

**Detektion von Prozessstörungen beim
Laserstrahlschmelzen mittels
Online-Prozessüberwachung und
Methoden des maschinellen Lernens**

Simon Schmid

01.08.2018

Aufgabenstellung

Titel der Semesterarbeit:

Detektion von Prozessstörungen beim Laserstrahlschmelzen mittels Online-Prozessüberwachung und Methoden des maschinellen Lernen

Inv.-Nr.: 2735

Verfasser: Simon Schmid

Betreuer: Claudia Rosenkranz

Ausgabe: 09.02.2018

Abgabe: 01.08.2018

Ausgangssituation:

Die additive Fertigung bietet einzigartige Möglichkeiten die von den traditionellen Fertigungsverfahren nicht erfüllt werden können. Allerdings stellt die Wiederholbarkeit des Prozesses und das Erreichen einer gleichbleibenden Bauteilqualität einen entscheidenden Faktor dar, der die Verbreitung der Verfahren limitiert.

Eine Methode um dieses Problem zu adressieren ist die Online-Prozessüberwachung. Mit dieser werden Messdaten während des Bauprozesses aufgenommen mit denen entweder schon im Prozess Korrekturmaßnahmen mittels einer Regelung eingeleitet werden können oder nachgelagert zerstörungsfrei die Bauteilqualität beurteilt werden kann. (SPEARS & GOLD 2016)

Am Fraunhofer IGCV wird die Strahlung aus dem Schmelzbad optisch mit zwei Photodioden gemessen. Die Messdaten sollen im Rahmen des Forschungsprojekts näher AM4 Industry untersucht werden. Dabei werden Proben aus der Aluminiumlegierung Al-Si10Mg aufgebaut mit welchen der Zusammenhang zwischen den Signalcharakteristika der Photodioden, den Prozessparametern und der Bauteilqualität erfasst werden soll.

Bei der Versuchsanlage handelt es sich um eine SLM 125^{HL} des Herstellers SLM Solutions Group AG, welche mit dem den optischen Messsystem des gleichen Herstellers ausgestattet ist.

Zielsetzung:

Das Ziel dieser Arbeit ist es nach einem neuartigen auf Korrelationen basierenden Konzept ein Algorithmus zu entwerfen mit dem Aussagen über die Qualität der gefertigten Bauteile zerstörungsfrei möglich sind. Der Algorithmus soll mit Methoden des maschinellen Lernens implementiert werden. Mit dem Algorithmus soll die Detektion von Prozessstörungen möglich sein. Des Weiteren soll der Zusammenhang zwischen Signalcharakteristika der Photodioden und den Prozessparametern und -bedingungen erfasst werden.

Vorgehensweise und Arbeitsmethodik:

- Detaillierte Literaturrecherche zum Prozess des Laserstrahlschmelzens, möglichen Prozessstörungen, der Online-Prozessüberwachung und den Methoden des maschinellen Lernens
- Identifikation relevanter Prozessstörungen
- Versuchsplanung und Durchführung
- Ausarbeitung eines Konzeptes zur Anwendung der Methoden des maschinellen Lernens
- Validierung des Algorithmus

Vereinbarung:

Mit der Betreuung von Herrn cand.-Ing. Simon Schmid durch M.Sc. Claudia Rosenkranz fließt geistiges Eigentum des iwB in diese Arbeit ein. Eine Veröffentlichung der Arbeit oder eine Weitergabe an Dritte bedarf der Genehmigung durch den Lehrstuhlinhaber. Der Archivierung der Arbeit in der iwB-eigenen und nur für iwB-Mitarbeiter zugänglichen Bibliothek als Bestand und in der digitalen Studienarbeitsdatenbank des iwB als PDF-Dokument stimme ich zu.

Garching, den 01.07.2018

Prof. Dr.-Ing.
Gunther Reinhart

M.Sc.
Claudia Rosenkranz

B.Sc.
Simon Schmid

Inhalt

Aufgabenstellung	I
Abstract	VII
Abkürzungsverzeichnis	VIII
Verzeichnis der Formelzeichen	IX
1 Einleitung	1
1.1 Additive Fertigung und deren Anwendungsgebiete	1
1.2 Zielsetzung	3
1.3 Aufbau der Arbeit	4
2 Grundlagen der additiven Fertigung und des maschinellen Lernens	5
2.1 Laserstrahlschmelzen	5
2.1.1 Funktionsprinzip des Laserstrahlschmelzens	5
2.1.2 Einflussgrößen auf den Prozess des Laserstrahlschmelzens	7
2.2 Prozessparameter und deren Einfluss auf die Bauteilqualität	9
2.2.1 Laserfokus und Ausgleich der Bildfeldwölbung	9
2.2.2 Belichtungsstrategie	11
2.2.3 Laserleitung und Scangeschwindigkeit	14
2.2.4 Schichtdicke	15
2.3 Prozessstörungen und Defekte beim Laserstrahlschmelzen	16
2.3.1 Spritzerbildung	17
2.3.2 Schmauch	18
2.3.3 Balling Effekt	19
2.3.4 Defekte beim Laserstrahlschmelzen	20
2.4 Grundlagen des maschinellen Lernens	22
2.4.1 Clustering Algorithmen	24
2.4.2 Klassifikations Algorithmen und Bewertungen	28
2.4.3 Hauptkomponentenanalyse	31

3	Stand der Technik und Forschung	33
3.1	Online-Prozessüberwachung	33
3.1.1	Messfrequenzen der Sensoren	35
3.1.2	On-Axis und off-Axis Betrachtung	36
3.2	Anwendungen von Regelungskonzepten und Methoden des maschinellen Lernens beim Laserstrahlschmelzen	37
3.3	Schlussfolgerungen aus dem Stand der Technik	39
4	Material und Methoden	40
4.1	Versuchsanlage und Werkstoff	40
4.1.1	Versuchsanlage	40
4.1.2	Aluminiumlegierung AlSi10Mg	41
4.2	Online-Prozessüberwachung mit dem MPM Messsystem	41
4.2.1	Funktionsprinzip des MPM Messsystems	42
4.2.2	Messdaten aus der MPM Prozessüberwachung	43
4.3	Dichtemessungen beim Laserstrahlschmelzen	46
4.3.1	Dichtemessung nach Archimedes	46
4.3.2	Metallographische Dichtebestimmung	49
5	Versuchsplanung und -durchführung	52
5.1	Generierung von Daten zum Trainieren der Algorithmen	52
5.1.1	Statistische Versuchsplanung	52
5.1.2	Versuchsdurchführung	54
5.2	Versuche zur Validierung der Algorithmen	58
6	Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen	60
6.1	Konzept zur Implementierung der Algorithmen	60
6.1.1	Arten der Korrelation	61
6.1.2	Korrelationsmetrik zur Auswahl der Cluster	63
6.1.3	Korrelation vs. Kausalität	65
6.2	Vorverarbeitung der Messdaten	66
6.3	Feature Auswahl	70
6.4	Validierung der Cluster- und Featureauswahl	73
6.5	Trainieren und Bewerten der Klassifikationsalgorithmen	79

7 Ergebnisse und Diskussion	84
7.1 Validierung des Algorithmus mit dem Validierungsversuch	84
7.1.1 Ergebnisse aus der Metallographie	84
7.1.2 Ergebnisse des Algorithmus	86
7.1.3 Diskussion	89
7.2 Veränderung der Signale durch die Parametervariation	91
7.2.1 Untersuchung der Signaländerungen mit dem FCCCD	92
7.2.2 Einfluss der Volumenenergiedichte auf die Signale	95
7.2.3 Veränderung der Signale über den Drehwinkel und der Scanvektorlänge	97
7.2.4 Untersuchung des Bauraumeinflusses auf die Signale und die Porositäten	99
7.2.5 Fazit und weiteres Vorgehen	105
8 Zusammenfassung	107
9 Ausblick	109
9.1 Verbesserungen des Vorgehens	109
9.2 Vorstellung eines auf Ausheilung basierendes Regelungskonzeptes . . .	111
Literatur	113
Anhang	130

Tabellenverzeichnis

4.1	Zusammensetzung von AlSi10Mg (SLM2 2018)	41
5.1	Abstufungen der Parametervariationen in einem Baujob	56
5.2	Darstellung der belichteten Proben in den Schichten	56
5.3	Volumenenergiedichte und Parameterstufen im Validierungsversuch in Anlehnung an ROSENKRANZ et al. (2018)	59
6.1	Verwendete Feature sowie die Auswahl der Feature nach einer Überprü- fung der Korrelationen (2) und einer sequentiellen Rückwärtssauswahl (3)	69
A.1	Zuordnung der Probennummerierung zu den Prozessparametern beim Trainingsversuch. Da zwei Replika gefertigt wurden sind jedem Prozess- parametersatz immer zwei Nummern zugeordnet.	133
A.2	Zuordnung der Probennummerierung zu den Prozessparametern beim Validierungsversuch. Da drei Replika gefertigt wurden sind jedem Pro- zessparametersatz immer drei Nummern zugeordnet.	135

Abstract

Additive manufacturing offers unique possibilities in comparison to traditional manufacturing technologies. However reaching consistent part quality is still a crucial factor, which limits the widespread of the technology. A method for solving this problem is online process monitoring.

In this work a new on correlation based approach for developing a machine learning algorithm to detect process disturbances with online process monitoring is introduced. With this approach process disturbances can not only be detected but also be localized. For gathering data to train the algorithm a experiment with a parameter variation is performed. The trained algorithm is then validated with a separate experiment. The result of validation are a promising and could be seen as a proof of concept of this approach. Furthermore, the relationship between process parameters or conditions and signal characteristics is investigated. In this context a method was developed for estimating the shielding gas flow direction and the turbulences in the shielding gas with the measurement data of the online process monitoring system.

Abkürzungsverzeichnis

ADC	Analog Digital Converter
BIRCH	Balanced Iterative Reducing and Clustering using Hierarchies
CAD	Computer Aided Design
CCD	Charged Couple Device oder Central Composite Design
CFS	Correlation based Feature Selection
CMOS	Complementary Metal Oxid Semiconductor
CPU	Central Processing Unit
CT	Computertomographie
CURE	Clustering Using Representatives
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
DoE	Design of Experiments
IR	Infrarotes Licht
FCCCD	Face Centered Central Composite Design
FPGA	Field Programmable Gate Array
GPU	Graphics Processing Unit
HCTSA	Highly Comparative Time-Series Analysis
KNN	k Nearest Neighbour
LBM	Laser Beam Melting
ML	Machine Learning
MPM	Melt Pool Monitoring
PCA	Principal Component Analysis
PID	Proportional Integral Derivative
POD	Probability of Detection
RMSE	Root Mean Square Error
UV	Ultraviolettes Licht
VIS	sichtbares Licht
SRV	Signal-Rausch-Verhältnis
STL	Standard Transformation Language

Verzeichnis der Formelzeichen

Lateinische Zeichen

A	[–]	Transformationsmatrix
A_F	[μm^2]	Fläche eines Defekts
A_{Ind}	[%]	Anteil an Indikationen
Al	[–]	Aluminium
d_s	[μm]	Schichtdicke
C	[–]	Kovarianzmatrix
Cu	[–]	Kupfer
D	[–]	Dimension der Feature des Datensatzes
D_G	[%]	Drehzahl des E-Motors der Gaspumpe
Fe	[–]	Eisen
G	[%]	Vorhersagegenauigkeit
h	[μm]	Hatchabstand
k	[–]	Anzahl an Clustern
m_L	[g]	Masse der Probe in Luft
m_{Fl}	[g]	Masse der Probe in Flüssigkeit
Mg	[–]	Magnesium
Mn	[–]	Mangan
$MinPts$	[–]	Minimale Anzahl an Datenpunkten in einem Cluster
Ni	[–]	Nickel
n	[–]	Datenpunkt
P_A	[%]	Archimedisches bestimmte Porosität
P_M	[%]	Metallographisch ermittelte Porosität
Pb	[–]	Blei
p	[%]	statistische Signifikanz
P	[W]	Laserleistung
r_k	[–]	Korrelationskoeffizient nach Kendall Tau
r_p	[–]	Korrelationskoeffizient nach Pearson
r_s	[–]	Korrelationskoeffizient nach Spearman

Ru	$[-]$	Rundheit
Sn	$[-]$	Zinn
Si	$[-]$	Silizium
T	$[^{\circ}C]$	Temperatur
t_r	$[-]$	Anzahl der korrekt vorhergesagten Klassen
Ti	$[-]$	Titan
U	$[\mu m]$	Umfang eine Defekts
v_s	$[\frac{mm}{s}]$	Scangeschwindigkeit
w_0	$[\mu m]$	Minimaler Strahlenradius
$w(z)$	$[\mu m]$	Strahlenradius bei Fokusverschiebung z
x	$[mm]$	x-Position auf der Bauplattform
x_{unkor}	$[-]$	Unkorrigierte x-Position auf der Bauplattform
y	$[mm]$	y-Position auf der Bauplattform
y_{unkor}	$[-]$	Unkorrigierte y-Position auf der Bauplattform
z_R	$[mm]$	Rayleigh-Länge
Zn	$[-]$	Zink
z	$[mm]$	z-Verschiebung des Laserfokus oder Bauhöhe

Griechische Zeichen

γ	$[^{\circ}]$	Drehwinkel
ϵ	$[-]$	Nachbarschaftlänge des DBSCAN Algorithmus
Θ	$[-]$	Zeitkomplexität
λ	$[nm]$	Wellenlänge des Lasers
λ_{PCA}	$[-]$	Eigenwerte der Kovarianzmatrix
μ_{ADC1}	$[-]$	Mittelwert der ADC1 Photodiode
μ_{ADC2}	$[-]$	Mittelwert der ADC2 Photodiode
ρ_{Fl}	$[\frac{g}{cm^3}]$	Dichte der Flüssigkeit
$\Delta\rho_{PFl}$	$[\frac{g}{cm^3}]$	Fehler der Dichte bei Gewichtsmessung in der Flüssigkeit
$\Delta\rho_{PL}$	$[\frac{g}{cm^3}]$	Fehler der Dichte bei Gewichtsmessung in der Luft
$\Delta\rho_{Prel}$	$[\%]$	Relativfehler bei der Dichtebestimmung
$\Delta\rho_{PT}$	$[\frac{g}{cm^3}]$	Fehler der Dichte durch Temperaturablesefehler
ρ_{Werk}	$[\frac{g}{cm^3}]$	Materialdichte des Werkstoffs
ρ_P	$[\frac{g}{cm^3}]$	Dichte einer Probe

σ_{ADC1}	$[-]$	Standardabweichung der ADC1 Photodiode
σ_{ADC2}	$[-]$	Standardabweichung der ADC2 Photodiode
τ	$[-]$	Lage der Clusterzentren bei dem k-Means Algorithmus
ϕ	$[\mu m]$	Strahlendurchmesser des Lasers
Ψ	$[\frac{J}{mm^3}]$	Volumenenergiedichte

1 Einleitung

Die vorliegende Arbeit beschäftigt sich mit der Online-Prozessüberwachung beim Laserstrahlschmelzen (englisch Laser Beam Melting [LBM](#)). Es werden mit Methoden des maschinellen Lernens Algorithmen implementiert, mit denen es möglich ist aus den Prozessüberwachungsdaten die Bauteilqualität vorherzusagen. Einleitend wird zuerst die additive Fertigung und deren Anwendungsgebiete eingeführt. Anschließend erfolgt eine Darstellung der Zielsetzung und des Aufbaus dieser Arbeit.

1.1 Additive Fertigung und deren Anwendungsgebiete

Die additive Fertigung, umgangssprachlich auch als 3D-Druck bezeichnet, ist ein junges Verfahren zur Erstellung dreidimensionaler Bauteile. Bei diesen Verfahren werden Bauteile auf der Basis eines dreidimensionalen Computermodells in physische Bauteile umgesetzt. Dies geschieht im Gegensatz zu konventionellen Fertigungsverfahren durch schichtweises Aufeinanderfügen von Werkstoff. (GEBHARDT 2014, S. 4-5)

Bis heute hat die additive Fertigungstechnologie eine rasante Entwicklung durchlaufen. Als erstes additives Verfahren wurde 1986 die Stereolithographie zum Patent angemeldet. Der für dieses Verfahren verwendete Werkstoff ist flüssiges Kunstharz. Damals waren die additiven Fertigungsverfahren noch sehr teuer und nicht weit verbreitet. Im 21. Jahrhundert sanken die Kosten durch den technischen Fortschritt jedoch enorm, wodurch die Verfahren den Einzug in viele Industriebereiche fanden. (ATTARAN 2017) In den 90er Jahren wurden additive Verfahren mit metallischem Pulver als Grundwerkstoff entwickelt. Ein pulverbettbasiertes additives Verfahren ist zum Beispiel das Laserstrahlschmelzen. Die erste Anlage für dieses Verfahren kam 1994 auf den Markt. (SEHRT 2010)

Ein großer Vorteil additiver Verfahren sind die Designfreiheiten, die sie ermöglichen. Es können komplexe und belastungsorientierte Geometrien hergestellt werden, die mit konventionellen Herstellungsverfahren, wie Gießen und Zerspanen, nicht herstellbar

sind. (KRAUSS 2016, S. 1) Ein Beispiel hierfür sind gekrümmte Hohlkörper und Kanalstrukturen in Bauteilen. (GEBHARDT 2014, S. 1) Zudem können mit additiven Verfahren Werkstoffe zu Multimaterialbauteilen kombiniert werden. Des Weiteren ist eine erhebliche Gewichtsreduktion der Bauteile und somit auch eine erhöhte Ressourceneffizienz durch Materialeinsparung möglich. (KRAUSS 2016, S. 2) Insgesamt liegt der wirtschaftliche Vorteil additiver Verfahren in der Produktion von komplexen Bauteilen in kleiner Stückzahl. (KRAUSS et al. 2011) Das liegt daran, dass keine Formen und Werkzeuge bei der Fertigung benötigt werden, und somit die Fertigungskosten bei steigender Stückzahl annähernd konstant bleiben. (ZÄH 2006, S. 5)

Additive Fertigungsverfahren werden in verschiedenen Branchen eingesetzt. Ein Darstellung der Marktanteil der einzelnen Branchen ist in Abbildung 1.1 gegeben. Im Fahrzeugbau und in der Luftfahrtindustrie werden neben dem Prototypenbau bereits erste Serienbauteile additiv gefertigt. (KRAUSS 2016, S. 1) In der Medizintechnik finden additive Verfahren vor allem in der Dentalprothetik, zum Beispiel zur Herstellung von Zahnkronen, Anwendung. (VDI-GESELLSCHAFT PRODUKTION UND LOGISTIK 2016, S. 1)

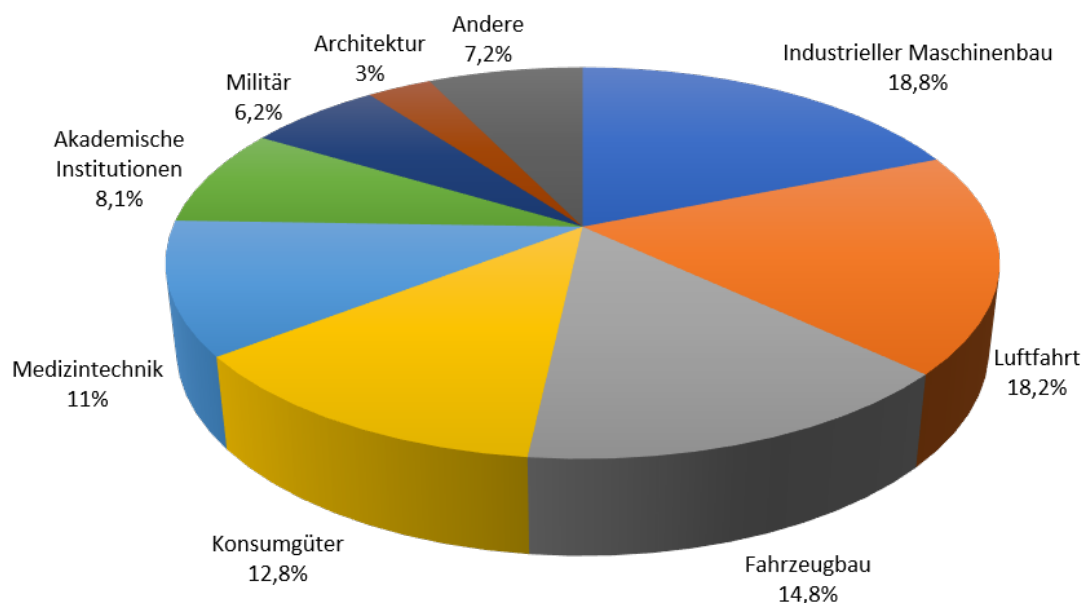


Abbildung 1.1: Marktanteile der Branchen in der additiven Fertigung in Anlehnung an WOHLERS & CAFFREY (2017)

1.2 Zielsetzung

Der Prozess des Laserstrahlschmelzens ist sehr komplex und unterliegt vielen Einflussgrößen. Nach SPEARS & GOLD (2016) gibt es über 50 Prozessparameter, welche die Bauteilqualität beeinflussen. Zudem unterliegt der Prozess vielen Störungen, die systematischer oder zufälliger Natur sein können. (BAYERLEIN & ZÄH 2016) Deshalb ist es nur bedingt möglich den Prozess im Bezug auf die entstehende Bauteilqualität zu modellieren oder analytisch zu beschreiben. Um dennoch Aussagen über die Bauteilqualität treffen zu können, oder um während des Bauprozesses auf Prozessabweichungen zu reagieren, wird der Prozess von Messsystemen überwacht. Die analysierten Signale können die Grundlage für eine Regelung bilden mit der schon während des Bauprozesses auf Abweichungen reagiert werden kann. (SPEARS & GOLD 2016) Das generelle Vorgehen bei der Online-Prozessüberwachung ist in Abbildung 1.2 dargestellt. In dieser Arbeit, welche im Rahmen des Forschungsprojekts AM4 Industry am Fraunhofer IGCV verfasst wurde, wird das Online-Prozessüberwachungsmesssystem (englisch Melt Pool Monitoring **MPM**) der Firma SLM Solutions Group AG verwendet. Das Ziel der Arbeit ist es ein Algorithmus zu implementieren, welcher den Zusammenhang zwischen Signal- und Prozesscharakteristika aus dem Messsystem und der Bauteilqualität beschreibt. Dies geschieht mittels Methoden und Algorithmen des maschinellen Lernens. Die Algorithmen werden auf der Grundlage von Korrelationen zwischen den Prozess- bzw. Signalcharakteristika, den Prozessparametern und der Bauteilqualität implementiert.

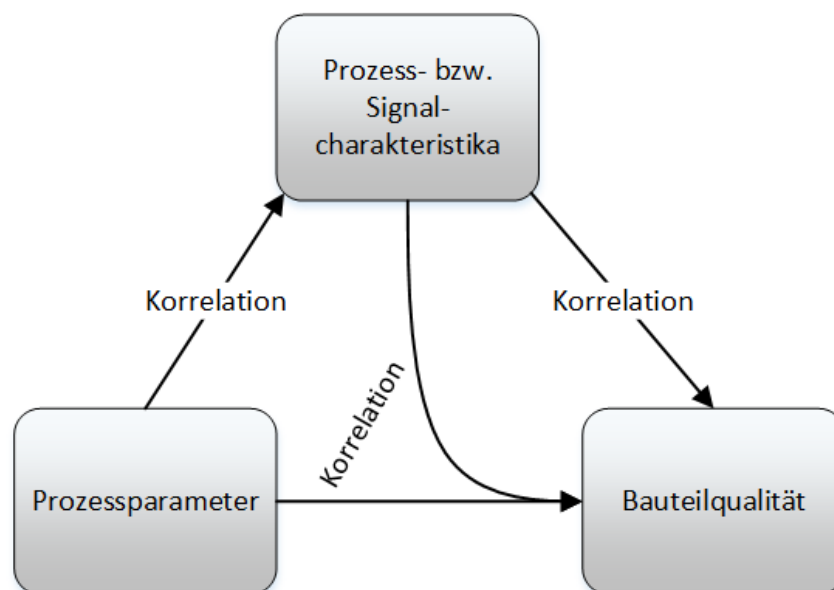


Abbildung 1.2: Generelles Vorgehen bei der Online-Prozessüberwachung in Anlehnung an SPEARS & GOLD (2016)

1.3 Aufbau der Arbeit

Die Struktur der Arbeit beschreibt sich wie folgt:

Zunächst werden die Grundlagen der additiven Fertigung und des Laserstrahlschmelzprozesses erläutert. Hierbei wird auf die Einflussgrößen auf den Prozess, die Prozessparameter und die Prozessstörungen eingegangen. Danach werden die Grundlagen des maschinellen Lernens eingeführt. Hierbei wird auf die in dieser Arbeit verwendeten Methoden und Algorithmen eingegangen. Anschließend erfolgt eine Darstellung des Stand der Technik der Online-Prozessüberwachung. Ferner wird die Versuchsanlage und das Messsystem beschrieben sowie die verwendeten Analyseverfahren zu Dichtebestimmung. Danach folgt die Beschreibung der Versuchsplanung und Durchführung. Die Versuche in dieser Arbeit sind in zwei Abschnitte aufgeteilt. Der erste dient zur Generierung von Daten zum Trainieren des Algorithmus und mit dem zweiten wird der Algorithmus validiert. Des Weiteren wird das Konzept, mit dem die Algorithmen des maschinellen Lernens angewendet wurden, eingeführt. Die Ergebnisse aus den Algorithmen bei dem Trainings- und Validierungsversuchen werden anschließend dargestellt und diskutiert. Zudem folgt eine Untersuchung des Zusammenhangs zwischen Prozessparametern und -bedingungen und den Signalcharakteristika der Photodioden. Zum Schluss wird das Ergebnis dieser Arbeit zusammengefasst und ein Ausblick auf weitere Arbeiten gegeben.

2 Grundlagen der additiven Fertigung und des maschinellen Lernens

Ein grundlegendes Verständnis für das Laserstahlschmelzverfahren ist essentiell um die dabei Einflüsse von entstehenden Prozessstörungen zu verstehen. In diesem Kapitel wird zuerst das Laserstrahlschmelzverfahren beschrieben. Anschließend erfolgt eine Erklärung der wichtigsten Prozessparameter und Prozessstörungen. Des Weiteren werden die Grundlagen des maschinellen Lernens eingeführt.

2.1 Laserstrahlschmelzen

Eine Einteilung des Laserstrahlschmelzens in die Fertigungsverfahren erfolgt nach DIN 8050 (DIN 8050). Hierbei wird das Verfahren der Hauptgruppe 4 (Fügen) und der Untergruppe Fügen durch Schweißen zugeordnet. (KRAUSS 2016, S. 7) Eine Klassifizierung der additiven Verfahren wird von GEBHARDT (2013, S. 92) gegeben. Das Laserstahlschmelzen wird hier als Aufschmelzverfahren mit pulverförmigen Ausgangsmaterial klassifiziert. Additives Schmelzen ist das am häufigsten in modernen Anlagen umgesetzte Verfahren. (VDI-Richtlinie 3405 Blatt 2). In diesem Kapitel wird zunächst das Funktionsprinzip des Laserstrahlschmelzens beschrieben. Anschließend erfolgt eine Darstellung der wichtigsten Einflussgrößen auf den Prozess.

2.1.1 Funktionsprinzip des Laserstrahlschmelzens

Das Laserstrahlschmelzen ist ein zyklischer Prozess, der so lange wiederholt wird bis das Bauteil aufgebaut ist. Eine schematische Darstellung des Funktionsprinzips des Laserstrahlschmelzens ist in [Abbildung 2.1](#) gegeben. Bei bestmöglicher ProzessparameterEinstellung werden beim Laserstrahlschmelzen Materialdichten von nahezu 100% der Werkstoffdichte erreicht. Die Festigkeit der durch Laserstrahlschmelzen gefertigten

Bauteile ist geringer als beim Schmieden und höher als beim Gießen. (TROSCH et al. 2016)

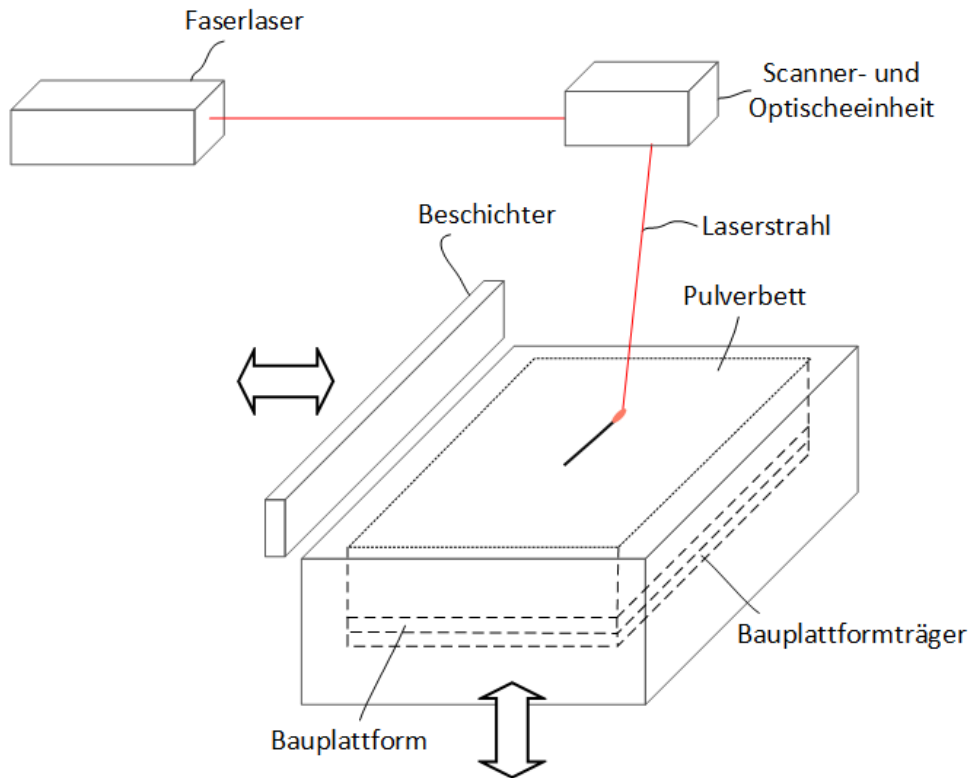


Abbildung 2.1: Schematische Darstellung des Funktionsprinzips des Laserstrahlschmelzens in Anlehnung an GRASSO & COLOSIMO (2017)

Vor Beginn des Bauprozesses wird die Bauplattform, welche an dem Bauplattformträger angeschraubt ist, auf die Bauplattformvorheiztemperatur aufgeheizt. Außerdem wird der Bauraum mit einem Schutzgas geflutet, um Oxidation oder Nitrierung zu vermeiden und Prozessnebenprodukte abzutransportieren. Als Schutzgas wird ein Inertgas, je nach Werkstoff Stickstoff oder Argon, verwendet. Der Prozess besteht aus drei Schritten. Im ersten Schritt wird Metallpulver mit der Beschichter Klinge auf der Bauplattform verteilt. Damit der Schichtauftrag vollständig ist wird mehr Pulver als notwendig verwendet. Das überschüssige Pulver wird in den Überlaufbehälter geschoben. Das Pulver besteht üblicherweise aus $10\ \mu\text{m}$ bis $60\ \mu\text{m}$ großen, gasverdünsten, runden Pulverkörnern. (J. P. KRUTH et al. 2005) Erreicht der Beschichter die linke oder rechte Endposition, wie in Abbildung 2.1 dargestellt, beginnt der Prozessschritt Belichtung. Dabei wird das Pulver an den Stellen lokal aufgeschmolzen, an denen das Bauteil aufgebaut wird. Um ein dichtes Bauteil zu erhalten wird die schon verfestigte Schicht darunter teilweise mitaufgeschmolzen. Die Informationen über die Belichtungsstrategie wird von der Anlagensteuerung

an die Scannereinheit übergeben, die den Laser dann entsprechend mit zwei Spiegeln umlenkt. Die Spiegel werden auch Galvanometer-Spiegel genannt. (GEBHARDT 2013, S. 81) Zudem wird durch die optische Einheit der Laserstrahl auf die Bauplattform fokussiert. Nach der Belichtung wird die Bauplattform um eine Schichtdicke heruntergefahren. Die Schichtdicken der Pulverschicht liegen typischerweise zwischen $20\ \mu\text{m}$ und $50\ \mu\text{m}$. (LADEWIG et al. 2016) Ein Charakteristikum des Prozesses ist, dass die Wärme hauptsächlich durch das schon verfestigte Material abgeführt wird. Das liegt daran, dass der Wärmeleitkoeffizient des Pulvers um zwei Größenordnungen geringer als der des verfestigten Material ist. (SCHLEIFENBAUM 2012, S. 26)

Nachdem das Bauteil fertig aufgebaut ist, wird das nicht aufgeschmolzene Pulver abgesaugt. Dieses kann nach einer Aufbereitung wiederverwendet werden. Das fest mit der Bauplatte verbundene Bauteil wird aus dem Bauraum entfernt. Bauteil und Bauplatte werden mittels Sägen oder Drahterodieren voneinander getrennt. Mögliche Nachbearbeitungsschritte sind das Entfernen der Stützkonstruktionen, Wärmebehandlungen oder eine spanende Nachbearbeitung. (MEINERS 1999) (SEHRT 2010)

2.1.2 Einflussgrößen auf den Prozess des Laserstrahlschmelzens

Für ein grundlegendes Verständnis des Laserstrahlschmelzprozesses ist es wichtig die Einflussgrößen auf den Prozess sowie deren Auswirkung auf die Bauteilqualität im Vorfeld zu identifizieren. In Abbildung 2.2 ist ein Diagramm in Anlehnung an ein Ishikawa-Diagramm (5-M Methode) dargestellt. Hierbei wird eine Auswahl der für die Arbeit relevanten Einflussgrößen getroffen. Die Einflussgrößen werden den fünf Bereichen Mensch, Maschine, Mitwelt, Material und Methode zugeordnet.

Zu den vom Menschen abhängige Einflussgrößen gehören die Datenvorbereitung und der Rüstvorgang. Zur Datenvorbereitung gehören das Erstellen des 3D-Bauteils, die Konvertierung in das **STL** -Format (Standard Transformation Language) und das Anfügen von Stützkonstruktionen. Die menschlichen Einflüsse hängen von der Erfahrung und Ausbildung des Mitarbeiters ab.

Zu den Hauptzweig Maschine gehört die Prozessgasführung. Während des Bauprozesses strömt Schutzgas von der Einlass zur Auslassdüse. Der Schutzgasstrom transportiert Prozessnebenprodukte von der Schweißstelle ab und schützt das Material vor Oxidation. (LADEWIG et al. 2016) Das Partikelhaltige Schutzgas wird anschließend durch ein Prozessgasfiltersystem gereinigt und dem Prozess wieder zugeführt. Die Schutzgasströmung kann unterschiedlich Strömungsrichtungen und Strömungsgeschwindigkeiten

über den Bauraum aufweisen. (FERRAR et al. 2012) Zudem sind der Laser, die optische Einheit und die mechanischen Komponenten, wie zum Beispiel der Beschichter, Teil der Maschineneinflussgrößen. Die maschinellen Daten, die in dieser Arbeit verwendeten Anlage SLM 125^{HL}, sind in Kapitel 4.1.1 gegeben.

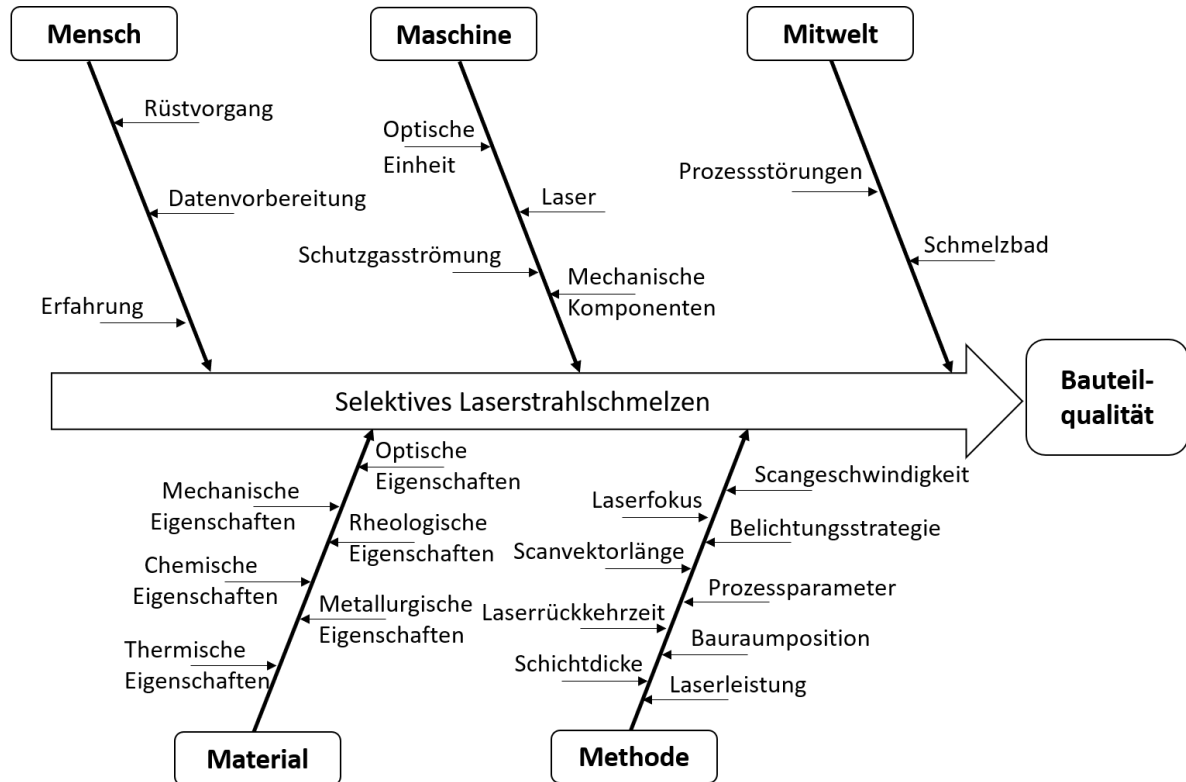


Abbildung 2.2: Einflussgrößen auf den Laserstrahlschmelzprozess in Anlehnung an REHME (2010, S.53) und HESS (2015)

Zu den Hauptzweigen Mitwelt zählen Einflüsse des Schmelzbades. Diese sind einerseits die Dynamik und andererseits die Ausbreitung oder Geometrie des Schmelzbades. Bei einer zu hohen Dynamik des Schmelzbades kommt es zu Prozessstörungen wie die Spritzerbildung, welche einen negativen Einfluss auf die Bauteilqualität haben.

Der Zweig Material beschreibt die Eigenschaften des Pulverwerkstoffs und des verfestigten Materials. In dieser Arbeit wird als Werkstoff ausschließlich die Aluminiumlegierung AlSi10Mg verwendet. Eine genauere Charakterisierung des Werkstoffs erfolgt in Kapitel 4.1.2.

Zu den Einflussgrößen, die von der Methodik abhängig sind, gehören zum einen Prozessparameter, wie Laserleistung und Scangeschwindigkeit, und zum anderen verfahrensspezifische Größen, wie die Laserrückkehrzeit oder die Bauraumposition. Die Laserrückkehrzeit beschreibt die Zeitspanne zwischen der Belichtung eines Bauteils in

zwei aufeinanderfolgenden Schichten. Im Folgenden wird eine Auswahl der Prozessparameter und deren Einfluss auf die Bauteilqualität genauer erläutert.

2.2 Prozessparameter und deren Einfluss auf die Bauteilqualität

Beim Laserstrahlschmelzen gibt es über 50 Prozessparameter, welche die Bauteilqualität beeinflussen. Diese Parameter müssen entweder vor dem Prozess festgelegt werden oder können während des Bauprozesses geändert werden. Eine Möglichkeit der Änderung der Prozessparameter während des Bauprozesses bildet die Grundlage für eine Regelung. Oft haben schon kleine Variationen der Prozessparameter einen erheblichen Einfluss auf die Bauteilqualität. Für das Erreichen einer guten Bauteilqualität ist ein optimales Zusammenspiel von Prozess- und Materialparametern essentiell. (SPEARS & GOLD 2016) Nach REHME & EMMELMANN (2005) stellen die Parameter Laserfokus, Belichtungsstrategie, Laserleistung, Scangeschwindigkeit, Schichtdicke, Hatchabstand und Belichtungsstrategie die wichtigsten kontrollierbaren Einflussgrößen auf die Bauteilqualität dar. In diesem Kapitel werden diese Prozessparameter genauer betrachtet.

2.2.1 Laserfokus und Ausgleich der Bildfeldwölbung

Im Allgemeinen ist bei einem größeren Laserfokus die Spotgröße des Lasers auf der Bauplattform größer. Das führt zu einem geringeren Energieeintrag pro Fläche. Deshalb ist es wichtig einen gleichbleibenden Laserfokus über den Bauprozess und auf der gesamten Bauplattform zu gewährleisten. Ohne eine entsprechende Fokussiereinheit würde es zu einer Defokussierung des Laserlichts über die Bauplattform kommen. Das liegt an folgenden Zusammenhang.

Der Laser wird durch zwei orthogonal zueinander ausgerichtete Spiegel, den Scanner, in x und y Richtung abgelenkt. Ohne eine weitere Fokussiereinheit würde wegen den unterschiedlichen Längen des optischen Weges der Fokus über den Bauraum einen Kugelmantel beschreiben, die sogenannte Bildverwölbung. Im Zentrum des Bauraums ist der Fokus scharf und zum Rand hin zunehmend unscharf. (GEBHARDT 2013, S. 81)

In der Industrie sind zwei Varianten in Anwendung um diesen Fehler auszugleichen. Die etabliertere Variante ist die Fokussierung über eine F-Theta Linse. Diese erzeugt den

Brennpunkt außerhalb der optischen Achse. Der Fokus bleibt damit mit jeder beliebigen Ablenkung in Bauplattformebene. Alternativ kann der Fokussierfehler durch eine Linse mit beweglichem Objektiv, den sogenannten Vario-Scan, ausgeglichen werden. (SCHLEIFENBAUM 2012, S. 41-42) Diese Variante wird auch als Fokusregelung bezeichnet. (RICHTER 2017) Die in dieser Arbeit verwendete Anlage SLM 125^{HL} nutzt auch eine solche Fokusregelung. Es sei darauf hingewiesen, dass zwar die z-Verschiebung ausgeglichen wird, es aber trotzdem zu einer Verzeichnung des Bildes über den Bauraum kommt. Das bedeutet, dass der Laserspot zum Rand des Bauraums hin eine elliptische Form annimmt, aber trotzdem im Fokus ist. (RICHTER 2017)

In der Praxis wird die Intensitätsverteilung eines Laserstrahls meist über ein Gaußsches Strahlenbündel angenähert. Wegen der Einfachheit dieses Modells wird es auch in dieser Arbeit verwendet. (KÜHLKE 2011, S. 225)(Z. LI et al. 2018) In Abbildung 2.3 ist ein Gaußstrahl schematisch dargestellt. Die Variable z ist die z Verschiebung und bestimmt den Strahlenradius $w(z)$ des Laserspots in der z-Achse. Sowohl eine positive als auch eine negative z-Verschiebung führt zu einem größeren Strahlenradius $w(z)$. Der Strahlendurchmesser wird mit ϕ bezeichnet.




Abbildung 2.3: Schematische Darstellung des Gaußstrahls in Anlehnung an MESCHEDE (2008, S. 50)

Bei $z = 0$ gibt w_0 den minimalen Strahlenradius an und bei der Rayleigh-Länge z_R nimmt der Strahlenradius den Wert $\sqrt{2}w_0$ an. In Abbildung 2.3 rechts ist exemplarisch die Intensitätsverteilung bei einer positiven z-Verschiebung skizziert. Im Allgemeinen verläuft die Intensität über den Radius nach der Gaußschen Glockenkurve. Zudem sind die Wellenfronten skizziert, die von $z = 0$ als Punktquelle ausgehen. (KÜHLKE

2011, S. 225-229) In Formel 2.1 ist der Zusammenhang zwischen der Wellenlänge des Laserlichts λ der Rayleigh-Länge z_R und dem minimalen Strahlenradius w_0 beschrieben. (MESCHÉDE 2008, S. 50)

$$w_0 = \sqrt{\frac{\lambda \cdot z_R}{\pi}} \quad (2.1)$$

Formel 2.2 gibt die Veränderung des Strahlenradius über die z-Verschiebung wieder.

$$w(z) = w_0 \cdot \sqrt{1 + \left(\frac{z}{z_R}\right)^2} \quad (2.2)$$

2.2.2 Belichtungsstrategie

Durch die Belichtungsstrategie wird festgelegt auf welche Weise der Laser die Bauplattform abfährt. Es sind verschiedene Belichtungsstrategien möglich. Diese können zum Beispiel die Schachbrettbelichtung (MASOOMI et al. 2017), die Streifenbelichtung (HESS 2015) oder die Linienbelichtung (LOUVIS et al. 2011) sein. In dieser Arbeit wird ausschließlich die Linienbelichtung verwendet. Bei dieser wird das Bauteil, wie in Abbildung 2.4 dargestellt, nacheinander von einzelnen Scanvektoren in alternierender Richtung belichtet. Bevor der Innenbereich belichtet wird, werden zwei Konturen, die Randkontur und die Füllkontur, geschweißt. Wie in Abbildung 2.4 zu sehen werden die

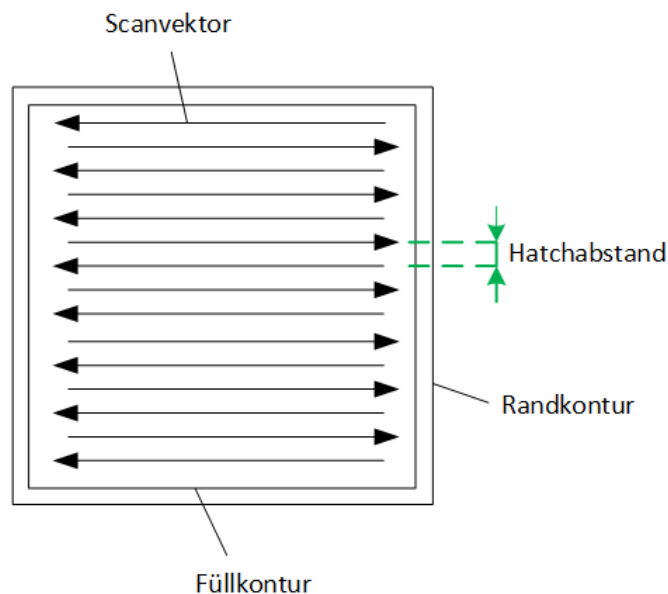


Abbildung 2.4: Schematische Darstellung der Belichtungsstrategie Linienbelichtung in Anlehnung an LOUVIS et al. (2011)

einzelnen Schweißspuren als Scanvektoren bezeichnet. Der Hatch- oder Spurbabstand h definiert den Abstand zwischen zwei Scanvektoren.

Um ein dichtes Gefüge zu erreichen sollte die Nebenspur mitaufgeschmolzen werden. Deshalb muss der Hatchabstand entsprechend eingestellt werden. Bei zu großen Hatchabständen ist der Überlappbereich der Scanspuren zu klein, was zu unzureichenden Aufschmelzen des Pulverwerkstoffs führt und zu einer geringeren Bauteildichte. Bei zu geringem Hatchabstand kommt es zu Verdampfungen und einer höheren Dynamik im Schmelzbad. (JUNFENG & ZHENGYING 2017) Dies führt wiederum zu einer höheren Oberflächenrauigkeit und einer geringeren Dichte. (XIA et al. 2016)

Zudem wird in der in dieser Arbeit verwendeten Belichtungsstrategie das sogenannte Skywriting angewandt. Durch das Skywriting wird die Massenträgheit der Scanner Spiegel kompensiert. (MANCISIDOR et al. 2016) Der Laserfokuspunkt kehrt nach der Belichtung eines Scanvectors nicht unmittelbar um, sondern überstreicht einen Wendekreis im ausgeschalteten Zustand mit konstanter Geschwindigkeit. Dadurch finden keine Abbrems- oder Beschleunigungsvorgänge der Scannereinheit während der Belichtung statt. (KRAUSS 2016, S.108)

Einen Einflussparameter innerhalb der Belichtungsstrategie stellt der Hatch- oder Drehwinkel γ dar. In Abbildung 2.5 rechts ist die positive Drehrichtung des Drehwinkels γ , welche auf das in dieser Arbeit verwendete Koordinatensystem bezogen ist, dargestellt. γ nimmt Werte zwischen 1° und 360° an. Die Scanrichtung der einzelnen Schweißspu-




Abbildung 2.5: links: Drehung der Scanrichtung in jeder Schicht. rechts: Koordinatensystem mit positiver Drehrichtung und übersprungenem Drehwinkelbereich in Anlehnung an ROSENKRANZ et al. (2018)

ren wird bei dem Standardparameter nach jeder Schicht um den Primzahlwinkel 67° gedreht. Dies ist in Abbildung 2.5 links dargestellt. Bei einer Drehung der Scanvektoren jeder Schicht um 67° wiederholen sich die Drehwinkel γ erst nach 360 Schichten. Eine Drehung der Scanrichtung zwischen den einzelnen Schichten wird verwendet um anisotropes Materialverhalten zu verhindern und um durch eine Reduktion der Eigenspannungen die Festigkeit zu erhöhen. Anisotropie führt zu einer Verschlechterung der mechanischen Eigenschaften des gesamten Bauteils. (DIMTER et al. 2007) Nach HANZL et al. (2015) nimmt die Isotropie des Bauteils in der x-y Ebene mit Anzahl an Schichten, bei der sich ein Drehwinkel wiederholt, zu. Anisotropes Materialverhalten tritt allerdings trotzdem zwischen der Aufbaurichtung (z) und der Bauebene (x-y) auf.

Nach DOMRÖSE et al. (2013) beeinflussen Drehwinkeln, bei denen der Laser in der Strömungsrichtung der Schutzgasströmung schweißt, die Bauteilqualität negativ. Das liegt daran, dass Prozessnebenprodukte dann in den Strahlengang des Lasers gelangen. (ANWAR & PHAM 2017) Dadurch kommt es zu einer Defokussierung des Laserlichts. Dieser Zusammenhang ist in Abbildung 2.6 dargestellt.

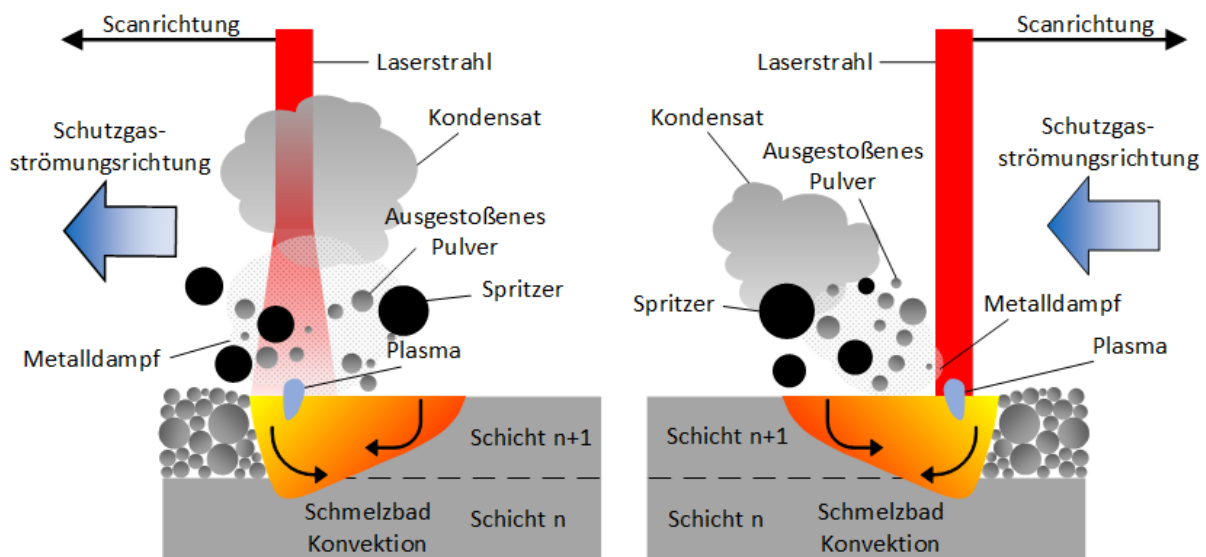


Abbildung 2.6: links: Defokussierung des Laserlichts beim Schweißen in Schutzgasströmungsrichtung. rechts: keine Defokussierung beim Schweißen entgegen der Schutzgasströmungsrichtung in Anlehnung an ROSENKRANZ et al. (2018)

Deshalb werden bei dem IGCV Standardparametersatz Drehwinkel zwischen $81,5^\circ$ - $98,5^\circ$ und $261,5^\circ$ - $278,5^\circ$ übersprungen. Der übersprungene Bereich ist in Abbildung 2.5 rechts dargestellt. Die negative x-Richtung entspricht der Strömungsrichtung des Schutzgases. Das heißt, wenn aufgrund der Drehwinkeländerung ein Winkel in dem zu überspringenden Bereich gefertigt werden soll, springt der Drehwinkel von dem Winkel

der im übersprungenen Bereich gefertigt werden soll um 17° ¹ und den Winkel den die Schichten zueinander gedreht werden. Dieser Zusammenhang wurde im Rahmen dieser Arbeit experimentell ermittelt.

2.2.3 Laserleitung und Scangeschwindigkeit

Der Energieeintrag in das Bauteil hängt hauptsächlich von der Scangeschwindigkeit v_s und der Laserleistung P ab. Die Scangeschwindigkeit beschreibt die Vorschubgeschwindigkeit des Lasers bei der Belichtung. Durch die Scangeschwindigkeit wird die Verweildauer des Lasers an einer bestimmten Position im Bauraum festgelegt. Im Allgemeinen führt sowohl ein zu hoher als auch ein zu geringer Energieeintrag zu schlechter Bauteilqualität. (SPEARS & GOLD 2016) Generell wird eine möglichst hohe Dichte der Bauteile bei einer möglichst geringen Bauzeit angestrebt. Deshalb müssen Scangeschwindigkeit und Laserleistung optimal aufeinander abgestimmt werden. In Abbildung 2.7 ist das Prozessfenster für AlSi10Mg nach KEMPEN, THIJS, YASA et al. (2011) dargestellt.

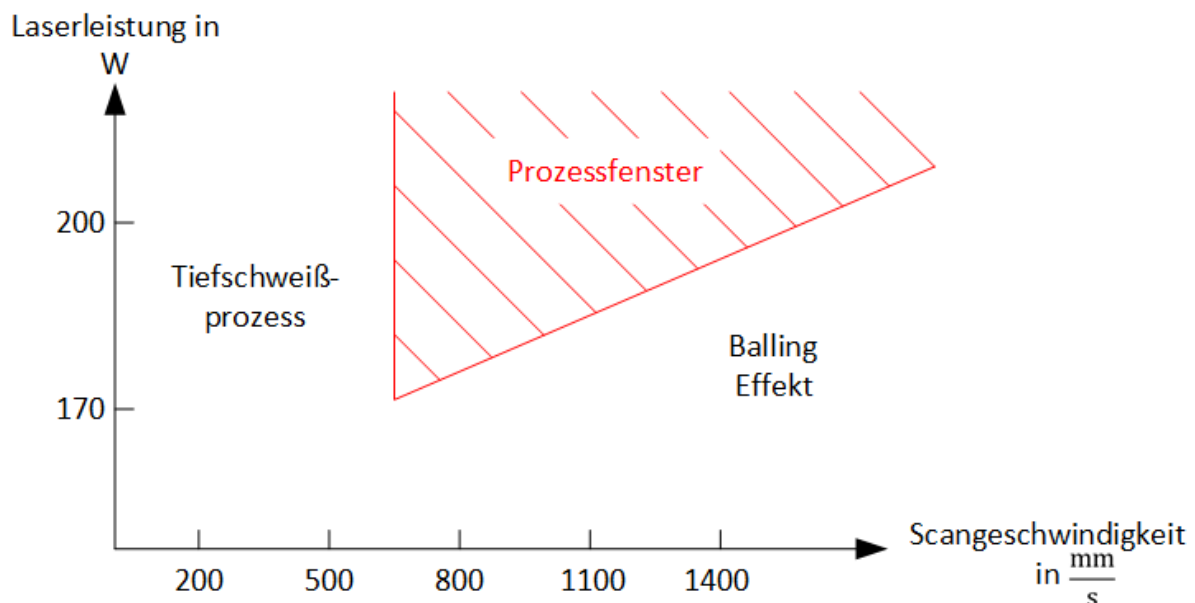


Abbildung 2.7: Prozessfenster der Laserleistung und Scangeschwindigkeit für AlSi10Mg in Anlehnung an KEMPEN, THIJS, YASA et al. (2011)

In KEMPEN, THIJS, YASA et al. (2011) wurde das Prozessfenster für die Scangeschwindigkeit und Laserleistung von AlSi10Mg mittels einzelner Scanvektoren und einem

¹ 17° entspricht der Winkelspannweite des übersprungenen Bereichs.

Strahlendurchmesser ϕ von $150 \mu\text{m}$ bestimmt. Im Bereich hoher Scangeschwindigkeit und geringer Laserleistung kommt es zu dem sogenannten Balling Effekt. Dabei entstehen große Kugeln auf der Oberfläche. Der Balling Effekt wird in Kapitel 2.3.3 näher betrachtet. Bei einer geringeren Scangeschwindigkeit und einer hohen Laserleistung geht der Prozess vom Wärmeleitungsschweißen in das Tiefschweißen über. (HESS 2015) Beim Tiefschweißen bildet sich im Gegensatz zum Wärmeleitungsschweißen eine Dampfkapillare aus. Durch die Dampfkapillare, das sogenannte Keyhole, kommt es zu einer höheren Strahlungsabsorption und die Einschweißtiefe steigt somit. Allerdings ist der Tiefschweißprozess instabiler und es werden mehr Spritzer gebildet. (KING et al. 2014) Kollabiert das Keyhole kommt es oft zu Porenbildung im Material. (ELMESALAMY 2013, S. 84)

2.2.4 Schichtdicke

Das Einstellen der Schichtdicke d_s stellt einen Kompromiss zwischen benötigter Bauzeit und erreichbarer Bauteilqualität dar. Zudem sind Geometrien in Aufbaurichtung nur auflösbar wenn ihre Abmessung kleiner als die Schichtdicke ist. (MEINERS 1999)

Es sei darauf hingewiesen, dass es durch das Aufschmelzen des Pulvers zu einer Volumenverkleinerung des Werkstoffs kommt und sich eine kleinere Schichtdicke, die so genannte effektive Schichtdicke, einstellt. Dadurch wird die effektive Schichtdicke der darauffolgenden Schicht erhöht, da das Pulver mit der Anlagenschichtdicke aufgetragen wird. (SPIERINGS & LEVY 2009) Nach sechs bis zehn Pulveraufträgen stellt sich ein konstanter Wert für die effektive Schichtdicke ein. (MEINERS 1999)

Nach GU & SHEN (2008) wird beim Schmelzprozess häufig Luft, welche zuvor zwischen den Pulverpartikel oder im Werkstoff gelöst war, im verfestigten Material eingeschlossen. Bei einer geringeren Schichtdicke und sonst gleichen Parametern wird mehr von dem Pulver und der darunter liegenden Schicht aufgeschmolzen. Dadurch können eingeschlossene Luftblasen besser aufsteigen. Somit wird bei einer geringeren Schichtdicke in der Regel eine höhere Bauteildichte erreicht. (GU & SHEN 2008)

Um den Energieeintrag in das Bauteil auf das Volumen des aufzuschmelzenden Materials zu beziehen wird von MEINERS (1999) folgende Formel vorgeschlagen. Die Volu-

menenergiedichte Ψ wird mit den Prozessparametern Laserleistung P , Hatchabstand h , Scangeschwindigkeit v_s und Schichtdicke d_s berechnet.

$$\Psi = \frac{P}{d_s h v_s} \quad (2.3)$$

2.3 Prozessstörungen und Defekte beim Laserstrahlschmelzen

Sowohl bei dem Laserstrahlschmelzen als auch beim Laserstrahlschweißen² entstehen beim Schweißprozess Prozessnebenprodukte wie Spritzer und Schmauch. Beim Laserstrahlschmelzen kommt es zusätzlich zu pulverbettbasierten Nebenprodukten. Zu diesen gehört Pulver, das aus der Umgebung des Schmelzbades ausgestoßen wird. In Abbildung 2.8 ist eine Darstellung der Prozessnebenprodukte beim Laserstrahlschmelzen gegeben.

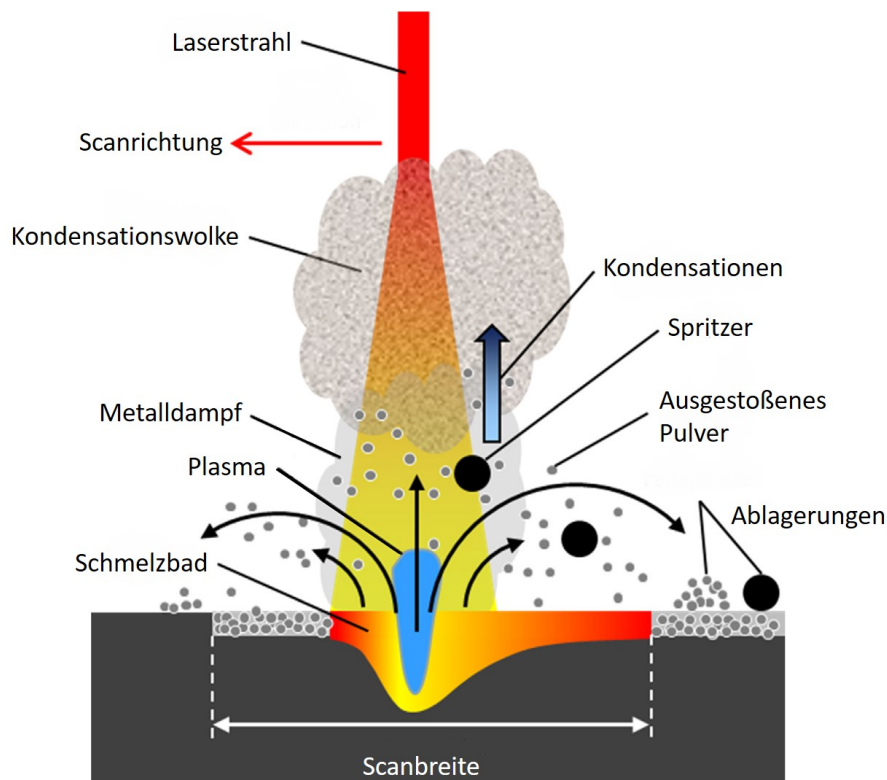


Abbildung 2.8: Schematische Darstellung der Prozessnebenprodukte beim Laserstrahlschmelzen in Anlehnung an LADEWIG et al. (2016)

²Das Laserstrahlschweißen ist ein dem Laserstrahlschmelzen verwandtes Verfahren. Hierbei werden metallische Bauteile durch örtlich begrenzten Schmelzfluss vereinigt. Dabei werden die Materialien mit einem Laser aufgeschmolzen.

Die Prozessnebenprodukte können sich an der Oberfläche des Pulverbetts anlagern und bei erneuter Belichtung des Prozess stören, da sie zu einer lokalen Schichtdicken-erhöhung führen. Die Prozessnebenprodukte sind die Ursache für einige der auftretenden Prozessstörungen. Der Abtransport der Prozessnebenprodukte erfolgt durch die Schutzgasströmung. (LADEWIG et al. 2016) In diesem Kapitel wird näher auf die Prozessstörungen Spritzerbildung, Schmauch und den Balling Effekt eingegangen. Für eine umfassendere Beschreibung möglicher Prozessabweichungen und Störungen wird auf BAYERLEIN & ZÄH (2016) verwiesen. Im Allgemeinen können Prozessstörungen zur Defektbildung führen. Auf die beim Laserstahlschmelzen auftretenden Defektarten wird in Kapitel 2.3.4 eingegangen.

2.3.1 Spritzerbildung

Wegen den hohen Energiedichten im Fokuspunkt des Laser wird die Verdampfungstemperatur des Materials überschritten. Durch die Verdampfung wird vom aufströmenden Metaldampf Material aus dem Schmelzbad mitgerissen. (TAHERI ANDANI et al. 2017) Dies tritt nach SIMONELLI et al. (2015) vor allem bei einem Tiefschweißprozess auf. Während des Schmelzprozesses wird geschmolzenes Material entlang des Temperaturgradienten im Schmelzbad transportiert. Das heißt vom Fokuspunkt des Lasers zu den kälteren Rändern.³ An den Rändern des Schmelzbades bilden sich Tropfen um die Oberflächenenergie zu minimieren. Diese Tropfen werden dann von dem verdampften Material mitgerissen, kühlen sich während der Flugphase in der Schutzgasströmung ab und verfestigen sich. (BAYERLEIN & ZÄH 2016)

Die Flugbahnen der Spritzer können nur statistisch beschrieben werden und reichen von Millimetern bis zu wenigen Zentimetern. (BAYERLEIN & ZÄH 2016) Die Spritzpartikel enthalten nach SIMONELLI et al. (2015) teilweise Oxide. Zudem sind die Spritzerpartikel deutlich größer als der Pulverwerkstoff und nehmen aufgrund der Oberflächenspannung der Schmelze eine kugelförmige Form an. Für AlSi10Mg nehmen die Spritzerpartikel Größen von 110 μm bis 330 μm an. (SIMONELLI et al. 2015)

Des Weiteren verringert sich die Spritzaktivität mit zunehmenden Umgebungsdruck. Das liegt zum Teil daran das die Verdampfungstemperatur mit zunehmendem Umge-

³Diese Strömung wird auch Marangoni Konvektion genannt, da sie von temperaturgradientgetriebenen Oberflächenspannungsunterschieden induziert wird. (OLAKANMI et al. 2011) Die Richtung der Strömung kann sich abhängig vom Oberflächenspannungszustand umkehren. (SIMONELLI et al. 2015)

bungsdruck zunimmt. Außerdem nimmt die Spritzerbildung mit steigendem Energieeintrag zu. (MEINERS 1999)

Nach GRÜNBERGER & DOMRÖSE (2015) nimmt die Spritzerbildung mit der Defokussierung des Laserlichts zu. Eine Defokussierung des Laserlichts kann entweder direkt an der Anlage eingestellt werden oder über eine Wechselwirkung mit dem Laserschmauch provoziert werden. (GRÜNBERGER & DOMRÖSE 2015) In Abbildung 2.9 ist links ein Prozess mit erhöhter Spritzerbildung dargestellt, der in der Literatur auch Splashy Process genannt wird (GRÜNBERGER & DOMRÖSE 2015), und rechts ein Prozess mit verminderter Spritzerbildung. Die linke Probe wurde mit einem Fokussdurchmesser von ϕ von $116,1 \mu\text{m}$ und die rechte Probe mit einem Fokussdurchmesser $68,1 \mu\text{m}$ gefertigt.




Abbildung 2.9: links: Prozess mit erhöhter Spritzerbildung. rechts: Prozess mit verminderter Spritzerbildung

2.3.2 Schmauch

Beim Aufschmelzen des Pulvers wird im Fokuspunkt des Lasers die Verdampfungstemperatur des Materials überschritten. Der entstehende Dampf kondensiert und bildet den Schweißrauch oder Schmauch. Die Emissionsrate an Schweißrauch nimmt mit dem Energieeintrag, also einer Erhöhung der Laserleistung oder einer Minderung der Scangeschwindigkeit, zu. (HESS 2015)

Der Schweißrauch wird von der Schutzgasströmung abtransportiert. Geschieht dies in unzureichender Form dann trifft das Laserlicht auf den Schmauch. Dies ist vor allem der Fall, wenn sich Laser und Schweißrauch in die selbe Richtung bewegen. Das Laserlicht wird von Schweißrauch gebrochen, reflektiert und absorbiert. Somit

wird der Energieeintrag in das Bauteil gemindert. Durch die Brechung des Lichts wird der Laserfokusbereich vergrößert und ein sogenannter Splashy Process tritt auf. Insgesamt haben diese Effekte einen negativen Einfluss auf die Bauteilqualität. Nach GRÜNBERGER & DOMRÖSE (2014) tritt dieser Effekt zufällig auf. Es kann aber durch eine Verringerung der Durchflussrate der Schutzgasströmung die Wahrscheinlichkeit dieser Wechselwirkung erhöht werden. Bei seltenem Vorkommen eines Splashy Process hat dieser nach GRÜNBERGER & DOMRÖSE (2015) keinen Einfluss auf die Bauteilqualität, da Defekte in der nächsten Schicht durch das Wiederaufschmelzen ausgeheilt werden können. Auch in einem regulär ablaufenden Prozess kann es nach BAYERLEIN & ZÄH (2016) zu kleinen lokalen Störungen in der Schutzgasführung kommen und dadurch zur verminderten Schmauchabführung und somit zu einer Aufweitung des Laserstrahls.

2.3.3 Balling Effekt

Bei einem unzureichendem Energieeintrag, zum Beispiel durch Prozessnebenprodukte, kann es sein, dass die Schweißspur abreißt. Wegen der Oberflächenspannung der Schmelze bilden sich dann Kugeln auf der Oberfläche, die größer als die Pulverkörner sind. Diese Kugeln werden Balling Effekte genannt, und führen zu einer lokalen Schichtdickenerhöhung. Dies führt einerseits zu einer veränderten Schweißbedingung in der darauffolgenden Schicht und andererseits kann es bei einer Kollision mit dem Beschichter zu einer Beschädigung des Beschichters kommen. Balling Effekte führen insgesamt zu einer größeren Porosität oder sogar zu Delaminationen⁴. (LADEWIG et al. 2016) Nach GU & SHEN (2009) nimmt die Häufigkeit des Auftretens von Balling Effekten mit steigender Volumenenergiedichte ab, da die Schmelze das Material dann wegen der geringeren Viskosität besser benetzen kann. AlSi10Mg neigt zu Balling Effekten, da es einen hohen Wärmeleitfähigkeitskoeffizienten aufweist, wodurch die Temperatur des aufgeschmolzenen Materials und damit auch dessen Viskosität schnell absinkt. (OLAKANMI et al. 2011) In Abbildung 2.10 ist die Konfokalmikroskopaufnahme zweier Proben, mit und ohne Balling Effekte, dargestellt. Bei der rechten Probe wurde die Durchflussrate der Schutzgasströmung reduziert, um eine Wechselwirkung mit dem Schmauch zu provozieren und einen geminderten Energieeintrag zu erzeugen. Durch diesen geminderten Energieeintrag kommt es zu Balling Effekten. (LADEWIG et al. 2016)

⁴Delamination beschreibt das Ablösen von Schichten




Abbildung 2.10: Konfokalmikroskopaufnahme zweier Proben. links: ohne Balling Effekte. rechts: mit Balling Effekte (LADEWIG et al. 2016)

2.3.4 Defekte beim Laserstrahlschmelzen

Im Allgemeinen können Prozessstörungen zu Defekten führen. Beim Laserstrahlschmelzen kommt es auch bei Standardparametern zu Defekten in den Bauteilen. Trotz der über 20 Jahre langen Forschung, sind die Eigenschaften von mit Laserstrahlschmelzen gefertigten Aluminiumlegierungsbauteile wegen der vielen Defektarten immer noch schwer zu beherrschen. (GALY et al. 2018) Die unterschiedlichen Defektarten führen zu Porositäten, die einen signifikanten Einfluss auf die mechanischen Eigenschaften haben. (B. ZHANG et al. 2017)

Für diese Arbeit wird eine Auswahl der folgenden relevanten Defektarten vorgenommen:

- Gasporen
- Bindefehler
- Heißrisse

Gasporen oder metallurgische Poren entstehen entweder durch das Einschließen von Gasen aus der Atomsphäre, zum Beispiel beim Kollabieren eines Keyholes, oder durch das

Verdampfen bestimmter Legierungselemente. (GALY et al. 2018) Bei AlSi10Mg führt vor allem die Wasserstoffentgasung zu Gasporen. Der Wasserstoff stellt eine Verunreinigung dar, der durch eine Reaktion mit Wasser während des Schmelzprozesses oder durch gelösten Wasserstoff in dem Pulverwerkstoff entsteht. (WEINGARTEN et al. 2015) Gasporen weisen eine runde Form auf und entstehen vor allem bei hohen Energiedichten. (GALY et al. 2018) Gasporen in den Bauteilen sind zufällig verteilt und sind in der Regel kleiner als $100\ \mu\text{m}$. (B. ZHANG et al. 2017) In Abbildung 2.11 ist links das Schlifffbild einer Probe mit überwiegend Gasporen dargestellt.

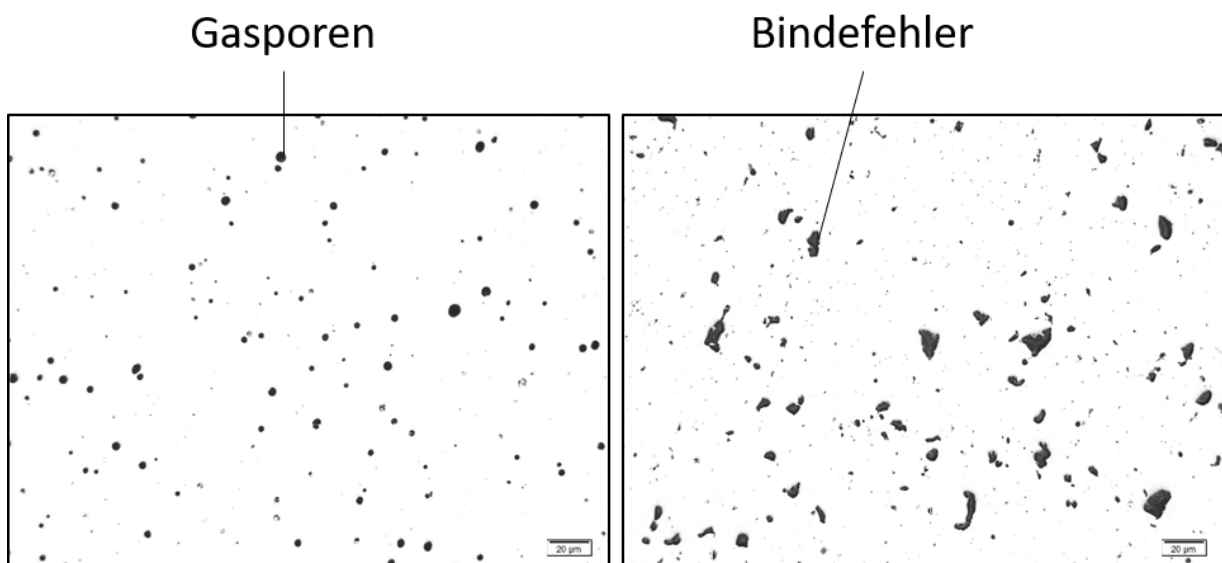


Abbildung 2.11: Schlifffbilder zweier Proben. links: überwiegend Gasporen. rechts: überwiegend Bindefehler

Bindefehler oder Anbindungsfehler entstehen durch unzureichendes Aufschmelzen des Werkstoffs. Bei leicht zu oxidierenden Materialien wie AlSi10Mg können Oxide die Schmelzfluss blockieren und so zu einer schlechteren Benetzung und letztendlich zu Bindefehlern führen. Es wird zwischen zwei Arten von Bindefehlern unterschieden. Die erste Bindefehlerart entsteht durch unzureichende Anbindung zwischen den Schichten oder den einzelnen Schweißspuren wegen fehlender Benetzung. Diese Defektart weist eine deutlich geringere Höhe (ca. $10\ \mu\text{m}$) im Verhältnis zu Breite auf. Die zweite Bindefehlerart weist ein kleineres Höhe-Breite Verhältnis auf und enthält unaufgeschmolzenes Pulver. (B. ZHANG et al. 2017) Eine solche Art von Bindefehlern ist in Abbildung 2.11 rechts dargestellt.

Eine weitere Defektart sind Heißrisse. Diese werden von niedrigschmelzenden Legierungselementen entlang der Korngrenzen verursacht. Diese Legierungselemente können die auftretenden Schrumpfspannungen bei der Abkühlung nicht aufnehmen

und reißen deshalb ab. (HESS 2015) Wegen dem kleinen Temperaturbereich, bei der die Verfestigung stattfindet ($\Delta T \sim 50^\circ\text{C}$), neigt nach GALY et al. (2018) AlSi10Mg nicht zur Heißrissbildung.

2.4 Grundlagen des maschinellen Lernens

Das maschinelle Lernen (englisch Machine Learning [ML](#)) beschäftigt sich mit der Frage wie man Computerprogramme gestaltet, damit sie sich automatisch mit Erfahrung verbessern. (MITCHELL 1997) Das maschinelle Lernen ist ein Teilgebiet der künstlichen Intelligenz. (KROLL 2016, S. 6) Mit Algorithmen des Maschinellen Lernens können Prozesse approximiert werden ohne sie vollständig zu verstehen. Die Algorithmen finden Strukturen in Daten, mit denen Vorhersagen für neue Daten getroffen werden können. Die Anwendung von [ML](#) Algorithmen auf große Datensätze wird Data Mining genannt. (ALPAYDIN 2010, S. 2-5)

Die meisten Aufgaben im maschinellen Lernen lassen sich in zwei Kategorien einteilen, nämlich in das überwachte (englisch supervised) und das unüberwachte (englisch unsupervised) Lernen. Beim überwachten Lernen wird zwischen Klassifikation und Regression unterschieden. Das unüberwachte Lernen wird auch Clustering genannt. In [Abbildung 2.12](#) ist die Einteilung der Algorithmen des maschinellen Lernens dargestellt. (JAMES 2013, S. 26)

Ziel des überwachten Lernens ist es den Wert beziehungsweise die Werte der Ausgabevariablen, auch Label genannt, auf Grundlage einer Reihe von Eingabevariablen vorherzusagen. Die Eingabevariablen sind die Datenpunkte n , die jeweils aus ein oder mehreren Features bzw. Merkmalen bestehen. (HASTIE et al. 2009, S. 2) Da auch in der deutschsprachigen Literatur (KROLL 2016) überwiegend der Begriff Feature angewandt wird, werden in dieser Arbeit die Merkmale ausschließlich als Feature bezeichnet. Die Anzahl an Features wird als Dimension D bezeichnet und muss für alle Datenpunkte eines Datensatzes gleich sein. Beim überwachten Lernen wird der Datensatz in ein Trainings- und ein Testdatensatz aufgeteilt. Der Trainingsdatensatz dient dazu den Algorithmus zu trainieren, das heißt die Struktur des Datensatzes zu lernen. Mit dem Testdatensatz wird die Leistungsfähigkeit des trainierten Algorithmus bewertet. (HASTIE et al. 2009, S. 4)

Von einem Klassifikationsproblem wird gesprochen, wenn Eingabevariablen in eine endliche Anzahl an diskreten Klassen eingeordnet werden. Werden die Eingabevariablen

hingegen einer kontinuierlichen, quantitativen Variable zugeordnet spricht man von Regression. (JAMES 2013, S. 28)

Beim unüberwachten Lernen oder Clustering sind für die Eingabevariablen keine Ausgabevariablen vorhanden. Stattdessen wird der Datensatz in Gruppen, auch Cluster genannt, aufgeteilt. Die Datenpunkte sollten innerhalb der Cluster eine möglichst große Ähnlichkeit zueinander aufweisen, während Cluster sich untereinander möglichst stark unterscheiden sollten. Mit Clustering Algorithmen ist es möglich Strukturen oder Muster in Daten zu finden. (AGGARWAL & REDDY 2014, S. 1-3)




Abbildung 2.12: Einteilung der Algorithmen des maschinellen Lernens

Bei der Auswahl der Algorithmen ist aufgrund der großen Datenmengen, auch Big Data genannt, die durch das Online-Prozessüberwachungssystem entstehen, die Rechenzeit ein entscheidendes Kriterium. Um eine Auswahl an geeigneten Algorithmen zu treffen wird die Größe der Zeitkomplexität Θ herangezogen. Mit dieser Größe lässt sich die Rechenzeit abhängig von der Anzahl an Datenpunkten, Features und anderen algorithmusspezifischen Größen abschätzen. (PAPADIMITRIOU 2005) Die verwendeten Algorithmen müssen eine geringere Zeitkomplexität als quadratisch hinsichtlich der Anzahl an Datenpunkte aufweisen um für große Datenmengen geeignet zu sein.⁵ (SUTHAHARAN 2016) Es sei darauf hingewiesen dass neuronale Netze auf diese Weise nicht klassifiziert werden können, da die Rechenzeit dieser nicht deterministisch ist. Allerdings werden neuronale Netze in dieser Arbeit nicht verwendet und deshalb auch nicht weiter behandelt. In dieser Arbeit werden Clustering und Klassifikationsalgorithmen verwendet. Außerdem wird die Hauptkomponentenanalyse (englisch Principal Component Analysis [PCA](#)) als eine Methode zur Dimensionsreduktion angewandt, und

⁵Quadratische Zeitkomplexität bedeutet zum Beispiel $\Theta(n^2D)$.

die Normalisierung für eine Anpassung an das von den Algorithmen verwendete Datenformat genutzt. Die verwendeten Methoden und Algorithmen werden im Folgenden genauer beschrieben.

2.4.1 Clustering Algorithmen

Nach AGGARWAL & REDDY (2014, S. 32) können Clustering Algorithmen in drei Kategorien eingeteilt werden. Diese sind:

- partitionierende Clusterverfahren
- hierarchische Clusterverfahren
- dichtebasierte Clusterverfahren

Um Einflüsse der Algorithmen zu erfassen wird in dieser Arbeit jeweils ein Algorithmus aus den Kategorien partitionierende und dichtebasierte Clusterverfahren verwendet. Im Folgenden werden die drei Kategorien sowie die angewendeten Algorithmen beschrieben.

Der Nachteil an dem partitionierenden Clusterverfahren ist das die Anzahl der Cluster k vom Algorithmus nicht bestimmt wird und diesem im Voraus übergeben werden muss. Gängige partitionierende Clusteralgorithmen sind k -Means oder k -Medoid. (AGGARWAL & REDDY 2014, S. 89) In dieser Arbeit wird der k -Means Algorithmus verwendet und deshalb im Folgenden genauer betrachtet.

Der Algorithmus startet durch eine zufällige Wahl von k Clusterzentren τ im Feature-Raum. Die Clusterzentren sind in Abbildung 2.13 durch ein x gekennzeichnet. Anschließend wird jeder Datenpunkt dem nächstliegenden Zentrum, welches mit der euklidischen Distanz bestimmt wird, zugewiesen. Nach diesem Schritt werden die Clusterzentren aktualisiert, indem die Position der minimalen Distanz zu den Datenpunkten, die den Clustern zugewiesen wurden, berechnet wird. Diese zwei Schritte werden so lange wiederholt bis sich die Zentren nicht mehr ändern oder ein Konvergenzkriterium erfüllt wird. Das Ziel des k -Means Algorithmus ist es, den Datensatz so in k Cluster aufzuteilen, dass die Summe der quadrierten Abweichungen von den Clusterzentren minimal ist. Mathematisch entspricht dies einer Optimierung von Formel 2.4. (BISHOP

2010, S. 424-427) Die einzelnen Datenpunkte sind hier n , die Lage der Clusterzentren ist τ , k ist die Anzahl an Cluster.

$$J = \sum_{i=1}^k \sum_{\mathbf{n}_j \in k_i} \|\mathbf{n}_j - \tau_i\|^2 \quad (2.4)$$

Wie in Abbildung 2.13 links zu sehen ist kann es sein, dass der Algorithmus gegen ein lokales Minima konvergiert. Um dieses nicht deterministische Verhalten zu verhindern,




Abbildung 2.13: Funktionsweise des k-Means Algorithmus. links: Konvergenz gegen lokales Minimum. rechts: Konvergenz gegen globales Minimum

sollte der Algorithmus mehrmals mit unterschiedlichen Startwerten für die Clusterzentren berechnet werden. Zudem kann der k-Means Algorithmus nur lineare Grenzen setzen um die Cluster zu partitionieren. Des Weiteren ist der Algorithmus für große Datenmengen geeignet, da er eine lineare Zeitkomplexität von $\Theta(nkD)$ aufweist. (R. XU & WUNSCH 2005) Da die Clusteranzahl dem Algorithmus im Voraus übergeben werden muss, sind Metriken nötig, um die bestmögliche Anzahl an Cluster im Nachhinein zu bestimmen und die Güte des Ergebnisses zu bewerten. Für diese Metriken müssen die Cluster zuerst für mehrere k berechnet werden. Nach AGGARWAL & REDDY (2014, S. 572) gibt es keine optimale Metrik um die Clustering Güte zu bewerten und die Metrik sollte immer auf den Anwendungsfall bezogen werden. Metriken zur Bestimmung der Güte des Clustering Ergebnisses können in interne und externe Metriken aufgeteilt werden. Bei externen Metriken werden Informationen verwendet die nicht in dem Datensatz enthalten sind. Da solche Informationen für den Anwendungsfall in dieser Arbeit nicht vorhanden sind, wird eine interne Metrik verwendet, der sogenannte Davies-Bouldin Index. Der Davies-Bouldin Index gibt an wie ähnlich sich die gefundenen Cluster sind. Je geringer der Wert des Indexes desto unähnlicher sind sich die Cluster und umso

besser ist die Clustering Güte. Für weitere Informationen zu dem Davies-Bouldin Index wird auf DAVIES & BOULDIN (1979) verwiesen.

Hierarchische Clusterverfahren überwinden einige Nachteile der partitionierenden Clusterverfahren. Bei hierarchischen Clusterverfahren ist es nicht nötig eine Clusteranzahl k vorher festzulegen und die Ergebnisse dieser Algorithmen sind deterministisch. Diese Verfahren produzieren anstatt einzelner Cluster eine Hierarchie von Clustern. (THEODORIDIS & KOUTROUMBAS 2009, S. 653) Hierarchische Clustering Algorithmen werden in zwei Kategorien aufgeteilt, den divisiven und den agglomerativen Algorithmen. Divisive Algorithmen, auch als Top-Down Verfahren bezeichnet, starten mit allen Datenpunkten in einem Cluster und spalten dieses schrittweise in kleinere Cluster auf, die am Ende nur noch aus einem Datenpunkt bestehen. Agglomerative Algorithmen, auch als Bottom-up Verfahren bezeichnet, hingegen fusionieren die einzelnen Datenpunkte schrittweise zu immer größeren Clustern. (AGGARWAL & REDDY 2014, S. 100-101) Eine übersichtlichen Darstellung der Ergebnisse hierarchischer Clusterverfahren stellt ein Dendrogramm dar. Das Dendrogramm kann in einer beliebigen Hierarchieebene abgeschnitten werden um die um die dazugehörigen Cluster zu erhalten. (THEODORIDIS & KOUTROUMBAS 2009, S. 656) In Abbildung 2.14 ist ein Dendrogramm dargestellt, bei dem die Äste in der dritten Hierarchieebene in Cluster zusammengefasst wurden. Es ergeben sich so vier Cluster. Die Zeitkomplexität für die meisten hierarchischen Clusterverfahren wird von AGGARWAL & REDDY (2014, S. 107) als quadratisch $\Theta(n^2)$ angegeben. Somit sind sie nicht für große Datenmengen geeignet.




Abbildung 2.14: Dendrogramm eines hierarchischen Clusteralgorithmus indem nach der dritten Hierarchieebene Cluster gebildet werden in Anlehnung an AGGARWAL & REDDY (2014, S. 102)

Bei dichte-basierten Clusterverfahren werden Cluster aufgrund von Dichteunterschieden

im Featureerraum gebildet, wobei aus dicht beieinander liegenden Datenpunkte Cluster entstehen. Der Vorteil dichtebasierter Clusterverfahren gegenüber partitionierender und hierarchischer Clusterverfahren ist das diese Algorithmen Cluster beliebiger Form ermitteln können. Des Weiteren wird die Clusteranzahl k vom Algorithmen von selber berechnet. (AGGARWAL & REDDY 2014, S. 111-113) Im Folgenden wird der Dichte-basierte Clustering Algorithmus **DBSCAN** (englisch Density-Based Spatial Clustering of Applications with Noise) eingeführt.

DBSCAN bestimmt die Dichte der Daten, indem die Punkte in einer bestimmten Nachbarschaftlänge ϵ gezählt werden. Neben ϵ ist zudem die minimale Anzahl an Datenpunkten in einem Cluster $MinPts$ ein Eingabeparameter von **DBSCAN**. Der Algorithmus weist den Datenpunkten entweder ein Cluster zu oder klassifiziert sie als Rauschpunkt, und ist somit im Gegensatz zu k -Means robust gegen Ausreißer in den Daten. (AGGARWAL & REDDY 2014, S. 113-115) In Abbildung 2.15 ist ein Clustering Ergebnis des **DBSCAN** Algorithmus mit Rauschdatenpunkten dargestellt. Für die Wahl des Parameters ϵ wird in ESTER et al. (1996) der sortierte k -Distanz Graph mit $k = MinPts - 1$ vorgeschlagen. Nimmt der Verlauf dieses Graphen einen Knick an, dann liegt dort ein Dichtesprung in den Daten und somit ein valider Wert für ϵ , vor. $MinPts$ hingegen sollte nach Expertenwissen über dem spezifischen Anwendungsfall ausgewählt werden. Bei einem kleineren $MinPts$ werden mehr Cluster gebildet. (ESTER et al. 1996) **DBSCAN** weist eine quadratische Zeitkomplexität von $\Theta(n^2)$ auf. Wird aber eine Indexstruktur, wie zum Beispiel eine R-Tree, hinterlegt um die Rechenzeit zu reduzieren, nimmt der Algorithmus eine Zeitkomplexität von $\Theta(n \log(n))$ an, und ist somit für große Datenmengen geeignet.

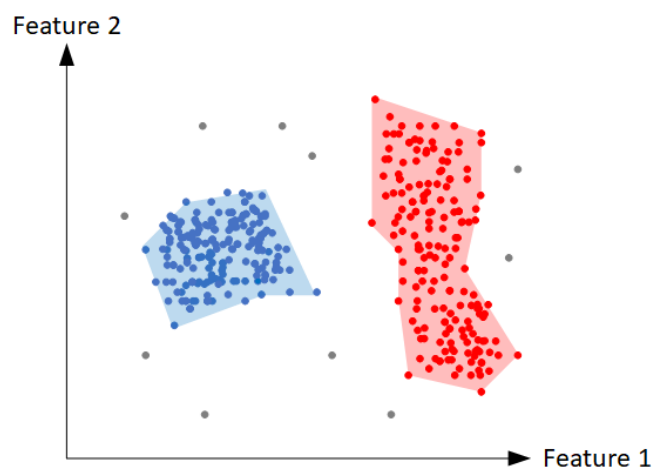


Abbildung 2.15: Clustering Ergebnis des **DBSCAN** Algorithmus mit zwei Cluster und Rauschdatenpunkten in Anlehnung an ESTER et al. (1996)

2.4.2 Klassifikations Algorithmen und Bewertungen

Des Weiteren handelt sich es bei einem Teil des in dieser Arbeit verwendeten **ML** Workflow um ein Klassifikationsproblem. Auch hier ist die Rechenzeit, welche durch die Zeitkomplexität Θ beschrieben wird, ein beschränkendes Kriterium bei der Auswahl der Algorithmen. Allerdings wird hier im Gegensatz zum Clustering zwischen des Trainings und der Vorhersage Zeitkomplexität der Algorithmen unterschieden. In dieser Arbeit werden Entscheidungsbäume und nächste Nachbarn Klassifikationsalgorithmen verwendet und deshalb im Folgenden eingeführt.

Entscheidungsbäume funktionieren ähnlich wie die in Kapitel 2.4.1 vorgestellten hierarchischen Clusterverfahren. Die Ergebnisse der Entscheidungsbäume sind anschaulich in einer Baumstruktur darstellbar. Die Klassifikation für einen einzelnen Datenpunkt verläuft von der Wurzel eines Baumes aus abwärts. In der Regel weisen Entscheidungsbäume eine geringere Entscheidungsgenauigkeit als die meisten anderen Klassifikationsalgorithmen auf. Allerdings haben die meisten Entscheidungsbäume eine lineare Trainings und Vorhersage Zeitkomplexität. (QUINLAN 1986)

Ein weiterer schnell trainierbarer Algorithmus ist der nächste Nachbarn (englisch k Nearest Neighbour **KNN**) Algorithmus. Beim diesem findet keine richtige Trainingsphase statt, und die Trainingsdaten werden lediglich abgespeichert. Die Klassifikation eines Datenpunktes erfolgt durch eine Mehrheitsentscheidung, bei der die Label der Trainingsdaten verglichen werden. An der Mehrheitsentscheidung sind die nächsten Nachbarn des Datenpunktes im Featureraum beteiligt. Die nächsten Nachbarn können über verschiedene Distanzmaße, wie die Euklidische- oder Manhattendistanz, berechnet werden. In Abbildung 2.16 ist eine Mehrheitsentscheidung eines Datenpunktes, der mit einem Stern gekennzeichnet ist, dargestellt. Dieser Datenpunkt würde hier mit dem Label der roten Datenpunkte klassifiziert werden. Insgesamt ermöglicht der **KNN** Algorithmus ein suboptimales, nichtlineares, aber trotzdem in den meisten Fällen ausreichend genaues Klassifizierungsergebnis. (THEODORIDIS & KOUTROUMBAS 2009, S. 61-63) Die Zeitkomplexität ist für diesen Algorithmus nur für die Vorhersage relevant und beträgt $\Theta(kn)$. (THEODORIDIS & KOUTROUMBAS 2009, S. 63)

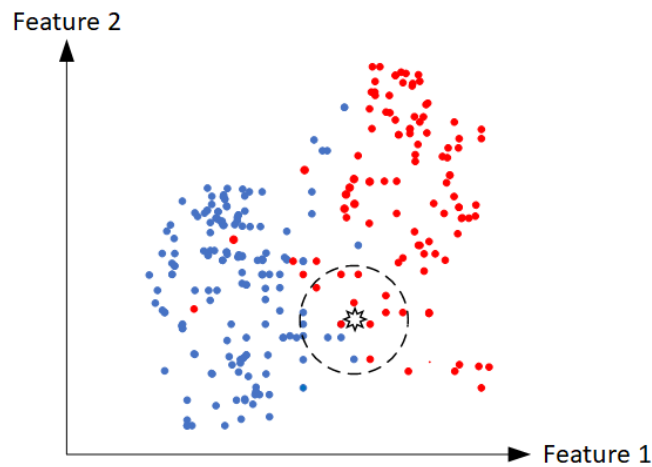


Abbildung 2.16: Schematische Darstellung der Mehrheitsentscheidung beim *KNN* Algorithmus in Anlehnung an THEODORIDIS & KOUTROUMBAS (2009, S. 61)

Insgesamt ist es wichtig das die Algorithmen sowohl den Trainingsdatensatz als auch neue Daten gut abbilden. Um das Klassifizierungsergebnis zu bewerten gibt es nach RUNKLER (2010, S. 86) bei Daten mit zwei verschiedenen Klassen (positiv und negativ) vier verschiedene Fälle, je nachdem ob die Klassen richtig oder falsch vorhergesagt werden. Diese sind:

- richtig positiv
- richtig negativ
- falsch positiv
- falsch negativ

Den einzelnen Fällen kommt je nach Anwendungsfall unterschiedliche Bedeutung zu. Eine Übersichtliche Darstellung dieser Fälle bietet eine Konfusionsmatrix. Die Zeilen der Konfusionsmatrix stellen die richtigen Klassen des Datensatzes dar und die Spalten die vorhergesagten Klassen. In [Abbildung 2.17](#) ist eine schematische Darstellung einer Konfusionsmatrix gegeben.

Richtige Klassen	P	richtig positiv	falsch negativ
	N	falsch positiv	richtig negativ
		P	N
		Vorhergesagte Klassen	

Abbildung 2.17: Schematische Darstellung einer Konfusionsmatrix

Die gesamte Vorhersagegenauigkeit G der Daten wird Formel 2.5 berechnet. t_r ist die Anzahl der korrekt vorhergesagten Klassen und n ist die Anzahl der Datenpunkte in dem Datensatz.

$$G = \frac{t_r}{n} \cdot 100\% \quad (2.5)$$

Einen Einfluss auf die Vorhersagegenauigkeit hat der sogenannte Fluch der Dimensionalität. Dieser beschreibt das die Vorhersagegenauigkeit eines Algorithmus bei steigender Feature Anzahl sinkt. Das kann durch das Versagen der auf Ähnlichkeit basierender Logiken und Distanzmaße vieler Algorithmen bei höherer Dimensionalität erklärt werden. (L'HEUREUX et al. 2017) Aus diesem Grund ist es sinnvoll eine Auswahl an Feature zu treffen, wodurch zudem die Rechenzeit reduziert wird.

Viele Klassifikationsalgorithmen nutzen Distanzmaße. Liegen aber die Feature in unterschiedlichen Skalierungen vor, kann das einen negativen Einfluss auf die Klassifikationsgenauigkeit haben, da die Distanzen dann nur ungenau berechnet werden können. Deshalb wird in dieser Arbeit die sogenannte z-Transformation oder Standardisierung für jedes Feature verwendet. Nach der z-Transformationen haben alle Feature einen Skalenbereich zwischen null und eins. Die z-Transformation wird mittels Formel 2.6 berechnet. σ ist die Standardabweichung und μ der Mittelwert eines Features. (AKSOY & HARALICK 2000)

$$x_{stand} = \frac{x - \mu}{\sigma} \quad (2.6)$$

2.4.3 Hauptkomponentenanalyse

Neben der Auswahl von Features kann die Dimensionen auch durch die Hauptkomponentenanalyse reduziert werden. (englisch Principal Component Analysis [PCA](#)). In realen Datensätzen existieren Korrelationen zwischen den einzelnen Features. Diese Korrelationen weisen auf redundante Features hin, sind aber nicht immer durch eine Feature Auswahl zu eliminieren. Zum Beispiel ist in [Abbildung 2.18](#) ein zweidimensionaler Datensatz dargestellt. Werden hier die Achsen zu der in grün dargestellten Orientierung gedreht, können die Redundanzen entfernt und die Daten als Linie in einer Dimension dargestellt werden.

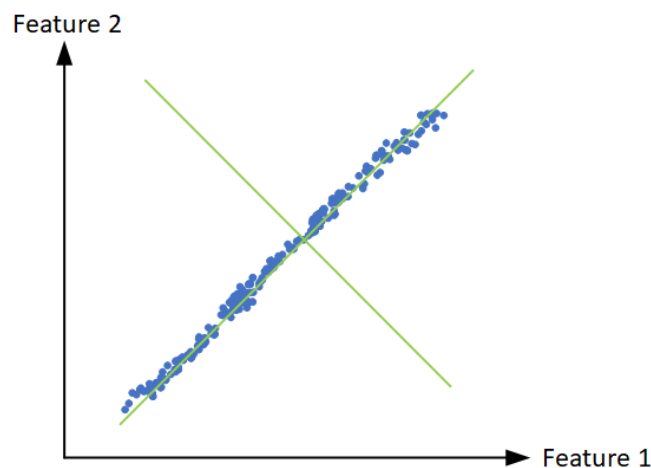


Abbildung 2.18: Stark korrelierende Daten in zwei Dimensionen mit einem grün dargestellten gedrehten Koordinatensystem

Die andere Dimension mit geringerer Varianz kann fast ohne Informationsverlust weggelassen werden. (AGGARWAL 2015, S. 43-44) Eine Methode, um diese Dimensionen mit geringer Varianz zu finden und das Koordinatensystem entsprechend zu drehen, stellt die Hauptkomponentenanalyse dar. Die [PCA](#) dreht das Koordinatensystem so, dass die Kovarianzmatrix C ⁶ diagonalisiert wird. Die Drehung erfolgt mittels der Transformationsmatrix A die aus den Eigenvektoren der Kovarianzmatrix C besteht. Außerdem erfolgt mit der [PCA](#) eine Zentrierung der Daten über die Subtraktion des Mittelwerts μ_{PCA} von den Datenpunkten. Die Transformation der Datenmatrix durch Rotation und

⁶Matrix deren Elemente auf der Hauptdiagonalen Varianzen darstellen und alle übrigen Elemente Kovarianzen beinhalten.

Translation in die PCA_{Matrix} wird mit der Formel 2.7 beschrieben. (RUNKLER 2010, S. 37-39)

$$PCA_{Matrix} = (Datenmatrix - \mu_{PCA})A \quad (2.7)$$

Die Eigenwerte λ_{PCA} der Kovarianzmatrix C beschreiben die erklärable Varianz der einzelnen Dimensionen der transformierten Matrix. Zur Dimensionsreduktion können die q Dimensionen mit den höchsten Eigenwerten beziehungsweise der höchsten Varianz ausgewählt werden. Eine geeignete Projektionsdimension q kann zum Beispiel dadurch bestimmt werden, dass gefordert wird, dass in der Projektion mindestens 95% der gesamten Varianzen aller Dimensionen p enthalten ist. Dieser Zusammenhang wird in Formel 2.8 erfasst. (RUNKLER 2010, S.39)

$$\frac{\sum_{i=1}^q \lambda_{PCAi}}{\sum_{i=1}^p \lambda_{PCAi}} \geq 95\% \quad (2.8)$$

3 Stand der Technik und Forschung

Wegen den zahlreichen Einflussgrößen, die der Prozess des Laserstrahlschmelzens unterliegt, kommt es zu Schwankungen in der resultierenden Bauteilqualität. (SEHRT 2010) Deshalb sind in der Regel zusätzlich nachgelagerte Qualitätssicherungsmaßnahmen nötig um eine gleichbleibende Bauteilqualität zu gewährleisten. Dies ist vor allem in sicherheitskritischen Anwendungen wie in der Luftfahrtindustrie der Fall. Die Qualitätssicherung kann zerstörend oder zerstörungsfrei erfolgen. Ein mögliches zerstörungsfreies Prüfverfahren ist zum Beispiel die Computertomographie (CT), welche allerdings sehr kosten- und zeitintensiv ist. Ist keine zerstörungsfreie Prüfung möglich können identische Bauteile im selben Bauprozess hergestellt werden und zerstörend geprüft werden. (BAYERLEIN & ZÄH 2016)

Eine weitere Möglichkeit der zerstörungsfreien Prüfung bietet die Online-Prozessüberwachung. Hier findet die Ermittlung qualitätsrelevanter Merkmale während des Bauprozesses statt. Die Online-Prozessüberwachung bildet die Grundlage dafür aktiv in den Prozess einzugreifen und Prozessparameter zu regeln. (BAYERLEIN & ZÄH 2016)

Im Folgenden wird die Online-Prozessüberwachung genauer betrachtet. Anschließend erfolgt eine Beschreibung der Anwendungen von Regelungskonzepten und ML Methoden beim Laserstrahlschmelzen.

3.1 Online-Prozessüberwachung

Eine Einteilung der Online-Prozessüberwachung nach verschiedenen Gesichtspunkten ist in Abbildung 3.1 gegeben. Die Einteilung des in dieser Arbeit verwendete Messsystem, das MPM System der Firma SLM Solutions Group AG, ist dabei hervorgehoben.

Im Allgemeinen kann durch die Online-Prozessüberwachung die Verfestigung bzw. das Aufschmelzen und der Schichtauftrag überwacht werden. Bei der Überwachung des Schichtauftrags wird überprüft ob die Beschichtung fehlerhaft ist. (KLESZCZYNSKI,

Online-Prozessüberwachung beim Laserstrahlschmelzen						
Prozessschritt	Verfestigung			Schichtauftrag		
Anordnung/ Prinzip	Prozessemission		Prozessparameter	Prozessergebnis		
	On-Axis	Off-Axis				
Dimension	Einzelsensor			Multisensor		
Signal/ Sensor	optisch			akustisch	mechanisch	elektrisch
	UV	VIS	IR			
Auflösungs- prinzip	räumlich direkt		räumlich indirekt		räumlich integriert	

Abbildung 3.1: Einteilung der Online-Prozessüberwachung nach verschiedenen Gesichtspunkten in Anlehnung an KRAUSS (2016, S. 38). In schwarz ist das in dieser Arbeit verwendete Messsystem hervorgehoben

ZUR JACOBSMÜHLEN et al. 2012) Des Weiteren können die Prozessemissionen, Prozessparameter (z.B. durch Laser Power Monitoring) und das Prozessergebnis gemessen werden.

Die Grundlage für die von den Sensoren gemessene Größen bilden verschiedene Prozessphänomene. Diese sind die Emission elektromagnetischer Strahlung, Schall, gasförmigen und flüssigen Materials sowie die Reflexion und Transmission des Laserlichts. (KRAUSS 2016, S. 35) Abhängig von dem zu messenden Prozessphänomen werden optische, akustische, mechanische und elektrische Sensoren verwendet. Am weitesten verbreitet in Industrie und Forschung sind die optische Sensoren, welche auch in dieser Arbeit verwendet werden. Durch die Kombination gleicher oder verschiedener Art von Sensoren mit Sensor Daten Fusion, z.B. mit einem Kalman-Filter Ansatz, kann der Informationsgehalt der Signale erhöht werden. Zum einen wird dadurch das Rauschen gemindert und zum anderen können unterschiedliche Informationen in den Signalen enthalten sein. (EVERTON et al. 2016) Nach DIETRICH (2009) können unterschiedliche Informationen zum Beispiel durch die gleichzeitige Betrachtung unterschiedlicher Wellenlängenbereiche der emittierten Strahlung (UV, VIS, IR) generiert werden.

Eine weiter Unterscheidung erfolgt nach BAYERLEIN & ZÄH (2016) zwischen räumlich integrierten, räumlich direkt auflösenden und räumlich indirekt auflösenden Verfahren. Räumlich integrierte Verfahren mitteln Messgrößen über ein bestimmtes Messvolumen.

Stand der Technik beim Laserstrahlschmelzen sind zum Beispiel Sauerstoffsensoren in der Baukammer oder Temperatursensoren an der Bauplatte. (BAYERLEIN & ZÄH 2016)

Räumlich direkt auflösende Verfahren erfassen die gesamte Bauplattform oder Teilbereiche davon. Dadurch wird sowohl das Schmelzbad und sein Wärmeinflussbereich, als auch die Pulverschicht gemessen. Als Sensoren werden in der Regel **CCD** (Charged Couple Device), **CMOS** (Complementary Metal Oxid Semiconductor) oder Infrarot Kameras verwendet. Nachteile der räumlich direkt auflösenden Sensoren sind die geringe Messfrequenz und die hohen Kosten. (SPEARS & GOLD 2016)

Als räumlich indirekt auflösenden Verfahren werden Messsysteme bezeichnet, die den Sensorwert über eine Zusatzinformation (z.B. Winkel der Ablenkeoptik) verorten. Dadurch entsteht ein räumlich aufgelöstes aber zeitlich lediglich zusammengesetztes Bild. (BAYERLEIN & ZÄH 2016) Räumlich indirekt auflösende Sensoren sind zum Beispiel Photodioden und Pyrometer. Photodioden sind Sensoren, die Strahlung detektieren und in ein elektrisches Signal umwandeln. Die Umwandlung funktioniert auf der Grundlage des photoelektrischen Effekts. Die Vor- und Nachteile solcher Sensoren ist die Reduktion eines Sichtfelds auf einen einzelnen Spannungswert. Dadurch wird einerseits die Datenmenge reduziert, andererseits ist das Signal schwerer zu interpretieren als Bilder der räumlich direkt aufgelösten Sensoren. Für die Interpretation des Signals räumlich direkt aufgelöster Sensoren sind hauptsächlich Kenntnisse in der Bildverarbeitung notwendig, und bei räumlich indirekt aufgelösten Sensoren liegt der Schwerpunkt in der Signalverarbeitung. (NORMAN et al. 2007) Für die Analyse des Signals werden empirische Korrelationen oder theoretische Modelle benötigt. Vorteile räumlich indirekt aufgelösten Sensoren sind geringe Kosten, hohe Sensitivitäten, hohe Messfrequenzen und Robustheit. (SPEARS & GOLD 2016)

3.1.1 Messfrequenzen der Sensoren

Die Messfrequenz ist neben den sensorspezifischen Leistungsmerkmalen, entscheidend um die Dynamik des Schmelzbades zu erfassen und detaillierte Aussagen über Fehler im Aufschmelzprozess treffen zu können. Das liegt an den hohen Scangeschwindigkeiten, die bis zu einigen Metern pro Sekunde betragen können, und an der gleichzeitig benötigten hohen Ortsauflösung. Die für eine Regelung benötigte Messfrequenz wird in CRAEGHS, CLIJSTER et al. (2011) diskutiert und auf mindestens 10 kHz festgelegt. Bei einer Messfrequenz von 10 kHz und einer Scangeschwindigkeit von $1000 \frac{mm}{s}$ nimmt der Sensor alle $100 \mu m$ einen Wert auf.

Mit den unterschiedlichen Sensorarten sind unterschiedliche Messfrequenzen möglich. Mit Photodioden sind die höchsten Messfrequenzen von bis zu 100 kHz zu erreichen. (ALBERTS et al. 2016) CCD oder CMOS Kameras weisen eine Messfrequenz von 10 kHz (CRAEGHS, CLIJSTER et al. 2011) und ungekühlte Infrarotkameras eine Messfrequenz von 50 Hz (BAYERLEIN & ZÄH 2016) auf. Hohe Messfrequenzen führen zu großen Datenmengen. Für die Bestimmung einer ausreichend großen Messfrequenz kann eine Fourier Analyse angewendet werden, indem der Prozess hochfrequent abgetastet wird und mit der Fourier-Analyse die maximale Frequenz $f_{Mess,max}$ bestimmt wird. (SEIBT 2010) Nach dem Abtasttheorem von Nyquist-Shannon gilt dann:

$$f_{Abtast} \geq 2 \cdot f_{Mess,max} \quad (3.1)$$

Nach dem Abtasttheorem kann ein Signal exakt rekonstruiert werden wenn es mit einer Frequenz von $2 \cdot f_{Mess,max}$ abgetastet wird.

3.1.2 On-Axis und off-Axis Betrachtung

Sensoren können beim Laserstrahlschmelzen in einer on-Axis oder off-Axis Konfiguration eingebaut werden. Eine schematische Darstellung der on- und off-Axis ist in Abbildung 3.2 gegeben.




Abbildung 3.2: Schematische Darstellung der on- und off-Axis Betrachtung

In der off-Axis Konfiguration ist der Sensor im Bauraum integriert und misst dabei die Strahlung der gesamten Bauplatzform. Hierbei werden neben der Strahlung aus dem Schmelzbad auch die thermische Vorgeschichte des Materials und der Wärmeinflussbereich des Schmelzbades mitgemessen. Dadurch können Aussagen über das Abkühlverhalten des Materials, wie zum Beispiel Wärmestauungen, getroffen werden. Das Abkühlverhalten bestimmt in vielen Fällen die mechanischen und metallographischen Eigenschaften des Bauteils.

Bei der on-Axis Konfiguration, welche auch als koaxiale Anordnung bezeichnet wird, ist der Sensor im optischen System der Anlage integriert. Die Messung geschieht durch den Strahlengang des Lasers. (SPEARS & GOLD 2016) Bei den on-Axis Messsystemen handelt es sich prinzipiell um räumlich indirekt auflösende Messverfahren. (KRAUSS 2016, S. 38) Da die Optik auf die Wellenlänge des Lasers optimiert ist, ist der zu beobachtenden Wellenlängenbereich eingeschränkt und es werden Filter und Korrekturoptiken benötigt. (CLIJSTERS et al. 2014) Nachdem die Strahlung die optisch Einheit durchlaufen hat, wird sie durch einen Strahlenteiler von dem Laserlicht getrennt. Der Vorteil der on-Axis Konfiguration ist, dass genauere Aussagen über das Schmelzbad getroffen werden können. Dafür sind aber nur begrenzt Aussagen über die thermische Vorgeschichte des Materials möglich. Nach KRAUSS (2016, S. 43) stellt die on-Axis Betrachtung wegen dem hohen Detaillierungsgrad die Grundlage für eine echtzeitnahe Prozessregelung dar.

3.2 Anwendungen von Regelungskonzepten und Methoden des maschinellen Lernens beim Laserstrahlschmelzen

Während die meisten Qualitätssicherungsansätze beim Laserstrahlschmelzen die Qualität vor oder nach dem Bauprozess kontrollieren, ist es mit der Online-Prozessüberwachung schon während des Prozesses möglich auf Qualitätsabweichungen mittels einer Regelung zu reagieren. Nach DIN IEC 60050-351 ist das Regeln ein Vorgang, bei dem fortlaufend eine Größe, die Regel- oder Messgröße erfasst, mit einer anderen Größe, der Führungsgröße, verglichen und im Sinne einer Angleichung an die Führungsgröße beeinflusst wird. (DIN IEC 60050-351) Als Eingangsgrößen für den Regler werden bei der Online-Prozessüberwachung beim Laserstrahlschmelzen aus den Messgrößen Qualitätsindikatoren gebildet. Diese können zum Beispiel die Temperatur, die Geometrie des Schmelzbades oder Prozessstörungen, wie Spritzerbildung oder der Balling Effekt, sein. (VLASEA et al. 2015) Die von dem Regler kontrollierbaren Größen stellen alle während des Prozess änderbaren Prozessparameter dar. Diesbezüglich hat sich nach

STEEN & MAZUMDER (2010) wegen der einfacheren Umsetzung vor allem die Kontrolle der Laserleistung und des Lasefokus etabliert. Allerdings ist auch eine Änderung der Scangeschwindigkeit oder der Belichtungsstrategie möglich. In Abbildung 3.3 ist das Blockdiagramm eines Reglers beim Laserstrahlschmelzen dargestellt.

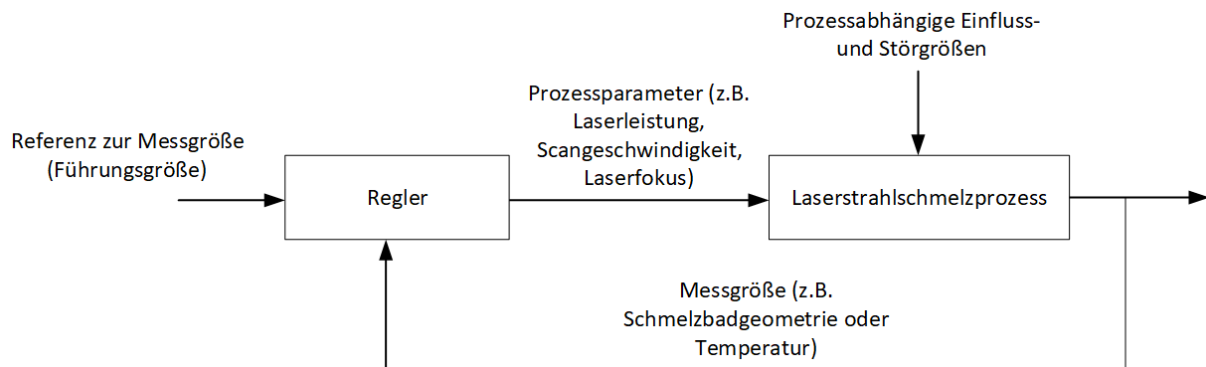


Abbildung 3.3: Blockdiagramm eines Reglers beim Laserstrahlschmelzen in Anlehnung an FOX et al. (2016)

Als Regler werden meist PID Regler oder in wenigen Fällen auch modellprädiktive Regler eingesetzt. Der Reglerentwurf basiert meist auf Heuristiken oder Systemidentifikationen¹ und selten auf physikalischen Modellen. (VLASEA et al. 2015) Ein Beispiel für einen PID Regler ist in CRAEGHS, BECHMANN et al. (2010) zu finden. Hier wurde die Schmelzbadgeometrie mit einer CMOS Kamera erfasst, und es wurde ermittelt, dass diese eine gute Korrelation mit dem Signal einer on-Axis Photodiode aufweist. Das Signal der Photodiode wurde dann als Messgröße für einem PID Regler, welcher die Laserleistung als Regelgröße anpasst, verwendet. Insgesamt wurde eine Verbesserung der Oberflächenqualität erreicht. Des Weiterem wird in REUTZEL & NASSAR (2015) eine Regelung der Belichtungsreihenfolge vorgestellt. Die Reihenfolge, in der die einzelnen Scanvektoren belichtet werden, wurde aufgrund eines Pyrometersignals verändert. Eine Verbesserung des Gefüges konnte dadurch erreicht werden. In RENKEN et al. (2017) wird einer Multisensorkonzept, welches mit Abstandssensoren Unterschiede in der Schichtdicke feststellt und diese zusammen mit anderen während des Schmelzprozesses bestimmten Messgrößen aus einer Infrarotkamera einem Regler übergibt, der eine Anpassung der Laserleistung vornimmt. Dabei wird aus Messgrößen von einem Modell Prozesscharakteristika oder Indikatoren wie die Einschweißtiefe berechnet. Das Modell wird während des Prozesses angepasst, wodurch es sich hier um einen selbstlernenden Ansatz handelt. Nach RENKEN et al. (2017) ist das Ermitteln der Indikatoren aus den

¹Systemidentifikation beschreibt die theoretische oder experimentelle Ermittlung einer quantitativen Abhängigkeit einer Aus- und Eingangsgröße.

Signal­daten, die gut mit Qualitätsmerkmalen korrelieren, ein entscheidender Schritt um ein Regelung zu implementieren. Hierfür können Methoden des maschinellen Lernens einen großen Beitrag leisten. In GOBERT et al. (2018) wurde zum Beispiel den mit einer Kamera während des Schmelzprozesses aufgenommen Bildern lokal Defekte zugewiesen, die zuvor mit der CT detektiert wurden. Auf die so gelabelten Daten wurde der Klassifikationsalgorithmus Support Vector Machine angewandt. Der trainierte Algorithmus erreichte eine Genauigkeit von 80%. Bei der Forschung vom AMINZADEH (2016) wird eine hochauflösende im sichtbaren Wellenlängenbereich sensitive Kamera verwendet um Bilder von der aufgeschmolzenen Oberfläche nach der Belichtung aufzunehmen. Anschließend wurden in diesen Bildern mit verschiedenen Algorithmen aus der Bildverarbeitung Defekte detektiert. Dabei wurden in 85 % der Fälle die an Schliffbildern ermittelten Defekte richtig detektiert. Diese Informationen über die Defekte wurden zum Trainieren eines Bayesischen Klassifikationsalgorithmus genutzt, um poröse von nicht porösen Schichten zu unterscheiden. Eine Genauigkeit von 89% wurde erreicht. In KHANZADEH et al. (2018) werden mehrere Klassifikationsalgorithmen angewendet, um den Zusammenhang zwischen der von einer Kamera bestimmten Schmelzbadgeometrie und der Porosität zu erfassen. Die Daten wurden dabei mit Defekten gelabelt, die mit der CT detektiert wurden. Der KNN Algorithmus erreichte die höchste Genauigkeit mit 98%.

3.3 Schlussfolgerungen aus dem Stand der Technik

Zur Qualitätsüberwachung werden verschiedene Sensortechniken eingesetzt. Als am vielversprechendsten sind optische Sensoren zu sehen, welche in einer on-Axis und off-Axis Konfiguration eingebaut werden können. Zudem können unterschiedliche Prozesscharakteristika durch verschieden sensitive Sensoren in den einzelnen Wellenlängenbereichen erfasst werden. (BAYERLEIN & ZÄH 2016) Bisherige Ansätze der Indikatorenbildung adressieren kurzzeitige zufällige Prozessschwankungen nur unzureichend. Das liegt zum einen an den zu geringen Messfrequenzen einiger Sensoren (z.B. Infrarotkameras) und zum anderen an der schwierigen Indikatorenbildung für solche Prozessphänomene. Das führt bei den betrachteten Regelungskonzepten, welche die Indikatoren als Eingangsgröße nutzen, dazu, dass nur mittel- und langfristige Prozessabweichungen ausgeregelt werden können und auf die beim Laserstrahl auftretende mehr oder weniger zufällige Defektbildung nicht reagiert werden kann. Potential um genauere Indikatoren zu ermitteln bieten Ansätze des maschinellen Lernens in Kombination mit einem zeitlich hochauflösenden Sensoren, wie zum Beispiel einer Photodioden.

4 Material und Methoden

In den nachfolgenden Kapiteln wird zunächst die Versuchsanlage, der Werkstoff, sowie das verwendete MPM Messsystem beschrieben. Des Weiteren folgt eine Darstellung der verwendeten Prüfverfahren zur Dichtemessung.

4.1 Versuchsanlage und Werkstoff

In diesem Kapitel folgt eine Einführung der Versuchsanlage SLM 125^{HL} und des verwendeten Werkstoffs AlSi10Mg.

4.1.1 Versuchsanlage

Im Rahmen dieser Arbeit wurden Versuche an der Laserstrahlschmelzanlage SLM 125^{HL} durchgeführt. Die Anlage ist mit einem 400 W Ytterbium Faserlaser, welcher eine Wellenlänge von 1070 nm aufweist, ausgestattet. Die maximale Scangeschwindigkeit beträgt $10 \frac{m}{s}$ und das Bauvolumen $125 \times 125 \times 125 \text{ mm}^3$. (SLM 2018) Die Bauplattform wird in dieser Arbeit auf eine Bauplattformvorheiztemperatur von 200 °C vorgeheizt, um thermische Spannungen zu mindern und eine gute Anbindung der ersten Schichten zu gewährleisten. (KRAUSS 2016, S. 17) Zudem wird die Schutzgasströmung, welche von der Einlass- zur Auslassdüse strömt, von einem Umluftfiltersystem erzeugt. (HESS 2015) Das Filtersystem reinigt das Schutzgas und führt es dem Prozess wieder zu. Es findet somit eine Umwälzung des Schutzgases statt. Nach LADEWIG et al. (2016) sollte das Schutzgas möglichst gleichgerichtet und laminar sein, um eine gute Bauteilqualität zu erreichen. Als Schutzgas wird in dieser Arbeit Argon verwendet.

4.1.2 Aluminiumlegierung AlSi10Mg

In dieser Arbeit wird ausschließlich die Aluminiumlegierung AlSi10Mg verwendet. AlSi10Mg wird wegen seiner sehr guten Schweißbarkeit, seiner guten Korrosionsbeständigkeit und seiner hohen spezifischen Festigkeit¹ viel in Leichtbauanwendungen in der Automobil- und Luftfahrtindustrie eingesetzt. (CALIGNANO et al. 2018) Für die Fertigung komplexer Leichtbaustrukturen stellt das Laserstrahlschmelzen ein attraktives Verfahren dar. Allerdings ist der Laserstrahlschmelzprozess mit AlSi10Mg Pulver im Vergleich zu anderen Materialien wie rostfreier Stahl oder Titanlegierungen nur schwer beherrschbar. (Y. LI & GU 2014) Das liegt an der hohen Reflektivität von 91%², an dem hohen Wärmeleitfähigkeitskoeffizienten von $146 \frac{W}{mK}$ und an der schlechten Fließfähigkeit des Pulverwerkstoffs. (ABOULKHAIR et al. 2014) Die hohe Reflektivität führt dazu, dass mit einem höheren Energieeintrag gefertigt werden muss, da ein Großteil der Energie reflektiert wird. Der hohe Wärmeleitfähigkeitskoeffizient kann zu einer schlechten Benetzung mit der Schmelze und somit zu Balling Effekten führen. Deshalb sind für anspruchsvolle Anwendungen Qualitätssicherungsmaßnahmen, wie zum Beispiel die Online-Prozessüberwachung, notwendig.

In Tabelle 4.1 ist die chemische Zusammensetzung (mit dem Massenanteil wt in %) von AlSi10Mg angegeben. Die Pulverkörner des in dieser Arbeit verwendeten Pulverwerkstoffs wurden gasverdüst und weisen eine Größenverteilung von $20 \mu m$ bis $63 \mu m$ auf. (SLM2 2018)

Tabelle 4.1: Zusammensetzung von AlSi10Mg (SLM2 2018)

Element	Al	Si	Mg	Cu	Fe	Mn	Zn	Ti	Ni	Pb	Sn	Andere
wt in %	Rest	9-11	0,2-0,45	0,05	0,55	0,45	0,1	0,15	0,05	0,05	0,05	0,05-0,15

4.2 Online-Prozessüberwachung mit dem MPM Messsystem

In diesem Kapitel wird die Online-Prozessüberwachung mit dem MPM Messsystem der Firma SLM Solutions Group AG beschrieben. Dabei wird zuerst auf das Funktionsprin-

¹Die spezifische Festigkeit beschreibt das Verhältnis aus Festigkeit und Dichte.

²Die Reflektivität gibt den Anteil der elektromagnetischen Strahlung der von der Oberfläche reflektiert wird an. Der Wert ist neben dem Material auch noch von der Wellenlänge des Lasers und von dem Einstrahlwinkel abhängig.

zip und anschließend auf die Messdaten, die das Messsystem generiert, eingegangen.

4.2.1 Funktionsprinzip des MPM Messsystems

Der prinzipielle Aufbau des Messsystems und des optischen Aufbaus der Anlage ist in Abbildung 4.1 dargestellt. Die Strahlung aus dem Schmelzbad wird von zwei Photodioden, die in on-Axis Konfiguration eingebaut sind, gemessen. Die emittierte Strahlung wird durch den Strahlenteiler 1 abgelenkt, und vom Strahlengang des Laserlichts getrennt. Strahlenteiler 2 teilt die Strahlung anschließend in die von den beiden Photodioden betrachteten Strahlenanteile. (ALBERTS et al. 2017) Das Messsystem betrachtet sowohl das Schmelzbad, als auch einen Teil des Wärmeeinflussbereiches. (RICHTER 2017) Der Messwert der Photodiode stellt somit eine Mittelung über beide Bereiche dar. Die Photodioden weisen einen unterschiedlich sensitiven Wellenlängenbereich auf, wobei beide Wellenlängenbereiche im nahinfraroten Spektrum liegen. (ALBERTS et al. 2017) In diesem messen die meisten optischen Sensoren in der Online-Prozessüberwachung, da in diesem Bereich die Wärmestrahlung aus dem Schmelzbad bei den im Prozess auftretenden Temperaturen die größte Strahlungsintensität aufweist. (PLANK 1900) Die Strahlung wird von den Photodioden zeitkontinuierlich gemessen und somit erzeugen diese ein analoges Signal. Dieses analoge Signal wird von einem Analog-Digital-Wandler (englisch Analog Digital Converter [ADC](#)) in ein digitales, also zeit- und wertdiskretes, Signal umgewandelt. Nach der Umwandlung werden die Signale in einem Field Programmable Gate Array ([FPGA](#)) weiter verarbeitet. Das [FPGA](#) übernimmt die Zeitsteuerung der Signale und andere Rechenoperationen. (ALBERTS et al. 2016) In ALBERTS et al. (2017) werden Photodiode 1 und Photodiode 2 bzw. der zugehörige [ADC](#) mit ADC1 und ADC2 benannt. Diese Notation wird in dieser Arbeit verwendet. Die [ADC](#) tasten in der Standardeinstellung das Signal mit einer Messfrequenz von 100 kHz ab. Mit dieser Frequenz wird auch in dieser Arbeit gemessen.

Während des Bauprozesses wird das Signal mittels der Online-Software von SLM an den Positionen der Signalentstehung auf der Bauplattform verortet, und graphisch in einem 2D-Plot der Bauplattform dargestellt. Die Messdaten werden für jede Schicht mit einem Zeitstempel versehen und abgespeichert. (ALBERTS et al. 2017) Neben den Photodiodenmessdaten werden noch weitere Mess- und Anlagendaten gespeichert, auf die im Folgenden eingegangen wird.

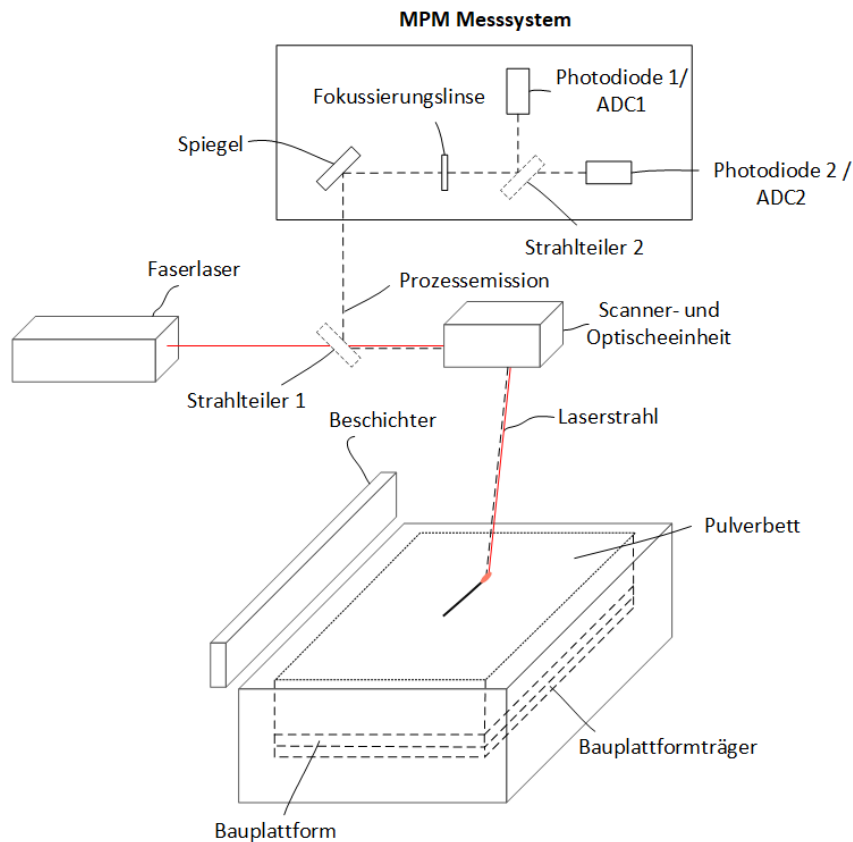


Abbildung 4.1: Schematische Darstellung des optischen Aufbau des *MPM* Messsystem in Anlehnung an ALBERTS et al. (2016) und ROSENKRANZ et al. (2018)

4.2.2 Messdaten aus der MPM Prozessüberwachung

Da es sich bei Software des *MPM* Systems um eine sogenannte proprietäre³ Software handelt, musste der Aufbau des Datenformats, in dem die einzelnen Schichten abgespeichert sind, erst entschlüsselt werden. Diese Aufgabe wurde in der Bachelorarbeit von SCHEWZOW (2018) gelöst. Dabei wurde ein Programm implementiert, das die Schichtdaten, welche in einem bin Format gespeichert sind, in das csv Format umwandelt. Das csv Format wurde gewählt, da hier in den gängigen Programmiersprachen, wie Python und MATLAB, hoch entwickelte und schnelle Algorithmen für den Datenimport bereitgestellt werden. Die Ergebnisse der Arbeit von SCHEWZOW (2018) werden im Folgenden kurz zusammengefasst.

In Abbildung 4.2 ist eine Schichtdatei in einem Hex-Editor dargestellt. Dieser stellt die

³Proprietär ist eine Software, welche die Möglichkeiten der Weiterverwendung sowie Änderung und Anpassung durch Dritte stark einschränkt. (DONOVAN 1994)

Daten in dem hexadezimal Format dar. In der hexadezimal Codierung, werden die 256 Zustände eines Bytes durch jeweils zwei Zeichen kodiert. (KNUTH 2006) Mit dem Hex-Editor wurden Muster in den Daten erkannt und letztendlich zehn unterschiedliche Variablen (Var1 bis Var10) identifiziert, welche immer in der gleichen Reihenfolge in den Daten vorliegen.



Abbildung 4.2: Darstellung einer Schicht in dem hexadezimal Dateiformat mit einem Hex-Editor nach SCHEWZOW (2018)

Um zu untersuchen ob mehrere Variablen die gleiche Messgröße beschreiben, wurden die Variablen gegeneinander graphisch aufgetragen. Dadurch wurden vier der zehn Variablen als Zusatzvariablen identifiziert, welche einen Zwischenzustand der 256 diskreten Zustände beschreiben. Somit ergeben sich sechs Messgrößen, welche sich wie folgt aus den zehn Variablen berechnen lassen.

x-Position:

$$Var6 + \frac{Var5}{255} \quad (4.1)$$

y-Position:

$$Var8 + \frac{Var7}{255} \quad (4.2)$$

Photodiodenmessdaten ADC1:

$$Var2 + \frac{Var1}{255} \quad (4.3)$$

Photodiodenmessdaten ADC2:

$$Var4 + \frac{Var3}{255} \quad (4.4)$$

Die letzten beiden Messgrößen werden durch Var9 und Var10 beschrieben. In Var9 sind Informationen über die analoge Laserleistung, die der Anlage übergeben wird, enthalten. Und Var10 unterscheidet zwischen den einzelnen Belichtungszuständen. Das heißt zum einen ist hinterlegt ob der Laser an oder aus ist, und zum anderen wann das Skywriting stattfindet. Mit Var10 ist es möglich die Daten zu filtern, so dass nur noch Messpunkte,

an denen mit dem Laser belichtet wurde, enthalten sind. In Abbildung 4.3 sind alle Messgrößen des MPM Systems in einer Schicht als Zeitreihendarstellung aufgetragen.

Es sei darauf hingewiesen, dass in den Daten nicht enthalten ist ob es sich um eine Belichtung der Kontur oder des Innenbereichs handelt. Diese Information ist allerdings wichtig für die Datenanalyse. Eine Möglichkeit, um zwischen Kontur und Innenbereich zu unterscheiden, bieten die Messdaten der x-Position auf der Bauplattform. In Abbildung 4.3 oben ist zu erkennen, dass die x-Position nach der Belichtung der Kontur einen Sprung aufweist. Diesen Sprung kann man durch eine Bildung der Differenz zweier aufeinander folgender Datenpunkte detektieren und so zwischen Kontur und Innenbereich unterscheiden.




Abbildung 4.3: Zeitreihendarstellung aller Messgrößen

Des Weiteren sind alle Datenpunkte zwischen 0 und 255 skaliert, da dies den Wertebereich eines Byte darstellt. In der MPM Software sind Anpassung der Skalen hinterlegt, welche allerdings für ADC1 und ADC2 nur näherungsweise durch einen Vergleich mit den Darstellungen aus der MPM Software rekonstruiert werden können. Deshalb wird in dieser Arbeit darauf verzichtet und die Photodiodenmesswerte als dimensionslos angesehen. Für die x- und y-Position wurde eine Korrektur der Werte durch ein Vergleich mit der Software zur Versuchs Vorbereitung Materialise Magics ermittelt. Diese Korrektur wird mit Formel 4.5 und 4.6 berechnet.

$$x = x_{unkor} * 0.5144mm - 66.7748mm \quad (4.5)$$

$$y = y_{unkor} * 0.5144mm - 64.1054mm \quad (4.6)$$

Alle Variablen bzw. Messgrößen werden in $10 \mu s$ Schritten gemessen (Messfrequenz 100 kHz). Die zehn Variablen benötigen jeweils einen Speicherplatz von einem Byte. Insgesamt ergibt sich so eine Datenübertragungsrate von $10 \frac{MB}{s}$. Dieser vermeintlich kleine Wert führt allerdings unter Berücksichtigung der Bauzeit, die sogar Tage dauern kann, zu großen Datenmengen. Zum Beispiel generiert ein eintägige Bauzeit mit einer Belichtungszeit von 90 % eine Datenmenge von 865 GB. (SPEARS & GOLD 2016)

4.3 Dichtemessungen beim Laserstrahlschmelzen

Als Dichte versteht man in der Regel das Verhältnis aus Gewicht und Volumen. Die relative Dichte, welche auf die absolute Materialdichte bezogen ist und in Prozent angegeben wird, hat nach SPIERINGS, SCHNEIDER et al. (2011) unter Berücksichtigung der Porosität einen direkten Einfluss auf die mechanischen Kennwert, wie die Zugfestigkeit oder das Elastizitätsmodul. Die relative Dichte oder Porosität stellt somit ein wichtiges Qualitätsmerkmal dar, und Prozessparameter werden in der Regel auf eine geringe Porosität hin optimiert. (SPIERINGS, SCHNEIDER et al. 2011) In der Literatur wird sowohl die relative Dichte eines Bauteils als auch die Porosität als Qualitätsmerkmal verwendet. Die Porosität wird durch Subtraktion der relativen Dichte von 100% berechnet. In dieser Arbeit wird ausschließlich die Porosität verwendet, um eine Verwechslung der relativen und absoluten Dichte zu vermeiden. Für die Dichtemessung wird beim Laserstrahlschmelzen das archimedische Verfahren, die quantitative Analyse metallographischer Schlifffbilder und die Computertomographie, herangezogen. Die Computertomographie ermöglicht eine 3D-Rekonstruktion eines Bauteils mit der Defekte nicht nur detektiert, sondern auch lokalisiert werden können. Dadurch kann direkt, wie in GOBERT et al. (2018) vorgestellt, der Zusammenhang zwischen Signalcharakteristika aus dem Online-Prozessüberwachungsmesssystem und Defekten erfasst werden.

In dieser Arbeit wird das archimedische und metallographische Verfahren zur Dichtebestimmung angewandt und im Folgenden genauer betrachtet.

4.3.1 Dichtemessung nach Archimedes

Die Dichtemessung nach Archimedes beruht auf dem archimedischen Prinzip und hat den Vorteil, dass keine ungenaue Bestimmung des Volumens wie bei rein gravimetri-

schen Dichtemessung notwendig ist. Dieses besagt das der Auftrieb eines Körpers in einem Medium genauso groß ist wie die Gewichtskraft des von dem Körper verdrängten Medium. (HEATH 1897) Bei dem archimedischen Verfahren werden die Bauteile zuerst in einer Flüssigkeit, in der Regel Isopropanol oder Ethanol, und dann in Luft gewogen. In Abbildung 4.4 ist die Messung einer Probe in einer Flüssigkeit und in Luft dargestellt. Durch den Aufbau wird die Gewichtsmessung der Probe von dem Gewicht des Aufbaus entkoppelt.




Abbildung 4.4: Messung einer Probe mit dem archimedischen Verfahren in Anlehnung an SPIERINGS, SCHNEIDER *et al.* (2011). links: in einer Flüssigkeit. rechts: in Luft

Die Dichte der Probe ρ_P wird mit dem Gewicht der Probe in der Luft m_L und in der Flüssigkeit m_{Fl} sowie der Dichte der Flüssigkeit ρ_{Fl} über Formel 4.7 berechnet. Dabei ist ρ_{Fl} temperaturabhängig. Deshalb wird die Temperatur der Flüssigkeit mit einem Thermometer gemessen und bei jeder Messung notiert. ρ_{Fl} wird dann für die jeweilige Temperatur aus Tabellenwerten ausgelesen. Als Flüssigkeit wird in dieser Arbeit Isopropanol verwendet.

$$\rho_P = \frac{m_L}{m_L - m_{Fl}} \cdot \rho_{Fl} \quad (4.7)$$

Um die relative Dichte zu erhalten wird ρ_P durch die Materialdichte des Werkstoffs ρ_{Werk} , welche für AlSi10Mg $2,68 \frac{g}{cm^3}$ beträgt, geteilt und in Prozent umgerechnet. Durch eine Subtraktion der relativen Dicht von 100% erhält man die archimedisch bestimmte Porosität P_A .

Jede Probe wird jeweils drei mal in der Luft und in der Flüssigkeit gemessen. Die Messwerte in der Luft und in der Flüssigkeit werden gemittelt, um Einflüsse des Messsystems zu mindern. Neben den Fehlern bei der Gewichtsmessung, verringert auch der Fehler bei dem Ablesen der Temperatur die Genauigkeit der Messung. Für den Fehler beim

Temperaturablesen wird angenommen, dass ein Temperaturfehler von $\pm 1^\circ\text{C}$ zu einem Dichtefehler von $\pm 1,2 \frac{\text{kg}}{\text{m}^3}$ führt. Der mittlere Temperaturablesefehler wird auf $0,5^\circ\text{C}$ geschätzt. Der Gesamtfehler der Messung wird über die Fehler in der Dichte durch die Messfehler bei der Gewichtsbestimmung in Luft $\Delta\rho_{PL}$, in der Flüssigkeit $\Delta\rho_{FL}$ und bei der Temperaturmessung $\Delta\rho_{FT}$ bestimmt. In Formel 4.8 ist die Berechnung des Relativfehlers $\Delta\rho_{Prel}$ eingeführt.

$$\Delta\rho_{Prel} = \frac{\sqrt{\Delta\rho_{PT} + \Delta\rho_{PL} + \Delta\rho_{PFL}}}{\rho_{Werk}} \cdot 100\% \quad (4.8)$$

Luftblasen an der Oberfläche können die Genauigkeit der Gewichtsbestimmung in der Flüssigkeit negativ beeinflussen. (SPIERINGS, SCHNEIDER et al. 2011) Zum einen kann dieser Einfluss gemindert werden indem ein geringeres Oberflächen zu Volumen Verhältnis der Probe gewählt wird. Deshalb sollten z.B. Würfelgeometrien, welche auch in dieser Arbeit verwendet werden, mindesten eine Kantenlänge von 10 mm aufweisen. (VDI-Richtlinie 3405 Blatt 2) Andererseits kann die Luftblasenbildung durch ein Abschleifen der Oberfläche gemindert werden. Alle archimedisch gemessenen Proben dieser Arbeit wurden vor der Messung abgeschliffen. In Abbildung 4.5 ist ein Würfelprobe vor und nach dem Abschleifen dargestellt.




Abbildung 4.5: links: Würfelprobe vor dem Abschleifen. rechts: Würfelprobe nach dem Abschleifen

Im Allgemeinen liegt der Vorteil der archimedischen Dichtebestimmung in ihrem geringem Aufwand und der Erfassung des gesamten Volumens einer Probe. Allerdings sind nach WITS et al. (2016) in Bindefehler häufig unaufgeschmolzenes Pulver eingeschlossen. Dies führt zu einer Ungenauigkeit des archimedischen Verfahrens bei der Dichtebestimmung an Proben mit vielen Bindefehlern. Ein weiterer Nachteil dieses Verfahrens ist, dass keine Aussagen über das Gefüge oder Verteilung und Form der Defekte möglich ist. (VDI-Richtlinie 3405 Blatt 2) Dies ist allerdings mit einer metallographischen Untersuchung realisierbar, auf welche im nächsten Kapitel eingegangen wird.

4.3.2 Metallographische Dichtebestimmung

Bei der Metallographie handelt es sich um ein zerstörendes Prüfverfahren, dessen Aufgabe die qualitative und quantitative Beschreibung von Gefügen und Fehlstellen ist. (SCHUMANN & OETTEL 2004, S. 55) Beim Laserstrahlschmelzen wird die Dichtebestimmung oder Porositätsanalyse als Bestandteil der quantitativen Gefügeanalyse angewandt und erlaubt eine Bestimmung der relativen Dichte. (VDI-Richtlinie 3405 Blatt 2) Diese ist zur archimedisch ermittelten relativen Dichte vergleichbar. (SPIERINGS, SCHNEIDER et al. 2011) Ein wesentlicher Vorteil gegenüber der Dichtebestimmung nach dem archimedischen Prinzip ist, dass aus den lichtmikroskopischen Aufnahmen und der nachfolgenden Bildverarbeitung neben der relativen Dichte weitere Qualitätsmerkmale wie Größe, Form oder Verteilung von Defekten bestimmt werden kann. (VDI-Richtlinie 3405 Blatt 2) Somit kann auch eine Unterscheidung zwischen den Defektarten, wie Poren, Heißrisse und Bindefehler, über Formfaktoren getroffen werden. (WEINGARTEN et al. 2015)

Die Präparation metallographischer Proben wird in die Schritte Probenentnahme, Einbetten, Schleifen, Polieren und evtl. Kontrastieren oder Ätzen eingeteilt. (SCHUMANN & OETTEL 2004, S. 135) Die Probenentnahme erfolgt in dieser Arbeit, wie in Abbildung 4.6 an einem Würfel dargestellt, sowohl in Bauebene (x-y) als auch in Aufbaurichtung (z).

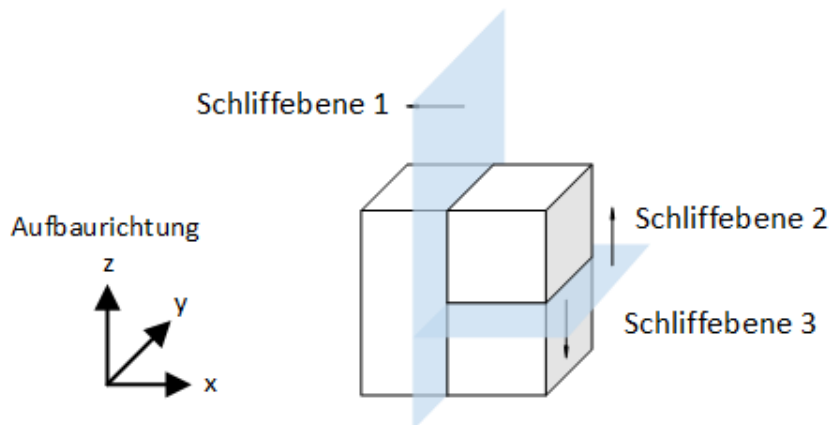


Abbildung 4.6: Schematische Darstellung der Schliffebene für die Probenpräparation in Anlehnung an ROSENKRANZ et al. (2018)

Es werden drei Schliffebene betrachtet, wobei eine in z Richtung und zwei in der x-y Ebenen liegen. Die Proben werden für die Probenentnahme mittels einer Trennschleifmaschine zerteilt. Die Einbettung erfolgt mit Bakelit, ein warmhärtendes Kunstharz, in zylindrischen Formen. Das Schleifen läuft in drei Stufen, von einer gröberen Körnung der Schleiffolie hin zu einer feineren, ab. Es werden jeweils Siliciumkarbid Folien mit

den Körnungen 320 μm , 600 μm und 1200 μm verwendet. Nach dem Schleifen folgt das Polieren in zwei Stufen. In der ersten, gröberen Stufe wird das Poliertuch SIGMA mit einer 3 μm polykristallinen Diamantpaste genutzt. Bei der zweiten, feineren Stufe folgt die Politur mit dem Poliertuch OMEGA und der Poliersuspension Eposil F. Nach der Politur entsteht eine glänzende Oberfläche, an der eine Untersuchung der Defekte, die sich farblich absetzen, durchgeführt wird.

Die Schriffe der Proben wurden mit dem Lichtmikroskop OLYMPUS BX53M bei einer Vergrößerung von 10 zu 1 untersucht, und mit der Bildanalysesoftware OLYMPUS Stream Essential analysiert. Bei dieser Vergrößerung ergibt sich eine Pixelgröße von 620,87 nm. Aus den drei Schriftebenen jeder Probe, wurden für die Aufbaurichtung (z) fünf Bilder und für die beiden Schriffe in der Bauebene jeweils drei Bilder in schwarz-weiß aufgenommen. Innerhalb der Proben wurden jeweils Bereiche mit hoher Defektkonzentration ausgewählt. Dadurch wird eine konservative Schätzung der Porosität durchgeführt.

Im ersten Schritt der Bildverarbeitung, welcher in Abbildung 4.7 dargestellt ist, wurden die Bilder binarisiert, das heißt abhängig davon ob der Grauwert eines Pixels über oder unter einem Schwellwert liegt wird dem Pixel ein dunkler oder heller Grauwert zugewiesen. Nach der Binarisierung weist das Bild nur noch zwei unterschiedliche Grauwerte auf. Die Binarisierung wird durchgeführt um die eine genauere Bestimmung der Formfaktoren zu ermöglichen, das Bildrauschen zu reduzieren und Verunreinigungen oder Kratzer auszuschließen. (SCHUMANN & OETTEL 2004, S. 259)

Zudem wurden Indikationen, die kleiner als zwei Pixel sind, von der Analyse ausgeschlossen. Für die Unterscheidung zwischen den Defektarten zu treffen werden in Anlehnung an die Forschung von WEINGARTEN et al. (2015) und DALGIC (2009) Formfaktoren genutzt. Da den in den Schliffbildern keine Heißrisse zu erkennen waren, wurde die Unterscheidung nur zwischen Gasporen und Bindefehlern getroffen. Gasporen weisen im Gegensatz zu Bindefehlern eine sphärische Form auf und können somit mittels dem Formfaktor der Rundheit, welcher für dieses Anwendungsfall auch von WEINGARTEN et al. (2015) verwendet wird, von den anderen Defektarten unterschieden werden. Die Rundheit Ru wird mit der Fläche A und dem Umfang U des Defekte nach Formel 4.9 berechnet. (SCHUMANN & OETTEL 2004, S. 267)

$$Ru = \frac{4\pi A}{U^2} \quad (4.9)$$

Durch eine Rundheit von 1 wird ein perfekter Kreis beschrieben. Um so geringer Ru desto ungleichmäßiger ist der Defekt geformt. Symmetrie wird in der Rundheit nicht

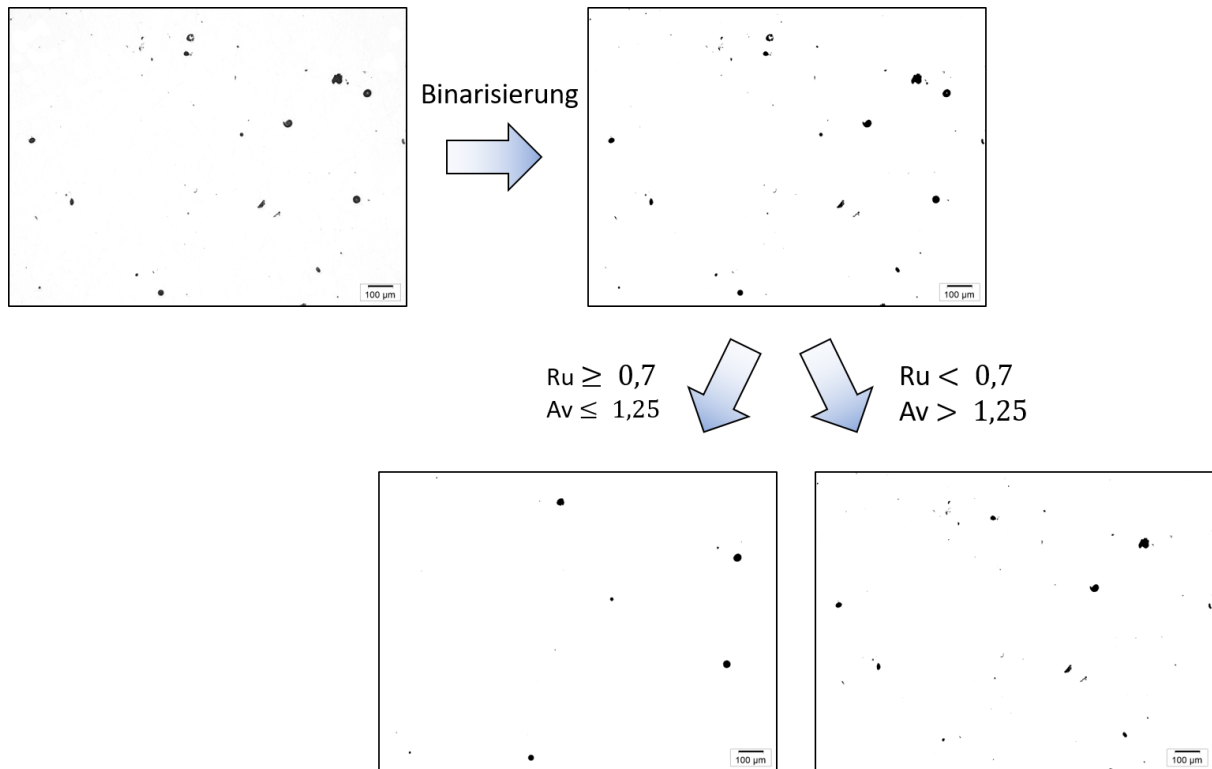


Abbildung 4.7: Vorgehen bei der Defektunterscheidung in der Bildverarbeitung in Anlehnung an ROSENKRANZ *et al.* (2018)

berücksichtigt. Da nach einer Betrachtung der klassifizierten Defekte die Rundheit als Kriterium als nicht ausreichend angesehen wurde, wurde zusätzlich das Aspektverhältnis als Unterscheidungskriterium eingeführt. Das Aspektverhältnis wird über den minimalen und maximalen Durchmesser d_{min} und d_{max} mit Formel 4.10 berechnet. Der minimale Durchmesser wird dabei an jedem Defekt zuerst bestimmt und der maximale Durchmesser ist als orthogonal zu diesem definiert. (SCHUMANN & OETTEL 2004, S. 267)

$$A_v = \frac{d_{max}}{d_{min}} \quad (4.10)$$

Ein Aspektverhältnis von 1 beschreibt wiederum einen perfekten Kreis. Defekte, die ein Aspektverhältnis kleiner gleich 1,25 und eine Rundheit größer gleich 0,7 aufweisen, wurden als Gasporen klassifiziert. Alle anderen Defekte als Bindefehler. Diese Klassifizierung ist in Abbildung 4.7 dargestellt. Die Klassifizierungsgrenzen stellen keine Literaturwerte dar, sondern wurden nach subjektiver Einschätzung festgelegt.

Im weiteren Verlauf wird die metallographisch ermittelten Porosität P_M , die durch Bindefehler und Gasporen entsteht, verwendet. Diese wird berechnet indem die Fläche der Defekte durch die Fläche des gesamten Bildes geteilt wird.

5 Versuchsplanung und -durchführung

Die Versuche die im Rahmen dieser Arbeit durchgeführt wurden, lassen sich in zwei Abschnitte aufteilen. In dem ersten Abschnitt werden Daten generiert mit dem der Analysealgorithmus trainiert wird. Hierfür ist es notwendig Bauteile mit unterschiedlicher Qualität, insbesondere unterschiedlicher Dichte, herzustellen. Zudem sollen die Bauteile sich in der Menge und Art der im Bauprozess auftretenden Störungen, welche in Kapitel 2.3 beschrieben wurden, unterscheiden. Aus diesem Grund wurden Prozessparameter variiert um die beschriebenen Effekte zu erzeugen.

Der zweite Abschnitt dient zur Validierung oder zum Test der Algorithmen. Dabei wird die Robustheit des Algorithmen getestet indem andere Parameterstufen gefertigt werden. Zudem werden Bauraumuntersuchungen bezüglich der Dichte und der Photodiodensignale durchgeführt.

5.1 Generierung von Daten zum Trainieren der Algorithmen

Zur Generierung eines Datensatzes mit dem der Algorithmus trainiert werden kann, wird in dieser Arbeit ein statistischer Versuchsplan verwendet, um die Wechselwirkungen zwischen den einzelnen Parametern statistisch zu erfassen und die Versuchsanzahl zu reduzieren.

In diesem Kapitel wird zuerst auf die Grundlagen der statistischen Versuchsplanung eingegangen, und anschließend die Versuchsdurchführung der Versuche zur Generierung der Trainingsdaten beschrieben.

5.1.1 Statistische Versuchsplanung

Für die Generierung des Testdatensatzes wurden drei Versuche, auch Baujobs genannt, durchgeführt. Der Versuchsplan, welcher für die drei Baujobs identisch ist, wurde mittels statistischer Versuchsplanung erstellt. Die statistische Versuchsplanung, auch

Design of Experiments (DoE) genannt, dient zur effizienten Planung von Versuchen und Optimierung von Prozessen. (SIEBERTZ et al. 2017, S. 1-2) Durch die statistisch abgesicherte und kombinatorische Variation mehrerer Parameter kann die Anzahl an benötigten Versuchen verringert und Wechselwirkung zwischen den Parametern erfasst werden. (KLEPPMANN 2010, S. 4-5) In der additiven Fertigung kommt die statistische Versuchsplanung meist zur Prozessanalyse oder Qualitätssteigerung zum Einsatz. Beispiele hierfür sind in KRAUSS (2016), PAWLAK et al. (2017) und AVERYANOVA et al. (2012) zu finden.

Der Versuchsplan dieser Arbeit wurde nach dem sogenannten Face Centered Central Composite Design (FCCCD) mit der Software Minitab 2017 erstellt. Eine Versuchsplanung nach einem FCCCD wird benutzt um die Anzahl an Versuchen zu reduzieren, den Prozess empirisch zu modellieren und um die Auswirkung der Parameter, einschließlich ihrer Interaktionen, zu betrachten. (SOOD et al. 2012) Bei den einzelnen Baujobs wurden die Prozessparameter Laserleitung P , Schichtdicke d_s und die z-Verschiebung des Laserfokus und somit der Strahlendurchmesser ϕ nach einem FCCCD Versuchsplan variiert. Diese Parameter wurden gewählt, da sie nach REHME & EMMELMANN (2005) zusammen mit dem Hatchabstand und der Scangeschwindigkeit die wichtigsten Einflussgrößen auf die Bauteilqualität darstellen. Der Hatchabstand und die Scangeschwindigkeit wurden in diesem Versuch wegen dem sonst zu großen Versuchsaufwand konstant gehalten. Der FCCCD Versuchsplan besteht, wie in Abbildung 5.1 dargestellt, aus einem Würfel und einem Stern, wobei der Würfel einen zweistufigen Versuchsplan darstellt. Jeder Punkt in der Abbildung 5.1 stellt ein Prozessparametersatz dar. Der Stern entsteht durch Variation der einzelnen Parameter ausgehend von der Mittelstellung, welcher hier dem Standardparametersatz entspricht. Insgesamt wurden, wie in Abbildung 5.1 zu sehen, Proben mit 15 verschiedenen Parametersätzen gefertigt.

Da die Stufenbreite des Sterns hier nicht über die Grenzflächen des Würfels verändert werden kann, wie es bei dem Central Composite Design (CCD) der Fall ist, wird in dieser Arbeit das FCCCD verwendet. Es wird angenommen, dass die Parameter nicht über die Grenzflächen des Würfels variiert werden dürfen, da dann die Gefahr eines Prozessabbruches besteht. Wegen einer Korrelation der quadratischen Effekte zueinander ist der Informationsgehalt des FCCCD im Vergleich zum ursprünglichen CCD geringer. (SIEBERTZ et al. 2017, S. 40-41) Für weitere Informationen über die statistische Versuchsplanung wird auf SIEBERTZ et al. (2017) und KLEPPMANN (2010) verwiesen.

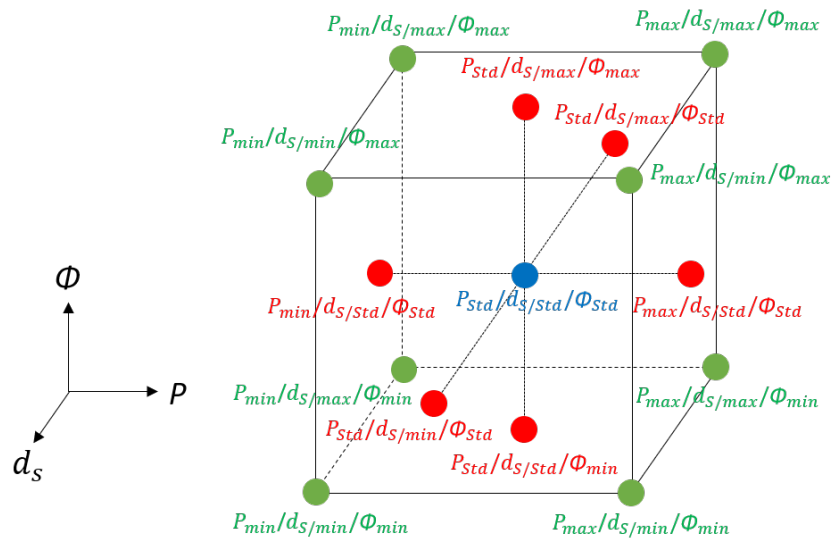


Abbildung 5.1: Face Centered Central Composite Design in Anlehnung an SIEBERTZ et al. (2017, S. 40-41)

5.1.2 Versuchsdurchführung

Zur Generierung des Testdatensatzes wurden Dichtewürfel in drei Baujobs erstellt in denen, wie bereits erwähnt, jeweils die drei Prozessparameter Laserleistung P , Schichtdicke d_s und die z-Verschiebung des Laserfokus auf gleiche Art und Weise variiert wurden. Die Festlegung der Grenzwerte für die Parametervariation beruht dabei Erfahrungswerten des Fraunhofer IGCV. Die Dichte der Würfel wurde, wie in Kapitel 4.3.1 beschrieben, nach dem archimedischen Prinzip ermittelt.

Die drei Baujobs wurden aufeinander aufgebaut, wie in Abbildung 5.2 dargestellt. Die Schutzgasströmung wurde für jeden Baujob anders eingestellt. Hierfür wurde der Anlagenparameter Drehzahl des E-Motors der Gaspumpe D_G , welcher in Prozent der Maximaldrehzahl angegeben wird, variiert. Durch eine Reduktion des D_G -Werts wird auch die Geschwindigkeit der Schutzgasströmung geringer. (RICHTER 2017) Baujob 1 wurde mit dem Standardwert von D_G mit 70% gefertigt. In Baujob 2 wurde der D_G -Wert um 30% vom Standardwert auf 49% und in Baujob 3 um 60% vom Standardwert auf 28% reduziert.

Des Weiteren wurden für jedem Baujob Stützkonstruktionen mit einer Höhe von 2 mm unter den Würfeln aufgebaut, um einerseits beim Trennen der Proben möglichst wenig Material von den Proben wegzunehmen und andererseits um die Wärmeleitung in das darunterliegende Material, welche nach KRAUSS (2016, S. 113) sowohl einen




Abbildung 5.2: Gefertigte Proben auf der Bauplattform

Einfluss auf die Bauteilqualität als auch auf die emittierte Strahlung aus dem Schmelzbad hat, möglichst gleich zu halten. Um die Bauzeit zu verkürzen wurden die eine Stützkonstruktionen mit einer höheren Schichtdicke von $50\ \mu\text{m}$ gefertigt.

Die Prozessparameter Laserleistung P und die Schichtdicke d_s wurden von ihrem Standardwert auf folgende Weise verändert: Die Laserleistung P um $\pm 20\%$ und die Schichtdicke d_s um $\pm 50\%$. Die z -Verschiebung des Laserfokus wurde von ihrem Standardwert um \pm die Rayleigh-Länge z_R variiert.

Mit einer Laserkaustikmessung wurde zuvor ein Wert von $2,618\ \text{mm}$ für z_R bestimmt, welcher für diese Arbeit verwendet wird. Es sei erwähnt, dass der Standardwert für die z -Verschiebung des Laserfokus nicht den geringsten Strahlendurchmesser ϕ aufweist, welcher über Formel 2.2 mit $62,4\ \mu\text{m}$ berechnet wurde. Das liegt daran, dass beim Standardparametersatz der Fokus um $z = -1,482\ \text{mm}$ verschoben ist. Der berechnete Strahlendurchmesser ist in Tabelle 5.1 in Klammern angegeben und wird in der weiteren Arbeit verwendet. In Tabelle 5.1 sind die Abstufungen der verwendeten Parameter dargestellt.

Die Schichtdicke wurde in den Baujobs verändert indem die Anlagenschichtdicke, welche durch den Abstand zwischen Beschichter und Bauplattform eingestellt wird, auf $25\ \mu\text{m}$ gesetzt wurde. Die Proben wurden dann jeweils jede, jede zweite oder jede dritte Schicht belichtet um die gewünschte Schichtdicke herzustellen. Dieses Prinzip ist in Tabelle 5.2 anhand der drei gefertigten Schichtdicken dargestellt. Ein X steht für

eine Belichtung einer Probe in dieser Schicht und bei einem O fand keine Belichtung in dieser Schicht statt.

Tabelle 5.1: Abstufungen der Parametervariationen in einem Baujob

	Minimalwert	Standardwert	Maximalwert
Laserleistung P in W	240	300	360
Schichtdicke d_s in μm	25	50	75
z -Verschiebung in mm (Strahlendurchmesser ϕ in μm)	$z-z_R$ (116,1)	z (71,8)	$z+z_R$ (68,1)

Tabelle 5.2: Darstellung der belichteten Proben in den Schichten

Schichtnummer	25 μm	50 μm	75 μm
1	X	X	X
2	X	O	O
3	X	X	O
4	X	O	X
5	X	X	O
6	X	O	O
7	X	X	X

Da es mit der Software Materialise Magics, in welcher den Proben ihre Lage und Prozessparameter zugewiesen werden, nicht möglich ist eine solche Belichtungsstrategie einzustellen, wurde dieses Verhalten über die CAD Geometrie erzeugt. In Abbildung 5.3 ist am Beispiel einer 75 μm Probe die CAD Geometrie dargestellt. Das Verbindungselement, welches in Abbildung 5.3 rechts zu sehen ist, ist notwendig damit alle Schichten in Magics als ein Bauteil erkannt werden. In der CAD Geometrie haben die einzelnen Schichten eine Dicke von 25 μm und der Abstand zwischen den Schichten beträgt 50 μm . Somit ergibt sich eine Schichtdicke von 75 μm . Für die 50 μm Probe verhält sich dies analog, bis auf das der Abstand zwischen den Schichten dann 25 μm beträgt. Im Anhang sind die technischen Zeichnungen der Proben mit unterschiedlichen Schichtdicken gegeben. Insgesamt wurden 120 Proben in drei Baujobs mit jeweils 40 Proben gefertigt. Dabei wurden in einem Baujob 15 Proben mit unterschiedlichen Parametern nach dem FCCCD Versuchsplan aufgebaut. Zudem wurden noch fünf Proben mit Standardparametern erstellt. Dies erfolgt zum einen um den Standardparametersatz in den Algorithmen eine größere Bedeutung zukommen zu lassen, da die Algorithmen auf diesen Parametersatz am besten funktionieren sollen, und zum anderen um Effekte, die nicht von den beschriebenen Prozessparametern abhängen, zu untersuchen. Des Weiteren wurden für jede Probe ein Replika erstellt, das heißt, dass eine weitere Probe mit dem gleichen Parametersatz gefertigt wurde, um Unterschiede in der Bauraumposition zu erfassen.




Abbildung 5.3: Darstellung der Schichtdickenänderung in der CAD-Geometrie am Beispiel einer 75 μm Probe. Links ist der rechts eingezeichnete Ausschnitt dargestellt.

Die Bauraumposition der Proben wurde über den MATLAB Zufallsgenerator ausgewählt und für jeden Baujob mit dem Zufallsgenerator neu bestimmt. Diese zufällige Auswahl der Bauraumposition wurde durchgeführt, da die Einflüsse der Bauraumposition nicht genau bekannt ist und deshalb eine systematische Auswahl nicht möglich ist. In Abbildung 5.4 sind die Bauraumpositionen der einzelnen Proben in Baujob 1 gegeben. Die Benennung der Proben erfolgt im Baujob 1 von oben links auf der Bauplattform nach unten rechts und entspricht den Nummern, die auf den Bauteilen stehen. Den einzelnen Proben ist der zuvor mit dem Zufallsgenerator ermittelte Parametersatz an dieser Bauraumposition zugewiesen. Die Zuordnung der Parametersätze zu den Nummern ist für alle drei Baujobs identisch. Zudem ist in Abbildung 5.4, das in dieser Arbeit verwendete Koordinatensystem auf der Bauplattformebene, sowie die Richtung der Schutzgasströmung und des Beschichters, dargestellt.

Der Nullpunkt des Koordinatensystems liegt in der Mitte der Bauplattform. Im Anhang sind die Bauraumpositionen für Baujob 2 und 3 gegeben und die Zuordnung der Prozessparameter zu den Probennummern. Zudem wurden die Proben um 10° gedreht, um Kollisionen mit dem Beschichter zu vermeiden, wie in Abbildung 5.4 zu erkennen ist. Wie in Kapitel 2.2.2 beschrieben, gibt es eine Abhängigkeit der Prozessstörungen von dem Drehwinkel der Schichten, welche durch eine Wechselwirkung mit der Schutzgasströmung auftritt. Deswegen wird der Drehwinkelbereich in Schutzgasströmungsrichtung im Standardparametersatz übersprungen. Dieses Überspringen von bestimmten Drehwinkelbereichen wurde für diesen Versuch ausgestellt, um mehr Prozessstörungen zu provozieren und die Drehwinkelabhängigkeit von Prozessstörungen zu untersuchen.

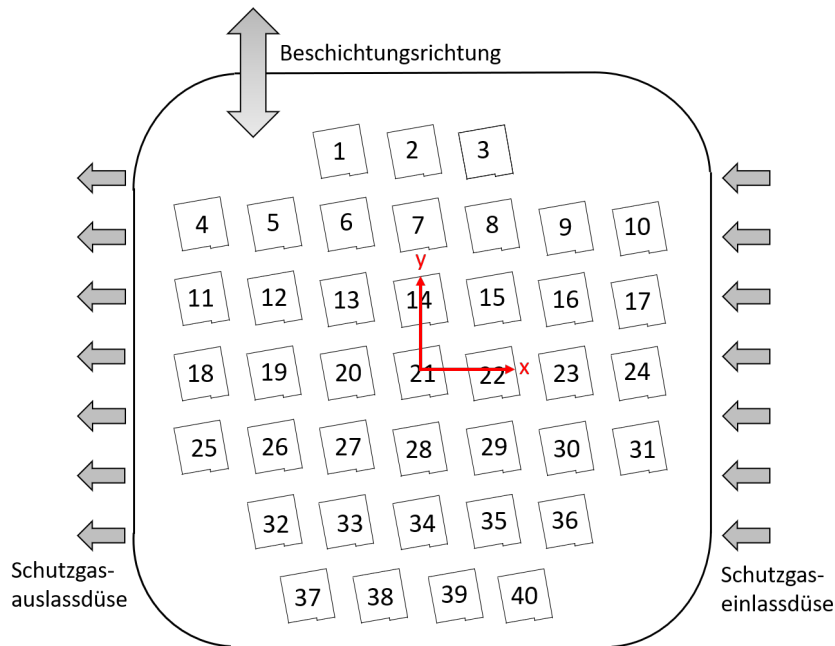


Abbildung 5.4: Anordnung der Proben auf der Bauplattform des Baujob 1

5.2 Versuche zur Validierung der Algorithmen

Dieser Versuch wurde im Rahmen einer Veröffentlichung von ROSENKRANZ et al. (2018) durchgeführt und die Ergebnisse daraus werden für diese Arbeit verwendet. In den Versuchen zur Validierung soll die Robustheit¹ der Algorithmen überprüft werden. Dies geschieht zum einen durch die Anwendung eines anderen Prüfverfahren, der metallographischen Dichtebestimmung, und andererseits durch eine Variation von anderen Prozessparametern oder den gleichen Prozessparametern in anderen Stufen im Vergleich zum Trainingsversuch. Es soll zudem erfasst werden wie stark die Signale oder Algorithmen auf die Änderung der einzelnen Prozessparameter reagieren. Dabei ist es wichtig die Parameter in einer ähnlichen Skalierung zu variieren, um die Größen der Werte vergleichen zu können. Hierfür bietet sich nach ALBERTS et al. (2017) die Volumenenergiedichte Ψ an, welche im Kapitel 2.2.4 eingeführt wurde. In den Versuchen werden fünf Stufen mit unterschiedlicher Volumenenergiedichte gefertigt. Die Prozessparameter Hatchabstand h , Schichtdicke d_s , Laserleistung P und Scangeschwindigkeit v_s werden jeweils so geändert, dass sich bei gleichbleibenden anderen Parametern eine der fünf Volumenenergiedichtestufen ergibt. Die mittlere Stufe entspricht dem Standardparametersatz des Fraunhofer IGCV und ist in Tabelle 5.3 mit einem * markiert. Die nicht

¹Die Robustheit beschreibt wie gut die Algorithmen auf veränderte Systemzustände reagieren, mit denen diese zuvor nicht trainiert wurden.

variieren Parameter werden auf ihrem Standardwert konstant gehalten. Die fünf Stufen von Ψ und die Werte der jeweils geänderten Parametern sind in Tabelle 5.3 angegeben. Die Werte wurden jeweils auf die erste Nachkommastelle gerundet, was der Genauigkeit von Materialise Magics entspricht.

Tabelle 5.3: Volumenenergiedichte und Parameterstufen im Validierungsversuch in Anlehnung an ROSENKRANZ et al. (2018)

Ψ in $\frac{J}{mm^3}$	37,5	34,1	30,7*	27,9	25,1
h in μm	139,1	153,0	170,0*	187,0	207,8
d_s in μm	40,9	45,0	50,0*	55,0	61,1
P in W	366,7	333,3	300,0*	272,7	245,5
v_s in $\frac{mm}{s}$	940,9	1035,0	1150,0*	1265,0	1405,6

Für jeden Parametersatz wurden drei Replika gefertigt, um die Varianz der Ergebnisse bei der metallographischen Dichtemessung zu mindern. Die Variation der Prozessparameter Hatchabstand h , Laserleistung P und Scangeschwindigkeit v_s wurde in einem Baujob durchgeführt. Dabei wurden 39 Proben mit den Parametervariationen sowie 6 Dummy Proben gefertigt. Die Anordnung der Proben auf der Bauplattform und die Zuordnung zu der Nummerierung ist im Anhang gegeben. Die Dummy Proben wurden aufgebaut, um die Laserrückkehrzeit, welche im wesentlichen durch die Probenanzahl bestimmt wird, im Vergleich zu den Schichtdickenbaujobs konstant zu halten. In den vier Schichtdickenbaujobs wurden auch jeweils 45 Proben mit den in der Tabelle 5.3 angegebenen Schichtdicken gefertigt. Zudem wurde die Drehung der Schweißspuren nach jeder Schicht von 67° auf 90° geändert und der Drehwinkelbereich in Schutzgasströmungsrichtung wurde wie auch beim Standardparameter übersprungen. Diese Änderungen wurden im Vergleich zum Trainingsversuch vorgenommen, um andere Prozessbedingungen zu schaffen und so die Algorithmen zu testen.

Es wurde eine hohe Probenanzahl von 45 je Baujob gewählt, um mit den Schichtdickenbaujobs Bauraumuntersuchungen durchführen zu können. Hierfür wurden die Proben, die mit einer Schichtdicke von $40,9 \mu m$ und $61,1 \mu m$ gefertigt wurden, nach dem archimedischen Prinzip geprüft. Zusätzlich wurde noch ein weiterer Versuch mit einer Schichtdicke von $61,1 \mu m$ aufgebaut, bei dem das überspringen des Drehwinkelbereichs in Schutzgasströmungsrichtung ausgestellt wurde. Dies wurde durchgeführt, um Änderungen in der Schutzgasströmung über den Bauraum zu erfassen.

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozessstörungen

In diesem Kapitel wird das Vorgehen bei der Anwendung der [ML](#) Methoden beschrieben. Dafür wird zuerst das Konzept dargestellt, welches in dieser Arbeit angewendet wird, um die Algorithmen zu implementieren. Im speziellen wird hier die Korrelationsmetrik eingeführt, auf der das Konzept aufbaut, und es wird auf die Vorverarbeitung der Messdaten sowie die Feature Auswahl eingegangen. Zum Schluss folgt eine Validierung der Cluster und Feature Auswahl sowie das Trainieren der Klassifikationsalgorithmen. Die gesamten Rechnungen dieser Arbeit wurden auf einer Intel Xeon CPU mit zwei 3.30 GHz Prozessor und 64 GB Arbeitsspeicher durchgeführt. Die angegebenen Rechenzeiten sind entsprechend zu bewerten.

6.1 Konzept zur Implementierung der Algorithmen

Der Ablauf des Vorgehens zur Implementierung der Algorithmen ist in [Abbildung 6.1](#) dargestellt. Die während des Bauprozesses aufgenommenen Messdaten werden für jede Schicht und Probe in einzelne Pixel mit einer Kantenlänge von 1 mm aufgeteilt. Aus den Messdaten in den Pixeln werden Feature generiert, aus welchen dann redundante Feature und Feature mit wenig Informationsgehalt entfernt werden. Zudem folgt eine Standardisierung, um den Skalenbereich der Feature zwischen 0 und 1 festzulegen, sowie eine [PCA](#) zur Dimensionsreduktion. Diese Schritte werden in [Kapitel 6.2](#) beschrieben.

Anschließend erfolgt das Clustering. Aus dem Ergebnis des Clustering werden dann die Summe an Cluster ausgewählt, die am besten mit den Porositäten korrelieren. Hierbei werden die Anzahl an Messpunkten einer Probe die in einem Cluster liegen durch gesamte Anzahl an Messpunkten dieser Probe geteilt, und mit den Porositäten korreliert. Auf den genauen Aufbau dieser Metrik wird im [Kapitel 6.1.2.](#) eingegangen. Nachdem die Cluster ausgewählt wurden, werden sie im Datensatz als Indikation bzw. Prozessstörung gelabelt und die in [Kapitel 2.4.2](#) beschriebenen Klassifikationsalgorithmen werden

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

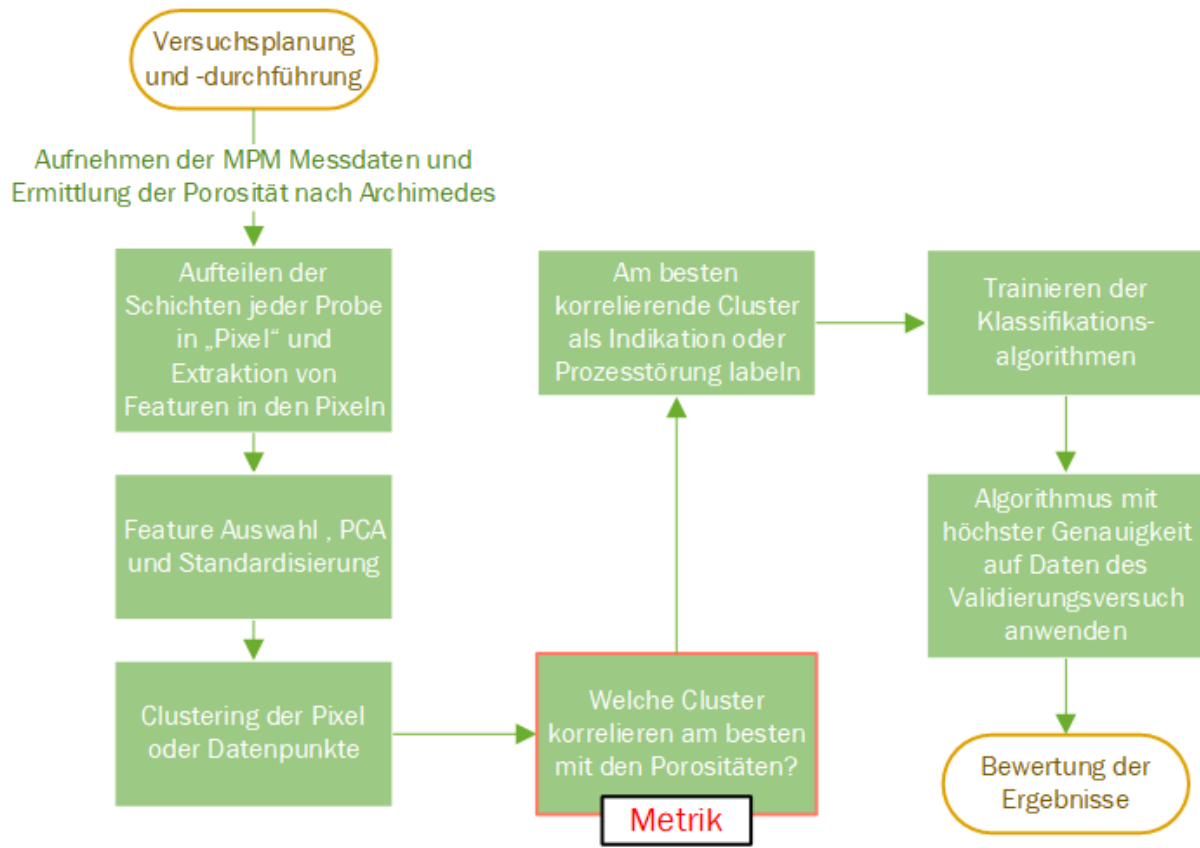


Abbildung 6.1: Ablaufdiagramm des Vorgehens zur Implementierung der Algorithmen

mit den gelabelten Datensatz trainiert. Der trainierte Klassifikator mit der höchsten Genauigkeit wird anschließend auf den Datensatz des Validierungsversuches angewandt, wobei die Daten des Validierungsversuches auf die selbe Weise vorverarbeitet werden wie die Daten des Trainingsversuches. Das bedeutet auch, dass unter anderem die selbe Standardisierung und PCA wie bei dem Trainingsdaten verwendet wird. Zum Schluss folgt eine Bewertung des Konzeptes anhand des Vergleichs der Ergebnisse des Klassifikationsalgorithmus beim Validierungsversuch mit den Ergebnissen aus der Metallographie.

6.1.1 Arten der Korrelation

Korrelation beschreibt die Beziehung oder den Zusammenhang zwischen zwei oder mehreren Merkmalen. Die Stärke und Richtung dieses Zusammenhangs kann durch die sogenannten Korrelationskoeffizienten beschrieben werden. Die Korrelationskoeffizienten nehmen Werte im Bereich von -1 bis 1 an, wobei -1 eine negative Korrelation und +1 eine positive Korrelation angibt. Eine negative Korrelation bedeutet, dass wenn

eine Größe kleiner wird, die andere größer wird, und eine positive Korrelation heißt, dass wenn eine Größe zunimmt auch die andere zunimmt. Um so näher der Korrelationskoeffizienten an -1 oder 1 liegen, desto stärker ist die Korrelation der beiden Größen, wobei ein Korrelationskoeffizient von 0 keine Korrelation der Größen bedeutet. (GIBBONS & CHAKRABORTI 2003, S. 399-422) Die drei am meisten verwendeten Korrelationskoeffizienten sind:

- der lineare Korrelationskoeffizient nach Pearson
- der Rangkorrelationskoeffizient nach Kendall Tau
- der Rangkorrelationskoeffizient nach Spearman

Der Pearsonsche Korrelationskoeffizient r_p ist ein Maß für den linearen Zusammenhang zweier Größen. r_p wird mit Formel 6.1 berechnet. x und y beschreiben hier die Werte der Größen sowie \bar{x} und \bar{y} die Mittelwerte dieser. (GIBBONS & CHAKRABORTI 2003, S. 399)

$$r_p := \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2 \cdot \sum_i (y_i - \bar{y})^2}} \quad (6.1)$$

Allerdings hängen Größen nicht immer linear zusammen. In diesem Fall muss auf die Rangkorrelationskoeffizienten zurückgegriffen werden, welche erfassen, ob zwei Größen zueinander monoton steigen oder fallen. Die Rangkorrelationskoeffizienten können nach Spearman oder nach Kendall Tau berechnet werden. Der Spearmanische Rangkorrelationskoeffizient r_s stellt einen Spezialfall des Pearsonschen Korrelationskoeffizient dar, bei dem die Daten in Ränge¹ umgewandelt werden bevor der Korrelationskoeffizient berechnet wird. (W. XU et al. 2013) Dies ist in Formel 6.2 zu sehen.

$$r_s = \frac{\sum_i (rg(x_i) - \overline{rg(x)})(rg(y_i) - \overline{rg(y)})}{\sqrt{\sum_i (rg(x_i) - \overline{rg(x)})^2} \sqrt{\sum_i (rg(y_i) - \overline{rg(y)})^2}} \quad (6.2)$$

Im Gegensatz zu r_s nutzt der Korrelationskoeffizient nach Kendall r_k nur den Unterschied in den Rängen und nicht die Differenz der Ränge, wie in Formel 6.3 dargestellt. In der Regel ist der Wert von r_k etwas kleiner als der von r_s . Vorteile von r_k gegenüber r_s sind zum einen, dass r_k nicht so stark von Ausreißern beeinflusst wird, und dass r_k bessere Ergebnisse liefert wenn gleiche Ränge² vorliegen. (CROUX & DEHON 2010) Als

¹Der Rang beschreibt die Position einer Größe nach der Sortierung nach der Höhe des Wertes der Größe und der Durchnummerierung.

²Gleiche Ränge bedeutet, dass die zu korrelierenden Größen mehrere identische Werte aufweisen.

Nachteil von r_k gegenüber r_s ist die Zeitkomplexität zu nennen, welche für den Kendall Tau Korrelationskoeffizient $\Theta(n^2)$ und für den Spearman Korrelationskoeffizient $\Theta(n \log(n))$ beträgt. (W. XU et al. 2013)

$$r_k = \frac{2}{n(n-1)} \sum_{i < j} \text{sign}((x_i - x_j)(y_i - y_j)). \quad (6.3)$$

In der Regel wird mit einem Korrelationskoeffizienten auch die statistische Signifikanz p der Korrelation angegeben. Diese beschreibt die Wahrscheinlichkeit, dass die Nullhypothese, welche aussagt, dass keine Korrelation vorliegt, eintritt. Ein p -Wert von 0,05% gilt dabei als statistisch signifikant. (EID et al. 2015, S. 218-220) Da in dieser Arbeit alle Korrelation statistische Signifikanz aufweisen wird im Folgenden auf die Angabe des p -Werts verzichtet.

6.1.2 Korrelationsmetrik zur Auswahl der Cluster

Die Grundidee der Korrelationsmetrik ist es ein oder mehrere Cluster zu finden, die am besten mit den Porositäten korrelieren und somit für Prozesstörungen stehen können. Der Ablauf der Metrik ist in Abbildung 6.2 dargestellt. Zu Beginn wird die Matrix S bestimmt. Diese enthält in jedem Element den Anteil an Messpunkten einer Probe, die in einem bestimmten Cluster liegen. Die Zeilen beschreiben die einzelnen Proben und die Spalten die Cluster. Nach der Bestimmung von S werden die ermittelten Porositäten mit den Spalten von S korreliert. Dabei müssen die Zeilen von S die selbe Reihenfolge der Proben wie die Proben im Vektor der Porositäten aufweisen. Mit den so bestimmten Korrelationskoeffizienten werden die Spalten mit einem negativen Korrelationskoeffizienten gelöscht und so die Matrix G gebildet. Dies wird so gemacht, da hier die Annahme getroffen wird, dass Prozesstörungen, für welche die so bestimmten Cluster stehen sollen, positiv mit den Porositäten korrelieren. Nach diesem Schritt werden immer zwei Spalten der Matrix G aufsummiert, bis jegliche Kombinationen aus zwei Spalten gebildet wurden. Hierbei werden jeweils die Spaltenelemente, die sich in der gleichen Zeile befinden, addiert. Aus den so gebildeten Vektoren wird der Vektor u mit dem höchsten Korrelationskoeffizienten ermittelt. Anschließend werden zu diesem Vektor wieder jeweils die Spalten von G addiert. Wobei die schon in u enthaltenen Spalten nicht berücksichtigt werden. Danach folgt wieder die Bestimmung der Spalte mit dem höchsten Korrelationskoeffizienten und die Aufsummierung mit den Spalten von G . Diese zwei in Abbildung 6.2 gekennzeichneten Schritte werden so lange wiederholt bis eine von zwei Abbruchbedingungen erfüllt wird. Die erste Abbruchbedingung ist,

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

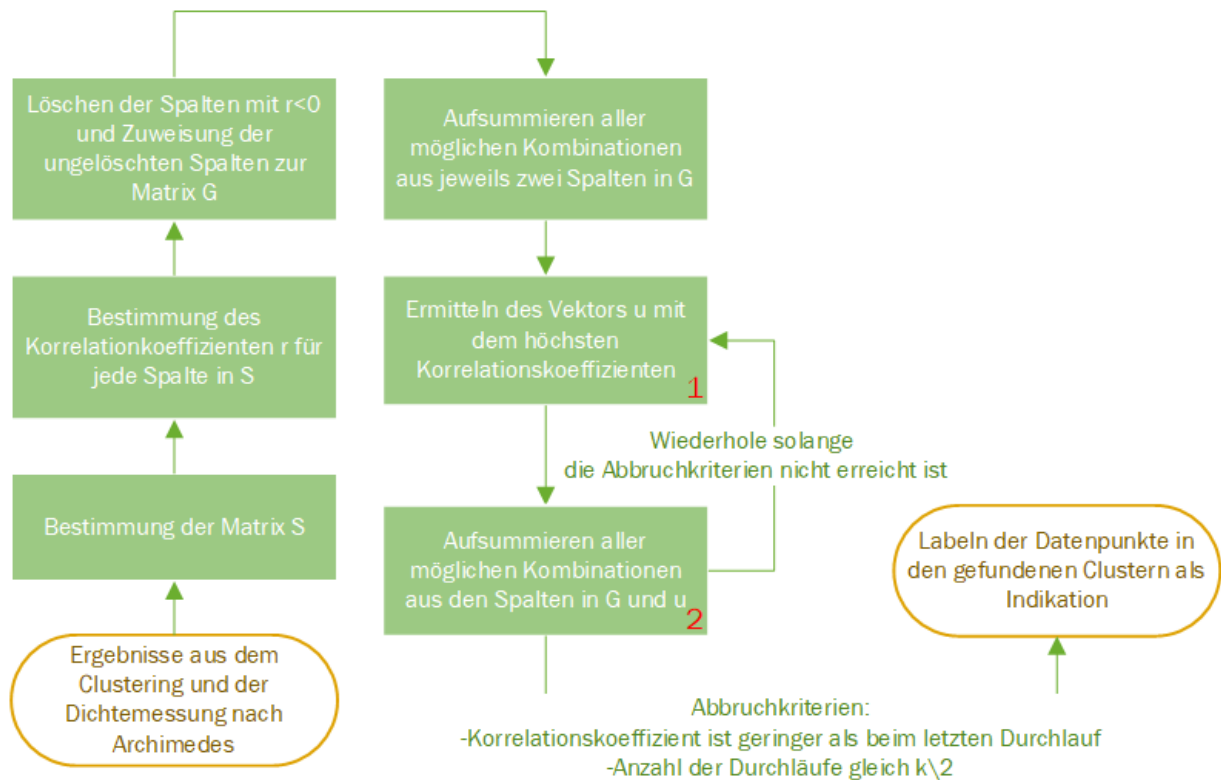


Abbildung 6.2: Ablaufdiagramm der Metrik zur Auswahl der Cluster

dass der Korrelationskoeffizient im Vergleich zum letzten Zyklus nicht geringer werden darf. Dahinter steht die Annahme das alle ausgewählten Cluster für Prozesstörungen stehen, und deshalb jeweils zu einer positiven Korrelation beitragen sollen. Die zweite Abbruchbedingen bezieht sich auf die Anzahl der Cluster k . Nach jedem Zyklus wird ein Cluster mehr als Prozesstörungen gelabelt. Nach $\frac{k}{2}$ Zyklen ist die Hälfte der Cluster als Prozesstörungen gelabelt, was auch bedeutet das ca. die Hälfte der Daten für Prozesstörung stehen. Würden noch mehr Daten Prozesstörung beschreiben, wäre dies unrealistisch und nicht dem realen Prozess entsprechend. Das liegt daran, dass Prozesstörungen als eine Abweichung von dem regulären Prozess eine Ausnahme darstellen und im realen Prozess nicht so häufig vorkommen.

Die Wahl der Korrelationskoeffizient ist angelehnt an die Forschung von KRAUSS (2016, S. 156). Hier wurde anhand der Messdaten eines Thermographiesystems Indikationen gebildet und gegen die metallographisch ermittelte Porositäten aufgetragen. Zudem wurden die Daten auf eine lineare Korrelation hin untersucht. In Abbildung 6.3 wurde der Verlauf dieser Indikationen über die Porosität approximiert. Wie zu erkennen ist kann keine lineare Korrelation angenommen werden. Allerdings treten in KRAUSS (2016, S. 156) große Streuungen in den Messdaten auf, wodurch eine Unsicherheit in dieser

Annahme entsteht. Eine Betrachtung der Gründe für die Nichtlineariät der Korrelation ist in KRAUSS (2016) nicht gegeben. Mögliche Erklärungen sind eine erhöhte Sensitivität der Indikatorenbildung bei großen Prozessabweichungen vom regulären Prozess, die bei einer hohen Porosität vermehrt auftreten, oder ein zunehmendes Eintreten der Defektausheilung durch das Wiederaufschmelzen bei hohen Porositäten.




Abbildung 6.3: Verlauf der Porositäten zu den Indikationen in Anlehnung an KRAUSS (2016, S. 156)

Die Grundlage für die Korrelationsmetrik bildet das Clustering Ergebnis. Für das Funktionieren der Metrik ist es wichtig, dass folgende Hypothese erfüllt wird.

Prozessstörungen weisen eine spezifische Signalcharakteristik auf die von Prozessparametervariation unterscheidbar ist.

Die Erfüllung der Hypothese ist wichtig, da sich dann Cluster über die Prozessstörungen und nicht nur über die Prozessparameter bilden. Dadurch können Prozessstörungen vom Rest des Datensatzes unterschieden werden.

6.1.3 Korrelation vs. Kausalität

Bei einer Korrelation zweier Größen muss nicht unbedingt eine Ursache-Wirkungs-Beziehung zwischen den Größen vorliegen. Das liegt daran, dass Korrelation zwar eine notwendige aber keine hinreichende Bedingung für Kausalität ist. (BERGER et al. 1993, S. 19-22) Es kann immer den Fall geben, dass die korrelierenden Größen eigentlich von einer dritten Größe abhängen und deswegen keine Ursache-Wirkungs-Beziehung vorhanden ist. Zudem kann eine Korrelation auch zufällig auftreten ohne einen realen Zusammenhang zu beschreiben. (ALDRICH 1995)

Allerdings werden in HILL (2004) neun Kriterien eingeführt, die bei Erfüllung einen Rückschluss von Korrelation auf Kausalität plausibel machen. Da die Arbeit von HILL (2004) sich mit dem Fachgebiet der Medizin beschäftigt, sind jedoch nur drei Kriterien auf den Anwendungsfall in dieser Arbeit anwendbar. Diese sind:

- Stärke der Korrelation
- zeitlicher Zusammenhang
- Experiment

Ein Maß für die Stärke der Korrelation ist der Betrag des Korrelationskoeffizienten. Da in dieser Arbeit die Clusterauswahl auf einem möglichst hohen Korrelationskoeffizient hin optimiert wird, werden hohe Werte des Koeffizienten erreicht. Die Bedingung des zeitlichen Zusammenhangs bedeutet, dass ein Ereignis zeitlich vor dem anderen auftreten muss um das andere Ereignis zu verursachen. Diese Bedingung ist hier immer erfüllt, da die Indikationen, welche für Prozesstörungen stehen sollen, immer vor oder gleichzeitig mit der eigentlichen Defektbildung auftreten. Das liegt daran, dass die Messdaten während der Defektbildung aufgezeichnet werden. Mit dem Kriterium des Experiments wird die Übertragbarkeit des gefundenen Zusammenhangs auf neue Daten überprüft. In dem Anwendungsfall dieser Arbeit wird dies durch den Validerungsversuch umgesetzt.

6.2 Vorverarbeitung der Messdaten

Die Bauplatzform für den Trainingsversuch war schief aufgrund von einer ungenauen Einspannung beim abräsen der Bauplatzform. Deshalb konnten die auf der Bauplatzform gefertigten Proben nicht gerade abgetrennt werden. Aus diesem Grund wurden die Proben mit einem Messschieber ausgemessen, die Anzahl der abgetrennten Schichten abgeschätzt und aus den Daten entfernt.

Wie bereits erwähnt wurden die Schichten der Proben in Anlehnung an ACKERL et al. (2015) in einzelne Pixel mit einer Kantenlänge von 1 *mm* aufgeteilt. Dies ist in Abbildung 6.4 rechts dargestellt. Es ergeben sich so 100 Pixel für jede Probe in einer Schicht. Es sei darauf hingewiesen, dass dies eine große Einschränkung der Genauigkeit, in der Prozesstörungen detektiert werden können, darstellt. Zum einen ist dadurch das räumliche Auflösungsvermögen auf 1 *mm*² begrenzt und andererseits wird hier über

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozessstörungen

einen größeren Bereich gemittelt, in welchen sowohl Defekte als auch regulär aufgeschmolzenes Material enthalten ist. Deswegen können die Algorithmen nur Bereiche größerer Defekt- bzw. Prozessstörungskonzentration detektieren. Die Segmentierung in Pixel wurde trotzdem aus den Gründen der Einfachheit und der geringeren Rechenzeit gewählt. Insgesamt ergaben sich 2613500 Pixel oder Datenpunkte, wobei hier die entfernten Schichten schon abgezogen sind.

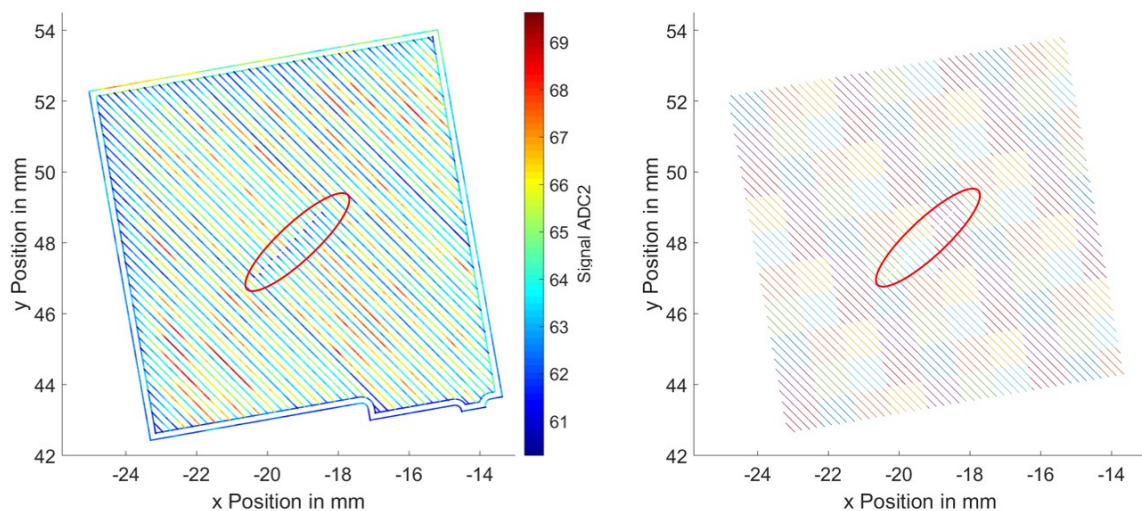


Abbildung 6.4: Probe mit Auffälligkeit. links: Probe mit Kontur, Verbindungselement und ADC2 Signalen. rechts: Probe in Pixeln

Des Weiteren ist in Abbildung 6.4 links zu sehen, dass die Kontur deutlich unterschiedliche Signalwerte im Vergleich zum Innenbereich aufweist. Da diese Unterscheidung zwischen Kontur und Innenbereich zusätzlich von den Algorithmen erfasst werden würde, wurde die Kontur aus den Messdaten entfernt. Damit wird die Komplexität der Zusammenhänge, die der Algorithmus lernen soll, geringer. Zudem wurde die Oberfläche für die Dichtemessung nach Archimedes abgeschliffen. Dadurch wurde ein Teil der Kontur auch in der Dichtemessung nicht berücksichtigt. Ferner wurde das Verbindungselement zwischen den Schichten, welches dazu dient allen Schichten einen Parametersatz zuweisen zu können, auch bei der Archimedesmessung abgeschliffen. Deshalb wurde dieses Teilstück auch aus den Messdaten entfernt.

Bei der Analyse der Messdaten nach den Bauprozess wurde eine Auffälligkeit in der Belichtungsstrategie entdeckt. Bei dieser werden Scanvektoren unterbrochen und erst nach einer Lücke weiter belichtet. Die Lücke ist immer $50 \mu\text{m}$ breit, und ein negativer Einfluss auf die Bauteilqualität wird vermutet, da hier ein Teil der Probe nicht belichtet

wird. Die Auffälligkeit tritt zufällig auf und das MPM System nimmt in der Lücke keine Messdaten auf. Indem der Prozessparameter »Vector Merge Length« erhöht wird, kann die Auffälligkeit abgestellt werden. Die Auffälligkeit wurde nach dem Testversuch entdeckt und für den Validierungsversuch entfernt.

Aus den Signaldaten der Photodioden ADC1 und ADC2 in den einzelnen Pixel wurden statistische Feature ermittelt. Diese sind in Tabelle 6.1 von den Nummern 1 bis 40 aufgetragen. Die einzelnen statistischen Feature werden zudem in Lage-, Streuungs- und Formparameter unterschieden. Lageparameter, wie zum Beispiel der Mittelwert μ , beschreiben die durchschnittliche Lage der Werte einer Häufigkeitsverteilung und sind in Tabelle 6.1 mit einem L gekennzeichnet. Streuungsparameter sind ein Maß für die Schwankung der Werte um den Lageparameter und sind mit einem S markiert. Ein Beispiel hierfür ist die Standardabweichung σ . Formparameter beschreiben die Form der Häufigkeitsverteilung. Hier ist zum Beispiel die Schiefe zu nennen, welche die Symmetrie oder Asymmetrie einer Häufigkeitsverteilung charakterisiert. Formparameter sind in Tabelle 6.1 mit einem F gekennzeichnet. Für die Berechnung der statistischen Kennwerte wird auf SACHS (1978) und FAHRMEIR et al. (2016) verwiesen. Des Weiteren wurde das sogenannte Signal-Rausch-Verhältnis (SRV) berechnet. Dieses ist ein Maß für die Qualität eines Signals und wird aus dem Verhältnis des Mittelwerts und der Standardabweichung des Signals gebildet. (KRAUSS 2016, S. 129) Zudem wird eine Normierung der Feature durchgeführt. Die Normierung wird vorgenommen, um zu verhindern, dass die Cluster sich zu einem großen Teil über die Prozessparameter bilden indem hier nur noch die Abweichung der Feature von den Features eines Prozessparametersatz betrachtet wird. Für die Normierung werden jeweils an den Proben die mit einem Prozessparametersatz gefertigt wurden, die Feature ermittelt. Anschließend werden die einzelnen Feature jeweils durch die Feature des Prozessparametersatz geteilt. Die Feature werden sowohl normiert als auch nicht normiert den Algorithmen übergeben, um zum einen zu verhindern, dass sich Cluster über die Prozessparameter bilden und zum anderen um keine Informationen durch die Normierung zu verlieren. Eine Normierung ist in Tabelle 6.1 durch ein N gekennzeichnet. Als ein weiteres Feature aus den Signaldaten wird das von ALBERTS et al. (2017) eingeführte Verhältnis von ADC1 zu ADC2 verwendet. Dieses weist nach ALBERTS et al. (2017) eine klare Korrelation zur relativen Dichte auf und könnte als ein Maß für die Temperatur des Schmelzbades herangezogen werden. Neben den statistischen Features der Signale wurden auch prozessbezogene Feature, welche mit einem P gekennzeichnet sind, ermittelt. Diese beziehen sich entweder auf die gesamte Probe, wie die Prozessparameter und die x oder y Position im Bauraum, oder auf eine Schicht bzw. eine Probe in einer Schicht wie der Drehwinkel und die

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

Tabelle 6.1: Verwendete Feature sowie die Auswahl der Feature nach einer Überprüfung der Korrelationen (2) und einer sequentiellen Rückwärtssauswahl (3)

Feature	Art des Feature	Auswahl	Feature	Art des Feature	Auswahl
1. $\mu_{ADC1/N}$	Mittelwert ADC1 (N)(L)	3	27. R_{ADC1}	Reichweite ADC1 (S)	1
2. $\mu_{ADC2/N}$	Mittelwert ADC2 (N)(L)	3	28. R_{ADC2}	Reichweite ADC2 (S)	1
3. μ_{ADC1}	Mittelwert ADC1 (L)	3	29. $\tilde{\mu}_{ADC1/N}$	Median ADC1 (N)(L)	1
4. μ_{ADC2}	Mittelwert ADC2 (L)	1	30. $\tilde{\mu}_{ADC2/N}$	Median ADC2 (N)(L)	3
5. $\sigma_{ADC1/N}$	Standardab- weichung ADC1 (N)(S)	3	31. $\tilde{\mu}_{ADC1}$	Median ADC1 (L)	2
6. $\sigma_{ADC2/N}$	Standardab- weichung ADC2 (N)(S)	3	32. $\tilde{\mu}_{ADC2}$	Median ADC2 (L)	1
7. σ_{ADC1}	Standardab- weichung ADC1 (S)	3	33. $v_{ADC1/N}$	Schiefe ADC1 (N)(F)	3
8. σ_{ADC2}	Standardab- weichung ADC2 (S)	1	34. $v_{ADC2/N}$	Schiefe ADC2 (N)(F)	3
9. $M_{ADC1/N}$	Modus ADC1 (N)(L)	2	35. v_{ADC1}	Schiefe ADC1 (F)	3
10. $M_{ADC2/N}$	Modus ADC2 (N)(L)	3	36. v_{ADC2}	Schiefe ADC2 (F)	1
11. M_{ADC1}	Modus ADC1 (L)	3	37. $\kappa_{ADC1/N}$	Kurtosis ADC1 (N)(F)	2
12. M_{ADC2}	Modus ADC2 (L)	3	38. $\kappa_{ADC2/N}$	Kurtosis ADC2 (N)(F)	3
13. $min_{ADC1/N}$	Minimum ADC1 (N)(S)	3	39. κ_{ADC1}	Kurtosis ADC1 (F)	2
14. $min_{ADC2/N}$	Minimum ADC2 (N)(S)	3	40. κ_{ADC2}	Kurtosis ADC2 (F)	3
15. min_{ADC1}	Minimum ADC1 (S)	1	41. SRV_{ADC1}	Signal-Rausch- Verhältnis ADC1 (L)(S)	3
16. min_{ADC2}	Minimum ADC2 (S)	1	42. SRV_{ADC2}	Signal-Rausch- Verhältnis ADC2 (L)(S)	3
17. $max_{ADC1/N}$	Maximum ADC1 (N)(S)	2	43. $\mu_{ADC1/ADC2}$	Mittelwert ADC1/ADC2 (L)	3

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

Feature	Art des Feature	Auswahl	Feature	Art des Feature	Auswahl
18. $max_{ADC2/N}$	Maximum ADC2 (N)(S)	2	44. γ	Drehwinkel (P)	3
19. max_{ADC1}	Maximum ADC1 (S)	1	45. L_R	Laserrückkehrzeit (P)	2
20. max_{ADC2}	Maximum ADC2 (S)	3	46. P	Laserleistung (P)	2
21. $mad_{ADC1/N}$	mittlere absolute Abweichung ADC1 (N)(S)	1	47. d_s	Schichtdicke (P)	2
22. $mad_{ADC2/N}$	mittlere absolute Abweichung ADC2 (N)(S)	1	48. ϕ	Strahlendurchmesser (P)	2
23. mad_{ADC1}	mittlere absolute Abweichung ADC1 (S)	1	49. D_G	Drehzahl des E-Motors (P)	2
24. mad_{ADC2}	mittlere absolute Abweichung ADC2 (S)	1	50. x	x Position (P)	2
25. $R_{ADC1/N}$	Reichweite ADC1 (N)(S)	1	51. y	y Position (P)	2
26. $R_{ADC2/N}$	Reichweite ADC2 (N)(S)	2			

Laserrückkehrzeit. Die Laserrückkehrzeit wird hier als Zeit zwischen der Belichtung der Probe in zwei aufeinanderfolgenden Schichten definiert. In der Laserrückkehrzeit wurde die Zeit berücksichtigt, in der das Messsystem Daten aufgenommen hat und somit ist die Beschichtungszeit nicht enthalten. Diese ist allerdings konstant über den Bauprozess. Insgesamt wurden 51 Feature ermittelt.

6.3 Feature Auswahl

Da die Distanzmaße vieler Algorithmen bei einer hohen Dimensionalität versagen, wird eine Auswahl an Features des gesamten Featuresatzes getroffen, um die Rechenzeit zu reduzieren und zudem das Ergebnis der Algorithmen zu verbessern. (AGGARWAL & REDDY 2014, S. 32) Dies erfolgt in zwei Schritten. Der erste Schritt beruht auf einer korrelationsbasierten Feature Auswahl (englisch Correlation based Feature Selection **CFS**). Dieser liegt die Annahme zugrunde, dass eine gute Featuresatz stark mit dem Ergebnis des Algorithmus korreliert die Feature aber nicht untereinander korrelieren.

(HALL 1999) In dieser Arbeit wird der Spearman Korrelationskoeffizient r_s zwischen allen Features berechnet und in einer sogenannten Korrelationsmatrix aufgetragen. Der Korrelationskoeffizient nach Spearman wurde wegen seiner geringen Rechenzeit verwendet. Anschließend wurde, beginnend von dem Feature 51 bis zum Feature 1, überprüft, ob der Korrelationskoeffizient zu einem anderen Feature größer als 0,95 ist. Diese Grenze wurde durch subjektive Einschätzung gesetzt. Ist dies der Fall wurde das jeweilige Feature aus dem Datensatz entfernt. Die so als redundant ermittelten Feature sind in der Tabelle 6.1 in der Spalte Auswahl mit einer 1 gekennzeichnet. Nach diesem Schritt waren von den 51 Features noch 36 übrig.

Im zweiten Schritt erfolgt die Feature Auswahl mit einer auf diesen Anwendungsfall angepassten sequentielle Rückwärtsauswahl. Das Verfahren findet möglicherweise nicht die optimale Kombination an Features, da im Gegensatz zu einem vollständigen Suchansatz nicht alle Kombinationen der Feature evaluiert werden. Aus Gründen der Rechenzeit wird die sequentielle Rückwärtsauswahl allerdings trotzdem verwendet. Bei diesem Verfahren werden nicht nur redundante Feature gefunden, sondern auch der Informationsgehalt der Feature wird bewertet. Bei der sequentiellen Rückwärtsauswahl wird aus dem gesamten Featuresatz nacheinander eine Feature entfernt, und danach mit einer Metrik bewertet ob der Algorithmus besser oder schlechtere Ergebnisse liefert. (THEODORIDIS & KOUTROUMBAS 2009, S. 181) In der Regel wird dieses Vorgehen bei Klassifikationsproblemen angewendet und die Bewertungsmetrik stellt die Genauigkeit des Algorithmus dar. In dieser Arbeit liegt eine Clusteringproblem vor. Deshalb wird als Bewertungskriterium der Kendall Tau Korrelationskoeffizient, welcher mit der in Kapitel 6.1.2 beschriebenen Metrik berechnet wird, genutzt. In Abbildung 6.1 ist das Vorgehen in dieser Arbeit bei der sequentiellen Rückwärtsauswahl dargestellt.

Da eine solcher Ansatz einen erheblichen Rechenaufwand mit sich bringt, wurde zuerst eine reduzierter Datensatz mit weniger Proben ermittelt, um die Rechenzeit zu reduzieren. Hierfür wurde der Relativfehler der Dichte $\Delta\rho_{P_{rel}}$ als Kriterium herangezogen, um möglichst unterschiedliche Dichten zu finden, womit eine gute Unterscheidung zwischen der Anzahl der Prozesstörungen in den Proben getroffen werden kann. Dabei wurden innerhalb der Porositäten der 120 Proben 33 Bereiche ermittelt, in denen keine Probe mit ihrer Porosität $P_A \pm \Delta\rho_{P_{rel}}$ innerhalb eines anderen Bereichs liegt. Aus den Bereichen wurde jeweils eine Probe gewählt, mit der die Feature Auswahl durchgeführt wurde. Für die Feature Auswahl wurde der k-Means Algorithmus verwendet, da dieser eine lineare Zeitkomplexität aufweist. Es wurde der k-Means Algorithmus zu Beginn mit 1 bis 450 Cluster berechnet, und anschließend, wurde die nach dem Davies-Bouldin Index optimale Clusteranzahl k mit 170 Cluster ermittelt. Im Anschluss wurde der

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

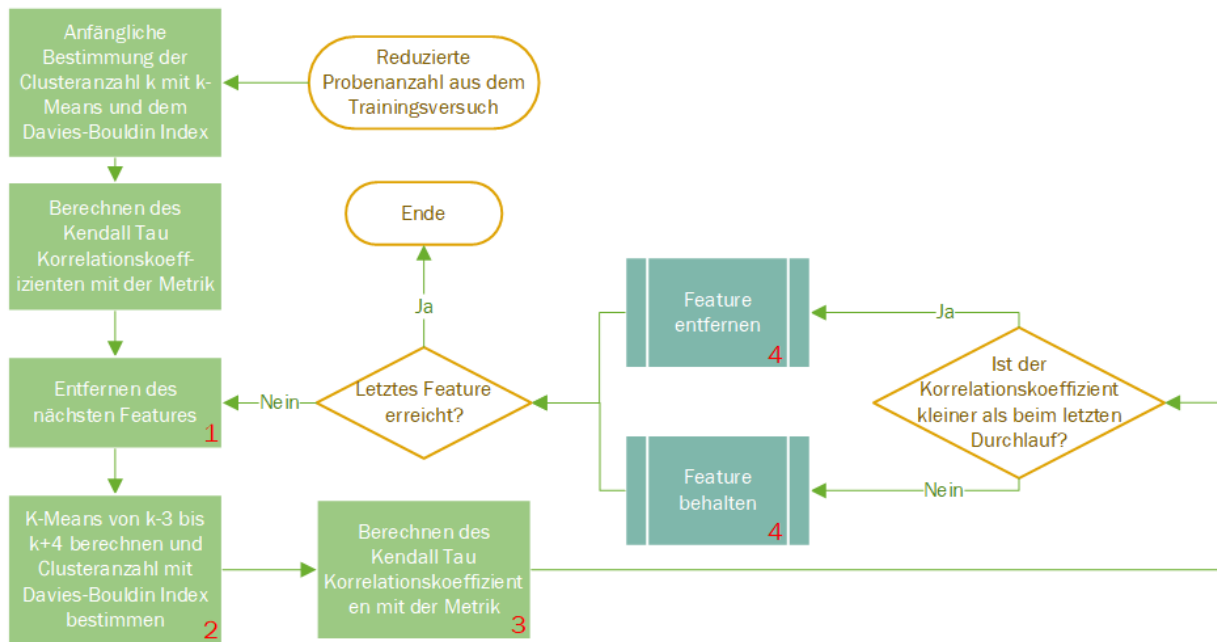


Abbildung 6.5: Ablaufdiagramm des Vorgehens der bei sequentiellen Rückwärtsauswahl

Kendall Tau Korrelationskoeffizient berechnet und ein Feature entfernt. Danach wurde der k-Means Algorithmus mit den Clustern $k-3$ bis $k+4$ ³ berechnet, die bestmögliche Clusternanzahl k mit dem Davies-Bouldin Index gesucht und der Korrelationskoeffizient ermittelt. Ist der Korrelationskoeffizient kleiner als im vorherigen Durchlauf wurde das Feature entfernt. Diese in Abbildung 6.1 markierten vier Schritte werden so lange durchgeführt bis das letzte Feature erreicht wird. Es ergab sich eine Rechenzeit für die sequentielle Rückwärtsauswahl von ca. drei Wochen. Die durch die sequentielle Rückwärtsauswahl entfernten Feature sind in Tabelle 6.1 in der Spalte Auswahl mit einer 2 gekennzeichnet. Nach der gesamten Feature Auswahl blieben 22 Feature übrig, welche in Tabelle 6.1 mit einer 3 markiert sind.

Dieser Featuresatz wurde anschließend auf den gesamten Datensatz angewandt. Zudem wurde eine Standardisierung und eine PCA durchgeführt, welche eine Reduktion von 22 auf 14 Dimensionen ermöglichte, wobei 95% der gesamten Varianz erhalten blieb.

³Die Anzahl von acht Clustern die berechnet wurden, wurde gewählt da der verwendete Computer in MATLAB mit acht Kernen rechnet, und somit die acht Algorithmen mit unterschiedlicher Clusteranzahl parallel berechnet werden konnten.

6.4 Validierung der Cluster- und Featureauswahl

Auf den wie in Kapitel 6.3 beschriebenen vorverarbeiteten Datensatz wurden zwei Clustering Algorithmen angewendet. Diese sind der k-Means Algorithmus, welcher auch schon für die Feature Auswahl genutzt wurde, und der DBSCAN Algorithmus. Beide wurden im Kapitel 2.4.1 eingeführt. Für den k-Means Algorithmus wurde die Implementierung in MATLAB verwendet, bei dem DBSCAN Algorithmus wurde die Implementierung in ELKI⁴ genutzt. Um für den DBSCAN Algorithmus den ϵ Parameter zu bestimmen, wurde, wie von ESTER et al. (1996) vorgeschlagen, der sortierte k-Distanz Graph mit $k = MinPts - 1$ verwendet. Die minimale Anzahl an Datenpunkten in einem Cluster $MinPts$ wurde anhand der Probe mit der geringsten Porosität ermittelt. Hier wurde angenommen, dass 10% der als Prozesstörung gelabelten Datenpunkte den Wert für $MinPts$ bestimmen sollten. Deshalb wurde als $MinPts$ der Anteil $P_A \cdot 0,1$ aller Datenpunkte der Probe mit der geringsten Porosität verwendet. Dies ergab für $MinPts$ eine Wert von 164. Anschließend wurde die Distanz zu den k nächsten Nachbarn im Featureraum, auch k-Distanz genannt, mit $k = MinPts - 1 = 163$ berechnet. Im Anschluss wurden die ermittelten Distanzen sortiert und in Abbildung 6.6 aufgetragen. Es ist zu erkennen, dass bei ca. 2608000 Datenpunkten ein Knick in Graphen auftritt. Der k-Distanz Wert bei diesem Knick beträgt ca. 3,878 und dieser Punkt ist in Abbildung 6.6 rot markiert. Dieser Wert stellt nach ESTER et al. (1996) einen validen Wert für ϵ dar. Als $MinPts$ wurde für den DBSCAN Algorithmus 164 verwendet.

Der DBSCAN Algorithmus ermittelte mit dieser Parametrisierung nur zwei Cluster sowie Rauschpunkte, die als weiteres Cluster angesehen werden können. Diese Clusteranzahl ist zu gering um eine Unterscheidung zwischen einem regulär ablaufenden Prozess und Prozesstörungen treffen zu können. Eine Begründung für die geringe Anzahl an Clustern kann eine falsche Parametrisierung oder ein zu geringer Dichteunterschied in den Daten sein, welchen der Algorithmus detektiert. Wegen der zu geringen Clusteranzahl wird der Algorithmus im Folgenden nicht weiter betrachtet.

Im Allgemeinen stellt die ermittelte Clusteranzahl einen Kompromiss zwischen der Detektion zufälliger Korrelationen bei einer zu hohen Clusteranzahl und einem nicht detektieren von Prozesstörungen, da diese nicht in Cluster segmentiert werden, bei einer zu geringen Clusteranzahl, dar.

⁴ELKI ist ein Clustering Framework der Ludwig Maximilians Universität München. In diesem sind über 130 Clustering Algorithmen nach dem Stand der Technik implementiert. (ELKI 2018) (SCHUBERT et al. 2015)

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen




Abbildung 6.6: k-Distanz Graph zur Bestimmung des ϵ Parameters.

Neben dem DBSCAN Algorithmus wurde der Datensatz auch mit den k-Means Algorithmus geclustert. Hierfür wurde der Algorithmus zuerst für Cluster von 1 bis 450 berechnet, um dann die nach dem Davies-Bouldin Index bestmögliche Clusteranzahl zu bestimmen. Die Rechenzeit betrug ca. zwei Wochen. Hierbei wurde eine Clusteranzahl von 438 bestimmt. Mit diesem Clusteringergebnis wurde mit der Korrelationsmetrik die für Prozesstörungen stehenden Cluster ermittelt. Um den Verlauf der Indikationen über die Porositäten zu bewerten wird der Anteil an Indikationen A_{Ind} für die ganze Probe herangezogen. Dieser wird mit mit Formel der 6.4 berechnet.

$$A_{Ind} = \frac{\text{Anzahl an Messpunkten einer Probe mit Indikationen}}{\text{Gesamte Anzahl an Messpunkten einer Probe}} \cdot 100\% \quad (6.4)$$

In Abbildung 6.7 sind die ermittelten A_{Ind} -Werte gegen die archimedisch gemessenen Porositäten P_A aufgetragen. Hierbei wurden die A_{Ind} -Werte mit der Metrik und den drei in Kapitel 6.1.1 beschriebenen Korrelationskoeffizienten berechnet. Die mit der Metrik ermittelten Korrelationskoeffizienten sind für Kendall Tau $r_k = 0,608$, für Spearman $r_s = 0,810$ und für Pearson $r_p = 0,959$. Zudem wurden mit dem Korrelationskoeffizienten Kendall Tau 47 der 438 Cluster als Prozesstörungen klassifiziert. Mit Spearman waren es auch 47, wobei 40 der Cluster mit denen nach Kendall Tau überstimmen. Die Metrik mit dem Pearson Korrelationskoeffizient hat 30 Cluster ausgewählt, wobei von diesen 12 auch durch Kendall Tau und 20 durch Spearman ermittelt wurden. Des Weiteren nehmen die A_{Ind} -Werte, die nach Kendall Tau und Spearman bestimmt wurden, für hohe Porositäten von größer als 6 % hohe A_{Ind} -Werte von über 50% an. Das bedeutet,

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen




Abbildung 6.7: Verlauf der A_{Ind} -Werte gegen die Porositäten mit einer linearen Skalierung der x-Achse

dass in diesem Fall mehr als die Hälfte der Messpunkte als Prozesstörungen gelabelt sind. Dies entspricht nicht dem realen Prozess. Der Pearson Korrelationskoeffizient liefert hier für hohe Porositäten geringere A_{Ind} -Werte. Da die Porosität der meisten gefertigten Proben unter 3 % beträgt und die Proben auch entsprechend geringe A_{Ind} -Werte aufweisen, ist eine Darstellung dieser Punkte mit einem linear skalierten Diagramm unübersichtlich. Deshalb wurde in Abbildung 6.8 die x-Achse logarithmisch skaliert. Der Pearson Korrelationskoeffizient weist bei geringeren Porositäten eine höhere Sensitivität also höhere A_{Ind} -Werte auf. Das ist wichtig um auch bei einem regulär ablaufenden Prozess Unterscheidungen in der Bauteilqualität treffen zu können. Da sowohl eine erhöhte Sensitivität bei geringen Porositäten als auch die Annahme einer Nichtlinearität als Bedingungen für eine gute Clusterauswahl angenommen wird, wird sowohl der Korrelationskoeffizient nach Pearson als auch der nach Kendall Tau verwendet und die mit beiden Korrelationskoeffizient ermittelten Cluster werden kombiniert. Hierbei ergeben sich 65 der 438 Cluster, die als Prozesstörungen klassifiziert werden.

Um den Einfluss der einzelnen Prozessparameter auf die Porosität und auf die A_{Ind} -Werte zu ermitteln, wurden Wirkungsflächendiagramme mit der Software Minitab 2017 erstellt. Diese sind in Abbildung 6.9 dargestellt.

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

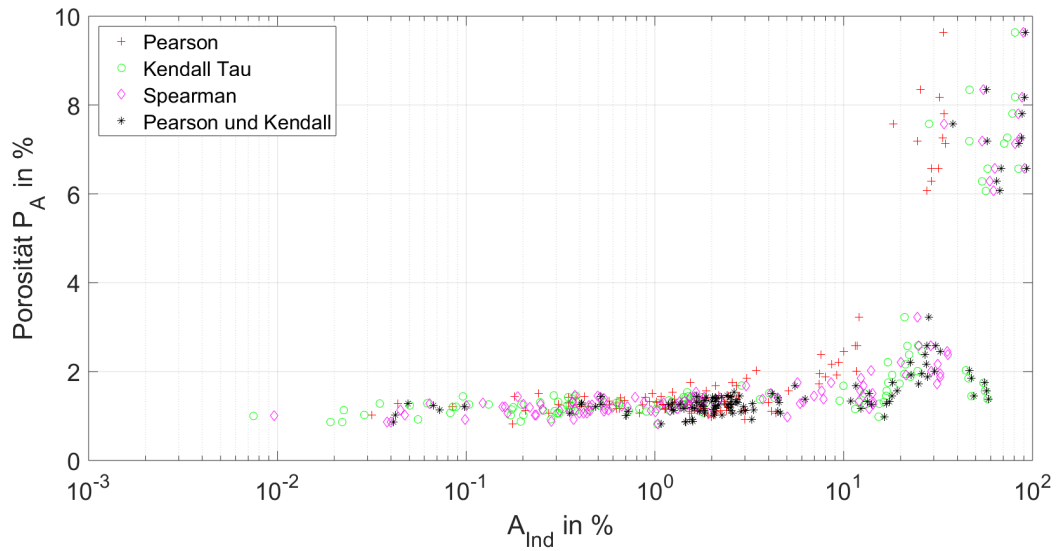


Abbildung 6.8: Verlauf der A_{Ind} -Werte gegen die Porositäten mit einer logarithmischen Skalierung der x-Achse

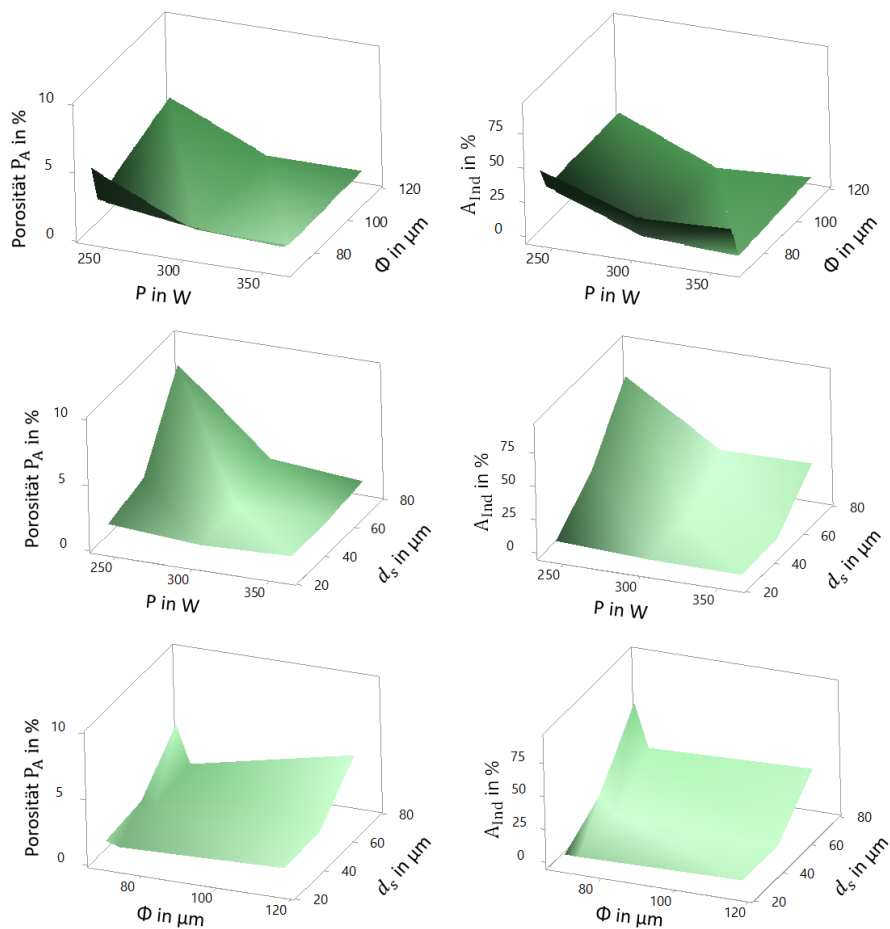


Abbildung 6.9: Wirkungsflächendiagramme des Baujobs 1 zwischen jeweils zwei Prozessparametern nach dem FCCCD

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

Mit den Wirkungsflächendiagrammen werden Wechselwirkungen zwischen den Prozessparametern dargestellt, welche durch die Verwendung eines FCCCD Versuchsplan statistisch abgesichert wurden. Die Werte zwischen den einzelnen Punkten wurden für die Erstellung des Wirkungsflächendiagrammes mit der Distanzmethode interpoliert. Bei der Erstellung der Diagramme wurden die Proben des Baujobs 1, welche mit dem Standardwert für D_G von 70 % gefertigt wurden, berücksichtigt. Dabei wurden alle Proben, die mit einem Parametersatz gefertigt wurden, also auch die Replika, für die Interpolation verwendet. Der Mittelpunkt in der x-y Ebene stellt in den Diagrammen den Standardparametersatz dar. In Abbildung 6.9 ist zu erkennen, dass die Unterschiede in den Porositäten durch die Prozessparameteränderung von den A_{Ind} -Werten gut erfasst werden. Dabei werden die Wechselwirkungen zwischen den Parametern und deren Einfluss auf die Porosität von den A_{Ind} -Werten richtig wiedergegeben. Hohe Schichtdicken in Kombination mit einer geringen Laserleistung führen zu den höchsten Porositäten. Auf eine Erhöhung der Schichtdicke reagiert der A_{Ind} -Wert sehr stark, obwohl diese wie zum Beispiel bei einer hohen Laserleistung nicht unbedingt zu einer deutlichen größeren Porosität führen muss. Die geringsten Porositäten werden bei einer geringeren Schichtdicke, in diesem Fall 25 μm , erreicht. Die Gründe dafür sind zum einen, dass hier Defekte durch das häufigere Wiederaufschmelzen ausgeheilt werden und zum anderen, dass Gasporen bei einer geringeren Schichtdicke besser aufsteigen können. (GU & SHEN 2008) Beim Laserfokus führt sowohl ein zu geringer als auch ein zu großer Laserfokus zu hohen A_{Ind} Werten bzw. Porositäten. Wobei die Porosität nicht linear vom Laserfokus abhängt, da eine Knick bei einem geringem Laserfokus auftritt.

Des Weiteren wird der Einfluss des D_G -Werts, welcher bei einer Verringerung zu einer kleineren Geschwindigkeit der Schutzgasströmung und Durchflussrate führt, auf die Porositäten und die A_{Ind} -Werte betrachtet. (RICHTER 2017) Hierfür werden die Porositäten und A_{Ind} -Werte der mit dem Standardparametersatz gefertigten Proben von den drei Baujobs gemittelt. Bei den drei Baujobs wurde jeweils ein unterschiedlicher D_G -Wert eingestellt. In Abbildung 6.10 sind diese gemittelten Werte, sowie deren Standardabweichung als Fehlerbalken, gegen den D_G -Wert aufgetragen. Es ist eine Verringerung der Porositäten bei einer Reduzierung des D_G -Werts zu erkennen. Allerdings sollte nach LADEWIG et al. (2016) eine Reduzierung der Durchflussrate zu einer schlechteren Bauteilqualität führen, da Prozessnebenprodukte dann schlechter von der Schweißstelle abtransportiert werden. Dieser Widerspruch ist zum einen dadurch zu erklären, dass der D_G -Wert noch zu hoch war um vermehrt zu Prozesstörungen zu führen. Somit wird der kritische Bereich der Durchflussrate noch nicht erreicht. Zum anderen kann der Widerspruch durch die zufällige Wahl der Bauraumposition in den drei Baujobs be-

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen




Abbildung 6.10: Verlauf der Porositäten und A_{Ind} -Werte über die D_G -Werte

schrieben werden. Es wurden zufällig Bauraumpositionen ausgewählt, bei denen im Mittel eine bessere Bauteilqualität auftritt. Die großen Fehlerbalken sind auch ein Indiz für den großen Einfluss der Bauraumpositionen. Der Verlauf der A_{Ind} -Werte stimmt allerdings mit dem Verlauf der Porositäten über die drei Baujobs überein.

Außerdem sollten Prozesstörungen und somit auch die Indikationen abhängig von Drehwinkel γ vermehrt auftreten. Das liegt daran, dass bei Drehwinkeln, mit denen in Schutzgasströmung geschweißt wird, Prozessnebenprodukte in den Strahlengang des Lasers kommen und das Laserlicht defokussieren. (DOMRÖSE et al. 2013) In Abbildung 6.11 sind die Anzahl an Indikationen in bestimmten Drehwinkelbereichen als Histogramm dargestellt. Es ist zu erkennen, dass vermehrt Indikationen bei Drehwinkeln in Richtung der Schutzgasströmung, also 90° oder 270° , auftreten. Dies validiert die Clusterauswahl, da die Cluster nicht nach möglichst vielen Indikationen in diesem Drehwinkelbereichen ausgewählt wurden.

Ferner sollte die Verteilung der Indikationen in den Proben realistisch sein und der Verteilung der Defekte in den Proben entsprechen. Um dies zu prüfen wurden in Abbildung 6.12 die Indikationen an der jeweiligen Bauraumposition der Messdaten der Indikationen in den Proben dargestellt. Hierbei wird die Probe 7 des Baujobs 2 untersucht, welche mit einem größeren Strahlendurchmesser gefertigt wurde. Eine erhöhte Konzentration an Indikationen in dem Randbereich ist zu erkennen. Dies ist dadurch zu erklären, dass nach KLESZCZYNSKI, LADEWIG et al. (2015) im Randbereich ein anderer Wärmeleitungszustand eintritt, da der umgebene Pulverwerkstoff isolierend wirkt. Dies

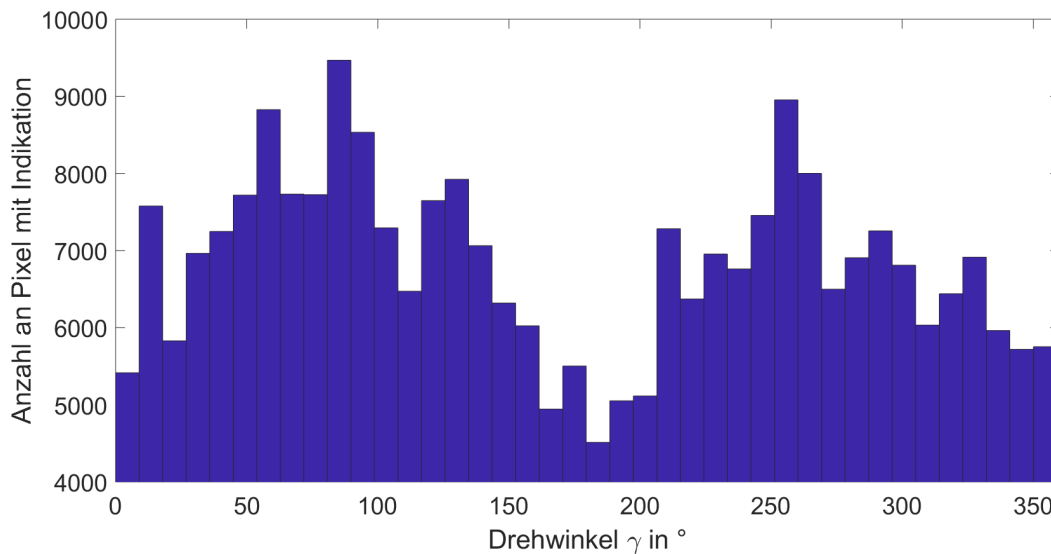


Abbildung 6.11: Histogramm der Anzahl an Indikationen für die einzelnen Drehwinkelbereiche

kann bei einer bestimmten Parametereinstellung zu einer erhöhten Defektkonzentration in dem Randbereich führen. Zudem treten nach KEMPEN, THIJS, VAN HUMBEECK et al. (2012) bei AlSi10Mg an den Endpunkten der Scanvektoren und somit in dem Randbereich vermehrt Defekte auf. Somit beschreibt die ermittelte Verteilung der Indikationen diese Zusammenhänge.

6.5 Trainieren und Bewerten der Klassifikationsalgorithmen

Der wie in Kapitel 6.2 beschriebene vorverarbeitete Datensatz wurde mit der Metrik und einer Kombination aus dem Pearson und dem Kendall Tau Korrelationskoeffizienten gelabelt. Anschließend wurde der gesamte Datensatz zufällig in ein Trainings- und Testdatensatz aufgeteilt, wobei 10 % der Daten im Testdatensatz enthalten sind. Als Klassifikationsalgorithmen wurden, wie in Kapitel 2.4.2 beschrieben, der nächste Nachbarn Klassifikationsalgorithmus und Entscheidungsbäume verwendet. Dabei wird auf die Implementierung im Classification Learner App in MATLAB zurückgegriffen.

Im Rahmen dieser Arbeit werden diese Klassifikatoren trainiert und die Genauigkeit anhand des zuvor abgespaltenen Testdatensatz bewertet. Dabei werden verschiedene Variationen der Algorithmen angewandt. Bei den Entscheidungsbäumen bezieht sich die Variation auf die Anzahl an Teilungen und bei den nächste Nachbarn Klassifikatoren auf die verwendete Distanzfunktion, die Anzahl der Nachbarn oder die Abstandsgewichtung. (THE MATHWORKS 2018) Die verwendeten Algorithmen sind:




Abbildung 6.12: Verteilung der Indikationen in der Probe 7 des Baujobs 2

- Entscheidungsbäume
 - Simple Tree: maximal 4 Teilungen jedes Knoten
 - Medium Tree: maximal 20 Teilungen jedes Knoten
 - Complex Tree: maximal 100 Teilungen jedes Knoten
- nächste Nachbarn Klassifikatoren
 - Fine **KNN**: Nachbarzahl 1, Abstandsfunktion Euclidlean, Abstandsgewichtung Equal
 - Medium **KNN**: Nachbarzahl 10, Abstandsfunktion Euclidlean, Abstandsgewichtung Equal
 - Coarse **KNN**: Nachbarzahl 100, Abstandsfunktion Euclidlean, Abstandsgewichtung Equal
 - Cosine **KNN**: Nachbarzahl 10, Abstandsfunktion Cosine, Abstandsgewichtung Equal

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

- Weighted **KNN**: Nachbarzahl 10, Abstandsfunktion Euclidean, Abstandsgewichtung Squared Inverse

Neben der Genauigkeit ist zudem die Vorhersagegeschwindigkeit in Bezug auf einer echtzeitfähigen Anwendung von Bedeutung und die Trainingszeit gibt an inwiefern die Algorithmen für große Datenmengen geeignet sind. In Abbildung 6.13 sind die ermittelten Werte für Genauigkeit, Vorhersagegeschwindigkeit und Trainingszeit der verwendeten Algorithmen dargestellt.

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen




Abbildung 6.13: Genauigkeit, Vorhersagegeschwindigkeit und Trainingszeit der verwendeten Klassifikatoren

Die Entscheidungsbäume weisen zwar eine geringere Trainingszeit und eine höherer Vorsagegeschwindigkeit auf, allerdings aber nur eine geringere Genauigkeit. Der Algorithmus mit der höchsten Genauigkeit, welche 97,8 % beträgt, ist der Weighted KNN. Deshalb wird dieser im Folgenden verwendet.

6 Vorgehen bei der Anwendung der Methoden des maschinellen Lernens zur Vorhersage von Prozesstörungen

Um zu bewerten wie gut der Algorithmus Prozesstörungen und den regulär ablaufenden Prozess unterscheiden kann, wird eine Konfusionsmatrix herangezogen. Diese ist in Abbildung 6.14 dargestellt. Die Klasse 1 stellt hier die als Prozesstörung gelabelten Datenpunkte dar und die Klasse 0 beschreibt den regulären Prozess. In den grauen Kästchen ist das Verhältnis zwischen der Anzahl der korrekt klassifizierten Datenpunkte (grün) und der gesamten Anzahl einer richtigen oder einer vorhergesagten Klasse, also die Summe einer Zeile oder Spalte, in Prozent angegeben. Entscheidend für die Funktionsfähigkeit des Algorithmus ist es, dass die Prozesstörungen richtig vorhergesagt werden, und somit mit welchem Anteil Klasse 1 richtig vorhergesagt wird. Dieser Anteil beträgt nur 87,3 %. Eine Verbesserung dieses Wertes könnte durch einen komplexeren Algorithmus, wie zum Beispiel ein neuronales Netz, erreicht werden.




Abbildung 6.14: Konfusionsmatrix des Weighted KNN

7 Ergebnisse und Diskussion

Im nachfolgenden Kapitel werden die Ergebnisse dieser Arbeit beschrieben und diskutiert. Dabei wird zuerst auf den Validierungsversuch eingegangen. Des Weiteren folgt eine Untersuchung der Signalveränderungen durch die Parametervariationen.

7.1 Validierung des Algorithmus mit dem Validierungsversuch

In diesem Kapitel werden die Ergebnisse des Validierungsversuchs dargestellt und diskutiert. Dafür werden zuerst die Ergebnisse aus der Metallographie eingeführt. Anschließend folgt eine Darstellung der Resultate des zuvor trainierten Algorithmus, der auf die Messdaten des Validierungsversuchs angewandt wurde. Zum Schluss folgt ein Vergleich der Ergebnisse aus der Metallographie mit denen des Algorithmus und abschließend eine Diskussion.

7.1.1 Ergebnisse aus der Metallographie

Die Ergebnisse dieses Versuches stammen aus der Veröffentlichung von ROSENKRANZ et al. (2018). Die Proben des Validierungsversuchs wurden, wie in Kapitel 4.3.2, beschrieben metallographisch untersucht. In Abbildung 7.1 sind die Porositäten in Abhängigkeit der Prozessparameter Laserleistung, Schichtdicke, Scangeschwindigkeit und Hatchabstand gegen die Volumenenergiedichte Ψ aufgetragen. Es wird zwischen den Defektarten Gasporen und Bindefehler unterschieden. Die mittleren Balken beschreiben die Porositäten der mit dem Standardparametersatz gefertigten Proben. Die Fehlerbalken stellen die Standardabweichung der Porosität, die durch Gasporen oder Bindefehler verursacht wurden über die drei mit dem gleichem Prozessparametersatz gefertigten Proben, dar.

Es ist zu erkennen, dass sowohl für hohe als auch für geringere Volumenenergiedichten die Porositäten zunehmen, wobei die mit einer kleinen Schichtdicke gefertigten Proben hier eine Ausnahme bilden. Des Weiteren treten bei geringen Volumenenergiedichten

die größten Porositäten auf. Zudem kommt es vermehrt zur Bildung von Gasporen bei hohen und von Bindefehlern bei geringen Volumenenergiedichten. Die Porosität durch Gasporen nimmt für die Schichtdicke im Gegensatz zu den anderen Prozessparametern mit zunehmender Volumenenergiedichte ab. Zur höchsten Porosität führt die geringste Stufe der Laserleistung.




Abbildung 7.1: Porositäten der untersuchten Volumenenergiedichtestufen bezogen auf die Parameter Laserleistung, Schichtdicke, Scangeschwindigkeit und Hatchabstand einschließlich einer Einteilung nach Gasporen und Bindefehlern in Anlehnung an ROSENKRANZ et al. (2018)

Des Weiteren wird die Veränderung der mittleren Defektgröße μ und der Standardabweichung der Defektgröße σ über die Volumenenergiedichte betrachtet. Diese sind Abbildung 7.2 dargestellt. Dabei wird zwischen Gasporen und Bindefehlern unterschieden. Bei jedem Punkt wurden die metallographisch ermittelten Messdaten der drei mit dem gleichen Parametersatz gefertigten Proben berücksichtigt.

Sowohl für große als auch für geringe Volumenenergiedichten nimmt μ und σ der Defektgröße im Vergleich zum Standardparametersatz zu, wobei die Variation der Scangeschwindigkeit hier ein Ausnahme darstellt. Bei den mit unterschiedlichen Scangeschwindigkeiten gefertigten Proben ist keine Veränderung von μ und σ der Defektgröße zu erkennen. Da die Porosität, wie in Abbildung 7.1 zu sehen ist, bei einer Variation der Scangeschwindigkeit im Vergleich zum Standardparametersatz trotzdem steigt, muss die Anzahl an Defekten zunehmen. Es sei darauf hingewiesen, dass die Skala von σ um eine Größenordnung größer als die von μ ist. Das weist auf eine sehr breite Häufigkeitsverteilung hin, bei der sowohl sehr große als auch sehr kleine Defekte

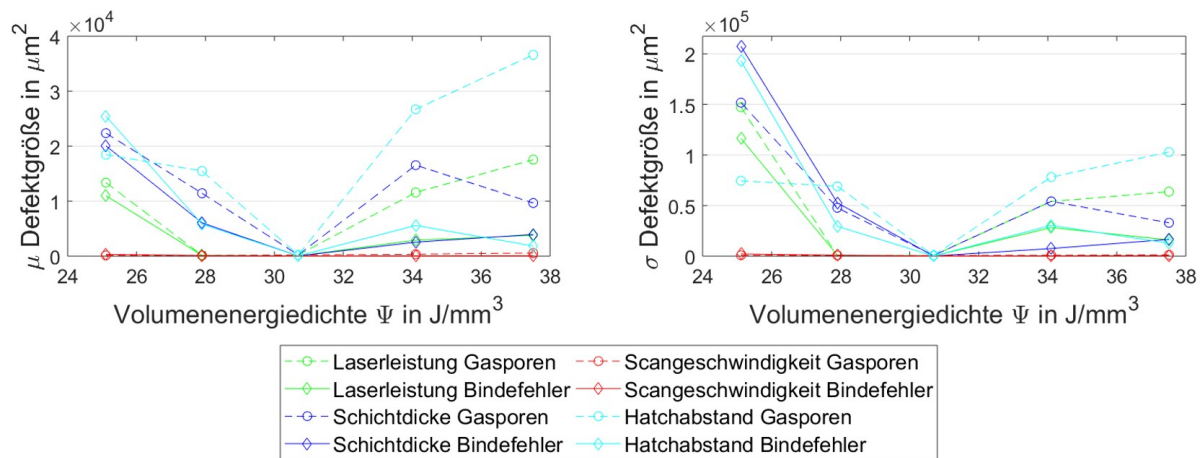


Abbildung 7.2: links: Veränderung der mittleren Defektgröße μ über die Volumenenergiedichte. rechts: Veränderung der Standardabweichung der Defektgröße σ über die Volumenenergiedichte

auftreten. Die größte mittlere Defektgröße weisen die Gasporen der mit dem kleinsten Hatchabstand und somit der größten Volumenenergiedichte gefertigten Proben auf. Dies wurde auch schon im Vorfeld vermutet, da bei diesen Proben sehr große runde Defekte in den Schlifffbildern zu sehen waren.

7.1.2 Ergebnisse des Algorithmus

Die Messdaten des Validierungsversuchs wurden auf die selbe Art und Weise vorverarbeitet wie des Trainingsversuchs. Das heißt es wurden aus den Pixeln die selben 22 Feature extrahiert, und diese wurden mit der selben Standardisierung und PCA transformiert. Damit ist gemeint, dass die mit den Daten des Trainingsversuchs ermittelte Transformationsmatrix A und die Mittelwerte μ_{PCA} zur Zentrierung auf die Daten des Validierungsversuchs bei der PCA angewandt wurden. Auch hier wurden, wie beim Trainingsversuch, die 14 Hauptkomponenten mit der größten Varianz weiterverwendet. Die selbe PCA wurde verwendet, damit die Feature in das gleiche Koordinatensystem wie im Trainingsversuch transformiert werden. Bei der Standardisierung wurden die mit den Daten des Trainingsversuch ermittelten Wert für μ und σ der Feature auf die Daten des Validierungsversuch angewandt. Diese wurde gemacht, damit die Feature sich im Vergleich zum Trainingsversuch im gleichen Skalenbereich befinden.

Nach dieser Datenvorverarbeitung wurde der Weighted KNN Algorithmus, welcher wie in Kapitel 6.5 beschrieben mit den Daten des Trainingsversuch trainierte wurde,

auf den Datensatz des Validierungsversuchs angewandt. Aus dem Ergebnis wurde der Anteil an Indikationen A_{Ind} der Proben berechnet und für die jeweilige Volumenenergiegedichtestufe in Abbildung 7.3 dargestellt. Die Fehlerbalken stellen dabei die Standardabweichung der A_{Ind} -Werte der mit einem gleichem Parametersatz gefertigten Proben dar.




Abbildung 7.3: Anteil an Indikationen A_{Ind} der untersuchten Volumenenergiegedichtestufen bezogen auf die Parameter Laserleistung, Schichtdicke, Scangeschwindigkeit und Hatchabstand

Die A_{Ind} -Werte sind, mit Ausnahme bei der Variation der Schichtdicke, bei dem Standardparametersatz minimal. Der Algorithmus reagiert am sensitivsten auf eine Änderung der Laserleistung und der Scangeschwindigkeit. Hier werden hohe A_{Ind} -Werte bei einer hohen und niedrigen Volumenenergiegedichten erreicht. Die mit der höchsten Laserleistung gefertigten Proben weisen die größten A_{Ind} -Werte auf.

Des Weiteren wird eine Abhängigkeit der Indikationen von dem Drehwinkel γ betrachtet. In Abbildung 7.4 ist die Anzahl an Indikationen in bestimmten Drehwinkelbereichen als Histogramm dargestellt. Da in diesem Versuch der Drehwinkelbereich in Schutzgasströmungsrichtung (90° und 270°) übersprungen wurde, können in diesem Bereich auch keine Indikationen auftreten. Dennoch treten vermehrt Indikationen bei Drehwinkeln zur Schutzgasströmungsrichtung hin auf. Allerdings liegen die meisten Indikationen nicht in dem Drehwinkelbereich der direkt am übersprungenen Bereich liegt vor. Der Drehwinkelbereich mit den meisten Indikationen ist von $58,5^\circ$ bis $67,6^\circ$.




Abbildung 7.4: Histogramm der Anzahl an Indikationen des Validierungsversuchs für die einzelnen Drehwinkelbereiche

Zudem wird die Verteilung der Indikationen anhand der Probe 11 betrachtet, welche mit einem erhöhten Hatchabstand gefertigt wurde. In Abbildung 7.5 sind die Indikationen an der jeweiligen Position, an der die Messdaten bestimmt wurden, dargestellt.




Abbildung 7.5: Verteilung der Indikationen in der Probe 11 des Validierungsversuchs

Die Indikationen sind über die ganze Probe verteilt, wobei eine erhöhte Indikationskonzentration im Randbereich zu erkennen ist.

7.1.3 Diskussion

Im Allgemeinen führt sowohl ein zu hoher als auch ein zu geringer Energieeintrag, welcher durch die Laserleistung und Scangeschwindigkeit bestimmt wird, zu hohen Porositäten. Bei einem zu geringen Energieeintrag werden die Schichten nicht ausreichend miteinander verschmolzen und ein zu hoher Energieeintrag hat Prozessstörungen wie die Spritzerbildung zur Folge. (MEINERS 1999) Unzureichendes Aufschmelzen führt zu Bindefehlern und ein zu hoher Energieeintrag zu Gasporen. Letztere entstehen meist durch das Kollabieren des Keyholes beim Tiefschweißprozess. Des Weiteren führt auch ein zu großer oder zu kleiner Hatchabstand zu erhöhten Porositäten. Das liegt daran, dass bei einem zu großen Hatchabstand der Pulverwerkstoff nur unzureichend aufgeschmolzen wird und bei einem zu kleinen Hatchabstand wird mehr Material verdampft, und die Dynamik im Schmelzbads steigt. (JUNFENG & ZHENGYING 2017) Die Schichtdicke führt bei einer Erhöhung zu höheren und einer Reduzierung zu geringeren Porositäten. Das liegt daran, dass bei geringeren Schichtdicken Luftblasen, welche bei der Verfestigung Gasporen bilden würden, besser aus dem Schmelzbad aufsteigen können. Dadurch wird die Abnahme der Porositäten durch Gasporen in Abbildung 7.1 bei einer Reduzierung der Schichtdicke erklärt. Zudem werden bei geringeren Schichtdicken die einzelnen Schichten öfter wieder aufgeschmolzen. Dadurch können Defekte besser ausheilen. Es ist allerdings zu erwarten, dass eine untere Grenze der Porosität bei einer Schichtdickenreduzierung nicht unterschritten werden kann, da immer einige Defekt im Material verbleiben. (GU & SHEN 2008) Das beschriebene Verhalten der Porositäten über die Änderung der Prozessparameter der Volumenenergiedichte wurde in dieser Arbeit nachgewiesen.

Des Weiteren wurde bei der Untersuchung der Defektgrößen festgestellt, dass eine Variation der Scangeschwindigkeit, im Gegensatz zu den anderen Prozessparametern, keinen Einfluss auf die mittlere Defektgröße und die Standardabweichung der Defektgrößen hat. Die Anzahl an Defekten ändert sich allerdings trotzdem und beeinflusst die Porosität. Dieses Ergebnis bestätigt die Ergebnisse aus der Dissertation von Simone Dietrich, welche die Grundlage dieser Untersuchung ist und in welcher dieses Verhalten zuvor festgestellt wurde. Im Rahmen dieser Dissertation wurden Proben mit Pulvern aus verschiedenen Aluminiumlegierungen gefertigt. Zudem wurde bei den Proben aus den verschiedenen Pulvern eine Variation Scangeschwindigkeit durchgeführt. Es

wurde festgestellt, dass die Verhältnisse der einzelnen Defektgrößen in der Häufigkeitsverteilung bei einer Variation der Scangeschwindigkeit nahezu gleich bleiben. Dies gilt sowohl für hohe Scangeschwindigkeiten, also kleine Volumenenergiedichten, als auch für geringe Scangeschwindigkeiten, und somit große Volumenenergiedichten. Das beschriebene Verhalten tritt trotz der unterschiedlichen Defektbildungsmechanismen bei hohen und geringen Scangeschwindigkeiten auf. Eine mögliche Interpretation für diese Defektgrößenverteilung bei geringen Scangeschwindigkeit ist, dass das Keyhole ab einer bestimmten maximalen Größe kollabiert. Deshalb treten Keyhole- oder Gasporen bei einer geringeren Scangeschwindigkeit nur bis zu einer bestimmten Größe auf. (DIETRICH 2018) Bei einer zu hohen Scangeschwindigkeit ist eine Erklärung über die Erhöhung der Abkühlrate möglich. Nach Y. LI & GU (2014) tritt beim Laserstrahlschmelzen von AlSi10Mg bei einer Vergrößerung der Scangeschwindigkeit eine deutlich größere Abkühlrate¹ auf. Dies ist bei der ebenfalls untersuchten Laserleistung nicht der Fall. Durch die hohen Abkühlraten und die generell höhere Viskosität der Schmelze, wegen dem geringeren Energieeintrag, benetzt die Schmelze das darunterliegende Material nur unzureichend und Defekte zwischen den Schichten werden gebildet. (XIA et al. 2017) Wegen den hohen Abkühlraten agglomerieren diese sich Defekte nicht und weisen deshalb eine geringe Größe auf. Die hohen Abkühlraten sind unter anderem ein Resultat des hohen Wärmeleitfähigkeitskoeffizienten von Aluminiumlegierungen. Deshalb kann der beschriebene Zusammenhang ein Materialcharakteristikum von Aluminiumlegierungen darstellen.

Der Verlauf der Porositäten über die Volumenenergiedichten aus Abbildung 7.1 stimmt mit den der A_{Ind} -Werten aus Abbildung 7.3 für alle Prozessparameter außer der Schichtdicke überein. Eine Begründung für das schlechte Erfassen der Porositäten geringer Schichtdicken durch die A_{Ind} -Werte ist durch die Ausheilung von Defekten gegeben. Bei einer Schichtdickenreduzierung werden die einzelnen Schichten häufiger wiederaufgeschmolzen, da die Schmelzbaddtiefe gleich bleibt. Dadurch können Defekte ausgeheilt werden. (LADEWIG et al. 2016) Eine Lösung dieses Problems stellt eine Filterung der Indikationen basierend darauf, ob die nachfolgenden Schichten an der gleichen Stelle auch eine Indikation aufweisen, dar. Von LADEWIG et al. (2016) wird angenommen, dass wenn eine Indikation in den zwei darauffolgenden an der gleicher Stelle auftritt ein negativer Einfluss auf die Bauteilqualität erwartet wird. In EOS (EOS 2016) wird hier die darauffolgende Schicht vorgeschlagen, die an der Stelle ohne Indikation vorliegen muss

¹Bei einer Erhöhung der Scangeschwindigkeit von $100 \frac{mm}{s}$ auf $400 \frac{mm}{s}$ stieg die Abkühlrate von $1,25 \cdot 10^6 \frac{^\circ C}{s}$ auf $6,17 \cdot 10^6 \frac{^\circ C}{s}$. (Y. LI & GU 2014)

damit der Defekt ausheilt. Somit kann, wenn eine oder zwei nachfolgenden Schichten an der Stelle der Indikation keine Indikation aufweisen die Indikation gelöscht werden. Des Weiteren reagiert der A_{Ind} -Wert auf eine Änderung des Hatchabstands und der Schichtdicke nur mit einer geringen Werteänderung. Die Porosität reagiert allerdings deutlich stärker auf diese Prozessparameteränderungen. Bei einer Variation der Laserleistung und Scangeschwindigkeit treten hingegen deutlich größere A_{Ind} -Werte auf. Im Allgemeinen werden höhere A_{Ind} -Werte als Porositäten angestrebt, da immer mehr Prozessstörungen als Defekte vorliegen. Diese Bedingung wird hier erfüllt.

Des Weiteren treten Indikationen abhängig vom Drehwinkel auf. Allerdings liegen die meisten Indikationen in einem Drehwinkelbereich von $58,5^\circ$ bis $67,6^\circ$. Dies kann ein Artefakt² des Weighted KNN Algorithmus sein. Der KNN Algorithmus beruht auf einer Mehrheitsentscheidungen im Featureraum, bei den die k nächsten Nachbarn einbezogen werden. Es kann sein, dass der Drehwinkelbereich im Trainingsdatensatz, welcher zu einem größeren Anteil mit Indikationen gelabelt wurde, im Featurraum des Validierungsdatensatz in der Nähe des Drehwinkelbereich von $58,5^\circ$ bis $67,6^\circ$ liegt. Dadurch werden diese Datenpunkte durch die Mehrheitsentscheidung vermehrt als Indikationen gelabelt. Somit versagt der Algorithmus dabei die Informationen des Trainingsdatensatz hinsichtlich des Drehwinkels auf den Validierungsdatensatz zu verallgemeinern. Abhilfe könnte ein komplexerer Algorithmus, der Daten besser verallgemeinern kann, schaffen. Mögliche Algorithmen sind hier neuronale Netze oder eine Support Vector Machine.

7.2 Veränderung der Signale durch die Parametervariation

In diesem Kapitel wird die Veränderung der Signale durch die Parametervariation untersucht. Dafür werden einige Signalcharakteristika ermittelt. Diese sind die Mittelwerte und die Standardabweichungen der beiden Photodioden ADC1 und ADC2. Ferner werden diese Untersuchungen anhand der Signaldaten des Trainingsversuchs (Kapitel 7.2.1) und des Validierungsversuchs (Kapitel 7.2.2) durchgeführt. Zudem wird der Einfluss des Drehwinkels, der Scanvektorlänge und der Bauraumposition auf die Signalcharakteristika betrachtet.

²Ein Artefakt beschreibt ein nicht der Realität entsprechendes durch Eigenschaften der Methode hervorgerufenen Ergebnis.

7.2.1 Untersuchung der Signaländerungen mit dem FCCCD

Um den Einfluss der einzelnen Prozessparameter, sowie deren Wechselwirkungen auf die Mittelwerte und Standardabweichung der Signale zu erfassen, wurden Wirkungsflächendiagramme mit der Software Minitab 2017 erstellt. In Abbildung 7.6 sind die Wirkungsflächendiagrammen mit den Mittelwert und Standardabweichung von ADC1 μ_{ADC1} und σ_{ADC1} dargestellt. Es ist zu erkennen, dass bei einer Erhöhung der Laserleistung der μ_{ADC1} -Wert zunimmt. Bei einer Vergrößerung des Strahlendurchmesser oder der Schichtdicke treten hingegen kaum Werteänderungen auf. Für σ_{ADC1} treten deutlich größere Werte bei dem kleinsten Strahlendurchmesser auf, wie auch schon im geringeren Maße bei μ_{ADC1} . Zudem weist σ_{ADC1} einen stark nichtlinearen Zusammenhang zwischen der Laserleistung und Schichtdicke auf.

In Abbildung 7.7 sind die Prozessparameter gegen die Standardabweichungen und Mittelwerte von ADC2 aufgetragen. Die Verläufe von μ_{ADC2} und σ_{ADC2} über die Prozessparameter sind ähnlich. Bei beiden führen eine Erhöhung der Laserleistung und der Schichtdicke zu hohen Werten, wobei die Werte vor allem mit der Vergrößerung der Schichtdicke zunehmen. Dies kann dadurch erklärt werden, dass die Schichtdicke von ihrem Standardwert um $\pm 50\%$ variiert wurde und die Laserleistung lediglich um $\pm 20\%$. Des Weiteren nehmen μ_{ADC2} und σ_{ADC2} mit dem Strahlendurchmesser zu, wobei ein Knick bei geringen Strahlendurchmesser auftritt und dort höhere Werte erreicht werden. Ein größerer Strahlendurchmesser führt einerseits zu einem geringeren auf die Fläche bezogenen Energieeintrag in das Bauteil und andererseits zu erhöhter Spritzerbildung. (GRÜNBERGER & DOMRÖSE 2015) Diese Effekte werden somit von σ_{ADC2} erfasst. Da die Prozessparameter Schichtdicke und Laserleistung auch in dem im Validierungsversuch variiert wurden, wird hier auf eine Erklärung der den Verläufen zugrundeliegenden Effekte verzichtet und stattdessen auf das folgende Kapitel verwiesen.

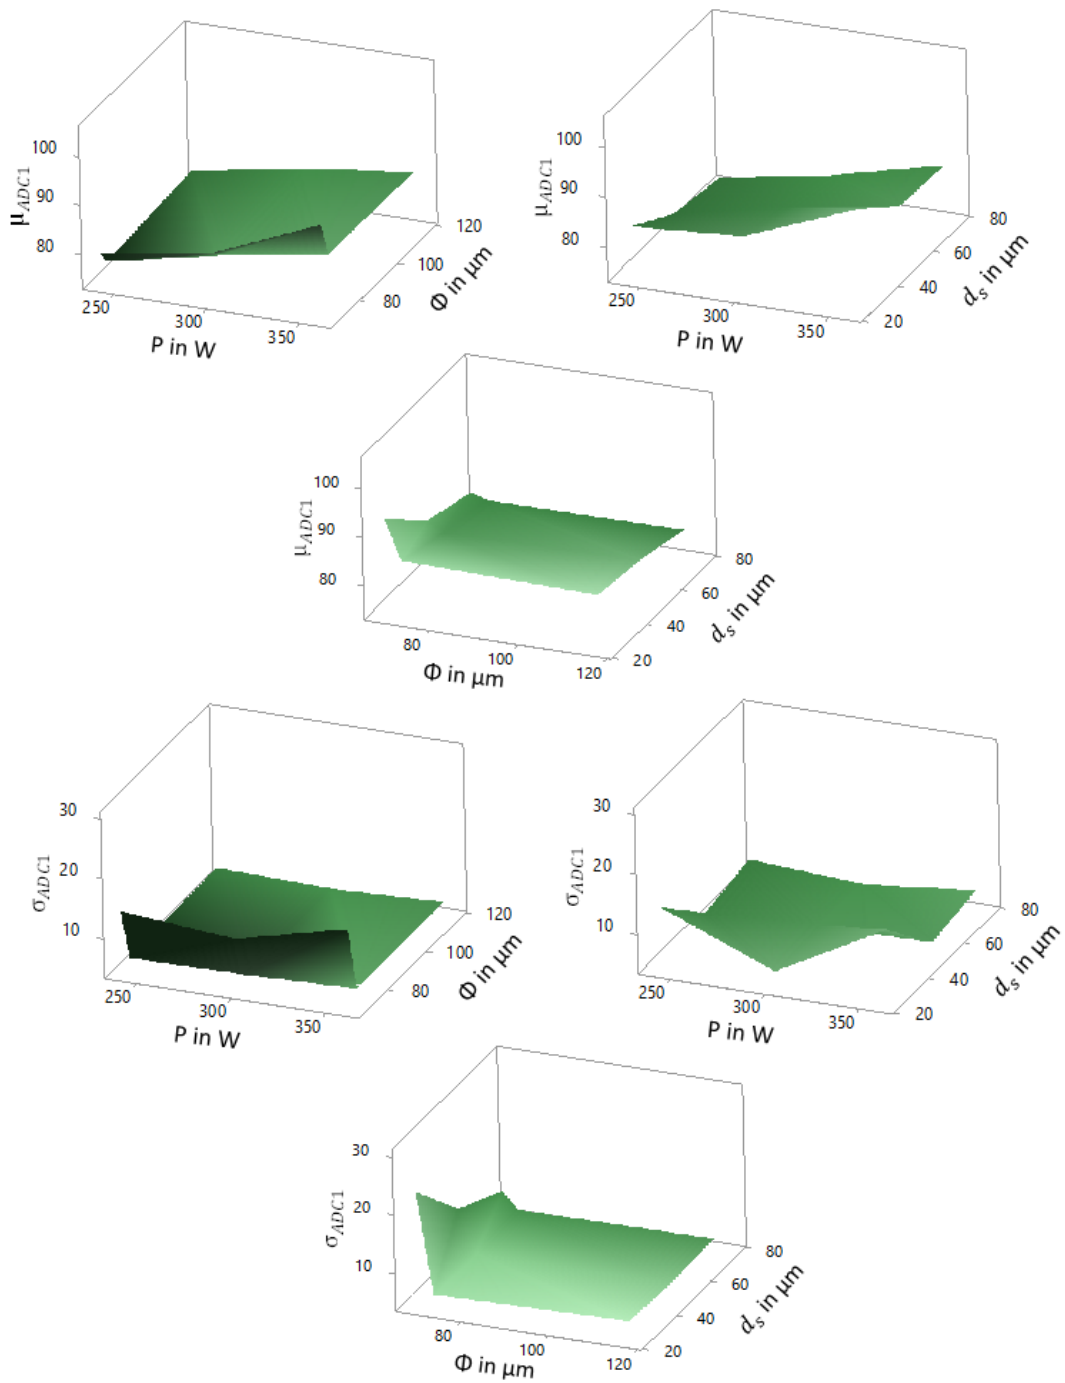


Abbildung 7.6: Wirkungsflächendiagramme mit μ_{ADC1} und σ_{ADC1} in der z-Richtung nach dem FCCCD

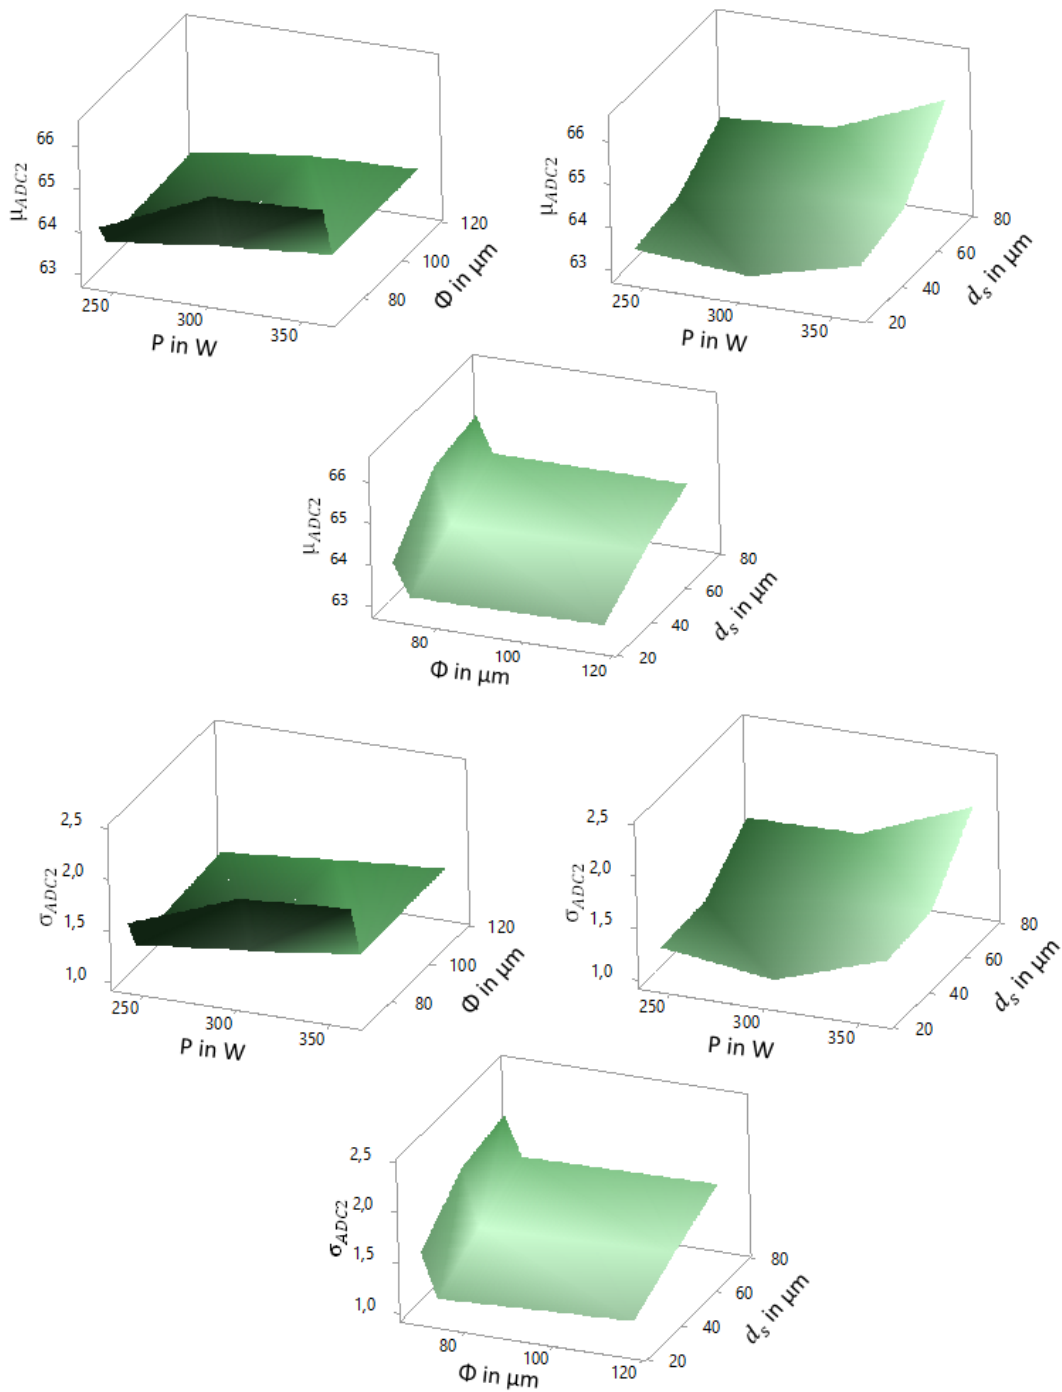


Abbildung 7.7: Wirkungsflächendiagramme mit μ_{ADC2} und σ_{ADC2} in der z-Richtung nach dem FCCCD

Zudem wird die Auswirkung einer Reduzierung des D_G -Werts auf die Signalcharakteristika untersucht. In Abbildung 7.8 sind die Signalcharakteristika der mit dem Standardparametersatz gefertigten Proben in den drei Baujobs gegen den D_G -Wert aufgetragen.

Die Fehlerbalken stellt die Standardabweichung der ermittelten Signalcharakteristika zwischen den einzelnen Proben dar.

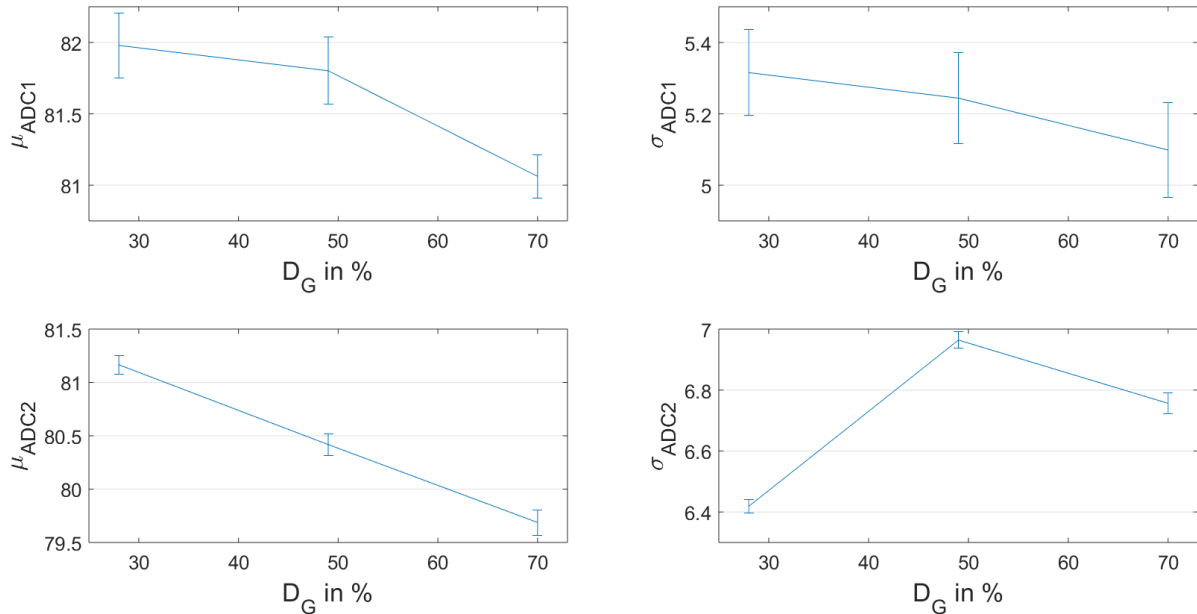


Abbildung 7.8: Signalcharakteristika μ_{ADC1} , σ_{ADC1} , μ_{ADC2} und σ_{ADC2} der mit dem Standardparametersatz gefertigten Proben aufgetragen gegen den D_G -Wert

Es ist zu erkennen, dass μ_{ADC1} , σ_{ADC1} und μ_{ADC2} mit einer Reduzierung des D_G -Werts zunehmen. σ_{ADC2} weist ein Maximum bei deinem D_G -Wert von 49 % auf. Die Zunahme der Signalcharakteristika bei einer Reduzierung des D_G -Wert kann dadurch erklärt werden, dass eine Reduzierung der Durchflussrate zu einer erhöhten Spritzerbildung führt. (GRÜNBERGER & DOMRÖSE 2015) Diese wird von den Signalcharakteristika erfasst.

7.2.2 Einfluss der Volumenenergiedichte auf die Signale

Im Folgenden werden die Änderung der Signalcharakteristika der Proben aus dem Validierungsversuch in Bezug auf die Variation der Volumenenergiedichte untersucht. Diese Untersuchung wurde in ROSENKRANZ et al. (2018) durchgeführt und wird hier zur Vollständigkeit übernommen. In Abbildung 7.9 sind die Mittelwerte und Standardabweichung der Signale von den Photodioden ADC1 und ADC2 gegen die Volumenenergiedichte Ψ aufgetragen. Mit den Fehlerbalken ist die Standardabweichung der

Signalcharakteristika zwischen den drei mit dem gleichen Parametersatz gefertigten Proben dargestellt.

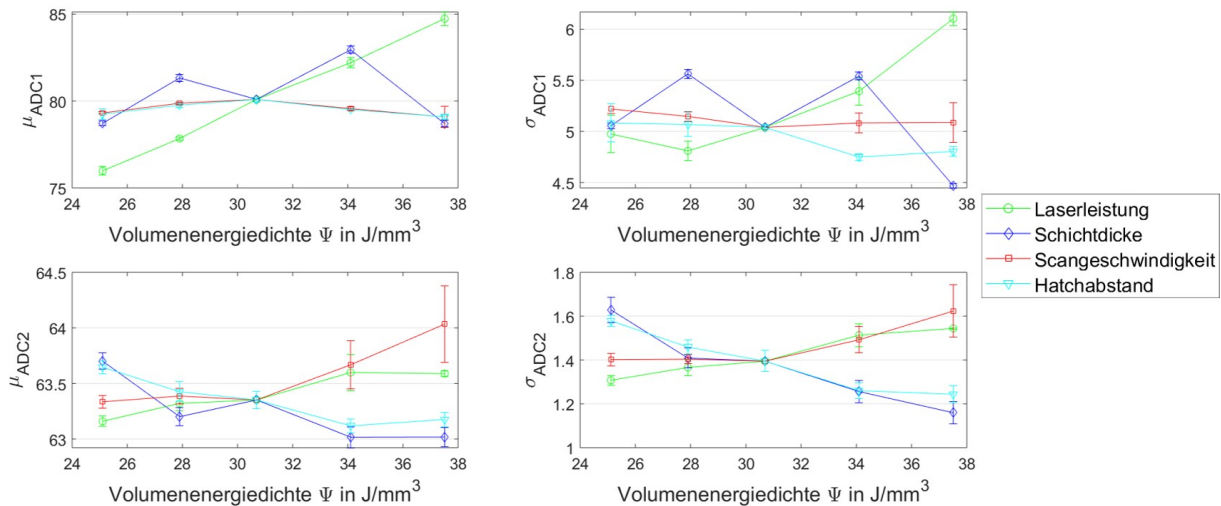


Abbildung 7.9: Signalcharakteristika μ_{ADC1} , σ_{ADC1} , μ_{ADC2} und σ_{ADC2} der untersuchten Volumenenergiedichtestufen in Anlehnung an ROSENKRANZ et al. (2018)

Fast alle Signalcharakteristika steigen mit einer Erhöhung der Laserleistung, wobei μ_{ADC1} und σ_{ADC1} die größten Werteänderungen aufweisen. Das liegt daran, dass eine Erhöhung der Laserleistung mit einem Temperaturanstieg im Schmelzbad verbunden ist, und somit nimmt nach dem Planck'schen Strahlungsgesetz auch die emittierte Wärmestrahlung zu. Die Erhöhung der Standardabweichung σ_{ADC1} und σ_{ADC2} mit der Laserleistung kann auf die größere Schmelzbadynamik und vermehrte Spritzerbildung bei höheren Laserleistungen zurückgeführt werden. (MEINERS 1999) Die Schichtdicke weist keinen klaren Trend mit μ_{ADC1} und σ_{ADC1} auf. Es treten jedoch Maxima bei Schichtdicken von $45 \mu\text{m}$ und $55 \mu\text{m}$ auf. Im Gegensatz dazu reagieren die Signalcharakteristika μ_{ADC2} und σ_{ADC2} auf die Variation der Schichtdicke und des Hatchabstands mit deutlichen Änderungen, wobei bei einer Erhöhung der Volumenenergiedichte die Werte dieser Signalcharakteristika abnehmen. Wegen der besseren Schichtanbindung erfolgt bei dünneren Schichtdicken eine stärkere Wärmeableitung in das verfestigte Material. Deshalb sinken die Temperaturen schneller und die Strahlungsintensität der Wärmestrahlung nimmt ab. Die abnehmenden μ_{ADC2} - und σ_{ADC2} -Werte bei kleineren Hatchabständen können auch durch eine besserer Anbindung der Schmelzspuren zueinander und somit durch einen höhere Wärmeabfuhr erklärt werden. Unterschiedliche Scangeschwindigkeiten und Hatchabstände führen zu kleinen Wertänderungen von μ_{ADC1} und σ_{ADC1} ohne erkennbaren Trend. μ_{ADC2} und σ_{ADC2} steigen mit einer Erhöhung der Volumenenergiedichte durch die Scangeschwindigkeit. Dies kann wie schon bei der Laserleistung

an den größeren Energieeintrag liegen, welcher zu erhöhter Strahlungsintensität der Wärmestrahlung führt.

7.2.3 Veränderung der Signale über den Drehwinkel und der Scanvektorlänge

Die Betrachtung der Signale über den Drehwinkel und der Scanvektorlänge wurde aus ROSENKRANZ et al. (2018) übernommen. Bei Scanvektoren, in denen der Laser in Strömungsrichtung des Schutzgases schweißt, wird das Laserlicht defokussiert und es bilden sich vermehrt Spritzer. (ANWAR & PHAM 2017) Diese beiden Effekte führen zu einer Signaländerung über den Drehwinkel. In Abbildung 7.10 sind die Verläufe der Signalcharakteristika μ_{ADC1} , σ_{ADC1} , μ_{ADC2} und σ_{ADC2} gegen den Drehwinkel γ aufgetragen. Die einzelnen Punkte wurden hierbei jeweils aus den Signalen einer der 164 Schichten der Proben ermittelt. Zur Veranschaulichung wurde für Abbildung 7.10 eine Auswahl von neun gleichmäßig über die Bauplattform verteilten Proben verwendet. Funktionen, die aus einer Summe von Sinusen bestehen, wurden mit der MATLAB Curve Fitting Toolbox ermittelt und sind ebenfalls in Abbildung 7.10 dargestellt. Der Bereich des Drehwinkels, der im Standardparametersatz übersprungen wird, ist blau markiert.

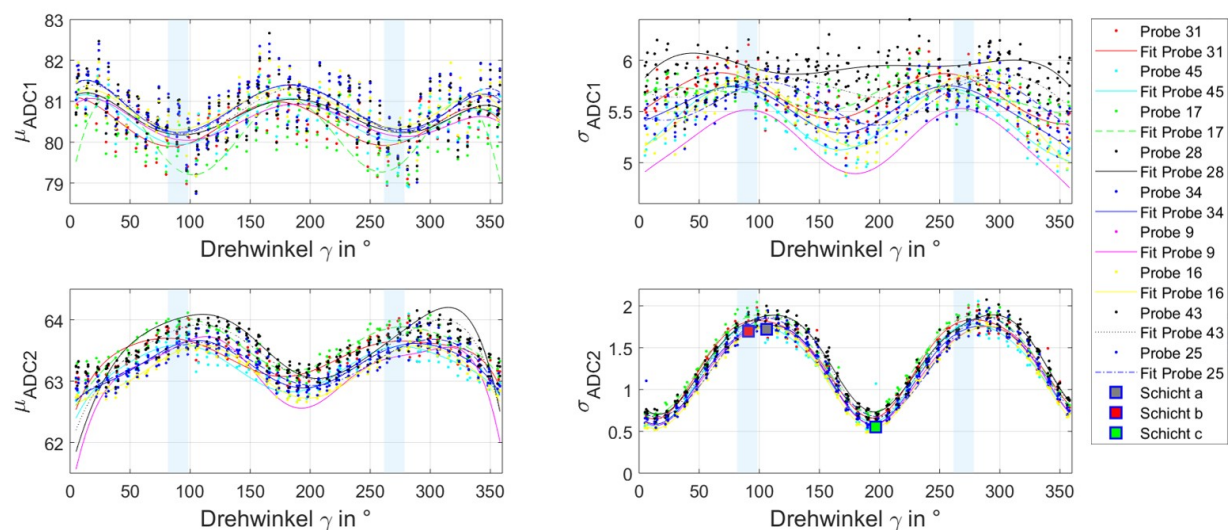


Abbildung 7.10: Untersuchung der Veränderung von Mittelwert μ und Standardabweichung σ der Photodioden ADC1 und ADC2 gegen den Drehwinkel γ für mehrere Schichten in Anlehnung an ROSENKRANZ et al. (2018)

Die gefitteten Funktionen μ_{ADC2} und σ_{ADC2} sind um die Drehwinkel 90° oder 270° maximal. Bei diesen Drehwinkeln ist die Scanrichtung gleich der Schutzgasströmungsrichtung und damit die Defokussierung des Laserlichts maximal. μ_{ADC1} verläuft gegenläufig zu μ_{ADC2} . Im Allgemeinen zeigen die Signalcharakteristika von ADC2 und im speziellen von σ_{ADC2} einen eindeutigeren Trend über den Drehwinkel im Vergleich zu ADC1.

Für weitere Untersuchungen von σ_{ADC2} der einzelnen Scanvektoren wurden drei Schichten der Probe 34 exemplarisch ausgewählt. Diese Schichten sind in Abbildung 7.10 mit a,b und c gekennzeichnet. Schicht a ($\gamma = 106^\circ$) wurde gewählt, da σ_{ADC2} bei dieser Schicht maximal ist. Des Weiteren stellt Schicht b ($\gamma = 91^\circ$) eine Schicht innerhalb des übersprungenen Drehwinkelbereichs dar. Die Schicht c ($\gamma = 197^\circ$) weist einen Drehwinkel auf, bei dem σ_{ADC2} minimal ist. In Abbildung 7.11 ist die Standardabweichung σ_{ADC2} jedes Scanvektors der jeweiligen Schicht gegen die Scanvektorenlänge aufgetragen. Bei den Schichten a und b tritt eine Trennung der σ_{ADC2} -Werte in zwei Wertebereiche

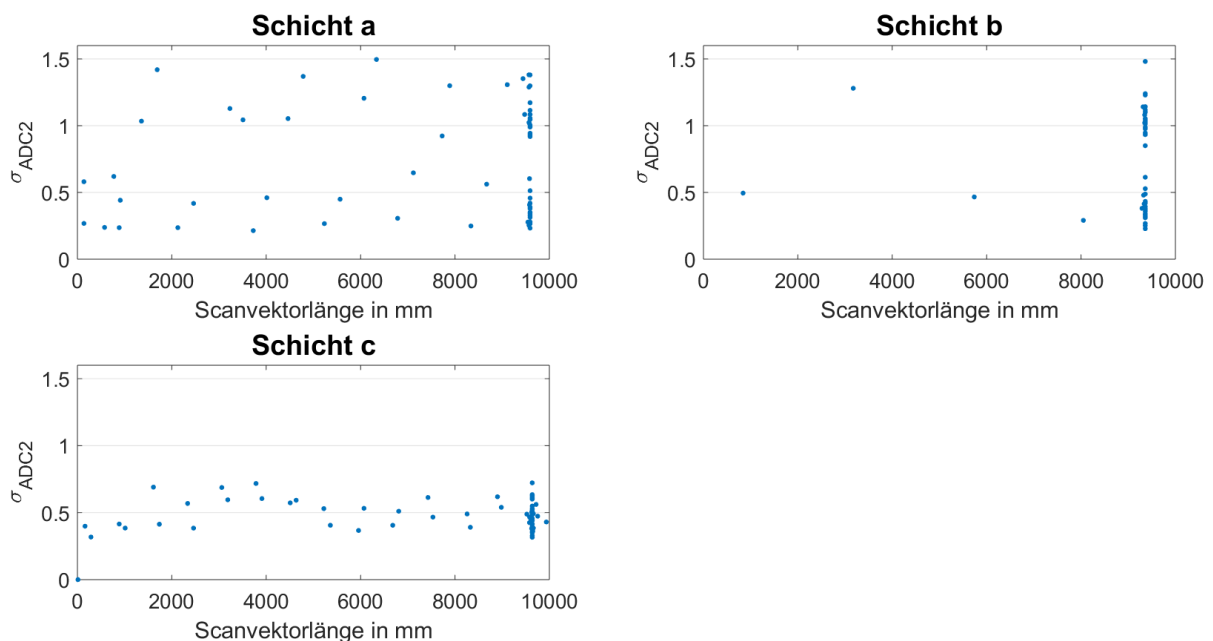


Abbildung 7.11: Untersuchung des Einflusses der Scanvektorenlänge auf σ_{ADC2} in Anlehnung an ROSENKRANZ *et al.* (2018)

auf. Dabei wurden die Scanvektoren mit den höheren σ_{ADC2} -Werten in Schutzgasströmungsrichtung gefertigt und die mit den geringeren σ_{ADC2} -Werten entgegen der Schutzgasströmungsrichtung. Diese Aufteilung in zwei Wertebereiche ist ein deutlicher Hinweis darauf, dass die Defokussierung des Laserlichts mit σ_{ADC2} -Wert detektiert wird. Schicht c, in welcher die Scanvektoren orthogonal zur Schutzgasströmung verlaufen,

weist keine Trennung in zwei Wertebereiche auf. Des Weiteren steigen die σ_{ADC2} -Werte der Schichten für kleine Scanvektoren an. Dies liegt nach KRAUSS (2016, S. 108) an einer Wechselwirkung zwischen dem Skywriting und der Belichtungszeit bei kleinen Scanvektorlängen. Die Laserauszeit während des Skywritings beträgt dann ungefähr der Belichtungszeit und es kommt zu Überlagerungseffekten. (KRAUSS 2016, S. 108)

7.2.4 Untersuchung des Bauraumeinflusses auf die Signale und die Porositäten

Das Vorgehen um die Richtung der Schutzgasströmung mit einem online-Prozessüberwachungs Messsystem zu bestimmen stammt aus ROSENKRANZ et al. (2018) und wird hier mit den Ergebnissen dieser Forschung vorgestellt.

Aus Kapitel 7.2.3 ist bekannt, dass σ_{ADC2} als eine Maß für die Defokussierung des Laserlichts über den Drehwinkel angesehen werden. Diese Defokussierung ist maximal wenn die Laser in Schutzgasströmungsrichtung schweift. Die Strömungsrichtung ist allerdings nach FERRAR et al. (2012) über die Bauplatzform nicht konstant. Um die Strömungsrichtung zu bestimmen wurden mit der findpeaks Funktion aus MATLAB die Maximalwerte der gefitteten Funktionen von σ_{ADC2} ermittelt, welche wie in Kapitel 7.2.3 beschrieben bestimmt wurden. Da die Verläufe, wie in Abbildung 7.10 zu sehen, zwei Maxima aufweisen, wurde immer der Maximalwert mit dem kleineren Drehwinkel weiterverwendet. Die Drehwinkel der so bestimmten Maxima wurden anschließend mit der Funktion arrow3 aus MATLAB File Exchange über den Bauraum an der Position der jeweiligen Probe aufgetragen. Die Drehwinkel stellen dabei die Richtung der Pfeile dar. Dies ist in Abbildung 7.12 dargestellt. Dieses Vorgehen dient dazu die Richtung der Schutzgasströmung über den Bauraum zu bestimmen. Es ist zu erkennen, dass die Pfeile in der Mitte der Bauplatzform häufig ihre Richtung ändern. Diese Richtungsänderung der Schutzgasströmung findet auch im realen Prozess statt und hängt von der Düsenkonfiguration der Anlage ab. (FERRAR et al. 2012)

Des Weiteren wird die Güte der gefitteten Funktionen mit der Wurzel der mittleren quadratischen Abweichung (englisch Root Mean Square Error **RMSE**) ermittelt. Diese gibt an wie gut die Funktionen an die Daten angepasst sind und sagt aus um wie viel im Durchschnitt die Schätzung von den Daten abweicht. (FAHRMEIR et al. 2016) Es wird angenommen, dass ein hoher **RMSE**-Wert für Turbulenzen in der Schutzgasströmung steht. Das liegt daran, dass durch eine häufige Richtungsänderung der Schutzgasströmung zwischen den einzelnen Schichten der Verlauf von σ_{ADC2} schlechter durch eine




Abbildung 7.12: Drehwinkel der Maxima von den gefitteten Funktionen aufgetragen über den Bauraum in Anlehnung an ROSENKRANZ et al. (2018)

Funktion abgebildet werden kann. In Abbildung 7.13 sind die **RMSE**-Werte dargestellt, welche über den Bauraum interpoliert wurden. Die Interpolation wurde mit der MATLAB Funktion `griddata` durchgeführt. Als Interpolationsart wurde eine quadratische auf Triangulation basierende Interpolation zwischen den Punkten gewählt. Mit dieser werden die nicht gleichmäßig auf der Fläche verteilten Punkte zu gleichmäßig auf der Fläche verteilten Punkten interpoliert.

Im Randbereich der Bauplattform treten höhere **RMSE**-Werte auf. Dies kann an einer Ablösung der Schutzgasströmung in diesem Bereich und den daraus folgenden Turbulenzen liegen. Zudem nehmen die **RMSE**-Werte von der Einlassdüse zur Auslassdüse hin zu. Ein Weitere Grund für die Unterschiede in den **RMSE**-Werten können neben den Turbulenzen Prozessstörungen sein, welche die Signale in einigen Schichten verändern und somit die Güte des Fittes verschlechtern. Des Einfluss von Prozessstörungen auf den **RMSE**-Werte kann durch eine Prozessparametervariation an verschiedenen Bauraumpositionen untersucht werden.

Zudem werden die Porositätsunterschiede über die Bauplattform betrachtet. Die Porositäten wurden wie in Kapitel 4.3.1 beschrieben nach Archimedes bestimmt. In Abbildung 7.14 sind die Porositäten, der mit einer Schichtdicke von $61,1 \mu\text{m}$ gefertigten Versuche




Abbildung 7.13: Interpolierte *RMSE*-Werte über den Bauraum

über die Bauplattform, dargestellt. Dabei wurde die selbe Interpolationsart wie auch schon beim *RMSE*-Wert gewählt. Abbildung 7.14 links zeigt den Versuch bei dem alle Drehwinkel gefertigt wurden und Abbildung 7.14 rechts stellt die Porositäten des Versuches, bei dem der Drehwinkelbereich in Schutzgasströmungsrichtung übersprungen wurde, dar. Die mittlere Porosität der beiden in Abbildung 7.14 dargestellten Versuche beträgt für den Versuch bei dem alle Drehwinkel gefertigt wurden 1,5168 % und für den Versuch bei dem der Bereich in Schutzgasströmungsrichtung übersprungen wurde 1,5398 %. Das heißt, dass ein Überspringen des Drehwinkelbereichs in Schutzgasströmungsrichtung führt hier im Mittel nicht zu einer geringeren Porosität führt. Dennoch weisen viele Proben mit dem übersprungen Drehwinkelbereich an einigen Bauraumpositionen eine geringere Porosität auf. Im Allgemeinen weist der Versuch mit dem nicht übersprungen Drehwinkelbereich Proben mit einer hohen Porosität auf. Dennoch werden in dem Versuch mit dem übersprungen Drehwinkelbereich die höchsten Porositäten erreicht. Die Porositäten von Abbildung 7.14 links weisen an ähnlichen Stellen wie die *RMSE*-Werte in Abbildung 7.13 hohe Beträge auf. Da es sich hier um den selben Versuch handelt kann daraus geschlossen werden, dass entweder Prozessstörungen, die zu hohen Porositäten führen, auch zu hohen *RMSE*-Werten führen oder dass Turbulenzen in der Schutzgasströmung, die nach LADEWIG et al. (2016) zu schlechter Bauteilqualität führen, von den *RMSE*-Werten erfasst werden.




Abbildung 7.14: Interpolation der Porositäten über den Bauraum der mit einer Schichtdicke von $61,1 \mu\text{m}$ gefertigten Versuche. links: alle Drehwinkel wurden gefertigt. rechts: der Drehwinkelbereich in Schutzgasströmungsrichtung wurde übersprungen

Des Weiteren werden die Porositäten des mit einer Schichtdicke von $40,9 \mu\text{m}$ gefertigten Versuchs über den Bauraum betrachtet. Die Interpolation wurde auf die selbe Weise wie beim [RMSE](#)-Werter durchgeführt.

Bei diesem Versuch treten in anderen Bereichen des Bauraums als bei den mit $61,1 \mu\text{m}$ gefertigten Versuchen hohe Porositäten auf. Diese Bereiche liegen vor allem an der Einlassdüse. Eine Begründung für die schlechtere Bauteilqualität an der Einlassdüse kann die höhere Schutzgasströmungsgeschwindigkeit in Kombination mit der zu hohen gefertigten Volumenenergiedichte sein. Die Schutzgasströmungsgeschwindigkeit nimmt von der Einlassdüse hin zur Auslassdüse ab. Deshalb wird der Schmauch an der Einlassdüse besser abtransportiert. (LADEWIG et al. 2016) Der Schmauch führt zu einer Defokussierung des Laserlichts und so zu einem geringeren Energieeintrag. Da die Proben mit einer zu hohen Volumenenergiedichte gefertigt wurden, führt ein geringerer Energieeintrag zu einer besseren Bauteilqualität.

Neben den Porositäten werden die Signalcharakteristika über den Bauraum betrachtet. Hierfür werden μ_{ADC1} , σ_{ADC1} und μ_{ADC2} und σ_{ADC2} für die mit einer Schichtdicke von $61,1 \mu\text{m}$ gefertigten Versuchs über den Bauraum interpoliert. In [Abbildung 7.16](#) sind die Baurauminterpolationen des mit allen Drehwinkel gefertigten Versuchs und in




Abbildung 7.15: Interpolation der Porositäten über den Bauraum des mit einer Schichtdicke von $40,9 \mu\text{m}$ gefertigten Versuchs

Abbildung 7.17, die des mit dem übersprungen Drehwinkelbereich gefertigten Versuchs, dargestellt.

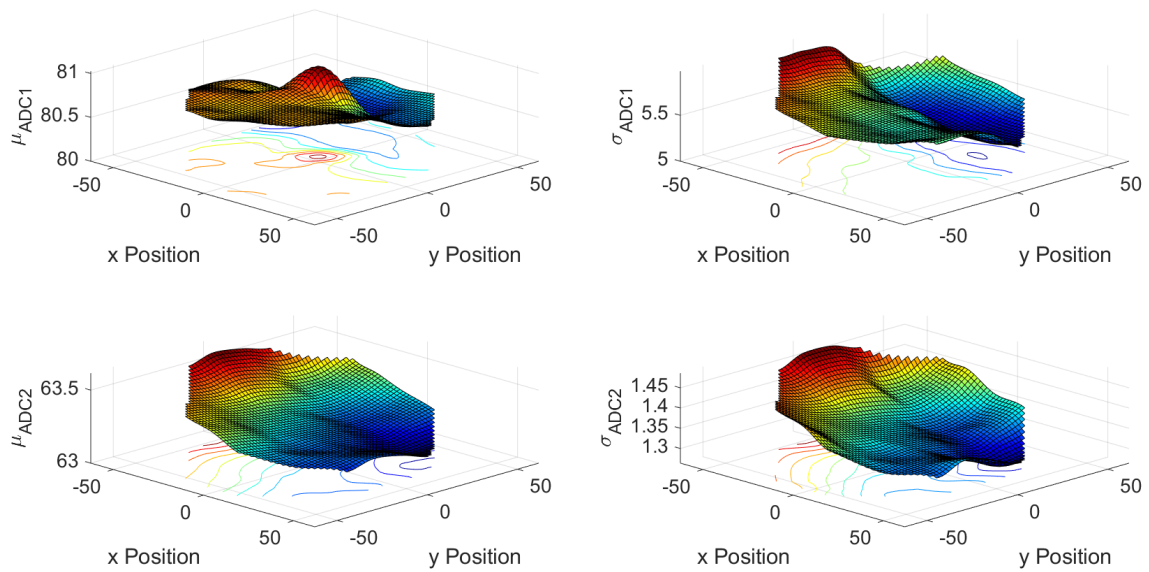


Abbildung 7.16: Interpolation der Signalcharakteristika über den Bauraum des mit einer Schichtdicke von $61,1 \mu\text{m}$ und allen Drehwinkeln gefertigten Versuchs

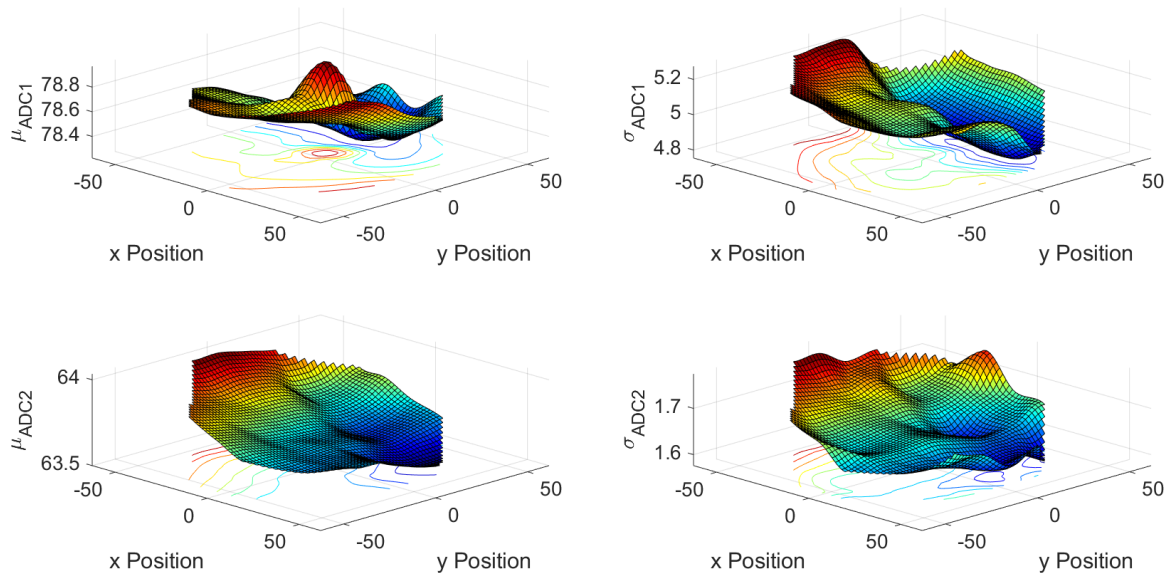


Abbildung 7.17: Interpolation der Signalcharakteristika über den Bauraum des mit einer Schichtdicke von $61,1 \mu\text{m}$ und dem übersprungenen Drehwinkelbereichs gefertigten Versuchs

Die Verläufe der Signalcharakteristika von den beiden Versuchen in Abbildung 7.16 und 7.17 sind ähnlich. Der μ_{ADC1} weist ein Maximum in der Mitte des Bauraums auf. In der Mit-

te des Bauraums wird die Energie des Laserlichts am besten eingekoppelt. Zudem weist der Laserspot zum Rand der Bauplattform eine Verzeichnung auf und nimmt eine elliptische Form an. Auf diese beiden Effekte reagiert der μ_{ADC1} -Wert. σ_{ADC1} -Wert nimmt zum Rand hin im Gegensatz zu μ_{ADC1} höhere Werte an. Dies kann an der Verzeichnung des Laserspots und an Turbulenzen in der Schutzgasströmung, welche nach dem Verlauf des [RMSE](#)-Werts am Rand auftreten, liegen. Zudem nehmen die σ_{ADC1} -Werte zur Auslassdüse hin zu. Eine Begründung dafür ist die abnehmende Geschwindigkeit der Schutzgasströmung, welche zu einer stärkeren Wechselwirkung des Lasers und der Prozessnebenprodukte führt und somit zu einer größeren Schwankung im Prozess und dadurch einer höheren Standardabweichung im Signal. Mit der Geschwindigkeit der Schutzgasströmung korrelieren auch μ_{ADC2} -Wert und σ_{ADC2} negativ. σ_{ADC2} unterliegt bei dem Versuch mit dem übersprungenen Drehwinkelbereich deutlich größeren Schwankungen als bei dem Versuch, bei dem alle Drehwinkel gefertigt wurden.

7.2.5 Fazit und weiteres Vorgehen

Der Zusammenhang zwischen den Signalcharakteristika und der Prozessparameteränderung ist komplex. Dies liegt zum einen daran, dass bei einer Prozessparameteränderung verschiedene Effekte auftreten, die zu unterschiedlichen emittierten Strahlungsintensitäten aus dem Schmelzbad führen. Andererseits weisen die Photodioden unterschiedliche sensitive Wellenlängenbereiche auf und erfassen die Strahlung aus dem Schmelzbad bei verschiedenen Prozessparameterstufen somit unterschiedlich. Die Wiensche Verschiebung führt dazu, dass sich der Wellenlängenbereich, indem am meisten Strahlung emittiert wird, über die Temperatur und somit die Prozessparametervariation verschiebt. Dabei werden bei einer Erhöhung der Temperatur höhere Strahlungsintensitäten bei kleineren Wellenlängen emittiert. (WIEN 1893) Diese Verschiebung in Kombination mit den sensitiven Wellenlängenbereichen der Photodioden führt zu komplizierten Zusammenhängen zwischen den Signalen der Photodioden und dem realen Prozess. Die Methoden des maschinellen Lernens bilden einen vielversprechenden Ansatz, um diese Zusammenhänge erfassen zu können.

Zudem kann über die Standardabweichung des Signals der ADC2 Photodiode σ_{ADC2} die Richtung und die Turbulenzen der Schutzgasströmung bestimmt werden. Wobei dies noch durch weitere Versuche oder eine Simulation validiert werden sollte. Um die Genauigkeit dieses Vorgehens zu verbessern, wird vorgeschlagen, die Anzahl an Schichten zu erhöhen und zylinderförmige anstatt würfelförmige Proben zu fertigen. Zylinderförmige Proben weisen unabhängig vom Drehwinkel annähernd die gleichen Anteile an

Scanvektoren einer bestimmten Scanvektolänge in jeder Schicht auf und dadurch wird der Einfluss der Scanvektolänge auf den σ_{ADC2} -Wert eliminiert. Des Weiteren korrelieren die μ_{ADC2} - und σ_{ADC2} -Werte über den gesamten Bauraum mit der Geschwindigkeit der Schutzgasströmung. Dadurch kann über diese eine Abschätzung der Geschwindigkeit der Schutzgasströmung getroffen werden, wobei hier weitere Einflussgrößen, wie die Verzeichnung des Laserlichts über die Bauplattform, berücksichtigt werden müssen. Um den Zusammenhang dieser Signalcharakteristika mit der Geschwindigkeit der Schutzgasströmung zu erfassen, können Versuche mit verschiedenen D_G -Werten und somit Schutzgasströmungsgeschwindigkeiten durchgeführt werden. Anschließend werden die ermittelten μ_{ADC2} - und σ_{ADC2} -Werte an der Einlassdüse auf einen Zusammenhang mit der von der Anlage in der Einlassdüse gemessenen Schutzgasströmungsgeschwindigkeiten untersucht. Diese hängt mit ihrem Absolutwert allerdings vom konkreten Einbaus des Sensors ab, sollte aber eine qualitative Aussage über die Geschwindigkeit ermöglichen. (RICHTER 2017) Sind die Zusammenhänge zwischen Signalcharakteristika und Schutzgasströmungsrichtung, -geschwindigkeit und Turbulenzen erfasst, stellt dieses Vorgehen eine effiziente Möglichkeit dar, den Schutzgasstrom zu optimieren. Hierbei können verschiedene Düsenkonfigurationen erprobt und deren Auswirkungen auf den Schutzgasstrom direkt mittels eines Versuchs erfasst werden.

Des Weiteren ermöglicht die Erfassung der Schutzgasstromrichtung und der Größe der Defokussierung des Laserlichts bei Schweißvorgängen in Schutzgasstromrichtung eine Anpassung der Belichtungsstrategie. Einerseits können die übersprungen Drehwinkelbereiche auf die Richtung der Schutzgasströmung angepasst werden und andererseits können Scanvektoren in Schutzgasströmung mit einem geringem Laserfokus gefertigt werden, um die Defokussierung des Laserlichts durch den Schmauch auszugleichen. Dafür muss in Vorversuchen die Größe der Defokussierung durch den Schmauch bestimmt werden, indem der σ_{ADC2} -Wert der Schweißvorgängen in Schutzgasstromrichtung mit dem σ_{ADC2} -Wert in Versuchen mit einer Variation des Anlagenfokus verglichen wird. Des Weiteren kann auch der Energieverlust durch die Absorption des Laserlichts bei der Wechselwirkung mit dem Schmauch durch die Signalcharakteristika bestimmt und mit einer Erhöhung der Laserleistung ausgeglichen werden.

8 Zusammenfassung

In vorliegende Arbeit wurde ein Konzept des maschinellen Lernens zur Detektion von Prozessstörungen umgesetzt. Das Konzept basiert auf Korrelationen zwischen den Messdaten und den archimedisch gemessenen Porosität der Proben eines Trainingsversuchs. Auf die mit einer Korrelationsmetrik ausgewählten Daten wurde ein **KNN** Algorithmus trainiert, welcher anschließend mit einem weiteren Versuch validiert wurde.

Die Messdaten der gesamten Proben wurden in einzelne Pixel mit einer Kantenlänge von 1 *mm* aufgeteilt. Aus den Signaldaten der Pixeln und den Prozessdaten der Proben wurden Feature extrahiert. So ergaben sich 51 Feature für jedes Pixel. Bei den Features wurden anschließend die redundanten Feautre über den Spearman Korrelationskoeffizienten entfernt. Es blieben 36 Feature übrig. Danach wurde eine sequentielle Rückwärtswahl durchgeführt und so die Featureanzahl auf 22 reduziert. Diese 22 Feature wurden mittels einer **PCA** auf 14 Dimensionen transformiert, welche dem Clustering Algorithmus k-Means übergeben wurden. Aus dem Ergebnis des Clusterings wurde mittels einer Korrelationsmetrik die Cluster bestimmt, die am besten mit den Porosität korrelieren. Die Daten der ausgewählten Cluster wurden anschließend als Indikationen gelabelt. Beim Vergleich des Anteils der Indikationen in den Proben mit den Porositäten der Proben fiel auf, dass die Verläufe Porositäten von den Indikationen zu einem großen Teil qualitativ richtig erfasst wurden. Zudem trat eine Drehwinkelabhängigkeit der Indikationen auf. Drehwinkel bei denen der Laser in Richtung der Schutzgasströmung schweißt, weisen vermehrt Indikationen auf. Dies liegt daran, dass dann Prozessnebenprodukte in den Strahlengang des Lasers geraten und das Laserlicht defokussiert wird. (DOMRÖSE et al. 2013) Auf die gelabelten Daten des Trainingsversuch wurde der **KNN** Algorithmus trainiert, welcher eine Genauigkeit von 97,8 % aufwies. Dieser wurde anschließend auf die Daten des Validierungsversuch angewendet. Der Validierungsversuch wurde im Vergleich zum Trainingsversuch mit anderen variierten Prozessparametern oder verschiedenen Prozessparameterstufen gefertigt wurde. Der Validierungsversuch stellt einen Test der Robustheit des ermitteltem Algorithmus dar. An den Proben des Validierungsversuch wurden metallographisch die Porositäten ermittelt. Die Verläufe der Porositäten über die Proben wurde von den Indikationen

richtig wiedergegeben. Allerdings wurde die Höhe der Porositätsänderungen von dem Algorithmus nicht richtig erfasst. Somit ermöglicht der entwickelte Algorithmus eine qualitative und keine quantitative Erfassung von Prozessstörungen.

Des Weiteren wurden die Signalcharakteristika der beiden Photodioden ADC1 und ADC2 über den Drehwinkel γ und den Bauraum untersucht. Es fiel auf, dass σ_{ADC2} einen sinusförmigen Verlauf über den Drehwinkel aufweist. Mit diesen Verläufen eines Versuchs mit 45 Proben auf der Bauplattform wurden Funktionen bestimmt, an welchen anschließend die Maxima ermittelt wurden. Der Wert bei dem σ_{ADC2} maximal ist steht für den Drehwinkel, bei der die Defokussierung durch den Schmauch maximal ist. Dies ist der Fall, wenn der Laser in Richtung des Schutzgases schweift. Somit sind die so bestimmten Drehwinkel ein Maß für die Richtung des Schutzgases. Des Weiteren wurde die Güte der gefitteten Funktion mit dem **RMSE**-Wert bestimmt, da dies ein Maß für Turbulenzen in der Schutzgasströmung sein könnte. Die **RMSE**-Werte wurden über den Bauraum interpoliert und es fiel auf, dass in Randbereichen der Bauplattform höhere **RMSE**-Werte auftreten. Dies kann durch Ablösevorgänge der Schutzgasströmung in diesem Bereichen, welche zu Turbulenzen führen, begründet werden.

9 Ausblick

In diesem Kapitel wird ein Ausblick gegeben wie das vorgestellte Konzept verbessert werden kann. Zudem erfolgt die Darstellung eines auf der Ausheilung von Defekten basierenden Regelungskonzeptes.

9.1 Verbesserungen des Vorgehens

Da die Separierung der Messdaten der Proben in einzelne Pixel eine große Einschränkung in der Genauigkeit mit welcher Prozesstörungen detektiert werden können darstellt sollte zukünftig ein anderes Vorgehen gewählt werden. Für die Segmentierung von Zeitreihendaten, welche die Photodioden erzeugen, gibt es etablierte Methoden. Diese sind zum Beispiel das Top-Down, das Bottom-Up oder das SWAB Verfahren. (LOVRIC et al. 2014) Durch diese Methoden wird eine bessere Aufteilung der Messpunkte in einzelne Abschnitte basierend auf Informationen in den Daten ermöglicht. Hierfür müssen allerdings einzelne Scanvektoren betrachtet werden und nicht mehrere nebeneinander liegende Scanvektoren, wie es bei den Pixeln der Fall war. Die Betrachtung einzelner Scanvektoren ermöglicht zudem das extrahieren zusätzlicher Feature aus dem Zeitfrequenzbereich. Beispiele hierfür sind die Fourier oder die Wavelet Koeffizienten. Es wird vermutet das der Zeitfrequenzbereich noch viel Information enthält welche von statistischen Features nicht erfasst wird. (Z. ZHANG et al. 2015) Ein MATLAB Framework für die Extraktion von Zeitreihenfeature ist in FULCHER et al. (2013) gegeben. Das Framework heißt Highly Comparative Time-Series Analysis ([HCTSA](#)) und ermöglicht die Berechnung von über 7000 Feature aus dem Zeitfrequenzbereich. Ein Vergleichbares Framework mit 1200 Feature ist das in Python implementierte [tsfresh](#). (TSFRESH 2018) Sowohl [HCTSA](#) als auch [tsfresh](#) bieten Möglichkeiten zur Eliminierung irrelevanter Feature. Im Allgemeinen kann bei einer so hohen Fetureanzahl die Rechenzeit bei der Feature Auswahl und beim Trainieren der Algorithmen zu einem Problem werden. Zudem sollte die Anzahl an Proben sowie der gefertigten Prozessparameterstufen und

der variierten Prozessparameter erhöht werden. Hier ist ein vollfaktorieller Versuchsplan mit Replika anzustreben. Insgesamt sollte jeder mögliche Prozesszustand erfasst und die Messungenauigkeit der Dichtemessung statistisch abgesichert werden. Hierfür kann es auch notwendig sein überhängenden Strukturen zu bauen, welche einen anderen Wärmeleitungs- und Prozesszustand darstellen. Des Weiteren kann das Clustering Ergebnis durch eine Anwendung mehrerer Algorithmen verbessert werden. Dabei wird die Varianz der einzelnen Algorithmen gemindert. Hierbei können zum Beispiel mehrere Clusteringalgorithmen berechnet werden und mit der Korrelationsmetrik wird jeder Datenpunkt nach dem Ergebnis jedes Algorithmus als Prozessstörung oder regulären Prozess gelabelt. Anschließend wird ein Grenzwert gesetzt wie viele Label Prozessstörung angeben müssen, damit der Datenpunkt als Prozessstörung klassifiziert wird. So kann auch die Sensitivität der Detektion angepasst werden. Mögliche für große Datenmengen geeignete Algorithmen sind zum Beispiel [BIRCH](#), [CURE](#) und [k-Medoid](#). (DAVE & GIANEY 2016) Anschließend sollte ein Klassifikationsalgorithmus der möglichst komplexe Zusammenhänge erfassen kann, darauf trainiert werden. Dies kann zum Beispiel ein neuronales Netz sein. Neuronale Netze bieten zudem den Vorteil einer guten Parallelisierbarkeit, weshalb diese auf der [GPU](#) anstatt auf der [CPU](#) berechnet werden können. So kann die Rechenzeit deutlich reduziert werden, da auf der [GPU](#) mehrere tausend Rechnungen parallel abgearbeitet werden können.

Des Weiteren können auch andere Qualitätsmerkmale als die Porosität, wie zum Beispiel die Zugfestigkeit, das Elastizitätsmodul oder die Vickershärte, herangezogen werden um die Cluster auszuwählen. Dadurch ist es möglich auch andere Inhomogenitäten, die zu einer Änderung dieser Qualitätsmerkmale führen, wie zum Beispiel Gefügeänderungen, zu detektiert.

Nach der Entwicklung eines Algorithmus mit dem vorgestellten Konzept sollte dieser validiert werden. Dafür bietet die Computertomographie die Möglichkeit Indikationen mit den Defekten zu überlagern und so lokal festzustellen ob ein Defekt erkannt wurde. Des Weiteren bietet die Berechnung der Auffindwahrscheinlichkeit (englisch Probability of Detection [POD](#)) die Möglichkeit das Messsystem und die Algorithmen, für Anwendungen in der zerstörungsfreien Prüfung zu qualifizieren. (BAMBERGER et al. 2016)

9.2 Vorstellung eines auf Ausheilung basierendes Regelungskonzeptes

Das Problem bisheriger Regelungskonzepte beim Laserstrahlschmelzen ist die zu geringe Mess- und Verarbeitungsfrequenz des Messsystems. Dadurch kann auf die kurzzeitig und zufällig im Prozess auftretenden Abweichungen nicht reagiert werden. Hierbei bietet das Prozesscharakteristikum des Ausheilens die Möglichkeit trotzdem diese durch den Prozesstörungen verursachten Defekte zu mindern. Das Auheilung von Defekten erfolgt durch das Wierderaufschmelzen des Materials in der den darauffolgenden Schichten. (YASA & J. KRUTH 2011)

Der Ablauf des Regelungskonzeptes wird im Folgenden erklärt und ist in Abbildung 9.1 dargestellt. Zuerst werden in einer Schicht n Prozesstörungen durch das Messsystem

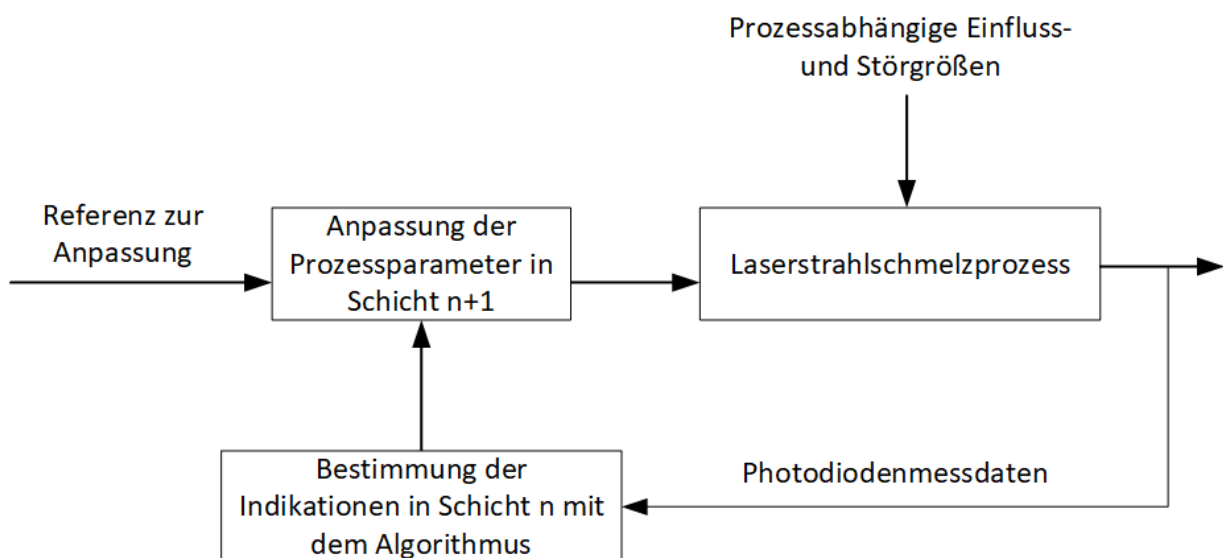


Abbildung 9.1: Vorschlag für ein auf der Ausheilung von Defekten basierendes Regelungskonzept

und den Algorithmus detektiert. In der darauffolgenden Schicht n+1 wird mit einer Änderung der Prozessparameter, an der Stelle auf der Bauplatzform an der Prozesstörungen oder Indikationen in Schicht n detektiert wurden, reagiert, um die Ausheilung der Defekte zu verbessern. Mögliche Prozessparameteränderungen sind eine Erhöhung der Laserleistung eine Reduzierung der Scangeschwindigkeit oder eine Änderung der Belichtungsstrategie. Während mit der Laserleistung und der Scangeschwindigkeit der Energieeintrag in das Bauteil erhöht wird, um eine bessere Schichtenanbindung zu erreichen, zielt eine Änderung der Belichtungsstrategie auf eine erneutes Aufschmelzen ohne einen weiteren Pulverauftrag ab. Dies kann nur an den Stellen der Indikationen

erfolgen, wodurch allerdings Eigenspannungen induziert werden welche zu Verzug führen, oder für die gesamte Schicht. Nach YASA & J. KRUTH (2011) führt eine erneute Belichtung einer Schicht ohne erneuten Pulverauftrag zu höheren Dichten und geringeren Oberflächenrauheiten. Ein weiterer Vorteil dieses Vorgehens sind die geringeren Echtzeitanforderungen an das System im Vergleich zu den meisten anderen Regelungskonzepten, da für die Berechnung der Indikationen die Belichtungs- und Beschichtungszeit einer Schicht zu Verfügung steht.

Literatur

ABOULKHAIR et al. 2014

Aboulkhair, N. T.; N. M. Everitt; I. Ashcroft; C. Tuck: „Reducing porosity in AlSi10Mg parts processed by selective laser melting“. *Additive Manufacturing* (2014), S. 77–86. ISSN: 22148604. DOI: 10.1016/j.addma.2014.08.001.

ACKERL et al. 2015

Ackerl, C.; R. Gangl; J. Gumbinger; W. Wöber; T. Grünberger: „Entwicklung eines Qualitätssicherungssystems für das Metall-3D-Drucken“. 2015. URL: <http://ffhoarep.fh-ooe.at/bitstream/123456789/355/1/FFH2015-TII3-1.pdf> (besucht am 08.06.2018).

AGGARWAL 2015

Aggarwal, C. C.: *Data Mining. The Textbook*. 2015. ISBN: 9783319141428. URL: <http://dx.doi.org/10.1007/978-3-319-14142-8>.

AGGARWAL & REDDY 2014

Aggarwal, C. C.; C. K. Reddy: *Data Clustering. Algorithms and Applications*. New York: CRC Press Taylor and Francis Group. 2014. ISBN: 9781466558212.

AKSOY & HARALICK 2000

Aksoy, S.; R. M. Haralick: „Feature Normalization and Likelihood-based Similarity Measures for Image Retrieval“. *Pattern Recognit. Lett., Special Issue on Image and Video Retrieval* (2000).

ALBERTS et al. 2017

Alberts, D.; D. Schwarze; G. Witt: „In situ melt pool monitoring and the correlation to part density of inconel® 718 for quality assurance in selective laser melting“. *Solid Freeform Fabrication 2017: Proceedings of the 28th Annual International* (2017), S. 1481–1495.

ALBERTS et al. 2016

Alberts, D.; D. Schwarze; G. Witt: „High speed melt pool & laser power monitoring for selective laser melting (SLM®)“. *9th International Conference on Photonic Technologies LANE 2016*. (2016).

ALDRICH 1995

Aldrich, J.: „Correlation Genuine and Spurious in Pearson and Yule“. *Statistical Science* (1995) (10), S. 364–376.

ALPAYDIN 2010

Alpaydin, E.: *Introduction to machine learning*. eng. 2nd ed. Adaptive computation and machine learning. Cambridge, Mass: MIT Press. 2010. 537 S. ISBN: 9780262012430. URL: <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=307676>.

AMINZADEH 2016

Aminzadeh, M.: „A machine vision system for in-situ quality inspection in metal powder-bed additive manufacturing“. School of Mechanical Engineering. Dissertation. Georgia Institute of Technology. 2016.

ANWAR & PHAM 2017

Anwar, A. B.; Q.-C. Pham: „Selective laser melting of AlSi10Mg. Effects of scan direction, part placement and inert gas flow velocity on tensile strength“. *Journal of Materials Processing Technology* 240 (2017), S. 388–396. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2016.10.015.

ATTARAN 2017

Attaran, M.: „The rise of 3-D printing. The advantages of additive manufacturing over traditional manufacturing“. *Business Horizons* (2017) (5), S. 677–688. ISSN: 00076813.

AVERYANOVA et al. 2012

Averyanova, M.; E. Cicala; P. Bertrand; D. Grevey: „Experimental design approach to optimize selective laser melting of martensitic 17–4 PH powder. Part I – single laser tracks and first layer“. *Rapid Prototyping Journal* (2012) (1), S. 28–37. ISSN: 1355-2546. DOI: 10.1108/13552541211193476.

BAMBERGER et al. 2016

Bamberger, J.; G. Zenzinger; A. Ladewig: „In-Process Control of Selective Laser Melting

by Quantitative Optical Tomography“. *19th World Conference on Non-Destructive Testing* (2016).

BAYERLEIN & ZÄH 2016

Bayerlein, F.; M. F. Zäh: „Schlussbericht zu dem IGF-Vorhaben 17.911 N. Qualitätssicherung beim Laserstrahlschmelzen von metallischen Bauteilen durch thermographische Schichtüberwachung“. Institut für Werkzeugmaschinen und Betriebswissenschaften. München: Technische Universität München. 2016.

BERGER et al. 1993

Berger, J.; S. Fienberg; J. Gani; K. Krickeberg; I. Olkin; B. Singer; P. Spirtes; C. Glymour; R. Scheines: *Causation, Prediction, and Search*. Bd. 81. New York, NY: Springer New York. 1993. 568 S. ISBN: 978-1-4612-7650-0. DOI: 10.1007/978-1-4612-2748-9.

BISHOP 2010

Bishop, C. M.: *Pattern Recognition and Machine Learning*. 8. Aufl. Information science and statistics. New York NY: Springer. 2010. ISBN: 978-0-387-31073-2.

CALIGNANO et al. 2018

Calignano, F.; G. Cattano; D. Manfredi: „Manufacturing of thin wall structures in Al-Si10Mg alloy by laser powder bed fusion through process parameters“. *Journal of Materials Processing Technology* (2018), S. 773–783. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2018.01.029.

CLIJSTERS et al. 2014

Clijsters, S.; T. Craeghs; S. Buls; K. Kempen; J.-P. Kruth: „In situ quality control of the selective laser melting process using a high-speed, real-time melt pool monitoring system“. *The International Journal of Advanced Manufacturing Technology* (2014) (5-8), S. 1089–1101. ISSN: 0268-3768. DOI: 10.1007/s00170-014-6214-8.

CRAEGHS, BECHMANN et al. 2010

Craeghs, T.; F. Bechmann; S. Berumen; J.-P. Kruth: „Feedback control of Layerwise Laser Melting using optical sensors“. *Physics Procedia* 5 (2010), S. 505–514. ISSN: 18753892. DOI: 10.1016/j.phpro.2010.08.078.

CRAEGHS, CLIJISTER et al. 2011

Craeghs, T.; S. Clijster; E. Yasa; J. P. Kruth: „Online Quality Control of Selective Laser Melting“. *Proceedings of the 20th Solid Freeform Fabrication (SFF) symposium, Austin (Texas)* (2011), S. 212–226.

CROUX & DEHON 2010

Croux, C.; C. Dehon: „Influence functions of the Spearman and Kendall correlation measures“. *Statistical Methods and Applications* (2010) (19), S. 497–515.

DALGIC 2009

Dalgic, M.: *Zusammenhang zwischen der Porenmorphologie und der Schwingfestigkeit von Sinterstahl und Sintereisen*. Zugl.: Aachen, Techn. Hochsch., Diss., 2009. ger. Berichte aus der Werkstofftechnik. Aachen: Shaker. 2009. 210 S. ISBN: 9783832285753.

DAVE & GIANEY 2016

Dave, M.; H. Gianey: „Different clustering algorithms for Big Data analytics. A review“. *International Conference System Modeling & Advancement in Research Trends (SMART)* (2016), S. 328–333. DOI: 10.1109/SYSMART.2016.7894544.

DAVIES & BOULDIN 1979

Davies, D. L.; D. W. Bouldin: „A Cluster Separation Measure“. *IEEE Transactions on Pattern Analysis and Machine Intelligence PAMI-1* (1979) (2), S. 224–227. ISSN: 0162-8828. DOI: 10.1109/TPAMI.1979.4766909.

DIETRICH 2009

Dietrich, S.: „Sensoriken zur Schwerpunktslagebestimmung der optischen Prozessemissionen beim Laserstrahl-tiefschweißen“. Dissertation. Friedrich-Alexander-Universität Nürnberg. 2009.

DIETRICH 2018

Dietrich, S.: *Gespräch*. Augsburg 24.05.2018.

DIMTER et al. 2007

Schutzrecht: DE 102007014683A1. EOS GmbH Electro Optical Systems. 2007. Dimter, M.; L. Hümmeler; J. Kotila; R. Mayer; R. Salzberger; T. Syvänen: „Verfahren und Vorrichtung zum Herstellen eines dreidimensionalen Objekts“.

DIN 8050

DIN, Hrsg. (2003): *DIN 8050 Fertigungsverfahren - Begriffe, Einteilung*. Berlin: Beuth.

DIN IEC 60050-351

DIN, Hrsg. (2014): *International electrotechnical vocabulary - Part 351: Control technology (IEC 60050-351:2013)*. Berlin: Beuth.

DOMRÖSE et al. 2013

Schutzrecht: EP 2978589A1. EOS GmbH Electro Optical Systems, MTU Aero Engines AG. 2013. DOMRÖSE, R. A.; M. Frey; A. Schilling; A. Danzig; J. Hamann; T. Hess; M. Dimter: „Verfahren und Vorrichtung zum Herstellen eines dreidimensionalen Objekts“.

DONOVAN 1994

Donovan, S.: „Patent, copyright and trade secret protection for software“. *IEEE Potentials* (1994) (3), S. 20–24. ISSN: 0278-6648. DOI: 10.1109/45.310923.

EID et al. 2015

Eid, M.; M. Gollwitzer; M. Schmitt: *Statistik und Forschungsmethoden*. Weinheim & Basel: Beltz. 2015. ISBN: 9783621282017. URL: http://sub-hh.ciando.com/book/?bok_id=1995502.

ELKI 2018

ELKI Wiki: Liste der enthaltenen Data-Mining Algorithmen (2018). URL: <https://elki-project.github.io/algorithms/> (besucht am 09.06.2018).

ELMESALAMY 2013

Elmesalamy, A. S. E.: „Narrow Gap Laser Welding of 316L Stainless Steel for Potential Application in the Manufacture of Thick Section Nuclear Components“. School of Mechanical, Aerospace and Civil Engineering. Dissertation. Manchester: University of Manchester. 2013. 348 S.

EOS 2016

EOS: *EOSTATE MeltPool Analysis Toolbox Software*.

ESTER et al. 1996

Ester, M.; H.-P. Kriegel; J. Sander; X. Xu: „A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise“. In *Proc. 2nd Int. Conf. on Knowledge Discovery and Data Mining (KDD '96)* (1996).

EVERTON et al. 2016

Everton, S. K.; M. Hirsch; P. Stravroulakis; R. K. Leach; A. T. Clare: „Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing“. *Materials & Design* (2016), S. 431–445. ISSN: 02641275. DOI: 10.1016/j.matdes.2016.01.099.

FAHRMEIR et al. 2016

Fahrmeir, L.; C. Heumann; R. Künstler; I. Pigeot; G. Tutz: *Statistik. Der Weg zur Datenanalyse*. Springer-Lehrbuch. Berlin & Heidelberg: Springer Spektrum. 2016. ISBN:

9783662503713. DOI: 10.1007/978-3-662-50372-0. URL: <http://dx.doi.org/10.1007/978-3-662-50372-0>.

FERRAR et al. 2012

Ferrar, B.; L. Mullen; E. Jones; R. Stamp; C. J. Sutcliffe: „Gas flow effects on selective laser melting (SLM) manufacturing performance“. *Journal of Materials Processing Technology* 212 (2012) (2), S. 355–364. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2011.09.020.

FOX et al. 2016

Fox, J.; F. Lopez; B. Lane; H. Yeung; S. Grantham: „On The Requirements For Model-Based Thermal Control Of Melt Pool Geometry In Laser Powder Bed Fusion Additive Manufacturing“. *Measurement Science and Technology Conference* (2016).

FULCHER et al. 2013

Fulcher, B. D.; M. A. Little; N. S. Jones: „Highly comparative time-series analysis. The empirical structure of time series and their methods“. eng. *Journal of the Royal Society, Interface* 10 (2013) (83), S. 20130048. ISSN: 1742-5662. DOI: 10.1098/rsif.2013.0048. eprint: 23554344.

GALY et al. 2018

Galy, C.; E. Le Guen; E. Lacoste; C. Arvieu: „Main defects observed in aluminum alloy parts produced by SLM. From causes to consequences“. *Additive Manufacturing* (2018). ISSN: 22148604. DOI: 10.1016/j.addma.2018.05.005.

GEBHARDT 2013

Gebhardt, A.: *Generative Fertigungsverfahren. Additive Manufacturing und 3D Drucken für Prototyping ; Tooling ; Produktion*. München: Carl Hanser Fachbuchverlag. 2013. ISBN: 978-3-446-43651-0.

GEBHARDT 2014

Gebhardt, A.: *3D-Drucken. Grundlagen und Anwendungen des Additive Manufacturing (AM)*. München: Carl Hanser Fachbuchverlag. 2014. ISBN: 9783446442382. DOI: 10.3139/9783446442375. URL: <http://dx.doi.org/10.3139/9783446442375>.

GIBBONS & CHAKRABORTI 2003

Gibbons, J. D.; S. Chakraborti: *Nonparametric statistical inference*. Statistics, textbooks and monographs. New York: Marcel Dekker. 2003. ISBN: 0824740521.

GOBERT et al. 2018

Gobert, C.; E. W. Reutzler; J. Petrich; A. R. Nassar; S. Phoha: „Application of supervised

machine learning for defect detection during metallic powder bed fusion additive manufacturing using high resolution imaging". *Additive Manufacturing* 21 (2018), S. 517–528. ISSN: 22148604. DOI: 10.1016/j.addma.2018.04.005.

GRASSO & COLOSIMO 2017

Grasso, M.; B. M. Colosimo: „Process defects and in situ monitoring methods in metal powder bed fusion. A review". *Measurement Science and Technology* 28 (2017) (4), S. 044005. ISSN: 0957-0233. DOI: 10.1088/1361-6501/aa5c4f.

GRÜNBERGER & DOMRÖSE 2014

Grünberger, T.; R. Domröse: „Optical In-Process Monitoring of Direct Metal Laser Sintering (DMLS)". *Laser Technik Journal* 11 (2014) (2), S. 40–42. ISSN: 16137728. DOI: 10.1002/latj.201400026.

GRÜNBERGER & DOMRÖSE 2015

Grünberger, T.; R. Domröse: „Direct Metal Laser Sintering". *Laser Technik Journal* (2015) (1), S. 45–48. ISSN: 16137728. DOI: 10.1002/latj.201500007.

GU & SHEN 2008

Gu, D.; Y. Shen: „Processing conditions and microstructural features of porous 316L stainless steel components by DMLS". *Applied Surface Science* (2008) (5), S. 1880–1887. ISSN: 01694332. DOI: 10.1016/j.apsusc.2008.06.118.

GU & SHEN 2009

Gu, D.; Y. Shen: „Balling phenomena in direct laser sintering of stainless steel powder. Metallurgical mechanisms and control methods". *Materials & Design* (2009) (8), S. 2903–2910. ISSN: 02641275. DOI: 10.1016/j.matdes.2009.01.013.

HALL 1999

Hall, M. A.: „Correlation-based Feature Selection for Machine Learning". Dissertation. University of Waikato. 1999. 198 S.

HANZL et al. 2015

Hanzl, P.; M. Zetek; T. Bakša; T. Kroupa: „The Influence of Processing Parameters on the Mechanical Properties of SLM Parts". *Procedia Engineering* 100 (2015), S. 1405–1413. ISSN: 18777058. DOI: 10.1016/j.proeng.2015.01.510.

HASTIE et al. 2009

Hastie, T.; R. Tibshirani; J. Friedman: *The Elements of Statistical Learning*. New York, NY: Springer New York. 2009. 764 S. ISBN: 978-0-387-84857-0. DOI: 10.1007/b94608.

HEATH 1897

Heath, T. L.: „The Works of Archimedes. Edited in a modern notation with introductory chapters“. Cambridge. 1897. URL: http://www.wilbourhall.org/pdfs/archimedes/The_Works_of_Archimedes.pdf.

HESS 2015

Heß, T.: „Beitrag zur Qualifizierung des pulverbettbasierten Laserstrahlschmelzens zur Serienfertigung am Beispiel der Triebwerksindustrie“. Dissertation. Karlsruhe: Karlsruher Institut für Technologie. 2015.

HILL 2004

Hill, S. A. B.: „The Environment and Disease: Association or Causation?“ *Chemotherapy* 9 (2004) (4-5), S. 196–202. ISSN: 0009-3157. DOI: 10.1159/000220363.

JAMES 2013

James, G.: *An introduction to statistical learning. With applications in R*. Bd. 103. Springer texts in statistics. New York NY: Springer. 2013. ISBN: 978-1-4614-7138-7.

JUNFENG & ZHENGYING 2017

Junfeng, L.; W. Zhengying: „Process Optimization and Microstructure Characterization of Ti6Al4V Manufactured by Selective Laser Melting“. *IOP Conference Series: Materials Science and Engineering* (2017). ISSN: 1757-8981. DOI: 10.1088/1757-899X/269/1/012026.

KEMPEN, THIJS, VAN HUMBEECK et al. 2012

Kempen, K.; L. Thijs; J. van Humbeeck; J.-P. Kruth: „Mechanical Properties of AlSi10Mg Produced by Selective Laser Melting“. *Physics Procedia* (2012), S. 439–446. ISSN: 18753892. DOI: 10.1016/j.phpro.2012.10.059.

KEMPEN, THIJS, YASA et al. 2011

Kempen, K.; L. Thijs; E. Yasa; M. Badrossamay: „Process Optimization and Microstructural Analysis for Selective Laser Melting of AlSi10Mg“. *Conference: Solid Freeform Fabrication Symposium, At Texas, USA, Volume: 22* (2011).

KHANZADEH et al. 2018

Khanzadeh, M.; S. Chowdhury; M. Marufuzzaman; M. A. Tschopp; L. Bian: „Porosity prediction. Supervised-learning of thermal history for direct laser deposition“. *Journal of Manufacturing Systems* (2018), S. 69–82. ISSN: 02786125. DOI: 10.1016/j.jmsy.2018.04.001.

KING et al. 2014

King, W. E.; H. D. Barth; V. M. Castillo; G. F. Gallegos; J. W. Gibbs; D. E. Hahn; C. Kamath; A. M. Rubenchik: „Observation of keyhole-mode laser melting in laser powder-bed fusion additive manufacturing“. *Journal of Materials Processing Technology* (2014) (12), S. 2915–2925. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2014.06.005.

KLEPPMANN 2010

Kleppmann, W.: *Versuchsplanung. Produkte und Prozesse optimieren*. Praxisreihe Qualitätswissen. München: Carl Hanser Fachbuchverlag. 2010. ISBN: 9783446422414. URL: <http://www.hanser-elibrary.com/action/showBook?doi=10.3139/9783446424197>.

KLESZCZYNSKI, LADEWIG et al. 2015

Kleszczynski, S.; A. Ladewig; K. Friedberger; J. zur Jacobsmühlen; D. Merhof; G. Witt: „Position Dependency of Surface Roughness in Parts from Laser Beam Melting Systems“. *Conference: Proceedings of the 26th International Solid Free Form Fabrication (SFF) Symposium* (2015), S. 360–370. DOI: 10.1002/0471741833.ch1.

KLESZCZYNSKI, ZUR JACOBSMÜHLEN et al. 2012

Kleszczynski, S.; J. zur Jacobsmühlen; G. Witt: „Error detection in laser beam melting systems by high resolution imaging“. *23rd Annual International Solid Freeform Fabrication Symposium - An Additive Manufacturing Conference, SFF* (2012).

KNUTH 2006

Knuth, D. E.: *The TeXbook*. eng. [Repr.] Bd. / Donald Ervin Knuth. American Mathematical Society ; A. Computers and typesetting. Reading, Mass.: Addison Wesley. 2006. 483 S. ISBN: 9780201134483.

KRAUSS 2016

Krauss, H.: „Qualitätssicherung beim Laserstrahlschmelzen durch schichtweise thermografische In-Process-Überwachung“. Dissertation. Technische Universität München. 2016.

KRAUSS et al. 2011

Krauss, H.; C. Eschey; A. Götzfried; S. Teufelhart; S. Westhäuser; M. F. Zäh; G. Reinhart: „Modellgestützte und hierarchische Prozesskettenbetrachtung für die additive Fertigung“. *RTejournal - Forum für Rapid Technologie* (2011) (8).

KROLL 2016

Kroll, A.: *Computational Intelligence. Probleme, Methoden und technische Anwendungen*. De Gruyter Studium. Berlin & Boston: De Gruyter Oldenbourg. 2016. ISBN: 9783110400663. DOI: 10.1515/9783110401776. URL: <http://dx.doi.org/10.1515/9783110401776>.

J. P. KRUTH et al. 2005

Kruth, J. P.; P. Mercelis; J. Van Vaerenbergh; L. Froyen; M. Rombouts: „Binding mechanisms in selective laser sintering and selective laser melting“. *Rapid Prototyping Journal* (2005) (1), S. 26–36. ISSN: 1355-2546. DOI: 10.1108/13552540510573365.

KÜHLKE 2011

Kühlke, D.: *Optik. Grundlagen und Anwendungen ; mit Tabellen, Beispielen und Aufgaben mit Lösungen*. Frankfurt am Main: Deutsch. 2011. ISBN: 978-3-8171-1878-6.

L'HEUREUX et al. 2017

L'Heureux, A.; K. Grolinger; H. F. Elyamany; M. A. M. Capretz: „Machine Learning With Big Data. Challenges and Approaches“. *IEEE Access* (2017), S. 7776–7797. ISSN: 2169-3536. DOI: 10.1109/ACCESS.2017.2696365.

LADEWIG et al. 2016

Ladewig, A.; G. Schlick; M. Fisser; V. Schulze; U. Glatzel: „Influence of the shielding gas flow on the removal of process by-products in the selective laser melting process“. *Additive Manufacturing* 10 (2016), S. 1–9. ISSN: 22148604. DOI: 10.1016/j.addma.2016.01.004.

Y. LI & GU 2014

Li, Y.; D. Gu: „Parametric analysis of thermal behavior during selective laser melting additive manufacturing of aluminum alloy powder“. *Materials & Design* (2014), S. 856–867. ISSN: 02641275. DOI: 10.1016/j.matdes.2014.07.006.

Z. LI et al. 2018

Li, Z.; R. Xu; Z. Zhang; I. Kucukkoc: „The influence of scan length on fabricating thin-walled components in selective laser melting“. *International Journal of Machine Tools and Manufacture* 126 (2018), S. 1–12. ISSN: 08906955. DOI: 10.1016/j.ijmactools.2017.11.012.

LOUVIS et al. 2011

Louvis, E.; P. Fox; C. J. Sutcliffe: „Selective laser melting of aluminium components“.

Journal of Materials Processing Technology 211 (2011) (2), S. 275–284. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2010.09.019.

LOVRIC et al. 2014

Lovric, M.; M. Milanovic; M. Stamenkovic: „Algorithmic Methods for Segmentation of Time Series: an Overview“. *Journal of Contemporary Economic and Business Issues* (2014) (1), S. 31–53.

MANCISIDOR et al. 2016

Mancisidor, A. M.; F. Garcíandia; M. S. Sebastian; P. Álvarez; J. Díaz; I. Unanue: „Reduction of the Residual Porosity in Parts Manufactured by Selective Laser Melting Using Skywriting and High Focus Offset Strategies“. *Physics Procedia* 83 (2016), S. 864–873. ISSN: 18753892. DOI: 10.1016/j.phpro.2016.08.090.

MASOOMI et al. 2017

Masoomi, M.; S. M. Thompson; N. Shamsaei: „Quality part production via multi-laser additive manufacturing“. *Manufacturing Letters* 13 (2017), S. 15–20. ISSN: 22138463. DOI: 10.1016/j.mfglet.2017.05.003.

MEINERS 1999

Meiners, W.: *Direktes selektives Laser Sintern einkomponentiger metallischer Werkstoffe*. Zugl.: Aachen, Techn. Hochsch., Diss., 1999. ger. Berichte aus der Lasertechnik. Aachen: Shaker. 1999. ISBN: 3826565711.

MESCHEDE 2008

Meschede, D.: *Optik, Licht und Laser*. 3., durchgesehene Auflage. Wiesbaden: Vieweg+Teubner Verlag / GWV Fachverlage GmbH Wiesbaden. 2008. ISBN: 9783834892881. URL: <http://dx.doi.org/10.1007/978-3-8348-9288-1>.

MITCHELL 1997

Mitchell, T. M.: *Machine Learning*. McGraw-Hill series in computer science. New York: McGraw-Hill. 1997. ISBN: 0070428077.

NORMAN et al. 2007

Norman, P.; H. Engström; A. F. H. Kaplan: „State of the art of monitoring and imaging of laser welding defects“. *11th NOLAMP Conference in Laser Processing of Materials* (2007), S. 20–33.

OLAKANMI et al. 2011

Olakanmi, E. O.; R. F. Cochrane; K. W. Dalgarno: „Densification mechanism and mi-

crostructural evolution in selective laser sintering of Al–12Si powders“. *Journal of Materials Processing Technology* (2011) (1), S. 113–121. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2010.09.003.

PAPADIMITRIOU 2005

Papadimitriou, C. H.: *Computational complexity*. Reading, Mass.: Addison-Wesley. 2005. ISBN: 0201530821.

PAWLAK et al. 2017

PAWLAK, A.; M. Rosienkiewicz; E. Chlebus: „Design of experiments approach in AZ31 powder selective laser melting process optimization“. *Archives of Civil and Mechanical Engineering* (2017) (1), S. 9–18. ISSN: 16449665. DOI: 10.1016/j.acme.2016.07.007.

PLANK 1900

Plank, M.: „Zur Theorie des Gesetzes der Energieverteilung im Normalspectrum“. *Verhandlungen der Deutschen Physikalischen Gesellschaft* (1900) (17), S. 237–245.

QUINLAN 1986

Quinlan, J. R.: „Induction of decision trees“. *Machine Learning* (1986) (1), S. 81–106. DOI: 10.1007/BF00116251.

REHME 2010

Rehme, O.: „Cellular Design for Laser Freeform Fabrication“. Institut für Laser- und Anlagensysteme. eng. Dissertation. Göttingen: Technische Universität Hamburg. 2010.

REHME & EMMELMANN 2005

Rehme, O.; C. Emmelmann: „Reproducibility for properties of Selective Laser Melting products“. *Lasers in Manufacturing – WLT Conference* (2005), S. 227–232.

RENKEN et al. 2017

Renken, V.; S. Albinger; G. Goch; A. Neef; C. Emmelmann: „Development of an adaptive, self-learning control concept for an additive manufacturing process“. *CIRP Journal of Manufacturing Science and Technology* (2017). ISSN: 17555817. DOI: 10.1016/j.cirpj.2017.05.002.

REUTZEL & NASSAR 2015

Reutzel, E. W.; A. R. Nassar: „A survey of sensing and control systems for machine and process monitoring of directed-energy, metal-based additive manufacturing“. *Rapid Prototyping Journal* (2015) (2), S. 159–167. ISSN: 1355-2546. DOI: 10.1108/RPJ-12-2014-0177.

RICHTER 2017

Richter, M.: *Expertengespräch*. Augburg 29.11.2017.

ROSENKRANZ et al. 2018

Rosenkranz, C.; S. Schmid; M. Lutter-Günther; C. Seidel; G. Reinhart: „Investigation of the correlation between signal characteristics of photodiode-based melt pool monitoring and part quality in laser-based powder bed fusion of AlSi10Mg“. *akzeptierte Einreichung: MAMC Wien* (2018).

RUNKLER 2010

Runkler, T. A.: *Data Mining. Methoden und Algorithmen intelligenter Datenanalyse*. ger. Computational intelligence. Wiesbaden: Vieweg + Teubner. 2010. 169 S. ISBN: 9783834808585. URL: <http://dx.doi.org/10.1007/978-3-8348-9353-6>.

SACHS 1978

Sachs, L.: *Angewandte Statistik*. Berlin, Heidelberg: Springer Berlin Heidelberg. 1978. 572 S. ISBN: 978-3-540-08813-4. DOI: 10.1007/978-3-662-21613-2.

SCHEWZOW 2018

Schewzow, W.: „Untersuchung der vorhersagbarkeit von Prozessparametervariationen beim Laserstrahlschmelzen anhand photodiodenbasierter Datensignale einer Schmelzbadüberwachung“. Bachelorarbeit. 2018.

SCHLEIFENBAUM 2012

Schleifenbaum, J. H.: „Maschinen- und Verfahrensentwicklung zum High Power Selective Laser Melting (HP SLM) für die Individualisierte Produktion“. Fakultät für Maschinenwesen. Dissertation. Aachen: Rheinisch-Westfälische Technische Hochschule. 2012.

SCHUBERT et al. 2015

Schubert, E.; A. Koos; T. Emrich; A. Züfle; K. A. Schmid; A. Zimek: „A framework for clustering uncertain data“. *Proceedings of the VLDB Endowment* (2015) (12), S. 1976–1979. ISSN: 21508097. DOI: 10.14778/2824032.2824115.

SCHUMANN & OETTEL 2004

Schumann, H.; H. Oettel: *Metallografie*. 14. Aufl. John Wiley & Sons. 2004. 800 s. ISBN: 352730679X.

SEHRT 2010

Sehrt, J. T.: „Möglichkeiten und Grenzen bei der generativen Herstellung metallischer

Bauteile durch das Strahlschmelzverfahren“. Abteilung Maschinenbau und Verfahrenstechnik. Dissertation. Duisburg-Essen: Universität Duisburg-Essen. 2010. 171 S.

SEIBT 2010

Seibt, P.: *Algorithmic information theory. Mathematics of digital information processing*. Signals and Communication Technology. Berlin & Heidelberg: Springer Verlag. 2010. VI, 442 s. ISBN: 3540332197.

SIEBERTZ et al. 2017

Siebertz, K.; D. van Bebber; T. Hochkirchen: *Statistische Versuchsplanung*. Berlin, Heidelberg: Springer Berlin Heidelberg. 2017. 518 S. ISBN: 978-3-662-55742-6. DOI: 10.1007/978-3-662-55743-3.

SIMONELLI et al. 2015

Simonelli, M.; C. Tuck; N. T. Aboulkhair; I. Maskery; I. Ashcroft; R. D. Wildman; R. Hague: „A Study on the Laser Spatter and the Oxidation Reactions During Selective Laser Melting of 316L Stainless Steel, Al-Si10-Mg, and Ti-6Al-4V“. *Metallurgical and Materials Transactions A* 46 (2015) (9), S. 3842–3851. ISSN: 1073-5623. DOI: 10.1007/s11661-015-2882-8.

SLM 2018

SLM Solutions Group AG. URL: https://slm-solutions.de/sites/default/files/downloads/130de171015-01-002-slm125_web.pdf (besucht am 27.05.2018).

SLM2 2018

SLM Solutions Group AG. URL: https://slm-solutions.de/sites/default/files/downloads/201en171023-01-001-powder_web.pdf (besucht am 29.05.2018).

SOOD et al. 2012

Sood, A. K.; R. K. Ohdar; S. S. Mahapatra: „Experimental investigation and empirical modelling of FDM process for compressive strength improvement“. *Journal of Advanced Research* (2012) (1), S. 81–90. ISSN: 20901232. DOI: 10.1016/j.jare.2011.05.001.

SPEARS & GOLD 2016

Spears, T. G.; S. A. Gold: „In-process sensing in selective laser melting (SLM) additive manufacturing“. *Integrating Materials and Manufacturing Innovation* (2016), S. 683–708.

SPIERINGS & LEVY 2009

Spierings, A. B.; G. Levy: „Comparison of density of stainless steel 316L parts produced with selective laser melting using different powder grades“. *Solid freeform fabrication proceedings* (2009), S. 342–353.

SPIERINGS, SCHNEIDER et al. 2011

Spierings, A. B.; M. Schneider; R. Eggenberger: „Comparison of density measurement techniques for additive manufactured metallic parts“. *Rapid Prototyping Journal* (2011) (5), S. 380–386. ISSN: 1355-2546. DOI: 10.1108/135525411111156504.

STEEN & MAZUMDER 2010

Steen, W. M.; J. Mazumder: *Laser material processing*. London: Springer International Publishing. 2010. ISBN: 9781849960625.

SUTHAHARAN 2016

Suthaharan, S.: *Machine Learning Models and Algorithms for Big Data Classification. Thinking with Examples for Effective Learning*. Springer New York. 2016. 364 S. ISBN: 978-1-4899-7641-3.

TAHERI ANDANI et al. 2017

Taheri Andani, M.; R. Dehghani; M. R. Karamooz-Ravari; R. Mirzaeifar; J. Ni: „Spatter formation in selective laser melting process using multi-laser technology“. *Materials & Design* (2017), S. 460–469. ISSN: 02641275. DOI: 10.1016/j.matdes.2017.06.040.

THE MATHWORKS 2018

The Mathworks: *Statistics and Machine Learning Toolbox™ User's Guide*. URL: https://de.mathworks.com/help/pdf_doc/stats/stats.pdf (besucht am 13.06.2018).

THEODORIDIS & KOUTROUMBAS 2009

Theodoridis, S.; K. Koutroumbas: *Pattern recognition*. Amsterdam: Elsevier/Acad. Press. 2009. ISBN: 9781597492720.

TROSCH et al. 2016

Trosch, T.; J. Strößner; R. Völkl; U. Glatzel: „Microstructure and mechanical properties of selective laser melted Inconel 718 compared to forging and casting“. *Materials Letters* 164 (2016), S. 428–431. DOI: 10.1016/j.matlet.2015.10.136.

TSFRESH 2018

tsfresh. URL: <https://media.readthedocs.org/pdf/tsfresh/latest/tsfresh.pdf> (besucht am 18.08.2018).

VDI-GESELLSCHAFT PRODUKTION UND LOGISTIK 2016

VDI-Gesellschaft Produktion und Logistik: *Additive Fertigungsverfahren. Handlungsfelder*. DOI: 10.3139/9783446445390.fm. URL: https://www.vdi.de/fileadmin/vdi_de/redakteur_dateien/gpl_dateien/6242_PUB_GPL_Handlungsfelder_-_Additive_Fertigungsverfahren_Internet.pdf.

VDI-Richtlinie 3405 Blatt 2

VDI-Richtlinie 3405, Hrsg. (2013): *VDI-Richtlinie 3405 - Additive Fertigungsverfahren Strahlschmelzen metallischer Bauteile Qualifizierung, Qualitätssicherung und Nachbearbeitung*. Richtlinie.

VLASEA et al. 2015

Vlasea, M.; B. M. Lane; F. F. Lopez; S. Mekhontsev; M. A. Donmez: „Development of powder bed fusion additive manufacturing test bed for enhanced real time process control“. *Solid Freeform Fabrication Symposium* (2015).

WEINGARTEN et al. 2015

Weingarten, C.; D. Buchbinder; N. Pirch; W. Meiners; K. Wissenbach; R. Poprawe: „Formation and reduction of hydrogen porosity during selective laser melting of AlSi10Mg“. *Journal of Materials Processing Technology* 221 (2015), S. 112–120. ISSN: 09240136. DOI: 10.1016/j.jmatprotec.2015.02.013.

WIEN 1893

Wien, W.: „Eine neue Beziehung der Strahlung schwarzer Körper zum zweiten Hauptsatz der Wärmetheorie“. *Sitzungsber. preuß. Akad. Wiss. Berlin* (1893) (55), S. 156–165. DOI: 10.1007/978-3-663-13885-3_12.

WITS et al. 2016

Wits, W. W.; S. Carmignato; F. Zanini; T. H. Vaneker: „Porosity testing methods for the quality assessment of selective laser melted parts“. *CIRP Annals* (2016) (1), S. 201–204. ISSN: 00078506. DOI: 10.1016/j.cirp.2016.04.054.

WOHLERS & CAFFREY 2017

Wohlers, T.; T. Caffrey: *Wohlers report. 3D Printing and Additive Manufacturing State of the Industry Annual Worldwide Progress Report*. Fort Collins: Wohlers Associates. 2017.

XIA et al. 2016

Xia, M.; D. Gu; G. Yu; D. Dai; H. Chen; Q. Shi: „Influence of hatch spacing on heat and mass transfer, thermodynamics and laser processability during additive manufacturing

of Inconel 718 alloy". *International Journal of Machine Tools and Manufacture* 109 (2016), S. 147–157. ISSN: 08906955. DOI: 10.1016/j.ijmactools.2016.07.010.

XIA et al. 2017

Xia, M.; D. Gu; G. Yu; D. Dai; H. Chen; Q. Shi: „Porosity evolution and its thermodynamic mechanism of randomly packed powder-bed during selective laser melting of Inconel 718 alloy". *International Journal of Machine Tools and Manufacture* 116 (2017), S. 96–106. ISSN: 08906955. DOI: 10.1016/j.ijmactools.2017.01.005.

R. XU & WUNSCH 2005

Xu, R.; D. Wunsch: „Survey of clustering algorithms". eng. *IEEE transactions on neural networks* (2005) (3). Comparative Study Journal Article Research Support, Non-U.S. Gov't Research Support, U.S. Gov't, Non-P.H.S. Review, S. 645–678. ISSN: 1045-9227. DOI: 10.1109/TNN.2005.845141. eprint: 15940994.

W. XU et al. 2013

Xu, W.; Y. Hou; Y. S. Hung; Y. Zou: „A comparative analysis of Spearman's rho and Kendall's tau in normal and contaminated normal models". *Signal Processing* (2013) (1), S. 261–276. ISSN: 01651684. DOI: 10.1016/j.sigpro.2012.08.005.

YASA & J. KRUTH 2011

Yasa, E.; J. Kruth: „Application of Laser Re-melting on Selective Laser Melting Parts". *Advances in Production Engineering and Management* (2011) (6), S. 259–270.

ZÄH 2006

Zäh, M. F.: *Wirtschaftliche Fertigung mit Rapid-Technologien. Anwender-Leitfaden zur Auswahl geeigneter Verfahren*. Wien: Carl Hanser Verlag GmbH & Co. KG. 2006. 271 S. ISBN: 978-3-446-43916-0.

B. ZHANG et al. 2017

Zhang, B.; Y. Li; Q. Bai: „Defect Formation Mechanisms in Selective Laser Melting. A Review". *Chinese Journal of Mechanical Engineering* (2017) (3), S. 515–527. ISSN: 1000-9345. DOI: 10.1007/s10033-017-0121-5.

Z. ZHANG et al. 2015

Zhang, Z.; H. Chen; Y. Xu; J. Zhong; N. Lv; S. Chen: „Multisensor-based real-time quality monitoring by means of feature extraction, selection and modeling for Al alloy in arc welding". *Mechanical Systems and Signal Processing* 60-61 (2015), S. 151–165. ISSN: 08883270. DOI: 10.1016/j.ymsp.2014.12.021.

Anhang




Abbildung A.1: Technische Zeichnung der Dichtewürfel mit einer Schichtdicke von 25 μm




Abbildung A.2: Technische Zeichnung der Dichtewürfel mit einer Schichtdicke von 50 μm




Abbildung A.3: Technische Zeichnung der Dichtewürfel mit einer Schichtdicke von 75 μm

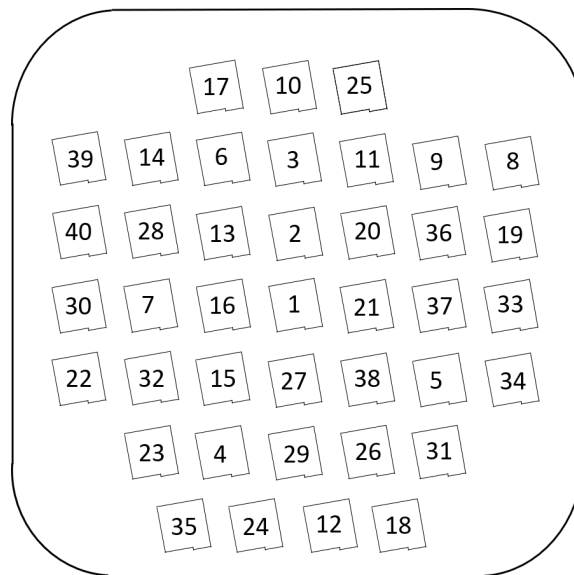


Abbildung A.4: Anordnung der Proben auf der Bauplattform des Baujob 2




Abbildung A.5: Anordnung der Proben auf der Bauplattform des Baujob 3

Tabelle A.1: Zuordnung der Probennummerierung zu den Prozessparametern beim Trainingsversuch. Da zwei Replika gefertigt wurden sind jedem Prozessparametersatz immer zwei Nummern zugeordnet.

Nummer	Laserleistung P in W	Schichtdicke d_s in μm	z-Verschiebung
1,23	240	75	Z-Z _R
2,22	240	75	Z+Z _R
30,28	300	75	Z
27,3	360	75	Z-Z _R
5,16	360	75	Z+Z _R
6,25	300	50	Z+Z _R
7,31	300	50	Z-Z _R
8,32	300	50	Z
9,33	240	50	Z
10,34	300	50	Z
11,4	300	50	Z
12,39	300	50	Z
13,38	300	50	Z
14,37	300	50	Z
15,36	360	50	Z
40,35	360	25	Z-Z _R
17,29	240	25	Z-Z _R
18,21	300	25	Z
19,24	360	25	Z+Z _R
20,26	240	25	Z+Z _R

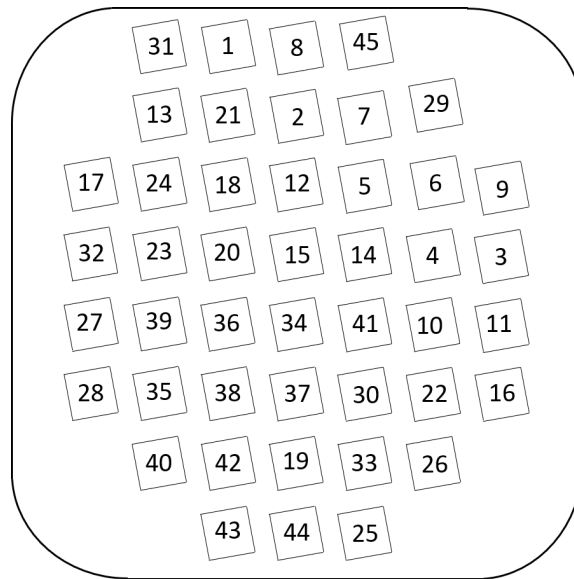


Abbildung A.6: Anordnung der Proben auf den Bauplattform für den Validierungsversuch in Anlehnung an ROSENKRANZ et al. (2018)

Tabelle A.2: Zuordnung der Probennummerierung zu den Prozessparametern beim Validierungsversuch. Da drei Replika gefertigt wurden sind jedem Prozessparametersatz immer drei Nummern zugeordnet.

Nummer	Hatchabstand	Schichtdicke	Laserleistung	Scangeschwindigkeit v_s in $\frac{mm}{s}$
	h in μm	d_s in μm	P in W	
1,22,34	170,0	50,0	30,00	1150,0
2,3,4	139,1	50,0	300,0	1150,0
5,6,7	153,0	50,0	300,0	1150,0
8,9,10	187,0	50,0	300,0	1150,0
11,12,13	207,8	50,0	300,0	1150,0
14,15,16	170,0	50,0	366,7	1150,0
17,18,19	170,0	50,0	333,3	1150,0
20,21,23	170,0	50,0	272,7	1150,0
24,25,26	170,0	50,0	245,5	1150,0
27,28,29	170,0	50,0	300,0	940,9
30,31,32	170,0	50,0	300,0	1035,0
33,35,36	170,0	50,0	300,0	1265,0
37,38,39	170,0	50,0	300,0	1405,6
1*,22*,34*	170,0	40,9	300,0	1150,0
1*,22*,34*	170,0	45,0	300,0	1150,0
1*,22*,34*	170,0	61,1	300,0	1150,0

Die angegebenen Kommastellen entsprechen der Genauigkeit in der die Parameter in Materialise Magics einstellbar sind. Die Proben bei denen die Schichtdicke variiert wurde mit einem * gekennzeichneten. Diese wurden jeweils in einem eigenen Baujob gefertigt und an der selben Bauraumposition entnommen.

Ordnerstruktur des elektronischen Anhangs

- 1 Digitale Version der Arbeit
- 2 Literatur
- 3 MATLAB Funktionen
- 4 Daten

Eidesstattliche Erklärung

Ich erkläre hiermit eidesstattlich, dass ich die vorliegende Arbeit selbstständig angefertigt habe. Die aus fremden Quellen direkt oder indirekt übernommenen Gedanken sind als solche gekennzeichnet.

Die Arbeit wurde bisher keiner anderen Prüfungsbehörde vorgelegt.

Garching, den 01.08.2018

(Simon Schmid)