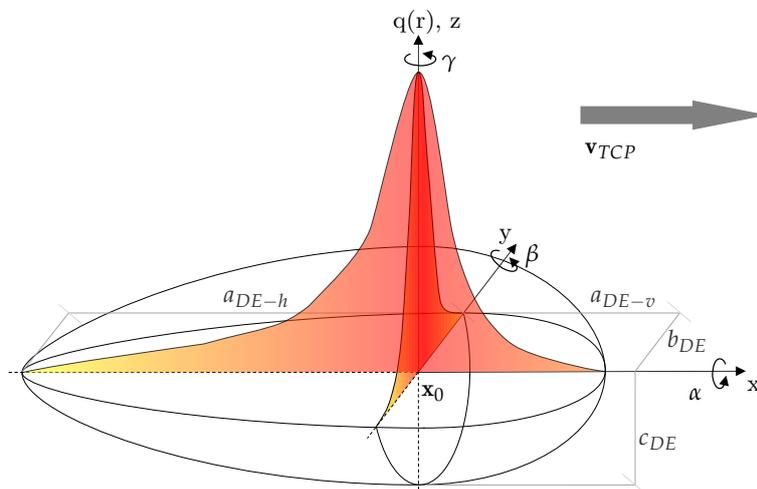


Abbildung 3.3: Doppelellipsoid mit Wärmeverteilung nach Goldak et al. [40] zur Modellierung eines Schweißbads inklusive der räumlichen Freiheitsgrade und Abmessungen [P8]

Doppelellipsoid besteht aus zwei Ellipsoiden mit Schwerpunkt im TCP, welche orthogonal zum Bewegungsvektor auf Höhe des TCPs halbiert und miteinander verbunden sind. Das vordere Halbellipsoid bezeichnet den Bereich, für den nach Gleichung 3.3 das Produkt der euklidischen Distanz eines enthaltenen Punkts \mathbf{x}_k mit den Koordinaten x_k , y_k und z_k und des Mittelpunkts des Doppelellipsoids \mathbf{x}_0 mit den Koordinaten x_0 , y_0 und z_0 mit dem Richtungsvektor der Schweißbewegung \mathbf{v}_{TCP} positiv ist. Das hintere Halbellipsoid umfasst den Bereich, in dem das

Produkt negativ ist.

$$(\mathbf{x}_k - \mathbf{x}_0) \cdot \mathbf{v}_{TCP} \begin{cases} > 0 : \text{Vorderes Halbellipsoid} \\ = 0 : \text{Indefinit} \\ < 0 : \text{Hinteres Halbellipsoid} \end{cases} \quad (3.3)$$

Das vordere Halbellipsoid weist, wie in Abbildung 3.3 dargestellt, eine Ausdehnung a_{DE-v} in Schweißrichtung und das hintere Halbellipsoid eine Ausdehnung von a_{DE-h} entgegen der Schweißrichtung auf. Bei einer Schweißgeschwindigkeit von $v_{TCP} > 0$ gilt im Normalfall $a_{DE-v} \leq a_{DE-h}$. Die Dimensionen b_{DE} und c_{DE} gleichen sich für beide Halbellipsoide, sodass tangentielle Kontinuität sichergestellt ist. Für das betrachtete Doppelellipsoid gilt Gleichung 3.4

$$(\mathbf{x} - \mathbf{x}_0)^T \cdot \mathbf{A}_{DE-v,h} \cdot (\mathbf{x} - \mathbf{x}_0) \leq 1 \quad (3.4)$$

mit $\mathbf{A}_{DE-v,h}$ aus Gleichung 3.5.

$$\mathbf{A}_{DE-v,h} = \mathbf{R} \cdot \mathbf{D}_{DE-v,h} \cdot \mathbf{R}^T. \quad (3.5)$$

$\mathbf{A}_{DE-v,h}$ ist das Produkt der Diagonalmatrix \mathbf{D} mit den reziproken Quadraten der Ellipsoidachsendimensionen $a_{DE-v,h}$, b_{DE} und c_{DE} auf der Diagonalen (siehe Gleichung 3.6) und der orthogonalen Matrix \mathbf{R} .

$$\mathbf{D}_{DE-v,h} = \begin{bmatrix} a_{DE-v,h}^{-2} & 0 & 0 \\ 0 & b_{DE}^{-2} & 0 \\ 0 & 0 & c_{DE}^{-2} \end{bmatrix} \quad (3.6)$$

Die Spalten von \mathbf{R} stellen die Richtungen der Hauptachsen des Doppelellipsoids dar. Die Orientierung des Doppelellipsoids lässt sich über eine Kombination der Rotationsmatrizen $\mathbf{R}_x(\alpha)$, $\mathbf{R}_y(\beta)$ und $\mathbf{R}_z(\gamma)$, wie in Gleichung 3.7 festgehalten, abbilden. Die Winkel α , β und γ werden aus der Richtung von \mathbf{v}_{TCP} und der Orientierung des Drehkipptisches abgeleitet.

$$\mathbf{R} = \mathbf{R}_x(\alpha) \cdot \mathbf{R}_y(\beta) \cdot \mathbf{R}_z(\gamma) \quad (3.7)$$

Für alle schichtbasierten additiven Fertigungsverfahren kann $\alpha = 0$ und $\beta = 0$ angenommen werden. Da auch im WAAM-Prozess das Schweißbad üblicherweise annähernd horizontal liegt, kann meistens $\alpha = 0$ und $\beta = 0$ gesetzt werden. Gleichung 3.4 vereinfacht sich somit zu Gleichung 3.8

$$(\mathbf{x}_k - \mathbf{x}_0)^T \cdot \mathbf{R}_z(\gamma) \cdot \mathbf{D}_{v,h} \cdot \mathbf{R}_z^T(\gamma) \cdot (\mathbf{x}_k - \mathbf{x}_0) \leq 1 \quad (3.8)$$

beziehungsweise zu Gleichung 3.9.

$$\begin{aligned} & \left(\frac{(x_k - x_0) \cdot \cos(\gamma) + (y_k - y_0) \cdot \sin(\gamma)}{a_{DE-v,h}} \right)^2 \\ & + \left(\frac{-(x_k - x_0) \cdot \sin(\gamma) + (y_k - y_0) \cdot \cos(\gamma)}{b_{DE}} \right)^2 \\ & + \left(\frac{z_k - z_0}{c_{DE}} \right)^2 \leq 1 \end{aligned} \quad (3.9)$$

Die Größenordnung der Werte von $a_{DE-v,h}$, b_{DE} und c_{DE} kann der Literatur [44, 45, 46] entnommen oder mittels Parameterstudien, wie in [P8] gezeigt, experimentell bestimmt werden.

Die Octreedatenstruktur und der abgetastete Werkzeugweg weisen per se eine Diskretisierung auf, welcher auch bei Abfragen des räumlichen Kontexts Rechnung zu tragen ist. b_{DE} sollte sich deshalb am Spurabstand (engl. *hatching distance*) d_h , d.h. dem vorgesehenen Abstand

zwischen zwei horizontalen Schweißspuren, orientieren. Der Wert von c_{DE} richtet sich nach der Schichthöhe d_l . Es gelten die Gleichungen 3.10 für mehrlagige, mehrspurige Bauteile, sofern lediglich unmittelbar benachbarte Schweißspuren in den räumlichen Kontext des Schweißbads einbezogen werden.

$$\begin{aligned} d_h &\leq b_{DE} \leq 2 \cdot d_h \\ d_l &\leq c_{DE} \leq 2 \cdot d_l \end{aligned} \quad (3.10)$$

Bei dünnwandigen, einspurigen Strukturen kann $b_{DE} = c_{DE}$ gesetzt werden.

Kontextintegrierende Qualitätsmetriken

Bei der additiven Fertigung wird das Bauteil voxelweise aufgebaut. Dadurch begünstigen Defekte die Entstehung von Folgedefekten in benachbarten Schweißbahnen. Zudem kann es zu Akkumulationen von Defekten in einem Bauteilbereich kommen. Je größer die Ausbreitung der Defektgruppe wird, desto kritischer ist sie für die Qualität des Bauteils. Um solche Defektgruppen im Raum quantitativ messbar zu machen, werden nachfolgend zwei kontextintegrierende Qualitätsmetriken für den voll 3D-fähigen WAAM-Prozess eingeführt. Es handelt sich dabei um die Defektgruppenausdehnung und um die lokale Anomaliedichte.

Defektgruppenausdehnung: Die Defektgruppenausdehnung untersucht die räumliche Ausbreitung von Defektgruppen. Unter der Annahme, dass sich Defekte im Falle einer Ausbreitung über mehrere Lagen kurzzeitig im selben Schweißbad befinden (siehe Gleichung 3.10), wird der Bereich des Schweißbads mithilfe des Doppelellipsoids als Zone der räumlichen Relevanz modelliert. Sofern sich ein Defekt ereignet, in dessen räumlicher Nähe sich ein anderer Defekt befindet, werden die beiden detektierten Defekte mit der gleichen Defektgruppenidentifikationsnummer markiert.

Es ist zu beachten, dass eine räumliche Defektkorrelation keine Kausalität impliziert. Um dennoch einen Defekt als Folgedefekt eines anderen Defekts zu identifizieren, kann auf Tabelle B.1 im Anhang zurückgegriffen werden, in welcher der in Experimenten beobachtete Zusammenhang zwischen Defekten und möglichen Folgedefekten festgehalten ist. Oxidation geht beispielsweise mit der Bildung von Schlacke einher. Poren können durch ungeeignete Prozessparameter bei Formabweichungen entstehen. Ein Bindefehler kann wegen des lokal gestörten Wärmeabflusses zu einer Hitzeansammlung und damit zu einem Seitenkollaps in den folgenden Lagen führen. Humping-Effekt induzierte Geometrieabweichungen können sich in den folgenden Lagen verstärken und in Unstetigkeiten münden.

Lokale Anomaliedichte: Die lokale Anomaliedichte betrachtet eine räumliche Mittelung von Anomaliewerten, um eine quantitative Aussage über die Prozessstabilität in Bauteilbereichen zu geben. Einzelne Prozessunregelmäßigkeiten wie beispielsweise Lichtbogeninstabilitäten führen nicht zwangsläufig zu Ausschuss. Eine räumliche Akkumulation von solchen Anomalien kann jedoch auf systematische Fehler im Prozess hindeuten. Zudem sind Anomalien Indikatoren für Defekte wie beispielsweise Poren, deren Akkumulation zu einer reduzierten Belastbarkeit des Bauteils führen. Aus diesem Grund muss die lokale Anomaliedichte quantifiziert werden. Prozessparallel kann die lokale Anomaliedichte für eine Kugel um den aktuellen TCP berechnet werden. Mit dem Eintreffen eines neuen Positionswerts ist die soeben berechnete lokale Anomaliedichte jedoch bereits veraltet.

Um für alle Bereiche des Bauteils stets die aktuellen lokalen Anomaliedichten zu erhalten, wird die ebenenabhängige Diskretisierung des Octrees genutzt. Abhängig von der erforderlichen

Auflösung wird für die Oktanten einer Octreeebene die lokale Anomaliedichte ermittelt und der prozessparallelen Qualitätsbewertung bereitgestellt.

3.3 Räumliche Annotation von Zeitreihen

Während die Prozessüberwachung des WAAM-Prozesses zeitbasiert stattfindet, liegen das CAD-Modell sowie das resultierende Bauteil lediglich als Elemente im dreidimensionalen Raum vor. Um dennoch eine Verbindung zwischen den vor- und nachgelagerten Schritten der Produktentstehung bzw. des Produktlebenszyklus zu ermöglichen, wird nachfolgend eine Methodik erörtert, welche zur Übertragung räumlicher Informationen auf die Zeitreihen dient. Als Ausgangsbasis dienen WAAM-Prozessdaten und Informationen aus der Qualitätssicherung beispielsweise eines CT-Scans. Die Methodik besteht aus sechs Schritten:

1. **Zeitliche Synchronisierung:** Während des WAAM-Prozesses werden die Daten der Sensoren sowie die Positionen des TCPs im Bauteilkoordinatensystem inklusive ihrer Zeitstempel, wie in Abbildung 3.2 dargestellt, in der zeitbasierten Datenbank gespeichert. Dadurch findet eine Synchronisierung der Daten statt.
2. **Anpassung der TCP-Positionen:** Da während des WAAM-Prozesses der Abstand zwischen der realen Position des TCPs und der Sollposition variieren kann, ist dieser Wert entweder zu regeln oder zu messen. Der Messwert wird als Korrekturfaktor für die Sollposition des TCPs genutzt, um die Istposition zu erhalten. Verfahren zur prozessparallelen Messung dieses Abstands werden in Abschnitt 4.4 vorgestellt.
3. **Zuordnung von Koordinaten zu Defekten:** Im Rahmen der Qualitätssicherung werden Informationen über die Bauteilqualität beispielsweise mithilfe eines CT-Scans oder eines räumlichen Sensors eingeholt. Die Defekte werden lokalisiert und Koordinaten in einem Referenzkoordinatensystem zugeordnet.
4. **Transformation der Defektkoordinaten:** Die erhaltenen Defektkoordinaten werden mittels Translations- und Rotationsoperationen vom Referenzkoordinatensystem in das Bauteilkoordinatensystem überführt. Weitere Details zur Koordinatentransformation für den räumlichen Sensor sind in [P10] veröffentlicht.
5. **Annotation der TCP-Werte:** Um die aufgezeichneten TCP-Positionen bei räumlicher Nähe zu den transformierten Defektkoordinaten zu annotieren, wird eine Kugel um jeden Defekt als räumlich relevanter Bereich definiert, in welchem die aufgezeichneten TCP-Positionen als abnormal annotiert werden. Dies geschieht durch einen Vergleich der euklidischen Distanzen zwischen den TCP-Positionen und den transformierten Defektkoordinaten mit einem Referenzabstand, der als Unschärfeparameter $d_{\text{Unschärfe}}$ bei der räumlichen Annotation dient. Die Wahl von $d_{\text{Unschärfe}}$ beeinflusst maßgeblich, ob jedem Defekt mindestens eine TCP-Position im Bauteil zugeordnet werden kann. Der dafür minimal erforderliche Wert kann mit Gleichung 3.11 berechnet werden. Es gilt die Annahme, dass der maximale Abstand eines Punktes im Bauteilvolumen zu einer räumlich benachbarten, aufgezeichneten TCP-Position maßgeblich von der Aufzeichnungsfrequenz der TCP-Positionen f_{TCP} , der Schweißgeschwindigkeit v_{TCP} , der Hatchingdistanz d_h sowie der Schichthöhe d_l abhängt.

$$d_{\text{Unschärfe}} \geq \sqrt{\left(\frac{v_{\text{TCP}}}{2 \cdot f_{\text{TCP}}}\right)^2 + \left(\frac{d_h}{2}\right)^2 + \left(\frac{d_l}{2}\right)^2} \quad (3.11)$$

6. **Übertragung der Defektannotationen:** Im letzten Schritt werden die Annotationen der TCP-Zeitreihen auf die Datenpunkte aller synchronisierten Zeitreihen übertragen.

Das Vorgehen lässt sich ohne Einschränkung auf Bauteile mit ein- und zweidimensionalem Werkzeugweg übertragen. In einem solchen Fall lassen sich anstelle dreidimensionaler Informationen auch zweidimensionale Daten aus der Qualitätssicherung wie beispielsweise Röntgenbilder oder Bauteilfotos nutzen.

Die Übertragbarkeit der räumlichen Annotation von Zeitreihen auf andere additive Fertigungsprozesse mit Multiachsooperationen wie beispielsweise LMD oder FDM ist durch den voxelweisen Auftrag implizit gegeben.

3.4 Evaluierung

Für die Evaluierung der vorgestellten Methoden wurde ein dünnwandiger Zylinder mit einem Durchmesser von 80 mm und einer Höhe von 68 mm mittels WAAM gefertigt. Der helixförmige Werkzeugweg wies eine Ganghöhe von 2.3 mm auf. Beim Aufbau wurden drei Defekte herbeigeführt: eine Unstetigkeit, welche sich über mehrere Windungen hinweg fortsetzte, und zwei Oxidationen, welche Schlackeeinschlüsse und Unstetigkeiten in der folgenden Windung zur Folge hatten. Der WAAM-Prozess wurde mithilfe eines Spannungssensors überwacht. Dessen Daten wurden mithilfe eines Autoencoders [P8] analysiert. Es standen damit neben den TCP-Positionen Anomaliewerte zur Verfügung, welche als Basis für die kontextintegrierenden Qualitätsmetriken dienten. Der eingesetzte Octree wies eine Kantenlänge von $l_{Octree} = 88 \text{ mm}$ bei $j_{Octree} = 10$ Ebenen auf, sodass auf unterster Ebene etwa eine Milliarde Suboktanten mit einer jeweiligen Kantenlänge von 85.9 μm möglich waren. Der Octree wurde in der Programmiersprache Python 3.8 implementiert.

3.4.1 Latenzen im Aufbau des Octrees

Zunächst wurde eine Untersuchung der Octreelatenzen für Punkteinfüge- und Kontextabfrageoperationen vorgenommen.

Messungen der Latenzen für Punkteinfügeoperationen zeigten eine annähernd konstante Latenz für den Aufbau des Bauteils (Durchschnitt 0.05 ms, Median 0.04 ms, minimal 0.02 ms, maximal 2.37 ms, Standardabweichung 0.08 ms). In den Latenzen ist kein Trend und keine Saisonalität erkennbar. Die Initialisierung des Octrees unter Nutzung des Maschinencodes ergab keine signifikanten Veränderungen in den Latenzen.

Die Messungen der Latenzen bei Kontextabfrageoperationen wurden für einen kugelförmigen Kontext um den TCP mit einem Radius von 5 mm vorgenommen und fanden prozessparallel einmal pro Sekunde statt. Die resultierenden Latenzen sind in Abbildung 3.4 dargestellt und lagen zwischen 0.19 ms und 16.94 ms. Als Bezugsgröße wurde die z-Position des TCPs verwendet, welche auf Grund des helixförmigen Werkzeugwegs monoton mit der Zeit zunahm. Die Entwicklungen der Latenzen waren von saisonalen Mustern und einem Aufwärtstrend bestimmt. Der Trend ging auf die zunehmende Anzahl von Elementen n_{Octree} im Octree zurück, durch die die Zeitkomplexität jeder Suchabfrage nach $\mathcal{O}(\log n_{Octree})$ anstieg. Die saisonalen Muster waren auf die geometriebedingte lokale Granularität des Octrees und das schrittweise Hinzufügen neuer Punkte in den Octree im Laufe des Prozesses zurückzuführen. Die in Abbildung 3.4 sichtbaren Übergänge entlang der z-Richtung korrespondierten mit

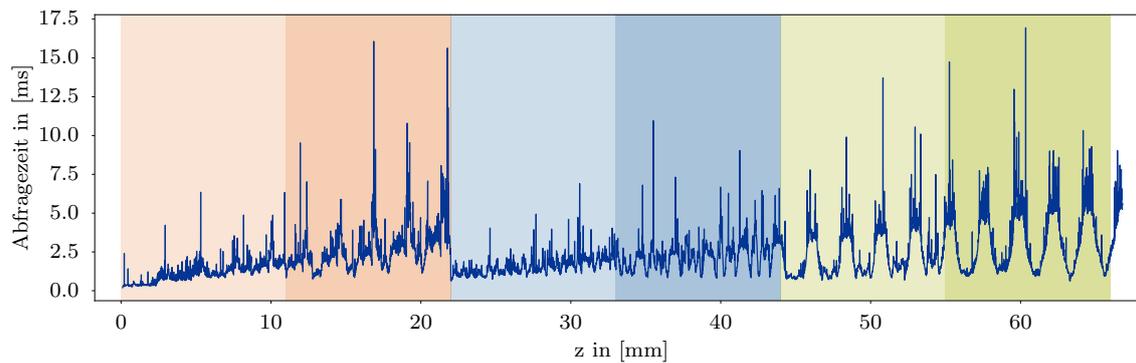


Abbildung 3.4: Latenzen für eine Octree-Abfrage, deren räumliche Relevanz über eine Kugel mit 5 mm Radius definiert ist, entlang des Aufbaus des exemplarischen Bauteils [P8]

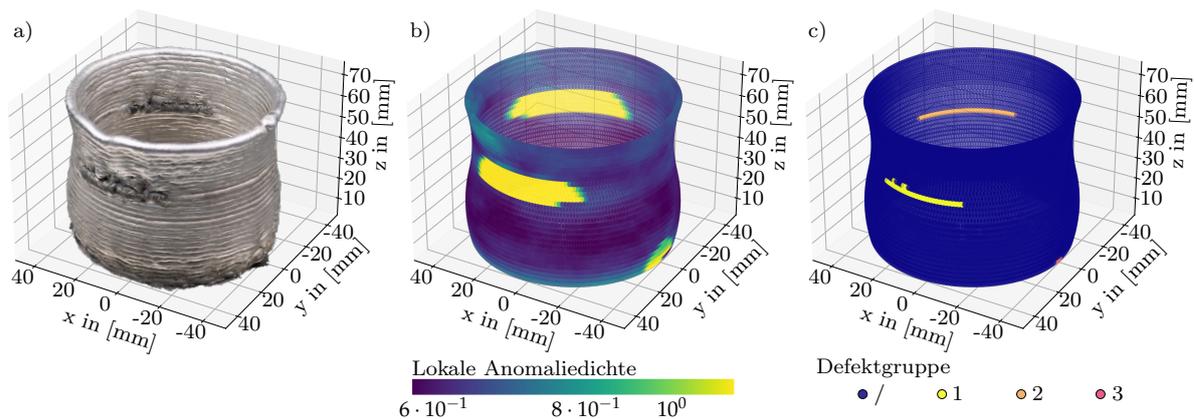


Abbildung 3.5: Vergleich des realen Beispielbauteils mit Darstellungen der kontextintegrierenden Qualitätsmetriken: a) Beispielbauteil, b) Darstellung der lokalen Anomaliedichte, c) Darstellung der Defektgruppenausdehnung

den Übergängen zwischen den Oktanten der zweiten Octree-Ebene (rote, blaue und grüne Farbbereiche) sowie den Oktanten der dritten Octree-Ebene (hellere und dunklere Bereiche jeder Farbe). Im Bereich dieser Übergänge waren temporär zwei Oktanten einer höheren Ebene zu untersuchen, sodass sich der Abfrageaufwand erhöhte. Zusätzlich waren saisonale Muster in Form von lokalen Bergen und Tälern in den Latenzen jedes Abschnitts zu sehen, welche mit den in horizontaler Richtung durchlaufenen Oktanten entlang der Helix sowie der Tiefensuche in Verbindung gebracht werden konnten. Die Abfragelatzen hingen damit maßgeblich von der Bauteilgeometrie und den Bauteilabmessungen ab. Bei einem größeren Radius der Kugel stiegen die Latenzen erwartungsgemäß an.

Während die quantitativen Ergebnisse dieser Untersuchung von der Implementierung des Octrees abhängen, waren die qualitativen Ergebnisse hinsichtlich der zeitlichen und geometriebedingten Entwicklung der Latenzen auch auf eine Octree-Implementierungen in der Programmiersprache C++ und weitere Bauteile verallgemeinerbar. Sie müssen bei der Nutzung eines Octrees für die Kontextbereitstellung berücksichtigt werden.

3.4.2 Evaluierung der kontextintegrierenden Qualitätsmetriken

In Abbildung 3.5 sind neben dem realen Bauteil a) die kontextintegrierenden Qualitätsmetriken dargestellt. In c) ist die Defektgruppenausdehnung visualisiert. Es sind drei Defektgruppen zu erkennen. Sie korrespondieren mit den Positionen und Ausbreitungen der Defekte im

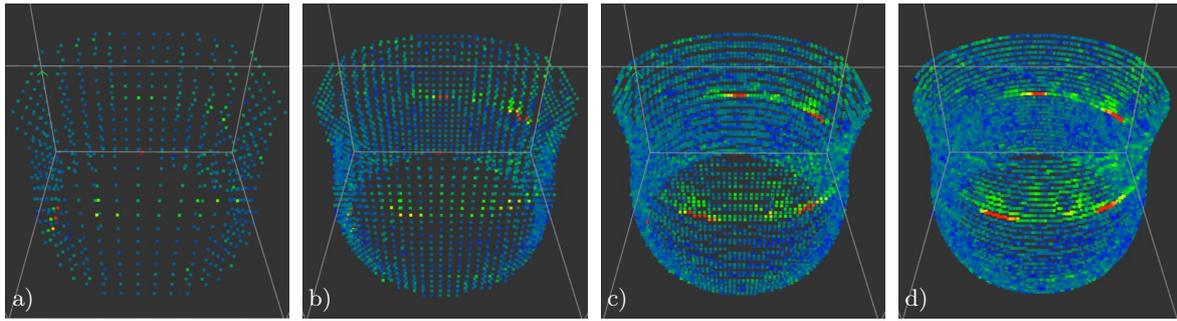


Abbildung 3.6: Darstellung der lokalen Anomaliedichte, welche unter Nutzung der Octree inhärenten Diskretisierung für die Octreeebenen a) 4, b) 5, c) 6 und d) 7 ermittelt wurde

realen Bauteil. In b) ist die lokale Anomaliedichte für einen Kugelradius von 10 mm dargestellt. Auch in dieser Darstellung sind die Defektgruppen zu erkennen. Ihre Ausbreitung ist jedoch nicht mehr quantitativ erfassbar. Die lokale Anomaliedichte aggregierte Anomaliewerte über bis zu vier Windungen, sodass die hohen Anomaliewerte der Defektgruppen 2 und 3 erst in der fünften Helixwindung keine Wirkung mehr auf die lokale Anomaliedichte hatten. Abgesehen von den auch in c) sichtbaren Defektgruppen ist im oberen linken Bereich von b) ($x = 20 \text{ mm}$, $y = 30 \text{ mm}$, $z = 60 \text{ mm}$) ein Gebiet zu erkennen, in welchem die lokale Anomaliedichte erhöhte Werte annahm. Dies war auf die räumliche Ansammlung erhöhter Anomaliewerte zurückzuführen, welche aus einer wellenförmigen Formabweichung und einem instabilen Lichtbogen resultierten. Eine Darstellung der lokalen Anomaliedichte unter Nutzung der Octreediskretisierung ist in Abbildung 3.6 für die Octreeebenen 4, 5, 6 und 7 dargestellt. Abhängig vom gewählten Aggregationslevel wird ein geringerer oder höherer Detailgrad erreicht. Auf Basis dieser Datenkompression kann die 3D-Visualisierung der relevanten Prozessinformationen effizient umgesetzt werden. Weitere Evaluierungen zur lokalen Anomaliedichte und der Defektgruppenausdehnung sind in [P8] zu finden.

3.4.3 Evaluierung der räumlichen Zeitreihenannotation

Auf Basis des CT-Scans des dünnwandigen Zylinders wurden Defekte im Referenzkoordinatensystem lokalisiert. In Abbildung 3.7 a) sind in der Schnittansicht beispielhaft die zwei oberen in Abbildung 3.5 b) sichtbaren Defektgruppen rot markiert. Darüber hinaus wurde eine Annotation mittels räumlichen Sensors unter Nutzung der in [P10] vorgestellten Methodik umgesetzt und überprüft. Der CT-Scan wies jedoch aufgrund des durchleuchtenden Prüfungscharakters einen höheren Informationsgehalt für die Qualitätssicherung auf.

Im Anschluss an die Koordinatentransformation ließen sich die annotierten Defekte räumlich im selben Koordinatensystem wie die zeitlich aufgelösten TCP-Positionen darstellen. Durch Übertragung der Annotationen auf die synchronisierten Sensorzeitreihendaten unter Nutzung eines Unschärfeparameters von $d_{\text{Unschärfe}} = 1.4 \text{ mm}$ wurden die in Abbildung 3.8 markierten Abschnitte als Oxidations-, Schlacke- und Unstetigkeitsdefekte in den Spannungsdaten annotiert. Die in der Abbildung rot visualisierte, zeitbasierte Referenzannotation für die räumliche Zeitreihenannotation wurde auf Basis eines MA-Anomaliedetektors für die Spannungsdaten automatisiert erstellt. Der qualitative Vergleich der räumlich annotierten Daten mit den zeitlich annotierten Daten in Abbildung 3.8 zeigte eine hohe Übereinstimmung in den Annotationen für die Oxidations- (orange) und Schlackedefekte (blau). Die Unstetigkeiten (grün) wurden vom verwendeten Anomaliedetektor in drei von fünf Fällen nicht erkannt, konnten jedoch zielgerichtet räumlich annotiert werden. Die Übereinstimmung der Annotationen betrug

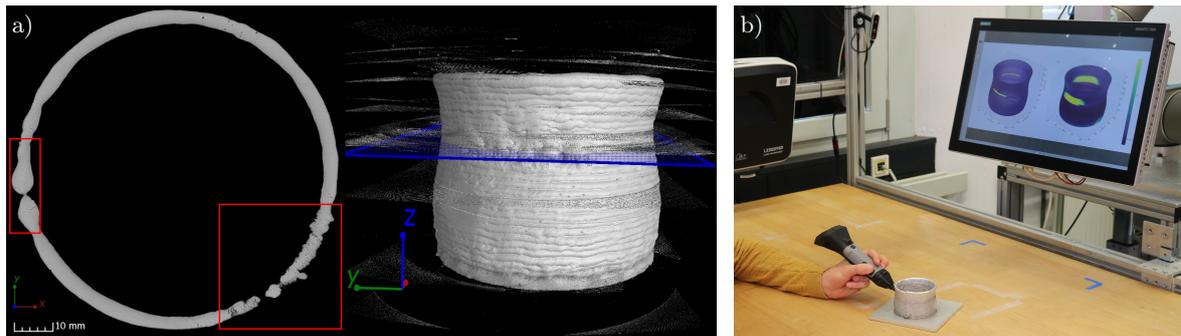


Abbildung 3.7: Annotation von Defekten im WAAM-Bauteils mithilfe a) des CT-Scans mit rötlich markierten Defekten und b) eines räumlichen Sensors am Bauteil unter Nutzung der Qualitätsmetriken auf Basis der unüberwachten Anomaliedetektion

$$ACC = 0.957.$$

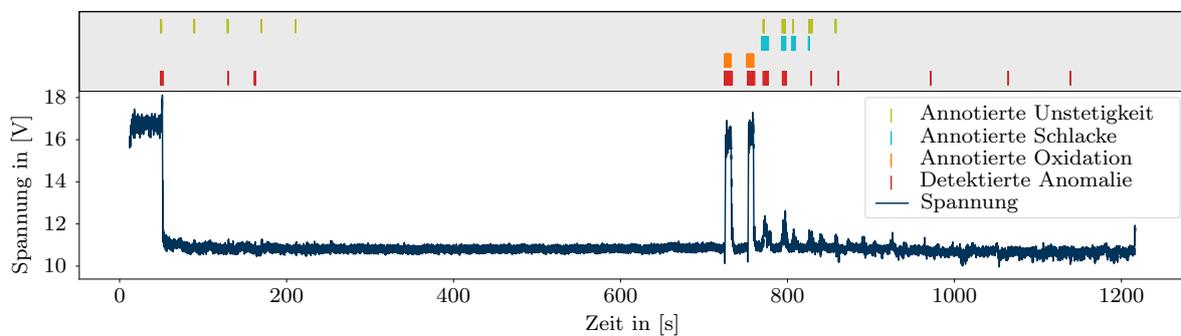


Abbildung 3.8: Vergleich der zeit- und raumbasierten Defektannotation entlang des zeitlichen Verlaufs der über 0.5 s gemittelten Schweißspannung

Die quantitative Analyse zeigte jedoch, wie in [P10] näher ausgeführt, die Grenzen der räumlichen Annotationsmethode auf. Es ergab sich eine räumliche Unschärfe der Annotationen, welche auf die Diskretisierung des Werkzeugpfads zurückging. Das um die singulären TCP-Positionen liegende Volumen konnte keiner TCP-Position unmittelbar zugewiesen werden, sodass die Nutzung des räumlichen Unschärfeparameters erforderlich war. Eine Erhöhung des räumlichen Unschärfeparameters reduzierte die Anzahl an FN-Werten bei der Annotation, gleichzeitig erhöhte sich jedoch die Anzahl der FP-Werte. Analog zum Grenzwert bei der PR-Kurve beeinflusste der Unschärfeparameter damit maßgeblich die Sensitivität und Genauigkeit der räumlichen Annotation. Um Normaldaten für das semiüberwachte Training eines Anomaliedetektors zu erhalten, wurde deshalb ein hoher Unschärfeparameter gewählt. Wie in [P10] gezeigt, wurde die räumliche Annotation bei der Untersuchung der Qualität nutzerfreundlicher als die manuelle zeitliche Annotation wahrgenommen. Sie führte trotz der gegenläufigen quantitativen Ergebnisse zu einem erhöhten Nutzervertrauen hinsichtlich der Genauigkeit der Annotationen.

3.5 Zusammenfassung

Innerhalb dieses Kapitels wurde die digitale Bauteil- und Prozessrepräsentation vorgestellt, mit deren Hilfe Kontext bereitgestellt werden kann. Der Kontext wurde in Systemkontext,

räumlichen und zeitlichen Kontext unterteilt. Für den Systemkontext wurde ein OPC UA Informationsmodell sowie ein Prozesszustandsmodell aufgebaut. Die zeitliche Einordnung wurde durch eine zeitliche Indexierung aller Dateninstanzen erreicht. Der räumliche Kontext konnte durch die Einführung eines Octrees und einer Raumzeitindexierung nutzbar gemacht werden. Es wurden drei Geometrien für die räumliche Relevanz definiert, um relevante Datenpunkte für die räumliche Kontextbereitstellung zu extrahieren.

Zu Beginn des Prozesses lag mit dem statischen Octree ein Digitales Modell vor. Durch die unidirektionale Datenanbindung während des Prozesses spiegelte die Repräsentation mit der zeitbasierten Datenbank und dem dynamischen Octree das Werkstück bzw. den Prozess wider, sodass es sich um einen Digitalen Schatten handelte. Ein Digitaler Zwilling kann auf Basis dieses Digitalen Schattens entstehen, wenn die unidirektionale Datenanbindung, wie in Kapitel 5 beschrieben, um einen Informationsfluss zum Prozess ergänzt wird.

Die vorgestellte Struktur konnte darüber hinaus als Informationsträger für Optimierungsschritte in der Prozess- und Produktentwicklung sowie für die Qualitätssicherung genutzt werden. Um die Anbindung an diese Schritte der Produktentstehung zu ermöglichen, wurde eine Methodik zur räumlichen Annotation von Zeitreihen vorgestellt. Die erhaltenen Annotationen wurden für das Training und die Evaluierung der in Kapitel 4 vorgestellten Methoden zur Anomaliedetektion und Defektklassifikation genutzt.

Kapitel 4

Prozessmodellierung und -überwachung

4.1	Prozessanalyse und -modellierung	54
4.1.1	Prozessbeschreibung	54
4.1.2	Sensorauswahl	57
4.1.3	Referenzprozess und Sensordaten	58
4.2	Detektion von Prozessanomalien	60
4.2.1	Detektorauswahl	61
4.2.2	Autoencoder zur Anomaliedetektion	63
4.2.3	Multivariate Anomaliebewertung	67
4.3	Klassifizierung von Prozessdefekten	67
4.3.1	Datenvorverarbeitung	68
4.3.2	Modellbildung	69
4.4	Bestimmung des Abstands zwischen Bauteil und Schweißbrenner	70
4.5	Evaluierung	72
4.5.1	Evaluierung der Anomaliedetektion	72
4.5.2	Evaluierung der Defektklassifikation	78
4.5.3	Evaluierung der Abstandsmessung	80
4.6	Zusammenfassung	85

In der Prozessüberwachung werden Prozessdaten ausgewertet, um Informationen über den Prozess abzuleiten und sie den Modulen des Digitalen Zwillings zur Verfügung zu stellen. Einerseits sollen abnormales Prozessverhalten sowie Bauteildefekte prozessparallel erkannt und so die Prozessstabilität und die resultierende Bauteilqualität bewertet werden. Dabei ist eine Übertragbarkeit auf unbekannte Prozessparametersätze bei geringem Aufwand zur Anpassung zu gewährleisten. Andererseits ist eine Messung physischer Prozessgrößen notwendig. Besondere Bedeutung kommt dabei dem Abstand zwischen Schweißbrenner und Bauteil zu, der richtungs- und schichtunabhängig gemessen werden soll, um dem voll 3D-fähigen WAAM-Prozess gerecht zu werden.

Aus dem in Abschnitt 2.4 abgeleiteten Forschungsbedarf (B1, B4 und B6) sowie den Anforderungen an den Digitalen Zwilling ergeben sich folgende Anforderungen an die Prozessüberwachung:

1. Erkennung abnormalen Prozessverhaltens ohne Referenzdatensatz
2. Kontextsensitive Defektklassifikation
3. Übertragbarkeit auf andere Prozessparametersätze
4. Richtungs- und schichtinvariante Abstandsmessung

5. Prozellparallele Inferenz der Modelle

Um diese Anforderungen zu erfüllen werden die Schritte der CRISP-DM-Methode durchlaufen. Zunächst wird im Abschnitt 4.1 ein Daten- und Prozessverständnis aufgebaut und der WAAM-Prozess datenbasiert analysiert und modelliert. Dazu werden ein Referenzprozess und die Referenzsensorik inklusive typischer Sensordaten vorgestellt. Es folgen drei Abschnitte zur Datenauswertung, welche die Datenvorbereitung und die Modellierung umfassen. Zuerst wird in Abschnitt 4.2 auf die unüberwachte Detektion von Anomalien eingegangen. Es folgt Abschnitt 4.3 mit der Vorstellung der Methodik zur kontextsensitiven Defektklassifizierung. Abschließend wird in Abschnitt 4.4 dargelegt, wie der Abstand zwischen Bauteil und Schweißbrenner prozessparallel extrahiert werden kann. In Abschnitt 4.5 werden die genannten Methoden evaluiert und in Abschnitt 4.6 eine Zusammenfassung der Ergebnisse gegeben. Die Bereitstellung der Modelle wird im Validierungskapitel 6 demonstriert. Teile dieses Kapitels wurden bereits in Publikationen [P1, P2, P4, P6, P8] der Fachöffentlichkeit vorgestellt. Darüber hinaus wurden vom Autor dieser Schrift zu einzelnen Aspekten dieses Kapitels Studienarbeiten [S1, S4, S6, S8, S9, S13, S14, S15] ausgeschrieben und betreut.

4.1 Prozessanalyse und -modellierung

Als Grundlage für die prozessparallele Datenauswertung dienen eine physikalische Prozessbeschreibung sowie eine Ursachen-Wirkungs-Analyse, um die Einflussfaktoren auf Unregelmäßigkeiten in den gemessenen Prozessdaten zu bestimmen. Auf deren Basis erfolgt die Sensorauswahl. Die Sensordaten nutzend wird eine digitale Prozessmodellierung anhand eines WAAM-Referenzprozesses vorgenommen.

4.1.1 Prozessbeschreibung

Wie in Abbildung 4.1 schematisch dargestellt kommt bei Nutzung von CMT-basiertem WAAM ein Schweißbrenner zum Einsatz, bei dem der Draht durch eine Schutzgasdüse geführt und über ein Kontaktrohr mit Strom und Spannung beaufschlagt wird. Zwischen Drahtende und Bauteil wird ein Lichtbogen gezündet. Das Schmelzbad umfasst die flüssige Phase des aufgetragenen Materials.

Neben Stromstärke, Spannung, Schutzgasfluss und Drahtvorschubgeschwindigkeit beeinflusst eine Vielzahl weiterer Prozessparameter den Prozess und die Bauteilqualität. So führt beispielsweise die Kippung des Schweißbrenners zu einem stechenden oder schleppenden Schweißprozess und verändert die Dynamik der Schmelze entsprechend [P1]. Der Abstand zwischen Schweißbrenner und Bauteil beeinflusst die Schutzgasatmosphäre am TCP. Prozessparameter sind Sollgrößen, welche die Steuerungen von Schweißquelle und Kinematik vorgeben. Abweichungen der Istgrößen von den Sollgrößen weisen auf Defekte wie beispielsweise verunreinigungsbedingte Schlackeeinschlüsse oder Bindefehler hin oder induzieren selbst Defekte wie beispielsweise Poren. Defekte können darüber hinaus auf ungeeignete Prozessparameter, instabile Umgebungsbedingungen wie beispielsweise Turbulenzen oder andere Ursachen wie Verschleiß des Kontaktrohrs oder Verschmutzungen des Drahtes und des Substrats zurückgeführt werden. Einen zusätzlichen Einblick in den Prozess geben Prozessemissionen. So erzeugt der Lichtbogen intensivere Lichtemissionen, wenn statt CMT CMT-P verwendet wird oder wenn ein Oxidationsdefekt entsteht. Die Ionisierung des Prozessgases führt zu Luftschallemissionen. Der

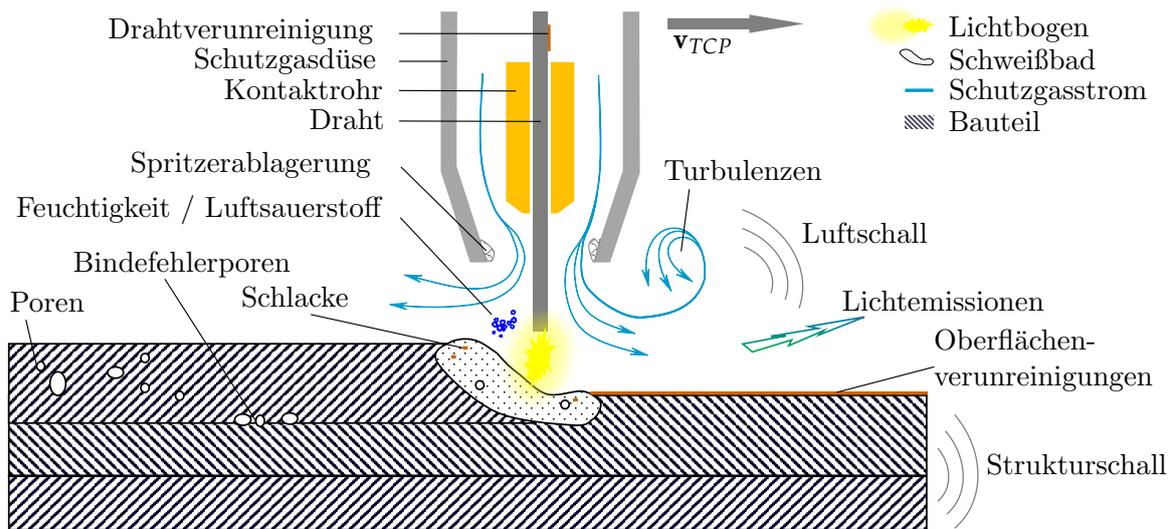


Abbildung 4.1: Schematische Darstellung der Schweißregion inklusive möglicher Defekte (Poren, Schlacke, ...) und ihrer Ursachen (Spritzerablagerungen, Turbulenzen, Verunreinigungen, Feuchtigkeit, ...) sowie Prozessemissionen

oszillierende Draht, die Tropfenablösung und der elektrische Kurzschluss führen zu Vibrationen im Bauteil. Diese Prozessemissionen können durch geeignete Sensorik gemessen werden. Alle Daten, die prozessparallel beispielsweise in Form von Messwerten anfallen, werden nachfolgend als Prozessdaten bezeichnet.

Unregelmäßigkeiten in den Prozessdaten lassen sich nicht nur auf Defekte zurückführen. Aus diesem Grund wurde eine Ursachen-Wirkungs-Analyse vorgenommen, welche in Abbildung 4.2 als Ishikawa-Diagramm dargestellt ist. Die Ursachen für Unregelmäßigkeiten in den Prozessdaten wurden dafür in die sechs Kategorien Mensch, Maschine, Umgebung, Material, Prozess und Messung eingeteilt. Es ist zu berücksichtigen, dass die verschiedenen Prozessdaten auf unterschiedliche Art und Weise und zum Teil nicht von allen vorgestellten Ursachen beeinflusst werden.

Ursachen für Unregelmäßigkeiten, die auf Defekte zurückgehen, sind vielfältig und finden sich in allen Bereichen des Ishikawa-Diagramms. Beispielsweise können Verunreinigungen im Schutzgas zu Porosität im Bauteil und ein verschlissenes Kontaktrohr zu einem instabilen Lichtbogen führen. Gegebenenfalls kann auch die Messung selbst den Prozess beeinflussen. Einige Unregelmäßigkeiten in den Prozessdaten gehen jedoch auf Ursachen zurück, die die Messungen bestimmter Sensoren negativ beeinträchtigen auch wenn keine Auswirkung auf die Prozessstabilität und Bauteilqualität vorliegt. Diese Ursachen sind im Ishikawa-Diagramm kursiv und farblich in blau hervorgehoben und sie gilt es durch geeignete Maßnahmen, sowohl auf Hardware- als auch auf Softwareseite, zu beheben, da sie die Defekterkennung erschweren. Sensorwerte können aufgrund von Kommunikationsfehlern, einer ungeeigneten Abtastrate, Messrauschen und -fehler zu falschen Schlüssen führen. Messfehler können beispielsweise auf eine galvanische Kopplung im Messsystem zurückzuführen sein, die durch die Nutzung von Optokopplern vermieden wird. WAAM-Start- und Stopsequenzen und Prozessparameteränderungen führen zu Prozessdaten, die sich von den Normaldaten unterscheiden. Diese Daten können durch die Nutzung des Systemkontexts eingeordnet und entsprechend bewertet werden. Die im Prozess zunehmenden Abmessungen des Bauteils führen zu einer Konzeptverschiebung in den Sensorwerten, beispielsweise im Falle der Strukturschallemissionen. Die Kombination mehrerer Ursachen wie beispielsweise des Werkzeugpfads mit der Sensorposition und -orientierung kann in einer Verdeckung der Sicht des Sensors auf den ROI oder in Re-

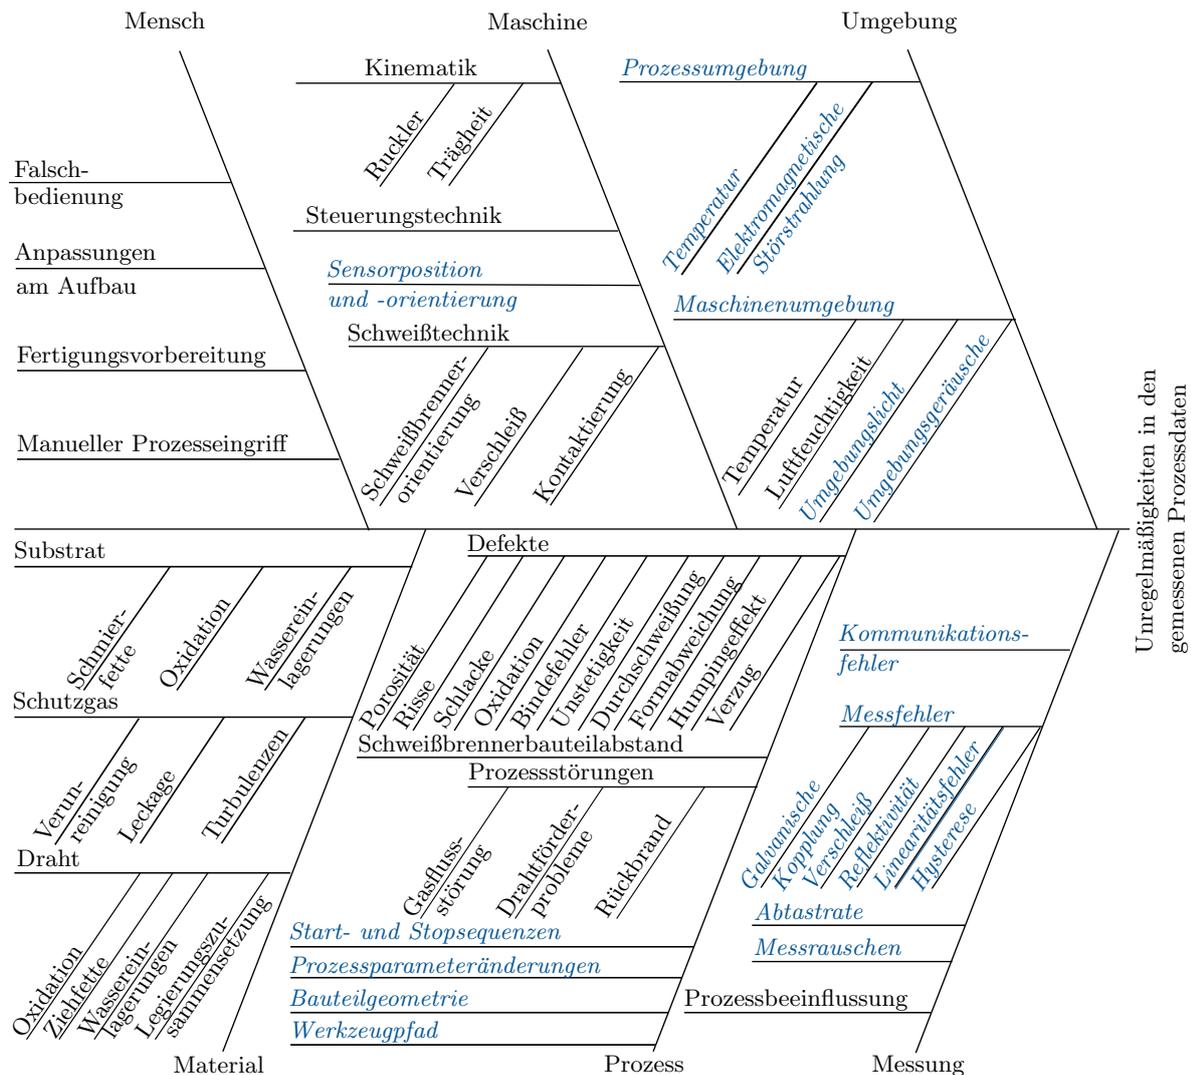


Abbildung 4.2: Ishikawa-Diagramm zur Darstellung der Ursachen für Unregelmäßigkeiten in den gemessenen WAAM-Prozessdaten

flexionen resultieren. Dies gilt besonders für die Sensoren, die ohne Gegenmaßnahmen eine Richtungsabhängigkeit aufweisen. Auch die Maschinen- und Prozessumgebung kann Einfluss auf die Sensorwerte nehmen ohne den Prozess zu beeinflussen. Beispielsweise kann eine sich im Laufe des Tages verändernde Umgebungsbeleuchtung zu Konzeptverschiebungen in den Messwerten optischer Sensoren führen. Optische Messungen können darüber hinaus durch die optische Strahlung des Lichtbogens beeinträchtigt werden. Niederfrequenter elektromagnetische Strahlung des Schweißprozesses kann als Störstrahlung die Messungen der Sensorik in der unmittelbaren Umgebung des Schweißprozesses beeinflussen. Umgebungsgeräusche können eine Störquelle für akustische Messungen sein. Die Temperatur und die Luftfeuchtigkeit können die Messgenauigkeit der Sensoren verändern.

Verbleibende Unregelmäßigkeiten in den Prozessdaten sind als Anomalien zu detektieren, da sie auf einen fehlerhaften Prozess hindeuten. Sie können beispielsweise in Form von Änderungen der Prozessfrequenz, der CMT-Muster und der Intensität der Signale auftreten. Unter der Annahme, dass alle Defekte in den Prozessdaten zu erkennen sind, kann die Menge aller Defekte D als Teilmenge der Menge aller Anomalien A gesehen werden:

$$D \subset A \quad (4.1)$$

Anomalien in den Prozessdaten müssen nicht in einem physischen Defekt resultieren beziehungsweise auf einen solchen zurückzuführen sein, da es sich beispielsweise um eine Prozessinstabilität ohne Einfluss auf die Bauteilqualität oder um einen Messfehler handeln kann. Mithilfe der in Abschnitt 3.3 vorgestellten Vorgehensweise werden prozessnachgelagert lediglich physische Defekte, die in den Daten der Qualitätssicherung ersichtlich sind, als TP-Defekt annotiert. Defekte können zudem durch ein erneutes Aufschmelzen des Bauteilbereichs auf Grund des additiven Aufbaus verschwinden. Sie sind dann als Anomalien in den Daten detektierbar, können jedoch nicht im Rahmen der räumlichen Zeitreihenannotation markiert werden. Bei den Versuchen zur Evaluierung der Anomaliedetektion und Defektklassifizierung werden Defekte basierend auf den Zusammenhängen im Ishikawa-Diagramm aus Abbildung 4.2 herbeigeführt.

4.1.2 Sensorauswahl

Auf Basis der physikalischen Prozessbeschreibung und der Ursachen-Wirkungs-Analyse wird eine systematische Auswahl der Sensorik nach dem VDMA-Leitfaden *Sensorik für Industrie 4.0* [248] vorgenommen. Dazu werden in den fünf Bereichen Sensortyp, Kommunikationstechnologie, Datenverarbeitung, mechanische Integration und Informationsgenerierung morphologische Kästen aufgespannt und für den WAAM-Prozess relevante Ausprägungen ausgewählt. Das Ergebnis dieser Untersuchung ist nachfolgend kondensiert anhand der Antworten auf die sieben Leitfragen des Leitfadens dargestellt.

1. Die **Sensoranwendung** soll den WAAM-Prozess überwachen, um auf die Prozessstabilität und die Bauteilqualität zu schließen und den Prozess zu optimieren.
2. Die **Messgrößen** sind die definierten Prozessparameter (Strom, Spannung, Gasfluss, Drahtvorschub und Schweißbrenner-Bauteil-Abstand) sowie Prozessemissionen (Licht-, Luftschall- und Strukturschallemissionen).
3. Der **Bauraum** der Sensorik darf die Fertigung nicht behindern. Gleichzeitig muss die Sensorik so orientiert und positioniert sein, dass sie auch bei komplexen Werkzeugpfaden eingesetzt werden kann.
4. Die **Umgebungsbedingungen** sind primär vom Schweißprozess geprägt. Die Sensorik muss hohe Temperaturen aushalten. Zudem ist der Lichtbogen aufgrund der hohen Intensität eine elektromagnetische Störquelle. Trotz der sich während des Prozesses ändernden Orientierung des Schweißbrenners ist eine Richtungsabhängigkeit des Sensorsignals zu vermeiden. Es kann zu Schweißrauch kommen.
5. Die **Messsignale** sollen den relevanten Messbereich abbilden und eine ausreichend hohe Messgenauigkeit aufweisen, um im WAAM-Umfeld nutzbare und verlässliche Werte zu liefern. Sie sollen darüber hinaus eine Abtastrate $f_s > 17 \text{ Hz}$ bereitstellen, um bei einer Schweißgeschwindigkeit von 1000 mm min^{-1} je Millimeter mindestens einen Datenpunkt bereitzustellen.
6. Ein **Ausfall oder eine Fehlfunktion** führt zu einer fehlenden Produktqualifizierung und erzeugt Zusatzkosten in der Qualitätssicherung. Sofern ein Prozesseingriff auf Basis der Sensordaten stattfindet, kann bei Sensorfehlfunktion eine Gefährdung für die Maschine vorliegen.
7. Je Maschine ist die **Anzahl an Sensoren** zu begrenzen, um unnötige Kosten zu vermeiden.

Als Sensoren zur Überwachung der durch Prozessparameter definierten Prozessgrößen werden ein Stromsensor, ein Spannungssensor, ein Gasflusssensor sowie ein Drahtvorschubsensor genutzt. Die Daten dieser Sensoren sind unabhängig von der Schweißrichtung und können unmittelbar mit den Sollgrößen verglichen werden. Zur Betrachtung der Auswirkungen der Prozessparameter wird eine Schweißkamera mit aktiver Beleuchtung, ein Spektrometer, ein Mikrofön und ein Strukturakustiksensoren eingesetzt. Ihre Sensormessungen sind richtungsabhängig. Zusätzliche Sensoren zur Messung des Schweißbrenner-Bauteil-Abstands wie beispielsweise Laserlinienscanner, Ultraschallsensoren oder induktive Sensoren werden aufgrund der Richtungsabhängigkeit der Messung sowie der Beeinflussung der Messwerte durch den Lichtbogen verworfen. Ein Pyrometer sowie eine thermographische Kamera werden zwar in den Systemaufbau integriert, zeigen jedoch bei den in dieser Arbeit hauptsächlich verwendeten Aluminiumlegierungen aufgrund der unbeständigen Oberflächenreflektivität keine verlässlichen Messwerte.

Für die prozessnachgelagerte Qualitätssicherung und die Annotation der Datensätze werden zudem eine Kamera, ein Laserlinienscanner, ein Röntgenscanner sowie ein Computertomograph genutzt. Da die raue Oberfläche von WAAM-Bauteilen ohne Nachbearbeitung zu Artefakten im Scan führt, wird keine Untersuchung mittels Ultraschall und Wirbelstromsensoren vorgenommen.

4.1.3 Referenzprozess und Sensordaten

Während in Abschnitt 3.1 aus ganzheitlicher Perspektive eine digitale Bauteil- und zustandsbasierte Prozessrepräsentation erstellt wurde, wird nun der Fokus auf die digitale Modellierung des Prozesses im Detail anhand von Sensordaten gelegt. Dazu werden die Sensordaten eines CMT-Referenzprozess im Zeitbereich weniger CMT-Zyklen beispielhaft dargestellt. Die Prozessparameter des Referenzprozesses sind in Tabelle 4.1 festgehalten.

Tabelle 4.1: Prozessparameter für den CMT-basierten WAAM-Referenzprozess inklusive ihrer Formelzeichen, Einheiten und Ausprägungen

Prozessparameter	Formelzeichen	Ausprägung	Einheit
Drahtvorschubgeschwindigkeit	v_{WF}	3.8	m min^{-1}
Strom	I	62	A
Spannung	U	11.7	V
Schweißgeschwindigkeit	v_{TCP}	350	mm min^{-1}
Gasfluss	f_g	8	L min^{-1}
Schutzgas		Argon 4.5	
Draht- und Substratmaterial		AlSi5	
Drahtdurchmesser	d_w	1.2	mm

Jeder CMT-Zyklus durchläuft die in Abschnitt 2.1.2 vorgestellten drei Phasen, welche durch die oszillierende Bewegung des Drahtes sowie durch ein charakteristisches Strom- und Spannungsprofil gekennzeichnet sind. Hochgeschwindigkeitskamerabilder der einzelnen Phasen sind in Abbildung 4.3 dargestellt. Zunächst wird in a) der Draht mit Spannung beaufschlagt, bis die Lichtbogenzündung stattfindet. Infolgedessen wird der Lichtbogen in b-i) stabilisiert und der Draht in Richtung des Schweißbads geschoben. An der Spitze des Drahts entsteht ein Tropfen geschmolzenen Materials. Bei Berührung mit dem Schmelzbad in b-ii) erfolgt ein Kurzschluss. Der Tropfen löst sich begleitet von einem diesen Vorgang unterstützenden Rückziehbewegung des Drahts in c) ab, bis keine Verbindung mehr zwischen Schweißbad und Draht besteht und

ein neuer CMT-Zyklus startet.

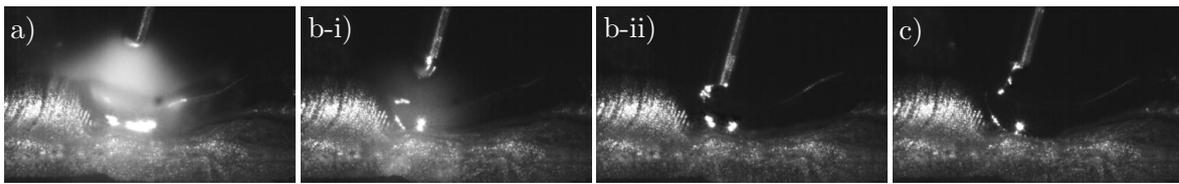


Abbildung 4.3: Aufnahmen des CMT-Prozesses mit einer Hochgeschwindigkeitskamera: a) Lichtbogenzündung, b-i) Stabiler Lichtbogen und Tropfenbildung, b-ii) Kurzschluss, c) Tropfenablösung und Drahrückziehbewegung

In den Strom- und Spannungsdaten spiegelt sich dieser Ablauf wider. Wie in Abbildung 4.4 gezeigt, liegen in Phase a) bei Lichtbogenzündung erhöhte Strom- und Spannungswerte an. In Phase b) sind reduzierte Hintergrundstrom- und -spannungswerte zu sehen und in Phase c) wird die Spannung stark reduziert um einen hohen Kurzschlussstrom zu vermeiden. In der Abbildung 4.4 sind Zeitreihenmerkmale im Strom- und Spannungsverlauf benannt, welche für die Defektklassifizierung (Abschnitt 4.3) und die Messung des Abstands zwischen Schweißbrenner und Bauteil (Abschnitt 4.4) genutzt werden.

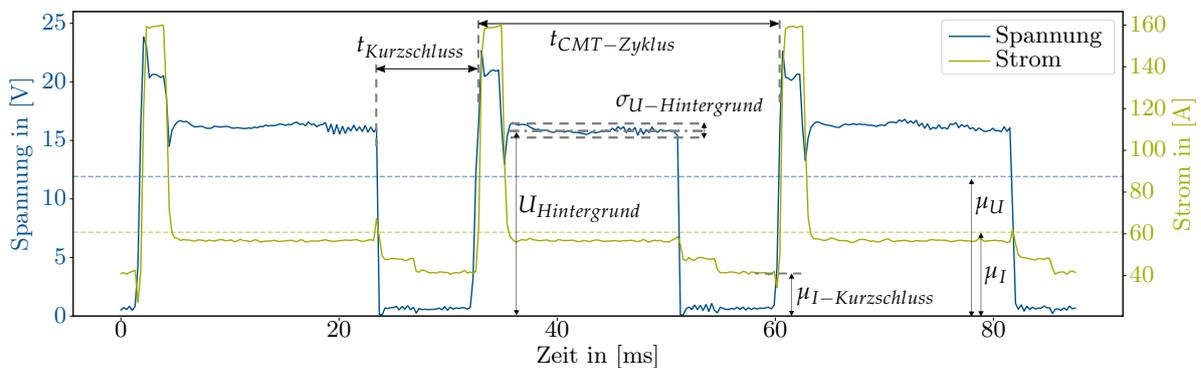


Abbildung 4.4: Modellierung des WAAM-Referenzprozesses mittels Strom- und Spannungsdaten für drei CMT-Zyklen inklusive Benennung relevanter Merkmale

Es handelt sich dabei um den durchschnittlichen Strom μ_I und die durchschnittliche Spannung μ_U , um den Kurzschlussstrom $\mu_{I\text{-Kurzschluss}}$, um die Hintergrundspannung $U_{\text{Hintergrund}}$ und deren Standardabweichung $\sigma_{U\text{-Hintergrund}}$, um die Zeit des gesamten CMT-Zyklus $t_{\text{CMT-Zyklus}}$ sowie um die Zeit des Kurzschlusses $t_{\text{Kurzschluss}}$. Zusätzlich wird das Verhältnis $r_{\text{Zyklusphasen}}$ der Kurzschlusszeit zur gesamten Zykluszeit mittels Gleichung 4.2 berechnet:

$$r_{\text{Zyklusphasen}} = \frac{t_{\text{Kurzschluss}}}{t_{\text{CMT-Zyklus}}} \quad (4.2)$$

Beim CMT-Prozess wird der Strom unter Nutzung der Spannung als Stellgröße geregelt, sodass sich korrelierte Wertverläufe ergeben. Die Verläufe weisen zudem jeweils eine hohe Autokorrelation auf, die auf den sich mit einer Frequenz zwischen 30 Hz und 180 Hz wiederholenden CMT-Zyklus zurückgeht.

Wie in Abbildung 4.5 zu sehen ist, lässt sich die CMT-zyklusbedingte Saisonalität zudem in den Daten des Strukturakustiksensors sowie in den Daten des Mikrofons finden, wobei Rauschen sowie eine geringere Abtastrate die CMT-Phasendifferenzierung erschweren. Der Verlauf der Strukturakustikdaten verhält sich analog zu den Strom- und Spannungsdaten, wohingegen die Luftschallemissionen Ausschläge zeigen, die den Gradienten des Spannungsverlaufs ähneln, sofern die jeweiligen Abtastraten der Sensoren berücksichtigt werden.

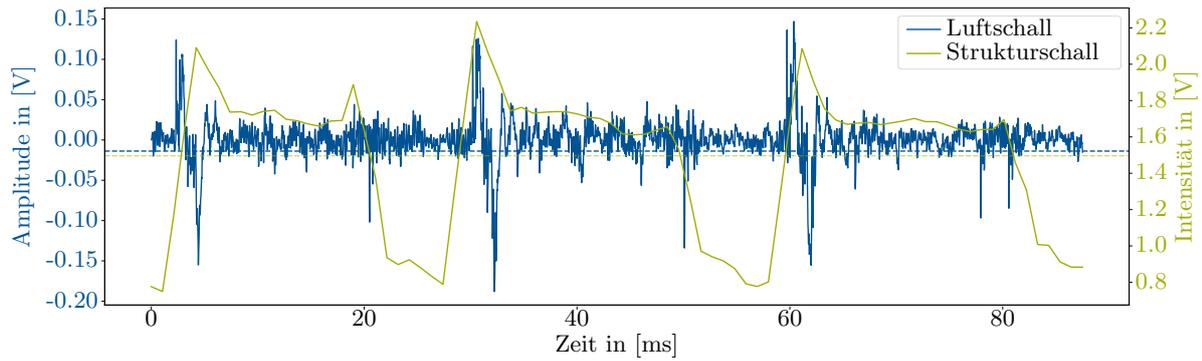


Abbildung 4.5: Modellierung des Referenzprozesses mittels Struktur- und Luftschallemissionen für drei CMT-Zyklen

Das Spektrometer misst zeit- und wertdiskret das Prozessspektrum, womit sich eine Zeitreihe von Vektoren ergibt. In Abbildung 4.6 ist ein über einen Zeitraum von drei CMT-Zyklen gemitteltetes Spektrum für den WAAM-Prozess dargestellt, welches aus der Superposition von diskreten Peaks und der kontinuierlichen Schwarzkörperstrahlung entsteht. Die Peaks gehen auf die Anregung von Elementen der Schutzgasatmosphäre (hauptsächlich Argon Ar, Sauerstoff O und Stickstoff N) und der Draht- und Substratlegierungselemente (u.a. Aluminium Al und Magnesium Mg) sowie auf Störquellen wie beispielsweise das Umgebungslicht zurück. Die Schwarzkörperstrahlung lässt sich auf erhitzte Körper im Fokus des Spektrometers wie beispielsweise das Schweißbad zurückführen. Sie lässt sich durch Subtraktion der unteren Hüllkurve vom Spektrum ausblenden.

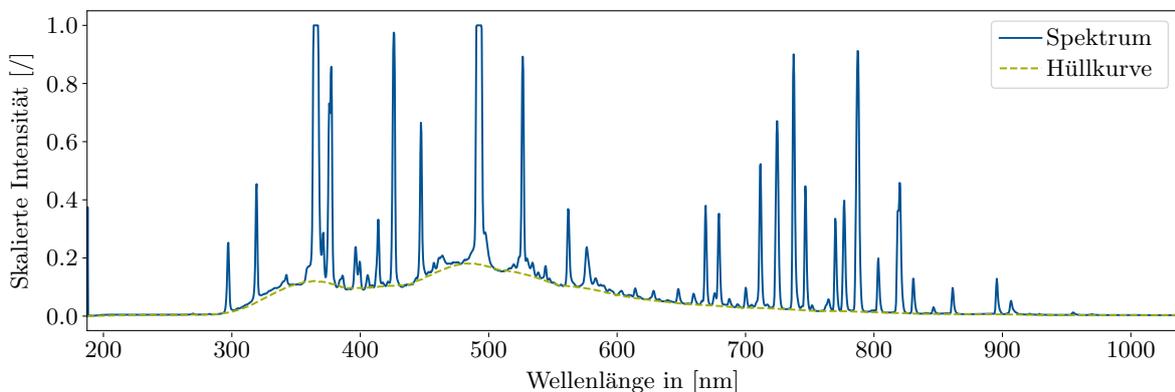


Abbildung 4.6: Spektrum des Referenzprozesses gemittelt über drei CMT-Zyklen bestehend aus der kontinuierlichen Schwarzkörperstrahlung und diskreten Peaks

Die Prozessdaten für Gasfluss und Drahtvorschub weisen einen annähernd konstanten Wert auf, wobei sich eine Gaußsche Verteilung um die gesetzten, stationären Prozessparameterwerte einstellt.

4.2 Detektion von Prozessanomalien

Die Sensordaten der Prozessüberwachung liegen als Zeitreihen vor. Die Detektion von Prozessanomalien soll prozessparallel die robuste und prozessparametersatzadaptive Erkennung von Unregelmäßigkeiten in diesen Zeitreihen ermöglichen. Um einen modularen Aufbau des

Digitalen Zwillingen zu ermöglichen, wird jeder Sensordatenstrom separat betrachtet. Die Anomaliedetektion ist damit ohne die Datenfusionsmethodik aus Abschnitt 4.2.3 univariat. Da annotierbare Defekte lediglich eine Teilmenge aller Anomalien ausmachen, führt die räumliche Annotation der Zeitreihen (Abschnitt 3.3) zu einem nur teilweise annotierten Datensatz für den Anwendungsfall der Anomaliedetektion. Anomalien sind jedoch per Definition selten, sodass die als defektfrei annotierten Daten als überwiegend normal anzusehen ist. Damit handelt es sich um ein semiüberwachtes Anomaliedetektionsproblem, bei dem die negative Ausprägung bekannt ist. Diese Betrachtungsweise fördert zudem die Übertragbarkeit auf neue Prozesskonditionen, da im Falle eines normalen Prozesses auf eine umfassende Datenannotation verzichtet werden kann.

Nachfolgend wird zunächst eine Methodik zur semi-automatisierten Auswahl eines geeigneten Detektors für das beschriebene Anomaliedetektionsproblem vorgestellt. Dadurch kann bei Nutzung eines neuen Sensors oder im Falle eines neuen Prozesses ein geeigneter Anomaliedetektor bestimmt werden. Anschließend wird auf die Anomaliedetektion mittels Autoencodern eingegangen. Es wird ein konditionierter, speichererweiterter Autoencoder vorgestellt, welcher modellbasiertes Metalernen für die Anomaliedetektion ermöglicht. Abschließend folgt ein Abschnitt zur Datenfusion mittels Mahalanobisdistanz, mithilfe derer eine kondensierte Aussage über Prozessanomalien für die multivariate Prozessüberwachung getroffen wird.

4.2.1 Detektorauswahl

Zur un- und semiüberwachten Detektion von Anomalien in Zeitreihen können diverse Detektoren eingesetzt werden, welche sich, wie in Kapitel 2.3 gezeigt, in distanz- und wahrscheinlichkeitsbasierte, prädiktionsbasierte und rekonstruktionsbasierte Methoden einteilen lassen. Bei der Wahl eines geeigneten Detektors ist zu beachten, dass die Leistungsfähigkeit eines Detektors von den Merkmalen des Datensatzes sowie von der Art der Anomalie abhängt. Daten mit Saisonalität erfordern andere Detektoren als stationäre Daten. Um semi-automatisiert einen potentiell optimalen Anomaliedetektor für ein Sensorsignal vorzuschlagen, wird die Auswahl eines geeigneten Anomaliedetektors deshalb nachfolgend auf eine Zuordnungsaufgabe zurückgeführt, die mithilfe dreier Schritte gelöst wird:

1. Evaluierung von Detektoren anhand der verfügbaren Zeitreihen
2. Extraktion von Merkmalen der verfügbaren Zeitreihen
3. Anlernen eines Klassifikationsmodells zur Zuordnung von Zeitreihenmerkmalen und Detektionsleistungen

Das angelernte Klassifikationsmodell ermöglicht schlussendlich die Auswahl eines geeigneten Detektors für eine neue Zeitreihe anhand ihrer Zeitreihenmerkmale.

Evaluierung der Detektoren

Im ersten Schritt werden vollständig annotierte Zeitreihen zur Anomaliedetektion herangezogen. Sie sollten eine hohe Varianz hinsichtlich ihrer Eigenschaften aufweisen und können beispielsweise aus öffentlich zugänglichen Benchmarkdatensätzen stammen. Die Zeitreihen werden jeweils in Trainings- und Testdaten unterteilt, wobei die Trainingsdaten den ersten 65 % der Datenpunkte jeder Zeitreihe entsprechen und der verbleibende Teil als Testdaten für die Evaluierung genutzt werden. Um sicherzustellen, dass die Evaluierungsmetriken auf Basis

mehrerer Anomalien berechnet werden können, werden alle Datensätze, welche weniger als fünf Anomalien in den Testdaten aufweisen, verworfen. Jede Zeitreihe T wird in n Subsequenzen $\mathbf{t}_k \in \mathcal{R}^u$ der Länge u mit $k \in 1, \dots, n$ eingeteilt. Für die rekonstruktionsbasierten Methoden bedeutet eine Anomalie innerhalb einer Subsequenz, dass die gesamte Subsequenz als Anomalie zu werten ist. Für die prädiktionsbasierten Methoden wird der Anomaliewert des vorherzusagenden Datenpunkts als Referenz herangezogen. Bei distanz- und wahrscheinlichkeitsbasierten Methoden wird jeder Datenpunkt separat betrachtet.

Mithilfe der Trainingsdaten werden die Anomaliedetektoren unüberwacht angelernt. Die betrachteten distanz- und wahrscheinlichkeitsbasierten Verfahren zur Anomaliedetektion umfassen LOF, DBSCAN, K-Means, OC-SVM und Isolation Forest. Die prädiktionsbasierten Verfahren schließen AR, MA, ARIMA, SARIMA, ES, SES, MLP, LSTM und CNN ein. Als rekonstruktionsbasierte Methoden kommen ein MLP-AE, ein LSTM-AE und ein CNN-AE zum Einsatz. Für alle Datensätze werden die in den Tabellen C.3, C.4 und C.5 im Anhang notierten Detektorhyperparameter genutzt. Die angelernten Detektoren werden jeweils mit den Testdaten evaluiert, sodass am Ende vom ersten Schritt jedem Detektor für jeden Datensatz ein PR AUC-Wert zugeordnet werden kann. Die Auswahl des PR AUC-Werts als Evaluierungsmetrik geht auf den unüberwachten Charakter des Anomaliedetektionsproblems zurück. Bei der Detektorauswahl kann nicht vorausgesetzt werden, dass der Datensatz annotiert ist, so dass kein optimaler Grenzwert bestimmt werden kann. Aus diesem Grund erfordert die Detektorauswahl eine Evaluierungsmetrik, welche unabhängig von einem spezifischen Grenzwert ist.

Merkmalsextraktion der Zeitreihen

Schritt zwei schafft eine abstrahierte Darstellung der Zeitreihen, indem die nach Lubba et al. [165] 22 relevantesten Merkmale der Zeitreihen extrahiert werden. Eine Übersicht über diese Merkmale ist in Tabelle C.2 im Anhang zu finden.

Zuordnung des Detektors zur Zeitreihe

Im dritten Schritt werden die Zeitreihenmerkmale mit den Evaluierungsergebnissen der Detektoren in Verbindung gesetzt. Dazu wird ein Klassifikationsmodell überwacht angelernt. Als Eingangsgröße dienen die Vektoren der Zeitreihenmerkmale für jeden Datensatz. Die Zielgröße ist jeweils der Detektor mit dem besten PR AUC-Wert. Als Klassifikationsmodelle werden ein Random-Forest-Algorithmus, eine SVM und ein MLP genutzt. Die Modelle werden miteinander hinsichtlich ihrer F_1 -Werte und Treffergenauigkeiten verglichen.

Mithilfe des resultierenden Klassifikationsmodells wird für jeden WAAM-Sensordatenstrom ein geeigneter Detektor automatisiert vorgeschlagen. Während die meisten der WAAM-Sensoren skalare Werte ($t \in \mathbb{R}^1$) bereitstellen, handelt es sich beim Spektrometer um einen Vektor ($\mathbf{t} \in \mathbb{R}^u$) und bei der Schweißkamera um eine Matrix ($\mathbf{t} \in \mathbb{R}^{u \times v}$). Vektoren und Matrizen können beispielsweise durch eine Mittlung der Einträge auf einen skalaren Wert komprimiert werden, sodass die vorgestellten Detektoren eingesetzt werden können. Alternativ können die Daten unmittelbar, beispielsweise unter Nutzung rekonstruktionsbasierter Methoden, wie in [P2] und [S4] gezeigt, ausgewertet werden.

4.2.2 Autoencoder zur Anomaliedetektion

Beim CMT-basierten WAAM-Prozess stellen Anomalien in den Spannungsdaten einen guten Anhaltspunkt für die Bewertung der Prozessstabilität dar. Die Auswertung der Schritte aus dem vorangegangenen Abschnitt zeigte bei diesen Daten vielversprechende Ergebnisse für die Gruppe der Autoencoder. Autoencoder sind Vertreter der rekonstruktionsbasierten Methoden, welche laut Pimentel et al. häufig in sicherheitskritischen Bereichen zum Einsatz kommen [216]. Damit versprechen sie ein geeigneter Kandidat zu sein, um den Anforderungen für die Anomaliedetektion in der Additiven Fertigung zu begegnen. Autoencoder sind grundsätzlich unüberwacht und können sowohl für Zeitreihen als auch für nicht sequentielle Daten genutzt werden. Ziel beim Anlernen des Autoencoders für die Anomaliedetektion ist die Modellierung des Normalzustands, sodass Anomalien zu Abweichungen in der Rekonstruktion führen. Nachfolgend wird zunächst eine parametrisierbare Autoencoderarchitektur vorgestellt. Anschließend folgt die Erweiterung dieser Architektur um ein externes Speichermodul sowie um eine Konditionierung, um den Autoencoder für ein Metalernszenario mit wenigen Dateninstanzen vorzubereiten. Abschließend wird eine Methodik zur Umsetzung von Anomaliedetektion in einem solchen Szenario beschrieben.

Modellarchitektur

Wegen der vergleichsweise geringen Parameteranzahl und der hohen PR AUC-Werte in den Voruntersuchungen wird der CNN-Autoencoder als Ausgangsbasis gewählt. Die Architektur basiert auf einem Modell, das bereits im L-PBF-Umfeld erfolgreich zur Anomaliedetektion in Bilddaten eingesetzt wurde [194]. Sie besteht aus einer kaskadierenden Abfolge von Komprimierungsblöcken im Encoder und Entkomprimierungsblöcken im Decoder. Jeder Komprimierungsblock beinhaltet eine Faltungs- und eine Max-Pooling-Schicht. Darüber hinaus findet Regularisierung mittels Batchnormalisierung und Dropout statt. Ein Entkomprimierungsblock folgt dem gleichen Schema mit Ausnahme der Max-Pooling-Schicht, welche durch eine Up-Sampling-Schicht ersetzt wird. Die Repräsentation im latenten Bereich des Autoencoders ist so gewählt, dass deren Dimension kleiner ist als die der Eingangsdaten.

Zur Nutzung des Autoencoders für die Anomaliedetektion in Zeitreihen werden Anpassungen an dieser Struktur vorgenommen und eindimensionale Faltungsschichten sowie eindimensionale Max-Pooling- und Up-Sampling-Schichten genutzt. Dadurch wird der geringeren Dimensionalität der Zeitreihendaten im Vergleich zu den Bilddaten Rechnung getragen. Die Modelle werden mit leaky ReLU als Aktivierungsfunktion für die faltenden Schichten und mit RMSE als Fehlerwertfunktion unter Nutzung des Adam-Optimierers innerhalb von 100 Epochen mit einer Lernrate von 0.001 trainiert. Basierend auf den Ergebnissen aus [P8] wird die Länge des Eingangsvektors auf 256 gesetzt. Mittels einer baumstrukturierten Hyperparameteroptimierung [249] wird innerhalb des in Tabelle 4.2 definierten Lösungsraums eine optimale Modellarchitektur gesucht. Als Hyperparameter werden die Blockanzahl, die Kanalanzahl der Faltungsoperationen, die Kernelgröße für die Faltungs-, Max-Pooling- und Up-Sampling-Schichten, der Kompressionsfaktor zwischen Eingangsvektor und Größe des latenten Bereichs, der Dropoutfaktor sowie die Steigung der leaky ReLU Aktivierungsfunktion betrachtet. Die Schrittgröße in den Max-Pooling- und Faltungsschichten wird abhängig vom Kompressionsfaktor, von der Länge des Eingangsvektors, von der Kernelgröße sowie von der Block- und Kanalanzahl, wie in [S14] vorgestellt, berechnet. Optional werden darüber hinaus in Vorbereitung auf den speichererweiterten Autoencoder vor dem latenten Bereich der Vektor des Encodings abgeflacht sowie eine abschließende Linearschicht eingefügt.

Tabelle 4.2: Lösungsraum der Hyperparameteroptimierung für den CNN-basierten Autoencoder zur Anomaliedetektion für die WAAM-Spannungsdaten

Hyperparameter	Lösungsraum	Parametertyp
Blockanzahl	[2, 6]	Ganzzahl
Kanalanzahl vor dem latenten Bereich	[2, 16]	Ganzzahl
Kernelgröße	[3, 6]	Ganzzahl
Linearschicht	[wahr, falsch]	Kategorisch
Abflachen vor dem latenten Bereich	[wahr, falsch]	Kategorisch
Kompressionsfaktor	[0.1, 0.9]	Gleitkommazahl
Dropout	[0.0, 0.8]	Gleitkommazahl
Steigung der leaky ReLU Aktivierungsfunktion	[0.01, 0.3]	Gleitkommazahl

Konditionierter speichererweiterter Autoencoder

Trotz der genutzten Regularisierungsmethoden sowie der Reduktion der Dimensionalität im latenten Bereich kann es bei Autoencodern zu einer nahezu idealen Rekonstruktion von Anomalien kommen [196]. Um diesem Problem entgegenzuwirken, wird der bereits in 2.3 vorgestellte Ansatz eines speichererweiterten Autoencoders nach Gong et al. [241] aufgegriffen und weiterentwickelt. Dazu wird die vorgestellte Autoencoderarchitektur im latenten Bereich um ein Speichermodul erweitert. Das Speichermodul besteht aus mehreren Einträgen, welche in der prozessparallelen Prozessüberwachung auf Basis eines Vergleichs mit der encodeten Version \mathbf{z} der Eingangsgröße \mathbf{x} mittels Kosinusähnlichkeit aktiviert werden. Die Fehlerwertfunktion wird gemäß Gong et al. [241] um einen Spärlichkeitsterm erweitert. Diese Version des Autoencoders wird nachfolgend als MemAE bezeichnet. Um auch für diese Architektur einen optimalen Hyperparametersatz für die WAAM-Daten zu generieren, wird die Hyperparameteranalyse aus Tabelle 4.2 um zwei Hyperparameter ergänzt. Dabei handelt es sich um die Anzahl an Speichermoduleinträgen s , welche einen ganzzahligen Wert zwischen 1 und 100 annimmt, sowie um einen Spärlichkeitsgrenzwert zur Aktivierung der Speichermoduleinträge, dessen Gleitkommawert zwischen 0.001 und 0.5 liegt.

Wie in Kapitel 2.1.2 beschrieben, kommen im WAAM-Prozess je nach Material und Bauteilabschnitt unterschiedliche Prozessparametersätze zum Einsatz. Um für diese verschiedenen Prozesskonditionen ein Modell zu nutzen, wird das Konzept des speichererweiterten Autoencoders um Elemente zur Handhabung von Konditionen ergänzt. Es werden verallgemeinerte Encoder und Decoder erstellt, die für verschiedene Prozessparameter die relevanten Merkmale extrahieren beziehungsweise die Eingangsgrößen rekonstruieren. Die prozessparametersatzspezifische Ausprägung des Normalzustands wird hingegen konditioniert in Speichermodulen abgelegt. Die angepasste Architektur wird im Folgenden als konditionierter, speichererweiterter Autoencoder (engl. Conditional Memory Augmented Autoencoder (C-MemAE)) bezeichnet. Abbildung 4.7 zeigt den Aufbau des C-MemAEs schematisch.

Beim C-MemAE wird der Speicher M konditioniert genutzt. Er besteht aus k Speichermodulen M_c ($c \in 1, \dots, k$) mit jeweils s Speichermoduleinträgen $\mathbf{m}_{c,q}$ ($q \in 1, \dots, s$). Jedes Speichermodul ist einer Kondition c zugeordnet. In dem auf den Kosinusähnlichkeiten beruhenden Gewichtungsvektor \mathbf{w} werden alle für die aktive Kondition irrelevanten Einträge gleich 0 gesetzt und der verbleibende Vektor normalisiert, sodass \mathbf{w}_c entsteht. Auf diesen Vektor wird anschließend der Spärlichkeitsgrenzwert angewendet um $\hat{\mathbf{w}}_c$ zu erhalten. Innerhalb der Prozessüberwachung für WAAM handelt es sich bei den Konditionen um Prozessparametersätze. So kann beispielsweise einem CMT-Prozessparametersatz für die Aluminiumlegierung AlSi5 ein anderes Speichermodul zugewiesen werden als einem CMT-P-Prozessparametersatz für eine Stahllegierung. Die aktive Kondition wird im Prozess über den Systemkontext abhängig vom gewählten

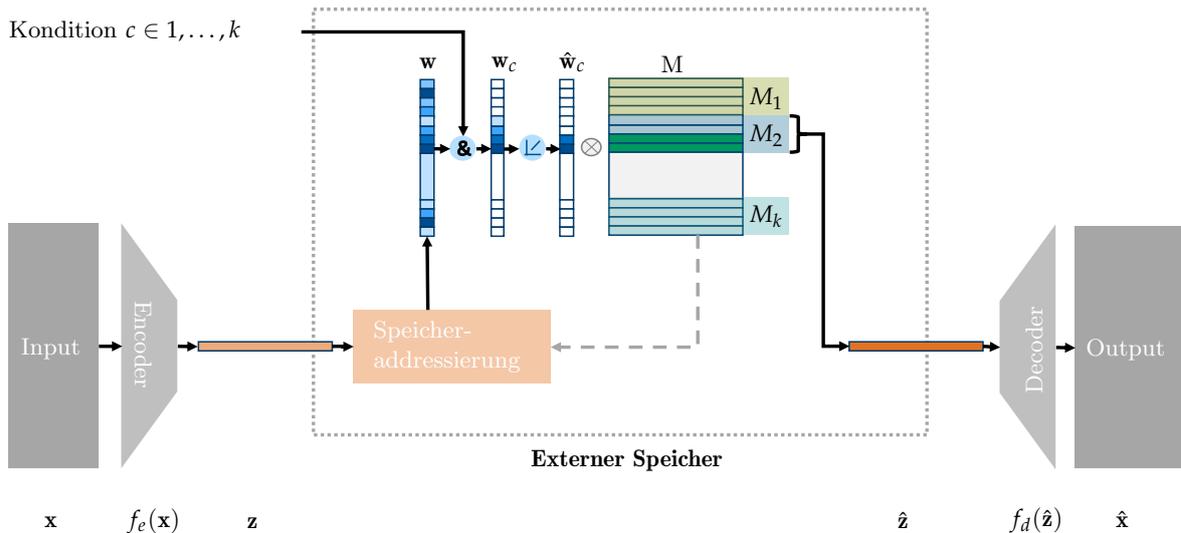


Abbildung 4.7: Schematischer Aufbau des C-MemAEs mit Encoder, Decoder sowie dazwischen liegendem externen, konditionierten Speichermodul mit k Speichereinheiten zu je $s = 4$ Speichermoduleinträgen

Prozessparametersatz bereitgestellt. Die Speichermodule teilen sich den gleichen Encoder und Decoder. Der Encoder lernt dadurch, für Zeitreihen mit unterschiedlichen Eigenschaften die für die Rekonstruktion relevanten Merkmale zu extrahieren. Somit übernimmt der Encoder die Aufgabe einer verallgemeinerten Merkmalsextraktion und ähnelt dadurch Methoden wie der Hauptkomponentenanalyse oder der Catch22-Merkmalsextraktion.

Metlernen und Modellanpassung

Das Modell soll auf neue Materialien und Schweißprozesse übertragen werden können. Dazu wird nachfolgend auf die Methodik zum Anlernen sowie zum Anpassen des Modells innerhalb weniger Schritte eingegangen.

Die Anpassungsfähigkeit des Modells wird durch Metlernen gewährleistet. Jede Prozesskondition c führt zu einem separaten Aufgabendatensatz D_i mit $i = c$ ($c \in 1, \dots, k$). Jeder Aufgabendatensatz D_i besteht aus j Elementen ($D_i = \mathbf{x}_{i,1}, \mathbf{x}_{i,2}, \dots, \mathbf{x}_{i,j}$), die jeweils Eingangsgrößen des Autoencoders sind. Das Ziel des Trainings ist auch hier eine Rekonstruktion der normalen Eingangswerte mit einem geringen Rekonstruktionsfehler. Der Mettrainingsdatensatz \mathcal{D}^{train} umfasst alle Trainingsdaten der bekannten Konditionen ($D_i \subseteq \mathcal{D}^{train}$). Der Datensatz eines neuen Prozessparametersatzes stellt den Metatestdatensatz \mathcal{D}^{test} dar.

Die vorgestellte C-MemAE-Architektur kann bereits für ein solches Multiaufgabenproblem eingesetzt werden. Beim Anlernen des Modells wird für jede Aufgabe ein separates Speichermodul erstellt. Zur Anpassung des speichererweiterten Modells $f(f_e(\theta_e), f_d(\theta_d), M(\theta_M))$ innerhalb weniger Schritte wird von einem unbekanntem Datensatz D_{k+1} der Kondition $c = k + 1$ mit einer geringen Anzahl von j Elementen $\mathbf{x}_{k+1,i}$ mit $i \in 1, \dots, j$ ($D_{k+1} = \mathcal{D}^{test}$) ausgegangen. Durch die beim Anlernen auf \mathcal{D}^{train} erreichte Generalisierung von En- und Decoder sind diese in der Lage auch bei neuen Datensätzen relevante Merkmale zu extrahieren. Der Speicher M wird für die neue Kondition um das Speichermodul M_{k+1} erweitert. Die neuen Speichermoduleinträge $\mathbf{m}_{k+1,q}$ des C-MemAEs können auf folgende drei Weisen initialisiert werden:

1. **Initialisierung mittels Encodingkopie:** Die s Speichermoduleinträge $\mathbf{m}_{k+1,q}$ werden, wie in Gleichung 4.3 mit $q = i$ formuliert, durch Kopien der j encodeten Elemente des Datensatzes initialisiert.

$$\mathbf{m}_{k+1,q} = f_e(\mathbf{x}_{k+1,i}; \theta_e) \quad (4.3)$$

Falls $j < s$ gilt, werden zusätzlich die Methoden zwei oder drei für die verbleibenden $s - j$ zu initialisierenden Speichermoduleinträge verwendet.

2. **Initialisierung durch bekannte Speichermoduleinträge:** Die s Speichermoduleinträge $\mathbf{m}_{k+1,q}$ werden auf Basis bereits vorhandener Speichermoduleinträge anderer Speichermodule initialisiert. Dazu wird das encodete Element durch die Berechnung der Kosinusähnlichkeit mit den Speichermoduleinträgen aller Speichermodule des Modells verglichen. Die Einträge mit der höchsten Ähnlichkeit werden genutzt, um die leeren Speichermoduleinträge $\mathbf{m}_{k+1,q}$ zu initialisieren.
3. **Zufällige Initialisierung:** Die s Speichermoduleinträge $\mathbf{m}_{k+1,q}$ werden zufällig initialisiert.

Zur Nutzung der Initialisierung durch bekannte Speichermoduleinträge ist eine Ähnlichkeit unter den Aufgabendatensätzen von Vorteil. Beim MemAE findet die Speicherinitialisierung analog zum C-MemAE statt, wobei die Methodik zur Initialisierung durch bekannte Speichermoduleinträge nicht angewendet werden kann. Stattdessen wird als dritte Art der Speicherinitialisierung keine Anpassung des Speichers im Anschluss an den Metalernvorgang vorgenommen. Nach der Initialisierung findet eine kurze Phase des Transferlernens statt, in der die Parameter des Modells innerhalb weniger Schritte justiert werden.

Metalernen auf Basis von MemAE und C-MemAE kann der Gruppe der modellbasierten Metalernalgorithmen zugeordnet werden. Um die Kombination von optimierungs- und modellbasierten Metalernmethoden zu untersuchen, wird eine Verknüpfung der speichererweiterten Methoden mit MAML vorgeschlagen. Während MAML für MemAE keine weitere Anpassung des Metalernalgorithmus erfordert, sind für C-MemAE Änderungen der Vorgehensweise von Finn et al. erforderlich, welche in Algorithmus 2 in den Schritten 7 und 9 zu finden sind. Dort werden die Speichermoduleinträge abhängig vom aktuell beim Training genutzten Datensatz konditioniert angepasst.

Algorithmus 2 MAML-basierter Metalernalgorithmus für den C-MemAE

Eingabe: $p(\mathcal{D}^{train})$: Verteilung über die Aufgaben

Eingabe: $\alpha_{MAML}, \beta_{MAML}$: MAML-Hyperparameter für die Lernrate

Eingabe: $f_\theta = f(f_e(\theta_e), f_d(\theta_d), M(\theta_M))$: C-MemAE mit Encoder, Decoder und konditioniertem Speicher

- 1: Zufällige Initialisierung von $\theta = \{\theta_e, \theta_d, \theta_M\}$
 - 2: **während** Lernvorgang nicht abgeschlossen **tue**
 - 3: Erstelle Batch B_i mit j Elementen für jede Aufgabe $D_i \subseteq p(\mathcal{D}^{train})$
 - 4: **für alle** B_i **tue**
 - 5: Werte $\nabla_\theta \mathcal{L}_{B_i}(f_\theta)$ aus für alle Elemente in B_i
 - 6: Berechne Parameter mit Gradientenverfahren: $\theta'_i = \theta - \alpha_{MAML} \nabla_\theta \mathcal{L}_{D_i}(f_\theta)$
 - 7: Aktualisiere Speichermoduleinträge $\theta_{M_i} \leftarrow \theta'_i$ für die aktive Kondition
 - 8: **beende für**
 - 9: Aktualisiere $\theta_e, \theta_d \leftarrow \theta - \beta_{MAML} \cdot \nabla_\theta \sum_{D_i \subseteq p(\mathcal{D}^{train})} \mathcal{L}_{D_i}(f_{\theta'_i})$
 - 10: **beende während**
-

Dadurch werden der Encoder und der Decoder mittels MAML in einen Zustand gebracht, von dem aus eine schnelle Anpassung möglich ist, während die Speichereinheiten des Speichermoduls aufgabenspezifisch optimiert werden. Im Anschluss an den MAML-basierten Metalernvorgang findet die aufgabenspezifische Anpassung des Modells statt. Dafür werden die vorgestellten Speicherinitialisierungstechniken für den C-MemAE beziehungsweise für den MemAE genutzt.

4.2.3 Multivariate Anomaliebewertung

Durch den modularen Aufbau der Anomaliedetektion liegen für k Sensordatenströme \mathbf{T}_i ($i \in 1, \dots, k$) Anomaliewerte vor. Um eine kondensierte Aussage über die Prozessstabilität zu treffen, wird eine multivariate Anomaliebewertung vorgenommen. Dazu wird auf Basis des in Abbildung 4.8 vorgestellten Schemas ein kombinierter Anomaliewert d_{Mahal} erstellt.

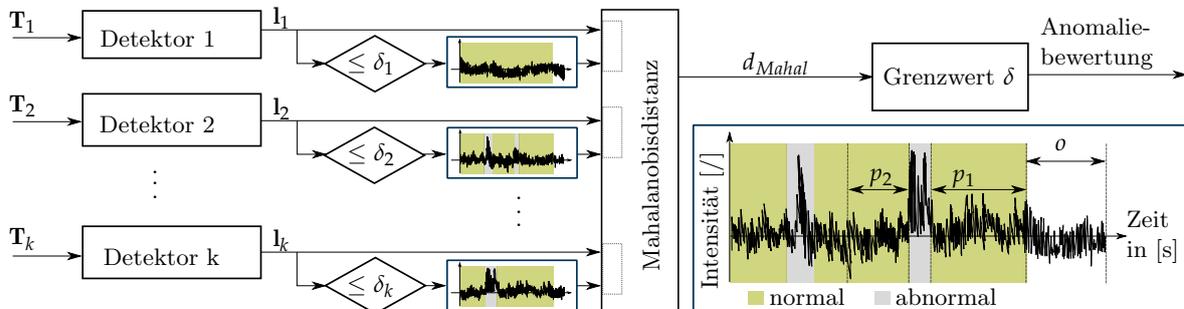


Abbildung 4.8: Multivariate Anomaliedetektion für k Sensordatenzeitreihen T unter Nutzung von k Detektoren, welche die Anomaliewerte l erzeugen, von k dynamischen Referenzdatensätzen, welche unter Ausschluss der über den Grenzwerten δ liegenden Anomaliewerten sowie unter Berücksichtigung eines zeitlichen Abstands o gebildet werden, sowie der Mahalanobisdistanz d_{Mahal}

Da sich die mittlere Intensitäten der Anomaliewertströme l_i und deren Standardabweichungen unterscheiden können, wird für die Kombination der Werte die skaleninvariante Mahalanobisdistanz aus Gleichung 2.11 herangezogen. Zur Berechnung der Distanz ist der Mittelwert \bar{x} von jedem Anomaliewertstrom l_i sowie die Kovarianzmatrix erforderlich. Diese beiden Elemente bilden die Referenz, anhand derer die Distanz gemessen wird. Um während des Prozesses Konzeptverschiebungen bis zu einem gewissen Grad ausgleichen zu können, wird die Referenz nicht zu Beginn des Prozesses festgelegt sondern ändert sich stetig. Für jeden Anomaliewertstrom wird ein dynamischer Referenzvektor der Länge m nach dem Prinzip eines Ringspeichers aufgebaut. Um zu verhindern, dass die Detektionssensitivität herabgesetzt wird, werden lediglich Datenpunkte zum Referenzvektor hinzugefügt, deren Anomaliewerte unterhalb eines definierten Grenzwertes δ_i liegen und einen zeitlichen Abstand größer o zum gegenwärtigen Zeitpunkt aufweisen. Exemplarisch ist dies anhand der Datenpunkte in den Abschnitten p_1 und p_2 in Abbildung 4.8 dargestellt. Abnormale Datenpunkte werden damit von der Bildung der Referenz ausgeschlossen. Das Vorgehen wurde in [P2] evaluiert.

4.3 Klassifizierung von Prozessdefekten

Ein abnormaler Prozess ist ein Indikator dafür, dass ein Defekt vorliegt. Da die Art des Defekts relevant ist, um die Auswirkung eines abnormalen Prozesses auf die Qualität des WAAM-Bauteils zu bewerten, ist eine Defektklassifizierung vorzunehmen. Nachfolgend wird eine Methodik vorgestellt, um diese Klassifikation zu erreichen. Es wird zunächst auf die Datenvorverarbeitung und anschließend auf die Modellbildung eingegangen.

4.3.1 Datenvorverarbeitung

Der Klassifikation liegen die Sensordaten des Prozesses zu Grunde. Bei der Einordnung eines Defekts sind jedoch nicht nur die Sensorwerte von Interesse sondern auch ihr Kontext. Messwerte, die für einen Prozessparametersatz normal sind, können bei einem anderen Prozessparametersatz auf einen Defekt hindeuten. Darüber hinaus beeinflusst die direkte räumliche Umgebung den Prozess, sodass historische Daten der unmittelbaren Umgebung einen Mehrwert an Informationen bereitstellen können. Beispielsweise kann es nach einem Defekt, wie in Tabelle B.1 im Anhang vorgestellt, zu Folgedefekten kommen, deren Klassifikation durch das Wissen über die Existenz eines vorherigen Defekts unterstützt werden kann. Der in Kapitel 3 vorgestellte Kontext wird deshalb zur Konditionierung des Modells sowie für eine räumliche und zeitliche Einordnung des Schweißprozesses in seine Umgebung verwendet. Das Klassifikationsmodell erhält damit Informationen aus drei Bereichen:

- $\mathbf{x}_{Messung}$: Messwerte und Zeitreihenmerkmale der letzten zwei CMT-Zyklen
- $\mathbf{x}_{Kondition}$: Systemkontext zur Konditionierung des Modells
- $\mathbf{x}_{Umgebung}$: Zeitlicher und räumlicher Kontext auf Basis der Umgebung des Schweißprozesses

Datenvorverarbeitung der Sensorwerte

Die Sensordaten, welche für die Klassifizierung genutzt werden, umfassen die Daten der Strom- und Spannungssensoren, des Spektrometers, des Strukturakustiksensors und des Mikrofons. Die Daten des Gasfluss- und des Drahtvorschubsensors sind quasi-stationär und dienen der Modellkonditionierung. Für jeden Sensor werden relevante Merkmale extrahiert und dem Modell als $\mathbf{x}_{Messung}$ bereitgestellt.

Strom- und Spannungsdaten: Es werden die unverarbeiteten Sensorwerte der letzten zwei CMT-Zyklen bereitgestellt. Zusätzlich werden aus den Strom- und Spannungsdaten die in Abbildung 4.4 gezeigten CMT-Merkmale für zwei CMT-Zyklen extrahiert und dem Klassifikationsmodell bereitgestellt. Dazu wird eine Zeitreihensegmentierung mithilfe einer Grenzwertdetektion vorgenommen. In Voruntersuchungen führte diese redundante, expertenwissenbasierte Informationsbereitstellung zu einer Verbesserung des Klassifikationsergebnisses.

Spektrometer: Durch Abzug der unteren Hüllkurve wird der Schwarzkörperstrahlungsanteil im Spektrum entfernt. Die Intensität der resultierenden Messwerte wird durch die Schweißrichtung und die Geometrie beeinflusst, da Reflexionen und Abschirmungen auftreten können. Um diese das gesamte Spektrum betreffende Intensitätsschwankungen zu kompensieren, wird für jede Wellenlänge i das Verhältnis I_{i-rel} der Intensität I_i zur gemittelten Intensität des gesamten Spektrums \bar{I} , wie in Gleichung 4.4 notiert, gebildet.

$$I_{i-rel} = \frac{I_i}{\bar{I}} \quad (4.4)$$

Aus diesem normierten Spektrum werden 23 Wellenlängen ausgewählt. Dazu wird in Anlehnung an die Selektion von Zeitreihenmerkmalen in [165] und [250] eine hierarchische Clusterbildung auf Basis der Rangkorrelationskoeffizienten nach Spearman zwischen den normierten Intensitäten der Wellenlängen vorgenommen. Aus jedem Cluster wird die Wellenlänge verwendet,

die die Verteilung am besten abbildet, resultierend in den Wellenlängen 278.7 nm, 355.1 nm, 385.4 nm, 399.5 nm, 406.5 nm, 412.3 nm, 415.8 nm, 422.4 nm, 438.6 nm, 453.1 nm, 483.45 nm, 530.9 nm, 534.4 nm, 581.0 nm, 616.6 nm, 631.1 nm, 657.5 nm, 662.3 nm, 779.6 nm, 788.0 nm, 883.3 nm, 960.3 nm und 976.1 nm.

Mikrofon: Aus den Luftschalldaten werden alle 50 ms sieben in der Musik- und Sprachanalyse gebräuchliche Audiomerkmale extrahiert. Es handelt sich dabei um die Nulldurchgangsrate, die Energie des Signals, die Spektralentropie, den Spektralfluss, die Grenzfrequenz, die Schwerpunktwellenlänge sowie die Frequenzspreizung [251, 252].

Strukturakustiksensoren: Die Strukturakustikdaten werden nicht vorverarbeitet. Dem Modell werden die Sensorwerte der letzten zwei CMT-Zyklen bereitgestellt.

Daten zur Konditionierung

Der Systemkontext umfasst Informationen zum Prozess, mit deren Hilfe das Modell konditioniert angelernt werden kann. Dem Modell werden mit $\mathbf{x}_{Kondition}$ Informationen über den Prozesstyp, das verwendete Material sowie die vorgegebenen Prozessparameter Gasfluss, Drahtvorschub und Schweißgeschwindigkeit übergeben. Die Werte für die Konditionierung weisen während eines laufenden Prozesses für gewöhnlich quasi-stationäre Eigenschaften auf.

Räumliche und zeitliche Einordnung des Schweißprozesses

Der räumliche Kontext wird mithilfe des in Abschnitt 3.2 vorgestellten Octrees analysiert. Dazu wird nach den drei räumlich nächsten Octreeelementen der benachbarten Schweißnähte gesucht, welche Einfluss auf das Schweißbad und den aktuellen Schweißprozess nehmen. Die im Octree abgelegten TCP-Positionen werden dafür um die zuvor genannten, zeitlich gemittelten Sensordaten und -merkmale ergänzt. Darüber hinaus werden die Zeitdifferenzen zwischen dem aktuellen Zeitpunkt sowie den Zeitstempeln der relevanten TCP-Positionen gebildet und dem Modell zur Verfügung gestellt. Diese Informationen werden dem Modell als $\mathbf{x}_{Umgebung}$ übergeben.

4.3.2 Modellbildung

Das Auftreten eines Defekts schließt das zeitgleiche Auftreten eines anderen Defekts nicht aus. Aus diesem Grund wird je Defekt ein separates Klassifikationsmodell erstellt. Dafür wird jeweils ein angepasstes MLP aufgebaut. Es verfügt über Abkürzungsverbindungen, welche jeweils eine Schicht des MLPs überspringen. Damit ergibt sich für jede Schicht außer der Ersten anstelle von Gleichung 2.18 folgende Gleichung, wobei \oplus die Konkatenation zweier Vektoren darstellt:

$$\mathbf{x}_{k+1} = s(\mathbf{w}_{k+1}(\mathbf{x}_k \oplus \mathbf{x}_{k-1}) + \mathbf{b}_{k+1}) \quad (4.5)$$

Abgesehen von der letzten Schicht des MLPs wird die parametrisierbare ReLU-Funktion genutzt. In der letzten Schicht führt eine Sigmoid-Aktivierungsfunktion zu einem Modellausgangswert zwischen 0 und 1, welcher die Wahrscheinlichkeit für den entsprechenden Defekt wiedergibt. Als Eingangsvektor dient die Konkatenation von $\mathbf{x}_{Messung}$, $\mathbf{x}_{Kondition}$ und $\mathbf{x}_{Umgebung}$.

Als Optimierungsmethode wird AdamW eingesetzt und als Fehlerfunktion die binäre Kreuzentropie. Um ein optimales Modell zu erhalten, wird auch hier eine Hyperparameteroptimierung mit dem Ziel durchgeführt, PR AUC zu maximieren. Der Lösungsraum ist in Tabelle 4.3 festgehalten.

Tabelle 4.3: Lösungsraum der Hyperparameteroptimierung für die Defektklassifikation mittels MLP

Hyperparameter	Lösungsraum	Parametertyp
Anzahl an verdeckten Schichten	[1, 4]	Ganzzahl
Dimension der verdeckten Schichten	[32, 512]	Ganzzahl
Lernrate	[0.0001, 0.01]	Gleitkommazahl
Gewichtsregulierung	[0.00001, 1]	Gleitkommazahl
Dropoutrate	[0, 0.3]	Gleitkommazahl

Neben der Anzahl und Dimension der verdeckten Schichten im MLP wird hinsichtlich der Lernrate, der Dropoutrate und des Parameters für die Gewichtsregulierung in AdamW optimiert. Als Trainings- und Testdaten kommen die Datensätze von Bauteilen mit unterschiedlichen Geometrien, teils unterschiedlichen Prozessparametern und annotierten Defekten zum Einsatz. Jeder Datensatz besteht aus j Elementen, die jeweils den konkatenierten Eingangsvektor sowie die zugehörige Annotation umfassen. Es werden je nach Defekt zwei Datensätze zum Testen des Modells ausgewählt, wohingegen die restlichen Datensätze für das Training verwendet werden. Die genutzten Datensätze je Defekt sowie ein Überblick über die Charakteristika aller Datensätze für die Defektklassifikation sind in Abschnitt B.3 des Anhangs festgehalten. Da Defekte selten sind, werden die Elemente der Trainingsdaten mit annotiertem Defekt beim Training mittels synthetischer Anpassung übermäßig häufig bereitgestellt. Diese Technik nennt sich SMOTE und wurde von Chawla et al. für Klassifikationsdatensätze mit starken Klassenungleichgewicht entwickelt [253].

Um zudem explizit Übertragbarkeit auf andere Prozessparameter und Bauteilgeometrien zu erreichen, wird für das Training des MLPs ein Metalernansatz auf Basis von MAML eingesetzt. Dafür werden die einzelnen Datensätzen der Bauteile als Aufgabendatensätze D_i definiert. Auch hier findet eine Einteilung in Metatrainingsdatensatz \mathcal{D}^{train} und Metatestdatensatz \mathcal{D}^{test} statt. Ein Anpassungsschritt findet nicht statt, sodass stattdessen mit \mathcal{D}^{test} das metaangelernete Modell analog zum MLP ohne Metalernansatz unmittelbar auf unbekanntem Bauteilgeometrien getestet wird. Die Hyperparameteroptimierung aus Tabelle 4.3 wird für den Metalernansatz um eine kategorische Entscheidungsvariable, die die Nutzung von Batchnormalisierung im MLP definiert, sowie um einen ganzzahligen Parameter, der die Anzahl an Epochen je MAML-Anpassungsschritte für jede Aufgabe angibt, ergänzt. Um Vergleichbarkeit sicherzustellen, werden die Modellparameter zu Beginn der Versuche auf die gleiche Art und Weise initialisiert.

4.4 Bestimmung des Abstands zwischen Bauteil und Schweißbrenner

Der Abstand zwischen Bauteil und Schweißbrenner ist beim Schweißen ein Prozessparameter. Bei WAAM handelt es sich aufgrund des dreidimensionalen Charakters des Prozesses um eine sich dynamisch verändernde Größe, welche stets überwacht werden muss. Änderungen dieses Abstands gehen auf Geometrieabweichungen beispielsweise aufgrund von Verzug, von Überhitzungen oder von Humpingeffekt induzierten, wellenförmigen Materialansammlungen

zurück. Darüber hinaus müssen die gewählten Prozessparameter zum definierten Lagenabstand passen, um Formabweichungen zu vermeiden. Die Wahl geeigneter Prozessparameter ist dabei großen Unsicherheiten unterworfen, da sich das Temperaturprofil im Bauteil entlang des Aufbaus dynamisch verändert. Dies hat Auswirkungen auf die Schweißnahtgeometrie, sodass es zu Abweichungen von der definierten Schichthöhe und damit zu Abweichungen vom Referenzabstand zwischen Schweißbrenner und Bauteil kommen kann. Formabweichungen setzen sich über mehrere Lagen hinweg fort. Aggregiert können sie dazu führen, dass der Schweißbrenner mit dem aufgetragenen Material kollidiert oder der Schweißprozess aus dem Fokus läuft. Ziel ist es daher, diese Entwicklung zu quantifizieren, indem der Abstand zwischen Bauteil und Schweißbrenner d_{NIW} in-situ gemessen wird. Bei nicht aktiven Lichtbogen kann die Messung mithilfe von Laserprofilometern oder Ultraschallsensoren erfolgen. Während des Schweißprozesses wird deren Messung jedoch durch die hohen elektromagnetischen und akustischen Emissionen gestört, sodass alternative Messstrategien erforderlich sind. Zusätzlich muss die Messung für den voll 3D-fähigen WAAM-Prozess geeignet sein und deshalb richtungs- und schichtunabhängig sein. Nachfolgend werden die Daten des Spannungssensors, der Schweißkamera sowie des Spektrometers und abgeleitete Merkmale auf ihre Korrelation mit d_{NIW} untersucht. Weitere Sensoren wurden in der Veröffentlichung [P6] behandelt.

Spannungssensor: Aus den Spannungsdaten werden die in Abbildung 4.4 definierten Merkmale extrahiert. Mithilfe einer Korrelationsanalyse wird das Merkmal ausgewählt, das den höchsten Informationsgehalt für die Bestimmung des Abstands aufweist.

Spektrometer: Analog zur Datenvorverarbeitung für die Defektklassifikation wird zunächst eine Hüllkurve bestimmt, welche vom Spektrum subtrahiert wird. Anschließend werden sämtliche Werte mit dem Mittelwert des Spektrums nach Gleichung 4.4 normiert, um die im Ishikawa-Diagramm aus Abbildung 4.2 genannten Einflüsse des Werkzeugwegs und der Orientierung des Spektrometers auf die gemessene Intensität zu reduzieren. Mithilfe einer Korrelationsanalyse wird die Wellenlänge ausgewählt, die den höchsten Informationsgehalt für die Bestimmung des Abstands aufweist.

Schweißkamera: Die Schweißkamera stellt ein Graustufenbild ohne Tiefeninformationen bereit. Die Messung von d_{NIW} erfolgt deshalb nicht unmittelbar sondern über die Messung der mittleren Länge des sichtbaren Schweißdrahts unter Nutzung eines CNNs. Zunächst wird dazu im Kamerabild der für die Analyse relevante Bildausschnitt (ROI) definiert. Der ROI wird nach oben von der unteren Kante des Schweißbrenners und nach unten von der maximal zu detektierenden Drahtlänge begrenzt. Die horizontale Ausdehnung des ROIs muss die Breite des Drahts inklusive drallbedingter Änderungen in der Orientierung des Drahts abdecken. Der resultierende ROI ist in Abbildung 4.9 im Schweißkamerabild rot umrandet dargestellt und ermöglicht die Messungen eines Abstands von minimal 6 mm und maximal 18 mm. Das CNN besteht, wie in [P6] vorgestellt sowie in Abbildung 4.9 schematisch angedeutet, aus einer Abfolge von Faltungs- und Max-Pooling-Schichten, zwischen denen jeweils eine Batchnormalisierung stattfindet. Zuletzt wird ein eindimensionaler Vektor erzeugt, eine Regularisierung mittels Dropout sowie eine dichte Schicht hinzugefügt. Der Ausgangswert des CNNs ist ein skalarer Wert, der die Länge des detektierten Drahts $d_{Messung}$ in Pixel angibt. Es werden ReLU-Aktivierungsfunktionen verwendet und für das Anlernen des Modells der Optimierungsalgorithmus RMSProp sowie die Fehlerwertfunktion MSE genutzt. Wegen der geringen Bildrate der Schweißkamera und der hohen Frequenz des CMT-Prozesses kann das Abtasttheorem nach Nyquist-Shannon nicht erfüllt werden. Die Messungen fangen

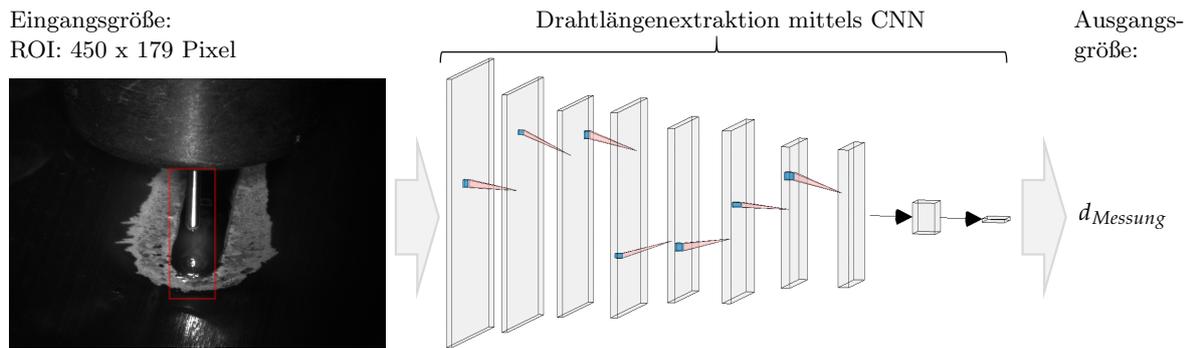


Abbildung 4.9: Darstellung des Datenflusses zur Erkennung der sichtbaren Drahtlänge unter Nutzung eines CNNs auf Basis des rotmarkierten ROIs im Bild der Schweißkamera

damit nicht die dynamische Charakteristik des CMT-Prozesses ein. Um einen belastbareren Messwert für den Abstand zu erhalten, wird deshalb der Mittelwert der gemessenen Drahtlänge über ein gleitendes Zeitfenster berechnet.

4.5 Evaluierung

Die vorgestellten Methoden der Prozessüberwachung werden im Folgenden evaluiert. Dazu wird zunächst auf die Anomaliedetektion und Defektklassifikation eingegangen. Abgeschlossen wird der Abschnitt mit einer Betrachtung der Ergebnisse für die Abstandsmessung.

4.5.1 Evaluierung der Anomaliedetektion

Für die Evaluierung der Methoden zur Anomaliedetektion werden einerseits Zeitreihen der Anomaliebenchmarkdatensätze *Yahoo Benchmark Dataset for Time Series Anomaly Detektion* [254], *Numenta Anomaly Benchmarks* [236] und *Kaggle Labeled Anomaly Detection TS Benchmarks* [255] sowie andererseits fünfzehn annotierte WAAM-Spannungsdatensätze (Tabelle C.1 im Anhang) verwendet.

Evaluierung der Methodik zur Detektorauswahl

Die Detektorauswahl folgt der in Abschnitt 4.2.1 vorgestellten Methodik. Anhand der Prämisse, dass ausreichend Anomalien im Testabschnitt jedes Datensatzes verfügbar sein müssen, wurden 162 Datensätze aus den Anomaliebenchmarkdatensätzen ausgewählt. Als Ergebnis des ersten Schritts sind die Evaluierungsmetriken der 17 Detektoren für die 164 Datensätze in Abbildung 4.10 als Kastendiagramme dargestellt. Zum Vergleich sind die PR AUC-Werte der Detektoren für die WAAM-Spannungsdaten in der Abbildung rot hervorgehoben.

Die höchsten Medianwerte waren für DBSCAN, OC-SVM, die drei Autoencoder sowie das Autoregressionsmodell zu sehen. Dies waren zugleich die Detektoren, bei denen die Werte für das erste und das dritte Quartil am höchsten lagen. Die niedrigsten PR AUC-Medianwerte zeigten die drei prädiktionsbasierten KNNs sowie der K-means Algorithmus. Diese vier Detektoren wiesen zudem die höchste Anzahl an Ausreißern auf. Die PR AUC-Werte waren für die meisten Detektoren über die Datensätze hinweg nicht normalverteilt.

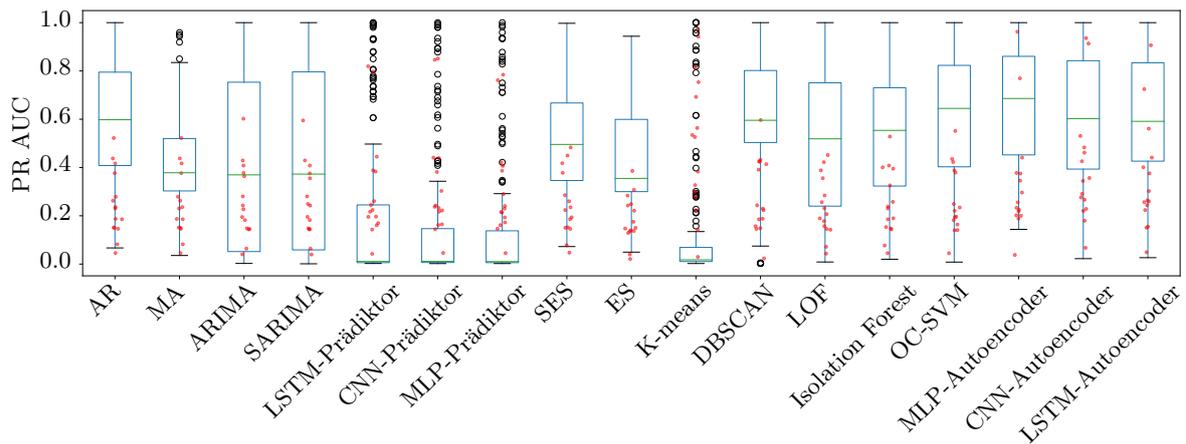


Abbildung 4.10: Kastendiagramme zur Darstellung der PR AUC-Werte der 17 Detektoren für 164 öffentliche Anomaliedatensätze sowie für die annotierten WAAM-Spannungsdatensätze (rot markiert)

Die PR AUC-Werte für die WAAM-Daten lagen für die meisten Detektoren innerhalb der zuvor ermittelten Interquartilbereiche. Die Autoencoder wiesen gemeinsam mit K-means und den KNN-basierten Vorhersagemodellen im Mittel die höchsten PR AUC-Werte auf. Bei K-means waren die vergleichsweise hohen Werte auf die Wahl des Modellhyperparameters $k_{K-Means} = 4$ zurückzuführen. Es ergaben sich vier Cluster, welche zu den Segmenten des CMT-Zyklus aus Abbildung 4.4 passten. Zwischen den WAAM-Datensätzen gab es erhebliche Unterschiede hinsichtlich der erreichten PR AUC-Werte. Dies ließ sich auf den Typ der Anomalie (Punktanomalien, konditionelle und kontextuelle Anomalie) zurückführen, der einen hohen Einfluss auf die Detektionsleistung hatte.

In Abbildung 4.11 sind die Verteilungen der im zweiten Schritt der Methodik extrahierten, nach Lubba et al. [165] 22 relevantesten Merkmale der 164 Datensätze als Kastendiagramme dargestellt. Die Ausprägungen der Merkmale für die WAAM-Datensätze sind in rot hinzugefügt.

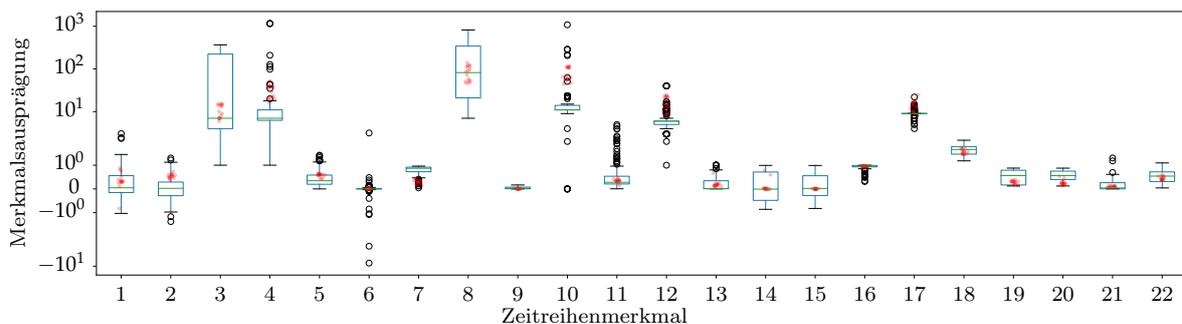


Abbildung 4.11: Kastendiagramme für die 22 relevantesten Zeitreihenmerkmale der 164 Datensätze sowie der in rot markierten WAAM-Datensätze nach Lubba et al. [165]

Die WAAM-Daten zeigten für die Merkmale 4 (Erstes Minimum der Autokorrelationsfunktion), 7 (Anteil aufeinanderfolgender Differenzen, die 0.04 der Standardabweichungen überschreiten), 10 (Periodizität), 12 (Erstes Minimum der Autotransinformationsfunktion) und 17 (Längste Serie an Werten über dem Durchschnitt) ein von den Vergleichszeitreihen abweichendes Verhalten. Diese Catch22-Merkmale bestätigten, dass die WAAM-Datensätze eine vergleichsweise hohe Periodizität, Autokorrelation und Autotransinformation besaßen. Eine Beschreibung aller Catch22-Zeitreihenmerkmale ist im Anhang in Tabelle C.2 zu finden.

Im dritten Schritt wurden die extrahierten Zeitreihenmerkmale und die Ergebnisse der Detek-

tovaluierung miteinander in Verbindung gesetzt. Dazu wurden zunächst die Ergebnisse der Zeitreihenmerkmalanalyse aus Abbildung 4.11 mit den Ergebnissen der Detektorevaluierung aus Abbildung 4.10 unter Nutzung des Rangkorrelationskoeffizienten nach Spearman korreliert. Die daraus hervorgegangene Matrix ist in Abbildung 4.12 dargestellt.

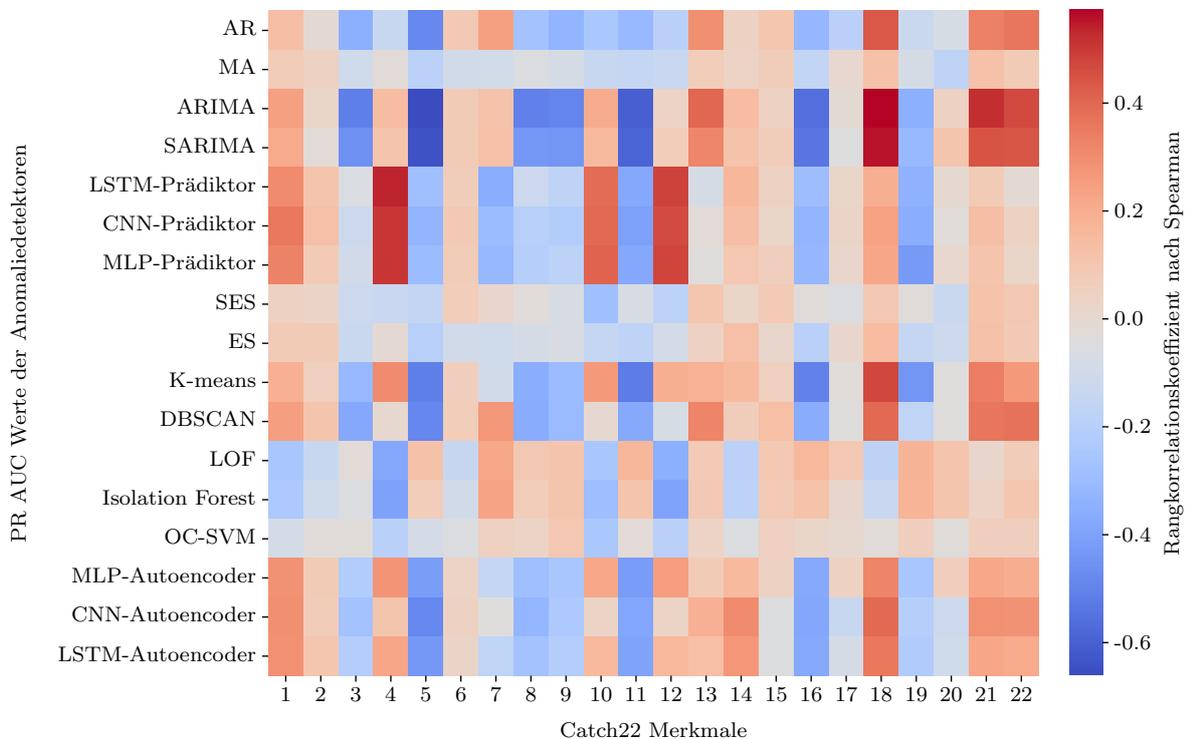


Abbildung 4.12: Darstellung der Korrelationsmatrix auf Basis des Rangkorrelationskoeffizienten nach Spearman zur Untersuchung der Korrelation zwischen Anomaliedetektionsleistungen der Detektoren und den Zeitreihenmerkmalen

Eine positive Korrelation zeigte bei einem vergleichsweise hohen Wert für das Zeitreihenmerkmal eine vorteilhafte Ausprägung für den Detektor an, wohingegen eine negative Korrelation einen negativen Einfluss einer stärkeren Ausprägung des Merkmals auf die Leistungsfähigkeit des Detektors bedeutete. Eine hohe absolute Korrelation implizierte damit, dass das verwendete Modell sensitiv hinsichtlich des Zeitreihenmerkmals war. Hohe absolute Korrelationen zeigten sich bei ARIMA, SARIMA, LSTM-, CNN- und MLP-basierter Vorhersage sowie bei K-means. Geringe absolute Korrelationen waren für die Detektoren MA, SES, ES und OC-SVM zu sehen. Ihre Detektionsleistung war damit invariant hinsichtlich der Ausprägung bestimmter Zeitreihenmerkmale. Die Gruppe der rekonstruktionsbasierten Methoden wies keine Extremwerte für die Korrelation auf, dennoch war eine Abhängigkeit von den Zeitreihenmerkmalen zu sehen. Eine höhere Ausprägung der Merkmale 4, 10 und 12 sowie eine geringe Ausprägung von Merkmal 7 bewirkten bessere Detektionsergebnisse, sodass die in Abbildung 4.11 zu sehenden Ausprägungen der Zeitreihenmerkmale für die WAAM-Spannungsdaten von Vorteil für die autoencoderbasierten Methoden waren.

Für die Klassifikation wurden drei Detektoren ausgewählt, die einerseits aus den drei unterschiedlichen Detektorkategorien stammen und andererseits hinsichtlich unterschiedlicher Zeitreihenmerkmale sensitiv waren. Es handelte sich um CNN-AE, Isolation Forest sowie ARIMA. Bei Betrachtung der Ergebnisse dieser drei Detektoren war CNN-AE in 64 Fällen der Detektor mit dem höchsten PR AUC-Wert, gefolgt von Isolation Forest mit 63 Nennungen und schließlich ARIMA mit 35 Nennungen. Das Klassifikationsproblem wies damit im Vergleich zu einem Anomaliedetektionsproblem ein ausgewogeneres Verhältnis der Klassen auf. Die

Klassifikationsergebnisse für ein 4-fach stratifiziert-kreuzvalidiertes Anlernen der Modelle sind in Tabelle 4.4 für die drei Klassifikationsmodelle (Random Forest-Algorithmus, SVM, MLP) dargestellt.

Tabelle 4.4: Durchschnittliche Werte für Treffergenauigkeit und F_1 -Wert der 4-fach stratifiziert-kreuzvalidierten Klassifikationsmodelle

Klassifikationsmodell	$\varnothing ACC$	$\varnothing F_1$
Random forest	0.648	0.650
SVM	0.450	0.481
MLP	0.587	0.599

Der Random Forest-Algorithmus wies die höchste Treffergenauigkeit und den höchsten F_1 -Wert auf, gefolgt vom MLP-Klassifikationsmodell. Eine Untersuchung der Wahrheitsmatrix für den Random Forest Algorithmus zeigte, dass falsch klassifizierte ARIMA-Werte sowie falsch klassifizierte Isolation Forest-Werte eher dem CNN-AE zugeordnet wurden. Bei falsch klassifizierten CNN-AE-Werten zeigte sich hingegen keine eindeutige Tendenz, wenn die Wahrscheinlichkeiten jeder Klasse berücksichtigt wurden. Dieses Klassifikationsmuster zeigte Ähnlichkeiten mit den in Tabelle 4.12 zu sehenden Korrelationen, welche ein gegensätzliches Verhalten von ARIMA und Isolation Forest hinsichtlich der Zeitreihenmerkmale nahelegten. Die Treffergenauigkeit der Klassifikation lag oberhalb der zu erwartenden Treffergenauigkeit eines zufälligen Klassifikators ($ACC = 0.395$). Damit lieferte die Methodik eine Hilfestellung bei der Auswahl eines geeigneten Detektors. Abgesehen von den Ausprägungen der Zeitreihenmerkmale sind jedoch weitere Kriterien bei der Detektorauswahl zu berücksichtigen. Beispielsweise ist die Inferenzzeit für den produktiven Einsatz des Anomaliedetektionsmodells relevant und die zu erwartende Art der Anomalie (Punktanomalie, kontextuell, konditionell) bei der Detektorauswahl ebenfalls von Interesse.

Die Klassifikation auf Basis der WAAM-Prozessdaten ergab das in Tabelle 4.5 festgehaltene Ergebnis. Für den Einsatz im Rahmen des Digitalen Zwillings wurden letztendlich die in der dritten Spalte der Tabelle notierten Detektoren verwendet.

Tabelle 4.5: Gegenüberstellung der Klassifikationsergebnisse sowie der ausgewählten Anomaliedetektoren für die WAAM-Sensordaten

Sensordaten	Klassifikations- ergebnis	Gewählter Detektor	Bemerkung
Spannung	CNN-AE	CNN-AE	
Strom	CNN-AE	CNN-AE	
Strukturschall	CNN-AE	CNN-AE	
Luftschall	ARIMA	/	Anomaliedetektion nicht umgesetzt
Gasfluss	ARIMA	MA	Zusätzlich Soll-Ist-Wertvergleich
Drahtvorschub	ARIMA	MA	Zusätzlich Soll-Ist-Wertvergleich
Spektrometer	/	/	Anomaliedetektion nicht umgesetzt
Schweißkamera	/	2D-CNN-AE	Wie in [P2] vorgestellt

Für die Spannungs-, Strom- und Strukturschalldaten wurde der CNN-AE eingesetzt. Der Gasfluss und der Drahtvorschub wurden mithilfe von MA-Detektoren sowie mithilfe von Soll-Ist-Wertvergleichen bewertet. Die Schweißkamerabilder konnten mithilfe des in [P2] vorgestellten 2D-CNN-AE zur Anomaliedetektion herangezogen werden. Die Luftschalldaten sowie die Spektrometerdaten wurden lediglich für die Defektklassifikation genutzt.

Evaluierung der Autoencoderarchitektur

Die folgenden Untersuchungen der AEs, MemAEs und C-MemAEs wurden anhand der normalisierten WAAM-Spannungsdaten vorgenommen. Beispielhaft werden die Ergebnisse für den Datensatz 6 aus Tabelle C.1 gezeigt. Die Optimierung der Hyperparameter für den AE mittels optuna [249] mit dem Ziel eines maximalen PR AUC-Werts ergab die im Anhang in Abbildung C.1 in Parallelkoordinaten dargestellten Ergebnisse. Der innerhalb von 200 Iterationen erreichte, maximale PR AUC-Wert lag bei 0.938. Das optimierte AE-Modell wies drei Blöcke je Encoder und Decoder, eine Kernelgröße von sechs, einen Kompressionsfaktor von 0.785, eine Dropouttrate von 0.022 und eine Steigung der leaky ReLU-Funktion von 0.024 auf. Darüber hinaus wurde der Vektor vor dem latenten Bereich abgeflacht, es wurden vier Kanäle genutzt und keine zusätzliche Linearisierungsschicht hinzugefügt. Auf Basis dieser Autoencoderarchitektur wurde ein MemAE aufgebaut und eine Hyperparameteroptimierung hinsichtlich der Speichermodulgröße und des Spärlichkeitsgrenzwerts vorgenommen. Sie resultierte in einem maximalen PR AUC-Wert von 0.948 und lag damit einen Prozentpunkt höher als ohne Speichermodul. Dieses Verhalten konnte für alle betrachteten WAAM-Datensätze reproduziert werden. Das Speichermodul des optimierten MemAE-Modells für Datensatz 6 umfasste $s = 30$ Speichermoduleinträge. Der Spärlichkeitsgrenzwert betrug 0.005. Eine Untersuchung des Lösungsraums für den MemAE ergab für die Speichermodulgröße und den Spärlichkeitsgrenzwert das in Abbildung 4.13 dargestellte Konturdiagramm.

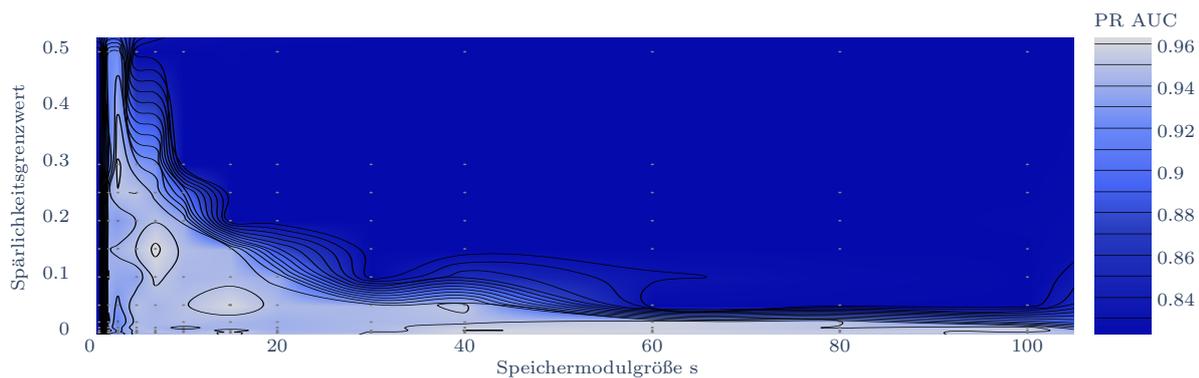


Abbildung 4.13: Konturdiagramm der Hyperparameteroptimierung für die Speichermodulgröße s und den Spärlichkeitsgrenzwert des MemAEs

Es ist eine deutliche Trennung in zwei Bereiche durch eine umgekehrt proportionale Kurve zu sehen. Oberhalb dieser Kurve wurden deutlich geringere PR AUC-Werte erreicht. Gong et al. nahmen an, dass der Spärlichkeitsgrenzwert zwischen $\frac{1}{s}$ und $\frac{3}{s}$ liegen sollte. Diese Annahme konnte in den Tests nur zum Teil bestätigt werden. Wie in der Abbildung gezeigt, ergibt sich als obere Grenze ein Wert von $\frac{2}{s}$, wobei in den Bereichen $s \leq 7$ und $s \geq 50$ kleinere Verhältnisse gewählt werden sollten. Eine untere Grenze für den Spärlichkeitsgrenzwert konnte lediglich im Bereich $s \leq 10$ ausgemacht werden. Bei Zeitreihendaten war eine Speichergröße von $N = 2$ hinreichend für ein gutes Detektionsergebnis. Zeitliche Verschiebungen des Eingangsvektors wurden damit nicht als separate Speichermoduleinträge abgelegt. Stattdessen spiegelte sich die zeitliche Verschiebung des Eingangsvektors im Speichermodul durch die gewichtete Auswahl der Speichermoduleinträge wider, wie Untersuchungen zeigten [S14]. Eine Hyperparameteroptimierung beim Datensatz 15 ergab für den AE einen maximalen PR AUC-Wert von 0.957 und für den MemAE von 0.963.

Evaluierung des Metalernansatzes bei der Anomaliedetektion

Zur Bewertung des Metalernansatzes für die Anomaliedetektion wurden die drei Modellarchitekturen AE, MemAE und C-MemAE einerseits mit und andererseits ohne MAML mithilfe der zufällig ausgewählten WAAM-Spannungsdatensätze 3, 5, 8, 9, 10, 11, 12 und 14 aus Tabelle C.1 vortrainiert. Anschließend erfolgte eine Anpassung innerhalb weniger Schritte mit zehn Datenelementen des bis dahin unbekanntes Datensatzes 15. Die Initialisierung des Speichermoduls gelang für den C-MemAE mittels der drei vorgestellten Initialisierungstechniken. Analog wurde das Speichermodul des MemAEs mittels der drei für diese Architektur genannten Initialisierungstechniken initialisiert. Beim AE fand keine Speicherinitialisierung statt. Die Versuche wurden dreimal wiederholt, wobei der Startpunkt jeweils für alle Architekturen der gleiche war. Die Ergebnisse der drei Läufe wurden gemittelt.

Die innerhalb von 60 Epochen maximal erreichten PR AUC-Werte jedes Detektors sind in Tabelle 4.6 festgehalten.

Tabelle 4.6: Maximale PR AUC-Werte für die verschiedenen Varianten von AE, MemAE und C-MemAE beim Lernen zur Modellanpassung an Datensatz 15 mithilfe von zehn Elementen

Architektur Initialisierung	AE		MemAE		C-MemAE		
	/	/	Zufall	Enc.	Zufall	Ähnlichkeit	Enc.
ohne MAML	0.785	0.811	0.824	0.839	0.838	0.833	0.850
mit MAML	0.819	0.828	0.826	0.833	0.827	0.828	0.837

Der AE ohne MAML hatte mit 0.785 den geringsten PR AUC-Wert, wohingegen der C-MemAE ohne MAML mit 0.850 den höchsten Wert aufwies. Die Diskrepanz zu den in Abschnitt 4.5.1 genannten Werten für den Datensatz 15 war auf den beschränkten Umfang der Trainingsdaten zur Modellanpassung sowie auf die nicht optimierte Modellarchitektur zurückzuführen. Während MAML beim AE zu einer Steigerung der Detektionsleistung von 0.034 führte, sorgte der Metalernalgorithmus beim MemAE nur für Verbesserungen, wenn das Speichermodul zur Initialisierung nicht angepasst wurde. Bei den beiden anderen Initialisierungstechniken für MemAE zeigten sich nur marginale Änderungen der PR AUC-Werte durch die Nutzung von MAML. Im Falle von C-MemAE bewirkte MAML in allen Fällen eine Verschlechterung der Detektionsleistung. Sowohl für MemAE als auch für C-MemAE zeigten sich die besten Ergebnisse für die Speichermodulinitialisierung mittels Encodingkopie.

Die Entwicklung der PR AUC-Werte entlang des Anpassungsschritts ist in Abbildung 4.14 für die Architekturen einerseits ohne MAML und andererseits mit MAML dargestellt.

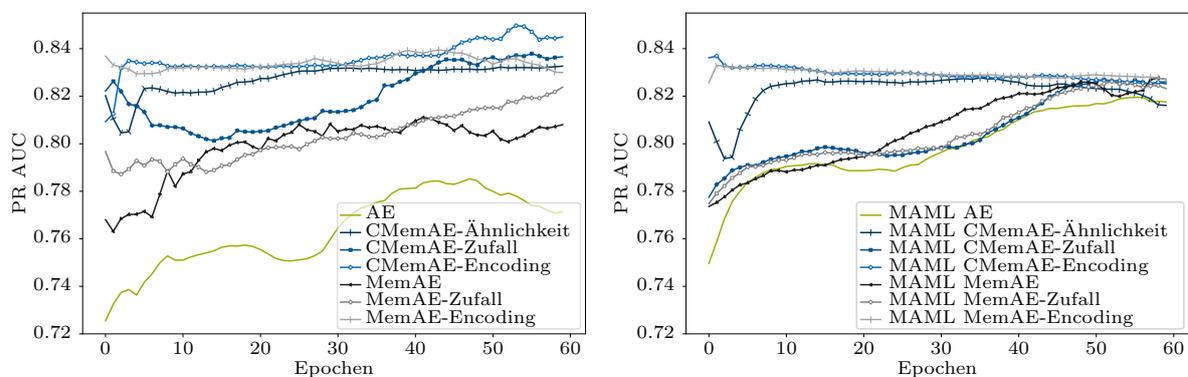


Abbildung 4.14: Entwicklung des PR AUC-Werts bei der Modellanpassung mit zehn Datenelementen

Durch die Nutzung der speichererweiterten Versionen des Autoencoders wurde unmittelbar

zu Beginn der Anpassung eine Verbesserung des PR AUC-Werts um bis zu 0.111 im Vergleich zum AE erreicht. Im Vergleich zur MAML-optimierten Variante des AEs betrug die Verbesserung bis zu 0.087. Während bei den mittels MAML angelernten Modellen in den meisten Fällen ein steiler Anstieg des PR AUC-Werts auszumachen war, zeigten die Modelle ohne MAML-Vortraining keine solch stark ausgeprägte Entwicklung. Eine Ausnahme bildeten die C-MemAE- und MemAE-Modelle, welche mittels Encodingkopie initialisiert wurden. Ihre Kurven verblieben annähernd konstant auf einem hohen Niveau, das von den anderen Architekturen erst nach 50 Epochen erreicht wurde. Dies ist auf die unmittelbare Nutzung der Daten als Teil des Modells zurückzuführen. Das C-MemAE-Modell, welches auf Basis der Kosinusähnlichkeit initialisiert wurde, zeigte ein ambivalentes Verhalten. Der Erfolg dieser Initialisierungstechnik ist von der Ähnlichkeit der Aufgabendatensätzen aus \mathcal{T}^{train} zum neuen Datensatz abhängig. Die Initialisierungstechnik hat damit besonders in der Anfangsphase einen hohen Einfluss auf die Detektionsleistung. Mit einer geeigneten Initialisierungsmethode zeigte sich innerhalb der ersten Epochen ein deutlicher Vorteil der modellbasierten Metalernmethoden gegenüber den Ansätzen, welche nur den optimierungsbasierten MAML-Algorithmus nutzten. Diese Methodik ist damit besonders für Umgebungen geeignet, in denen eine unmittelbare Modellanpassung gewünscht ist, beispielsweise wenn mittels autonomer Prozesseingriffe neue Prozessparameterkombinationen gesetzt werden. Eine Kombination der modellbasierten mit der optimierungsbasierten Metalernmethode war nicht förderlich um eine verbesserte Anomaliedetektion zu erreichen.

4.5.2 Evaluierung der Defektklassifikation

Für die Defektklassifikation wurden 17 Versuche mit natürlichen und forcierten Defekten durchgeführt. Die Defekte wurden annotiert und jeder Versuchsdatensatz als Aufgabendatensatz D_i mit $i \in 1, \dots, 17$ gehandhabt. Die 17 Datensätze wiesen die in Tabelle B.2 im Anhang festgehaltenen Charakteristika auf. Die Defektklassifikation wurde für drei Defekte (Oxidation, Schlackeeinschlüsse und Unstetigkeit) vorgenommen. Zur Erkennung von Poren bei Aluminiumlegierungen sei auf [P5] verwiesen. Je Defekt wurde ein Modell ohne Kontextwahrnehmung, das heißt lediglich mit $\mathbf{x}_{Messungen}$ als Eingangsvektor, sowie ein Modell inklusive Kontextwahrnehmung, das bedeutet mit $\mathbf{x}_{Kondition}$ und $\mathbf{x}_{Umgebung}$ als Teil des Eingangsvektors, trainiert. Dadurch wurde untersucht, inwieweit die Kontextwahrnehmung die Ergebnisse der Defektklassifikation beeinflusst.

Die Ergebnisse der Klassifikation für die Modelle ohne Metalernansatz sind in Tabelle 4.7 festgehalten. Sie zeigen den PR AUC-Wert, den maximalen F_1 -Wert, die zugehörige Genauigkeit und Sensitivität sowie die Treffergenauigkeit des jeweils besten Laufs der Hyperparameteroptimierung.

Tabelle 4.7: Ergebnisse der Defektklassifikation ohne Metalernansatz mit und ohne Kontext bei verschiedenen Defekten

Defekttyp	Kontextwahrnehmung	$PRAUC$	F_1	$PREC$	TPR	ACC
Unstetigkeit	ohne	0.462	0.455	0.414	0.506	0.988
	mit	0.487	0.470	0.498	0.446	0.986
Schlacke	ohne	0.816	0.784	0.713	0.871	0.983
	mit	0.828	0.783	0.712	0.871	0.975
Oxidation	ohne	0.855	0.810	0.755	0.873	0.989
	mit	0.990	0.977	0.977	0.977	0.998

Für Oxidations- und Schlackedefekte konnten hohe Werte für alle Evaluierungsmetriken erreicht werden. Bei Oxidationsdefekten wurden mit Kontext nahezu alle Datenpunkte korrekt klassifiziert. Für Schlackedefekte lag die Genauigkeit bei $PREC = 0.713$ und für Unstetigkeiten bei $PREC = 0.498$. Die Treffergenauigkeit lag aufgrund des hohen Klassenungleichgewichts bei Werten zwischen $ACC = 0.975$ und $ACC = 0.998$. Bezogen auf den PR AUC-Wert war in alle Fällen eine Verbesserung der Detektionsleistung durch die Integration der Kontextwahrnehmung zu erkennen. Je nach Defekt fiel die Verbesserung deutlicher oder geringfügiger aus. Im Fall der Unstetigkeit und der Schlacke lag die Verbesserung im Bereich von ein bis drei Prozentpunkten, wohingegen Kontext die Klassifikation von Oxidation um 0.135 hinsichtlich des PR AUC-Werts und um 0.222 hinsichtlich der Genauigkeit verbesserte. Bei Oxidation handelt es sich um einen Defekt, der auf eine Störung der Schutzgasatmosphäre zurückgeht und zu einem Anstieg der Spannungswerte führt. Durch die Kontextwahrnehmung erhielt das Modell Referenzwerte aus der räumlichen Umgebung sowie der Konditionierung, sodass das Modell zwischen oxidations- und prozessparameterbedingter Spannungswertveränderung unterscheiden konnte. Bei Schlackedefekten half die Konditionierung und die räumliche Umgebung hingegen nur geringfügig. Schlacke kann einerseits aus einer Oxidation in einer vorangegangenen Lage hervorgehen. Andererseits lässt sich Schlacke beispielsweise auf Verunreinigungen am Draht zurückführen, die ihren Ursprung nicht in der vorangegangenen Lage haben. Dadurch sind auffällige Messwerte benachbarter Punkte lediglich ein Indikator für das Entstehen eines Schlackedefekts. Der zusätzliche Kontext schadete zwar nicht, half aber auch nicht nennenswert. Bei Unstetigkeiten zeigte sich ein ähnliches Verhalten. Unstetigkeitsdefekte weisen eine geringe zeitliche Ausdehnung auf, welche die Klassifikation erschweren. Da der zugrunde liegende physikalische Vorgang zwischen zwei CMT-Zyklen stattfinden kann, ist beispielsweise in den Strom- und Spannungsdaten nicht immer ein abnormales Verhalten zu erkennen. Die Kontextwahrnehmung half deshalb nur, wenn in der vorherigen Lage eindeutig ein Defekt zugeordnet werden konnte, der eine Unstetigkeit zur Folge hatte.

Das Training der Klassifikationsmodelle wurde mit dem vorgestellten Metalernansatz auf Basis von MAML verglichen. Die Ergebnisse sind in Tabelle 4.8 notiert.

Tabelle 4.8: Ergebnisse der Defektklassifikation für das metaangelernete MLP mit und ohne Kontext bei verschiedenen Defekten

Defekttyp	Kontextwahrnehmung	$PRAUC$	F_1	$PREC$	TPR	ACC
Unstetigkeit	ohne	0.585	0.546	0.562	0.531	0.993
	mit	0.583	0.549	0.540	0.558	0.994
Schlacke	ohne	0.832	0.772	0.691	0.875	0.975
	mit	0.829	0.760	0.707	0.822	0.981
Oxidation	ohne	0.958	0.900	0.890	0.910	0.992
	mit	0.999	0.993	0.991	0.996	0.999

Die mittels MAML trainierten Modelle für Unstetigkeit und Oxidation erreichten höhere Werte für die Evaluierungsmetriken als die Klassifikationsmodelle ohne Metalernansatz. Für Unstetigkeiten lag der PR AUC-Wert ohne Kontextwahrnehmung bei 0.585 und damit 0.123 Prozentpunkte höher als ohne MAML. Die Genauigkeit verbesserte sich um 0.148 Prozentpunkte. Oxidationsdefekte konnten mit einer Genauigkeit von 0.991 eingeordnet werden, sodass die Verbesserung zum MLP mit Kontextwahrnehmung aus Tabelle 4.7 auf Grund des bereits hohen Wertes bei lediglich 0.014 lag. Der PR AUC-Wert des Modells ohne Kontextwahrnehmung konnte mit dem Metalernansatz um 0.103 verbessert werden. Bei der Klassifikation von Schlackedefekten zeigte sich keine Verbesserung durch die Nutzung von Metalernen beim Training. Es wurde ohne Kontextwahrnehmung ein um 0.004 verbesserter PR AUC-Wert

von 0.832 erreicht. Ein Mehrwert der Kontextwahrnehmung war für den Metalernansatz lediglich für Oxidationsdefekte zu erkennen (0.041). Bei Unstetigkeiten und Schlacke ergaben sich keine Verbesserungen hinsichtlich der Klassifikationsleistung. Dies ließ sich auf die separate Betrachtung der verschiedenen Fertigungsszenarien als Aufgabendatensätze beim Metalernansatz zurückführen. Das Modell wurde dadurch implizit konditioniert angelern, sodass Relationen zwischen Messwertausprägungen und $\mathbf{x}_{\text{Kondition}}$ bereits im Modell hinterlegt waren. Dadurch boten diese Informationen bei metaangelerten Modellen keinen zusätzlichen Mehrwert. Während die Integration des Umgebungskontexts $\mathbf{x}_{\text{Umgebung}}$ bei der Erkennung von Unstetigkeiten und Schlacke keinen Vorteil bot, ließ sich damit die Klassifikationsleistung für Oxidationsdefekte steigern.

Im Gegensatz zur Anomaliedetektion erfordert die Defektklassifikation auf Grund der zuvor durchgeführte Merkmalsextraktion für die Strom- und Spannungsdaten sowie für die Spektrometerdaten expertengebundenes Prozesswissen. Sie bietet damit bei der Skalierung mehr Herausforderungen als die Anomaliedetektion und ist darauf angewiesen, dass die Merkmalsextraktion gegenüber Änderungen der Prozessparameter oder des Materials robust ist. Die Übertragbarkeit der vorgestellten Methodik zur Defektklassifikation auf andere CMT-Prozessparameter sowie auf verschiedene Defekte konnte jedoch nachgewiesen werden (siehe Tabelle B.2 im Anhang).

4.5.3 Evaluierung der Abstandsmessung

Die Methodik zur Messung des Abstands zwischen Schweißbrenner und Bauteil wurde für eine neutrale Schweißbrennerstellung evaluiert. Diese bewirkte, wie in [P1] beschrieben, eine geringere Richtungsabhängigkeit der Messungen.

Merkmalsselektion

Aus den Sensordaten wurden die in Abschnitt 4.4 beschriebenen Merkmale extrahiert und anhand ihrer Korrelation mit dem Abstand selektiert. Als Analysedatensatz diente ein Experiment, in welchem der Abstand einer definierten Kurve ($d_{NtW} = 10 \text{ mm} \rightarrow d_{NtW} = 18 \text{ mm} \rightarrow d_{NtW} = 10 \text{ mm} \rightarrow d_{NtW} = 18 \text{ mm}$) folgte.

Spannungssensor: Für die extrahierten Merkmale der Spannungsdaten ergaben sich die in Tabelle 4.9 gezeigten Korrelationen. Während $t_{\text{CMT-Zyklus}}$, $\sigma_{\text{U-Hintergrund}}$ und $r_{\text{Zyklusphasen}}$ le-

Tabelle 4.9: Rangkorrelationskoeffizienten nach Spearman r_s und Pearsonkorrelationen $\rho_{x,y}$ der extrahierten Merkmale der Spannungsdaten mit dem Abstand zwischen Schweißbrenner und Bauteil

Merkmale	r_s	$\rho_{x,y}$
$\mu_{\text{U-Hintergrund}}$	-0.572	-0.547
μ_{U}	-0.380	-0.373
$t_{\text{CMT-Zyklus}}$	-0.159	-0.143
$\sigma_{\text{U-Hintergrund}}$	-0.089	-0.044
$r_{\text{Zyklusphasen}}$	-0.069	-0.069

diglich einen geringen Zusammenhang mit d_{NtW} zeigten, wiesen μ_{U} und $\mu_{\text{U-Hintergrund}}$ erhöhte Korrelationswerte auf.

In der Hintergrundphase des CMT-Zyklus wird der Lichtbogen aufrecht erhalten, der Metalltropfen gebildet und der Draht in Richtung des Bauteils bewegt bis der Kurzschluss erfolgt. Der stärkere Zusammenhang von Spannung und Abstand in dieser Phase könnte auf die Ionisierungsenergien der beteiligten Elemente zurückzuführen sein. Wie in Simulationen nachgewiesen wurde, führt ein größerer Abstand zwischen Bauteil und Schweißbrenner zu einer reduzierten Argon- und einer erhöhten Konzentration von Umgebungsluft in dem vom Lichtbogen abgedeckten Bereich [P4]. Da die Ionisierungsenergien für die in der Umgebungsluft primär enthaltenen Elemente Stickstoff (14.5 eV [256]) und Sauerstoff (13.6 eV [256]) geringer als die von Argon (15.8 eV [256]) sind, wird bei erhöhtem Abstand eine geringere Hintergrundspannung benötigt, um den Lichtbogen aufrecht zu erhalten. Dagegen ist eine höhere Hintergrundspannung bei einem geringeren Abstand erforderlich. Der zusätzliche elektrische Widerstand im Draht ist im Vergleich zu dem des Lichtbogenplasmas vernachlässigbar.

Spektrometer: Die Pearsonkorrelationen der relativen Intensitäten je Wellenlänge mit d_{NfW} sind in Abbildung 4.15 dargestellt.

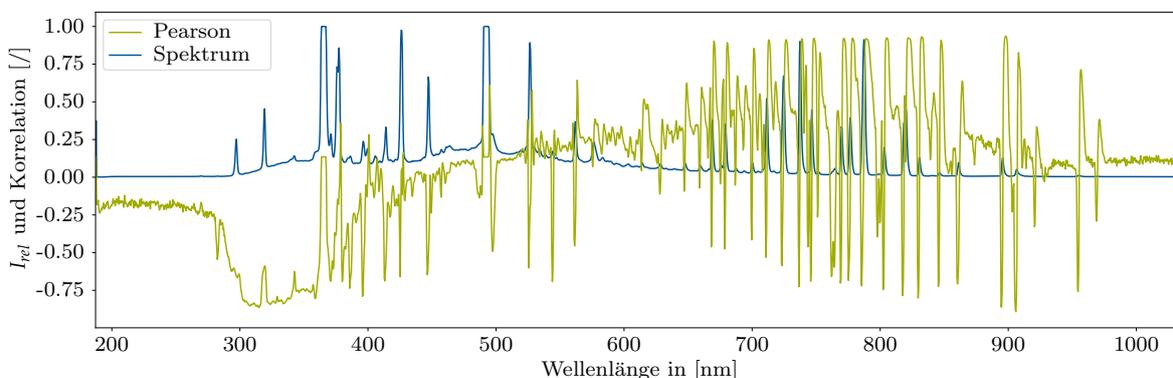


Abbildung 4.15: Pearsonkorrelationen der relativen Intensitäten der betrachteten Wellenlängen mit d_{NfW} in einem Spektralbereich von 187.3 nm bis 1037.2 nm

Für den Wellenlängenbereich zwischen 280 nm und 360 nm lag eine erhöhte absolute Korrelation vor. Sie korrespondierte mit dem UV-A Bereich des Spektrums. Darüber hinaus zeigten sich dezidierte Scheitelpunkte in der Korrelationskurve, welche mit den Flanken der Scheitelpunkte im Spektrum übereinstimmten. Aufgrund der hohen absoluten Pearsonkorrelation für diese Wellenlängen war von einem nahezu linearen Zusammenhang zwischen der relativen Intensität und d_{NfW} auszugehen. Die höchste absolute Pearsonkorrelation trat mit einem Wert von 0.896 für die Wellenlänge 905 nm auf. Eine spektralanalytische Untersuchung, bei der die Spektrallinie 905 nm mit den charakteristischen Spektrallinien der im Prozess beteiligten Elemente (Draht/Substrat: Mg, Al und Si; Inertgasatmosphäre: Ar; potentielle Einschlüsse/Verunreinigungen: H, C, N und O) verglichen wurde, ergab keine unmittelbare Zuordnung. Das Zusammenfallen der höchsten Korrelationswerte mit den Flanken der Scheitelpunkte ließ jedoch auf eine Verschiebung derselben bei sich änderndem Abstand schließen. Ein abnehmender Abstand führte in den Experimenten zu einer Verschiebung des Spektrums in den kurzwelligeren Bereich. Dies könnte an einem sich ändernden Druck im Bereich des Lichtbogens liegen, der in einer Verschiebung des Emissionsspektrums resultierte. Ein ähnliches Verhalten wurde von Quintanilla et al. für die Infrarotemissionen von Thulium bei veränderlichem Gasdruck nachgewiesen [257]. Innerhalb dieser Arbeit konnte der physikalische Zusammenhang jedoch nicht final geklärt werden, weshalb für weitere Untersuchungen auf die Literatur [73, 92, 94, 257, 258] verwiesen wird.

Für die Schweißkamera war keine Merkmalsselektion erforderlich, da lediglich die Schweißdrahtlänge mithilfe des CNNs extrahiert wurde. Die Rangkorrelationskoeffizienten nach Spearman r_s und die Pearsonkorrelationen $\rho_{x,y}$ aller selektierten Merkmale mit d_{NIW} sind in Tabelle 4.10 zusammengestellt. Die höchste absolute Korrelation wiesen die Daten des Spektrometers für die Wellenlänge 905 nm auf, gefolgt von der Länge des im Schweißkamerabild detektierten Drahts. Die Spannungsdaten zeigten deutlich geringere absolute Korrelationswerte als die Daten des Spektrometers und der Schweißkamera.

Tabelle 4.10: Rangkorrelationskoeffizienten nach Spearman r_s und Pearsonkorrelationen $\rho_{x,y}$ der betrachteten Sensorsignale bezüglich des Abstands zwischen Schweißbrenner und Bauteil

Sensor	r_s	$\rho_{x,y}$
Spannungssensor	-0.572	-0.547
Spektrometer	-0.903	-0.896
Schweißkamera	0.847	0.840

Die Messpunkte der drei Merkmale sind in Abbildung 4.16 über den Abstand d_{NIW} dargestellt.

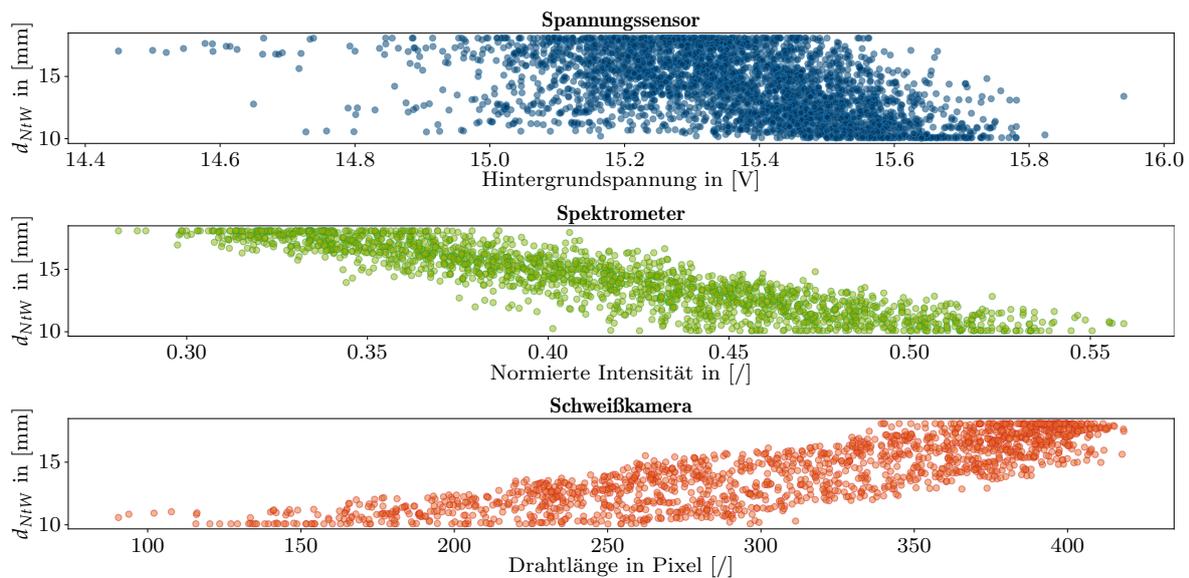


Abbildung 4.16: Ausprägungen der extrahierten Merkmale der Daten von Spannungssensor, Spektrometer und Schweißkamera über den Abstand d_{NIW} zwischen Schweißbrenner und Bauteil

Es zeigte sich ein annähernd linearer Verlauf für die Messung mittels Spektrometer und Schweißkamera. Auch die Spannungsdaten ließen einen Trend erkennen, der jedoch von einem starken Rauschen überlagert war. Die Messauflösung der verwendeten Referenzsensoren genügte dabei den Anforderungen für die Abstandsmessung (siehe Tabelle A.1). So ermöglichte der Spannungssensor eine maximal erreichbare Auflösung der Abstandsmessung von 0.244 mm, die Kamera von 0.023 mm und das Spektrometer von 0.001 mm. In der Punktwolke der Kameradaten war im Bereich von 18 mm eine Verdichtung der Messpunkte zu sehen, welche auf den auf 18 mm begrenzten ROI aus Abbildung 4.9 zurückzuführen ist.

Evaluierung der Robustheit und Sensitivität

Die Merkmale der drei Sensoren wurden hinsichtlich ihrer Robustheit und Sensitivität bei Richtungs-, Geometrie- und Prozessparametersatzänderungen untersucht. Dazu wurden zunächst die Konturen dreier Quadrate mittels WAAM aufgetragen. Je Quadrat wurde ein konstanter Abstand d_{NfW} (10 mm, 14 mm und 18 mm) eingehalten. In Abbildung 4.17 sind die Verteilungen der Merkmale für die konstanten Abstände als Histogramme dargestellt.

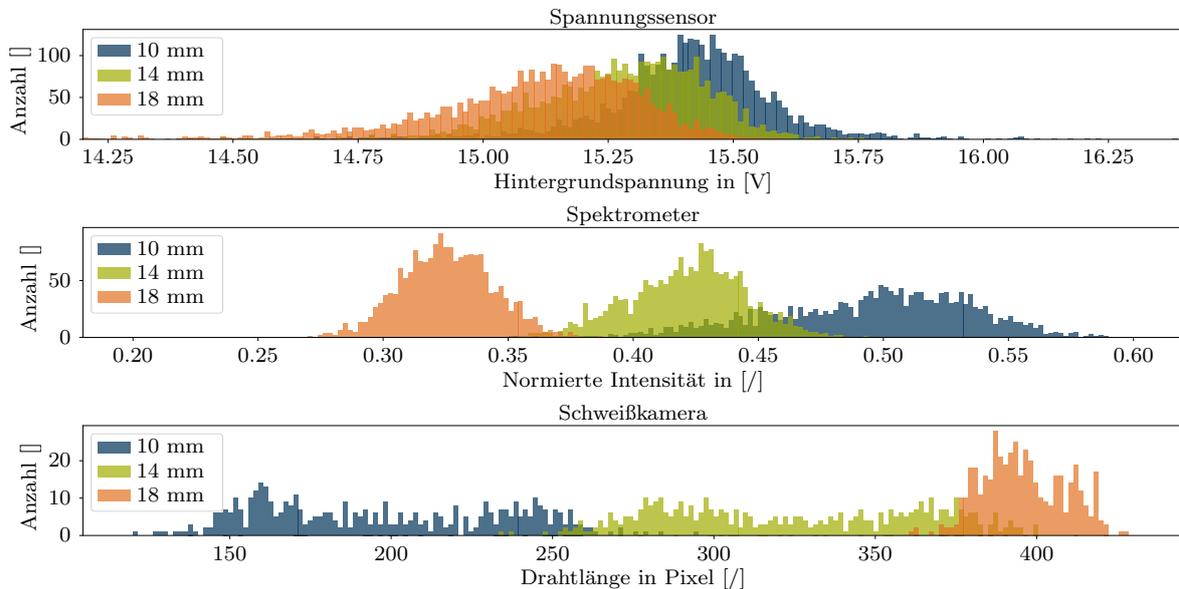


Abbildung 4.17: Histogramme für die extrahierten Merkmale der Daten von Spannungssensor, Spektrometer und Schweißkamera bei drei konstanten Abständen d_{NfW} (10 mm, 14 mm und 18 mm) zwischen Schweißbrenner und Bauteil

Die Spannungsdaten wiesen rechtsschiefe Verteilungen mit hohen Streubreiten auf, die mit steigendem Abstand d_{NfW} zunahm. Dies erschwerte eine Zuordnung eines Messwerts zum Abstand. Ausreißer waren in beide Richtungen zu sehen. Die Spektrometerdaten zeigten normalverteilte Daten mit geringerer Streubreite. Je Abstandswert war eine Spitze im Histogramm zu erkennen. Mit abnehmendem Abstand verbreiterte sich die Verteilung der Messwerte. Die Auswertung der Drahtlänge resultierte in drei in einander übergehende, multimodale Verteilungen ohne eindeutige Spitzen. An den Randbereichen jeder Verteilung war die Anzahl an Messpunkten erhöht. Dies ging auf die Messmethode zurück, welche die Drahtlänge innerhalb des oszillierenden CMT-Prozesses auswertete und somit in über den Oszillationsbereich verteilten Messpunkten mit Spitzen in den Umkehrpunkten resultierte. Für $d_{NfW} = 18$ mm ergab sich eine Ansammlung an Messwerten, die auf den durch den ROI begrenzten Messbereich zurückzuführen war. In allen Fällen waren die Unterschiede zwischen den Verteilungen für 10 mm, 14 mm und 18 mm statistisch signifikant (Mann-Whitney-U-Test: $p < 0.01$).

In Abbildung 4.18 ist der zeitliche Verlauf der Abstandsmessungen für zwei Testkörper dargestellt. Die Messungen wurden jeweils über einen Zeitraum von einer Sekunde gemittelt und mithilfe linearer Regressionsmodelle in Abstandsmesswerte in [mm] übertragen.

Im oberen Diagramm wurde der Abstand entlang eines helixförmigen Werkzeugspfades gemessen. Anfangs wurde die Schichthöhe sehr hoch parametrisiert, um einen zunehmenden Abstand zwischen Schweißbrenner und Bauteil zu erzielen. Am Umkehrpunkt (Zeit: 395 s) wurde der Prozessparametersatz verändert, so dass der Abstand nachfolgend wieder abnahm. Dieser Umkehrpunkt war in den Spannungs- und den Spektrometerdaten als Unstetigkeit erkennbar, was auf eine Prozessparametersatzabhängigkeit der Messwerte hindeutet. Die Kameradrahtlängenbestimmung war robust gegenüber dieser Änderung. In den Spektrometerdaten war

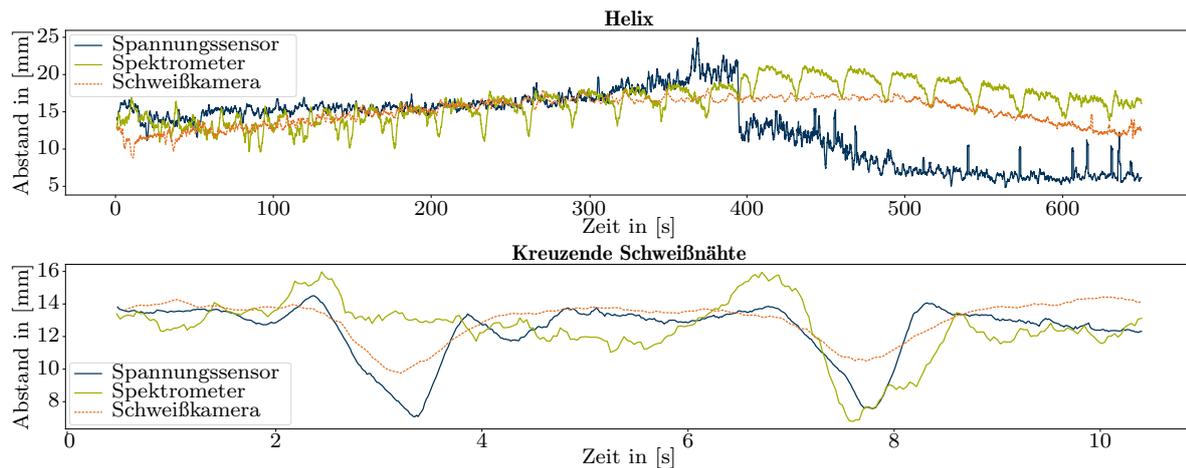


Abbildung 4.18: Messung des Abstands vom Schweißbrenner zum Bauteil entlang des Aufbaus zweier Testkörper: im oberen Diagramm für einen helixförmigen Werkzeugweg, im unteren Diagramm für eine Spur, welche zwei quer verlaufende Schweißnähte kreuzt

zudem Saisonalität zu erkennen. Sie korrespondierte mit dem helixförmigen Werkzeugpfad und ging auf Reflexionen und Abschattungen des Lichtbogens durch die vor bzw. hinter dem TCP liegende Schweißnaht zurück. Die Messung mittels Spektrometer wies damit trotz Normierung durch Gleichung 4.4 eine Richtungs- und Geometrieabhängigkeit auf. Bei der Abstandsmessung mittels Drahtlängenbestimmung war eine geringfügige Saisonalität zu erkennen, die allerdings eine deutlich geringere Ausprägung als bei den Spektrometerdaten aufwies. Bei nachgelagerter Betrachtung der Schweißkameravideos fiel in einzelnen Bauteilabschnitten eine erhöhte Helligkeit im Bild auf, die auf Reflexionen der aktiven Laserbeleuchtung am Bauteil zurückging. Die Spannungsdaten waren auf Grund der in-situ Messung und der neutralen Brennerstellung robust gegenüber Geometrie- und Richtungsänderungen.

Das untere Diagramm in Abbildung 4.18 zeigt die Abstandsmessungen für eine gerade Schweißnaht, welche über zwei zuvor gezogene Schweißnähte hinweg führte. Für die Messung wurde die Kamera- und Spektrometerposition und -orientierung angepasst. Die Höhenänderung in Folge der ersten quer verlaufenden Schweißnaht war in den Merkmalen des Spannungssensors und der Schweißkamera zu erkennen. Die Höhenänderung in Folge der zweiten quer verlaufenden Schweißnaht war in allen Fällen sichtbar. Bei den Lichtemissionen kam es zu starken Reflexionen und Abschattungen, sodass das Spektrometer kurz vor und nach den quer verlaufenden Schweißnähten keine verlässlichen Messwerte lieferte. Zudem bewirkte die Umpositionierung des Spektrometers eine Änderung der Messwerte, die durch eine Rekalibrierung des Regressionsmodells behoben werden musste. Die Abstandsmessungen mittels Kamera und Spannungssensor konnten die kurzzeitigen Abstandsänderungen detektieren.

Der Abstand zwischen Bauteil und Schweißbrenner wies eine hohe absolute Korrelation mit den Messungen mittels Spektrometer und Schweißkamera auf. Für die Messung mittels Spannungssensor und Spektrometer war eine Rekalibrierung bei Prozessparametersatzänderung erforderlich. Bei Messungen mittels Spektrometer und Kamera war eine Rekalibrierung im Falle einer Umpositionierung der Sensoren notwendig. Die Messung mittels Spannungssensor wies starkes Rauschen auf und die Messung mittels Spektrometer eine hohe Geometrie- und Richtungsabhängigkeit.

Für den industriellen Einsatz zeigt die Messung mittels Drahtlängenbestimmung im Kamerabild ein robustes Messverhalten, welches richtungs- und schichtinvariant ist. Sofern keine Reflexionen am Bauteil auftreten, ist die Abstandsmessung mithilfe der Schweißkamera darüber hinaus

geometrieunabhängig. Aufgrund der externen Messung und der Ausblendung des Lichtbogens ist sie darüber hinaus prozessparameterunabhängig.

4.6 Zusammenfassung

In diesem Kapitel wurde die Verarbeitung der WAAM-Prozessdaten als Eingangsgrößen für den Digitalen Zwilling im Rahmen der Prozessüberwachung vorgestellt. Zunächst wurde der WAAM-Prozess analysiert und eine Ursachen-Wirkungs-Analyse zur Untersuchung der Ursachen von Unregelmäßigkeiten in den Prozessdaten vorgenommen. Darauf basierend wurde eine Sensorauswahl getroffen und der Prozess digital modelliert. Unregelmäßigkeiten in den Prozessdaten wurden mithilfe einer Anomaliedetektion erkannt. Zunächst wurde eine Methodik dargelegt, mit welcher die semiautomatisierte Auswahl eines geeigneten Detektors auf Basis von Zeitreihenmerkmalen möglich wurde. Anschließend wurde eine parametrisierbare Autoencoderarchitektur generiert und diese hinsichtlich ihrer Fähigkeit zur Detektion von Anomalien optimiert. Sie wurde anschließend um ein konditioniertes, externes Speichermodul erweitert, um Übertragbarkeit durch ein modellbasiertes Metalernkonzept zu erreichen. Die Defektklassifikation wurde mithilfe eines MLP-basierten Ansatzes für Oxidations-, Schlacke- und Unstetigkeitsdefekte umgesetzt. Durch Kontextwahrnehmung und MAML-basiertes Metalernen konnte die Klassifikationsleistung für Oxidations- und Unstetigkeitsdefekte gesteigert werden. Abschließend wurden Methoden zur Messung des Abstands zwischen Schweißbrenner und Bauteil beleuchtet. Dafür wurden Merkmale der Daten von drei Sensoren extrahiert, selektiert und auf ihre Korrelation zum Abstand analysiert. Die in diesem Kapitel gewonnenen Informationen über den Prozess werden in Kombination mit der digitalen Bauteilrepräsentation für die im nachfolgenden Kapitel vorgestellten datengestützten Prozesseingriffe genutzt.

Kapitel 5

Datengestützter Prozesseingriff

5.1	Abstandsregelung	89
5.1.1	Systemidentifikation	89
5.1.2	Regelkreis	91
5.2	Präskriptive Prozessparameteranpassung	94
5.2.1	Positionsprädiktion	95
5.2.2	Kontextspezifische Prozessparameteranpassung	96
5.3	Evaluierung	96
5.3.1	Evaluierung der Abstandsregelung	97
5.3.2	Evaluierung der präskriptiven Prozessparameteranpassung	100
5.4	Zusammenfassung	102

Umgebungseinflüsse wie beispielsweise die Luftfeuchtigkeit, der Grad der Werkzeugabnutzung, die Materialcharge und Verunreinigungen auf dem Substrat oder dem Draht können auch bei optimalen Prozessparametern den Prozess negativ beeinflussen. Sie stellen ein hohes Maß an Unsicherheit für die Bauteilqualität dar und erfordern einen hohen Aufwand zur Beseitigung. Das dynamische Temperaturverhalten im Bauteil während des WAAM-Prozesses erschwert zudem die Wahl geeigneter Prozessparameter, sodass diese in mehreren Iterationen bauteilspezifisch optimiert werden müssen.

Prozesseingriffe können diesen Problemen entgegenwirken, indem sie den Prozess fehlertoleranter gestalten. Sie passen Prozessparameter autonom an, um Defekte zu verhindern oder zu beheben und auf diese Weise Folgekosten zu reduzieren. Dadurch kann ein erfolgreicher Druck beim ersten Versuch erreicht und die FPY erhöht werden.

Die Fähigkeit, solche Eingriffe durchzuführen, ist charakteristisch für den Digitalen Zwilling. In diesem Kapitel wird deshalb in Ergänzung zu den vorangegangenen Kapiteln der Schritt vom Digitalen Schatten zum Digitalen Zwilling für die additive Fertigung mittels Lichtbogen-auftragschweißen getan.

Für den datengestützten Prozesseingriff ergeben sich folgende Anforderungen:

1. Sicherung eines konstanten Abstands zwischen Schweißbrenner und Bauteil
2. Erhöhung der Fehlertoleranz
3. Omnidirektional einsetzbare, schichtinvariante Methoden
4. Möglichkeit zur Prozessqualifizierung

WAAM-Prozesseingriffe können auf vier Arten umgesetzt werden:

1. **Prozesswarnung:** Benachrichtigung der Anlagenbedienenden und der Qualitätsingenieure und -ingenieurinnen zur Veranlassung einer Aktion
2. **Prozessabbruch:** Abbruch des laufenden Prozesses zur Vermeidung von Folgekosten
3. **Prozessregelung:** Reaktive Anpassung der Prozessparameter zur Vermeidung von Defekten
4. **Präskriptive Prozessparameteranpassung:** Proaktive Anpassung von Prozessparametern zur Behebung von Defekten und zur Vermeidung von (Folge-)Defekten

Während der Prozessabbruch, die Prozessregelung und die präskriptive Prozessparameteranpassung eine Interaktion des Digitalen Zwillings mit der physischen Entität bedeuten, hat die Prozesswarnung einen rein informativen Charakter. Gegebenenfalls kann sie mit den anderen drei Arten des Prozesseingriffs einhergehen. Die Wahl der geeigneten Methode zum Prozesseingriff erfolgt abhängig vom Anwendungsszenario gemäß des in Abbildung 5.1 dargestellten Entscheidungsbaums. Darin wird in Anlehnung an die Informationen, welche in Kapitel 4 extrahiert wurden, zwischen einer Abstandsänderung, einem detektierten Defekt sowie einem überschrittenen Grenzwert einer Qualitätsmetrik unterschieden.

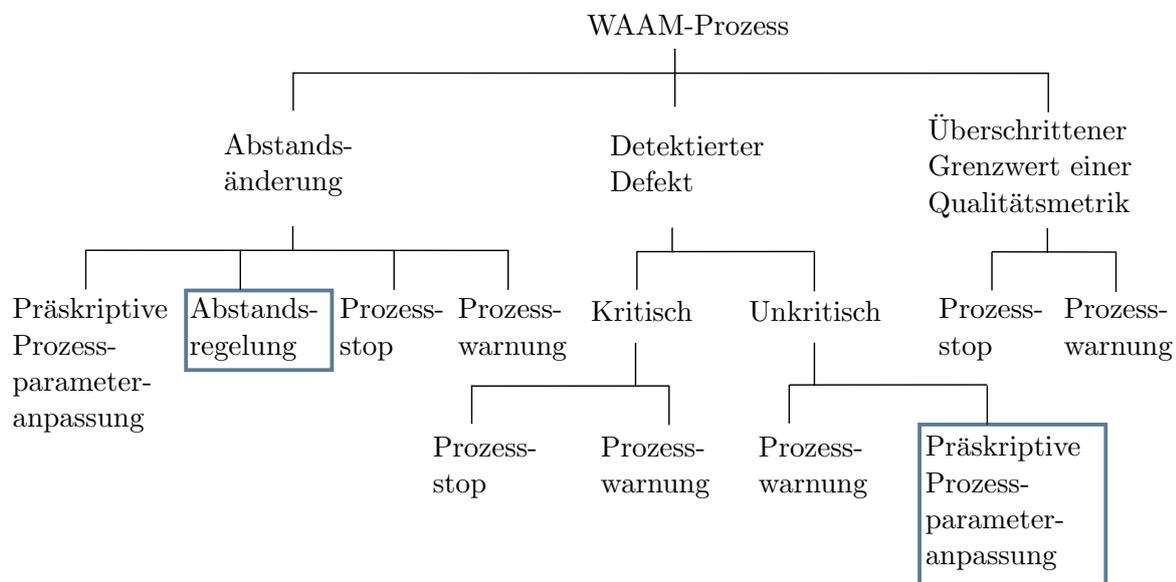


Abbildung 5.1: Entscheidungsbaum zur Auswahl des erforderlichen Prozesseingriffs. Blau umrandet sind die in dieser Arbeit methodisch erarbeiteten Prozesseingriffe hervorgehoben.

Um eine Prozesswarnung und einen Prozessabbruch zu initiieren, werden die verfügbaren Prozessinformationen (Anomaliewert, Defekttyp, Abstand zwischen Schweißbrenner und Bauteil, lokale Anomaliedichte, Defektgruppenausdehnung) ausgewertet. Die Warnung kann über die Benutzeroberfläche an der Fertigungsmaschine oder in der Leitwarte per Fernanbindung angezeigt werden. Der automatisierte Prozessabbruch erfordert eine hohe Genauigkeit und Sensitivität des Prozessüberwachungssystems, da eine hohe Anzahl an FP-Meldungen der Akzeptanz des Systems in der Industrie abträglich ist [208]. Da die Umsetzung von Prozesswarnung und Prozessabbruch primär von der Wahl geeigneter Grenzwerte abhängt und damit anwendungsfallspezifisch ist, werden diese beiden Typen des Prozesseingriffs in der vorliegenden Arbeit nicht weiter betrachtet. Stattdessen wird in den folgenden Abschnitten der Fokus auf die Prozessregelung (Abschnitt 5.1) und die präskriptive Prozessparameteranpassung (Abschnitt 5.2) gelegt. Das Kapitel schließt mit einer Evaluierung der vorgestellten Methoden sowie einer Zusammenfassung. Teile dieses Kapitels wurden der Fachöffentlichkeit

bereits in Publikationen [P6, P9] vorgestellt. Darüber hinaus wurden vom Autor dieser Schrift Studienarbeiten [S2, S11, S16] zu einzelnen Aspekten des Kapitels betreut.

5.1 Abstandsregelung

Der WAAM-Prozess ist ein Multiachsprozess, bei welchem ein konstanter Abstand zwischen Schweißbrenner und Bauteil eingehalten werden muss, um Kollisionen zu verhindern und einen aus dem Fokus laufenden Prozess zu vermeiden. Auf Grund von inhärenten Prozessinstabilitäten und thermomechanischen Phänomenen kann es zu Abweichungen vom Sollabstand kommen. [75] Im Folgenden wird eine omnidirektionale, schichtinvariante Prozessregelung vorgestellt, deren Ziel die Einhaltung eines konstanten Abstands zwischen Schweißbrenner und Bauteil ist. Es wird eine experimentelle Systemidentifikation vorgenommen, deren Ergebnisse in ein Regelungskonzept überführt werden.

5.1.1 Systemidentifikation

Die Systemidentifikation ermöglicht die Modellierung der regelungsrelevanten Aspekte des WAAM-Prozesses. Vorherige Forschungsarbeiten identifizierten den Energie- und Volumeneintrag entlang des Werkzeugpfades aus Gleichung 2.1 und Gleichung 2.2 als die Haupteinflussfaktoren auf die Schweißnahtgeometrie. Aufgrund der Kopplung der Drahtvorschubgeschwindigkeit mit Schweißspannung und -strom stehen für einen Prozesseingriff mit v_{TCP} und v_{WF} zwei Prozessparameter als Stellgrößen bereit, um unmittelbar Einfluss auf die Schweißnahtgeometrie zu nehmen.

Für die Systemidentifikation wurden zunächst 21 Wände mit je zwei CMT-P- und zehn CMT-Lagen mit dem Material AlSi12 aufgebaut. Während die CMT-P-Lagen stets die gleichen Prozessparameter aufwiesen ($v_{TCP} = 350 \text{ mm min}^{-1}$, $v_{WF} = 5.0 \text{ m min}^{-1}$), wurde für jede Wand ein anderer CMT-Prozessparametersatz gewählt ($200 \text{ mm min}^{-1} \leq v_{TCP} \leq 450 \text{ mm min}^{-1}$, $2.5 \text{ m min}^{-1} \leq v_{WF} \leq 4.5 \text{ m min}^{-1}$). An drei Stellen jeder Wand wurde die Gesamthöhe sowie die Breite der letzten Lage gemessen. Der Median der drei Messwerte ist in Abbildung 5.2 abhängig von v_{TCP} und v_{WF} für alle Wände dargestellt, wobei aus der Gesamthöhe auf die Höhe einer einzelnen CMT-Schweißnaht geschlossen wurde.

Eine höhere Schweißgeschwindigkeit resultierte in einer geringeren Schweißnahtbreite und -höhe. Ein höherer Drahtvorschub führte zu breiteren Schweißnähten, beeinflusste die Schweißnahthöhe jedoch kaum. Eine quantitative Korrelationsanalyse der Schweißnahthöhe h_S und -breite b_S mit den beiden Stellgrößen ist in Tabelle 5.1 notiert.

Tabelle 5.1: Rangkorrelationskoeffizienten nach Spearman r_s und Pearsonkorrelationen $\rho_{x,y}$ zwischen den Schweißparametern (Schweißgeschwindigkeit v_{TCP} und Drahtvorschubgeschwindigkeit v_{WF}) und der Schweißnahtgeometrie (Schweißnahtbreite b_S und Schweißnahthöhe h_S)

Stellgröße	Regelgröße	r_s	$\rho_{x,y}$
v_{TCP}	h_S	-0.900	-0.905
v_{TCP}	b_S	-0.388	-0.453
v_{WF}	h_S	-0.093	-0.156
v_{WF}	b_S	0.859	0.854

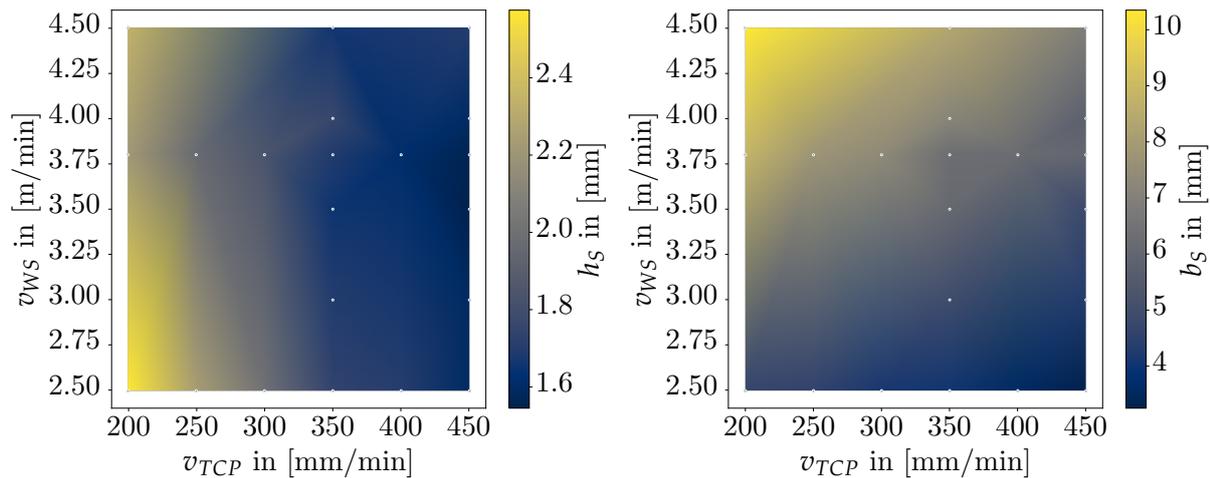


Abbildung 5.2: Zusammenhang zwischen den Schweißparametern (Schweißgeschwindigkeit v_{TCP} und Drahtvorschub v_{WF}) und der Schweißnahtgeometrie (Schweißnahtbreite b_S und Schweißnahthöhe h_S) als Ergebnis der Systemidentifikation. Messpunkte, an denen sich die Interpolation orientierte, sind als weiße Punkte dargestellt.

Aufgrund des hohen Pearson'schen Korrelationskoeffizienten kann der Zusammenhang zwischen Schweißgeschwindigkeit und Schweißnahthöhe sowie zwischen Drahtvorschub und Schweißnahtbreite als linear approximiert werden. Die Schweißgeschwindigkeit hat zudem einen hohen Einfluss auf die Schweißnahtbreite. Der geringe Einfluss des Drahtvorschubs auf die Schweißnahthöhe geht auf die Überlagerung zweier gegenläufiger Effekte zurück. Der erhöhte Drahtvorschub führt zu einem erhöhten Auftragsvolumen, wohingegen der erhöhte Energieeintrag für eine flachere Schweißnaht sorgt, wie experimentell bestätigt werden konnte [S2]. Die beiden gegenläufigen Effekte gleichen sich aus und führen zu dem geringen Einfluss des Drahtvorschubs auf die Schweißnahthöhe.

Bei Abgleich der experimentell ermittelten Werte bei einspurigen, mehrlagigen Wänden mit den Schweißnahtgeometriemodellen aus Tabelle 2.1 zeigte sich für das Kosinusmodell sowie für die Modellierung mittels symmetrischer Parabel eine hohe Pearsonkorrelation ($\rho_{x,y} = 0.98$) zwischen dem mittleren Volumeneintrag entlang des Werkzeugpfades A_V und dem berechneten Schweißnahtquerschnitt A_S . Bezugnehmend auf die realen Volumeneinträge liegen die absoluten Werte der zu erwartenden Querschnitte jedoch höher als die Schweißnahtmodelle auf Basis der gemessenen Höhe und Breite nahelegen. Dies lässt sich auf die Unterschiede in der Schweißnahtgeometrie für einzel- und mehrspurige sowie einzel- und mehrlagige Bauteilelemente zurückführen. In den Experimenten wurden einspurige, mehrlagige Wände aufgebaut, deren Schweißnähte in den Seitenbereichen im Vergleich zu einlagigen Bauteilelementen zusätzliches Auftragsvolumen erfordern (siehe Abbildung 2.2 b)). Aufgrund der hohen linearen Korrelation wird das Modell der symmetrischen Parabel lediglich um einen Proportionalfaktor k_{sp} erweitert, der diesen Zusatzbedarf an Querschnittsfläche bei einspurigen, mehrlagigen Bauteilelementen kompensiert.

Die Korrelationen in Tabelle 5.1 zeigen, dass die Schweißnahthöhe und -breite nicht unabhängig voneinander betrachtet werden können. Damit handelt es sich bei der Regelstrecke um ein Multi Input Multi Output (MIMO)-System. Die dynamischen Zusammenhänge innerhalb dieses Systems werden mithilfe von vier Übertragungsfunktionen G_{11} , G_{12} , G_{21} und G_{22} modelliert, welche die Stell- und Regelgrößen, wie in Gleichung 5.1 und in Abbildung 5.3 als

Blockdiagramm gezeigt, verbinden.

$$\begin{bmatrix} b_S \\ h_S \end{bmatrix} = \begin{bmatrix} G_{11} & G_{12} \\ G_{21} & G_{22} \end{bmatrix} \cdot \begin{bmatrix} v_{WF} \\ v_{TCP} \end{bmatrix} \quad (5.1)$$

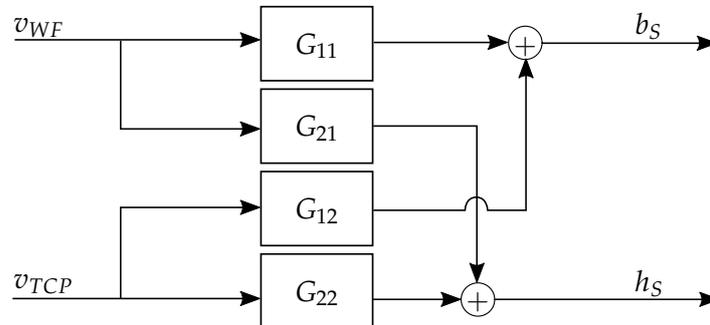


Abbildung 5.3: Blockdiagramm des WAAM MIMO Systems mit vier Übertragungsfunktionen zwischen den Stellgrößen v_{TCP} und v_{WF} und Regelgrößen h_S und b_S

Zur Bestimmung der Übertragungsfunktionen wurden 45 Experimente durchgeführt, in denen die Sprungantwort des linearen, zeitinvarianten Systems auf Änderungen der Stellgrößen untersucht wurden. Als Arbeitspunkt des Systems wurde eine Schweißgeschwindigkeit von $v_{TCP} = 300 \text{ mm min}^{-1}$ und eine Drahtvorschubgeschwindigkeit von $v_{WF} = 4.1 \text{ m min}^{-1}$ gewählt. Die Sprungfunktion bewirkte eine Änderung dieser Stellgrößen um jeweils $\pm 20\%$, $\pm 30\%$, $\pm 40\%$ und $\pm 50\%$. Die resultierenden Schweißnähte wurden mithilfe eines Laserprofilometers vermessen, die Höhe und Breite der Schweißnaht extrahiert und diese Werte mit den Verläufen der Stellgrößen synchronisiert. Die über mehrere Experimente gemittelten Übertragungsfunktionen sind in Tabelle 5.2 festgehalten.

Tabelle 5.2: Übertragungsfunktionen für den WAAM-Prozess auf Basis der in Abbildung 5.3 dargestellten Verbindungen zwischen den Stell- und den Regelgrößen

Übertragungsfunktion	Funktion
G_{11}	$G_{11} = e^{-0.170s} \cdot \frac{3.652}{s+1.584}$
G_{12}	$G_{12} = e^{-0.201s} \cdot \frac{0.020}{s+2.225}$
G_{21}	$G_{21} = 0$
G_{22}	$G_{22} = e^{-0.091s} \cdot \frac{0.032}{s+4.801}$

In den Experimenten für die Übertragungsfunktion G_{21} zeigte sich erneut die geringe Kopplung von v_{WF} und h_S , sodass G_{21} gleich null gesetzt werden konnte. Die Pole von G_{11} , G_{12} und G_{22} liegen in der linken Halbebene, sodass die Übertragungsfunktionen ein stabiles Verhalten zeigen. Sie sind kausal und weisen keine konjugiert-komplexen Pole auf. Die drei Übertragungsfunktionen entsprechen PT1-Gliedern mit einer Totzeit.

5.1.2 Regelkreis

Auf Basis der Systemidentifikation wird ein Prozessregelkreis konzipiert, der den Abstand zwischen Schweißbrenner und Bauteil konstant hält. Die Realisierung der Abstandsregelung erfolgt durch eine Anpassung der Schweißnahthöhe, sodass der Werkzeugweg unverändert

bleibt. Eine Zertifizierung der Fertigungsunterlagen nach DIN 17024-2 [56] wird damit nicht beeinträchtigt. Die physischen Elemente der Abstandsregelung sind in Abbildung 5.4 dargestellt.

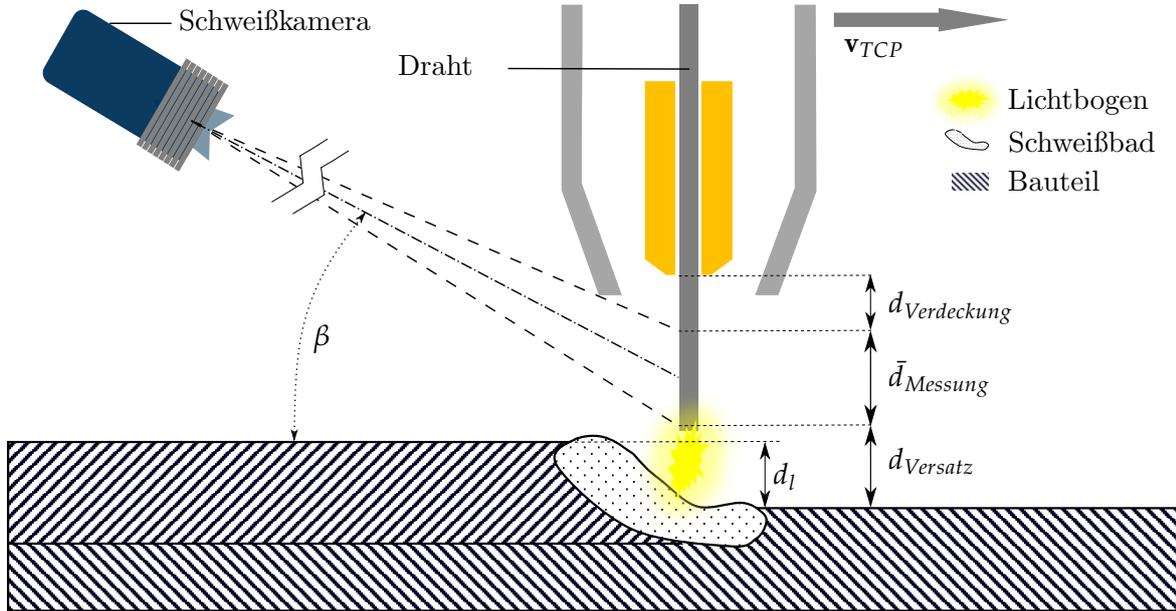


Abbildung 5.4: Systemkomponenten (Kamera, Schweißbrenner, Bauteil) der Abstandsregelung im WAAM-Prozess zuzüglich der Benennung relevanter Größen zur Messung des Abstands zwischen Schweißbrenner und Bauteil

Die Messgröße für die Abstandsregelung wird aus der in Kapitel 4.4 vorgestellten schicht- und richtungsunabhängigen Abstandsmessung auf Basis der Schweißkameradaten gewonnen. Dies ermöglicht es, schichtungebunden und ohne Messpausen auf den realen Abstand d_{NtW} vom Schweißbrenner zum Bauteil zu schließen. Um $d_{NtW-Messung}$ zu erhalten wird, wie in Gleichung 5.2 festgehalten, die perspektivische Verkürzung der mittleren gemessenen Drahtlänge $\bar{d}_{Messung}$ in [mm] unter Nutzung des Nickwinkels β der Schweißkamera einbezogen. Zusätzlich wird der nicht sichtbare Abschnitt des Drahts $d_{Verdeckung}$ und der durchschnittliche Abstand des Drahtendes zum Bauteil $d_{Versatz}$ hinzuaddiert.

$$d_{NtW-Messung} = \frac{\bar{d}_{Messung}}{\cos \beta} + d_{Verdeckung} + d_{Versatz} \quad (5.2)$$

Eine Abweichung des Abstands $d_{NtW-Messung}$ vom Referenzabstand $d_{NtW-ref}$ entspricht der zu realisierenden Anpassung der Lagenhöhe d_l , welche gegebenenfalls über mehrere Lagen hinweg umgesetzt werden muss. Den Ergebnissen der Systemidentifikation folgend wird die Anpassung durch eine Änderung der Schweißgeschwindigkeit v_{TCP} basierend auf der Referenzschweißgeschwindigkeit $v_{TCP-ref}$ realisiert. Da sich der Schweißpunkt beim WAAM-Prozess stetig voran bewegt, hat die Anpassung der Stellgröße erst in der darauffolgenden Lage eine Auswirkung auf die Messgröße. Ein Regler mit Integralanteil würde in diesem Szenario zu hohen Reglerausschlägen führen. Die Abstandsregelung nutzt deshalb den in Gleichung 5.3 angeführten P-Regler mit dem Proportionalfaktor K_P , welcher den in der Systemidentifikation beobachteten linearen Zusammenhang zwischen v_{TCP} und b_S nutzt. Ein P-Regler führt zu einer Regelabweichung, die jedoch mit der genutzten Abstandsmessmethode erst in der folgenden Lage sichtbar wird. Der Proportionalfaktor wurde auf Basis von Parameterstudien auf $K_P = 0.2$ gesetzt.

$$v_{TCP} = (K_P \cdot (d_{NtW-ref} - d_{NtW-Messung}) + 1) \cdot v_{TCP-ref} \quad (5.3)$$

Der Referenzwert für die Schweißgeschwindigkeit muss während eines Druckauftrags nicht konstant sein. Stattdessen kann dieser Wert im Maschinencode mit jedem Befehl angepasst werden, beispielsweise auf Basis der Ergebnisse einer prozessvorgelagerten Geschwindigkeitsoptimierung.

Wie in der Systemidentifikation (Abschnitt 5.1.1) gezeigt, hat die Schweißgeschwindigkeit einen hohen Einfluss auf die Schweißnahtbreite. Um diese trotz der sich dynamisch ändernden Schweißgeschwindigkeit konstant zu halten, wird die Regelung um ein Breitenmodul ergänzt, welches die Drahtvorschubgeschwindigkeit abhängig von der Schweißgeschwindigkeit anpasst. Da für die reale Schweißnahtbreite keine omnidirektionale Messmethode zur Verfügung steht, wird auf die experimentell und analytisch ermittelten Ergebnisse aus der Systemidentifikation zurückgegriffen. Unter Einbeziehen des Volumeneintrags aus Gleichung 2.2 und des Parabelmodells für die Schweißgeometrie aus Tabelle 2.1 ergibt sich folgender in Gleichung 5.4 notierter Zusammenhang zwischen Drahtvorschub, Referenzschweißspurbreite b_{S-ref} , der Lagenhöhe d_l und der Schweißgeschwindigkeit v_{TCP} :

$$v_{WF} = \frac{8 \cdot k_{sp}}{3 \cdot \pi \cdot d_w^2} \cdot b_{S-ref} \cdot d_l \cdot v_{TCP} \quad (5.4)$$

Der zu erzielende Schweißnahtquerschnitt A_S wird dabei als konstant angenommen. Die vorgeschlagene Breitenregelung ist ausschließlich für dünnwandige, d.h. einspurige, mehrlagige, Bauteile geeignet, da das verwendete analytische Modell lediglich deren Schweißnahtgeometrie abbildet. Die Gleichungen 5.3 und 5.4 lassen sich mit dem in Abbildung 5.5 dargestellten Blockdiagramm zusammenfassen.

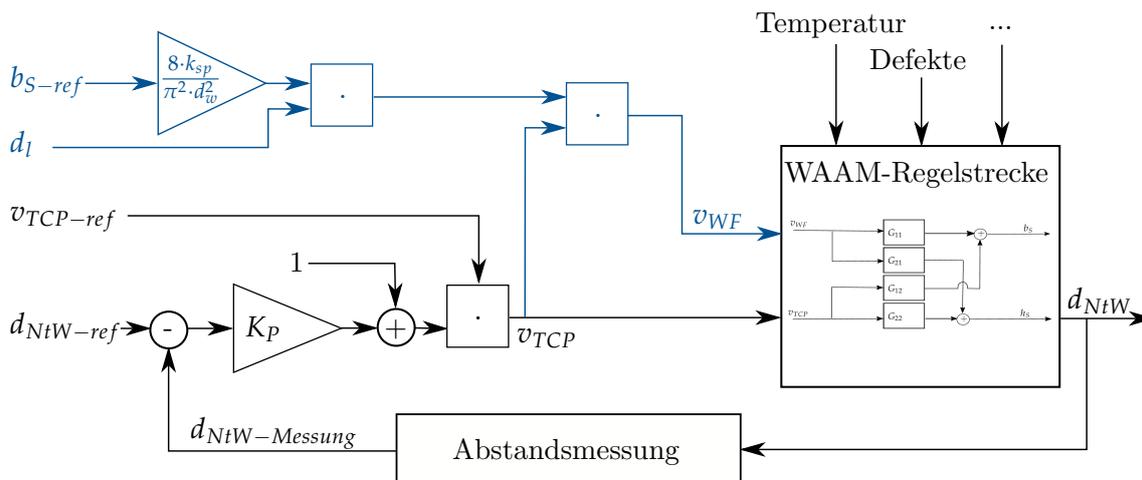


Abbildung 5.5: Schema der Abstandsregelung unter Nutzung der Ergebnisse der Abstandsmessung zuzüglich der in blau dargestellten Elemente zur Erweiterung um eine Schweißnahtbreitenanpassung auf Basis eines analytischen Modells der Schweißnahtgeometrie

Bei der kombinierten Abstands- und Schweißnahtbreitenregelung handelt es sich um ein System mit einer Messgröße und zwei Stellgrößen. Die Referenzwerte b_{S-ref} , d_l , $d_{NtW-ref}$ und $v_{TCP-ref}$ werden über das Maschinenprogramm festgelegt. Als Störgrößen wirken Umgebungseinflüsse wie beispielsweise die Temperatur auf die WAAM-Regelstrecke. Da der Einfluss von v_{WF} auf die Schweißnahthöhe, wie in den Tabellen 5.1 und 5.2 gezeigt, gering ist, kann die Abstandsregelung auch ohne die blau markierten Elemente des Breitenmoduls umgesetzt werden.

Bei der Implementierung der Regelung sind Begrenzungsblöcke für die Stellgrößen v_{TCP} und v_{WF} vorzusehen, um Extremwerte herauszufiltern und das Fertigungssystem zu schützen. Die Definition solcher Toleranzbänder für v_{TCP} und v_{WF} sowie für die Streckenenergie ermöglicht zudem die Prozessqualifizierung nach der DIN 17024-2 trotz Abstandsregelung. Sofern ein

Einsatz der Abstandsregelung in einem Produktivsystem nicht möglich ist, kann sie als Instrument dienen, um den Aufwand für die iterative Prozessparameteroptimierungen bei einem neuen Bauteil zu reduzieren.

5.2 Präskriptive Prozessparameteranpassung

In Abschnitt 4.3 wurde gezeigt, dass die Kontextwahrnehmung bei der Defektklassifikation zu besseren Detektionsergebnissen führen kann. Nachfolgend wird eine Methodik beschrieben, mit Hilfe derer auf Basis des wahrgenommenen Kontexts präskriptive Prozessparameteranpassungen vorgenommen werden, um autonom (Folge-)Defekte zu beheben und zu vermeiden und so den Prozess fehlertoleranter zu gestalten.

Auf Prozessebene wird das in Abbildung 5.6 dargestellte Szenario betrachtet.

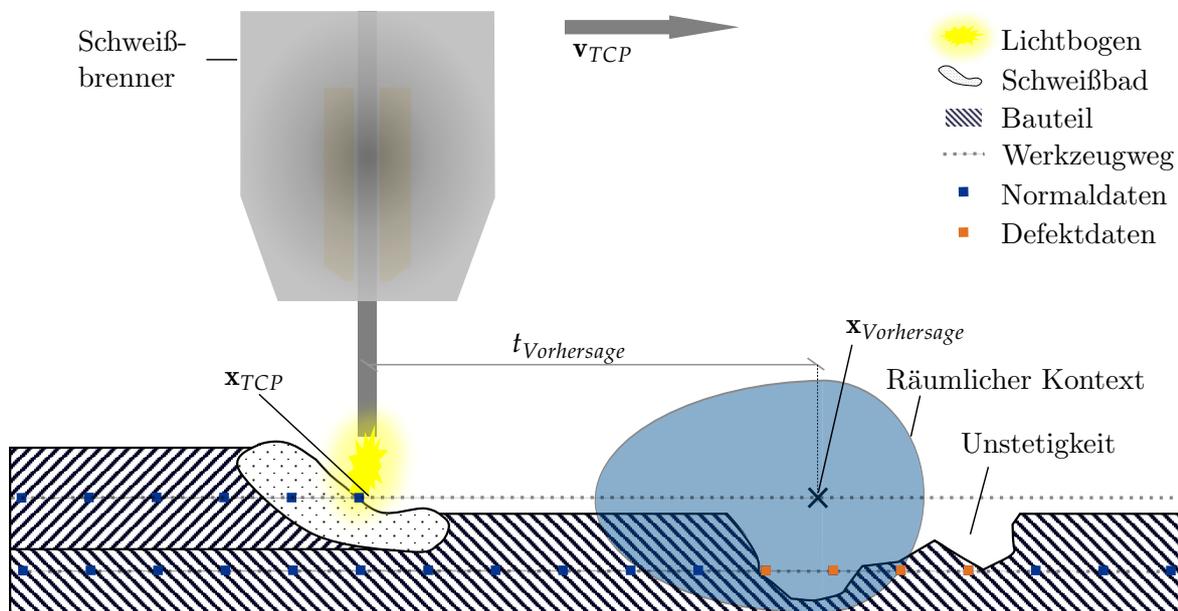


Abbildung 5.6: Szenario für die Prozessparameteranpassung mittels präskriptiver Analytik im WAAM-Prozess. Es wird die Position $x_{Vorhersage}$ des TCPs nach $t_{Vorhersage}$ Sekunden vorgesagt und deren räumlicher Kontext in Form eines Doppelellipsoids analysiert.

Der WAAM-Prozess wird mittels der in Kapitel 4 vorgestellten Methoden zur Anomaliedetektion, Defektklassifizierung und Abstandsmessung bewertet. Die erhaltenen Informationen wie beispielsweise Anomaliewerte und Defekttypen werden im Octree der digitalen Bauteil- und Prozessrepräsentation aus Kapitel 3 positionsbezogen als unmittelbar nutzbare Daten abgelegt. Die abgelegten Daten sind in der Abbildung 5.6 bei normalem Verhalten in blau und im Falle eines Defekts in orange dargestellt.

Während des Fertigungsprozesses wird ausgehend von der aktuellen TCP-Position x_{TCP} eine Vorhersage über die TCP-Position $x_{Vorhersage}$ getroffen, welche innerhalb einer Zeitspanne $t_{Vorhersage}$ angefahren wird. Auf Basis der vorhergesagten TCP-Position wird eine räumliche Kontextabfrage unter Nutzung des Octrees durchgeführt. Der erhaltene Kontext wird analysiert und auf Prozessdefekte und -anomalien untersucht. Sofern ein Defekt im Kontext vorliegt, wird eine Gegenmaßnahme ausgewählt, parametrisiert und zum geeigneten Zeitpunkt initiiert. Die Prozessparameter werden damit präskriptiv angepasst, sodass die Behebung von Defekten

und die Vermeidung von Folgedefekten erreicht wird. Der vorgestellte Ablauf lässt sich, wie in Algorithmus 3 notiert, als Handlungsabfolge darstellen.

Algorithmus 3 Algorithmus der präskriptiven Prozessparameteranpassung zur Erzeugung eines fehlertoleranten WAAM-Prozesses

Eingabe: Prozessüberwachung mit Anomaliedetektion oder Defektklassifikation

Eingabe: Digitale Bauteilrepräsentation in Form eines Octrees

- 1: **während** $R20 == 1$ **tue**
 - 2: Sage zukünftige Position $\mathbf{x}_{Vorhersage}$ vorher
 - 3: Stelle Abfrage nach räumlichen Kontext \mathcal{C} um $\mathbf{x}_{Vorhersage}$ an Octree
 - 4: Werte \mathcal{C} aus
 - 5: **wenn** Defekt $\in \mathcal{C}$ **dann**
 - 6: Leite kontextspezifische Gegenmaßnahme ab
 - 7: Initiiere Gegenmaßnahme
 - 8: **beende wenn**
 - 9: **beende während**
-

Nachfolgend werden der Schritt 2 (Positionsprädiktion) sowie die Schritte 6 und 7 (kontextspezifische Prozessparameteranpassung) erläutert.

5.2.1 Positionsprädiktion

$\mathbf{x}_{Vorhersage}$ wird abhängig vom Vorhersagezeitraum $t_{Vorhersage}$ basierend auf \mathbf{x}_{TCP} und dem Geschwindigkeitsvektor \mathbf{v}_{TCP} bestimmt. In Systemen mit geringer Dynamik genügt es bei kurzen Vorhersagezeiträumen, wie in Gleichung 5.5 gezeigt, eine Interpolation entlang der aktuellen Bewegungsrichtung vorzunehmen.

$$\mathbf{x}_{Vorhersage} = \mathbf{x}_{TCP} + \mathbf{v}_{TCP} \cdot t_{Vorhersage} \quad (5.5)$$

Hierbei gilt die Annahme, dass sich die Bewegungsrichtung innerhalb des Vorhersagezeitraums nicht ändert und eine gleichförmige Bewegung vorliegt.

Bei komplexeren Werkzeugpfaden mit häufigen Richtungs- oder Geschwindigkeitsänderungen sowie bei großen $t_{Vorhersage}$ führt Gleichung 5.5 zu ungenauen Vorhersagen. Aus diesem Grund wird in einem solchen Fall die Positionsprädiktion unter Nutzung des Maschinencodes (siehe Algorithmus 1) vorgenommen. Aus diesem wird die Zeitreihe T_{x-soll} abgeleitet, wobei zwischen den geplanten TCP-Positionen, wie in Abbildung 5.7 gezeigt, zusätzliche Interpolationspunkte eingefügt werden.

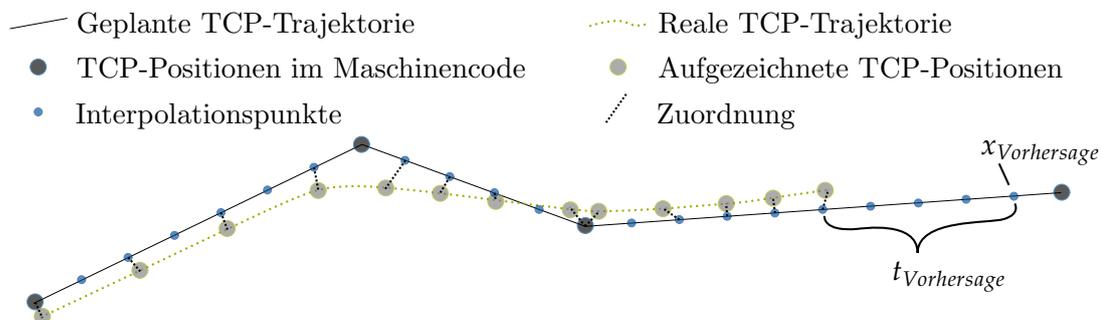


Abbildung 5.7: Zuordnung vom realen zum geplanten Werkzeugweg zur Positionsvorhersage für die präskriptive Analytik

Die reale TCP-Trajektorie weicht von der geplanten Trajektorie beispielsweise aufgrund von steuerungsbedingten Positionsinterpolationen (siehe G-Code-Befehl G645), diskretisierter Messdatenaufnahme sowie Trägheiten im System ab. Um dennoch eine Abschätzung über die nächsten Schritte zu treffen wird die Zeitreihe der bisher angefahrenen realen TCP-Positionen $\mathbf{T}_{TCP-ist}$ unter Nutzung des DTW-Algorithmus mit $\mathbf{T}_{TCP-soll}$ verglichen. Mithilfe des Vergleichs wird der Punkt entlang der geplanten Trajektorie bestimmt, der der aktuellen TCP-Position am nächsten liegt. Auf Basis der ermittelten Position wird dann mithilfe der $\mathbf{T}_{TCP-soll}$ -Zeitreihe die Position $\mathbf{x}_{Vorhersage}$ vorhergesagt, welche nach $t_{Vorhersage}$ erreicht wird. Die Vorhersagezeit $t_{Vorhersage}$ muss so gewählt sein, dass die Prozessparameteranpassung rechtzeitig umgesetzt werden kann. $t_{Vorhersage}$ inkludiert deshalb die zu erwartenden Latenzen der Kontextabfrage im Octree (siehe Abbildung 3.4 in Abschnitt 3.4), der Datenverarbeitung und des Datentransfers sowie die Reaktionszeiten im WAAM-System t_{System} .

5.2.2 Kontextspezifische Prozessparameteranpassung

Für die vorhergesagte TCP-Position $\mathbf{x}_{Vorhersage}$ wird der räumliche Kontext abgefragt und analysiert. Da alle Punkte innerhalb des Schweißbads den Prozess beeinflussen können, wird für die Octreeabfrage auf das Doppelellipsoid aus Kapitel 3.2 zurückgegriffen.

Abhängig vom Defekttyp sowie der Schwere des Defekts wird eine geeignete Strategie zur Prozessparameteranpassung gewählt und initiiert. Zur Bestimmung des Defekttyps wird die in Kapitel 4.3 beschriebene Methodik zur Defektklassifikation genutzt. Die Anpassungsstrategien können kompensierend wirken, wenn Defekte behoben werden, oder vermeidend sein, wenn Folgedefekte verhindert werden. Falls in der Umgebung des kommenden Werkzeugwegabschnitts Geometrieabweichungen vorliegen, kann beispielsweise der träge reagierende Gasfluss frühzeitig angepasst werden um eine optimale Schutzgasatmosphäre zu gewährleisten. Durch eine kontextabhängige Anpassung des Energieeintrags können Bindefehler und Durchschweißungen vermieden werden. Unstetigkeiten können durch eine lokale Erhöhung des Volumen- und Energieeintrags kompensiert und ein Fortschreiten der Unstetigkeit in den folgenden Lagen verhindert werden. Die Schwere des Defekts kann über die lokale Anomaliedichte oder die Defektgruppenausdehnung aus Kapitel 3.2 ermittelt werden. Eine Prozessparameteranpassung findet erst statt, wenn ein Schwellwert für die Schwere des Defekts überschritten wird. Ähnlich wie für die Abstandsregelung ist es auch für die präskriptive Prozessparameteranpassung erforderlich, die Stellgrößen durch Begrenzungsblöcke zu restringieren. Sofern der Defekt nicht in der ersten Lage nach der Entstehung kompensiert werden kann, sollten die Anlagenbedienenden und die Qualitätsingenieure und -ingenieurinnen informiert oder ein Prozessstopp ausgelöst werden.

5.3 Evaluierung

Die vorgestellten Methoden werden nachfolgend im WAAM-System evaluiert. Zunächst wird auf die Ergebnisse für die Abstandsregelung eingegangen. Anschließend folgt die Evaluierung der präskriptiven Prozessparameteranpassung.

5.3.1 Evaluierung der Abstandsregelung

Zur Evaluierung der Abstandsregelung wurden einspurige Wände der Länge $l = 121.6 \text{ mm}$ aus AlSi12 mit vier verschiedenen Prozessparameterkombinationen (K1-K4) sowohl ohne als auch mit Regelung aufgebaut und ihre Formtreue hinsichtlich Höhe und Breite untersucht. Die Wiederholbarkeit der Versuche wurde geprüft, indem mit jeder Konfiguration drei Wände aufgebaut wurden. Jede Wand bestand aus zwei CMT-P-Lagen sowie 30 CMT-Lagen. Der Referenzabstand d_{NW-ref} zwischen Schweißbrenner und Bauteil betrug 12.0 mm . Der Initialabstand zwischen Schweißbrenner und Bauteil für die erste Lage maß 13.9 mm , um die größere Schweißnahthöhe in der ersten Lage auszugleichen (siehe Abbildung 2.2 a) und b)).

In Tabelle 5.3 sind für K1 bis K4 die Ergebnisse der Abstandsregelung ohne die Elemente der Schweißnahtbreitenanpassung gezeigt. Die zu erzielende Gesamthöhe der Wände wurde auf Basis der geplanten Lagenhöhe d_l , des Initial- und des Referenzabstands erschlossen. Sie lag bei $H_{Soll-1.9} = 62.7 \text{ mm}$ für $d_l = 1.9 \text{ mm}$ und bei $H_{Soll-2.1} = 69.1 \text{ mm}$ für $d_l = 2.1 \text{ mm}$. In der Mitte jeder Wand wurde die realisierte Gesamthöhe (H_1, H_2, H_3) gemessen. Die durchschnittliche Abweichung zwischen Soll- und Isthöhe $\Delta\bar{H}$ war ein Indikator für die Formtreue des WAAM-Prozesses und für die Leistungsfähigkeit der Abstandsregelung.

Tabelle 5.3: Vergleich der realisierten Bauteilhöhen ohne und mit Abstandsregelung ohne Schweißnahtbreitenanpassung für verschiedene Prozessparametersätze

	Prozessparameter			ohne Abstandsregelung				mit Abstandsregelung			
	d_l in mm	$v_{TCP-ref}$ in mm min^{-1}	v_{WF-ref} in m min^{-1}	H_1 in mm	H_2 in mm	H_3 in mm	$\Delta\bar{H}$ in mm	H_1 in mm	H_2 in mm	H_3 in mm	$\Delta\bar{H}$ in mm
K1	2.1	400.0	3.0	54.2	54.5	54.8	-14.6	65.1	65.5	65.8	-3.6
K2	2.1	300.0	4.0	61.7	64.4	63.8	-5.8	68.6	69.0	69.1	-0.2
K3	1.9	400.0	4.0	53.5	53.6	54.5	-8.8	61.5	62.7	61.8	-0.7
K4	1.9	300.0	3.0	63.7	64.4	63.3	1.1	63.7	63.2	63.5	0.8

Mit Abstandsregelung konnte in allen Fällen eine größere Formtreue hinsichtlich der Bauteilhöhe erreicht werden als ohne Abstandsregelung. Die mittlere absolute Höhenabweichung lag mit Abstandsregelung bei maximal $|\Delta\bar{H}| = 3.6 \text{ mm}$, wohingegen sie ohne Abstandsregelung bis zu $|\Delta\bar{H}| = 14.6 \text{ mm}$ erreichte. Für K2, K3 und K4 konnte die mittlere, absolute Abweichung mit Abstandsregelung auf $|\Delta\bar{H}| = 0.8 \text{ mm}$ und weniger reduziert werden. Bei K1 war die Abstandsregelung nicht mehr in der Lage die hohe gesetzte Schweißgeschwindigkeit auszugleichen, sodass zwar die Formtreue um über 10 mm im Vergleich zum Prozess ohne Regelung verbessert wurde, aber trotz Prozesseingriff eine hohe Abweichung zur Referenzhöhe verblieb. Dieser Prozessparametersatz stellt damit ein Grenzszenario für den Einsatz der Abstandsregelung dar. Bei K4 handelt es sich um einen für $d_l = 1.9 \text{ mm}$ optimierten Prozessparametersatz, für den auch ohne Abstandsregelung geringe Lagenhöhenabweichungen zu sehen waren. Die Abstandsregelung bewirkte in diesem Fall vergleichbare Ergebnisse hinsichtlich der Wandhöhe.

Für die Evaluierung der Abstandsregelung mit aktiviertem Breitenmodul wurden als Referenzbreiten b_{S-ref} für K1-K4 die durchschnittlichen, im mittleren Bereich der obersten Lage gemessenen Schweißnahtbreiten der Wände ohne Abstandsregelung aus Tabelle 5.3 verwendet. Sie sind in Tabelle 5.4 den Schweißnahtbreiten (b_{S1}, b_{S2}, b_{S3}) der mit einem geregelten Prozess aufgebauten Wände gegenübergestellt. Die durchschnittliche Abweichung zwischen Soll- und Istbreite $\Delta\bar{b}_S$ ist ein Indikator für die Formtreue hinsichtlich der Schweißnahtbreite.

Während die Breite der Wände mit unbeeinflusstem Drahtvorschub aber geregelter Schweißgeschwindigkeit stark von der Breite der Wände, die ohne Abstandsregelung aufgebaut wurden,

Tabelle 5.4: Vergleich der realisierten Schweißnahtbreiten mit Abstandsregelung inklusive Schweißnahtbreitenanpassung für verschiedene Prozessparametersätze

	ohne Breitenmodul					mit Breitenmodul							
	b_{S-ref}	b_{S1}	b_{S2}	b_{S3}	$\Delta\bar{b}_S$	b_{S1}	b_{S2}	b_{S3}	$\Delta\bar{b}_S$	H_1	H_2	H_3	$\Delta\bar{H}$
	in mm	in mm	in mm	in mm	in mm	in mm	in mm	in mm	in mm	in mm	in mm	in mm	in mm
K1	5.1	7.7	8.6	8.3	3.1	5.4	5.5	5.2	0.3	66.8	66.8	67.3	-2.1
K2	9.2	10.9	11.3	10.9	1.8	8.9	9.5	9.5	0.1	69.6	69.1	69.4	0.3
K3	7.8	11.0	10.2	11.1	3.0	7.1	7.4	7.0	-0.6	61.8	60.5	61.4	-1.5
K4	6.4	6.6	6.7	6.6	0.2	5.7	5.8	6.0	-0.6	63.4	63.3	63.7	0.8

abwichen, zeigte sich für die Wände mit Abstandsregelung inklusive Breitenmodul eine Annäherung an die Referenzbreite. Die maximale mittlere Abweichung lag bei $|\Delta\bar{b}_S| = 0.6 \text{ mm}$ anstelle von $|\Delta\bar{b}_S| = 3.1 \text{ mm}$. Besonders auffällig sind die Unterschiede bei einer Sollschweißgeschwindigkeit von $v_{TCP-Soll} = 400 \text{ mm min}^{-1}$ (K1 und K3). In diesen Fällen nahm die Abstandsregelung eine Reduktion der Schweißgeschwindigkeit vor, die ohne Breitenmodul in einer starken Verbreiterung der Schweißnaht mündete. Das Breitenmodul wirkte dem entgegen und glich den Einfluss der Schweißgeschwindigkeit auf die Schweißnahtbreite aus. Dabei beeinträchtigte das Breitenmodul nicht die Leistungsfähigkeit der Abstandsregelung, sodass eine vergleichbare Genauigkeit hinsichtlich der Formtreue in vertikaler Richtung erreicht wurde (siehe $\Delta\bar{H}$ mit Breitenmodul in Tabelle 5.4).

Wie in Tabelle 5.5 gezeigt nahm das Auftragsvolumen für K1-K3 bei Nutzung der Abstandsregelung mit Breitenmodul Werte an, die zwischen denen der Versuche mit Abstandsregelung ohne Breitenmodul sowie denen der Versuche ohne Abstandsregelung lagen. Die Auftragsvolumina der Versuche mit Abstandsregelung inklusive Breitenmodul zeigten die geringsten Abweichungen von den Sollvolumina ($V_{Soll} = b_{S-ref} \cdot H_{Soll} \cdot l$). Hinsichtlich der Streckenenergie ($v_{konstant} = 0.8$) ergab sich ein ähnliches Verhalten. Ohne Breitenmodul lag die Abweichung zur geplanten Streckenenergie für K2-K4 bei bis zu 36.5% (K1: 53.3%) im Vergleich zu maximal 15.1% (K1: 28.4%) mit Breitenmodul. Das Ziel des Breitenmoduls, trotz Nutzung der Abstandsregelung eine definierte Sollschweißnahtbreite zu erreichen, begünstigte damit die Einhaltung des Toleranzbandes für die Streckenenergie bei Nutzung der Abstandsregelung. Für K4 waren die Ergebnisse der Abstandsregelung ohne Breitenmodul vergleichbar mit den Ergebnissen ohne Regelung. Die Streckenenergien und Auftragsvolumina für den Aufbau inklusive Breitenmodul zeigten hingegen auf Grund des reduzierten v_{WF} verringerte Werte. Die Abstandsregelung mit und ohne Breitenmodul zeigte in allen Fällen das auf Basis der Systemidentifikation zu erwartende Verhalten hinsichtlich der Stellgrößen v_{TCP} und v_{WF} .

Um die Übertragbarkeit der Abstandsregelung ohne Schweißnahtbreitenregelung auf eine andere Aluminiumlegierung und auf komplexe Werkzeugwege und Geometrien zu prüfen, wurden drei Musterbauteile mit den in Abbildung 5.8 gezeigten Werkzeugwegen aus der Aluminiumlegierung 6060 ohne und mit Abstandsregelung aufgebaut.

Das erste Musterbauteil (Abbildung 5.8 a)) war ein mehrlagiges Bauteil mit sich kreuzenden Werkzeugpfaden, mit dessen Aufbau das Verhalten der Regelung bei plötzlichen Abstandsänderungen untersucht wurde. Der Aufbau ohne Regelung zeigte Unstetigkeiten und starke Formabweichungen in den Start- und Endbereichen sowie im Bereich der Kreuzungen. Die Nutzung der Abstandsregelung reduzierte die Schwere der Formabweichungen und verhinderte Unstetigkeiten in allen Fällen. Im Bereich der Kreuzungen zeigten sich jedoch starke einseitige Einschnürungen der Schweißnahtbreite, welche auf den reaktiven Charakter der Regelung und den hohen Ausschlag der Schweißgeschwindigkeitsänderungen zurückzuführen sind.

Tabelle 5.5: Vergleich des Volumeneintrags V , der gemittelten Streckenenergie E_S , der mittleren Schweißgeschwindigkeit \bar{v}_{TCP} sowie der mittleren Drahtvorschubgeschwindigkeit \bar{v}_{WF} für die Prozessparametersätze K1-K4 für ein geregeltes System mit und ohne Breitenmodul sowie ein unregelmäßiges System

Typ der Abstandsregelung		V in cm^3	E_S in J mm^{-1}	\bar{v}_{TCP} in mm min^{-1}	\bar{v}_{WF} in m min^{-1}
K1	Unregelmäßig	35.3	77.7	371.4	3.0
	Geregelt mit Breitenmodul	43.1	99.8	274.6	2.6
	Geregelt ohne Breitenmodul	50.1	119.1	265.6	3.0
K2	Unregelmäßig	67.9	170.0	283.7	4.3
	Geregelt mit Breitenmodul	72.0	179.5	239.7	3.8
	Geregelt ohne Breitenmodul	83.5	218.4	233.2	4.3
K3	Unregelmäßig	51.4	124.6	367.9	4.2
	Geregelt mit Breitenmodul	56.4	124.9	309.8	3.9
	Geregelt ohne Breitenmodul	68.4	170.1	282.7	4.3
K4	Unregelmäßig	46.6	120.2	283.7	3.0
	Geregelt mit Breitenmodul	43.5	102.1	288.1	2.8
	Geregelt ohne Breitenmodul	46.7	121.4	281.6	3.0

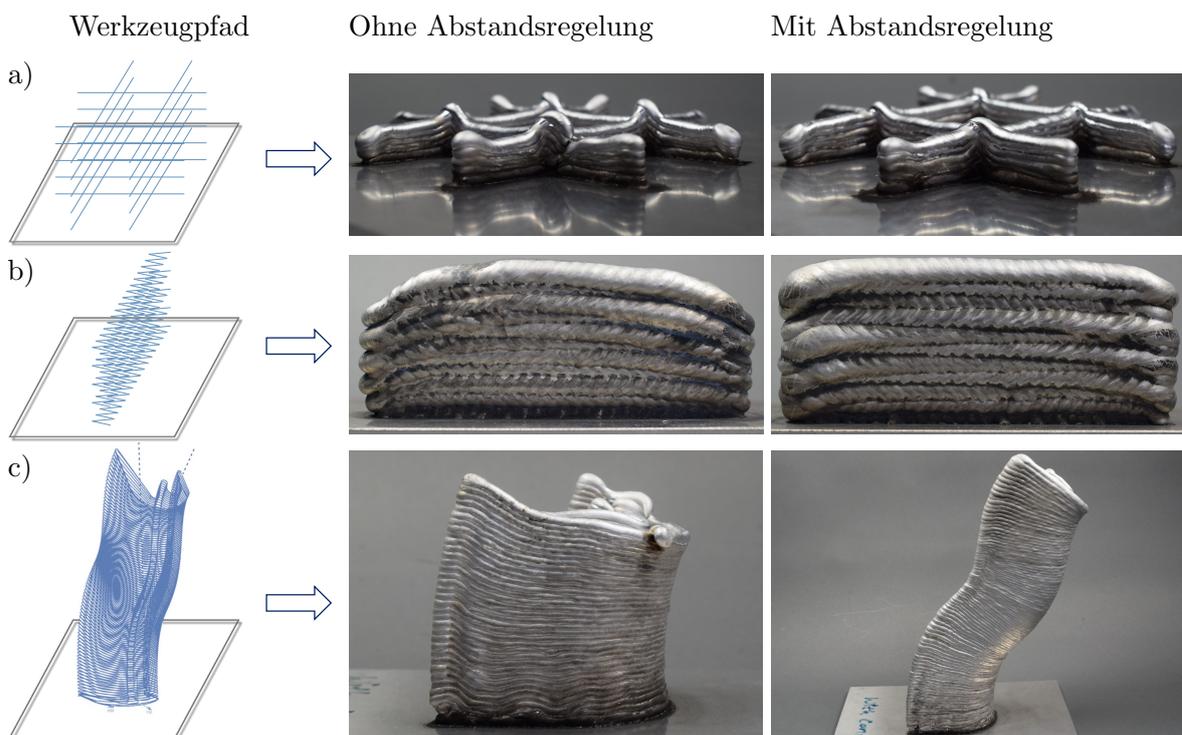


Abbildung 5.8: Gefertigte Musterbauteile mit den zugehörigen Werkzeugpfaden zur Evaluierung der Abstandsregelung: a) mehrlagiges Bauteil mit sich kreuzenden Werkzeugpfaden, b) breite Wand mit oszillierendem Werkzeugweg, c) gekrümmte Dünwandstruktur mit komplexer Außenkontur

Als zweites Musterbauteil (Abbildung 5.8 b)) wurde eine breite Wand mit oszillierendem Werkzeugweg gewählt, um die Übertragbarkeit der Abstandsregelung auf mehrlagige, mehrspurige Bauteile zu prüfen. Beim Aufbau ohne Abstandsregelung zeigte sich eine unerwünschte Höhenabweichung im Anfangs- und Endbereich der Wand. Mit Regelung ließen sich diese Abweichungen vermeiden und eine hohe Formtreue erreichen. Besonders in den Randbereichen

war jedoch die grundsätzliche Gefahr einer Überhitzung bei Verwendung der Regelung zu sehen. Eine starke Reduzierung der Schweißgeschwindigkeit resultiert in einer Erhöhung der Streckenenergie und kann damit eine Hitzeansammlung hervorrufen. Zur Vermeidung eines Durchbrands sollten dem System über eine Temperaturmessung Informationen bereitgestellt werden, um die Abkühlzeiten zwischen den Lagen situationsabhängig anzupassen.

Als drittes Musterbauteil (Abbildung 5.8 c)) wurde eine gekrümmte Dünnwandstruktur mit komplexer Außenkontur mittels Multiachsoperationen aufgebaut. Durch die Krümmung sowie die spitzen Ecken der Kontur änderte sich der Materialbedarf entlang jeder Windung des spiralförmigen Werkzeugpfads. Der Werkzeugweg wurde mithilfe der CAD/CAM-Software Siemens NX geplant. Dabei wurde eine prozessvorgelagerte Geschwindigkeitsoptimierung vorgenommen, um die Änderungen des Materialbedarfs auszugleichen. Beim Aufbau ohne Abstandsregelung musste der Prozess dennoch nach der 34. Windung abgebrochen werden, da der Schweißbrenner mit dem Bauteil nahezu kollidierte. Zusätzlich waren starke Oxidationen und Unstetigkeiten zu erkennen. Bei Nutzung der Abstandsregelung konnte derselbe Werkzeugweg ohne manuellen Eingriff abgefahren werden und das Bauteil ohne die oben erwähnten Defekte hergestellt werden. Die Abstandsregelung verwendete dabei die Ergebnisse der prozessvorgelagerten Geschwindigkeitsoptimierung als Referenzwerte und passte sie bei Bedarf an. Der Aufbau erfolgte ohne weiterführende Schweißprozessparameteroptimierung und ist damit ein Beispiel für den erfolgreichen Druck beim ersten Versuch.

5.3.2 Evaluierung der präskriptiven Prozessparameteranpassung

Die präskriptive Prozessparameteranpassung wurde für einen Unstetigkeitsdefekt evaluiert. Um zuverlässig eine Unstetigkeit herbeizuführen, wurden erst zwei Lagen mit dem CMT-P-Prozess aufgebaut, in deren mittleren Abschnitt für 10 mm der CMT-Prozess verwendet wurde. Durch den geringen Wärmeeintrag kam es dort zu Bindefehlern, in deren Folge sich, wie in Abbildung 5.9 gezeigt, Unstetigkeiten ausbildeten, die sich in den folgenden Lagen fortsetzten. In den nächsten acht Lagen wurde der CMT-Prozess eingesetzt. Für jede Wand wurde die Lage gemessen, in welcher sich die Unstetigkeit schloss. Bei der Wand in Abbildung 5.9 war dies beispielsweise in der neunten Lage der Fall. Damit diente die Defektgruppenausdehnung in vertikaler Richtung als Evaluierungsmetrik dieser Versuche.

Die präskriptive Prozessparameteranpassung wurde in der dritten Lage aktiviert. Zur Detektion der Unstetigkeit wurde auf die Anomaliedetektion mittels Autoencoder aus Kapitel 4.2 für die Spannungswerte sowie die lokale Anomaliedichte aus Kapitel 3.2 gesetzt.

In Voruntersuchungen wurden geeignete Prozesseingriffsparameter ausgewählt. Dazu wurde der Einfluss der eingeplanten Zeit für die Systemreaktion t_{System} sowie des Schwellwerts bezogen auf die lokale Anomaliedichte auf den Defektkompensationserfolg betrachtet. Eine zu hoch angesetzte t_{System} resultierte in einer verspäteten Reaktion des Systems wohingegen eine zu niedrig geschätzte t_{System} einen Eingriff bewirkte, der auf der Grund der frühen Anpassung keine Auswirkung auf den Defekt hatte. Bei Unstetigkeiten müssen die Prozessparameter bereits vor der Überschreitung des Defekts angepasst werden, um die Materiallücke zu füllen und den Defekt zu kompensieren. Im vorliegenden Fall lag der optimale Wert bei $t_{System} = 1.0$ s. Der Schwellwert hatte einen wesentlichen Einfluss darauf, wie und wo das System reagierte. Ein zu hoher Wert resultierte in einer geringen Sensitivität des Systems, sodass erforderliche Eingriffe nicht ausgelöst wurden. Zu geringe Schwellwerte bewirkten falsch-positive Eingriffe, welche zu zusätzlichen Unebenheiten im Aufbau führten. Für die genutzte Anomaliedichte auf Basis der Anomaliewerte des Autoencoders ergab sich ein optimaler Schwellwert von 0.9. Weitere Details zur Auswahl der Prozesseingriffsparameter finden sich in [P9].



Abbildung 5.9: Lagenweise Entwicklung des Unstetigkeitsdefekts: Entstehung in der ersten Lage, Fortsetzung in den darauf folgenden Lagen und Kompensation in der neunten Lage

Unter Nutzung der optimalen Prozesseingriffparameter (Systemreaktionszeit $t_{system} = 1.0\text{ s}$; Schwellwert von 0.9) wurden 25 Testläufe vorgenommen und mit dem Aufbau der Wände ohne präskriptive Prozessparameteranpassung verglichen. Die Ergebnisse sind in Tabelle 5.6 festgehalten.

Tabelle 5.6: Evaluierungsergebnisse für die präskriptive Prozessparameteranpassung: Darstellung der Anzahl an Experimenten je Lage, in welchen die Unstetigkeit mit beziehungsweise ohne präskriptive Prozessparameteranpassung kompensiert wurde

Präskriptive Prozessparameteranpassung	Lagennummer der Kompensation									Lagenmedian der Kompensation
	3	4	5	6	7	8	9	10	≥ 10	
ohne	0	0	0	0	0	1	2	4	18	>10
mit	4	8	8	5	0	0	0	0	0	5

Bei den Versuchen ohne präskriptive Prozessparameteranpassung setzte sich die Unstetigkeit in 72.0% der Fälle über die zehnte Lage hinweg fort. In allen Versuchen ohne Prozesseingriff erreichte die Defektgruppe mindestens die achte Lage, sodass die Defektgenerierung als verlässlich eingeordnet wurde. Im Gegensatz dazu konnte mit der präskriptiven Prozessparameteranpassung in allen Fällen ein Fortschreiten der Unstetigkeit über die sechste Lage hinaus verhindert werden. In 48% der Versuche war dies in der vierten Lage der Fall und in vier Versuchen wurde die Unstetigkeit bereits in der dritten Lage kompensiert. Damit benötigte das um die präskriptive Prozessparameteranpassung erweiterte System in diesen Fällen lediglich eine Lage, um den Defekt zu detektieren und zu kompensieren. Der Unterschied zwischen den Verteilungen mit und ohne präskriptiver Prozessparameteranpassung ist statistisch signifikant (Mann-Whitney-U-Test: $p < 0.01$).

Eine weitere Optimierung der Eingriffparameter sowie eine Erhöhung der Robustheit der Defektklassifikation für Unstetigkeiten durch Einbeziehen der Drahtlängenerkennung kann die Verlässlichkeit der Defektkompensation durch die präskriptive Prozessparameteranpassung erhöhen. Dabei ist jedoch zu berücksichtigen, dass Unstetigkeitsdefekte bereits per se ein Ausschusskriterium darstellen können, sodass in nachfolgenden Arbeiten die Nutzung der präskriptiven Prozessparameteranpassung für die Behebung und Vermeidung von anwendungsnäheren Defekten wie beispielsweise Bindefehlern untersucht werden sollte. Eine

Prozessqualifizierung nach DIN 17024-2 der präskriptiven Prozessparameteranpassung hängt von der gewählten Strategie zur Prozessparameteranpassung ab und konnte nicht abschließend geklärt werden. Die Nutzung von Toleranzbändern für die Prozessparameter würde die Prozessqualifizierung der präskriptiven Prozessparameteranpassung zur Vermeidung von Defekten erleichtern.

5.4 Zusammenfassung

In diesem Kapitel wurden Methoden für den datengestützten Prozesseingriff vorgestellt. Zunächst wurde eine Abstandsregelung konzipiert. Basierend auf den Ergebnissen einer Systemidentifikation nutzte die Regelung die Schweißgeschwindigkeit als Stellgröße, um Einfluss auf die Schweißnahthöhe zu nehmen und den Abstand zwischen Schweißbrenner und Bauteil konstant zu halten. Durch Anpassung der Drahtvorschubgeschwindigkeit war es möglich, die Schweißnahtbreite trotz Änderung der Schweißgeschwindigkeit konstant zu halten. Dank der richtungs- und schichtunabhängigen Abstandsmessung aus Kapitel 4.4 und der Abstandsregelung war es möglich, komplexe Bauteile mit Multiachsoperationen ohne vorherige Prozessparameteroptimierung beim ersten Versuch aufzubauen.

Da im Prozess jederzeit Instabilitäten auftreten können, wurde anschließend eine präskriptive Prozessparameteranpassung vorgestellt, mit der Defekte kompensiert und Folgedefekt vermieden werden konnten. Es wurde eine Positionsvorhersage vorgenommen und der zukünftige räumliche Kontext ausgewertet, um einen Prozesseingriff zu initiieren. Das Konzept wurde anhand der Kompensation eines Unstetigkeitsdefekts evaluiert und zeigte eine hohe Erfolgsquote. Die präskriptive Prozessparameteranpassung ermöglichte damit einen fehlertoleranteren Prozess, mit dem die FPY erhöht werden kann.

Die vorgestellten Methoden zum datengestützten Prozesseingriff beeinflussen den Prozess datenbasiert und bilden zusammen mit der Bauteil- und Prozessrepräsentation aus Kapitel 3 und der Prozessüberwachung aus Kapitel 4 den Digitalen Zwilling für die additive Fertigung mittels Lichtbogenauftragschweißen.

Kapitel 6

Erprobung in der industriellen Fertigung

6.1	Definition eines industriellen Fertigungsszenarios	103
6.1.1	Systemarchitektur	103
6.1.2	Validierungsbauteile	108
6.2	Erprobung des Systems	109
6.3	Anforderungsbezogene Bewertung	112
6.3.1	Bewertung des Gesamtsystems	112
6.3.2	Bewertung der Module des Digitalen Zwillings	115
6.4	Zusammenfassung	118

Die Module Bauteil- und Prozessrepräsentation (Kapitel 3), Prozessüberwachung (Kapitel 4) und Prozesseingriff (Kapitel 5) bilden die drei Kernelemente des Digitalen Zwillings für die additive Fertigung mittels Lichtbogenauftragschweißen. Während deren Methoden bereits in den vorhergehenden Kapiteln evaluiert wurden, findet nachfolgend die Validierung des Gesamtsystems innerhalb eines industriellen Fertigungsszenarios statt. Zunächst wird dafür der in dieser Arbeit entstandene Systemaufbau vorgestellt und das Fertigungsszenario definiert. Es folgt die Darstellung der Validierungsergebnisse sowie die anforderungsbezogene Bewertung des Digitalen Zwillings und seiner Elemente. Das Kapitel schließt mit einer Zusammenfassung.

6.1 Definition eines industriellen Fertigungsszenarios

Durch die Erprobung des Digitalen Zwillings innerhalb eines industriellen Fertigungsszenarios soll ein Funktionsnachweis des Gesamtsystems erbracht werden. Dazu wird zunächst der Aufbau des intelligenten Fertigungssystems erläutert, dessen Teil der Digitale Zwillings ist. Weiterhin werden die zwei Validierungsbauteile vorgestellt.

6.1.1 Systemarchitektur

Das in dieser Arbeit entstandene intelligente Fertigungssystem kann nach VDI/VDE 2206 als ein mechatronisches System aufgefasst werden. Als solches ist es in Abbildung 6.1 dargestellt. Es differenziert vier notwendige Einheiten (Informationsverarbeitung, Sensorsystem, Kinematik und Schweißquelle, WAAM-Fertigung) und verbindet diese über Informations-, Energie- und Stoffflüsse untereinander, mit der Umgebung sowie mit Nachbarsystemen in der

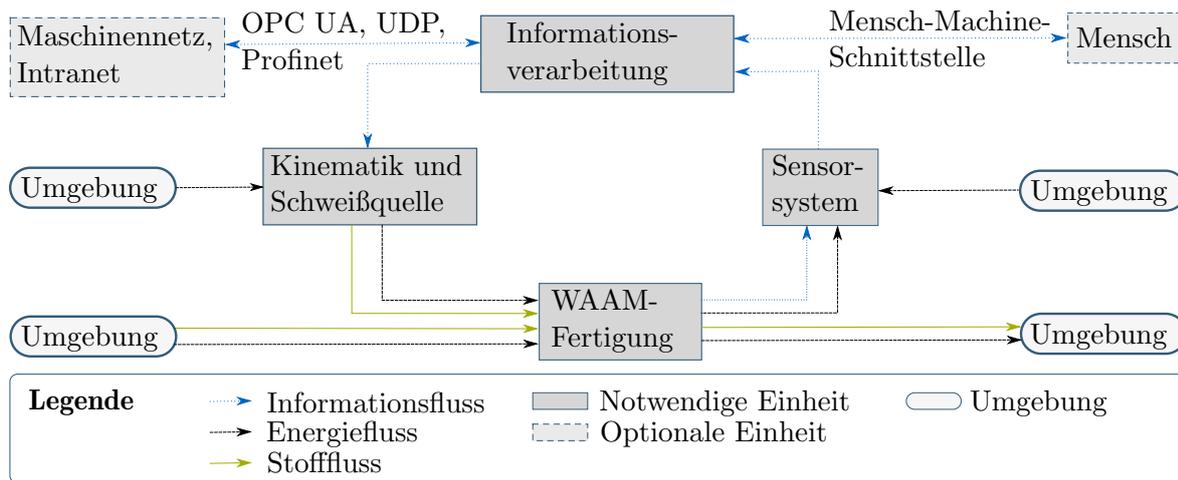


Abbildung 6.1: Darstellung des intelligenten WAAM-Fertigungssystems als mechatronisches System inklusive der Informations-, Energie- und Stoffflüsse, der notwendigen und optionalen Einheiten und der Umgebung

Fertigungsumgebung. Die Stoffflüsse umfassen die Draht-, Substrat- und Inertgasbereitstellung. Die Energieflüsse ermöglichen den Schweißvorgang und die Bewegung der Kinematik auf energetischer Ebene. Die Einheiten Kinematik und Schweißquelle, das Sensorsystem sowie die WAAM-Fertigung interagieren mit der Umgebung. Dazu zählen beispielsweise das Abluftsystem und das Energiesystem des Gebäudes. Die Einheit zur Informationsverarbeitung nutzt für den Informationsaustausch mit dem Maschinennetz und dem Intra-/Internet OPC UA, User Datagram Protocol (UDP) und Profinet. Für den Informationsaustausch mit dem Menschen wird eine Mensch-Maschine-Schnittstelle benötigt. Nachfolgend wird zunächst die Hardware zur Realisierung des mechatronischen Systems vorgestellt. Anschließend wird auf die softwaretechnische Umsetzung im Rahmen der Informationsverarbeitung eingegangen. Als Teil der Informationsverarbeitung wird der Aufbau des Digitalen Zwillings erläutert.

Hardware

Die Hardware des mechatronischen Systems besteht, wie in Abbildung 6.2 dargestellt, aus den Aktoren (Kinematik und Prozesstechnik), den Elementen der Informationsverarbeitung und der Sensortechnik:

1. 6-Achs-Industrieroboter NJ130 2.0 [259] von Comau
2. 2-Achs-Drehkipptisch PTS-ORB-1000 [260] von Comau
3. Schweißquelle CMT 4000 [261] mit Drahtvorschubeinheit VR 7000 [262] von Fronius
4. Sensoren der Prozessüberwachung diverser Hersteller
5. Numerical Control (NC) Sinumerik 840d sl [263] mit Run MyRobot /DirectControl [264] und Speicherprogrammierbare Steuerung (SPS) S7-319 PN/DP [265] von Siemens
6. Edge-Geräte Microbox 427E [266] von Siemens und Jetson AGX Xavier [267] von Nvidia
7. Mensch-Maschine-Schnittstelle (engl. Human Machine Interface (HMI)) in Form eines Ein- und Ausgabegeräts jeglicher Art

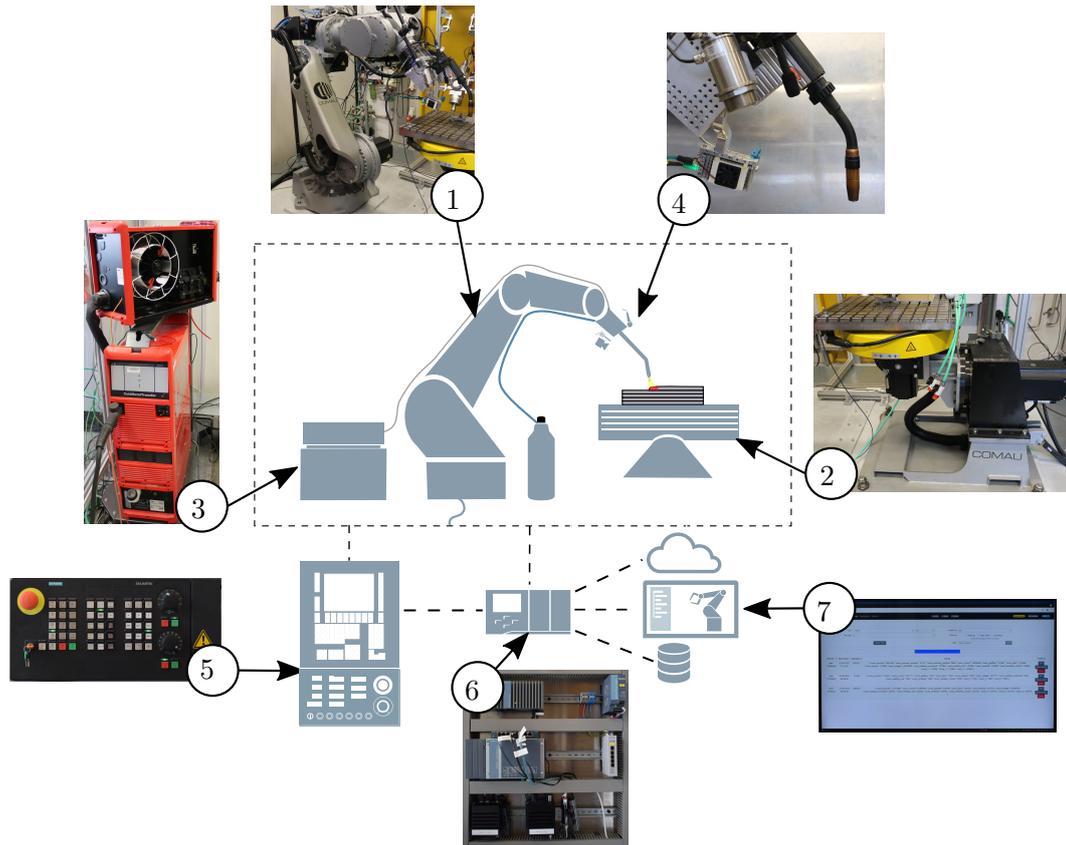


Abbildung 6.2: Schematischer Aufbau der WAAM-Zelle zur Erprobung des Digitalen Zwillings in der industriellen Fertigung

Die Absolutgenauigkeit des unbelasteten Roboters liegt nach einer Kalibrierung bei 0.14 mm (std.: 0.06 mm , max.: 0.28 mm), wohingegen die Wiederholgenauigkeit einen Wert von 0.09 mm (std.: 0.04 mm , max.: 0.18 mm) erreicht. Die NC ermöglicht die Nutzung von ISO 6983 basierten Maschinencode und koordiniert die Roboterbewegungen und Schweißzyklen. Die Schweißquelle ist für die Umsetzung des Schweißprozesses zuständig. Das system-on-module-Gerät NVIDIA Jetson AGX Xavier und die Microbox ermöglichen die Aufnahme, Synchronisierung und Auswertung der Prozessdaten. Sie sind mittels UDP und OPC UA mit der Steuerung verbunden und stellen die Konnektivität für einen Fernzugriff bereit. Die Sensoren der Prozessüberwachung sind in Tabelle A.1 im Anhang spezifiziert. Der Strom- und Spannungssensor sowie der Gasdurchfluss- und der Drahtvorschubsensor sind im Stromkreis beziehungsweise entlang des Drahtfördersystems und der Gasleitungen eingebunden. Die Schweißkamera (Abstand vom TCP $d = 200\text{ mm}$; Nickwinkel $\beta = 14^\circ$) mit aktiver Laserbeleuchtung, das Spektrometer ($d = 210\text{ mm}$; $\beta = 15^\circ$), welches zur Abschwächung der Lichtbogenemissionen mit einem optischen Neutralfilter (ND 1.5) versehen ist, und das Mikrofon ($d = 210\text{ mm}$; $\beta = 75^\circ$) sind am Schweißbrenner montiert und verändern während des Prozesses ihre relative Orientierung und Position zum TCP nicht. Der Strukturakustiksensoren ist an der T-Nut-Platte des Drehkipptisches befestigt, auf der die Substratplatten aufgespannt werden.

Software

Während die Steuerung der WAAM-Anlage von der SPS und der NC übernommen wird, findet die restliche Informationsverarbeitung im Rahmen des Digitalen Zwillings auf den Edge-Geräten statt. Das intelligente Fertigungssystem ist in die digitale Werkzeugkette eingebunden.

Aufbau des Digitalen Zwillings: Der Digitale Zwilling besteht aus fünf Modulen:

1. Konnektivitätsmodul
2. Digitale Repräsentation (Kapitel 3)
3. Prozessüberwachung (Kapitel 4)
4. Entscheidungsmodul (Kapitel 5)
5. Mensch-Maschine-Schnittstelle

Der Digitale Zwilling basiert auf einer Microservicearchitektur. Jedes Modul besteht aus mehreren Submodulen, welche jeweils auf eine Funktionalität der gesamten Applikation spezialisiert und als Container ausgeführt sind. Dadurch ist der Digitale Zwilling modular und flexibel erweiterbar. Eine Übersicht der Submodule und ihre Einordnung in die fünf Module des Digitalen Zwillings ist in Abbildung 6.3 dargestellt. Die einzelnen Submodule kommunizieren über einen MQTT-Datenbus, sodass 1-zu-n-Verbindungen möglich sind. Für ereignisgesteuerte 1-zu-1 Verbindungen beispielsweise für eine räumliche Kontextabfrage wird auf Schnittstellen zur repräsentativen Zustandsübertragung (engl. Representational State Transfer (REST)) zurückgegriffen. Dadurch wird eine Entkopplung von Informationsanbietern und -empfängern erreicht.

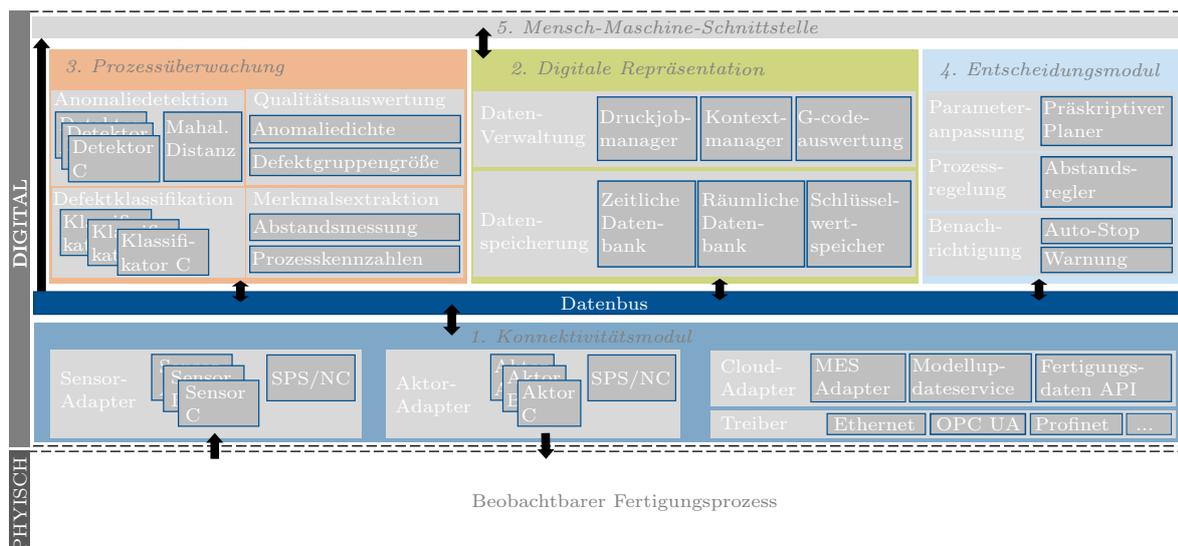


Abbildung 6.3: Microservicearchitektur des Digitalen Zwillings für die additive Fertigung mittels Lichtbogen-auftragschweißen als digitales Abbild des beobachtbaren Fertigungsprozesses. Der Digitale Zwilling besteht aus fünf Modulen (Konnektivitätsmodul, Digitale Repräsentation, Prozessüberwachung, Entscheidungsmodul, Mensch-Maschine-Schnittstelle).

Bei den Submodulen des Konnektivitätsmoduls handelt es sich um Systemadapter für cyber-physische Schnittstellen, die die Kommunikation mit der Steuerung und den Sensoren sowie Klienten der Prozessüberwachung ermöglichen. Es sind unter anderem ein OPC UA-Server und ein GigE-Adapter für die Schweißkamera implementiert. Über eine UDP-Verbindung ist eine asynchrone Kommunikation mit der SPS realisiert. SPS-seitig werden die Werte von einer Zustandsmaschine verarbeitet und an die NC weitergeleitet [268]. Die wesentlichen Funktionalitäten und Methoden der Module 2, 3 und 4 wurden in den vorangegangenen Kapiteln vorgestellt.

Das für die digitale Repräsentation erforderliche zeitliche, räumliche und systembezogene

Datenmanagement wird durch die Nutzung einer Zeitreihendatenbank, einer räumlichen Datenbank (Octree) sowie eines persistenten Schlüsselwertspeichers realisiert. Die Submodule verfügen über Schnittstellen zur Bereitstellung des Kontexts. Ein Druckjobmanager ordnet dem aktuellen Fertigungsauftrag die Bauteilidentifikationsnummer zu. Das Maschinencodanalysemodul ermöglicht die Auswertung des Maschinencodes zur Octreeinitialisierung sowie für Positionsvorhersagen.

Die Submodule der Prozessüberwachung umfassen neben den Elementen der Anomaliedetektion, der Defektklassifizierung und der Abstandsmessung Submodule zur Ableitung der Qualitätsmetriken sowie zur Berechnung von Prozesskennwerten wie der Streckenenergie. Darüber hinaus werden Zeitreihenmerkmale der Audio-, Spektrometer-, Strom- und Spannungsdaten extrahiert.

Das Entscheidungsmodul umfasst neben einer Schnittstelle für die Abstandsregelung Submodule für den Prozessstopp sowie für die präskriptive Prozessparameteranpassung. Prozesswarnungen werden über die Mensch-Maschine-Schnittstelle an die Anlagenbedienenden beziehungsweise die Qualitätsingenieure und -ingenieurinnen weitergegeben.

Das fünfte Modul ist als Webapplikation umgesetzt, auf die sowohl Anlagenbedienende vor Ort als auch Qualitätsingenieure und -ingenieurinnen per Fernanbindung zugreifen können. Eine Ansicht der Benutzeroberfläche ist in Abbildung 6.4 zu sehen. Sie zeigt im oberen Bereich die relevanten Informationen des Systemkontexts und im unteren Bereich eine dreidimensionale Darstellung des bis zur Betrachtung aufgebauten Bauteils sowie das Bild der Schweißkamera. Weitere Ansichten der Benutzeroberfläche sind im Anhang A dargestellt.

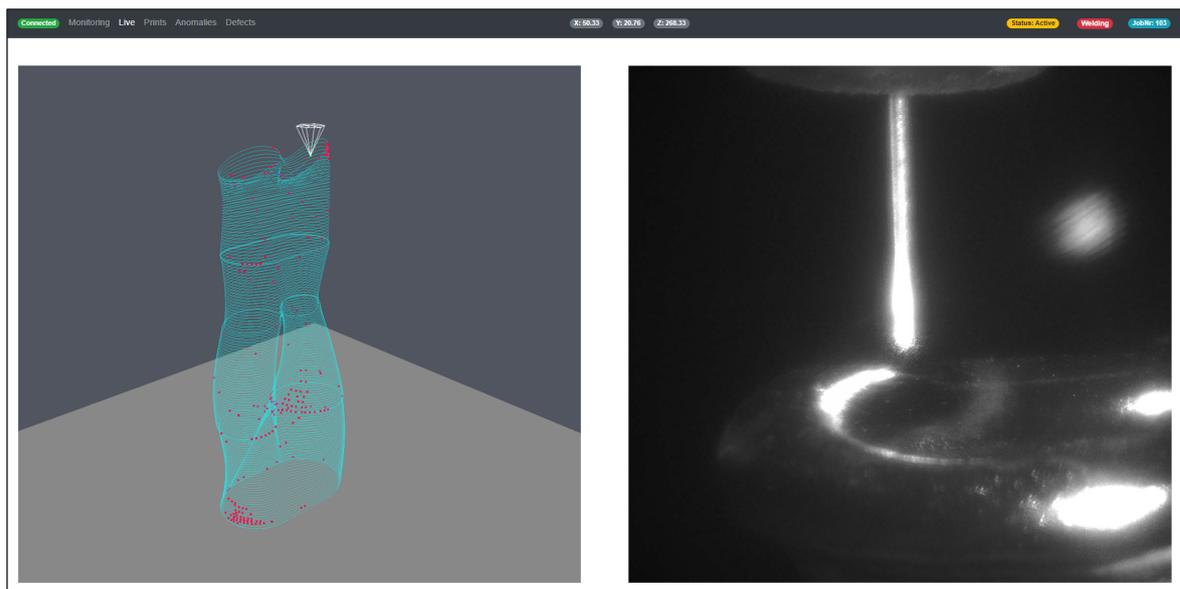


Abbildung 6.4: Live-Ansicht der Benutzeroberfläche der Webapplikation, welche als Mensch-Maschine-Schnittstelle des Digitalen Zwillings dient: Navigationselemente und Prozesszustandsinformationen im oberen Bereich, dreidimensionale Ansicht des Werkzeugwegs inklusive detektierter Anomalien auf der linken Seite und Videostream der Schweißkamera auf der rechten Seite

Einbindung in die digitale Werkzeugkette: Der Digitale Zwilling ist Teil einer digitalen Werkzeugkette, welche im Rahmen dieser Arbeit entstanden ist. Das Fertigungssystem wurde in einer CAD/CAM-Software modelliert. In Abbildung 6.5 ist dieses Digitale Modell des Fertigungssystems in der Software Siemens NX dargestellt. Durch die Kombination mit einer Maschinensimulation erlaubt es die Planung der Roboterbewegungen, die zum Abfahren des CAM-Werkzeugwegs erforderlich sind, und unterstützt die Kollisionsüberprüfung.

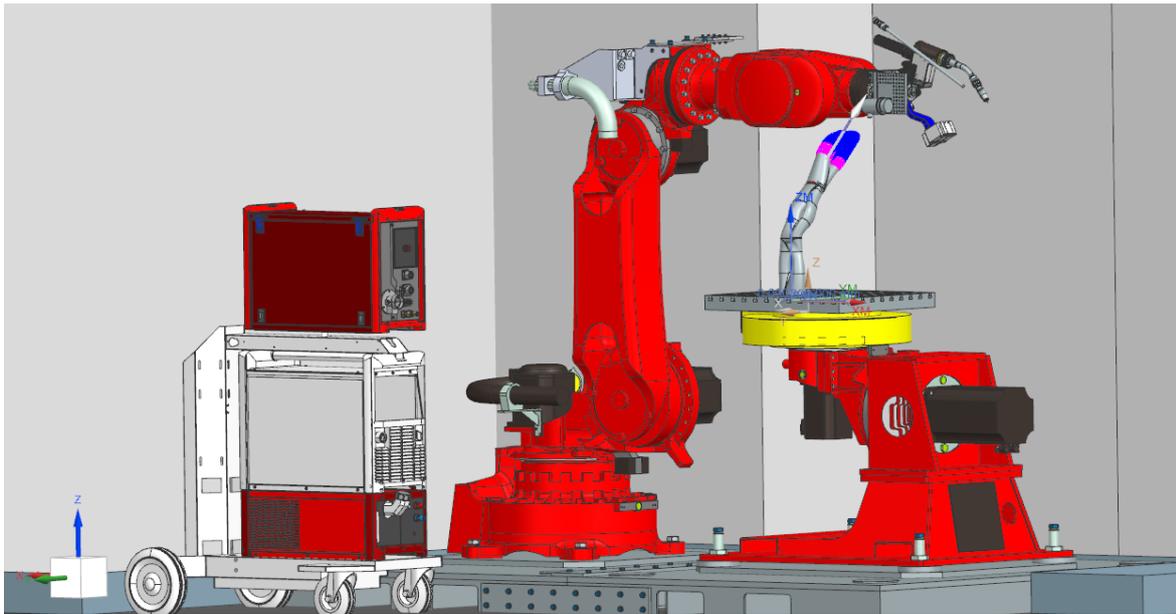


Abbildung 6.5: Maschinensimulation der WAAM-Fertigungsanlage auf Basis der digitalen Repräsentation des kinematischen Systems inklusive potentieller Kollisionsgeometrien wie beispielsweise der Schweißquelle und des aufgetragenen Volumens des zu fertigenden Bauteils

Aus der Maschinensimulation wird mithilfe eines für das Fertigungssystem erstellten CAM-Postprozessors der angepasste Maschinencode aus Algorithmus 1 erzeugt, welcher an die NC für die Fertigung übergeben wird. Die im WAAM-Prozess gesammelten Informationen werden den Qualitätsingenieuren und -ingenieurinnen über die Benutzerschnittstelle des Digitalen Zwillings bereitgestellt.

Historische Daten werden in einer Datenbank mit Anbindung an ein Visualisierungswerkzeug gesammelt. Die dreidimensionalen Informationen aus der Qualitätssicherung werden mithilfe einer Annotationsapplikation mit der in Abschnitt 3.3 beschriebenen Funktionalität sowie über die Bauteilidentifikationsnummer mit den Prozessdaten des Digitalen Zwillings in Verbindung gesetzt. Die Anbindung an die vorgelagerte Prozessplanung im CAD/CAM-Programm geschieht über eine .csv-basierte Datenschnittstelle des Digitalen Zwillings.

6.1.2 Validierungsbauteile

Zur Validierung werden ein Bauteil aus der Automobilbranche sowie eine bionisch inspirierte Leichtbaustruktur betrachtet.

Das Bauteil aus der Automobilbranche ist ein Verbindungselement einer Karosserie und wird bei Kleinstserien mit Stückzahlen von bis zu 10000 im Jahr eingesetzt. Konventionell wird das Bauteil mittels Druckguss hergestellt. Die Hauptmotivation für den Transfer auf die neue Fertigungstechnologie liegt in geringeren Kosten sowie in einer deutlich erhöhten Flexibilität in der Fertigung. Das Bauteil besteht aus zwei Segmenten. Das erste Segment ist eine Dünnwandstruktur, wobei im vorderen Bereich eine Ausbuchtung mit Überhang vorliegt, welche als Anbindungsstelle dient. Das zweite Segment baut an der Oberkante des ersten Segments an. Aus diesem Grund kommt Formtreue in der Fertigung eine hohe Bedeutung zu. Zur Fertigung des Bauteils werden Multiachsoperationen verwendet, sodass die Werkzeugwege nicht planar verlaufen.

Das zweite Validierungsbauteil ist ein bionisch inspiriertes Leichtbauelement, welches als

Hohlstruktur konzipiert ist, um innenliegende Verkabelungen aufzunehmen. Die Geometrie wurde erstmals in [269] vorgestellt. Aufgrund seiner Form ist eine subtraktive Fertigung nicht möglich. Das Bauteil ist in vier Segmente unterteilt. Im ersten Segment wird für den Werkzeugweg eine Helixstrategie eingesetzt. Es folgt eine Verästelung, in welcher abwechselnd eine Schicht des linken und eine Schicht des rechten Asts aufgebaut wird. Die Positionen der Start- und Endschweißsequenzen alternieren. Nach Zusammenführung der zwei Äste folgen das dritte und das vierte Segment mit jeweils helixförmigem Werkzeugweg. Zwischen den Segmenten findet eine Abkühlung des Bauteils statt.

Als Ausgangsmaterial wird in beiden Fällen ein $\varnothing 1.2$ mm AlSi5-Draht verwendet. Es kommen sowohl der CMT als auch der CMT-P Prozess zum Einsatz, wobei die in Tabelle 6.1 notierten Prozessparameter genutzt werden. Als Schutzgas wird Argon 4.5 mit einem Gasfluss von 10 L min^{-1} verwendet.

Tabelle 6.1: CMT- und CMT-P-Prozessparameter für die Fertigung der Bauteile im Rahmen der Validierung des Digitalen Zwillinges im industriellen Fertigungsszenario

Prozessparameter	CMT	CMT-P
$v_{TCP-Soll}$	350 mm min^{-1}	300 mm min^{-1}
v_{WF}	3.0 m min^{-1}	5.0 m min^{-1}
I	47 A	113 A
U	11.1 V	17.4 V

Während der Fertigung wird der Prozess überwacht und eine digitale Repräsentation angelegt. Darüber hinaus finden Prozesseingriffe durch die Abstandsregelung statt.

6.2 Erprobung des Systems

Nachfolgend werden die Ergebnisse der Erprobung vorgestellt. In Abbildung 6.6 sind der WAAM-Prozess zur Fertigung der bionischen inspirierten Leichtbaustruktur sowie die beiden gefertigten Validierungsbauteile auf den Substratplatten zu sehen.

Die unterschiedlichen Aspekte der Digitalen Zwillinge der Validierungsbauteile werden in dreidimensionalen Ansichten veranschaulicht.

Verbindungselement

Die Fertigung des Verbindungselements dauerte **39 min**. Insgesamt wurden **82 m** Draht genutzt, resultierend in einem Bauteilgewicht von **250 g** ohne Substratplatte. In Abbildung 6.7 sind in a) der Werkzeugweg, in b) der mittels CNN gemessene Abstand zwischen Schweißbrenner und Bauteil, in c) die Streckenenergie sowie in d) die Wahrscheinlichkeit für Oxidationsdefekte dargestellt.

Im ersten Segment des Bauteils war ein stabiler Prozess zu sehen. Der Abstand konnte mithilfe der Regelung konstant gehalten werden, wohingegen bei Vergleichsversuchen ohne Regelung die erforderliche Höhe des Bauteils nicht erreicht wurde.

Das zweite Segment, welches an das erste senkrecht anbaut, war von hohen Schwankungen des Abstands geprägt. Der hohe Abstand resultierte in einer verringerten Schutzgasabdeckung. Im Bereich der Krümmung führte dies zu Oxidationsdefekten, welche sich auch in den erhöhten

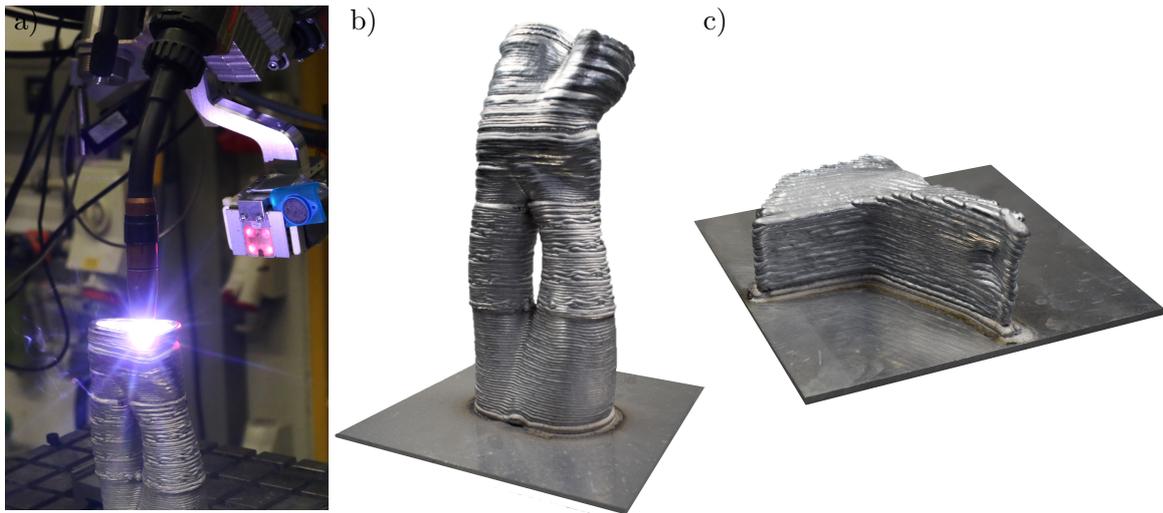


Abbildung 6.6: a) Multiaxialer WAAM-Prozess zur Erstellung der bionisch inspirierten Leichtbaustruktur, b) Validierungsbauteil bionisch inspirierte Leichtbaustruktur, c) Validierungsbauteil Verbindungselement

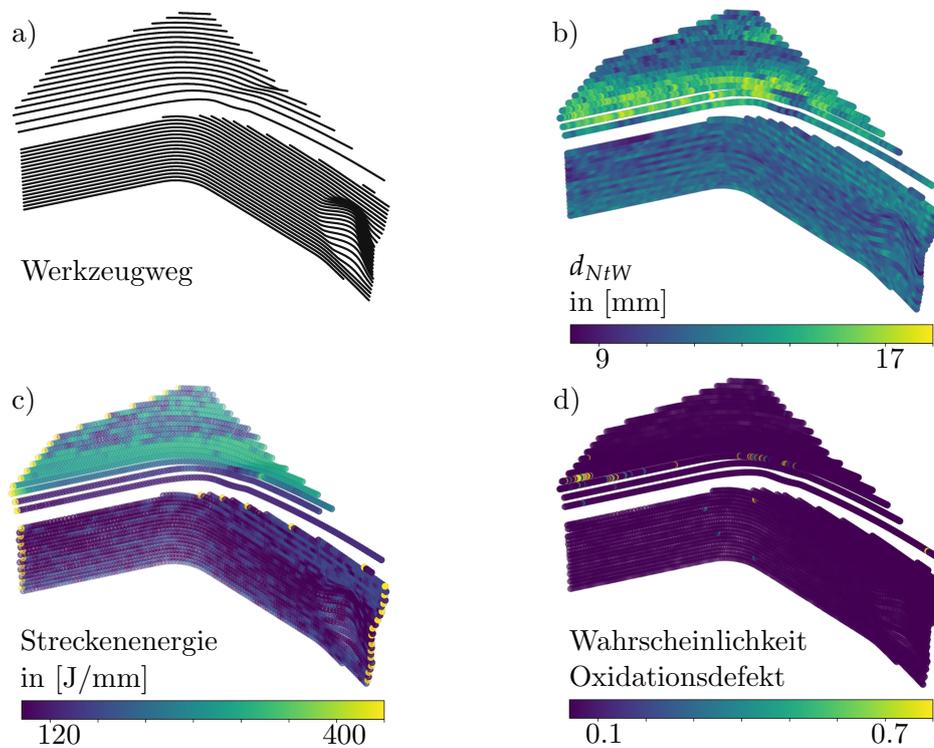


Abbildung 6.7: Aspekte des Digitalen Zwillings für das Verbindungselement als Validierungsbauteil entlang des Werkzeugwegs: a) Werkzeugweg, b) mittels CNN gemessener Abstands, c) Streckenenergie, d) Wahrscheinlichkeit für Oxidationsdefekte

Wahrscheinlichkeitswerten der Defektklassifikation wiederfanden. Die Abstandsregelung wirkte dem hohen Abstand entgegen, sodass die Prozessstabilität mit fortschreitendem Aufbau des zweiten Segments zunahm und letztendlich Formtreue erreicht wurde. Eine Auswirkung des Prozesseingriffs war die erhöhte Streckenenergie, die erst im oberen Teil des zweiten Segments wieder vergleichbare Werte wie im ersten Segment annahm.

Die Prozessplanung sollte auf Basis dieser Ergebnisse angepasst werden. So kann beispielsweise bereits in der Roboterbewegungsplanung ein konstanter Abstand zwischen Schweißbrenner

und Bauteil vorgesehen oder die Schweißgeschwindigkeit zu Beginn des zweiten Segments verringert werden.

Bionische Leichtbaustruktur

Die Fertigung der bionisch inspirierten Leichtbaustruktur dauerte insgesamt 119 min. Es wurden 302 m Draht genutzt, resultierend in einem Bauteilgewicht von 922 g ohne Substratplatte. In Abbildung 6.8 sind neben dem in a) aufgezeichneten Werkzeugweg der gemessene Abstand in b), die resultierende Schweißgeschwindigkeit in c) sowie der Anomaliewert entlang des Werkzeugwegs in d) dargestellt.

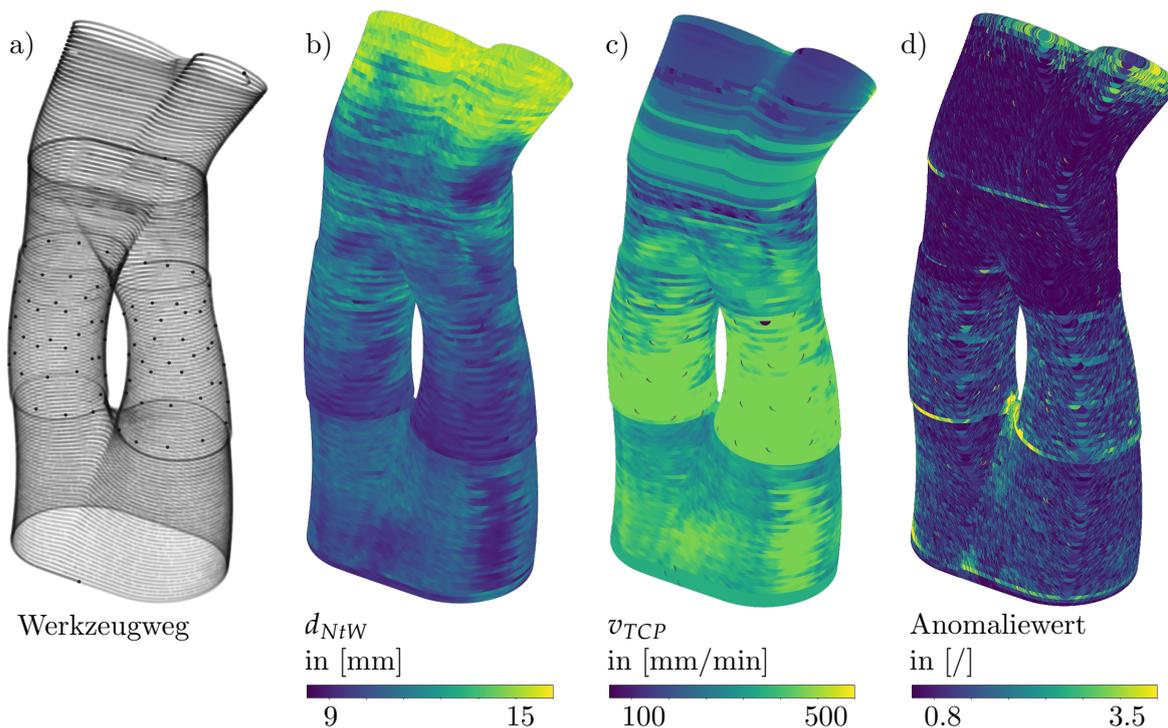


Abbildung 6.8: Aspekte des Digitalen Zwillings für die bionisch inspirierte Leichtbaustruktur als Validierungsbauteil entlang des Werkzeugwegs: a) Werkzeugweg, b) mittels CNN gemessener Abstand zwischen Schweißbrenner und Bauteil, c) geregelte Schweißgeschwindigkeit, d) Anomaliewert anhand der Mahalanobisdistanz

In der Darstellung des Werkzeugwegs sind die vier Segmente des Bauteils zu erkennen. Während im unteren und den zwei oberen Abschnitten kontinuierliche helixförmige Werkzeugwege eingesetzt wurden, sind im mittleren Abschnitt schwarze Punkte zu sehen, welche auf die Start- und Endpunkte der Schweißsequenzen zurückzuführen sind und auch in b) und c) zu erkennen sind.

Das erste Segment zeigte ein stabiles Schweißverhalten. In den Anomaliewerten gab es im Bereich des Startpunktes erhöhte Werte, die auf eine geometrische Unregelmäßigkeit zurückzuführen waren. Diese geometrische Abweichung konnte in den folgenden Lagen ausgeglichen werden. Die Drahtlängenerkennung ergab konsistente Werte, wobei im vorderen Bereich über mehrere Lagen hinweg systematisch niedrige Werte gemessen wurden. Diese korrespondieren nicht mit Geometrieabweichungen sondern gehen auf Reflexionen der aktiven Laserbeleuchtung der Schweißkamera am Bauteil zurück, die die Drahtlängenerkennung beeinträchtigten.

Im zweiten Segment zeigte sich anfangs ein geringer Abstand, der durch den Eingriff der Regelung nach mehreren Lagen in einen Normalzustand überführt werden konnte. Dabei lief

die Regelung in die gewählte Begrenzung, sodass eine nahezu konstant hohe Schweißgeschwindigkeit zu sehen war. Die Anomaliewertdarstellung zeigte in der ersten Lage des zweiten Segments erhöhte Werte, die auf Bindefehler aufgrund einer längeren Abkühlzeit zwischen den Segmenten zurückzuführen war. Zusätzlich war eine Anomalie im Bereich der Verästelung zu sehen, die als Unstetigkeit klassifiziert wurde. Eine Untersuchung dieses Bereichs am Bauteil bestätigte diese Einordnung.

Das dritte Segment zeigte ein stabiles Prozessverhalten, wohingegen das vierte Segment geprägt war von einer Erhöhung des Abstands, die in einer geringen, geregelten aber maschinell begrenzten Schweißgeschwindigkeit resultierte. Diese Erhöhung war auf einen Anbindungsfehler zwischen Segment drei und vier zurückzuführen, der in einer hellen grüngelben Linie in den Anomaliewerten in Abbildung 6.8 d) sichtbar ist. Während in Segment zwei aufgrund der alternierenden Schweißstrategie das Bauteil zwischenzeitlich abkühlen konnte, waren in Segment vier keine Abkühlzeiten vorgesehen. Aufgrund der bindefehlerbedingt verminderten Wärmeabfuhr und der fehlenden Abkühlzeiten kam es zu einer Überhitzung, welche in flacheren Schweißnaht Höhen resultierte. Während die Regelung die Schweißgeschwindigkeit niedrig hielt, um den Abstand zwischen Schweißbrenner und Bauteil zu verringern, erhöhte dies gleichzeitig die Streckenenergie und verstärkte damit die Überhitzung.

Durch den Digitalen Zwilling war es möglich, diese Kausalkette unmittelbar zu erschließen. Die Erkenntnisse konnten in der Prozessplanung genutzt werden, um in der nächsten Iteration bessere Druckergebnisse zu erhalten. Ein aufgrund der hohen Anomaliewerte initiiertes, automatisiertes Prozessstopp hätte Zeit und Material einsparen können. Bis zur Überhitzung konnte die Regelung alle Abstandsänderungen mithilfe von Schweißgeschwindigkeitsanpassungen ausgleichen. Nach Abschluss des Aufbaus hätte der erhöhte Anomaliewert in der Qualitätssicherung einen Hinweis auf den Bindefehler und damit einhergehende Qualitätsprobleme geben können.

6.3 Anforderungsbezogene Bewertung

In Abschnitt 2.4 sowie zu Beginn der Kapitel 3, 4 und 5 wurden Anforderungen an den Digitalen Zwilling und seine Module abgeleitet. Die zugehörigen technologischen Lösungen wurden in den Kapiteln 3, 4 und 5 vorgestellt und evaluiert sowie abschließend im Rahmen einer Erprobung in der industriellen Fertigung als Gesamtsystem validiert. Der Digitale Zwilling und die drei Kernelemente werden nachfolgend hinsichtlich der Erfüllung ihres Anforderungsprofils bewertet.

6.3.1 Bewertung des Gesamtsystems

Innerhalb der vorliegenden Forschungsarbeit wurde ein Digitaler Zwilling für die Additive Fertigung mittels Lichtbogenauftragschweißen entwickelt. Dieser wurde prototypisch entworfen, implementiert und anhand der Fertigung zweier industrieller WAAM-Bauteile validiert. Die in Abschnitt 2.4 definierten Anforderungen an das Gesamtsystem sowie die zugehörigen Lösungen sind in Tabelle 6.2 notiert.

Die bidirektionale Datenanbindung ermöglicht Synchronisierung zwischen der physischen Entität und dem Digitalen Zwilling. Einerseits wird die physische Entität durch die In-situ-Prozessüberwachung im Digitalen Zwilling abgebildet. Andererseits wird eine Anpassung der physischen Entität durch das Entscheidungsmodul vorgenommen. Die Nutzung von Edge-Geräten ermöglicht die zeitnahe Verarbeitung der Prozessdaten und den unmittelbaren Eingriff

Tabelle 6.2: Gegenüberstellung von Anforderungen an den Digitalen Zwilling und ihrer Lösungen

Anforderung	Lösung
Flexibilität	Modularität der Applikation durch Mikroservicearchitektur
Übertragbarkeit	Containerisierung der Submodule; Entkopplung von Informationsanbietern und -empfängern
Kompatibilität mit Industriehardware	Nutzung von industriellen Edge-Geräten
Schnittstellen	Konnektivitätsmodul; Webapplikation; Nutzung von Industriestandards

in den Prozess. Der modulare Aufbau resultiert in einer hohen Flexibilität, sodass mit geringem Aufwand Anpassungen an sich verändernde Randbedingungen und Erweiterungen vorgenommen werden können. Durch die Nutzung von Containerisierungstechnologien und die Entkopplung von Informationsanbietern und -empfängern wird die Übertragbarkeit auf weitere Fertigungs- und Sensorsysteme unterstützt.

Der vorgestellte Digitale Zwilling ist als industriegerechte Lösung konzipiert, welche zur Dokumentation im Rahmen der Bauteilqualifizierung nach DIN 17024-2 genutzt werden kann. Er umfasst die erforderlichen Elemente des Normentwurfs ISO 23247 für einen Digitalen Zwilling in der Fertigung und nutzt Industriestandards für die Kommunikationsschnittstellen. Die Subentität für Operabilität und Management deckt sich mit dem Modul zur digitalen Bauteil- und Prozessrepräsentation. Dort werden Informationen über beobachtbare Fertigungselemente vorgehalten, um sie weiteren Submodulen über OPC UA (IEC 62541) oder das MQTT-basierte Servicenetzwerk bereitzustellen. Die Subentität für Applikationen und Dienstleistungen fasst Funktionalitäten wie beispielsweise die Datenanalyse und Simulation zusammen. Sie wird im Rahmen dieser Arbeit in die zwei Module Prozessüberwachung und Prozesseingriff aufgeteilt, um eine Trennung zwischen Datenanalyse und Entscheidungsfindung zu erreichen. Das Konnektivitätsmodul findet sich in der Subentität für Ressourcenzugang und -austausch wieder, welches Zugangsmöglichkeiten für alle Funktionalitäten der Kernentität bereitstellt. Hier werden darüber hinaus Schnittstellen auf Basis industrieller Kommunikationsprotokolle für das Zugangsnetzwerk und das Nutzernetzwerk verfügbar gemacht. Die Mensch-Maschine-Schnittstelle ist als Webapplikation realisiert.

Der Digitale Zwilling ermöglicht Rückverfolgbarkeit, indem eine Anbindung an vor- und nachgelagerte Elemente des Produktlebenszyklus realisiert ist. Durch die Zuordnung einer eindeutigen Bauteilidentifikationsnummer sowie die Nutzung der Raumzeitindexierung können Qualitätsdaten mit den Prozessparametern und den Prozessdaten korreliert werden. Diese Informationen können genutzt werden, um die Prozessplanung zu beschleunigen und die Anzahl an Iterationszyklen zur Prozessparameteroptimierung zu reduzieren.

Gesondert werden die drei wesentlichen Eigenschaften von Digitalen Zwillingen nach Hribernik et al. [129] und ihre Ausprägung innerhalb des in dieser Arbeit vorgestellten Systems betrachtet. Dadurch wird die These aus Kapitel 2.4 im Hinblick auf die Ergebnisse dieser Arbeit bewertet und die Forschungsfrage beantwortet.

Kontextwahrnehmung:

Die Methoden des Kapitels 3 ermöglichen Kontextwahrnehmung für die Methoden der Kapitel 4 und 5, indem räumlicher und zeitlicher Kontext sowie Systemkontext bereitgestellt werden.

Der Systemkontext wird genutzt, um die Zustandsmaschinen der Submodule der Prozessüberwachung und des Prozesseingriffs zu schalten. Der zeitliche Kontext ermöglicht die Einordnung der Daten in Relation zum aktuellen Zeitpunkt, sodass sowohl Vorhersagen zukünftiger Ereignisse als auch Auswertungen vergangener Prozessabschnitte möglich sind. Die Wahrnehmung des räumlichen Kontext auf Basis des räumlich relevanten Bereichs ermöglicht einerseits die prozessparallele Nutzung neuartiger Qualitätsmetriken. Andererseits werden relevante Informationen für die Einordnung des Prozesszustands bereitgestellt, sodass eine Verbesserung von Defektklassifizierungsmethoden und präskriptive Prozessparameteranpassungen möglich sind. Quantitativ ergab sich durch die Nutzung von Kontextwahrnehmung eine Steigerung der Genauigkeit in der Defektklassifikation um 22.2 Prozentpunkte für Oxidationsdefekte. Dieser Mehrwert der Kontextwahrnehmung galt jedoch lediglich für bestimmte Defekttypen. Bei Schlackedefekten erhöhte die Kontextwahrnehmung die Detektionsleistung in der Klassifikation nicht. Erst mithilfe der Kontextwahrnehmung ist Autonomie und Anpassungsfähigkeit des Digitalen Zwillinges möglich.

Autonomie:

Der Digitale Zwilling interagiert selbstständig mit dem Fertigungsprozess und erfüllt so das Kriterium der Autonomie. Er kann auf Basis der Ergebnisse der Prozessüberwachung eigenständig Entscheidungen treffen und mithilfe der Methoden aus Kapitel 5 autonom in den Prozess eingreifen. Durch die Abstandsregelung mit Breitenmodul kann die Optimierung der Prozessparameter dem Digitalen Zwilling überlassen werden. Dies resultierte in einer erhöhten Formtreue und ermöglichte die erfolgreiche Fertigung von Bauteilen ohne vorherige Prozessparameteroptimierung. Der absolute Unterschied zwischen realisierter und geplanter Spurbreite konnte für die untersuchten Parametersätze im Mittel von 0.24 mm auf 0.04 mm reduziert werden. Der absolute Unterschied zwischen realisierter und geplanter Spurbreite wurde im Mittel von 2.0 mm für die Abstandsregelung ohne Breitenmodul auf 0.4 mm mit Breitenmodul vermindert. Die präskriptive Prozessparameteranpassung passt autonom und vorausschauend die Prozessparameter an, um Defekte zu kompensieren und (Folge-)Defekte zu vermeiden. Die vorgestellte Methodik erhöhte die Fehlertoleranz des Prozesses. Die lägenübergreifende Fortsetzung eines Unstetigkeitsdefekts konnte zum Teil gänzlich verhindert werden. Durch die Synchronisierung der Daten aus der Prozessplanung und der Prozessdaten mithilfe der Methoden aus Kapitel 3 erzeugt der Digitale Zwilling ohne externen Eingriff eine Dokumentation des Fertigungsprozesses.

Anpassungsfähigkeit:

Die Anpassungsfähigkeit des Digitalen Zwillinges zeigt sich durch seine Unabhängigkeit von der Bauteilgeometrie und von den Prozessparametern. Die bauteilspezifische Initialisierung der Repräsentationsstruktur aus Kapitel 3 erfolgt automatisiert auf Basis des Maschinencodes. Der modulare Aufbau des Softwaresystems ermöglicht eine schnelle Anpassung an sich verändernde Randbedingungen. Adaptive Algorithmen ermöglichen, wie in Kapitel 4 dargestellt, die Datenauswertung auch für unbekannte Materialien und Prozessparameter. So konnte bei der Anomaliedetektion mithilfe des konditionierten speichererweiterten Autoencoders in einem Szenario mit wenigen Daten einer neuen Aufgabe ein PR AUC-Wert von 0.850 im Gegensatz zu 0.785 ohne adaptive Algorithmen erreicht werden. Bei der Defektklassifikation konnte durch die Nutzung des Metalernalgorithmus MAML eine Steigerung der Detektionsgenauigkeit um bis zu 14.8 Prozentpunkte erreicht werden. Während die Anomaliedetektion eine hohe Anpassungsfähigkeit zeigte, konnte Anpassungsfähigkeit der Defektklassifikation

lediglich für Prozessparametersätze erreicht werden, deren Eigenschaften sich ähnelten. Dies geht auf die erforderliche Merkmalsextraktion in der Datenvorverarbeitung zurück, welche auf Expertenwissen basiert und nicht verallgemeinert ist. Um die Anpassungsfähigkeit der Defektklassifikation zu erhöhen, sollte deshalb auf die Merkmalsextraktion verzichtet und ein performanteres Klassifikationsmodell eingesetzt werden.

Kontextwahrnehmung, Autonomie und Anpassungsfähigkeit eines Digitalen Zwillings für die additive Fertigung mittels Lichtbogenauftragschweißen unterstützen die Industrialisierung des WAAM-Prozesses. Durch ihre Integration kann Rückverfolgbarkeit erreicht, die Prozessparametersensitivität reduziert, die Prozessreproduzierbarkeit erhöht, der Produktionsausschuss verringert und die Kosten der Qualitätssicherung vermindert werden.

6.3.2 Bewertung der Module des Digitalen Zwillings

Die anforderungsbezogene Bewertung der drei Kernelemente des Digitalen Zwillings, welche in den Kapiteln 3, 4 und 5 vorgestellt wurden, findet nachfolgend statt. Dazu werden die Anforderungen an das jeweilige Modul ihren zugehörigen Lösungen gegenübergestellt.

Digitale Bauteil- und Prozessrepräsentation

Die digitale Repräsentation schafft ein digitales Abbild des Prozesses und des Bauteils. Den definierten Anforderungen wird mit den in Tabelle 6.3 festgehaltenen Lösungen begegnet.

Tabelle 6.3: Gegenüberstellung von Anforderungen an die digitale Bauteil- und Prozessrepräsentation und ihrer in Kapitel 3 vorgestellten Lösungen

Anforderung	Lösung
Voll 3D-fähiges Datenmanagement	Raumzeitindexierung; Nutzung eines Octrees
Situationsabhängige Kontextbereitstellung	Definition räumlicher Relevanz; Zustandsmaschine
WAAM-gerechte Qualitätsbewertung	Lokale Anomaliedichte; Defektgruppenexpansion
Zuordnung von Qualitätsdaten, Prozessdaten und Prozessparametern	Räumliche Annotation von Zeitreihen
Anbindung an vor- und nachgelagerte Prozessschritte sowie übergeordnete Datenmanagementsysteme	OPC UA Informationsmodell; Schnittstellen für den Datenaustausch; Serialisierung des Octrees

Durch Einführung der Octreedatenstruktur wird eine voll 3D-fähige Datenstruktur für den WAAM-Prozess etabliert. Es wird ein Konzept für eine Raumzeitindexierung vorgestellt, mit dem die räumlichen und zeitlichen Aspekte für multiachs-basierte AM-Prozesse berücksichtigt werden. Der Prozess wird über eine Zustandsmaschine modelliert, welche einen Teil des Systemkontexts darstellt. Durch die Definition eines räumlich relevanten Bereichs in Form eines Kubus, einer Kugel und eines Dopelellipsoids sowie mithilfe des Systemkontexts wird eine kontextbezogene Datenauswertung ermöglicht, die in der Prozessüberwachung und für den Prozesseingriff eingesetzt wird. Dort können der räumliche und zeitliche Kontext sowie der Systemkontext zur Verbesserung der Anomaliedetektion und Defektklassifikation sowie für einen informierten Prozesseingriff verwendet werden. Weiterhin ermöglicht die Nutzung des

Octrees sowie der räumlichen Relevanz die Einführung WAAM-gerechter Qualitätsmetriken, die den dreidimensionalen Prozesscharakter einbeziehen. Beispielhaft ist dies anhand der lokalen Anomaliedichte und der Defektgruppenausdehnung zu sehen. Die Anbindung übergeordneter Datenmanagementsysteme gelingt durch den Aufbau eines OPC UA Informationsmodells. Mithilfe von Schnittstellen für den Datenaustausch können Informationen aus der Bauteil- und Prozessplanung in den statischen Octree überführt werden. Durch die Serialisierung des Octrees wird die Datenstruktur vor- und nachgelagerten Schritten der Produktentstehung verfügbar gemacht. Die Zuordnung zwischen Qualitätsdaten, Prozessparametern und Prozessdaten wird durch die Einführung einer Methodik zur räumlichen Annotation von Zeitreihendaten erreicht. Die Vorgehensweise ermöglicht die Erstellung von Annotationen für die Bewertung und das Training von Algorithmen der Prozessüberwachung.

Die Anforderungen an die digitale Bauteil- und Prozessrepräsentation wurden damit erfüllt.

Prozessüberwachung

Die Prozessüberwachung wertet Prozessdaten aus, um Aussagen über den Prozesszustand und die Bauteilqualität zu treffen. Den Anforderungen wird mit den in Tabelle 6.4 genannten Lösungen begegnet.

Tabelle 6.4: Gegenüberstellung von Anforderungen an die Prozessüberwachung und ihrer in Kapitel 4 vorgestellten Lösungen

Anforderung	Lösung
Defekterkennung trotz eines geringen Umfangs an gelabelten Daten	Unüberwachte Anomaliedetektion mittels Autoencoder
Kontextsensitive Defektklassifikation	Multivariate, kontextwahrnehmende Klassifikation
Übertragbarkeit auf andere Parametersätze	Meternalernen und kontextabhängige Datenauswertung
Richtungs- und schichtinvariante Abstandsmessung	Optische Messung der Drahtlänge mittels CNN
Prozessparallele Inferenz der Modelle	Nutzung eines Edge-Geräts

Die Anomaliedetektion mittels Autoencodern ermöglicht die Erkennung von abnormalen Prozesszuständen. Durch den unüberwachten Anomaliedetektionsansatz zur Defekterkennung ist keine Annotation der Daten erforderlich. Es wurden PR AUC-Werte von bis zu 0.963 erreicht. Der konditionierte, speichererweiterte Autoencoder ermöglicht modellbasiertes Meternalernen, mit dem die Übertragung des Modells auf andere Prozessparametersätze innerhalb weniger Schritte möglich ist. Im Anschluss an eine Anlernphase mit lediglich zehn Datenelementen eines neuen Prozessparametersatz wurde ein PR AUC-Wert von 0.850 in der Anomaliedetektion erreicht. Die Einordnung der Defekte wurde über eine überwachte, multivariate Defektklassifizierung realisiert. Je Defekt wird ein angepasstes MLP erstellt. Zusätzlich zu den Sensordaten wird den Klassifikationsmodellen der Systemkontext sowie räumlicher und zeitlicher Kontext bereitgestellt. Dadurch wurde der PR AUC-Wert für die Klassifikation von Oxidationsdefekten um 0.135 verbessert. Die Verbesserungen für Unstetigkeiten und Schlackedefekte lagen mit 0.025 respektive 0.012 deutlich niedriger. Um die Übertragbarkeit auf andere Prozessparameter zu erhöhen, wird auf den Meternalgorithmus MAML zurückgegriffen. Im Vergleich zu den Modellen ohne Meternalernmethode wurde eine Verbesserung des PR AUC-Werts um bis zu 0.123 für Unstetigkeitsdefekte und um bis zu 0.103 für Oxidationsdefekte erreicht. Die Einordnung von Schlackedefekte konnte durch die Meternalernmethode nicht verbessert

werden. Zuletzt ist eine schicht- und richtungsinvariante Abstandsmessung gefordert. Sie wird mithilfe eines CNNs realisiert, welches den sichtbaren Schweißdraht in Schweißkamerabildern extrahiert. Aufgrund möglicher Reflexionen der aktiven Laserbeleuchtung am Bauteil war Geometrieunabhängigkeit nicht zu jedem Zeitpunkt gegeben, wie auch die Validierung mit der bionisch inspirierten Leichtbaustruktur in Abschnitt 6.2 zeigte. Die Abstandsmessung ist prozessparameterunabhängig. Mit den verwendeten Modellen wurde auf dem genutzten Edge-Gerät prozessparallele Inferenz erreicht.

Die Anforderungen an die Prozessüberwachung wurden erfüllt. Weitere Untersuchungen im Bereich der Defektklassifikation und geometrieunabhängigen Abstandsmessung sind jedoch erforderlich.

Datengestützter Prozesseingriff

Der Prozesseingriff erhöht die Autonomie des Systems, indem Prozessparameter selbstständig angepasst und der Prozess fehlertoleranter gestaltet werden. Eine Gegenüberstellung der Anforderungen und ihrer Lösungen für den datengestützten Prozesseingriff ist in Tabelle 6.5 zu sehen.

Tabelle 6.5: Gegenüberstellung von Anforderungen an den datengestützten Prozesseingriff und ihrer in Kapitel 5 vorgestellten Lösungen

Anforderung	Lösung
Sicherung eines konstanten Abstands zwischen Schweißbrenner und Bauteil	Abstandsregelung
Erhöhung der Fehlertoleranz	Präskriptive Prozessparameteranpassung
Omnidirektionale einsetzbare, schichtinvariante Methoden	Nutzung richtungs- und schichtinvarianter Messmethoden und voll 3D-fähiger Datenstrukturen
Möglichkeit zur Prozessqualifizierung	Orientierung an der Norm DIN 17024-2; Erweiterung der Abstandsregelung um Breitenmodul; Wiederholbarkeit der Eingriffe

Die Einhaltung eines konstanten Abstands zwischen Schweißbrenner und Bauteil wird über eine omnidirektionale, schichtinvariante Abstandsregelung erreicht. Durch die Erweiterung der Abstandsregelung um ein Breitenmodul wurden die Schweißnahtbreite und die Streckenenergie an die Planwerte angenähert. Durch die Definition eines Toleranzbandes für die Prozessparameter sowie die Aufzeichnung aller relevanten Werte ist trotz Einsatzes der Regelung eine Prozessqualifizierung nach DIN 17024-2 möglich. Zur Erhöhung der Fehlertoleranz wird eine präskriptive Prozessparameteranpassung eingeführt, welche auf Basis des räumlichen und zeitlichen Kontexts einer zukünftigen TCP-Position die Prozessparameter anpasst. Dadurch können Defekte kompensiert und Folgedefekte vermieden werden. Mithilfe dieser Methodik konnte die lagenübergreifende Fortsetzung von Unstetigkeitsdefekten zum Teil gänzlich unterbunden werden. Zur Qualifizierung einer solchen Prozessanpassung sind weiterführende Tests und Nachuntersuchungen erforderlich. Eine Nutzung von Toleranzbändern für die Prozessparameter könnte die Prozesszertifizierung der präskriptiven Prozessparameteranpassung unterstützen. Durch die Nutzung richtungs- und schichtinvarianter Messmethoden und voll 3D-fähiger Datenstrukturen sind die vorgestellten Prozesseingriffe omnidirektional einsetzbar und schichtinvariant. Die Wiederholbarkeit der vorgestellten Methoden für den Prozesseingriff wurde durch den reproduzierbaren Aufbau von Teststrukturen nachgewiesen.

Die Anforderungen an den datengestützten Prozesseingriff wurden damit erfüllt.

6.4 Zusammenfassung

Innerhalb dieses Kapitel wurde der Digitale Zwilling für die Additive Fertigung mittels Lichtbogenauftragschweißen im Rahmen eines industriellen Fertigungsszenarios validiert. Dazu wurde er im Gesamten als Teil eines intelligenten Fertigungssystems konzipiert, prototypisch umgesetzt und anhand der Fertigung eines industriellen WAAM-Bauteils aus der Automobilbranche sowie einer bionisch inspirierten Leichtbaustruktur validiert. Mithilfe der Digitalen Zwillinge konnten Kausalketten für Defekte hergeleitet werden und so ein Mehrwert für die Prozessplanung, den Anlagenbedienenden und den Qualitätsingenieur beziehungsweise die Qualitätsingenieurin gezeigt werden. Im Anschluss wurde eine anforderungsbezogene Bewertung des Digitalen Zwillings vorgenommen. Es wurde die Forschungsfrage beantwortet und gezeigt, dass sowohl das Gesamtsystem als auch die einzelnen Module den anfangs definierten Anforderungen entsprechen.

Kapitel 7

Schlussfolgerung und Ausblick

7.1 Zusammenfassung und Beitrag der Arbeit	119
7.2 Übertragbarkeit	121
7.3 Ausblick	122

Zum Abschluss wird in diesem Kapitel der Inhalt der vorliegenden Arbeit zusammengefasst, ihr Beitrag zum Stand der Technik und Forschung beleuchtet und ihr Gültigkeitsbereich sowie die Übertragbarkeit der Methoden diskutiert. Auf Basis dieser abschließenden Betrachtung und den Erkenntnissen und Methoden der Arbeit werden Vorschläge hinsichtlich zukünftiger Forschungsthemen gegeben.

7.1 Zusammenfassung und Beitrag der Arbeit

In der vorliegenden Forschungsarbeit wurde untersucht, wie Kontextwahrnehmung, Autonomie und Anpassungsfähigkeit eines prozessorientierten Digitalen Zwillings für die Additive Fertigung mittels Lichtbogenauftragschweißen erreicht werden können. Der Digitale Zwillling wurde dafür prototypisch entworfen, implementiert und anhand der Fertigung zweier Bauteile validiert. Bei den Untersuchungen wurde der Fokus auf die drei Kernelemente des Digitalen Zwillings (digitale Bauteil- und Prozessrepräsentation, Prozessüberwachung, datengestützter Prozesseingriff) gelegt.

Im Kapitel für die digitale Repräsentation von Bauteil und Prozess (Kapitel 3) wurden Konzepte zur Bereitstellung von Systemkontext, räumlichen und zeitlichen Kontext vorgestellt. Der Systemkontext wurde über ein OPC UA Informationsmodell sowie über ein Prozesszustandsmodell bereitgestellt. Die Untersuchung des zeitlichen Kontexts gelang über die zeitliche Indexierung aller Dateninstanzen. Der räumliche Kontext wurde in einem Octree hinterlegt und konnte mithilfe einer Raumzeitindexierung mit dem zeitlichen Kontext in Verbindung gebracht werden. Für die Octreeabfrage wurden drei Geometrien definiert, um räumlich relevante Datenpunkte zu extrahieren. Um eine Anbindung an die vor- und nachgelagerten Schritte der Produktentstehung zu realisieren, wurde eine Methodik zur räumlichen Annotation von Zeitreihen vorgestellt. Die erhaltenen Annotationen wurden für das Training und die Evaluierung der Methoden zur Anomaliedetektion und Defektklassifikation genutzt.

Die Prozessüberwachung (Kapitel 4) analysierte den WAAM-Prozess datengetrieben und stellte prozessparallel Qualitäts- und Prozessinformationen bereit. Dafür wurde der Prozess zunächst auf physikalischer Ebene betrachtet und digital modelliert. Zudem wurde eine Ursachen-Wirkungs-Analyse hinsichtlich Unregelmäßigkeiten in den gemessenen Prozessdaten

vorgenommen. Anschließend wurden geeignete Sensoren für die Prozessüberwachung bestimmt. Die Auswahl eines geeigneten Anomaliedetektors wurde auf ein Klassifikationsproblem zurückgeführt, bei dem die Zeitreihenmerkmale der Prozessdaten mit den Detektionsleistungen der Anomaliedetektoren in Verbindung gesetzt wurden. Es wurde ein F_1 -Wert von 0.650 erreicht. Anschließend wurde eine parametrisierbare Autoencoderarchitektur konzipiert und um ein konditionierbares, externes Speichermodul erweitert. Es wurden PR AUC-Werte von bis zu 0.963 bei der Anomaliedetektion realisiert. Durch eine Initialisierung der Speichereinträge der C-MemAE-genannten Architektur auf Basis der Kopie der Encodings wurde bei einem unbekanntem Datensatz mit lediglich zehn Datenelementen ein PR AUC-Wert von 0.850 erreicht. Bei der Defektklassifikation wurde sowohl System- als auch zeitlicher und räumlicher Kontext einbezogen. Dadurch wurde eine Verbesserung der Klassifikationsgenauigkeit um 22.2 Prozentpunkte für Oxidationsdefekte erreicht. Durch die Nutzung eines Metalernansatzes wurde die Klassifikationsgenauigkeit für Unstetigkeitsdefekte um 14.8 Prozentpunkte verbessert. Abschließend wurden Methoden zur richtungs- und schichtinvarianten Messung des Abstands zwischen Schweißbrenner und Bauteil vorgestellt. Die Spektrometerdaten zeigten bei einer Wellenlänge von 905 nm eine nahezu lineare Korrelation mit dem Abstand, waren jedoch trotz Datenvorverarbeitung parameter- und geometrieabhängig. Die Analyse des Schweißkammerbilds zur Erkennung des sichtbaren Draht mithilfe eines CNNs ermöglichte eine richtungs-, schicht- und prozessparameterinvariante Abstandsmessung.

Auf Basis der aus der Prozessüberwachung gewonnenen Erkenntnisse wurde ein datengestützter Prozesseingriff (Kapitel 5) umgesetzt, um Abweichungen vom Sollzustand im Prozess autonom zu korrigieren. Es wurde eine Abstandsregelung konzipiert, welche die Schweißgeschwindigkeit anpasste, um Einfluss auf die Schweißnahthöhe zu nehmen und so den Abstand zwischen Schweißbrenner und Bauteil konstant zu halten. Durch Anpassung der Drahtvorschubgeschwindigkeit wurde die Schweißnahtbreite sowie die Streckenenergie trotz Schweißgeschwindigkeitsänderung annähernd konstant gehalten. Durch die omnidirektionale, schichtinvariante Abstandsregelung konnten komplexe Bauteile mit Multiachsoperationen ohne vorherige Prozessparameteroptimierung beim ersten Versuch erfolgreich aufgebaut werden. Darüber hinaus wurde eine Methodik zur präskriptiven Prozessparameteranpassung vorgestellt, mit der Defekte kompensiert und Folgedefekte vermieden werden konnten. Es wurde eine Positionsvorhersage vorgenommen und der zukünftige räumliche Kontext ausgewertet, um einen Prozesseingriff zu planen und zu initiieren. Das Konzept wurde anhand der Kompensation eines Unstetigkeitsdefekts evaluiert und eine statistisch signifikante Reduktion der Defektgruppengröße erreicht. Die präskriptive Prozessparameteranpassung ermöglichte damit einen fehlertoleranteren Prozess.

Die vorgestellten Methoden zum datengestützten Prozesseingriff bildeten zusammen mit der Prozessüberwachung und der Bauteil- und Prozessrepräsentation sowie einem Konnektivitäts- und einem HMI-Modul den Digitalen Zwilling für die additive Fertigung mittels Lichtbogenauftragschweißen. Dieser wurde schließlich im Rahmen eines industriellen Fertigungsszenarios untersucht (Kapitel 6). Dazu wurde der Digitale Zwilling im Gesamten als Teil eines intelligenten Fertigungssystems konzipiert, prototypisch umgesetzt und anhand der Fertigung zweier WAAM-Bauteile validiert. Sowohl das Gesamtsystem als auch die einzelnen Kernelemente erfüllten die Anforderungen an einen industriegerechten, kontextwahrnehmenden, anpassungsfähigen und autonomen Digitalen Zwilling für die Additive Fertigung mittels Lichtbogenauftragschweißen. Der Digitale Zwilling konnte für die Prozessoptimierung eingesetzt werden und als Datenbasis für die Qualitätssicherung, künftige Datenauswertungen und Prozessoptimierungsschritte dienen, sodass Kosten und Zeit in der Prozessplanung und Qualitätssicherung eingespart werden können.

Die Implementierung des Digitalen Zwillings wird inzwischen erfolgreich in Produktivsystemen

zur Prozessüberwachung eingesetzt. Kommerzielle Produkte auf Basis der vorgestellten Struktur des Digitalen Zwillings, der Raumzeitindexierung und der Abstandsregelung sind in der Entwicklung.

7.2 Übertragbarkeit

Die Übertragbarkeit der vorgestellten Methoden auf andere Prozessparameter, Materialien, Schweißprozesse, weitere AM-Verfahren sowie darüber hinausgehende Anwendungsgebiete wird anhand einer Matrixstruktur in Tabelle 7.1 erörtert.

Tabelle 7.1: Bewertung der Übertragbarkeit der vorgestellten Methoden auf andere Prozessparameter, andere Materialien, andere Schweißprozesse, weitere Multiachs-AM-Prozesse, pulverbettbasierte AM-Prozesse und darüber hinaus gehende Bereiche. Ein ●-Zeichen symbolisiert eine hohe Übertragbarkeit wohingegen ein ○-Zeichen eine geringe Übertragbarkeit darstellt.

	Software	Hardware	Anomaliedetektion	Defektklassifikation	Abstandsmessung	Systemkontext	Raumzeitindexierung	Zeitreihenannotation	Abstandsregelung	Präskriptive Anpassung
Prozessparameter	●	●	●	●	●	●	●	●	●	●
Material	●	●	●	◐	●	●	●	●	◐	●
Schweißprozess	●	●	●	◐	◐	●	●	●	◐	●
Weitere Multiachs-AM-Prozesse	●	◐	◐	◐	○	●	●	●	○	◐
Pulverbettbasierte AM-Prozesse	◐	○	◐	◐	○	◐	◐	◐	○	◐
Weitere Anwendungsgebiete	◐	○	◐	○	○	○	○	○	○	○

Die vorgestellten Methoden lassen sich, wie bereits in den Evaluierungsabschnitten der Kapitel 3, 4 und 5 nachgewiesen, auf andere Prozessparameter, andere Materialien (AlSi5, 6060) und andere Schweißverfahren (CMT, CMT-P) übertragen. Bei größeren Unterschieden im verwendeten Material oder Schweißprozess ist eine Anpassung der Zeitreihenmerkmalsextraktion und eine erneute Systemidentifikation erforderlich. Zur Übertragung der Abstandsmessung mittels Drahterkennung muss der Draht zugleich als Schweißelektrode fungieren, sodass diese Methode auf MSG-Schweißprozesse beschränkt ist. Die Methoden im Bereich der digitalen Bauteil- und Prozessrepräsentation sind uneingeschränkt auf andere Prozessparameter, Materialien und Schweißprozesse übertragbar.

Die behandelten Methoden können auf andere AM-Verfahren übertragen werden. Dafür kommen besonders multiachs-basierte Verfahren wie beispielsweise LMD oder FDM in Betracht, da sie dem WAAM-Prozess hinsichtlich des voll 3D-fähigen Materialauftrags ähneln. Da es sich in diesen Fällen nicht um MSG-Schweißprozesse handelt, ist eine angepasste Prozesstechnik sowie ein anderer Aufbau des Sensorsystems erforderlich. Die Prozessdaten unterscheiden sich von den CMT-Prozessdaten. Dennoch sind die Methoden zur Anomaliedetektion sowie zur Kontextwahrnehmung und Modellanpassung in abgewandelter Form nutzbar. Die Abstandsmessung und -regelung sind nicht auf weitere AM-Verfahren übertragbar, wohingegen

die Software und die digitale Bauteil- und Prozessrepräsentation uneingeschränkt verwendet werden können. Die Nutzung der präskriptiven Prozessparameteranpassung erfordert die Möglichkeit zum wiederholten Aufschmelzen bereits aufgetragenen Materials.

Auf pulverbettbasierte AM-Verfahren wie L-PBF sind lediglich Teile der vorgestellten Methoden übertragbar. Dazu gehören die Anomaliedetektion und die digitale Bauteil- und Prozessrepräsentation. Da die schichtbasierten Prozesse nicht voll 3D-fähig sind, sollte ein Austausch des Octrees erwogen werden. Als Alternative wäre beispielsweise ein Satz gestapelter Quadrees denkbar. Alle anderen Methoden lassen sich nur stark eingeschränkt oder nicht auf pulverbettbasierte AM-Verfahren übertragen.

In Anwendungsgebieten außerhalb von AM zeigten die Methoden der Anomaliedetektion eine hohe Übertragbarkeit. Es konnte nachgewiesen werden, dass die Methodik zur Detektorauswahl sowie die C-MemAE-basierte Metalearnmethode für Zeitreihendaten eingesetzt werden können, die keinen WAAM-Bezug aufweisen. Teile der Software für den Digitalen Zwilling lassen sich aufgrund der Modularität des Systems für andere Fertigungsprozesse wie beispielsweise Fräsen oder Drehen verwenden.

7.3 Ausblick

Die vorliegende Arbeit schafft einen Grundstein für die Generierung prozessorientierter Digitaler Zwillinge für die Additive Fertigung mittels Lichtbogenauftragschweißen. Auf Basis des Beitrags dieser Arbeit zum Stand der Technik ergeben sich neue Felder für zukünftige Forschungsthemen. Dazu gehören die in den Evaluierungen der einzelnen Kapitel angesprochenen, weiterführenden Untersuchungen beispielsweise der physikalischen Prinzipien hinter der Abstandsmessung, der Einflüsse von Zeitreihenmerkmalen und Anomalieausprägungen auf die Anomaliedetektion, des C-MemAEs beim Lernen mittels weniger Schritte sowie der Nutzung der präskriptiven Prozessparameteranpassung zur Behebung und Vermeidung weiterer Defekte. Unter Berücksichtigung des ganzheitlichen Konzepts des Digitalen Zwilling für WAAM werden nachfolgend als Ausgangspunkt zukünftiger Forschungsarbeiten drei übergeordnete Forschungsfragen gestellt.

- *Wie schafft die Nutzung von Informationen aus Prozesssimulationen in Kombination mit dem prozessorientiertem Digitalen Zwilling einen Mehrwert für den Prozess?*
Durch den statischen Octree wurde die Möglichkeit geschaffen, Informationen aus Prozesssimulationen in den prozessorientierten Digitalen Zwilling einzubinden. Es sind Methoden erforderlich, um mithilfe dieses Wissens Prozesseingriffe zu initiieren und die Qualität des Bauteils und die Prozessstabilität präziser einzuschätzen. Darüber hinaus sollte eine Untersuchung hinsichtlich der Einbindung von Echtzeitsimulationen in den Digitalen Zwilling stattfinden. Mit ihrer Hilfe könnten die Auswirkungen von Prozessparameteranpassungen bereits vor dem Prozesseingriff simulativ evaluiert werden. Beispielsweise könnte damit die präskriptive Prozessparameteranpassung eingesetzt werden, um Bindefehler zielgerichtet zu verhindern.
- *Wie lässt sich der prozessorientierte Digitale Zwilling mit dem Konzept der Digitalen Materialien kombinieren?*
Das Konzept der Digitalen Materialien schlägt die anwendungsorientierte Generierung neuer Legierungen vor, wobei sich besonders die Additive Fertigung für deren Herstellung anbietet. Der prozessorientierte Digitale Zwilling wiederum ermöglicht die Verbindung von Prozessparametern, Prozessdaten und Qualitätsdaten. Indem diese zwei Bereiche

zusammengebracht werden, könnten Synergien und neue Erkenntnisse in beiden Forschungsgebieten erreicht werden.

Beispielsweise könnten, wie von Wessels und Wriggers vorgeschlagen, mittels datengetriebener Ansätze funktional gradierte Materialien gezielt aufgebaut werden. Aus den Prozessdaten werden dazu Rückschlüsse auf die Struktureigenschaften des finalen Bauteils gezogen und der Prozess gegebenenfalls abgewandelt. [270]

- *Auf welche Art und Weise kann der prozessorientierte Digitale Zwilling zur Optimierung der Prozessplanung beitragen?*

Eine Anbindung des Digitalen Zwillings an die vorgelagerten Prozessschritte wurde im Rahmen dieser Arbeit bereits umgesetzt. Zur Nutzung der Informationen für die Optimierung der Prozessplanung sind jedoch weitere Methoden erforderlich. Es kann sich dabei beispielsweise um regionenbasierte Vorschläge für Prozessparameter oder qualitätsorientierte Änderungen der Werkzeugwegplanung handeln. Langfristig könnte durch diese Parameterrückführung eine automatisierte Prozessplanung gelingen.

Der WAAM-Prozess ermöglicht die kosten- und ressourceneffiziente Herstellung großvolumiger, individualisierter Bauteile aus Metall. Letztendlich lässt sich dessen Industrialisierung nur durch die Kombination voll 3D-fähiger Digitalisierungslösungen und umfassender Prozesskenntnisse im Bereich der Schweißtechnik erreichen.

Anhang A

Zusatzinformationen zum intelligenten Fertigungssystem

In diesem Kapitel des Anhangs werden zusätzliche Informationen zum Aufbau des intelligenten Fertigungssystems gegeben, welches für die Validierung des Digitalen Zwillings in Kapitel 6 genutzt wurde. Es wird zunächst eine detailreichere Darstellung des Systemaufbaus gegeben, anschließend wird auf die genutzten Sensoren für die Prozessüberwachung eingegangen und abschließend wird die Benutzeroberfläche des HMIs vorgestellt.

A.1 Systemaufbau des Cyber-Physischen-Systems

In Abbildung A.1 ist die Systemarchitektur des Cyber-Physischen-Systems für die WAAM-Fertigungsanlage dargestellt, welche in Rahmen dieser Arbeit entstanden ist und für die Validierung in Kapitel 6 genutzt wurde.

Die Fertigungsanlage (SPS, NC, Periphere, Schweißquelle, Antriebseinheiten und einzelne Sensoren) wurde über das Maschinennetz vernetzt und mit den Edge-Geräten verbunden, auf denen der Digitale Zwilling aufgebaut wurde. Über ein separates Sensornetzwerk wurden Sensoren mit hohen Anforderungen an die Bandbreite wie beispielsweise die Schweißkamera angebunden, so dass eine Überlastung des Maschinennetz vermieden wurde. Die Mensch-Maschine-Schnittstelle wurde einerseits dem Anlagenbediener über eine lokale Visualisierung bereitgestellt. Andererseits konnte über eine Fernanbindung auf die Visualisierung zugegriffen werden, wobei dann die Bildrate des Schweißvideos begrenzt war. Weiterhin konnten über eine Datenschnittstelle Daten zwischen dem Digitalen Zwilling und dem CAD-/CAM-System ausgetauscht sowie Daten für die Post-Prozess-Qualitätssicherung bereitgestellt werden. Die Applikation konnte per Fernzugriff aktualisiert werden.

A.2 Sensoren der Prozessüberwachung

In Tabelle A.1 sind die ausgewählten Sensoren der Prozessüberwachung (Abschnitt 4.1) zu finden. Sie wurden unter anderem zur datenbasierten Abbildung des Referenzprozesses genutzt. Während sich die Schweißkamera, das Spektrometer und das Mikrofon unmittelbar mit dem Edge-Gerät verbinden ließen, waren für den Strom- und Spannungssensor, den Gasflusssensor, den Drahtvorschubsensor sowie den Strukturakustiksensoren Analog-Digital-Wandler beziehungsweise Encoder erforderlich.

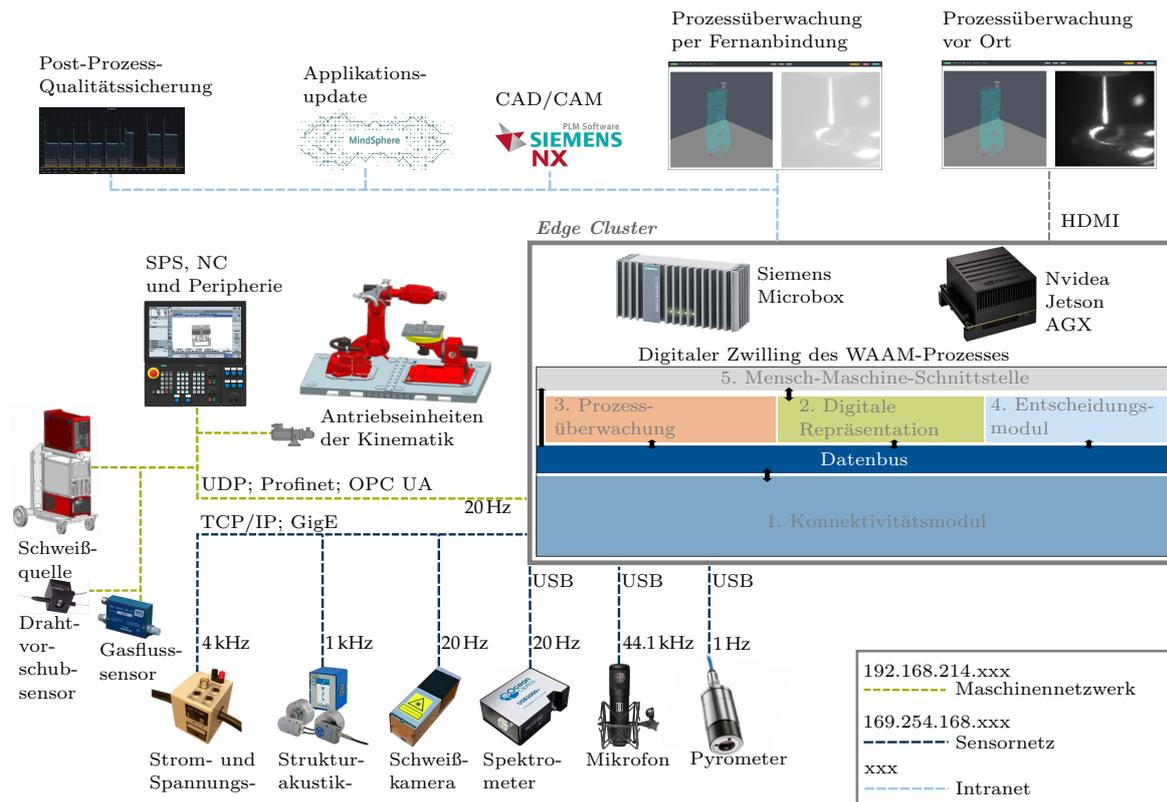


Abbildung A.1: Systemarchitektur des Cyber-Physischen-Systems inklusive Anbindung des Digitalen Zwillings an andere Komponenten über das Maschinennetz, das Sensornetz und das Intranet

Tabelle A.1: Sensoren der Prozessüberwachung

Sensortyp	Modell	Abtast-rate f_s	Messbereich	Messgenauigkeit	Messauflösung
Stromsensor [271, 272]	HKS P1000-S3	4 kHz	± 1000 A	10 A	14 bit
Spannungssensor [271, 272]	HKS P1000-S3	4 kHz	± 100 V	1 V	14 bit
Gasdurchflusssensor [271, 273]	HKS GM 30L 10B-S3	20 Hz	0 - 25 L min ⁻¹	1.3 L min ⁻¹	15 bit
Drahtvorschubsensor [271, 274]	HKS DV25ST-S3	20 Hz	0 - 25 m min ⁻¹	0.3 m min ⁻¹	8 bit
Spektrometer [275]	OceanOptics USB2000+	20 Hz	187.3 - 1037.2 nm	75 Zähler	0.1 nm; 16 bit
Schweißkamera [276]	Cavitar C300	20 Hz	640 nm	± 10 nm	1440x1080; 8 bit
Mikrofon [277]	Presonus PRM1	44 kHz	0 - 20 kHz; 26 - 132 dB	-37 dB Pa ⁻¹	16 bit
Strukturakustik-sensor [278, 272]	Dittel AE6000	1 kHz	0 - 10 V	500 Hz	14 bit

A.3 Ansichten der Benutzeroberfläche

Nachfolgend werden als Zusatz zur Abbildung 6.4 weitere Ansichten der Benutzeroberfläche der Mensch-Maschine-Schnittstelle des Digitalen Zwillings (Systemarchitektur in Abbildung 6.3) vorgestellt. Sie visualisieren prozessparallel die Sensordaten (Abbildung A.2), die Ergebnisse der prozessparallelen Anomalieerkennung (Abbildung A.3) und der Defektklassifikation (Abbildung A.4), das Druckauftragsmanagement (Abbildung A.5) und den aktuellen Systemzustand (Abbildung A.6).



Abbildung A.2: Ansicht der Benutzeroberfläche zur Darstellung der Sensordaten. Es sind die gemittelten Strom- und Spannungsdaten für einen mehrlagigen Druck zu sehen. Über die Nutzung von Tabs können verschiedene Sensoren angewählt werden. Im oberen Bereich der Ansicht sind Elemente des Systemkontexts, die aktuelle Position des TCPs sowie Schaltknöpfe zum Wechseln der Ansicht dargestellt.

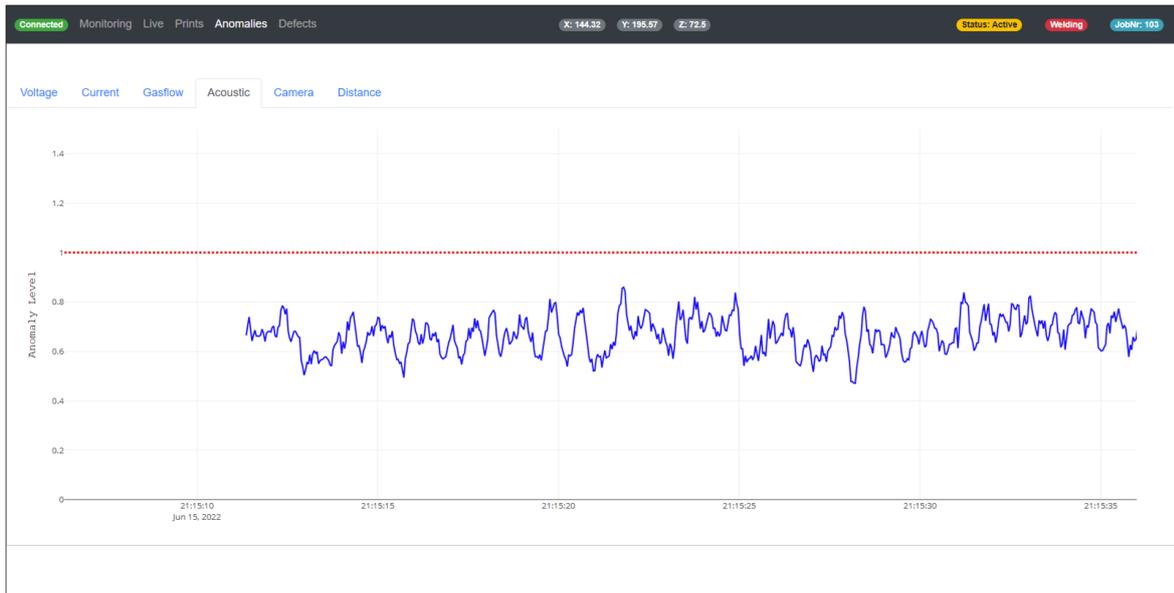


Abbildung A.3: Ansicht der Benutzeroberfläche zur Darstellung der Ergebnisse der prozessparallelen Anomalieerkennung aus Abschnitt 4.2. Es sind die Anomaliewerte des Autoencoders für die Strukturakustikdaten dargestellt. Die rote Linie stellt den Grenzwert dar, ab welchem im Prozess eine Anomalie detektiert wird. Über die Nutzung von Tabs können die Anomaliewerte der verschiedenen Sensoren und Detektoren sowie die Mahalanobisdistanz ausgewählt werden. Im oberen Bereich der Ansicht sind Elemente des Systemkontexts, die aktuelle Position des TCPs sowie Schaltknöpfe zum Wechseln der Ansicht dargestellt.

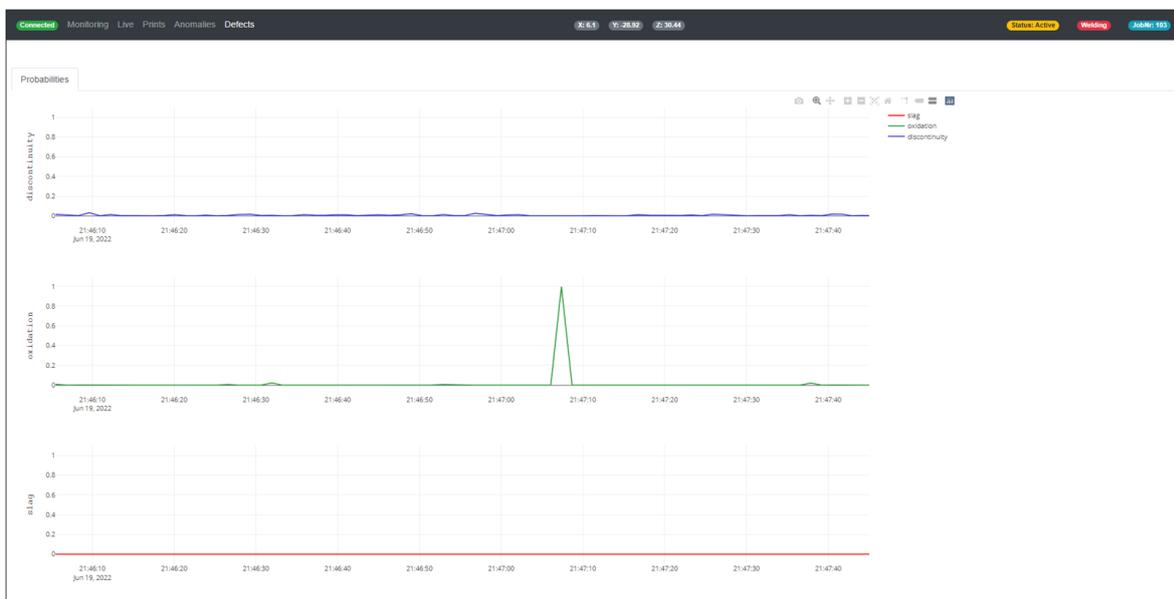


Abbildung A.4: Ansicht der Benutzeroberfläche zur Darstellung der Ergebnisse der prozessparallelen Defektklassifikation aus Abschnitt 4.3. Es sind die Defektwahrscheinlichkeiten für Oxidation, Schlacke und Unstetigkeiten zu sehen. Im oberen Bereich der Ansicht sind Elemente des Systemkontexts, die aktuelle Position des TCPs sowie Schaltknöpfe zum Wechseln der Ansicht dargestellt.

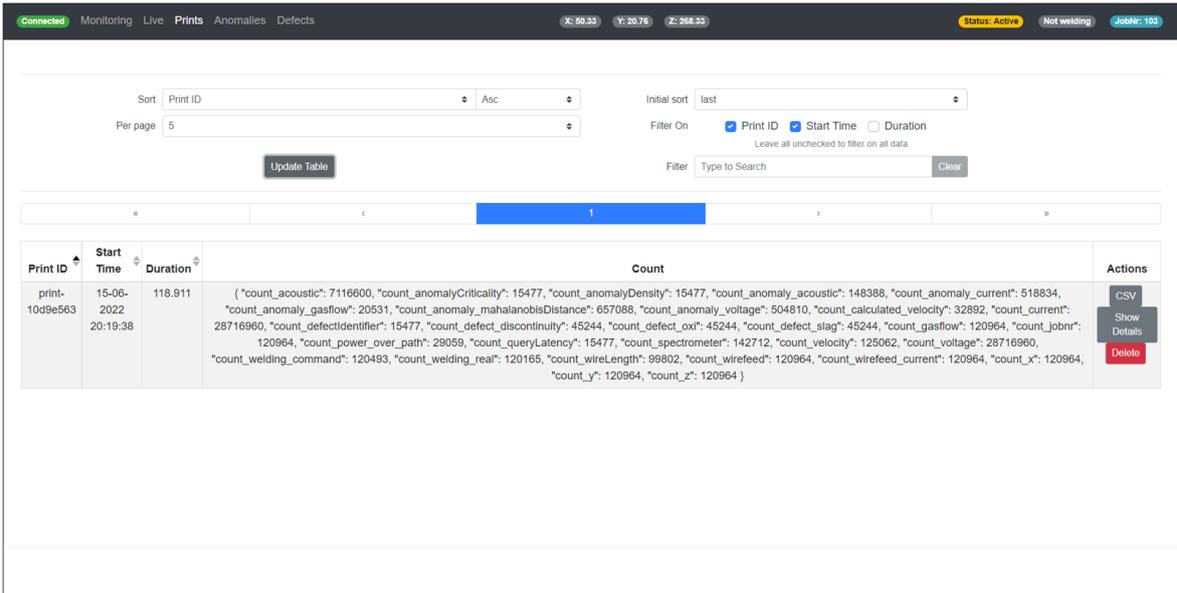


Abbildung A.5: Ansicht der Benutzeroberfläche zur Darstellung des Druckauftragsmanagements als Teil der Datenverwaltung im Modul für die digitale Repräsentation in Abbildung 6.3. Es sind verschiedene Konfigurationmöglichkeiten vorgesehen, mit denen nach einem abgeschlossenen Druckauftrag gesucht werden kann. Für jeden Druckauftrag sind die Druckauftragsidentifikationsnummer, der Startzeitpunkt, die Dauer und die Anzahl an aufgezeichneten Datenpunkten je Prozessdatenstrom zu sehen. Hier handelt es sich beispielsweise um einen zweistündigen Druckauftrag, bei dem knapp 30 Millionen Spannungswerte aufgezeichnet wurden. Es sind Aktionsknöpfe implementiert, mithilfe derer eine .csv-Datei heruntergeladen, der Druckauftrag gelöscht und Druckjobdetails gezeigt oder verborgen werden können. Im oberen Bereich der Ansicht sind Elemente des Systemkontexts, die aktuelle Position des TCPs sowie Schaltknöpfe zum Wechseln der Ansicht dargestellt.

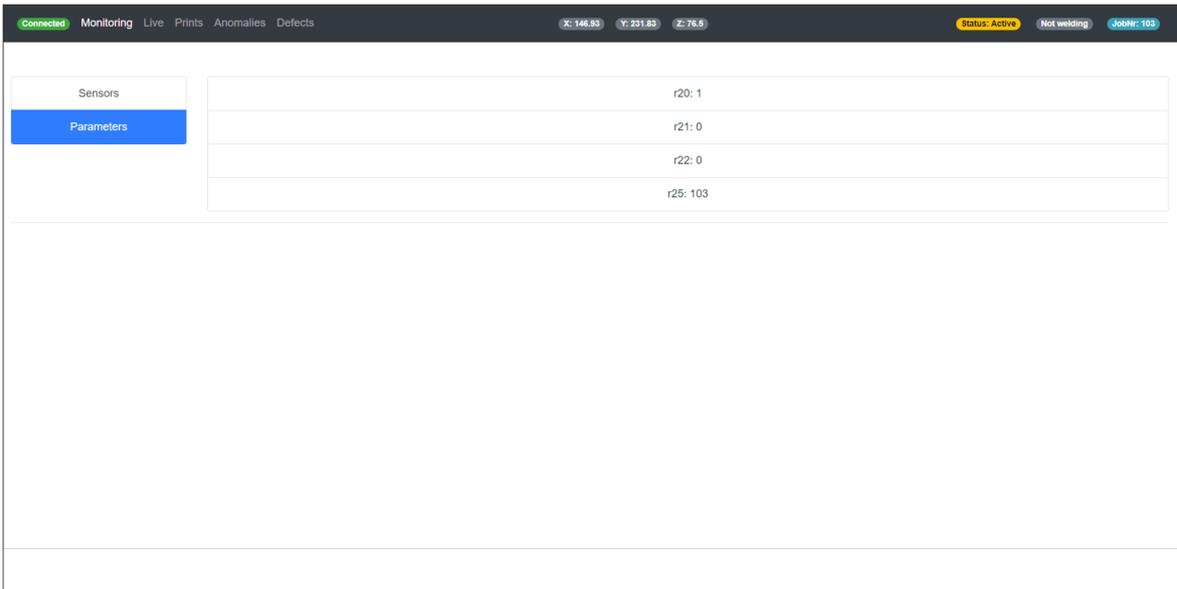


Abbildung A.6: Ansicht der Benutzeroberfläche zur Darstellung des Systemzustands aus Kapitel 3. Es sind die R-Parameter des Maschinencodes in Algorithmus 1 zu sehen. Im oberen Bereich der Ansicht sind Elemente des Systemkontexts, die aktuelle Position des TCPs sowie Schaltknöpfe zum Wechseln der Ansicht dargestellt.

A.4 Kommerzielle, prozessorientierte Digitalisierungslösungen

Der WAAM-Prozess und Abwandlungen dieses Prozesses finden zunehmend Verbreitung im industriellen Fertigungsbereich. Es gibt zahlreiche Start-Ups und Unternehmen, die kommerzielle Fertigungssysteme auf Basis dieser Technologie entwickeln und anbieten. Dazu zählen unter anderem Gefertec [279], Norsk Titanium [280], SBI International [281], AML3D [282], Lincoln Electric [283], Yamazaki Mazak [284], VLM Robotics [285] und Addilan [285]. Einige Unternehmen haben einen besonderen Fokus auf die Digitalisierung des Prozesses gelegt, weshalb sie nachfolgend separat betrachtet werden:

- **WAAM3D** (Milton, Großbritannien):
WAAM3D ist ein Unternehmen, welches aus einer Forschungsgruppe an der Cranfield Universität hervorgegangen ist und roboterbasierte WAAM-Zellen anbietet. 2022 wurde die prozessorientierte Digitalisierungslösung WAAMCtrl veröffentlicht. Sie umfasst Funktionalitäten zur Aufnahme von diversen Prozessdaten, für audio-visuelle Alarmer, für 3D-Visualisierungen, für Eventlogging sowie zur Anpassung der Drahtposition bei WIG-Prozessen. Darüber hinaus werden Softwarelösungen für die Prozessplanung und -simulation angeboten. [99]
- **RAMLAB** (Rotterdam, Niederlande):
RAMLAB ist ein Unternehmen mit 12 Angestellten (Stand September 2022), welches roboterbasierte WAAM-Komplettlösungen anbietet. Die Digitalisierungslösung zur Prozessüberwachung umfasst umfangreichen Anomaliedetektionsfunktionalitäten sowie Module zur Überwachung der Schmelzbadgröße (einlagig, einspurig, monodirektional), zur Sensordatenaufnahme, zur Geometrieüberwachung und -anpassung durch Anpassung des Maschinencodes sowie zur Temperaturregelung. [100]
- **MX3D** (Amsterdam, Niederlande):
MX3D ist ein Unternehmen, welches roboterbasierte WAAM-Zellen anbietet. Die bereitgestellte Digitalisierungslösung umfasst ein Modul zur schichtbasierten CAM-Planung sowie ein Modul zur Aufnahme von Sensordaten und zur 3D-Visualisierung dieser Daten. [101]

Anhang B

Zusatzinformationen zu Prozessdefekten

In diesem Kapitel des Anhang wird der Fokus auf Defekte des WAAM-Prozesses gelegt. Es werden Fotos der möglichen Defekte gezeigt, die beobachteten Zusammenhänge zwischen Defekten und Folgedefekten vorgestellt und die Datensätze, welche für die Defektklassifikation aus Abschnitt 4.3 genutzt wurden, vorgestellt.

B.1 Fotos der WAAM-Defekte

In Abbildung B.1 sind Fotos der WAAM-Defekte dargestellt, welche in Kapitel 2.1 genannt und beschrieben wurden. Einige Bilder zeigen kombinierte Defekte. Beispielsweise sind in a) Oxidation und Schlacke, in c) Porosität und Formabweichungen und in d) Humping-Effekte, eine Unstetigkeit und Oxidation zu sehen.



Abbildung B.1: Fotos von Defekten beim WAAM-Prozess für Aluminiumlegierungen: a) Oxidation und Schlackeeinschlüsse, b) Bindefehler, c) Porosität und Formabweichung [P5], d) Humping-Effekt, Unstetigkeit und Oxidation [P8], e) Verzug, f) Riss und g) Durchschweißung

Besonders Oxidations-, Schlacke- und Unstetigkeitsdefekte konnten in Teststrukturen auf Basis

der im Ishikawa-Diagramm aus Abbildung 4.2 genannten Ursachen reproduzierbar erzeugt werden.

B.2 Defekte und Folgedefekte

Wie in Abbildung B.1 a), c) und d) gezeigt, begünstigen bestimmte Defekte Folgedefekte. In Tabelle B.1 sind beobachtete Zusammenhänge zwischen Defekten und Folgedefekten beim WAAM-Prozess mit Aluminiumlegierungen festgehalten. Aus den beobachteten Zusammenhängen ist keine unmittelbare Kausalität zwischen Defekt und Folgedefekt abzuleiten. Dafür sind weitere Untersuchungen erforderlich. Die Beobachtungen können jedoch als Ausgangsbasis für zukünftige Untersuchungen beispielsweise zur Defektgruppenausdehnung und zur präskriptiven Prozessparameteranpassung dienen.

Tabelle B.1: Beobachtete Folgedefekte, die beim Schweißen über einen vorhandenen Defekt entstehen

	Beobachtete Folgedefekte									
	01	02	03	04	05	06	07	08	09	10
Defekt										
01: Porosität	×									
02: Risse										
03: Schlackeeinschlüsse					×					
04: Oxidation			×		×					×
05: Bindefehler	×					×		×	×	
06: Verzug	×	×		×	×					
07: Humping-Effekt	×			×	×		×		×	×
08: Seitenkollaps	×			×	×				×	
09: Formabweichungen	×			×	×				×	
10: Unstetigkeit				×	×				×	×

B.3 Datensätze für die Defektklassifikation

In Tabelle B.2 sind die Charakteristika der Datensätze festgehalten, welche für die Defektklassifikation in Kapitel 4.3 genutzt wurden. Neben der Nummer des Datensatzes wird der verwendete Prozessparametersatz, das Material (1: S Al 4043 [AlSi5 - Werkstoffnummer 3.2245]; 2: EN AW-6060 [Al MgSi - Werkstoffnummer 3.3206]) und die gesamte Anzahl an Datenpunkten angegeben. Darüber hinaus werden je Defekt die Anzahl der betroffenen Datenpunkte und der daraus resultierende Anteil am gesamten Datensatz festgehalten.

Beim Training sowie bei der Modellevaluierung zur Klassifikation von Oxidationsdefekten wurden die Datensätze 5, 9, 10 und 11 für die Validierung und die Datensätze 1 und 17 zum Testen der Anpassbarkeit genutzt.

Das Training des Modells zur Klassifikation von Schlackedefekten nutzt die Datensätze 5, 9, 10 und 11 für die Validierung. Die Modellevaluierung durch Testen der Anpassbarkeit geschieht mithilfe der Datensätze 1 und 17.

Beim Training sowie bei der Modellevaluierung zur Klassifikation von Defekten, die auf Unstetigkeit zurückgehen, wurden die Datensätze 3, 10, 11 und 14 für die Validierung und die

Datensätze 1 und 4 zum Testen der Anpassbarkeit genutzt.

Alle je Defekt nicht explizit genannten Datensätze wurden als reguläre Trainingsaufgabendatensätze verwendet.

Tabelle B.2: Charakteristika der 17 Datensätze, welche für die Defektklassifikation in Kapitel 4.3 genutzt wurden, inklusive der verwendeten Prozessparametersätze, des Materials (1: S Al 4043 [AlSi5 - Werkstoffnummer 3.2245]; 2: EN AW-6060 [Al MgSi - Werkstoffnummer 3.3206]), der Gesamtanzahl an Datenpunkten sowie der Informationen zum Anteil der von den Defekten betroffenen Datenpunkten

Daten-Prozess- satz	para- meter- satz	Material	Anzahl Daten- punkte	Oxi- dation (An- zahl)	Oxi- dation (%)	Schlacke (An- zahl)	Schlacke (%)	Unste- tigkeit (An- zahl)	Unste- tigkeit (%)
1	1	1	2907820	48156	1.7	42376	1.5	48466	1.7
2	1	1	2906630	52492	1.8	39229	1.3	72631	2.5
3	2	1	2916569	53930	1.8	23614	0.8	25328	0.9
4	3	1	3611513	144421	4.0	149485	4.1	0	0
5	4	2	12630819	0	0	0	0	10063	0.1
6	5	2	1160400	55889	4.8	111842	9.6	0	0
7	6	2	1378288	0	0	0	0	0	0
8	3	1	4843176	0	0	0	0	0	0
9	7	2	5715337	143851	2.5	148895	2.6	0	0
10	8	1	3004605	288801	9.6	289251	9.6	0	0
11	8	1	2617912	0	0	0	0	0	0
12	8	1	4357076	0	0	0	0	0	0
13	9	2	4022971	340509	8.5	0	0	0	0
14	10	2	4216321	0	0	0	0	111004	2.6
15	10	2	4721617	0	0	0	0	41097	0.9
16	1	1	2110606	0	0	0	0	17858	0.8
17	10	2	4389525	0	0	0	0	41097	0.9

Anhang C

Zusatzinformationen zur Anomaliedetektion

Nachfolgend sind Zusatzinformationen für die Anomaliedetektion aus Abschnitt 4.2 festgehalten. Zunächst werden die für die Anomaliedetektion verwendeten WAAM-Datensätze vorgestellt. Es folgt eine Auflistung der Catch22-Zeitreihenmerkmale. Nachfolgend werden die Hyperparameter der Detektoren sowie der Klassifikationsmodelle im Rahmen der Detektorauswahl aus Abschnitt 4.2.1 sowie die Ergebnisse der Hyperparameteroptimierung für den Autoencoder aus Abschnitt 4.2.2 vorgestellt.

C.1 Datensätze für die Anomaliedetektion

Für das Training, die Validierung und die Tests wurden in Abschnitt 4.2 fünfzehn annotierte Spannungsdatensätze genutzt, deren Charakteristika in Tabelle C.1 festgehalten sind.

Tabelle C.1: Charakteristika der 15 Datensätze, welche für die Anomaliedetektion in Abschnitt 4.2 verwendet wurden, inklusive der verwendeten Prozessparametersätze, der Materialien (1: S Al 4043 [AlSi5 - Werkstoffnummer 3.2245]; 2: EN AW-6060 [Al MgSi - Werkstoffnummer 3.3206], 3: SG X2 CrNi 19 9 [CrNi 19 9 - Werkstoffnummer 1.4316]), der Gesamtanzahl der Datenpunkte sowie des Anomalieanteils

Datensatz	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15
Anzahl Datenpunkte in Tsd.	32	72	32	32	32	56	48	50	36	18	45	18	25	18	32
Anomalieanteil in Prozent	32	16	10	24	14	19	11	12	22	23	12	11	25	2	3
Prozessparametersatz	1	1	1	1	1	1	1	2	3	1	4	5	6	7	8
Material	1	1	1	1	1	1	1	1	1	1	2	2	2	2	3

Sie entstammen acht Versuchen und beinhalten sowohl forcierte als auch natürliche Defekte. Es wurden acht Prozessparametersätze und drei Legierungen (1: S Al 4043 [AlSi5 - Werkstoffnummer 3.2245]; 2: EN AW-6060 [Al MgSi - Werkstoffnummer 3.3206], 3: SG X2 CrNi 19 9 [CrNi 19 9 - Werkstoffnummer 1.4316]) eingesetzt.

Darüber hinaus wurden folgende, öffentlich verfügbare Datensätze verwendet:

- *Numenta Anomaly Benchmarks* [236]: Der Benchmark umfasst 47 univariaten Zeitserien mit annotierten Anomalien. Die Daten stammen aus Bereichen wie der Verkehrsüber-

wachung in Minnesota und der Aufzeichnung von Nennungen spezifischer Begriffe auf Twitter.

- *Yahoo Benchmark Dataset for Time Series Anomaly Detektion* [254]: Der Benchmark umfasst etwa 350 univariaten Zeitserien mit annotierten Anomalien, welche in vier Gruppen eingeteilt sind. Es werden einerseits künstlich erzeugte Datensätze und andererseits reale Daten aus dem Yahoo Netzwerkverkehr bereitgestellt.
- *Kaggle Labeled Anomaly Detection TS Benchmarks* [255]: Der Benchmark umfasst vier univariate Zeitreihen mit annotierten Anomalien aus dem Bereich Netzwerkkommunikation und Computertechnik.

C.2 Catch22 - Merkmale

In Tabelle C.2 sind die Catch22-Merkmale nach Lubba et al. [165] mit der in Abschnitt 4.2.1 verwendeten Nummerierung festgehalten. Für weitere Details wird auf die Veröffentlichung [165] verwiesen.

Tabelle C.2: Catch22 Zeitreihenmerkmale nach Lubba et al. [165] mit der in Abschnitt 4.2.1 verwendeten Nummerierung

Nr.	Merkmalsname
1	DN-HistogramMode-5
2	DN-HistogramMode-10
3	CO-flecac
4	CO-FirstMin-ac
5	CO-HistogramAMI-even-2-5
6	CO-trev-1-num
7	MD-hrv-classic-pnn40
8	SB-BinaryStats-mean-longstretch0
9	SB-TransitionMatrix-3ac-sumdiagcov
10	PD-PeriodicityWang-th0-01
11	CO-Embed2-Dist-tau-d-expfit-meandiff
12	IN-AutoMutualInfoStats-40-gaussian-fmfi
13	FC-LocalSimple-mean1-tauresrat
14	DN-OutlierInclude-p-001-mdrmd
15	DN-OutlierInclude-n-001-mdrmd
16	SP-Summaries-welch-rect-area-5-1
17	SB-BinaryStats-diff-longstretch0
18	SB-MotifThree-quantile-hh
19	SC-FluctAnal-2-rsrange-fit-50-1-logi-prop-r1
20	SC-FluctAnal-2-dfa-50-1-2-logi-prop-r1
21	SP-Summaries-welch-rect-centroid
22	FC-LocalSimple-mean3-stderr

C.3 Hyperparameter für die Detektorauswahl

Nachfolgend sind die Hyperparameter und Architekturen der Anomaliedetektoren aus Abschnitt 4.2.1 festgehalten. Alle nicht angegebenen Parameter entsprechen den Standardwerten der Python-Bibliotheken scikit-learn (Version 0.18.1) [286], tensorflow (Version 2.6.0) [287] und statsmodels (Version 0.12.2) [288]. Die Anomaliedetektoren wurden gemäß ihrer Kategorie in rekonstruktionsbasierte, vorhersagebasierte und wahrscheinlichkeits- und distanzbasierte Methoden eingeteilt.

Die rekonstruktionsbasierten Anomaliedetektoren umfassen die in Tabelle C.3 vorgestellten Modelle:

- MLP-Autoencoder
- CNN-Autoencoder
- LSTM-Autoencoder

Tabelle C.3: Rekonstruktionsbasierte Anomaliedetektoren aus Abschnitt 4.2.1 und ihre Hyperparameter

Detektor	Hyperparameter	Wert
MLP-AE	Architektur	Dense(64,ReLU)-Dense(32,ReLU)-Dense(16,ReLU)- Dense(16,ReLU)-Dense(32,ReLU)-Dense(64,ReLU)
	Fehlerfunktion	MSE
	Optimierer	Adam
	Batchgröße	128
	Epochen	20
CNN-AE	Architektur	Conv1D(64,3,ReLU)-MaxPooling(2)-Batchnorm.- Dropout(0.2)-Conv1D(32,3,ReLU)-MaxPooling(2)- Batchnorm.-Dropout(0.2)-Dense(16,ReLU)- Dense(16,ReLU)-Conv1D(32,3,ReLU)- Upsampling(2)-Batchnorm.-Dropout(0.2)- Conv1D(64,3,ReLU)-Upsampling(2)-Batchnorm.- Dropout(0.2)
	Fehlerfunktion	MSE
	Optimierer	Adam
	Batchgröße	128
	Epochen	20
LSTM-AE	Architektur	Dense(64,ReLU)-Dense(32,ReLU)-LSTM(32)- Dense(16,ReLU)-Dense(16,ReLU)-LSTM(32)- Dense(32,ReLU)-Dense(64,ReLU)
	Fehlerfunktion	MSE
	Optimierer	Adam
	Batchgröße	128
	Epochen	20

Bei den wahrscheinlichkeits- und distanzbasierten Anomaliedetektoren handelt es sich um die in Tabelle C.4 vorgestellten Modelle:

- K-means
- DBSCAN
- LOF
- Isolation Forest
- OC-SVM

Tabelle C.4: Wahrscheinlichkeits- und distanzbasierte Anomaliedetektoren aus Abschnitt 4.2.1 und ihre Hyperparameter

Detektor	Hyperparameter	Wert
K-means	$k_{K-Means}$	4
DBSCAN	ϵ	0.9
	μ	16
	Distanzfunktion	Euklidische Distanz
LOF	k	5
	Distanzfunktion	Minkowskidistanz
Isolation Forest	Anzahl an Schätzern	20
OC-SVM	Ordnung	5

Die vorhersagebasierten Anomaliedetektoren umfassen die in Tabelle C.5 vorgestellten Modelle:

- AR
- MA
- ARIMA
- SARIMA
- SES
- ES
- LSTM
- CNN
- MLP

Tabelle C.5: Vorhersagebasierte Anomaliedetektoren aus Abschnitt 4.2.1 mit ihren Hyperparametern

Detektor	Hyperparameter	Wert
MA	q_{MA}	2
AR	p_{AR}	5
ARIMA	q_{MA}	2
	p_{AR}	0
	d_{ARIMA}	1
SARIMA	q_{MA}	2
	p_{AR}	0
	d_{ARIMA}	1
	s	14
SES	/	/
ES	/	/
LSTM	Architektur	LSTM(4,stateful)-LSTM(4,stateful)-Dense(1)
	Fehlerfunktion	MSE
	Optimierer	Adam
	Batchgröße	32
	Epochen	50
MLP	Architektur	Dense(64,ReLU)-Dropout(0.2)-Dense(32,ReLU)-Dropout(0.2)-Dense(16,ReLU)-Flatten-Dense(1, linear)
	Fehlerfunktion	MSE
	Optimierer	Adam
	Batchgröße	32
	Epochen	50
CNN	Architektur	Conv1D(64,3,ReLU)-MaxPooling(2)-Batchnorm.-Dropout(0.2)-Conv1D(32,3,ReLU)-MaxPooling(2)-Batchnorm.-Dropout(0.2)-Dense(16, ReLU)-Flatten-Dense(1, linear)
	Fehlerfunktion	MSE
	Optimierer	Adam
	Batchgröße	32
	Epochen	50

Die Hyperparameter der Klassifikationsmodelle (Random Forest, SVM, MLP) für die Detektorauswahl aus Abschnitt 4.2.1 sind in Tabelle C.6 hinterlegt.

Tabelle C.6: Hyperparameter der drei Klassifikationsmodelle zur Detektorauswahl aus Abschnitt 4.2.1

Klassifikationsmodell	Hyperparameter	Wert
Random Forest	Anzahl an Schätzern	100
	Maximale Tiefe	10
SVM	Kernelfunktion	sigmoid
	Ordnung	30
	C	2
MLP	Größe der versteckten Lagen	(40,10)
	Aktivierungsfunktion	tanh
	Batchgröße	16
	Optimierer	Adam
	α	0.2
	Lernrate	adaptiv
	Maximale Anzahl an Iterationen	500

C.4 Hyperparameteroptimierung des Autoencoders

Die Ergebnisse der Hyperparameteroptimierung für den AE aus Abschnitt 4.2.2 mit dem Lösungsraum aus Tabelle 4.2 sind in Abbildung C.1 als Parallelkoordinaten dargestellt. Die Hyperparameteroptimierung wurde unter Nutzung der Python-Bibliothek *optuna* vorgenommen [249].

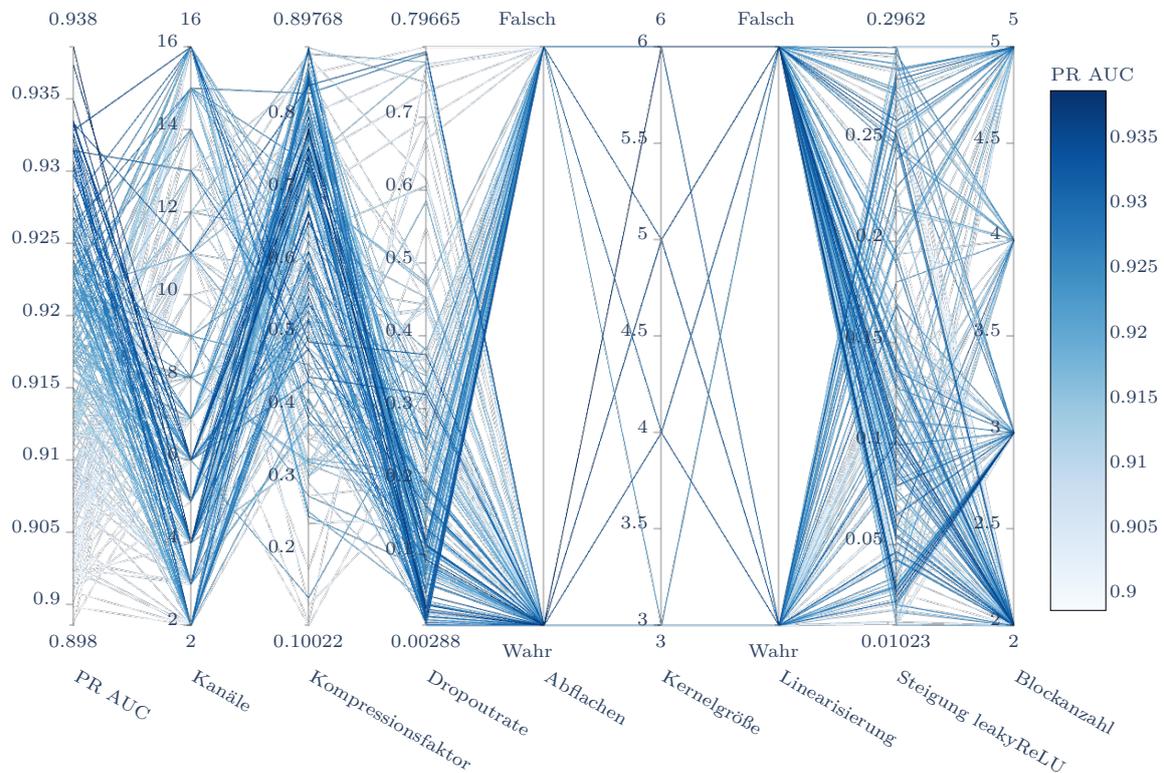


Abbildung C.1: Parallelkoordinaten für die Hyperparameteroptimierung des AEs aus Abschnitt 4.2.2 mit dem Lösungsraum aus Tabelle 4.2

Es war eine Tendenz zu einem hohen Kompressionsfaktor sowie einer geringen Dropout rate zu sehen. Für die restlichen Hyperparameter ist keine eindeutige Ausprägung erkennbar. Dies deckt sich mit der mittels *optuna* [249] vorgenommenen Analyse der Relevanz der Hyperparameter zum Erreichen eines hohen PR AUC-Werts.

Literatur

- [1] Y. Lu, C. Liu, K. I.-K. Wang, H. Huang und X. Xu. „Digital Twin-driven smart manufacturing: Connotation, reference model, applications and research issues“. In: *Robotics and Computer-Integrated Manufacturing* 61 (2020), S. 1018–1037. ISSN: 07365845. DOI: 10.1016/j.rcim.2019.101837.
- [2] M. Dias, J. P. M. Pragana, B. Ferreira, I. Ribeiro und C. M. A. Silva. „Economic and Environmental Potential of Wire-Arc Additive Manufacturing“. In: *Sustainability* 14.9 (2022). DOI: 10.3390/su14095197.
- [3] C. R. Cunningham, S. Wikshåland, F. Xu, N. Kemakolam, A. Shokrani, V. Dhokia und S. T. Newman. „Cost Modelling and Sensitivity Analysis of Wire and Arc Additive Manufacturing“. In: *Procedia Manufacturing* 11 (2017), S. 650–657. DOI: 10.1016/j.promfg.2017.07.163.
- [4] F. Martina und S. Williams. *Wire+arc additive manufacturing vs. traditional machining from solid: a cost comparison*. 2015.
- [5] D. Ding, Z.-X. Pan, C. Dominic und H.-J. Li. „Process Planning Strategy for Wire and Arc Additive Manufacturing“. In: *Robotic Welding, Intelligence and Automation* 363 (2015), S. 437–450. DOI: 10.1007/978-3-319-18997-0-37.
- [6] T. A. Rodrigues, V. Duarte, R. M. Miranda, T. G. Santos und J. P. Oliveira. „Current Status and Perspectives on Wire and Arc Additive Manufacturing (WAAM)“. In: *Materials (Basel, Switzerland)* 12.7 (2019). ISSN: 1996-1944. DOI: 10.3390/ma12071121.
- [7] Gefertec GmbH. *WAAM-Verfahren in Siemens-NX-Software integriert*. 2021. URL: <https://www.gefertec.de/news-2/> (besucht am 04. 10. 2021).
- [8] Mesago Messe Frankfurt GmbH, Hrsg. *formnext magazine*. 1–2021.
- [9] ISO/ASTM. *ISO/ASTM 52900:2015(E): Standard Terminology for Additive Manufacturing – General Principles – Terminology*. 1.12.2015.
- [10] T. T. WOHLERS. *Wohlers Report: 3d printing and additive manufacturing state of the industry*. Fort Collins: WOHLERS Associates, 2020. ISBN: 978-0-9913332-6-4.
- [11] M. Kumke. *Methodisches Konstruieren von additiv gefertigten Bauteilen*. Wiesbaden: Springer Fachmedien Wiesbaden, 2018. DOI: 10.1007/978-3-658-22209-3.
- [12] R. Baker. „Method of Making Decorative Articles“. Pat. 1,533,300. 1925.
- [13] F. Li, S. Chen, J. Shi, H. Tian und Y. Zhao. „Evaluation and Optimization of a Hybrid Manufacturing Process Combining Wire Arc Additive Manufacturing with Milling for the Fabrication of Stiffened Panels“. In: *Applied Sciences* 7.12 (2017), S. 1233. DOI: 10.3390/app7121233.
- [14] D. Ding, Z. Pan, D. Cuiuri und H. Li. „Wire-feed additive manufacturing of metal components: technologies, developments and future interests“. In: *Journal of Advanced Manufacturing Technology* 81.1-4 (2015), S. 465–481. DOI: 10.1007/s00170-015-7077--3.

- [15] G. Fischer, J. Kulasa, M. Scafè, P. Caballero und W. de Waele. *3DMPGWIRE: Project goals and objectives*. 2019. URL: <https://www.3dmpwire.com/project-details/goals-and-objectives/> (besucht am 09.10.2019).
- [16] Autorenkollektiv des GSI-Ressorts FuE. *Additive Fertigungsverfahren - Überblick und Erfahrungen in Einrichtungen des DVS (Teil 2)*. Hrsg. von Deutscher Verband für Schweißen und verwandte Verfahren e.V. Düsseldorf, 2020.
- [17] Z. Lin, C. Goulas, W. Ya und M. J. Hermans. „Microstructure and Mechanical Properties of Medium Carbon Steel Deposits Obtained via Wire and Arc Additive Manufacturing Using Metal-Cored Wire“. In: *Metals* 9.6 (2019), S. 673. DOI: 10.3390/met9060673.
- [18] D. Ding, Z. Pan, D. Cuiuri und H. Li. „A multi-bead overlapping model for robotic wire and arc additive manufacturing (WAAM)“. In: *Robotics and Computer-Integrated Manufacturing* (2015). ISSN: 07365845.
- [19] S. Tang, G. Wang und H. Zhang. „In situ 3D monitoring and control of geometric signatures in wire and arc additive manufacturing“. In: *Surface Topography: Metrology and Properties* 7.2 (2019), S. 025013. DOI: 10.1088/2051-672X/ab1c98.
- [20] H.-C. Wu und T.-C. T. Chen. „Quality control issues in 3D-printing manufacturing: a review“. In: *Rapid Prototyping Journal* 24.3 (2018), S. 607–614. ISSN: 1355-2546. DOI: 10.1108/RPJ-02-2017-0031.
- [21] K. Treutler und V. Wesling. „The Current State of Research of Wire Arc Additive Manufacturing (WAAM): A Review“. In: *Applied Sciences* 11.18 (2021), S. 8619. DOI: 10.3390/app11188619.
- [22] M. S. Weglowski, S. Błacha, R. Jachym, J. Dworak und J. Rykała. „Additive manufacturing with wire – Comparison of processes“. In: *Proceedings of ESAFORM* (2019). DOI: 10.1063/1.5112692.
- [23] B. Wu, Z. Pan, D. Ding, D. Cuiuri, H. Li, J. Xu und J. Norrish. „A review of the wire arc additive manufacturing of metals: properties, defects and quality improvement“. In: *Journal of Manufacturing Processes* 35 (2018), S. 127–139. ISSN: 15266125. DOI: 10.1016/j.jmapro.2018.08.001.
- [24] U. Dilthey. *Verhalten der Werkstoffe beim Schweißen*. 3., bearb. Aufl. 2005. ISBN: 3-540-21674-X.
- [25] U. Dilthey. *Schweißtechnische Fertigungsverfahren 2: Verhalten der Werkstoffe beim Schweißen*. 3., bearbeitete Aufl. VDI-Buch. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, 2005. ISBN: 978-3-540-27402-5.
- [26] ICS. *ISO/TR 18491:2015-05: Welding and allied processes - Guidelines for measurement of welding energies*. 5.2015.
- [27] S. Selvi, A. Vishvaksean und E. Rajasekar. „Cold metal transfer (CMT) technology - An overview“. In: *Defence Technology* 14.1 (2018), S. 28–44. ISSN: 22149147. DOI: 10.1016/j.dt.2017.08.002.
- [28] J. Feng, H. Zhang und P. He. „The CMT short-circuiting metal transfer process and its use in thin aluminium sheets welding“. In: *Materials & Design* 30.5 (2009), S. 1850–1852. ISSN: 02641275. DOI: 10.1016/j.matdes.2008.07.015.
- [29] B. Cong, J. Ding und S. Williams. „Effect of arc mode in cold metal transfer process on porosity of additively manufactured Al-6.3%Cu alloy“. In: *The International Journal of Advanced Manufacturing Technology* 76.9-12 (2015), S. 1593–1606. ISSN: 0268-3768. DOI: 10.1007/s00170-014-6346-x.

- [30] G. Langelandsvik, O. M. Akselsen, T. Furu und H. J. Roven. „Review of Aluminum Alloy Development for Wire Arc Additive Manufacturing“. In: *Materials (Basel, Switzerland)* 14.18 (2021). ISSN: 1996-1944. DOI: 10.3390/ma14185370.
- [31] S. Pattanayak und S. K. Sahoo. „Gas metal arc welding based additive manufacturing—a review“. In: *CIRP Journal of Manufacturing Science and Technology* 33 (2021), S. 398–442. ISSN: 17555817. DOI: 10.1016/j.cirpj.2021.04.010.
- [32] J. González, I. Rodríguez, J.-L. Prado-Cerqueira, J. L. Diéguez und A. Pereira. „Additive manufacturing with GMAW welding and CMT technology“. In: *Procedia Manufacturing* 13 (2017), S. 840–847. DOI: 10.1016/j.promfg.2017.09.189.
- [33] M. Liberini, A. Astarita, G. Campatelli, A. Scippa, F. Montevecchi, G. Venturini, M. Durante, L. Boccarusso, F. M. C. Minutolo und A. Squillace. „Selection of Optimal Process Parameters for Wire Arc Additive Manufacturing“. In: *Procedia CIRP* 62 (2017), S. 470–474. ISSN: 22128271. DOI: 10.1016/j.procir.2016.06.124.
- [34] A. G. Kamble und R. V. Rao. „Experimental investigation on the effects of process parameters of GMAW and transient thermal analysis of AISI321 steel“. In: *Advances in Manufacturing* 1.4 (2013), S. 362–377. ISSN: 2195-3597. DOI: 10.1007/s40436-013-0041-2.
- [35] N. Ghosh, R. Rudrapati, P. Pal und G. Nandi. „Parametric Optimization of Gas Metal Arc Welding Process by using Taguchi method on Ferritic Stainless Steel AISI409“. In: *Materials Today: Proceedings* 4.2 (2017), S. 2213–2221. ISSN: 22147853. DOI: 10.1016/j.matpr.2017.02.068.
- [36] B. Jaeschke und W. Ernst. „Verringerung von Fehlern bei der werkstoffspezifischen Bestimmung von Streckenenergie und Wärmeeinbringung moderner Lichtbogenschweißprozesse“. In: *Große Schweißtechnische Tagung Fachdokumentation Nr.: Y00.0050.0-00* (2013). URL: <https://www.lorch.eu/downloads-public/fachpublikationen/DE-Fachpublikation-Jaeschke-Luritzhofer-23.02.2014.pdf>.
- [37] A. Hälsig. „Energetische Bilanzierung von Lichtbogenschweißverfahren“. Dissertation. Chemnitz: Technische Universität Chemnitz, 2014.
- [38] B. Wu, Z. Pan, S. van Duin und H. Li. „Thermal Behavior in Wire Arc Additive Manufacturing: Characteristics, Effects and Control“. In: *Transactions on Intelligent Welding Manufacturing* 32 (2019), S. 3–18. DOI: 10.1007/978-981-13-3651-5-1.
- [39] X. Chen, F. Kong, Y. Fu, X. Zhao, R. Li, G. Wang und H. Zhang. „A review on wire-arc additive manufacturing: typical defects, detection approaches, and multisensor data fusion-based model“. In: *The International Journal of Advanced Manufacturing Technology* (2021). ISSN: 0268-3768. DOI: 10.1007/s00170-021-07807-8.
- [40] J. Goldak, A. Chakravarti und M. Bibby. „A new finite element model for welding heat sources“. In: *Metallurgical Transactions B* 15.2 (1984), S. 299–305. ISSN: 0360-2141. DOI: 10.1007/BF02667333.
- [41] N. T. Nguyen, Y.-W. Mai, S. Simpson und A. Ohta. „Analytical Approximate Solution For Double Ellipsoidal Heat Source In Finite Thick Plate“. In: *Welding Journal* (2004).
- [42] C. Pyo, J. Kim und J. Kim. „Estimation of Heat Source Model’s Parameters for GMAW with Non-linear Global Optimization—Part I: Application of Multi-island Genetic Algorithm“. In: *Metals* 10.7 (2020). DOI: 10.3390/met10070885.
- [43] A. S. Azar. „A heat source model for cold metal transfer (CMT) welding“. In: *Journal of Thermal Analysis and Calorimetry* 122.2 (2015), S. 741–746. ISSN: 1388-6150. DOI: 10.1007/s10973-015-4809-4.

- [44] M. Graf, A. Hälsig, K. Höfer, B. Awiszus und P. Mayr. „Thermo-Mechanical Modelling of Wire-Arc Additive Manufacturing (WAAM) of Semi-Finished Products“. In: *Metals* 8.12 (2018), S. 100–109. DOI: 10.3390/met8121009.
- [45] M. Graf, K. P. Pradjadhiana, A. Hälsig, Y. H. P. Manurung und B. Awiszus. „Numerical simulation of metallic wire arc additive manufacturing (WAAM)“. In: *Proceedings of ESAFORM* (2018), S. 1400–1410. DOI: 10.1063/1.5035002.
- [46] K. P. Prajadhiana, Y. H. P. Manurung, Z. Minggu, F. H. S. Pengadau, M. Graf, A. Hälsig, T.-E. Adams und H. L. Choo. „Development of Bead Modelling for Distortion Analysis Induced by Wire Arc Additive Manufacturing using FEM and Experiment“. In: *MATEC Web of Conferences* 269 (2019). DOI: 10.1051/mateconf/201926905003.
- [47] S. Suryakumar, K. P. Karunakaran, A. Bernard, U. Chandrasekhar, N. Raghavender und D. Sharma. „Weld bead modeling and process optimization in Hybrid Layered Manufacturing“. In: *Computer-Aided Design* 43.4 (2011), S. 331–344. ISSN: 00104485. DOI: 10.1016/j.cad.2011.01.006.
- [48] H. Geng, J. Xiong, D. Huang, X. Lin und J. Li. „A prediction model of layer geometrical size in wire and arc additive manufacture using response surface methodology“. In: *The International Journal of Advanced Manufacturing Technology* 93.1-4 (2017), S. 175–186. ISSN: 0268-3768. DOI: 10.1007/s00170-015-8147-2.
- [49] Y. Cao, S. Zhu, X. Liang und W. Wang. „Overlapping model of beads and curve fitting of bead section for rapid manufacturing by robotic MAG welding process“. In: *Robotics and Computer-Integrated Manufacturing* 27.3 (2011), S. 641–645. ISSN: 07365845. DOI: 10.1016/j.rcim.2010.11.002.
- [50] Y. Li, Y. Sun, Q. Han, G. Zhang und I. Horváth. „Enhanced beads overlapping model for wire and arc additive manufacturing of multi-layer multi-bead metallic parts“. In: *Journal of Materials Processing Technology* 252 (2018), S. 838–848. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2017.10.017.
- [51] F. Wang, W. K. Hou, S. J. Hu, E. Kannatey-Asibu, W. W. Schultz und P. C. Wang. „Modelling and analysis of metal transfer in gas metal arc welding“. In: *Journal of Physics D: Applied Physics* 36.9 (2003), S. 1143. DOI: 10.1088/0022-3727/36/9/313.
- [52] Y. M. Zhang und R. Kovacevic. „Neurofuzzy model-based predictive control of weld fusion zone geometry“. In: *IEEE Transactions on Fuzzy Systems* 6.3 (1998), S. 389–401.
- [53] J. Xiong, G. Zhang, J. Hu und L. Wu. „Bead geometry prediction for robotic GMAW-based rapid manufacturing through a neural network and a second-order regression analysis“. In: *Journal of Intelligent Manufacturing* 25.1 (2014), S. 157–163. ISSN: 0956-5515. DOI: 10.1007/s10845-012-0682-1.
- [54] F. Li, S. Chen, Z. Wu und Z. Yan. „Adaptive process control of wire and arc additive manufacturing for fabricating complex-shaped components“. In: *The International Journal of Advanced Manufacturing Technology* 96.1-4 (2018), S. 871–879. ISSN: 0268-3768. DOI: 10.1007/s00170-018-1590-0.
- [55] X. Xiao, C. Waddell, C. Hamilton und H. Xiao. „Quality Prediction and Control in Wire Arc Additive Manufacturing via Novel Machine Learning Framework“. In: *Micromachines* 13.1 (2022). ISSN: 2072-666X. DOI: 10.3390/mi13010137.
- [56] DIN-Normenausschuss Werkstofftechnologie. *Additive Fertigung – Prozessanforderungen und Qualifizierung – Teil 2: Materialauftrag mit gerichteter Energieeinbringung unter Verwendung von Draht und Lichtbogen in der Luft- und Raumfahrt: DIN 17024-2*. Oktober 2020.

- [57] D. Jafari, T. H. Vaneker und I. Gibson. „Wire and arc additive manufacturing: Opportunities and challenges to control the quality and accuracy of manufactured parts“. In: *Materials & Design* 202 (2021), S. 109471. ISSN: 02641275. DOI: 10.1016/j.matdes.2021.109471.
- [58] DIN. *Schweißen – Lichtbogenschweißverbindungen an Aluminium und seinen Legierungen – Bewertungsgruppen von Unregelmäßigkeiten (ISO 10042:2018)*; Berlin, 1.2019.
- [59] C. Wang, X. P. Tan, S. B. Tor und C. S. Lim. „Machine learning in additive manufacturing: State-of-the-art and perspectives“. In: *Additive Manufacturing* 36 (2020), S. 101538. ISSN: 22148604. DOI: 10.1016/j.addma.2020.101538.
- [60] L. J. Da Silva, F. M. Scotti, D. B. Fernandes, R. P. Reis und A. Scotti. „Effect of O₂ content in argon-based shielding gas on arc wandering in WAAM of aluminum thin walls“. In: *CIRP Journal of Manufacturing Science and Technology* 32 (2021), S. 338–345. ISSN: 17555817. DOI: 10.1016/j.cirpj.2021.01.018.
- [61] P. Berger, H. Hügel, A. Hess, R. Weber und T. Graf. „Understanding of Humping Based on Conservation of Volume Flow“. In: *Physics Procedia* 12 (2011), S. 232–240. ISSN: 18753892. DOI: 10.1016/j.phpro.2011.03.030.
- [62] H.-W. Cho, S.-J. Shin, G.-J. Seo, D. B. Kim und D.-H. Lee. „Real-time anomaly detection using convolutional neural network in wire arc additive manufacturing: Molybdenum material“. In: *Journal of Materials Processing Technology* 302 (2022), S. 117495. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2022.117495.
- [63] T. Hauser, R. T. Reisch, T. Kamps, A. F. H. Kaplan und J. Volpp. „Acoustic emissions in directed energy deposition processes“. In: *The International Journal of Advanced Manufacturing Technology* (2022). ISSN: 0268-3768. DOI: 10.1007/s00170-021-08598-8.
- [64] J. Lee, H. J. Park, S. Chai, G. R. Kim, H. Yong, S. J. Bae und D. Kwon. „Review on Quality Control Methods in Metal Additive Manufacturing“. In: *Applied Sciences* 11.4 (2021). DOI: 10.3390/app11041966.
- [65] P. Stavropoulos, A. Papacharalampopoulos, C. K. Michail und G. Chryssolouris. „Robust Additive Manufacturing Performance through a Control Oriented Digital Twin“. In: *Metals* 11.5 (2021), S. 708. DOI: 10.3390/met11050708.
- [66] D. Yang, G. Wang und G. Zhang. „Thermal analysis for single-pass multi-layer GMAW based additive manufacturing using infrared thermography“. In: *Journal of Materials Processing Technology* 244 (2017), S. 215–224. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2017.01.024.
- [67] S. Cadiou, M. Courtois, M. Carin, W. Berckmans und P. Le masson. „3D heat transfer, fluid flow and electromagnetic model for cold metal transfer wire arc additive manufacturing (Cmt-Waam)“. In: *Additive Manufacturing* 36 (2020), S. 101541. ISSN: 22148604. DOI: 10.1016/j.addma.2020.101541.
- [68] Y. Ogino, S. Asai und Y. Hirata. „Numerical simulation of WAAM process by a GMAW weld pool model“. In: *Welding in the World* 62.2 (2018), S. 393–401. ISSN: 0043-2288. DOI: 10.1007/s40194-018-0556-z.
- [69] A. Lopez, R. Bacelar, I. Pires, T. G. Santos, J. P. Sousa und L. Quintino. „Non-destructive testing application of radiography and ultrasound for wire and arc additive manufacturing“. In: *Additive Manufacturing* 21 (2018), S. 298–306. ISSN: 22148604. DOI: 10.1016/j.addma.2018.03.020.
- [70] ICS. *ISO 19828:2017-04: Welding for aerospace applications - Visual inspection of welds*. April 2017.

- [71] Z. Al-Nabulsi, J. T. Mottram, M. Gillie, N. Kourra und M. A. Williams. „Mechanical and X ray computed tomography characterisation of a WAAM 3D printed steel plate for structural engineering applications“. In: *Construction and Building Materials* 274 (2021), S. 121700. ISSN: 09500618. DOI: 10.1016/j.conbuildmat.2020.121700.
- [72] F. Xu, V. Dhokia, P. Colegrove, A. McAndrew, S. Williams, A. Henstridge und S. T. Newman. „Realisation of a multi-sensor framework for process monitoring of the wire arc additive manufacturing in producing Ti-6Al-4V parts“. In: *International Journal of Computer Integrated Manufacturing* 31.8 (2018), S. 785–798. ISSN: 0951-192X. DOI: 10.1080/0951192X.2018.1466395.
- [73] M. S. Weglowski. „Monitoring of Arc Welding Process Based on Arc Light Emission“. In: *Welding Processes* (2012). DOI: 10.5772/49987.
- [74] Z. Zhang, X. Chen, H. Chen, J. Zhong und S. Chen. „Online welding quality monitoring based on feature extraction of arc voltage signal“. In: *The International Journal of Advanced Manufacturing Technology* 70.9-12 (2014), S. 1661–1671. ISSN: 0268-3768. DOI: 10.1007/s00170-013-5402-2.
- [75] B. Zhu und J. Xiong. „Increasing deposition height stability in robotic GTA additive manufacturing based on arc voltage sensing and control“. In: *Robotics and Computer-Integrated Manufacturing* 65 (2020), S. 101977. ISSN: 07365845. DOI: 10.1016/j.rcim.2020.101977.
- [76] U. Reisgen, S. Mann, L. Oster, G. Gott, R. Sharma und D. Uhrlandt. „Study on identifying GMAW process deviations by means of optical and electrical process data using ANN“. In: *IEEE International Conference on Automation Science and Engineering (CASE)* 16th (2020), S. 1596–1601. DOI: 10.1109/CASE48305.2020.9216744.
- [77] A. Mazlan, H. Daniyal, A. I. Mohamed, M. Ishak und A. A. Hadi. „Monitoring the quality of welding based on welding current and ste analysis“. In: *IOP Conference Series: Materials Science and Engineering* 257 (2017), S. 012043. ISSN: 0043-2296. DOI: 10.1088/1757-899X/257/1/012043.
- [78] Y. Huang, X. Wang, D. Yang, L. Wang, J. Gu, X. Zhang und K. Wang. „A Weld Quality Classification Approach Based on Local Mean Decomposition and Deep Belief Network“. In: *Journal of Materials Engineering and Performance* 30.3 (2021), S. 2229–2237. ISSN: 1059-9495. DOI: 10.1007/s11665-021-05495-9.
- [79] M. Purrio. *Prozessanalyse und -überwachung beim Metall-Schutzgasschweißen durch optische In-situ-Sensorsysteme: Process analysis and monitoring in gas metal arc welding by optical in-situ sensor systems*. Aachen, 2017.
- [80] Y. M. Zhang, H. S. Song und G. Saeed. „Observation of a dynamic specular weld pool surface“. In: *Measurement Science and Technology* 17.6 (2006), S. L9–L12. ISSN: 0957-0233. DOI: 10.1088/0957-0233/17/6/L02.
- [81] T. Font comas, C. Diao, J. Ding, S. Williams und Y. Zhao. „A Passive Imaging System for Geometry Measurement for the Plasma Arc Welding Process“. In: *IEEE Transactions on Industrial Electronics* 64.9 (2017), S. 7201–7209. ISSN: 0278-0046. DOI: 10.1109/TIE.2017.2686349.
- [82] J. Xiong und G. Zhang. „Online measurement of bead geometry in GMAW-based additive manufacturing using passive vision“. In: *Measurement Science and Technology* 24.11 (2013), S. 115103. ISSN: 0957-0233. DOI: 10.1088/0957-0233/24/11/115103.

- [83] H. Borovkov, A. G. de La Yedra, X. Zurutuza, X. Angulo, P. Alvarez, J. C. Pereira und F. Cortes. „In-Line Height Measurement Technique for Directed Energy Deposition Processes“. In: *Journal of Manufacturing and Materials Processing* 5.3 (2021), S. 85. DOI: 10.3390/jmmp5030085.
- [84] C. Xia, Z. Pan, Y. Li, J. Chen und H. Li. „Vision-based melt pool monitoring for wire-arc additive manufacturing using deep learning method“. In: *The International Journal of Advanced Manufacturing Technology* (2022). ISSN: 0268-3768. DOI: 10.1007/s00170-022-08811-2.
- [85] A. Wagiman, M. S. Bin Wahab, Z. Mohid und A. Mamat. „Effect of GMAW-CMT Heat Input on Weld Bead Profile Geometry for Freeform Fabrication of Aluminium Parts“. In: *Applied Mechanics and Materials* (2014). DOI: 10.4028/www.scientific.net/AMM.465-466.1370.
- [86] T. K. Renil, P. V. Nithin, K. Balasubramaniam, P. Rajagopal, K. V. Phani Prabhakar, G. Padmanabham, F. Riedel und M. Puschmann. „Online monitoring of Cold Metal Transfer (CMT) process using Infrared Thermography“. In: *Quantitative InfraRed Thermography Asia 2015* (2015). DOI: 10.21611/qirt.2015.0088.
- [87] J. Horvat, J. Prezelj, I. Polajnar und M. Čudina. „Monitoring Gas Metal Arc Welding Process by Using Audible Sound Signal“. In: *Strojniški vestnik – Journal of Mechanical Engineering* 2011.03 (2011), S. 267–278. ISSN: 00392480. DOI: 10.5545/sv-jme.2010.181.
- [88] M. Cudina, J. Prezelj und I. Polajnar. „Use of Audible Sound For On-Line Monitoring of Gas Metal Arc Welding Process“. In: *Metallurgija -Sisak then Zagreb* (2008), S. 81–85.
- [89] B. Chen, S. Chen und J. Feng. „A study of multisensor information fusion in welding process by using fuzzy integral method“. In: *The International Journal of Advanced Manufacturing Technology* 74.1-4 (2014), S. 413–422. ISSN: 0268-3768. DOI: 10.1007/s00170-014-6001-6.
- [90] I. Polajnar, Z. Bergant und J. Grum. „Arc Welding Process Monitoring by Audible Sound“. In: *International Conference on Application of Contemporary Non-Destructive Testing in Engineering* (2013).
- [91] X. Dong, G. Wen, W. Ren, R. Luan, Z. Yang und Z. Zhang. „Frequency Selection for On-line Identification of Welding Penetration through Audible Sound“. In: *IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)* (2018), S. 326–331. DOI: 10.1109/CYBER.2017.8446299.
- [92] M. S. Weglowski und M. Kepinska. „An experimental study on the relationship between welding parameters and the arc light spectrum in TIG welding“. In: *Welding in the World, Le Soudage Dans Le Monde* 51 (2007), S. 291–300.
- [93] Z. Zhao, Y. Guo, L. Bai, K. Wang und J. Han. „Quality monitoring in wire-arc additive manufacturing based on cooperative awareness of spectrum and vision“. In: *Optik* 181 (2019), S. 351–360. ISSN: 00304026. DOI: 10.1016/j.ijleo.2018.12.071.
- [94] T. Okuno. „Spectra of optical radiation from welding arcs“. In: *Industrial health* 23.1 (1985), S. 53–70. ISSN: 0019-8366. DOI: 10.2486/indhealth.23.53.
- [95] C. Zhang, M. Gao, C. Chen und X. Zeng. „Spectral diagnosis of wire arc additive manufacturing of Al alloys“. In: *Additive Manufacturing* 30 (2019), S. 100869. ISSN: 22148604. DOI: 10.1016/j.addma.2019.100869.
- [96] Z. Zhang, L. Zhang und G. Wen. „Study of inner porosity detection for Al-Mg alloy in arc welding through on-line optical spectroscopy: Correlation and feature reduction“. In: *Journal of Manufacturing Processes* 39 (2019), S. 79–92. ISSN: 15266125. DOI: 10.1016/j.jmapro.2019.02.016.

- [97] Z. Zhang, W. Ren, Z. Yang und G. Wen. „Real-time seam defect identification for Al alloys in robotic arc welding using optical spectroscopy and integrating learning“. In: *Measurement* 156 - 107546 (2020). ISSN: 02632241. DOI: 10.1016/j.measurement.2020.107546.
- [98] T. Artaza, A. Alberdi, M. Murua, J. Gorrotxategi, J. Frías, G. Puertas, M. A. Melchor, D. Mugica und A. Suárez. „Design and integration of WAAM technology and in situ monitoring system in a gantry machine“. In: *Procedia Manufacturing* 13 (2017), S. 778–785. DOI: 10.1016/j.promfg.2017.09.184.
- [99] WAAM3D Limited. *WAAMCTRL*. URL: <https://www.waam3d.com/software/waamctrl> (besucht am 12. 08. 2022).
- [100] RAMLAB. *MaxQ*. URL: <https://www.ramlab.com/maxq/> (besucht am 12. 08. 2022).
- [101] MX3D. *MetalXL*. URL: <https://mx3d.com/services/metalxl/> (besucht am 11. 08. 2022).
- [102] Y.-M. Kwak und C. C. Doumanidis. „Geometry Regulation of Material Deposition in Near-Net Shape Manufacturing by Thermally Scanned Welding“. In: *Journal of Manufacturing Processes* 4.1 (2002), S. 28–41. ISSN: 15266125. DOI: 10.1016/S1526-6125(02)70131-X.
- [103] F. Lü, H. Chen, C. Fan und S. Chen. „A novel control algorithm for weld pool control“. In: *Industrial Robot: An International Journal* 37.1 (2010), S. 89–96. ISSN: 0143-991X. DOI: 10.1108/01439911011009993.
- [104] J. Xiong, G. Zhang, Z. Qiu und Y. Li. „Vision-sensing and bead width control of a single-bead multi-layer part: material and energy savings in GMAW-based rapid manufacturing“. In: *Journal of Cleaner Production* 41 (2013), S. 82–88. ISSN: 09596526. DOI: 10.1016/j.jclepro.2012.10.009.
- [105] C. Xia, Z. Pan, J. Polden, H. Li, Y. Xu, S. Chen und Y. Zhang. „A review on wire arc additive manufacturing: Monitoring, control and a framework of automated system“. In: *Journal of Manufacturing Systems* 57 (2020), S. 31–45. ISSN: 02786125. DOI: 10.1016/j.jmsy.2020.08.008.
- [106] S. Han. „Towards Efficient Implementation of an Octree for a Large 3D Point Cloud“. In: *Sensors (Basel, Switzerland)* 18.12 (2018). DOI: 10.3390/s18124398.
- [107] S. Tang, G. Wang, H. Song, R. Li und H. Zhang. „A novel method of bead modeling and control for wire and arc additive manufacturing“. In: *Rapid Prototyping Journal* 27.2 (2021), S. 311–320. ISSN: 1355-2546. DOI: 10.1108/RPJ-05-2020-0097.
- [108] Y. Li, X. Li, G. Zhang, I. Horváth und Q. Han. „Interlayer closed-loop control of forming geometries for wire and arc additive manufacturing based on fuzzy-logic inference“. In: *Journal of Manufacturing Processes* 63 (2021), S. 35–47. ISSN: 15266125. DOI: 10.1016/j.jmapro.2020.04.009.
- [109] A. Chabot, M. Rauch und J.-Y. Hascoët. „Novel control model of Contact-Tip-to-Work Distance (CTWD) for sound monitoring of arc-based DED processes based on spectral analysis“. In: *The International Journal of Advanced Manufacturing Technology* 116.11-12 (2021), S. 3463–3472. ISSN: 0268-3768. DOI: 10.1007/s00170-021-07621-2.
- [110] J. Xiong, Y. Zhang und Y. Pi. „Control of deposition height in WAAM using visual inspection of previous and current layers“. In: *J Intell Manuf* (2020). DOI: 10.1007/s10845-020-01634-6.
- [111] A. Ščetinec, D. Klobčar und D. Bračun. „In-process path replanning and online layer height control through deposition arc current for gas metal arc based additive manufacturing“. In: *Journal of Manufacturing Processes* 64 (2021), S. 1169–1179. ISSN: 15266125. DOI: 10.1016/j.jmapro.2021.02.038.

- [112] Y. K. Bandari, T. O. H. Charrett, F. Michel, J. Ding, S. Williams und R. P. Tatum. „Compensation strategies for robotic motion errors for additive manufacturing (AM)“. In: *Proceedings of 27th Annual International Solid Freeform Fabrication Symposium, 8-10 August 2016, Austin, Texas, USA 2016* (2016).
- [113] A. Chabot, M. Rauch und J.-Y. Hascoët. „Towards a multi-sensor monitoring methodology for AM metallic processes“. In: *Welding in the World* 63.3 (2019), S. 759–769. ISSN: 0043-2288. DOI: 10.1007/s40194-019-00705-4.
- [114] C. R. Cunningham, J. M. Flynn, A. Shokrani, V. Dhokia und S. T. Newman. „Invited review article: Strategies and processes for high quality wire arc additive manufacturing“. In: *Additive Manufacturing* 22 (2018), S. 672–686. ISSN: 22148604. DOI: 10.1016/j.addma.2018.06.020.
- [115] U. Reisgen, R. Sharma, S. Mann und L. Oster. „Increasing the manufacturing efficiency of WAAM by advanced cooling strategies“. In: *Welding in the World* 64.8 (2020), S. 1409–1416. ISSN: 0043-2288. DOI: 10.1007/s40194-020-00930-2.
- [116] M. W. Grieves. „Product lifecycle management: the new paradigm for enterprises“. In: *International Journal of Product Development* 2.1/2 (2005), S. 71. ISSN: 1477-9056. DOI: 10.1504/IJPD.2005.006669.
- [117] M. W. Grieves. *Digital Twin: Manufacturing Excellence through Virtual Factory Replication*. 2016. URL: https://www.researchgate.net/publication/275211047_Digital_Twin_Manufacturing_Excellence_through_Virtual_Factory_Replication.
- [118] marketsandmarkets, Hrsg. *Digital Twin Market by Technology, Type (Product, Process, and System), Application (predictive maintenance), Industry (Aerospace & Defense, Automotive & Transportation, Healthcare), and Geography: Global Forecast to 2026*. 2020. URL: <https://www.marketsandmarkets.com/PressReleases/digital-twin.asp> (besucht am 01.01.2022).
- [119] M. R. Enders und N. Hoßbach. „Dimensions of Digital Twin Applications - A Literature Review“. In: *AMCIS Proceedings* 20 (2019). URL: https://aisel.aisnet.org/amcis2019/org_transformation_is/org_transformation_is/20/.
- [120] S. R. Newrzella, D. W. Franklin und S. Haider. „5-Dimension Cross-Industry Digital Twin Applications Model and Analysis of Digital Twin Classification Terms and Models“. In: *IEEE Access* 9 (2021), S. 131306–131321. DOI: 10.1109/ACCESS.2021.3115055.
- [121] W. Kritzing, M. Karner, G. Traar, J. Henjes und W. Sihn. „Digital Twin in manufacturing: A categorical literature review and classification“. In: *IFAC-PapersOnLine* 51.11 (2018), S. 1016–1022. ISSN: 24058963. DOI: 10.1016/j.ifacol.2018.08.474.
- [122] R. Rosen, G. von Wichert, G. Lo und K. D. Bettenhausen. „About The Importance of Autonomy and Digital Twins for the Future of Manufacturing“. In: *IFAC-PapersOnLine* 48.3 (2015), S. 567–572. ISSN: 24058963. DOI: 10.1016/j.ifacol.2015.06.141.
- [123] T. Kuhn. „Digitaler Zwilling“. In: *Informatik-Spektrum* 40.5 (2017), S. 440–444. ISSN: 0170-6012. DOI: 10.1007/s00287-017-1061-2.
- [124] T. H.-J. Uhlemann, C. Lehmann und R. Steinhilper. „The Digital Twin: Realizing the Cyber-Physical Production System for Industry 4.0“. In: *Procedia CIRP* 61 (2017), S. 335–340. ISSN: 22128271. DOI: 10.1016/j.procir.2016.11.152.
- [125] T. H.-J. Uhlemann, C. Schock, C. Lehmann, S. Freiberger und R. Steinhilper. „The Digital Twin: Demonstrating the Potential of Real Time Data Acquisition in Production Systems“. In: *Procedia Manufacturing* 9 (2017), S. 113–120. DOI: 10.1016/j.promfg.2017.04.043.

- [126] J. Vater, L. Harscheidt und A. Knoll. „Smart Manufacturing with Prescriptive Analytics“. In: *8th International Conference on Industrial Technology and Management (ICITM)* (2019), S. 224–228. DOI: 10.1109/ICITM.2019.8710673.
- [127] H. Yao, Y. Liu, Y. Wei, X. Tang und Z. Li. „Learning from Multiple Cities: A Meta-Learning Approach for Spatial-Temporal Prediction“. In: (2019).
- [128] F. Tao, H. Zhang, A. Liu und A. Y. C. Nee. „Digital Twin in Industry: State-of-the-Art“. In: *IEEE Transactions on Industrial Informatics* 15.4 (2019), S. 2405–2415. ISSN: 1551-3203. DOI: 10.1109/TII.2018.2873186.
- [129] K. Hribernik, G. Cabri, F. Mandreoli und G. Mentzas. „Autonomous, context-aware, adaptive Digital Twins—State of the art and roadmap“. In: *Computers in Industry* 133 (2021). ISSN: 01663615. DOI: 10.1016/j.compind.2021.103508.
- [130] G. D. Abowd und A. K. Dey. *Towards a Better Understanding of Context and Context-Awareness*. Atlanta, USA, 1999.
- [131] P. Rosenberger und D. Gerhard. „Context-awareness in industrial applications: definition, classification and use case“. In: *Procedia CIRP* 72 (2018), S. 1172–1177. ISSN: 22128271. DOI: 10.1016/j.procir.2018.03.242.
- [132] J.-y. Hong, E.-h. Suh und S.-J. Kim. „Context-aware systems: A literature review and classification“. In: *Expert Systems with Applications* 36.4 (2009), S. 8509–8522. ISSN: 09574174. DOI: 10.1016/j.eswa.2008.10.071.
- [133] K. Alexopoulos, S. Makris, V. Xanthakis, K. Sipsas und G. Chryssolouris. „A concept for context-aware computing in manufacturing: the white goods case“. In: *International Journal of Computer Integrated Manufacturing* 29.8 (2016), S. 839–849. ISSN: 0951-192X. DOI: 10.1080/0951192X.2015.1130257.
- [134] A. N. Lee und J. L. Martinez Lastra. „Enhancement of industrial monitoring systems by utilizing context awareness“. In: *IEEE International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)* (2013), S. 277–284. DOI: 10.1109/CogSIMA.2013.6523858.
- [135] S. Mittal, M. A. Khan, D. Romero und T. Wuest. „Smart manufacturing: Characteristics, technologies and enabling factors“. In: *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture* 233.5 (2019), S. 1342–1361. ISSN: 0954-4054. DOI: 10.1177/0954405417736547.
- [136] N. J. Steiner. „Autonomous Computing Systems“. Dissertation. Virginia Polytechnic Institute and State University, 2008. URL: <http://hdl.handle.net/10919/26758>.
- [137] S. Poornima und M. Pushpalatha. „A survey on various applications of prescriptive analytics“. In: *International Journal of Intelligent Networks* 1 (2020), S. 76–84. ISSN: 26666030. DOI: 10.1016/j.ijin.2020.07.001.
- [138] S. Groggert, H. Elser, Q. H. Ngo und R. H. Schmitt. „Scenario-based Manufacturing Data Analytics with the Example of Order Tracing through BLE-Beacons“. In: *Procedia Manufacturing* 24 (2018), S. 243–249. DOI: 10.1016/j.promfg.2018.06.032.
- [139] J. Vater, M. Kirschning und A. Knoll. „Closing the loop: Real-time Error Detection and Correction in automotive production using Edge-/Cloud-Architecture and a CNN“. In: *International Conference on Omni-layer Intelligent Systems (COINS)* (2020), S. 1–7. DOI: 10.1109/COINS49042.2020.9191386.
- [140] F. Tao, Q. Qi, L. Wang und A. Nee. „Digital Twins and Cyber-Physical Systems toward Smart Manufacturing and Industry 4.0: Correlation and Comparison“. In: *Engineering* 5.4 (2019), S. 653–661. ISSN: 20958099. DOI: 10.1016/j.eng.2019.01.014.

- [141] Y. K. Liu, S. K. Ong und A. Y. C. Nee. „State-of-the-art survey on digital twin implementations“. In: *Advances in Manufacturing* 10.1 (2022), S. 1–23. ISSN: 2195-3597. DOI: 10.1007/s40436-021-00375-w.
- [142] Q. Qi und F. Tao. „A Smart Manufacturing Service System Based on Edge Computing, Fog Computing, and Cloud Computing“. In: *IEEE Access* 7 (2019), S. 86769–86777. DOI: 10.1109/ACCESS.2019.2923610.
- [143] OPC Foundation, Hrsg. *OPC Foundation: The Industrial Interoperability Standard*. URL: <https://opcfoundation.org/> (besucht am 21. 01. 2022).
- [144] VDW — Verein Deutscher Werkzeugmaschinenfabriken e.V., Hrsg. *umati - universal machine technology interface*. URL: <https://umati.org/> (besucht am 21. 01. 2022).
- [145] C. Liu, Z. Zhu und X. Xu. „Machine Tool Digital Twin: Modelling Methodology and Applications“. In: *48th International Conference on Computers and Industrial Engineering* (2018).
- [146] ANSI. *ISO/DIS 23247:2020(E): Automation systems and integration — Digital Twin framework for manufacturing*. 27.07.2020.
- [147] D. R. Gunasegaram, A. B. Murphy, M. J. Matthews und T. DebRoy. „The case for digital twins in metal additive manufacturing“. In: *Journal of Physics: Materials* 4.4 (2021), S. 040401. DOI: 10.1088/2515-7639/ac09fb.
- [148] T. DebRoy, W. Zhang, J. Turner und S. S. Babu. „Building digital twins of 3D printing machines“. In: *Scripta Materialia* 135 (2017), S. 119–124. ISSN: 13596462. DOI: 10.1016/j.scriptamat.2016.12.005.
- [149] G. L. Knapp, T. Mukherjee, J. S. Zuback, H. L. Wei, T. A. Palmer, A. De und T. DebRoy. „Building blocks for a digital twin of additive manufacturing“. In: *Acta Materialia* 135 (2017), S. 390–399. ISSN: 13596454. DOI: 10.1016/j.actamat.2017.06.039.
- [150] T. Mukherjee und T. DebRoy. „A digital twin for rapid qualification of 3D printed metallic components“. In: *Applied Materials Today* 14 (2019), S. 59–65. ISSN: 23529407. DOI: 10.1016/j.apmt.2018.11.003.
- [151] D. R. Gunasegaram, A. B. Murphy, A. Barnard, T. DebRoy, M. J. Matthews, L. Ladani und D. Gu. „Towards developing multiscale-multiphysics models and their surrogates for digital twins of metal additive manufacturing“. In: *Additive Manufacturing* 46 (2021), S. 102089. ISSN: 22148604. DOI: 10.1016/j.addma.2021.102089.
- [152] T.-E. Adams und P. Mayr. „The Path from Arc Welding to Additive Manufacturing of Multi-material Parts Using Directed Energy Deposition“. In: *BHM Berg- und Hüttenmännische Monatshefte* 167.7 (2022), S. 318–324. ISSN: 0005-8912. DOI: 10.1007/s00501-022-01241-3.
- [153] L. Zhang, X. Chen, W. Zhou, T. Cheng, L. Chen, Z. Guo, B. Han und L. Lu. „Digital Twins for Additive Manufacturing: A State-of-the-Art Review“. In: *Applied Sciences* 10.23 (2020), S. 8350. DOI: 10.3390/app10238350.
- [154] A. Gaikwad, R. Yavari, M. Montazeri, K. Cole, L. Bian und P. Rao. „Toward the digital twin of additive manufacturing: Integrating thermal simulations, sensing, and analytics to detect process faults“. In: *IISE Transactions* 52.11 (2020), S. 1204–1217. ISSN: 2472-5854. DOI: 10.1080/24725854.2019.1701753.
- [155] Z. Yang, D. Eddy, S. Krishnamurty, I. Grosse, P. Denno, Y. Lu und P. Witherell. „Investigating Grey-Box Modeling for Predictive Analytics in Smart Manufacturing“. In: *ASME 2017 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference* (2017). DOI: 10.1115/DETC2017-67794.

- [156] Z. Yang. „Model-based predictive analytics for additive and smart manufacturing“. Dissertation. University of Massachusetts Amherst, October 2018. DOI: 10.7275/12525860.
- [157] L. Hu, N.-T. Nguyen, W. Tao, M. C. Leu, X. F. Liu, M. R. Shahriar und S. M. N. Al Sunny. „Modeling of Cloud-Based Digital Twins for Smart Manufacturing with MT Connect“. In: *Procedia Manufacturing* 26 (2018), S. 1193–1203. DOI: 10.1016/j.promfg.2018.07.155.
- [158] D. Mourtzis, T. Toghias, J. Angelopoulos und P. Stavropoulos. „A Digital Twin architecture for monitoring and optimization of Fused Deposition Modeling processes“. In: *Procedia CIRP* 103 (2021), S. 97–102. ISSN: 22128271. DOI: 10.1016/j.procir.2021.10.015.
- [159] T. A. Runkler. *Data Analytics*. Wiesbaden: Springer Fachmedien Wiesbaden, 2020. DOI: 10.1007/978-3-658-29779-4.
- [160] C. Shearer. „The CRISP-DM model: The new blueprint for data mining“. In: *Journal of data warehousing* 5.4 (2000), S. 13–22.
- [161] E. Keogh, J. Lin und A. Fu. „HOT SAX: Efficiently Finding the Most Unusual Time Series Subsequence“. In: *ICDM 2005: Fifth IEEE International Conference on Data Mining (27-30 November 2005/Houston, TX)*. IEEE Computer Society Press, 2005, S. 226–233. ISBN: 0-7695-2278-5. DOI: 10.1109/ICDM.2005.79.
- [162] H. Borges, R. Akbarinia und F. Masegla. „Anomaly Detection in Time Series“. In: *Transactions on Large-Scale Data- and Knowledge-Centered Systems* (2021). URL: <https://hal-lirmm.ccsd.cnrs.fr/lirmm-03359500>.
- [163] B. D. Fulcher, M. A. Little und N. S. Jones. „Highly comparative time-series analysis: the empirical structure of time series and their methods“. In: *Journal of the Royal Society, Interface* 10.83 (2013), S. 20130048. DOI: 10.1098/rsif.2013.0048.
- [164] B. D. Fulcher und N. S. Jones. „hctsa: A Computational Framework for Automated Time-Series Phenotyping Using Massive Feature Extraction“. In: *Cell systems* 5.5 (2017), 527–531.e3. ISSN: 2405-4712. DOI: 10.1016/j.cels.2017.10.001.
- [165] C. H. Lubba, S. S. Sethi, P. Knaute, S. R. Schultz, B. D. Fulcher und N. S. Jones. „catch22: CAnonical Time-series CHaracteristics“. In: *Data Mining and Knowledge Discovery* 33.6 (2019), S. 1821–1852. ISSN: 13845810. DOI: 10.1007/s10618-019-00647-x.
- [166] S. Yen, M. Moh und T.-S. Moh. „CausalConvLSTM: Semi-Supervised Log Anomaly Detection Through Sequence Modeling“. In: *18th IEEE International Conference on Machine Learning and Applications (ICMLA)* (2019). DOI: 10.1109/ICMLA.2019.00217.
- [167] T. A. Runkler. *Data Mining: Methoden und Algorithmen intelligenter Datenanalyse*. Vieweg+Teubner, 2010. ISBN: 978-3-8348-0858-5.
- [168] P. Senin. *Dynamic Time Warping Algorithm Review*. 2008.
- [169] I. J. Goodfellow, Y. Bengio und A. Courville. *Deep Learning*. 2016. URL: <http://www.deeplearningbook.org>.
- [170] J. R. Quinlan. „Induction of decision trees“. In: *Machine Learning* 1.1 (1986), S. 81–106. ISSN: 0885-6125. DOI: 10.1007/BF00116251.
- [171] L. Breimann, J. H. Frieman, R. A. Olshen und C. J. S. Stone. *Classification And Regression Trees*. Routledge, 1983.
- [172] J. R. Quinlan. *C4.5: programs for machine learning*. Morgan Kaufmann Publishers Inc., 1993. ISBN: 978-1-55860-238-0.
- [173] M. Kuhn und K. Johnson. *Applied Predictive Modeling*. New York, NY: Springer New York, 2013. DOI: 10.1007/978-1-4614-6849-3.

- [174] T. K. Ho. „Random decision forests“. In: *Proceedings of 3rd International Conference on Document Analysis and Recognition* (1995), S. 278–282. DOI: 10.1109/ICDAR.1995.598994.
- [175] L. Breiman. „Random Forests“. In: *Machine Learning* 45.1 (2001), S. 5–32. ISSN: 0885-6125. DOI: 10.1023/A:1010933404324.
- [176] L. Breiman. „Bagging predictors“. In: *Machine Learning* 24.2 (1996), S. 123–140. ISSN: 0885-6125. DOI: 10.1007/BF00058655.
- [177] R. E. Schapire. „The Boosting Approach to Machine Learning: An Overview“. In: *Nonlinear Estimation and Classification*. Hrsg. von D. Denison, M. Hansen, C. Holmes, B. Mallick und B. Yu. Bd. 171. 2003, S. 149–171. DOI: 10.1007/978-0-387-21579-2-9.
- [178] T. Chen und C. Guestrin. „XGBoost: A Scalable Tree Boosting System“. In: *KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (2016), S. 785–794. DOI: 10.1145/2939672.2939785.
- [179] Y. Freund und R. E. Schapire. „A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting“. In: *Journal of Computer and System Sciences* 55.1 (1997), S. 119–139. ISSN: 00220000. DOI: 10.1006/jcss.1997.1504.
- [180] V. N. Vapnik und A. Y. Chervonenkis. *Theory of Pattern Recognition*. 1974.
- [181] C. J. Burges. In: *Data Mining and Knowledge Discovery 2.2* (1998), S. 121–167. ISSN: 13845810. DOI: 10.1023/A:1009715923555.
- [182] A. F. Agarap. „Deep Learning using Rectified Linear Units (ReLU)“. In: *arXiv preprint* (2018).
- [183] D. P. Kingma und J. Ba. „Adam: A Method for Stochastic Optimization“. In: *International Conference on Learning Representations (ICLR)* (2015).
- [184] I. Loshchilov und F. Hutter. „Decoupled Weight Decay Regularization“. In: *ICLR 2019* (2019).
- [185] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard und L. D. Jackel. „Backpropagation Applied to Handwritten Zip Code Recognition“. In: *Neural computation* 1.4 (1989), S. 541–551. ISSN: 0899-7667. DOI: 10.1162/neco.1989.1.4.541.
- [186] S. Albawi, T. A. Mohammed und S. Al-Zawi. „Understanding of a convolutional neural network“. In: *International Conference on Engineering and Technology (ICET)* (2017), S. 1–6. DOI: 10.1109/ICEngTechnol.2017.8308186.
- [187] Y. LeCun und Y. Bengio. „Convolutional Networks for Images, Speech, and Time Series“. In: *The Handbook of Brain Theory and Neural Networks* (1998), S. 255–258.
- [188] S. Lathuiliere, P. Mesejo, X. Alameda-Pineda und R. Horaud. „A Comprehensive Analysis of Deep Regression“. In: *IEEE transactions on pattern analysis and machine intelligence* 42.9 (2020), S. 2065–2081. DOI: 10.1109/TPAMI.2019.2910523.
- [189] S. Hochreiter und J. Schmidhuber. „Long short-term memory“. In: *Neural computation* 9.8 (1997), S. 1735–1780. ISSN: 0899-7667. DOI: 10.1162/neco.1997.9.8.1735.
- [190] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk und Y. Bengio. „Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation“. In: *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (2014).
- [191] D. Neil, M. Pfeiffer und S.-C. Liu. „Phased LSTM: Accelerating Recurrent Network Training for Long or Event-based Sequences“. In: *NIPS* (2016). DOI: 10.5167/UZH-149394.

- [192] D. Bank, N. Koenigstein und R. Giryes. „Autoencoders“. In: *arXiv preprint* (2021).
- [193] P. Baldi und K. Hornik. „Neural networks and principal component analysis: Learning from examples without local minima“. In: *Neural Networks* 2.1 (1989), S. 53–58. ISSN: 08936080. DOI: 10.1016/0893-6080(89)90014-2.
- [194] B. Jin, Y. Tan, A. Nettekoven, Y. Chen, Y. Yue, U. Topcu und A. Sangiovanni-Vincentelli. „An Encoder-Decoder Based Approach for Anomaly Detection with Application in Additive Manufacturing“. In: *ICMLA* (2019), S. 1008–1015. DOI: 10.1109/ICMLA.2019.00171.
- [195] S. Lee und J. Jo. „Information Flows of Diverse Autoencoders“. In: *Entropy (Basel, Switzerland)* 23.7 (2021). DOI: 10.3390/e23070862.
- [196] H. Steck. „Autoencoders that don’t overfit towards the Identity“. In: *NeurIPS 2020* (2020).
- [197] S. Ahmad, K. Styp-Rekowski, S. Nedelkoski und O. Kao. „Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines“. In: *IEEE International Conference on Big Data (Big Data)* (2021).
- [198] K. N. Haque, M. A. Yousuf und R. Rana. „Image denoising and restoration with CNN-LSTM Encoder Decoder with Direct Attention“. In: *arXiv preprint* (2018).
- [199] A. Oladosu, T. Xu, P. EKFeldt, B. A. Kelly, M. Cranmer, S. Ho, A. M. Price-Whelan und G. Contardo. „Meta-Learning for One-Class Classification with Few Examples using Order-Equivariant Network“. In: *arXiv preprint* (2021).
- [200] J. Vanschoren. „Meta-Learning“. In: *Automated Machine Learning*. Hrsg. von F. Hutter, L. Kotthoff und J. Vanschoren. 2019, S. 35–61. DOI: 10.1007/978-3-030-05318-5-2.
- [201] S. Ravi und H. Larochelle. „Optimization as a Model for Few-Shot Learning“. In: *ICLR* (2016).
- [202] C. Finn, P. Abbeel und S. Levine. „Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks“. In: *Proceedings of the 34th International Conference on Machine Learning* (2017).
- [203] A. Biswas und S. Agrawal. „First-order Meta-Learned Initialization for Faster Adaptation in Deep Reinforcement Learning“. In: *Conference on Neural Information Processing Systems (NIPS)* (2018).
- [204] A. Antoniou, H. Edwards und A. Storkey. „How to train your MAML“. In: *ICLR* (2019).
- [205] A. Nichol, J. Achiam und J. Schulman. „On First-Order Meta-Learning Algorithms“. In: *arXiv preprint* (2018). URL: <http://arxiv.org/pdf/1803.02999v3>.
- [206] A. Santoro, S. Bartunov, M. Botvinick, D. Wierstra und T. Lillicrap. „One-shot Learning with Memory-Augmented Neural Networks“. In: *arXiv preprint* (2016). URL: <http://arxiv.org/pdf/1605.06065v1>.
- [207] T. Munkhdalai und H. Yu. „Meta Networks“. In: *ICML* (2017).
- [208] T. Wu, J. Peurifoy, I. L. Chuang und M. Tegmark. „Meta-learning autoencoders for few-shot prediction“. In: *arXiv preprint* (2018).
- [209] G. Koch, R. Zemel und R. Salakhutdinov. „Siamese Neural Networks for One-shot Image Recognition“. In: *Proceedings of the 32nd International Conference on Machine Learning* (2015).
- [210] J. Snell, K. Swerskym und R. Zemel. „Prototypical Networks for Few-shot Learning“. In: *31st Conference on Neural Information Processing Systems (NIPS 2017)* (2017).

- [211] F. Sung, Y. Yang, L. Zhang, T. Xiang, P. H. Torr und T. M. Hospedales. „Learning to Compare: Relation Network for Few-Shot Learning“. In: *CVPR* (2017).
- [212] O. Vinyals, C. Blundell, T. Lillicrap, K. Kavukcuoglu und D. Wierstra. „Matching Networks for One Shot Learning“. In: *Conference on Neural Information Processing Systems (NIPS)* (2016).
- [213] S. Salvador und P. Chan. „Learning States and Rules for Detecting Anomalies in Time Series“. In: *Applied Intelligence* 23.3 (2005), S. 241–255. ISSN: 0924-669X. DOI: 10.1007/s10489-005-4610-3.
- [214] V. Chandola, A. Banerjee und V. Kumar. „Anomaly Detection: A Survey“. In: *ACM Computing Surveys* 41.3 (2009), S. 1–58. ISSN: 0360-0300. DOI: 10.1145/1541880.1541882.
- [215] R. Chalapathy und S. Chawla. „Deep Learning for Anomaly Detection: A Survey“. In: *arXiv preprint* (2019).
- [216] M. A. Pimentel, D. A. Clifton, L. Clifton und L. Tarassenko. „A review of novelty detection“. In: *Signal Processing* 99 (2014), S. 215–249. ISSN: 01651684. DOI: 10.1016/j.sigpro.2013.12.026.
- [217] L. Tarassenko. „Novelty detection for the identification of masses in mammograms“. In: *4th International Conference on Artificial Neural Networks*. IEE, 1995, S. 442–447. ISBN: 0 85296 641 5. DOI: 10.1049/cp:19950597.
- [218] D. Kim, J. Cha, S. Oh und J. Jeong. „AnoGAN-Based Anomaly Filtering for Intelligent Edge Device in Smart Factory“. In: *International Conference on Ubiquitous Information Management and Communication (IMCOM)* 15 (2021), S. 1–6. DOI: 10.1109/IMCOM51814.2021.9377409.
- [219] V. Lamsa und T. Raiko. „Novelty detection by nonlinear factor analysis for structural health monitoring“. In: *IEEE International Workshop on Machine Learning for Signal Processing* (2010), S. 468–473. DOI: 10.1109/MLSP.2010.5588688.
- [220] T. Klerx, M. Anderka, H. K. Buning und S. Priesterjahn. „Model-Based Anomaly Detection for Discrete Event Systems“. In: *IEEE 26th International Conference on Tools with Artificial Intelligence* (2014), S. 665–672. DOI: 10.1109/ICTAI.2014.105.
- [221] V. J. Hodge und J. Austin. „A Survey of Outlier Detection Methodologies“. In: *Artificial Intelligence Review* 22.2 (2004), S. 85–126. ISSN: 0269-2821. DOI: 10.1007/s10462-004-4304-y.
- [222] A. Geiger, D. Liu, S. Alnegheimish, A. Cuesta-Infante und K. Veeramachaneni. „TadGAN: Time Series Anomaly Detection Using Generative Adversarial Networks“. In: *IEEE International Conference on Big Data* (2020).
- [223] G. Pang, C. Shen, L. Cao und A. den van Hengel. „Deep Learning for Anomaly Detection“. In: *ACM Computing Surveys* 54.2 (2021), S. 1–38. ISSN: 0360-0300. DOI: 10.1145/3439950.
- [224] H. He und E. Garcia. „Learning from Imbalanced Data“. In: *IEEE Transactions on Knowledge and Data Engineering* 20.3 (2008), S. 1263–1284. ISSN: 1041-4347. DOI: 10.1109/TKDE.2008.23.
- [225] A. Frikha, D. Krompaß, H.-G. Köpken und V. Tresp. „Few-Shot One-Class Classification via Meta-Learning“. In: *AAAI Conference on Artificial Intelligence* (2021).
- [226] M. Braei und S. Wagner. „Anomaly Detection in Univariate Time-series: A Survey on the State-of-the-Art“. In: *arXiv preprint* (2020).
- [227] M. M. Breunig, H.-P. Kriegel, R. T. Ng und J. Sander. „LOF“. In: *ACM SIGMOD Record* 29.2 (2000), S. 93–104. ISSN: 0163-5808. DOI: 10.1145/335191.335388.

- [228] M. Ester, H. Kriegel, J. Sander und X. Xu. „A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise“. In: *KDD-96 Proceedings* (1996).
- [229] E. Schubert, J. Sander, M. Ester, H. P. Kriegel und X. Xu. „DBSCAN Revisited, Revisited: Why and How You Should (Still) Use DBSCAN“. In: *ACM Transactions on Database Systems* 42.3 (2017), S. 1–21. ISSN: 0362-5915. DOI: 10.1145/3068335.
- [230] M. Boldt, A. Borg, S. Ickin und J. Gustafsson. „Anomaly detection of event sequences using multiple temporal resolutions and Markov chains“. In: *Knowledge and Information Systems* 62.2 (2020), S. 669–686. ISSN: 0219-1377. DOI: 10.1007/s10115-019-01365-y.
- [231] F. T. Liu, K. M. Ting und Z.-H. Zhou. „Isolation-Based Anomaly Detection“. In: *ACM Transactions on Knowledge Discovery from Data* 6.1 (2012), S. 1–39. ISSN: 1556-4681. DOI: 10.1145/2133360.2133363.
- [232] F. T. Liu, K. M. Ting und Z.-H. Zhou. „Isolation Forest“. In: *ICDM '08. Eighth IEEE International Conference on Data Mining* (2008), S. 413–422. DOI: 10.1109/ICDM.2008.17.
- [233] D. M. Tax und R. P. Duin. „Support Vector Data Description“. In: *Machine Learning* 54.1 (2004), S. 45–66. ISSN: 0885-6125. DOI: 10.1023/B:MACH.0000008084.60811.49.
- [234] M. Szmit und A. Szmit. „Usage of Modified Holt-Winters Method in the Anomaly Detection of Network Traffic: Case Studies“. In: *Journal of Computer Networks and Communications* 2012 (2012), S. 1–5. ISSN: 2090-7141. DOI: 10.1155/2012/192913.
- [235] S. Ahmad und S. Purdy. „Real-Time Anomaly Detection for Streaming Analytics“. In: *arXiv preprint* (2016). URL: <https://arxiv.org/pdf/1607.02480.pdf>.
- [236] S. Ahmad, A. Lavin, S. Purdy und Z. Agha. „Unsupervised real-time anomaly detection for streaming data“. In: *Neurocomputing* 262 (2017), S. 134–147. ISSN: 09252312. DOI: 10.1016/j.neucom.2017.04.070.
- [237] A. Jerome, T. Ishii und H. Chen. „Forecasting and Anomaly Detection on Application Metrics using LSTM“. In: *IEEE International Conference on Big Data (Big Data)* (2018), S. 2221–2227. DOI: 10.1109/BigData.2018.8622492.
- [238] S. Chauhan und L. Vig. „Anomaly detection in ECG time signals via deep long short-term memory networks“. In: *IEEE International Conference on Data Science and Advanced Analytics (DSAA)* (2015), S. 1–7. DOI: 10.1109/DSAA.2015.7344872.
- [239] T. Wen und R. Keyes. „Time Series Anomaly Detection Using Convolutional Neural Networks and Transfer Learning“. In: *AI for Internet of Things Workshop in IJCAI* (2019).
- [240] M. Thill, W. Konen, H. Wang und T. Bäck. „Temporal convolutional autoencoder for unsupervised anomaly detection in time series“. In: *Applied Soft Computing* 112 (2021), S. 107751. ISSN: 15684946. DOI: 10.1016/j.asoc.2021.107751.
- [241] D. Gong, L. Liu, Le Vuong, B. Saha, M. R. Mansour, S. Venkatesh und A. van den Hengel. „Memorizing Normality to Detect Anomaly: Memory-augmented Deep Autoencoder for Unsupervised Anomaly Detection“. In: *IEEE/CVF International Conference on Computer Vision (ICCV)* (2019).
- [242] J. Brownlee. *Imbalanced Classification with Python: Better Metrics, Balance Skewed Classes, Cost-Sensitive Learning*. Machine Learning Mastery, 2020. URL: <https://books.google.de/books?id=jaXJDwAAQBAJ>.

- [243] T. DebRoy, H. L. Wei, J. S. Zuback, T. Mukherjee, J. W. Elmer, J. O. Milewski, A. M. Beese, A. Wilson-Heid, A. De und W. Zhang. „Additive manufacturing of metallic components – Process, structure and properties“. In: *Progress in Materials Science* 92 (2018), S. 112–224. ISSN: 00796425. DOI: 10.1016/j.pmatsci.2017.10.001.
- [244] S. Nasiri und M. R. Khosravani. „Machine learning in predicting mechanical behavior of additively manufactured parts“. In: *Journal of Materials Research and Technology* 14 (2021), S. 1137–1153. ISSN: 22387854. DOI: 10.1016/j.jmrt.2021.07.004.
- [245] J. Elseberg, D. Borrmann und A. Nüchter. „One Billion Points in the Cloud – an Octree for Efficient Processing of 3D Laser Scans“. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 76 (2013), S. 76–88. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2012.10.004.
- [246] Y. Pan. *DYNAMIC UPDATE OF SPARSE VOXEL OCTREE BASED ON MORTON CODE: Master Thesis*. 2021.
- [247] M. S. Warren und J. K. Salmon. „A parallel hashed Oct-Tree N-body algorithm“. In: *Proceedings of the 1993 ACM/IEEE conference on Supercomputing* (1993), S. 12–21. DOI: 10.1145/169627.169640.
- [248] H. Rauen und J. Binzer. *Leitfaden Sensorik für Industrie 4.0: Wege zu kostengünstigen Sensorsystemen*. Hrsg. von VDMA. 2018.
- [249] T. Akiba, S. Sano, T. Yanase, T. Ohta und M. Koyama. „Optuna: A Next-generation Hyperparameter Optimization Framework“. In: *KDD '19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (2019). URL: <https://optuna.readthedocs.io/en/stable/index.html>.
- [250] Scikit-learn. *Permutation Importance with Multicollinear or Correlated Features*. 2022. URL: https://scikit-learn.org/stable/auto_examples/inspection/plot_permutation_importance_multicollinear.html (besucht am 29.05.2022).
- [251] B. McFee, C. Raffel, D. Liang, A. Ellis, M. McVicar, E. Battenberg und O. Nieto. „librosa: Audio and Music Signal Analysis in Python“. In: *Proceedings of the 14th Python in Science Conference (SCIPY 2015)* (2015). URL: <https://librosa.org/doc/latest/feature.html> (besucht am 17.05.2022).
- [252] T. Giannakopoulos. „pyAudioAnalysis: An Open-Source Python Library for Audio Signal Analysis“. In: *PloS one* 12 (2015).
- [253] N. Chawla, K. Bowyer, L. Hall und P. Kegelmeyer. „SMOTE: synthetic minority over-sampling technique“. In: *Journal of Artificial Intelligence Research* 16.1 (2002), S. 321–357.
- [254] N. Laptev, S. Amizadeh und Y. Billawala. *A Benchmark Dataset for Time Series Anomaly Detection*. Hrsg. von Yahoo Research. 2015. URL: <https://yahooresearch.tumblr.com/post/114590420346/a-benchmark-dataset-for-time-series-anomaly> (besucht am 15.05.2022).
- [255] H. Xu, W. Chen, N. Zhao, Z. Li, J. Bu, Z. Li, Y. Liu, Y. Zhao, D. Pei und Y. Feng. „Unsupervised Anomaly Detection via Variational Auto-Encoder for Seasonal KPIs in Web Applications“. In: *Proceedings of the 2018 World Wide Web Conference on World Wide Web* (2018), S. 187–196.
- [256] A. Kramida. „Ground Levels and Ionization Energies for the Neutral Atoms - NIST Standard Reference Database 111“. In: *Data.gov* (2021). DOI: 10.18434/T42P4C.

- [257] M. Quintanilla, E. Cantelar, F. Cussó, J. A. Barreda-Argüeso, J. González, R. Valiente und F. Rodríguez. „Control of infrared cross-relaxation in $\text{LiNbO}_3:\text{Tm}^{3+}$ through high-pressure“. In: *Optical Materials Express* 5.5 (2015), S. 1168. DOI: 10.1364/OME.5.001168.
- [258] B. Zhang, S. Liu und Y. C. Shin. „In-Process monitoring of porosity during laser additive manufacturing process“. In: *Additive Manufacturing* 28 (2019), S. 497–505. ISSN: 22148604. DOI: 10.1016/j.addma.2019.05.030.
- [259] Comau S.p.A. *NJ-130-2.0*. URL: <https://www.comau.com/de/competencies/robotics-automation/robot-team/nj-130-2-0/> (besucht am 03.05.2022).
- [260] Comau S.p.A. *Robotics - Compact Catalogue*. Hrsg. von Comau S.p.A. Turin, 2021. URL: https://www.comau.com/wp-content/uploads/2021/06/Comau_Compact_Catalogue_Robotics.pdf (besucht am 15.06.2022).
- [261] Fronius International GmbH. : *VR 7000 CMT (42,0426,0015,EN): Wire-feed unit*. 2019.
- [262] Fronius International GmbH. *CMT 4000 Advanced (42,0426,0001,DE): MIG/MAG-Stromquelle*. 2019.
- [263] Siemens AG. *SINUMERIK 840D sl / 828D Grundfunktionen*. 2010.
- [264] Siemens AG. *SINUMERIK 840D sl - SINUMERIK Run MyRobot /Direct Control: Programming Manual*. Hrsg. von Siemens AG. 7–2020.
- [265] Siemens AG. *SIMATIC - S7-300 CPU 319-3 PN/DP: Produktdatenblatt*. Hrsg. von Siemens AG. 1. Apr. 2022. URL: <https://mall.industry.siemens.com/mall/de/WW/Catalog/Product/6ES7318-3EL01-0AB0> (besucht am 15.06.2022).
- [266] Siemens AG. *SIMATIC - Industrie-PC 427E: Betriebsanleitung*. Hrsg. von Siemens AG. 2021.
- [267] NVIDIA Corporation. *Jetson AGX Xavier Developer Kit*. Hrsg. von NVIDIA Corporation. URL: <https://developer.nvidia.com/embedded/jetson-agx-xavier-developer-kit> (besucht am 03.05.2022).
- [268] Siemens AG, Hrsg. *Examples of Open User Communication: UDP*. 7–2019.
- [269] T. Hauser. „In-situ analysis of process characteristics in Directed Energy Deposition“. Dissertation. Lulea University of Technology, 2022.
- [270] H. Wessels und P. Wriggers. „Vision: Digitale Zwillinge für die Additive Fertigung“. In: (2021), S. 77–100. DOI: 10.1007/978-3-662-63030-3-5.
- [271] HKS Prozesstechnik GmbH. *Sensoren*. Hrsg. von HKS Prozesstechnik GmbH. URL: <https://hks-prozesstechnik.de/sensoren-2/> (besucht am 03.05.2022).
- [272] Micro-Epsilon Messtechnik GmbH & Co. KG. *Betriebsanleitung IF1032/ETH*. Hrsg. von Micro-Epsilon Messtechnik. Ortenburg, 2020.
- [273] Siemens AG. *SIMATIC - ET 200SP - Analogeingabemodul AI 2xU/I 2-/4-wire HF (6ES7134-6HB00-0CA1)*. Hrsg. von Siemens AG. 2015.
- [274] Siemens AG. *SIMATIC - ET 200SP - Technologiemodul TM PosInput 1 (6ES7138-6BA00-0AA0)*. Hrsg. von Siemens AG. 2014.
- [275] Ocean Optics, Inc. *USB2000+ Fiber Optic Spectrometer (270-00000-000-02-201603) - Installation and Operation Manual*. Dunedin, 2010.
- [276] Cavitar LTD. *Cavitar Welding Camera*. URL: <https://www.cavitar.com/product/cavitar-welding-camera/> (besucht am 05.03.2022).

- [277] I. PreSonus Audio Electronics. *PreSonus PRM1: Precision Reference Microphone*. URL: <https://www.presonus.com/products/PRM1/tech-specs> (besucht am 03.05.2022).
- [278] Dittel Messtechnik GmbH. *AE6000: Dittel-System 6000 - AE-Prozessüberwachungsmodul*. Hrsg. von Dittel Messtechnik GmbH. 2019.
- [279] Gefertec GmbH. *3DMP-Verfahren*. URL: <https://www.gefertec.de/3dmp-verfahren/waam-technologie> (besucht am 10.09.2022).
- [280] Norsk Titanium AS. *Rapid Plasma Deposition*. URL: <https://www.norsktitanium.com/technology> (besucht am 12.08.2022).
- [281] SBI GmbH. *Additive Manufacturing*. URL: <https://www.sbi.at/de/solutions/additive-manufacturing> (besucht am 12.08.2022).
- [282] AML3D Limited. *WAAM Technology*. URL: <https://aml3d.com/technology/> (besucht am 12.08.2022).
- [283] The Lincoln Electric Company. *Additive Solutions*. URL: <https://additive.lincolnelectric.com/> (besucht am 15.08.2022).
- [284] Yamazaki Mazak UK Ltd. *Wire Arc Additive Manufacturing*. URL: <https://www.mazakeu.de/AM/> (besucht am 11.08.2022).
- [285] VLM Robotics. *Additive Manufacturing Cells*. URL: <http://www.vlm-robotics.fr/index.php/cells/#ADDITIVE> (besucht am 11.08.2022).
- [286] F. Pedregosa u. a. „Scikit-learn: Machine Learning in Python“. In: *The Journal of Machine Learning Research* (2011), S. 2825–2830. DOI: 10.5555/1953048.2078195. URL: <https://scikit-learn.org/>.
- [287] TensorFlow Developers. „TensorFlow“. In: *Zenodo* (2022). DOI: 10.5281/zenodo.4724125. URL: <https://www.tensorflow.org/>.
- [288] S. Seabold und J. Perktold. „statsmodels: Econometric and statistical modeling with python“. In: *9th Python in Science Conference* (2010). URL: <https://www.statsmodels.org/v0.12.2/index.html>.

Verzeichnis der Publikationen

Teile der vorliegenden Dissertationsarbeit wurden der Fachöffentlichkeit bereits in Publikationen vorgestellt. Nachfolgend sind die thematisch für die Arbeit relevanten Publikationen chronologisch aufgelistet:

- P1 R. T. Reisch, T. Hauser, T. Kamps und A. Knoll. „Robot Based Wire-Arc-Additive-Manufacturing System with Context-Sensitive Multivariate Monitoring Framework“. In *Procedia Manufacturing as Proceedings of FAIM 2020* (2020). DOI: 10.1016/j.promfg.-2020.10.103.
- P2 R. T. Reisch, T. Hauser, L. Lutz, M. Pantano, T. Kamps und A. Knoll. „Distance-Based Multivariate Anomaly Detection in Wire Arc Additive Manufacturing“. In *Proceedings of IEEE ICMLA 2020* (2020). DOI: 10.1109/ICMLA51294.2020.00109
- P3 R. T. Reisch. „Roboter in der additiven Fertigung“. In *VDI Magazin Technik in Bayern 02/2021 - Konzepte der Robotik* (2021). ISSN: 1610-6563
- P4 T. Hauser, R. T. Reisch, P. Breese, Y. Nalam, K. Joshi, K. Bela, T. Kamps, J. Volpp und A. Kaplan. „Oxidation in Wire Arc Additive Manufacturing of Aluminum Alloys“. In *Additive Manufacturing* (2021). DOI: 10.1016/j.addma.2021.101958
- P5 T. Hauser, R. T. Reisch, P. Breese, B. Lutz, M. Pantano, Y. Nalam, K. Bela, T. Kamps, J. Volpp und A. Kaplan. „Porosity in Wire Arc Additive Manufacturing of Aluminum Alloys“. In *Additive Manufacturing* (2021). DOI: 10.1016/j.addma.2021.101993
- P6 R. T. Reisch, T. Hauser, J. Franke, F. Heinrich, K. Theodorou, T. Kamps und A. Knoll. „Nozzle-to-Work Distance Measurement and Control for Wire Arc Additive Manufacturing“. In *Proceedings of ACM ESSE 2021* (2021). DOI: 10.1145/3501774.-3501798
- P7 T. Hauser, R. T. Reisch, T. Kamps, A. Kaplan und J. Volpp. „Acoustic emissions in directed energy deposition processes“. In *International Journal of Advanced Manufacturing Technology* (2022). DOI: 10.1007/s00170-021-08598-8
- P8 R. T. Reisch, T. Hauser, L. Lutz, A. Tsakpinis, D. Winter, T. Kamps und A. Knoll. „Context Awareness in Process Monitoring of Additive Manufacturing using a Digital Twin“. In *Journal of Advanced Manufacturing Technologies* (2022). DOI: 10.1007/s00170-021-08636-5
- P9 R. T. Reisch, L. Janisch, J. Tresselt, T. Kamps und A. Knoll. „Prescriptive Analytics - A Smart Manufacturing System for First-Time-Right Printing in Wire Arc Additive Manufacturing using a Digital Twin“. In *Procedia CIRP as Proceedings of CIRP ICME* (2023). DOI: 10.1016/j.procir.2023.06.130

- P10 R. T. Reisch, M. Pantano, L. Janisch, A. Knoll und D. Lee. „Spatial Annotation of Time Series for Data Driven Quality Assurance in Additive Manufacturing“. In *Procedia CIRP as Proceedings of CIRP ICME* (2023). DOI: 10.1016/j.procir.2023.06.129

Darüber hinaus wurde an folgenden Publikationen als Co-Autor mitgewirkt:

- P11 B. Lutz, D. Kißkalt, D. Regulin, R. T. Reisch, A. Schiffler und J. Franke. „Evaluation of Deep Learning for Semantic Image Segmentation in Tool Condition Monitoring“. In *Proceedings of IEEE ICMLA 2019* (2019). DOI: 10.1109/ICMLA.2019.00321
- P12 T. Hauser, A. Da Silva, R. T. Reisch, J. Volpp, T. Kamps und A. Kaplan. „Fluctuation effects in Wire Arc Additive Manufacturing of aluminium analysed by high-speed imaging“. In *Journal of Manufacturing Processes* (2020). DOI: 10.1016/j.jmapro.2020.05.030
- P13 B. Lutz, R. T. Reisch, D. Kißkalt, B. Avci, D. Regulin, A. Knoll und J. Franke. „Benchmark of Automated Machine Learning with State-of-the-Art Image Segmentation Algorithms for Tool Condition Monitoring“. In *Procedia Manufacturing as Proceedings of FAIM 2020* (2020). DOI: 10.1016/j.promfg.2020.10.031
- P14 T. Hauser, R. T. Reisch, S. Seebauer, A. Parasar, T. Kamps, R. Casati, J. Volpp und A. Kaplan. „Multi-Material Wire Arc Additive Manufacturing of low and high alloyed aluminium alloys with in-situ material analysis“. In *Journal of Manufacturing Processes* (2021). DOI: 10.1016/j.jmapro.2021.08.005.
- P15 M. Pantano, Q. Yang, A. Blumberg, R. T. Reisch, T. Hauser, B. Lutz, D. Regulin, T. Kamps, K. Traganos, D. Lee. „Influence of Task Decision Autonomy on Physical Ergonomics and Robot Performances in an Industrial Human–Robot Collaboration Scenario“. In *Frontiers in Robotics and AI* (2022). DOI: 10.3389/frobt.2022.943261

Verzeichnis der Studienarbeiten

Im Verlauf der vorliegenden Dissertationsarbeit wurden Studienarbeiten vom Autor dieser Arbeit ausgeschrieben und betreut. Nachfolgend sind die relevanten Studienarbeiten chronologisch aufgelistet:

- S1 A. Khaldi. „Cloud-based process optimization of additive and subtractive manufacturing through artificial intelligence“. Masterarbeit. Technische Hochschule Ulm, 2020.
- S2 K. Theodorou. „System Identification and Design of a Closed-Loop Control for Wire Arc Additive Manufacturing“. Masterarbeit. Technische Universität München, 2020.
- S3 S. Hölzel. „Analysing the Performance of Unsupervised Time Series Anomaly Detection Algorithms in the Context of Wire Arc Additive Manufacturing Processes“. Bachelorarbeit. Technische Universität München, 2020.
- S4 D. Winter. „Edge Computing in the Robot Based, Additive Manufacturing for Multivariate Data Analysis and Anomaly Detection“. Masterarbeit. Technische Universität München, 2020.
- S5 A. Parasar. „Data Driven Process Development and Optimization in Robot Based Additive Manufacturing Using Sensor Data“. Masterarbeit. Universität Paderborn, 2020.
- S6 A. Tsakpinis. „Context Sensitive Anomaly Detection in Additive Manufacturing“. Masterarbeit. Technische Universität München, 2020.
- S7 D. Huang. „Evaluation of Meta Learning Concepts for Anomaly Detection in Time Series of Process Monitoring Applications“. Bachelorarbeit. Technische Universität München, 2021.
- S8 A. Colelli. „Online Classification of Anomalies in Wire Arc Additive Manufacturing with Multivariate Sensor Data“. Masterarbeit. Technische Universität München, 2021.
- S9 A. Jamil. „Classification-based feature-detector mapping for online anomaly detection in time series data“. Masterarbeit. Technische Universität München, 2021.
- S10 K. Joshi. „Multivariate Sensor Data Analysis for Process Quality Optimization in Wire-Arc Additive Manufacturing“. Masterarbeit. Rheinisch-Westfälische Technische Hochschule Aachen, 2021.
- S11 S. Mohammed. „Closed-Loop-Control for Wire Arc Additive Manufacturing“. Masterarbeit. Hochschule Furtwangen, 2021.
- S12 S. Sternsdorf. „Conceptual Design and Evaluation of Data Structures on Edge Devices for Process Monitoring in Additive Manufacturing“. Masterarbeit. Technische Universität München, 2021.

- S13 L. Zamel. „Memory Augmented Conditional Autoencoder for Anomaly Detection“. Bachelorarbeit. Technische Universität München, 2021.
- S14 J. Taube. „Few-Shot Learning with Memory-Augmented Autoencoder for Time Series Data“. Bachelorarbeit. Technische Universität München, 2022.
- S15 D. Etkar. „Domain Adaptive Online Defect Classification for Wire Arc Additive Manufacturing“. Masterarbeit. Technische Universität München, 2022.
- S16 J. Tresselt. „Prozessoptimierung durch Smart-Process Monitoring zur Herstellung komplexer Strukturen mittels Wire-Arc Additive Manufacturing“. Masterarbeit. Hochschule Konstanz, 2022.
- S17 S. Hölzel. „Mutual Information Analysis for Autoencoders“. Semesterarbeit. Technische Universität München, 2022.
- S18 M. Schifferl. „Implementierung einer OPC UA-Kommunikation für eine WAAM-Zelle“. Bachelorarbeit. Hochschule München, 2022.