

# Qualitätssicherung in der additiven Metallfertigung durch hyperspektrale Bildgebung und maschinelles Lernen

Von der Fakultät für Maschinenbau  
der Gottfried Wilhelm Leibniz Universität Hannover  
zur Erlangung des akademischen Grades  
Doktor-Ingenieur  
Dr.-Ing.  
genehmigte Dissertation

von  
Niklas Gerdes, M. Sc.

2022

Vorsitzender: Prof. Dr.-Ing. Stefan Kaielerle  
1. Referent: Prof. Dr.-Ing. Ludger Overmeyer  
2. Referent: Prof. Dr.-Ing. Roland Lachmayer  
Tag der Promotion: 2. Mai 2022

---

## Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Laser Zentrum Hannover e.V. (LZH). Die Forschungsarbeiten wurden im Rahmen des Schwerpunktprogramms 2122 „Neue Materialien für die laserbasierte additive Fertigung“ von der Deutschen Forschungsgemeinschaft (DFG) gefördert.

Ich danke Prof. Dr.-Ing. Ludger Overmeyer, dem Leiter des Instituts für Transport- und Automatisierungstechnik (ITA) der Gottfried Wilhelm Leibniz Universität Hannover und Vorsitzenden des wissenschaftlichen Direktoriums des LZH für seine kompetente und motivierende Unterstützung bei der Betreuung der vorliegenden Arbeit.

Herrn Prof. Dr.-Ing. Roland Lachmayer danke ich für die Übernahme des Korreferats.

Herrn Prof. Dr.-Ing. Stefan Kaielerle danke ich für die Übernahme des Vorsitzes der Prüfungskommission.

Eine Reihe von Personen hat mich in den letzten Jahren sowohl menschlich als auch fachlich unterstützt und somit direkt und indirekt zum Gelingen dieser Arbeit beigetragen. Besonderer Dank gilt meinen Kolleginnen und Kollegen im LZH, die mir fortwährend und unermüdlich mit ihrem fachlichen Rat zur Seite stehen. Außerdem möchte ich meine große Dankbarkeit meiner Familie gegenüber ausdrücken – für ihren bedingungslosen Rückhalt.

Hannover, im Mai 2022

Niklas Gerdes

---

# Kurzzusammenfassung

Die additive Metallfertigung ist durch Vorteile wie Geometriefreiheit, werkzeuglose Fertigung „on-demand“ sowie hohen Bauteilfestigkeiten eine Schlüsseltechnologie zur dezentralen, digitalisierten Fertigung. Eine breite industrielle Nutzung dieser Technologie wird bislang aber durch mangelnde Zuverlässigkeit und Reproduzierbarkeit eingeschränkt. In dieser Arbeit wird deshalb der Einsatz einer Flächen-Hyperspektralkamera zur Prozessüberwachung beim laserbasierten Pulverbettverfahren untersucht. Dazu wird die Funktionsweise der hyperspektralen Bildgebung analysiert und die spektrale Auflösungsfähigkeit der Sensorik charakterisiert. Die Kamera wird in die Fertigungsanlage integriert, sodass Prozessaufnahmen bei der Verarbeitung der Magnesium-Legierung WE43 erhoben werden können. Zur Auswertung der Daten werden Methoden des maschinellen Lernens, insbesondere Convolutional Neural Networks, verwendet, die mit den Prozessaufnahmen trainiert werden. So kann die Oberflächenrauheit  $R_z$ , die im Probensatz mit einer mittleren absoluten Abweichung von  $14,3\ \mu\text{m}$  schwankt, mit einem mittleren absoluten Fehler von  $4,1\ \mu\text{m}$  vorhergesagt werden. Durch die Entwicklung eines Akquise-Systems können Prozessaufnahmen mit der Position des Laserspots im Pulverbett sowie weiteren Maschinendaten verknüpft werden. Dadurch können durch Eisenspäne künstlich erzeugte Prozessfehler mit einem F-Maß von 91 % erkannt werden.

Schlagwörter: Additive Metallfertigung, Laser Powder Bed Fusion, Prozessüberwachung, Maschinelles Lernen, Hyperspektrale Bildgebung

## Abstract

### Hyperspectral process monitoring in additive metal manufacturing

Additive metal manufacturing is a key technology for decentralized, digitized manufacturing due to advantages such as freedom of geometry, tool-free manufacturing „on-demand“ and high component strengths. However, widespread industrial use of this technology has so far been limited by a lack of reliability and reproducibility. This work therefore investigates the use of an area-scan hyperspectral camera for process monitoring in the laser-based powder bed process. To this end, the operation of hyperspectral imaging is analyzed and the spectral resolution capability of the sensor system is characterized. The camera is integrated into the production line so that process images can be collected during the processing of the magnesium alloy WE43. Methods of machine learning, in particular Convolutional Neural Networks, are used to evaluate the data, which are trained with the process recordings. Thus, the surface roughness  $R_z$ , which varies in the sample set with a mean absolute deviation of  $14.3\ \mu\text{m}$ , can be predicted with a mean absolute error of  $4.1\ \mu\text{m}$ . The development of an acquisition system has also allowed process images to be linked to the position of the laser spot in the powder bed as well as to other machine data. This makes it possible to detect process defects artificially generated by iron filings with an F-score of 91 %.

Key words: Metal additive manufacturing, Laser Powder Bed Fusion, Process monitoring, Machine learning, Hyperspectral imaging

---

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Bedeutung der additiven Metallfertigung und deren Qualitätssicherung	1
1.2	Handlungsbedarf und Motivation . . . . .	2
<b>2</b>	<b>Stand der Forschung und Technik</b>	<b>3</b>
2.1	Additive Metallfertigung . . . . .	3
2.1.1	Typische Prozessfehler . . . . .	5
2.2	Prozessüberwachung in der additiven Metallfertigung . . . . .	7
2.3	Wärmestrahlung . . . . .	10
2.3.1	Strahlungsgesetze . . . . .	10
2.4	Hyperspektrale Bildgebung . . . . .	12
2.4.1	Verfahren der hyperspektralen Bildgebung . . . . .	13
2.4.2	Flächen-Hyperspektralkamera . . . . .	14
2.5	Maschinelles Lernen . . . . .	16
2.5.1	Künstliche neuronale Netzwerke . . . . .	17
2.5.2	Maschinelles Lernen in der additiven Fertigung . . . . .	22
2.6	Fazit . . . . .	26
<b>3</b>	<b>Zielsetzung und Vorgehensweise</b>	<b>27</b>
3.1	Lösungsweg . . . . .	27
<b>4</b>	<b>Hyperspektralkamera und Reproduzierbarkeit der Messergebnisse</b>	<b>29</b>
4.1	Flächen-Hyperspektralkamera . . . . .	29
4.2	Reproduzierbarkeit der Messergebnisse . . . . .	30
4.2.1	Schwarzstrahler . . . . .	30
4.2.2	Punktschweißungen . . . . .	32
<b>5</b>	<b>Charakterisierung der Hyperspektralkamera</b>	<b>37</b>
5.1	Auswahl des Kameraobjektivs . . . . .	37
5.2	Korrektur der Sensordaten . . . . .	40
5.2.1	Statistische Korrektur . . . . .	40
5.2.2	Spektralvektoren . . . . .	41
5.2.3	Spektrale Flachfeldkorrektur . . . . .	41
5.2.4	Spektrale Korrekturmatrix . . . . .	43
5.2.5	Geometrische Korrektur . . . . .	47
5.3	Sensorantwort bei monochromatischem Licht . . . . .	47
5.3.1	Versuchsaufbau . . . . .	47
5.3.2	Spektrometer . . . . .	48
5.3.3	Kamera-Signal . . . . .	51

5.4	Fazit . . . . .	56
<b>6</b>	<b>Hyperspektrale Prozessüberwachung zur Vorhersage der Oberflächenrauheit durch ein Convolutional Neural Network</b>	<b>59</b>
6.1	LPBF-Anlage und Integration der Sensorik . . . . .	59
6.2	Versuchsdurchführung . . . . .	61
6.2.1	LPBF von Magnesium . . . . .	61
6.2.2	Pulverwerkstoff . . . . .	61
6.3	Aufnahme hyperspektraler Prozessdaten und Datenvorverarbeitung .	63
6.3.1	Datenaufnahme und -verarbeitung . . . . .	63
6.3.2	Bestimmung der Belichtungszeit . . . . .	64
6.4	Bestimmung der Oberflächenrauheit . . . . .	65
6.5	Regression der Oberflächenrauheit durch ein Convolutional Neural Network . . . . .	66
<b>7</b>	<b>Ortsaufgelöste Klassifikation von Prozessfehlern durch ein Convolutional Neural Network</b>	<b>73</b>
7.1	Akquise-System zur Verknüpfung von Prozess- und Maschinendaten .	73
7.1.1	XY2-100-E Protokoll . . . . .	74
7.1.2	Struktur des Akquise-Systems . . . . .	76
7.1.3	FPGA-Implementierung zur Datenerhebung . . . . .	79
7.1.4	Benutzeroberfläche des Akquise-Systems . . . . .	82
7.1.5	Positionsabhängiges Triggern von Prozessaufnahmen . . . . .	85
7.2	Künstliche Erzeugung von Prozessfehlern . . . . .	86
7.3	Ortsaufgelöste Vorhersage von Prozessfehlern . . . . .	89
7.3.1	Datensatz . . . . .	89
7.3.2	Anpassung des CNN auf unausgewogenen Datensatz . . . . .	90
7.3.3	Metriken zur Bewertung der Klassifizierungsgenauigkeit . . . . .	91
7.3.4	Hyperparameter-Tuning . . . . .	91
7.3.5	Bewertung der Klassifikationsgenauigkeit . . . . .	95
<b>8</b>	<b>Schlussbetrachtung</b>	<b>99</b>
8.1	Zusammenfassung . . . . .	99
8.2	Ausblick . . . . .	101
	<b>Abbildungsverzeichnis</b>	<b>103</b>
	<b>Tabellenverzeichnis</b>	<b>109</b>
	<b>Literaturverzeichnis</b>	<b>111</b>
<b>A</b>	<b>Anhang</b>	<b>119</b>
A.1	Ximea MQO22HG-IM-SM5X5-NIR . . . . .	119
A.2	nlight element e18.1400976105 . . . . .	119
A.3	Spektrale Charakterisierung der Kamera . . . . .	120
A.4	Hyperparameter-Tuning zur Erkennung künstlich eingebrachter Prozessfehler . . . . .	128
	<b>Publikationsliste</b>	<b>131</b>

**Lebenslauf**

**133**



# Abkürzungen

Adam	Adaptive moment estimation.
AOTF	Acousto-optic Tunable Filter.
API	Application Programming Interface.
CNN	Convolutional Neural Network.
DL	Deep Learning.
EBM	Electron Beam Melting.
FOV	Field of View (Sichtbereich).
FPGA	Field Programmable Gate Array.
FPI	Fabry-Pérot Interferometer.
fps	Frames per second.
FWHM	Full Width at Half Maximum.
KI	Künstliche Intelligenz.
LCTF	Liquid Crystal Tunable Filter.
LMD	Laser Metal Deposition.
LPBF	Laser Powder Bed Fusion.
LVTTL	Low voltage transistor-transistor logic.
MAE	Mean absolute error (mittlerer absoluter Fehler).
ML	Machine Learning.
MSE	Mean squared error (mittlerer quadratischer Fehler).
Nadam	Nesterov-accelerated adaptive moment estimation.
OCT	Optical Coherence Tomography.
PBF-LB/M	Laser-based Powder Bed Fusion of Metals.
PTFE	Polytetrafluorethylen.
RNN	Recurrent Neural Network.
ROI	Region of Interest.
SeDANN	Sequential Decision Analysis Neural Network.
SGD	Stochastic Gradient Descent.
SIFT	Scale Invariant Feature Transform.
SKS	Schwarzkörperstrahler.
SVM	Support Vector Machine.
SWIR	Short-wave infrared.
UART	Universal Asynchronous Receiver Transmitter.

VHDL      Very High Speed Integrated Circuit Hardware Description  
Language.

# Formelzeichen

Formelzeichen	Einheit	Bezeichnung
$A$	$m^2$	Oberfläche
$J(\theta)$	–	Kosten- bzw. Verlustfunktion
$M(T)$	$W/(m^2)$	Spezifische Ausstrahlung
$M(\lambda, T)$	$W/(m^2 \cdot m)$	Spektrale spezifische Ausstrahlung
$M_{SKS}(T)$	$W/(m^2)$	Spezifische Ausstrahlung eines Schwarzen Strahlers
$M_{SKS}(\lambda, T)$	$W/(m^2 \cdot m)$	Spektrale spezifische Ausstrahlung eines Schwarzen Strahlers
$L$	$m$	Länge
$R_{opt}$	–	Reflexionskoeffizient
$\vec{S}_S$	–	Spektralvektor einer hyperspektralen Bildaufnahme
$\vec{S}_C$	–	Korrigierter Spektralvektor
$T$	$K$	Temperatur
$T_{opt}$	–	Transmissionskoeffizient
$c$	$m/s$	Lichtgeschwindigkeit
$h_p$	$J_s$	Planck'sches Wirkungsquantum
$k_B$	$J/K$	Boltzmann-Konstante
$m_t$	–	Abschätzung erstes Moment
$\hat{m}_t$	–	Korrigierte Abschätzung erstes Moment
$n$	–	Brechungsindex
$n_i$	–	Natürliche Zahl
$v_t$	–	Abschätzung zweites Moment
$\hat{v}_t$	–	Korrigierte Abschätzung zweites Moment
$x^i$	–	i-tes Trainingsbeispiel
$y^i$	–	i-te Kennzeichnung bzw. Label
$\beta_1, \beta_2$	–	Zerfallsraten
$\epsilon$	–	Ausgleichsterm
$\epsilon(\lambda, T)$	–	Emissionsgrad
$\eta$	–	Lernrate
$\theta$	–	Parameter/Gewichtungen eines neuronalen Netzwerks
$\lambda$	$m$	Wellenlänge
$\sigma_B$	$W/(m^2 K^4)$	Stefan-Boltzmann-Konstante
$\Delta\phi$	rad	Phasendifferenz

# 1 Einleitung

## 1.1 Bedeutung der additiven Metallfertigung und deren Qualitätssicherung

Die additive Fertigung nahm ihren Anfang bereits in den 80er Jahren mit der Erfindung der Stereolithographie. Hideo Kodama nahm 1981 am Nagoya Industrial Research Institute die ersten Prototyp-Anlagen in Betrieb [Kod81]. Charles Hull wiederum begann die Kommerzialisierung der Technologie, indem er 1986 in den USA 3D Systems gründete [Koc17]. Im Laufe der Jahre kamen viele andere Verfahren zur schichtweisen Fertigung hinzu, was auch die möglichen Anwendungsbereiche erweiterte. Dadurch entstanden auch in Deutschland mehrere Anlagenhersteller – das heute mit über 900 Mitarbeitern größte deutsche Unternehmen in diesem Bereich, EOS, wurde beispielsweise 1989 gegründet [Who20].

Im Kunststoffbereich gibt es neben Anlagen für den industriellen Einsatz eine Vielzahl preiswerter Anlagen, die als sogenannte Desktop-Modelle sehr verbreitet sind, um im privaten wie industriellen Umfeld schnell und günstig z.B. Halterungen oder Ähnliches zu fertigen. Der Metallbereich ist deutlich teurer und aufwändiger [Sch17], sodass er auf Industrie und Forschung beschränkt ist. Sowohl für Kunststoff als auch für Metall ist das Einsatzfeld der additiven Fertigung stetig gewachsen – vom reinen Prototypenbau zur Werkzeug- und schließlich auch zur Serienfertigung [Ngo18].

Die additive Metallfertigung umfasste im Jahr 2019 ein globales Marktvolumen von 11,9 Milliarden Euro. Die Wachstumsrate fiel dabei zwar von 33,8 % im Vorjahr auf 21,2 %, signalisiert aber dennoch einen kräftigen Zuwachs. Allein in Deutschland gibt es 25 Unternehmen, die Anlagen zur additiven Fertigung im industriellen Umfeld herstellen [Who20]. Wie die noch junge Branche die Corona-Krise überstehen wird, ist noch offen. Die Vorzüge der additiven Fertigung könnten aber zukünftig eine größere Rolle spielen.

Die wesentlichen Vorteile der additiven Metallfertigung sind Geometriefreiheit, Fertigung ohne angepasste Werkzeuge sowie teilweise verbesserte mechanische Eigenschaften durch feinkörniges Gefüge. Bauteilgruppen bestehend aus mehreren Einzelkomponenten können beispielsweise zu einem einzigen Bauteil zusammengefügt werden. Topologie-optimierte Bauteile sind wiederum besonders für den Leichtbau interessant. Auch die Bionik profitiert von den geometrischen Freiheiten dieser Fertigungsmethode [Lip18].

Genauso wie bei anderen Fertigungsverfahren ist auch bei der additiven Fertigung die Qualitätssicherung elementarer Bestandteil industrieller Produktion. Viele an den Produktionsprozess nachgelagerte Prüfverfahren, die in der konventionellen Fer-

tigung verwendet werden, kommen auch bei der additiven Fertigung zum Einsatz. Hierzu zählen zerstörende Verfahren wie Zugversuche genauso wie zerstörungsfreie Verfahren wie die Röntgenprüfung [Who20]. Da sich die additive Fertigung durch hohe Flexibilität auszeichnet, werden häufig nur geringe Stückzahlen hergestellt. Gerade deshalb sind schnelle und kostengünstige Verfahren zur Qualitätssicherung von herausragender Bedeutung.

## 1.2 Handlungsbedarf und Motivation

Eine flexible, dezentrale Fertigung ist Kernelement einer digitalisierten Produktion [Sch20]. Die Corona-Krise hat gezeigt, dass die im Zuge der Globalisierung komplexer gewordenen Lieferketten eine problematische Abhängigkeit erzeugen können. Viele Unternehmen wie Philips, General Electric, Boeing, Adidas oder Bosch haben schon vor der Krise Produktionsschritte digitalisierungsbedingt aus Niedriglohnländern ins eigene Land zurückgeholt [Gör20]. Die Pandemie hat diesen Trend verstärkt.

Die additive Fertigung, die werkzeuglose „on-demand“-Produktion erlaubt, ist hierbei Schlüsseltechnologie. Die hohen Erwartungen wurden jedoch nur teilweise erfüllt: unvollständige Automatisierung, mangelnde Reproduzierbarkeit, hohe Kosten sowie unzureichende Oberflächenqualitäten haben den vollständigen Durchbruch der Technologie bislang verhindert [Sch17].

Um die Kosten für aufwändige nachgelagerte Prüfverfahren zu reduzieren und die Reproduzierbarkeit zu verbessern, werden diverse Verfahren zur Qualitätssicherung durch Online-Prozessüberwachung untersucht [Eve16]. Es ist bisher jedoch nur teilweise gelungen, industriell relevante Messdaten in situ zu erheben [Mal18].

Das Ziel dieser Arbeit ist folglich, die Grundlage dafür zu schaffen, industriell relevante Bauteileigenschaften schon während des additiven Bauprozesses zu bestimmen. Kern der Untersuchungen ist das sogenannte Laser Powder Bed Fusion Verfahren, das die Fertigung filigraner Metallbauteile erlaubt. Wenn die Produktqualifizierung mit Ende des Fertigungsprozesses bereits abgeschlossen ist, könnte dies den Mehrwert der Technologie für industrielle Anwendungen entscheidend verbessern. Der hierzu gewählte Ansatz umfasst die Untersuchung einer innovativen Sensortechnologie, der hyperspektralen Bildgebung, in Verbindung mit intelligenter Datenauswertung in Form des maschinellen Lernens, das in den letzten Jahren in vielen Bereichen erfolgreich eingesetzt wurde [Cho18]. So sollen Fehler im Bauprozess erkannt sowie Bauteileigenschaften vorhergesagt werden können und somit eine zuverlässige Qualitätssicherung für die additive Metallfertigung geschaffen werden.

# 2 Stand der Forschung und Technik

## 2.1 Additive Metallfertigung

Es gibt mehrere Verfahren, die zur additiven Fertigung metallischer Bauteile verwendet werden. Hierzu zählen in erster Linie das Laserauftragschweißen, engl. *Laser Metal Deposition (LMD)*, das Elektronenstrahlschmelzen, engl. *Electron Beam Melting (EBM)*, sowie das laserbasierte Pulverbettverfahren, engl. *Laser Powder Bed Fusion (LPBF)* oder *Laser-based Powder Bed Fusion of Metals (PBF-LB/M)*. Sie unterscheiden sich vor allem hinsichtlich der Form des Ausgangsmaterials, der Wärmequelle, sowie der Art der Zuführung des Ausgangsmaterials. Insbesondere das laserbasierte Pulverbettverfahren hat in den letzten Jahren große Aufmerksamkeit erfahren, denn es ermöglicht die werkzeuglose Fertigung filigraner Metallbauteile bei hoher Geometriefreiheit. Dieses Verfahren steht im Fokus der vorliegenden Arbeit.

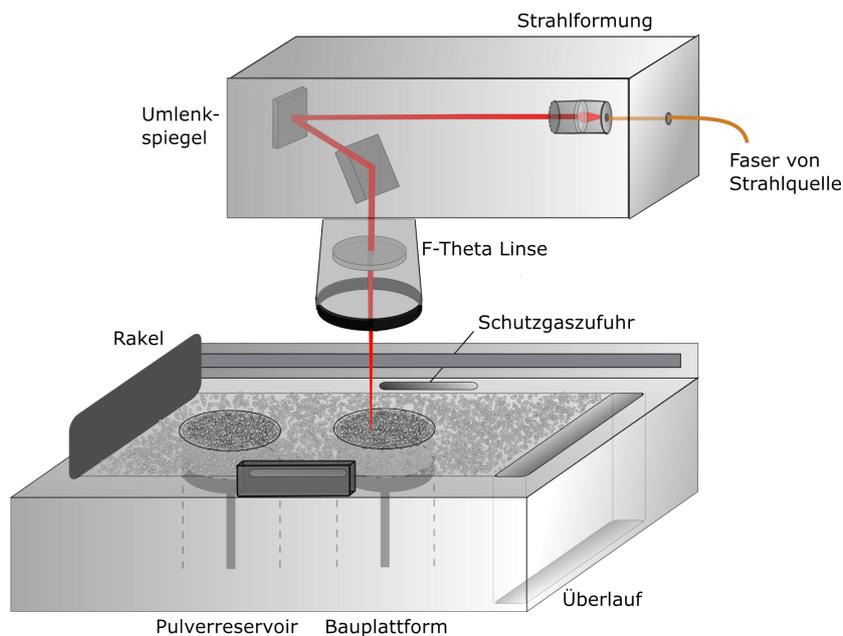


Abbildung 2.1: Prinzipskizze einer LPBF-Anlage.

Das LPBF-Verfahren verläuft, wie in Abbildung 2.1 dargestellt, zweistufig: 1) Eine Schicht des pulverförmigen Ausgangsmaterials wird durch einen Rakel abgelegt und

2) ein Laser schmilzt selektiv Bereiche des Pulverbetts und sorgt somit für eine Verfestigung. Nach einer Absenkung der Bauplattform wiederholt sich dieser Vorgang und das Bauteil entsteht Schicht für Schicht. Eine Inertgasumwälzung trägt während des Prozesses Schmauch ab und verhindert Oxidation. Der Laserstrahl wird über eine Faser zu strahlformenden Optiken geführt und in einem Galvanometer-Laserscanner durch Umlenkspiegel auf die Bauplattform gerichtet. Eine F-Theta Linse sorgt zudem für einen von der Auslenkung unabhängig gleich großen Laserspot.

Eine große Bandbreite an Legierungen lässt sich mit diesem Verfahren bereits verarbeiten. Industriell etabliert sind Edel- und Werkzeugstähle, Aluminium-, Titan-, Nickel-, Kupfer- und Kobaltlegierungen [Sch17]. Eine Vielzahl weiterer Legierungen ist noch Gegenstand der Forschung und stellt häufig besondere Anforderungen z.B. an die Systemtechnik (grüner Laser zur Kupferverarbeitung [Jad19]) oder die Sicherheitsvorkehrungen (Magnesium [Gie13]). Zur Beurteilung der Bauteilqualität werden als wichtigste Qualitätsmerkmale typischerweise die relative Materialdichte, Oberflächenrauheit, Maßhaltigkeit sowie Zugfestigkeit bestimmt. Je nach Anwendungsfall sind weitere Qualitätsmerkmale von Bedeutung, wie das Elastizitätsmodul in der Medizintechnik [Wan16] oder die Ermüdungseigenschaften in der Luft- und Raumfahrt [Uri15].

Bei der Parameterentwicklung werden üblicherweise im Rahmen einer statistischen Veruchsplanung zunächst die Laserleistung, Scangeschwindigkeit und der Schraffurabstand der Belichtungsstrategie variiert. Der Prozess unterliegt aber einer großen Anzahl an weiteren Einflussgrößen, die allesamt die Qualität des Bauteils wesentlich beeinflussen [Küs11]. Die wichtigsten Einflussgrößen betreffen die Anlagentechnik, den Zustand des Ausgangs-, also Pulverwerkstoffs, sowie die verwendete Software zur Erstellung der Projektdatei. Im Folgenden sind sie kurz zusammengefasst:

- **Pulverwerkstoff:** Korngrößenverteilung, Morphologie und Form des Pulvers sind maßgeblich für einen zuverlässigen Prozess und hängen von diversen Parametern beim Verdünnungsverfahren der Pulver ab. Auch die Art der Lagerung hat insbesondere auf die Feuchtigkeit und den Grad der Oxidation des Pulverwerkstoffs einen entscheidenden Einfluss.
- **Laser und Optik:** Der Laser sowie die zur Strahlführung und -formung eingesetzten Optiken bestimmen das Intensitätsprofil des Laserspots. Dieses spielt neben der Wellenlänge und Leistung des Lasers eine entscheidende Rolle bei der Schmelzbaderzeugung und somit Gefügeausbildung.
- **Software und Datenvorbereitung:** Die Festlegung der Bauteilausrichtung im Bauraum, der Belichtungsstrategie bzw. Schraffurmuster und Auslegung der Stützstrukturen erfolgen mittels entsprechender Software. Die an die Fertigungsanlage übergebene Projektdatei ist somit vom Bediener- und der Software abhängig.
- **Aktorik:** Der Beschichtungsmechanismus ist für einen homogenen und glatten Pulverauftrag zuständig. Er ist charakterisiert durch Material und Form der Beschichterlippe, Art des Pulverreservoirs sowie Geschwindigkeit und Bewegungsrichtung.
- **Schutzgasumwälzung:** Während des Prozesses entstehender Schmauch muss durch eine Schutzgasumwälzung abgetragen werden, um Prozessfehler zu vermeiden. Die Art und Reinheit des Schutzgases, der Restsauerstoffgehalt und

der Grad laminarer Strömung über dem Pulverbett im Gegensatz zu turbulenter Strömung sind hierbei wesentlich.

Für einen erfolgreichen Prozessdurchlauf müssen also zahlreiche Randbedingungen den Anforderungen entsprechen. Eine Verschmutzung optischer Elemente in der Strahlführung, deren Erwärmung oder Unreinheiten im Pulverwerkstoff können beispielsweise zu Prozessfehlern führen, die unzulässige Mängel in der Bauteilqualität nach sich ziehen. Zur Gewährleistung der Bauteilqualität liegt es deshalb nahe, direkt die Entstehung von Prozessfehlern während des Bauprozesses statt die Einhaltung aller Randbedingungen zu überwachen.

### 2.1.1 Typische Prozessfehler

Die verschiedenen Prozessfehler und die mit ihnen einhergehenden Auswirkungen auf die Bauteileigenschaften werden in der Wissenschaft umfassend betrachtet. Es gibt bislang zwar noch keine Normen, die speziell für das LPBF-Verfahren eine Einteilung der Prozessfehler und den korrespondierenden Bauteildefekten vornehmen, als Ausgangspunkt kann aber auf existierende Normen zum Schweißen metallischer Werkstoffe zurückgegriffen werden. Die DIN EN ISO 6520-1 [Beu07] befasst sich mit geometrischen Unregelmäßigkeiten beim Schweißen metallischer Werkstoffe und klassifiziert diese in Risse, Hohlräume, Feste Einschlüsse, Bindefehler, Formabweichungen sowie Sonstige Unregelmäßigkeiten. In zusätzlichen Unterkategorien wird eine genauere Einteilung vorgenommen - bei Rissen z.B. in Längs-, Quer- und Endkraterisse. Für das pulverbettbasierte Laserstrahlschmelzen – auch ein Schweißprozess metallischer Werkstoffe – ist diese Klassifikation ebenso sinnvoll, wobei weitere, dem Verfahren spezifische Prozessfehler von Bedeutung sind. In Tabelle 2.1 sind die für das LPBF-Verfahren wichtigsten Bauteildefekte sowie die entsprechenden Prozessfehler und ihre Ursachen aufgeführt.

Risse resultieren durch Eigenspannungen, die z.B. durch den Temperaturgradienten in der Abkühlphase bedingt entstehen [Mer06]. Rissentstehung hängt je nach Material in unterschiedlichem Ausmaß von der Auslegung der Stützstruktur, der Substrattemperatur sowie der Belichtungsstrategie ab. Eine Vorwärmung der Substratplatte kann bei der Vermeidung von Rissen helfen [Buc14]. Porenbildung wiederum kann eine Vielzahl an Ursachen haben, darunter unzureichend laminarer Gasfluss über der Bauplattform [Fer12], der Zustand des Pulverwerkstoffs (Feuchte und Reinheit) [Liu15], der Pulverauftrags-Mechanismus [Fos15] und die Laserleistung [Gie13]. Obwohl die meisten Bauteile einer auf den LPBF-Prozess folgenden Wärme- und Oberflächenbehandlung unterzogen werden, sind die Oberflächeneigenschaften insbesondere für die Ermüdungseigenschaften von Relevanz [Sam16]. Der Treppenstufeneffekt, zu geringe Scangeschwindigkeit und inhomogener Pulverauftrag führen zu erhöhter Oberflächenrauheit [Bad06]. Zudem hängt die Oberflächentopologie eines Bauteils stark von der Orientierung der jeweiligen Fläche zur Aufbaurichtung ab [Fox16].

Die Maßhaltigkeit kann durch von Eigenspannungen ausgelösten Verzug oder Schrumpfung beeinträchtigt werden. Verzug wird während der Abkühlung der aufgeschmolzenen Schicht erzeugt, da die darunterliegende Schicht die thermische Kontraktion blockiert [Mer06]. Die Ursachen für Verzug sind somit, ähnlich wie bei Rissen, Eigenspannungen erzeugende Prozessparameter. Entscheidend sind vor allem

Tabelle 2.1: Typische Prozessfehler und ihre Ursachen im LPBF-Verfahren

Bauteildefekt	Prozessfehler	Typische Ursachen
Risse	Wärmestau falscher Temperaturgradient	Stützstruktur [Fos15] Substrattemperatur [Buc14] Belichtungsstrategie [Che16]
Porenbildung	Balling Spritzerbildung Verdampfung, Plasma mangelnde Benetzung	Gasfluss [Fer12] Pulverwerkstoff [Liu15] Pulverauftrag [Fos15] Laserleistung [Gie13]
Oberflächenfehler	Balling Pulveranhaftung	Treppenstufeneffekt [Mal18] Scangeschwindigkeit [Bad06] Pulverauftrag [Kle12]
Formabweichungen	Wärmestau falscher Temperaturgradient	Belichtungsstrategie [Kru12] Orientierung im Bauraum [Del12] Stützstruktur [Kle12]
Unregelmäßigkeit im Gefüge	variierende Erstarrungsbedingungen	Pulverreinheit [Mal18] Belichtungsstrategie [Nel14] Bauteilgeometrie [Mei08]

die Auslegung der Stützstruktur, die Orientierung im Bauraum sowie die Belichtungsstrategie, wobei eine Variation der Belichtungsstrategie von Schicht zu Schicht für geringere Eigenspannungen sorgen kann [Kru12].

Anisotrope Bauteileigenschaften sind ein inhärentes Merkmal des LPBF-Verfahrens. Die Aufbaurichtung bestimmt das Kornwachstum und somit auch die Richtung maximaler Festigkeiten. So kann die höchste Zugfestigkeit quer zur Aufbaurichtung gemessen werden [Sch17]. Aber auch die Scan-Richtung kann eine Anisotropie bewirken, weshalb multidirektionale Belichtung bevorzugt wird [Nel14]. Weitere Unregelmäßigkeiten im Gefüge entstehen durch unreines Pulver und variierende Erstarrungsbedingungen, z.B. bedingt durch die Bauteilgeometrie [Mal18].

Das sogenannte Balling ist ein dem Pulverbett-Verfahren spezifischer Prozessfehler: es wird keine gleichmäßige Linie, sondern Schmelzkugeln aufgeschmolzen. Der von der Oberflächenspannung der Schmelze abhängige Balling-Effekt sorgt für Poren, raue Oberflächen und in besonders ausgeprägten Fällen für Beeinträchtigungen des Pulverauftrags [Li12].

Abbildung 2.2 zeigt Querschliffe von LPBF-gefertigten Proben der Magnesiumlegierung WE43. Während in Abbildung 2.2a Poren und Pulveranhaftung zu erkennen sind, zeigen 2.2b und 2.2c einen Riss bzw. mangelnde Benetzung. Hier ist es durch die typisch schwierige Verarbeitbarkeit von Magnesiumlegierungen und einen nicht optimal abgestimmten Prozess zu einer Vielzahl von Prozessfehlern gekommen, die sich im Schliffbild widerspiegeln.

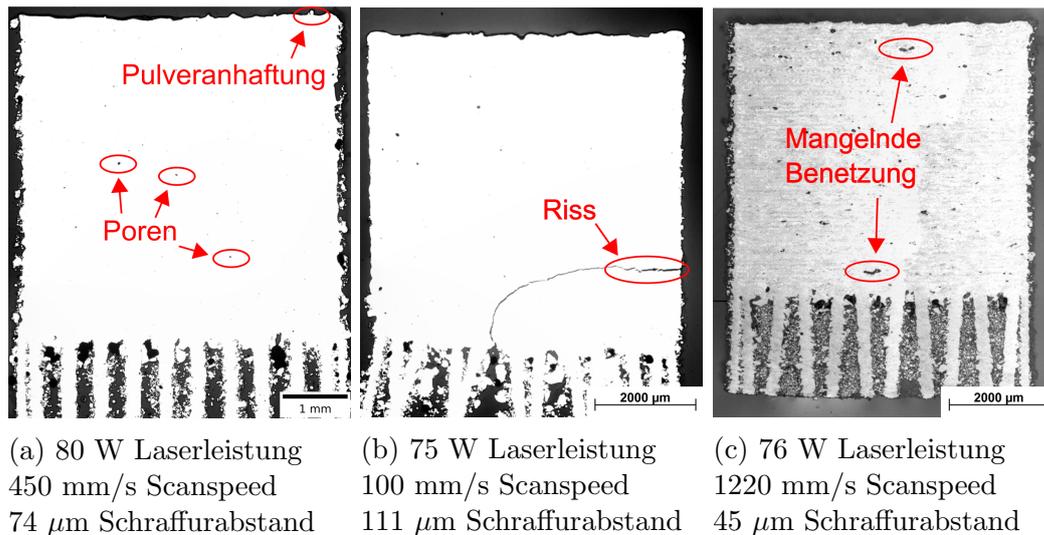


Abbildung 2.2: Querschliffe von Proben der Mg-Legierung WE43.

## 2.2 Prozessüberwachung in der additiven Metallfertigung

Das Potenzial der additiven Metallfertigung für die Medizintechnik oder die Luft- und Raumfahrt wurde früh erkannt. Gerade in diesen Anwendungsbereichen werden allerdings hohe Anforderungen an die Prozessqualifikation gestellt. Eine besondere Schwierigkeit liegt darin, hohe Reproduzierbarkeit und gleichbleibende Bauteileigenschaften zu erreichen. Dies ist als kritischer Schwachpunkt der additiven Metallfertigung identifiziert worden [Lot11]. Deshalb gibt es eine Vielzahl von Ansätzen zur Überwachung des Fertigungsprozesses, die dabei unterschiedliche Sensoriken, Optiken und Algorithmen zur Auswertung einsetzen [Spe16].

Das grundlegende Ziel dieser Ansätze ist, den quantitativen Zusammenhang zwischen Prozessparametern, -emissionen und Bauteileigenschaften zu ermitteln (Abbildung 2.3). Da die Bauteileigenschaften neben den einstellbaren Prozessparametern auch von einer großen Zahl an Störgrößen abhängen, ist es sinnvoll, die Prozessemissionen aufzuzeichnen und ihre Bedeutung für die Qualität des Prozesses zu erlernen.

Zur Erfassung elektromagnetischer Prozessemissionen gibt es zwei unterschiedliche Ansätze: erstens die Integration der Sensorik in den optischen Strahlengang des Lasers - die sogenannte On-Axis Konfiguration - oder zweitens eine schräg auf die Bauplattform ausgerichtete Sensorik - die Off-Axis Konfiguration. Abbildung 2.4 zeigt beide Varianten, wobei die On-Axis Sensorik einen dichroitischen Spiegel, also einen für den Laser transmittierenden, für die aufzunehmenden Emissionen aber reflektierenden Spiegel erfordert.

Die am weitesten verbreitete Methode zur Prozessüberwachung im LPBF-Verfahren ist die Aufzeichnung der Intensität der Schmelzbademissionen mit Hilfe einer Photodiode. Hierzu wird das vom Schmelzbad in den Galvanometer-Scanner emittierte Licht aus dem Strahlengang ausgekoppelt und von der Photodiode erfasst. Dieser Ansatz ist in der Wissenschaft umfassend untersucht worden [Eve16, Gra18] und wird von mehreren Herstellern bereits kommerziell vertrieben [Alb16]. Auch

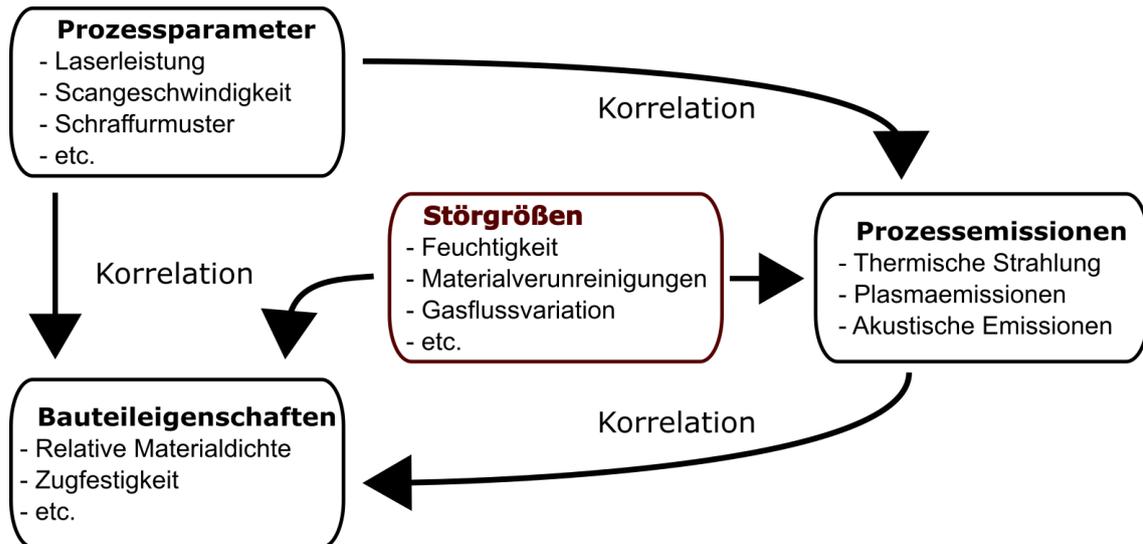


Abbildung 2.3: Grundlage der Prozessüberwachung: Störgrößen, die die Bauteileigenschaften beeinflussen, sollen möglichst von der Sensorik erkannt werden.

die Möglichkeit der Prozessregelung mit Hilfe einer Photodiode wurde bereits gezeigt [Mer07]. Zusätzlich zur Photodiode setzen Clijsters et al. [Cli14] gleichzeitig eine High-Speed Kamera (10 kHz) ein, sodass neben der Intensität der Schmelzbademissionen auch die Fläche, Länge und Breite des Schmelzbad aufzeichnet werden können. Zur Bewertung der Prozessqualität und Klassifikation in iO und niO-Prozesszustände werden dabei Messungen an Referenzbauteilen herangezogen. Insofern eignet sich die On-Axis Konfiguration vor allem für die hochfrequente Erfassung des Schmelzbad zur echtzeitnahen Prozessregelung. Die Überwachung ist durch die Bewegung der Spiegel des Galvanometer-Laserscanners bedingt aber auf das Schmelzbad und dessen unmittelbare Umgebung beschränkt. Ein weiterer Nachteil dieses Ansatzes ist, dass die für die Wellenlänge und Leistung des Bearbeitungslasers ausgelegten Optiken durch chromatische Abberationen das Signal verzerren können.

Die Off-Axis Konfiguration steht dazu im Gegensatz – die Erfassung der gesamten Bauplattform erlaubt Analysen über abkühlende Bereiche und die Erkennung bereichsübergreifender Defekte. Insbesondere für Thermografie- oder Hyperspektralkameras ist diese Konfiguration vorteilhaft, da die zu beobachtenden Wellenlängenbereiche stark von der Laserwellenlänge, auf die die Optiken ausgelegt sind, abweichen können. Zudem ist die Integration der Sensorik an bestehende kommerzielle und somit relativ geschlossene Systeme häufig unproblematischer. Das Bild der schräg auf die Bauebene ausgerichteten Kameras unterliegt perspektivischer Verzerrung und je nach verwendetem Objektiv und dessen Tiefenschärfe können nicht alle Bereiche der Bauplattform scharf aufgenommen werden. Dies kann mit speziell ausgelegten telezentrischen Objektiven unter Ausnutzung des Scheimpflug-Prinzips zwar korrigiert werden, die Größe und Kosten dieser Objektive sind allerdings ein Hindernis. Ein weiterer Nachteil der Off-Axis Konfiguration sind die großen Datenmengen, bei dennoch begrenzter räumlicher und zeitlicher Auflösung.

Krauss [Kra17] setzt eine Thermografiekamera ein, um in der Off-Axis Konfiguration eine schichtweise und schichtaufgelöste Überwachung umzusetzen. Dazu werden aus den Rohdaten mehrerer Kamera-Belichtungen pro Schicht Indikatoren gebildet, wie

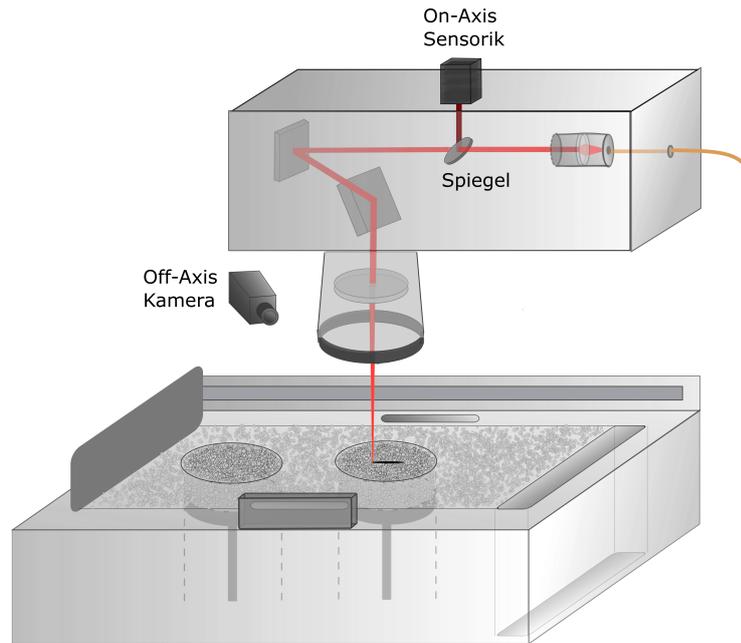


Abbildung 2.4: Prozessüberwachung im LPBF-Prozess.

z.B. die Maximaltemperatur oder Spritzerbildung. Diese werden hinsichtlich ihrer Sensibilität gegenüber Änderungen der Prozessparameter bewertet. Zudem wird die Eignung der einzelnen Indikatoren zur Erkennung von lokalen Unregelmäßigkeiten analysiert. Hierbei zeigt sich, dass die verschiedenen Indikatoren eine Vorhersage von Fehlstellen in Form von nicht verfestigtem Pulver mit unterschiedlicher Zuverlässigkeit zulassen. Zusätzlich werden die über das Bauteil gemittelten Indikatorwerte mit den Bauteileigenschaften korreliert, wobei die stärkste Korrelation mit einem Korrelationskoeffizienten von  $-0,85$  zwischen dem Indikator Spritzerbildung und der Zugfestigkeit ermittelt wird.

Das Unternehmen MTU Aero Engines AG hat ein ähnliches System zur Online-Prozesskontrolle des LPBF-Verfahrens vorgestellt [Zen14]. In dem Optische Tomografie genannten Ansatz werden mittels einer CCD- oder CMOS-Kamera mehrere Einzelbilder einer Schicht zu einem Auswertebild verrechnet. So können Anomalien in der Wärmeverteilung während des Prozesses erkannt werden. Im Gegensatz dazu gibt es Untersuchungen zum Einsatz hochauflösender Kameras, die lediglich jeweils eine Bildaufnahme nach der Pulverbeschichtung und der Laserbelichtung anfertigen. Durch Methoden der Bildverarbeitung können auch anhand dieser Einzelaufnahmen Unregelmäßigkeiten im Pulverauftrag sowie in den Kernprozessparametern identifiziert werden [Kle18].

Ein weiteres Verfahren der Prozessüberwachung nennt sich Optical Coherence Tomography (OCT), welches hauptsächlich in der Ophthalmologie zur Untersuchung der Netzhaut eingesetzt wird [Swa93]. In diesem interferometrischen Verfahren wird breitbandiges Licht mit entsprechend geringer Kohärenzlänge eingesetzt, um Oberflächen-Topologien zu bestimmen. Im Bereich der additiven Fertigung können so Oberflächendefekte während des Prozesses erkannt werden [Gar18]. Auch die Streifenprojektion kann zur Fehlerdetektion eingesetzt werden. Sie eignet sich vor allem zur Erkennung von Beschichtungsfehlern [Zha16]. Eine Übersicht über eingesetzte Sensoren und Verfahren für die Prozessüberwachung im LPBF-Verfahren zeigt Tabelle 2.2.

Tabelle 2.2: Sensoren und Verfahren zur Prozessüberwachung im LPBF-Verfahren

Sensor/Verfahren	Vorteil	Nachteil
Photodiode [Alb16]	-hohe zeitliche Auflösung -geringe Datenmenge -einfach integrierbar -günstig	-keine räumliche Auflösung -keine spektrale Auflösung
High-Speed-Kamera [Cli14]	-hohe räumliche Auflösung -hohe zeitliche Auflösung	-Datenmenge -keine spektrale Auflösung
Bolometer-Kamera [Kra17]	-LWIR-Sensitivität -gute räumliche Auflösung	-geringe zeitliche Auflösung -benötigt Spezialoptiken
Spektrometer [Led19]	-exzellente spektrale Auflösung -gute zeitliche Auflösung	-keine räumliche Auflösung -anfällig für chromatische Aberrationen
Optical Coherence Tomography [Gar18]	-hohe Auflösung des Oberflächenprofils	-keine direkte Erfassung der Prozessstrahlung
Streifenprojektion [Zha16]	-präzise Erkennung von Beschichtungsfehlern	-keine direkte Erfassung der Prozessstrahlung

## 2.3 Wärmestrahlung

Die optische Prozessüberwachung beruht auf der Messung elektromagnetischer Strahlung, die während des Fertigungsprozesses durch thermisch induzierte Schwingungen von Ladungsträgern entsteht. Die durch den Laserstrahl verursachte Wärme erzeugt gekoppelte Schwingungen, die für ein kontinuierliches Spektrum sorgen. Im Folgenden soll die theoretische Grundlage zur Beschreibung dieser Wärmestrahlung dargestellt werden. Die Darstellung orientiert sich dabei an den Ausführungen von W. Demtröder und F. Bernhard [Dem08, Ber14].

### 2.3.1 Strahlungsgesetze

Jeder Körper emittiert oberhalb des absoluten Nullpunkts Wärmestrahlung in Form von elektromagnetischen Wellen. Das *Planck'sche Strahlungsgesetz* beschreibt die Strahlung eines idealen schwarzen Körpers, der jegliche eintreffende Strahlung absorbiert. Zu dessen Herleitung wird sowohl das klassische Bild der Moden, die sich in einem Hohlraum ausbilden, als auch das moderne Bild der Besetzung dieser Moden

### 2.3. WÄRMESTRAHLUNG

mit Energiequanten gemäß der Bose-Einstein-Statistik zugrunde gelegt. Die spektrale spezifische Ausstrahlung  $M_{SKS}(\lambda, T)$  eines Schwarzkörperstrahlers (SKS) kann wie folgt beschrieben werden [Ber14]:

$$M_{SKS}(\lambda, T)d\lambda dA = \frac{2\pi h_p c^2}{\lambda^5 (e^{\frac{h_p c}{\lambda k_B T}} - 1)} d\lambda dA \quad (2.1)$$

$c$ : Lichtgeschwindigkeit;  $h_p$ : Planck'sches Wirkungsquantum;  $k_B$ : Boltzmann-Konstante

Die Integration über alle Wellenlängen führt zum *Stefan-Boltzmann-Gesetz*, das die gesamte Ausstrahlung eines Schwarzkörperstrahlers in Abhängigkeit seiner Temperatur beschreibt [Ber14]:

$$M_{SKS}(T) = \int_0^\infty M_{SKS}(\lambda, T)d\lambda = \sigma_B T^4 \quad (2.2)$$

$\sigma_B$ : Stefan-Boltzmann Konstante

Die ausgestrahlte Leistung ist also direkt proportional zu  $T^4$  mit der Stefan-Boltzmann Konstante  $\sigma_B$  als Proportionalitätsfaktor. Abbildung 2.5 verdeutlicht diesen Zusammenhang über die Darstellung der spektralen Ausstrahlung bei verschiedenen Temperaturen.  $650^\circ\text{C}$  entspricht der Solidustemperatur des im Rahmen dieser Arbeit untersuchten Werkstoffes Magnesium. Die Abbildung veranschaulicht zudem das *Wien'sche Verschiebungsgesetz*, welches beschreibt, bei welcher Wellenlänge  $\lambda_{max}$  bei gegebener Temperatur  $T$  die spektrale Energiedichte ihr Maximum erreicht [Ber14]:

$$\lambda_{max}T = \frac{h_p c}{4,965k_B} = 2,898 \cdot 10^{-3} mK \quad (2.3)$$

Der Zusammenhang zwischen der spektralen spezifischen Ausstrahlung  $M(\lambda, T)$  eines realen Strahlers und der eines idealen Strahlers in Form eines Schwarzkörperstrahlers kann durch den spektralen Emissionsgrad  $\epsilon(\lambda, T)$  ausgedrückt werden. Er definiert sich durch das Verhältnis der Ausstrahlung beider Strahler [Ber14]:

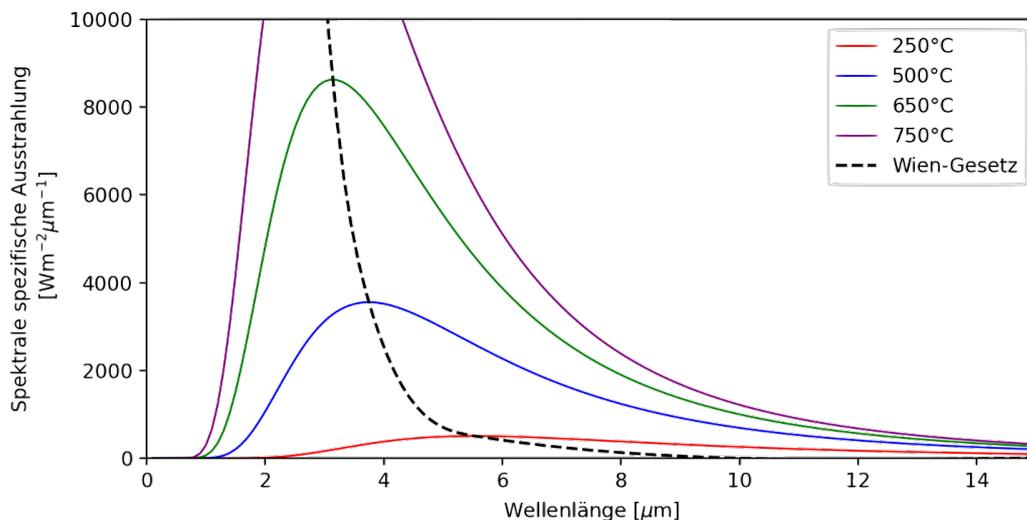


Abbildung 2.5: Das Planck'sche Strahlungsgesetz und das daraus abgeleitete Wien'sche Verschiebungsgesetz berechnet nach Gleichung 2.1.

$$\epsilon(\lambda, T) = \frac{M(\lambda, T)}{M_{SKS}(\lambda, T)} \quad (2.4)$$

Das vereinfachte Modell des grauen Strahlers nimmt einen wellenlängenunabhängigen spektralen Emissionsgrad  $\epsilon(T)$  an. Abbildung 2.6 veranschaulicht den Zusammenhang zwischen einem idealen Schwarzkörperstrahler, einem grauen Strahler und einem realen Strahler. Die spezifische Ausstrahlung eines realen Körpers kann somit durch die mit dem spektralen Emissionsgrad gewichtete spezifische Ausstrahlung des Schwarzkörperstrahlers, integriert über den interessierenden Wellenlängenbereich, dargestellt werden [Ber14]:

$$M(T) = \int_{\lambda_{min}}^{\lambda_{max}} \epsilon(\lambda, T) M_{SKS}(\lambda, T) d\lambda \quad (2.5)$$

Durch die Wellenlängenabhängigkeit des Emissionsgrades ist die Temperaturbestimmung eines realen Strahlers durch Ermittlung der spektralen Ausstrahlung erschwert. Andererseits können die durch Veränderungen des Emissionsgrades bedingten Schwankungen der spektralen Ausstrahlung von Laserstrahlprozessen Informationen enthalten, die auf die Qualität des Prozesses zurückzuführen sind.

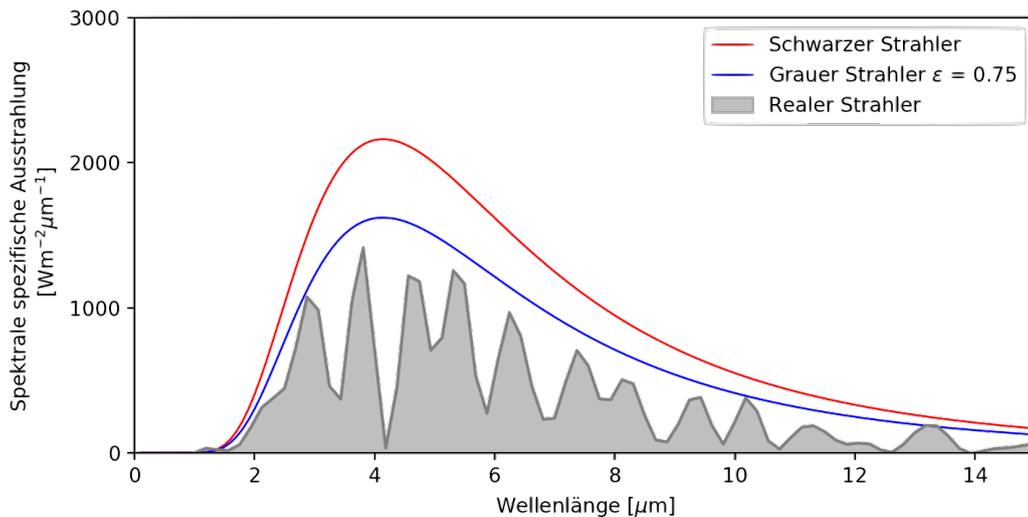


Abbildung 2.6: Vergleich der spektralen Ausstrahlung eines idealen, grauen und realen Strahlers berechnet nach Gleichungen 2.1 und 2.4.

## 2.4 Hyperspektrale Bildgebung

Im Folgenden sollen die Grundlagen der hyperspektralen Bildgebung erläutert werden. Diese definiert sich dadurch, dass das eintreffende, zu detektierende Licht in eine Vielzahl spektraler Bänder, und vor allem über die üblichen drei Rot-, Grün- und Blaukanäle hinaus, aufgeteilt wird. Anders als bei einem Spektrometer muss dafür nicht vollständig auf räumliche Information verzichtet werden. Zunächst werden verschiedene Verfahren der hyperspektralen Bildgebung vorgestellt, bevor anschließend die für diese Arbeit wichtige Flächen-Hyperspektralkamera erläutert wird.

### 2.4.1 Verfahren der hyperspektralen Bildgebung

Die hyperspektrale Bildgebung unterteilt sich in mehrere gebräuchliche Verfahren, die sich an der räumlichen (Punkt, Linie, Fläche) und spektralen Auflösungsfähigkeit des optischen Sensors orientieren. Die Namensgebung der Verfahren orientiert sich an den Ausführungen von Grahn et. al. [Gra07].

#### Räumliches Scannen – Point Scanning Imaging

Dieses Verfahren beruht auf einem Sensor, welcher ein punktförmiges Areal (mit bestimmter räumlicher Ausdehnung) erfassen kann. Eine Mechanik führt in zwei räumlichen Dimensionen entweder die zu untersuchende Probe unter dem Sensor oder den Sensor über die Probe hinweg. An jedem zu untersuchenden Punkt erfasst der Sensor das von der Probe emittierte Spektrum mit Hilfe eines Spektrometers in einem Messvorgang oder unter Verwendung von Passfiltern (Liquid Crystal Tunable Filter (LCTF), Acousto-optic Tunable Filter (AOTF) oder fixe Vorsatzfilter) in mehreren Sequenzen. Werden die zu erfassenden Bänder in einzelnen Schritten erfasst, so handelt es sich um ein Beispiel für räumlich-spektrales-Scannen. Durch jeden durchlaufenen Messzyklus wird ein Spektralvektor für einen Raumpunkt erfasst.

Für die Messungen im Allgemeinen kann die Probe entweder von einer breitbandigen Quelle bestrahlt werden, so dass das von der Probe gestreute Lichtfeld erfasst wird oder die Probe kann eigenständig emittieren. Die eigenständige Emission wird in dieser Arbeit am Beispiel des Prozessleuchtens erfasst. Ebenfalls kann dieses Verfahren zur Untersuchung lumineszierender Proben angewendet werden (z.B. UV-induzierte Fotolumineszenz an mit Markern versehenen biologischen Proben).

#### Räumliches Scannen – Line Scanning Imaging

Bei diesem Verfahren wird der Sensor in einer Dimension verfahren, sodass die Rauminformation sukzessiv in Form aneinander gereihter eindimensionaler Linien erhoben wird. Die Sensorik besteht aus einer zweidimensionalen Pixelfläche, die in der zweiten Dimension über ein dispersives Element (z.B. ein Prisma) die Spektralauflösung jedes Punktes in der Linie erzeugt. Die erste Dimension der Bildinformation ist somit die Ortsinformation, die Zweite wiederum die Spektralinformation. Anders als beim Point Scanning Imaging werden bei diesem Verfahren pro Messzyklus alle Spektralvektoren entlang einer Linie für das Hyperspektralbild erfasst.

#### Spektrales Scannen – Focal Plane Scanning Imaging

Bei diesem Verfahren befinden sich Probe und Sensor in einer starren Position. Die Oberfläche des zu untersuchenden Objekts wird über eine geeignete Optik auf den Sensor abgebildet. Zur Erhebung spektralselektiver Intensitätsinformationen werden nacheinander unterschiedliche Spektralfilter in den Strahlengang platziert und jeweils ein zweidimensionales Bild erfasst.

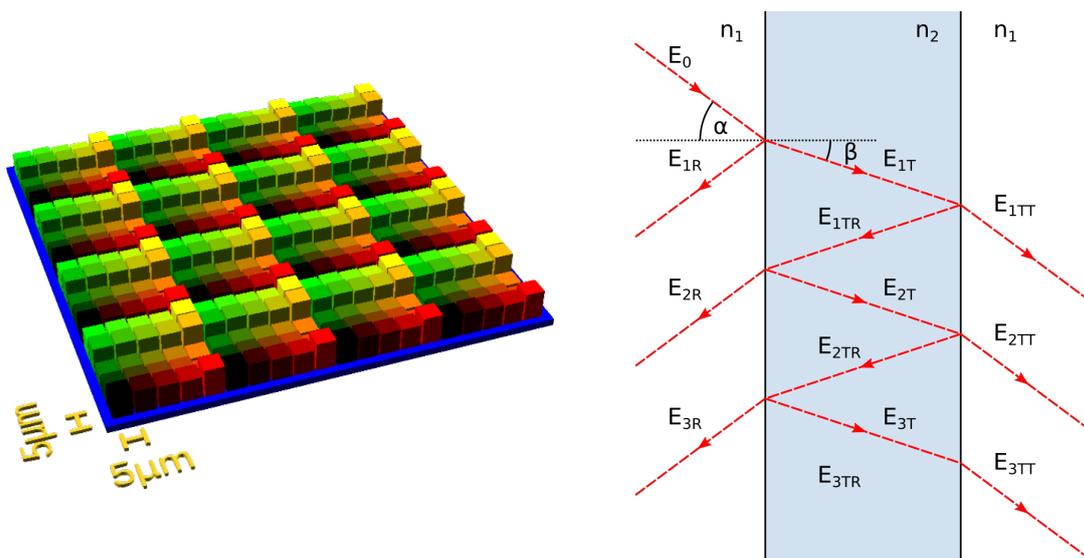
#### Nichtscannende Bildgebung – Flächen-Hyperspektralkamera

Flächen- oder Snapshot-Hyperspektralkameras erheben alle räumlichen und spektralen Informationen gleichzeitig in einem Messzyklus. Dies wird dadurch erreicht,

dass jedem Sensorelement ein spezifischer Spektralfilter vorgelagert ist. Jedes Sensorelement bzw. Pixel ist also mit einem solchen Filter beschichtet, wobei z.B. 16 oder 25 verschiedene Filter in Mosaiken von  $4 * 4$  oder  $5 * 5$  Pixeln angeordnet sind, die sich über die gesamte Pixelfläche wiederholen. Für diese 16 oder 25 spektralen Bänder wird also räumliche Auflösung für spektrale Auflösung geopfert. Da die hyperspektrale Bildgebung durch eine Flächen-Hyperspektralkamera im Fokus dieser Arbeit steht, wird im folgenden Abschnitt näher auf dessen Funktionsweise eingegangen.

### 2.4.2 Flächen-Hyperspektralkamera

Das grundlegende Prinzip einer Flächen-Hyperspektralkamera ist in Abbildung 2.7 dargestellt. Die Pixel eines CMOS-Bildsensors sind mit Fabry-Pérot Filtern beschichtet, die unterschiedliche wellenlängenabhängige Transmissivitäten aufweisen. Diese Wellenlängenselektivität beruht auf dem Prinzip der Vielstrahlinterferenz, wie es in Abbildung 2.7 skizziert ist. Die Zerlegung des eintreffenden Lichts in einzelne Spektralkomponenten basiert bei Flächen-Hyperspektralkameras also im Wesentlichen auf den Eigenschaften der Fabry-Pérot Filter, deren Transmissivität über die Airy-Funktion beschrieben wird. Da sie die für die Funktionsweise der Flächen-Hyperspektralkamera wesentliche physikalische Grundlage beschreibt, soll sie im Folgenden erläutert werden.



(a) Schema des CMOS-Sensors mit  $5 * 5$  Mosaik Mustern der Fabry-Pérot Filter.

(b) Vielstrahlinterferenz

Abbildung 2.7: Prinzip von Flächen-Hyperspektralkameras mit durch Fabry-Pérot Filter beschichtetem CMOS-Sensor. Diese erreichen wellenlängenabhängige Transmission durch Vielstrahlinterferenz [Dem13].

### Fabry-Pérot Interferometer und Airy-Formel

Die Airy-Formel wird im Folgenden in knapper Form dargestellt. Für eine umfassende Herleitung sei auf die Ausführungen von Wolfgang Demtröder [Dem13] verwiesen, an denen sich auch dieser Text orientiert.

Wenn alle elektrischen Felder der im Fabry-Pérot Interferometer umlaufenden Teilwellen phasen- und amplitudenabhängig addiert werden, ergibt sich die Airy-Formel. Sie beschreibt die Transmissivität  $T_{opt}$  des Interferometers in Abhängigkeit von der Phasendifferenz  $\Delta\phi$  [Dem13]:

$$T_{opt} = \frac{1}{1 + F \sin^2(\Delta\phi/2)} \quad \text{mit } F = \frac{4R_{opt}}{(1 - R_{opt})^2} \quad (2.6)$$

$T_{opt}$ : Transmissionskoeffizient;  $R_{opt}$ : Reflexionskoeffizient

Die Phasendifferenz berechnet sich aus der Länge des Interferometers, der Wellenlänge sowie dem Brechungsindex [Dem13]:

$$\Delta\phi = \frac{4\pi nL}{\lambda} \quad (2.7)$$

$L$ : Länge des Interferometers;  $n$ : Brechungsindex

Für eine konstruktive Interferenz und somit maximale Transmissivität gilt die Voraussetzung für die Phasendifferenz, dass  $\Delta\phi = 2\pi$ . Daraus berechnen sich die Wellenlängen, bei denen die Transmissivität maximal wird, wie folgt [Dem13]:

$$\lambda_i = \frac{2nL}{n_i} \quad \text{mit } n_i = 1, 2, \dots \quad (2.8)$$

Wie Abbildung 2.8 deutlich macht, werden neben der Grundwellenlänge bei  $n_i = 1$  auch deren Harmonische mit  $n_i = 2, 3, \dots$  transmittiert. Der Abstand zwischen den Transmissionsmaxima  $\Delta\lambda = \lambda_i - \lambda_{i+1} = \frac{\lambda}{i+1}$  wird als freier Spektralbereich bezeichnet. Abbildung 2.8 zeigt, dass die Transmission, bzw. genauer das Full Width at Half Maximum (FWHM) der Transmissionsmaxima  $\delta\lambda$ , vom Reflexionskoeffizienten der Oberfläche des Interferometers abhängt. Der Grad der Wellenlängenselektivität hängt also vom Reflexionskoeffizienten ab und kann über die sogenannte Finesse  $F$ ,

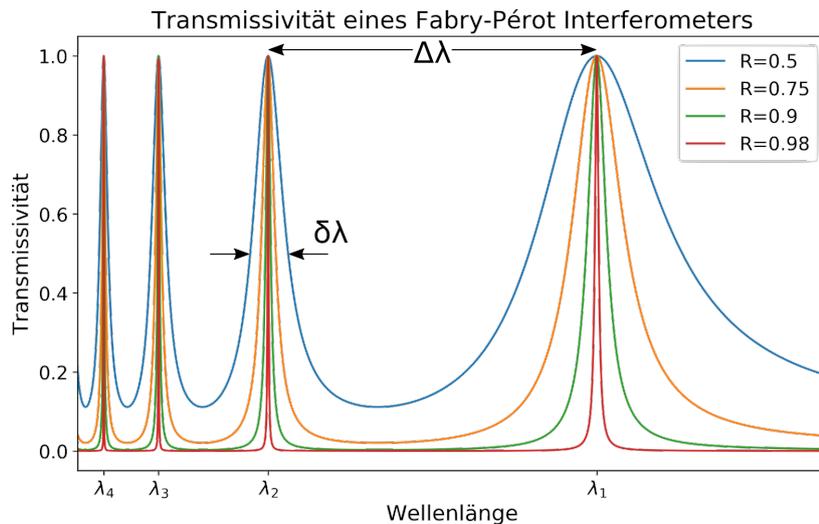


Abbildung 2.8: Transmissivität eines Fabry-Pérot Interferometers in Abhängigkeit der Wellenlänge für unterschiedliche Reflexionskoeffizienten bei gegebener Länge des Interferometers und wellenlängenunabhängigem Brechungsindex [Dem13].

dem Verhältnis zwischen freiem Spektralbereich und FWHM des Transmissionsbereichs, quantifiziert werden.

Der Verlauf der Transmissivität wie er in Abbildung 2.8 dargestellt ist, gilt nur für ein ideales Fabry-Pérot Interferometer. In der Realität sind die Transmissionskurven, bedingt u.a. durch die Rauheit der Spiegel und deren Abweichung von der Parallelität, deutlich unregelmäßiger, wie im Laufe dieser Arbeit noch zu sehen sein wird.

## 2.5 Maschinelles Lernen

Spätestens seit Alan Turings berühmter Veröffentlichung „Computing Machinery and Intelligence“ von 1950 [Tur50] zieht die Künstliche Intelligenz (KI) fächerübergreifend reges Forschungsinteresse an. Diverse Disziplinen, von der Philosophie über die Neurowissenschaften bis zur Informatik, widmen dem Feld der KI zunehmende Forschungsaktivitäten. Dabei hat es in den letzten Jahrzehnten einige Hochphasen gegeben, während derer der Optimismus über vermeintlich nahestehende technologische Durchbrüche die Fördergelder in die Höhe schießen ließ [Cre93]. Auch jetzt befinden wir uns wieder in einer solchen Phase, wenngleich diese bislang noch nicht wie alle zuvor abgeebbt ist.

Zum Oberbegriff der Künstlichen Intelligenz gehört als Unterkategorie das maschinelle Lernen, engl. *Machine Learning (ML)*, und dazu das sogenannte tiefe Lernen, engl. *Deep Learning (DL)* (Abbildung 2.9) [Cop16]. Während sich die KI im Allgemeinen mit der automatisierten Lösung komplexer Probleme beschäftigt, hat das in den 1990er Jahren entstandene maschinelle Lernen zum Fokus, Computern die Möglichkeit zum Lernen zu geben, ohne explizit programmiert zu werden. Konventionelle Programme folgen statischen Algorithmen und im Gegensatz dazu reagieren ML-Programme selbständig auf die Qualität ihrer Berechnung. Es gibt also eine Rückkopplung zwischen Algorithmus und Berechnungsergebnis. Das Deep Learning wiederum beruht auf sogenannten neuronalen Netzwerken, die seit einigen Jahren sehr erfolgreich eingesetzt werden und maßgeblich für den gegenwärtigen Hype um KI verantwortlich sind.

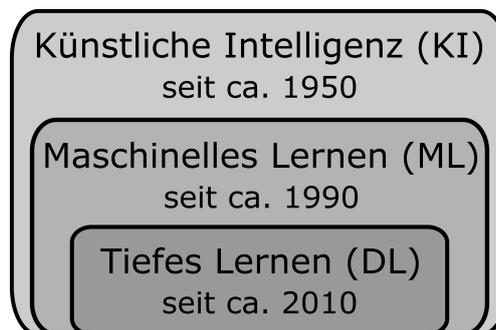


Abbildung 2.9: Unterbegriffe der Künstlichen Intelligenz und wann sie ungefähr Gegenstand wissenschaftlicher Forschung wurden [Wit19].

Das maschinelle Lernen kann zudem in drei Kategorien eingeteilt werden [Wit19]:

- **Überwachtes Lernen (Supervised Learning):** Das Programm wird anhand von gekennzeichneten Trainingsdaten angelernt. Für jedes der Trainings-

beispiele wird dem Programm also ein Zielwert übermittelt. So sollen charakteristische Zusammenhänge zwischen Einflussgrößen und erwarteter Ausgabe gefunden und anschließend auf unbekannte Eingabedaten angewandt werden. Regression und Klassifikation sind Verfahren des Überwachten Lernens.

- **Unüberwachtes Lernen (Unsupervised Learning):** Hierbei werden dem Programm Daten übergeben, die nicht gekennzeichnet sind. Es muss also eigenständig Merkmale finden, anhand derer z.B. eine Klassifikation möglich ist. Clustering und Dimensionsreduktion sind Verfahren des Unüberwachten Lernens.
- **Verstärktes Lernen (Reinforcement Learning):** Das Programm lernt aus der Interaktion mit seiner Umgebung durch Belohnung bei erwünschten Ergebnissen. Durch stetige Maximierung der Belohnung optimiert das Programm die Berechnungsergebnisse. Verstärktes Lernen ist eine zunehmend wichtige Technologie in der Robotik. Auch Googles bekanntes Alpha Go Zero beruht auf diesem Verfahren.

### 2.5.1 Künstliche neuronale Netzwerke

Künstliche neuronale Netze haben einen Großteil der Erfolge des letzten Jahrzehnts im Bereich der KI ermöglicht. Sie sind inspiriert durch das biologische Vorbild, wobei die Ähnlichkeiten zwischen natürlichen und künstlichen neuronalen Netzen begrenzt sind [Cho18].

Um künstliche neuronale Netze zu verstehen, lohnt sich ein Blick auf klassische Regressionsverfahren. Diese werden bereits seit sehr langer Zeit eingesetzt, um den Zusammenhang zwischen bestimmten Einfluss- und Zielgrößen zu ermitteln. Durch die Methode der kleinsten Quadrate können beispielsweise anhand empirischer Daten Koeffizienten gefunden werden, um ein möglichst akkurates Modell zur Beschreibung der Zielgröße zu erhalten. Die lineare Regression eignet sich zur Modellierung kontinuierlicher Größen, wohingegen die logistische Regression zur Klassifikation, also zur Vorhersage diskreter Größen vorgesehen ist [Ng16].

Bei bestimmten Problemstellungen sind die klassischen Regressionsverfahren allerdings unbrauchbar. Der Zusammenhang ist entweder zu komplex oder die Anzahl an Einflussgrößen zu hoch, um ein nützliches Modell zu ermitteln. In solchen Fällen können künstliche neuronale Netze eingesetzt werden. Sie ermöglichen die Abbildung komplizierter Zusammenhänge bei begrenzter Zahl an Eingangsgrößen. Abbildung 2.10 veranschaulicht die Struktur eines vereinfacht dargestellten künstlichen neuronalen Netzes.

Die Kreisflächen stehen für die einzelnen Neuronen bzw. Perzeptronen. Die erste Schicht auf der linken Seite besteht in diesem Beispiel aus drei solcher Perzeptronen,  $x_1$ ,  $x_2$  und  $x_3$ , die die Eingangswerte des Netzwerks darstellen. Von jedem Perzeptron der aktuellen Schicht wird ein Wert an jedes Perzeptron der nächsten Schicht weitergegeben. Dieser Wert wird durch eine Aktivierungsfunktion berechnet, die sowohl vom Wert des Perzeptrons der aktuellen Schicht als auch einer Gewichtung  $\theta$  abhängig ist. Die Aktivierungsfunktion  $a_1(x_1, \theta_{11}^1)$  stellt also die Verbindung zwischen den Perzeptronen  $x_1$  und  $a_1$  her und berechnet den Übergabewert. Dies funktioniert entsprechend für die weiteren Schichten. Die letzte Schicht stellt die

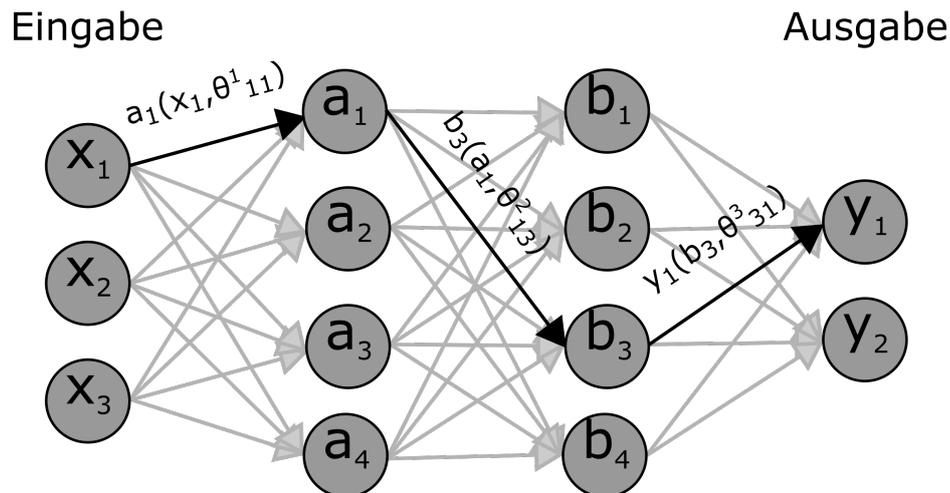


Abbildung 2.10: Struktur eines Künstlichen Neuronales Netzwerks. Die Aktivierungsfunktionen bestimmter Perzeptronen sind hervorgehoben. Sie hängen sowohl vom jeweiligen Eingabewert als auch der jeweiligen Gewichtung ab.

Ausgabewerte dar, die entweder diskret (Klassifikation) oder kontinuierlich (Regression) sein können.

Die Architektur des Modells wird durch die Anzahl der Schichten, Perzeptronen, Ein- und Ausgangswerte, Art der Aktivierungsfunktion und eine Reihe weiterer Parameter bestimmt. Die eigentliche Anpassung bzw. das Training eines Modells erfolgt mit Hilfe von Beispieldaten, deren Zielgröße bekannt ist. Die Abweichung zu den vom Modell berechneten Werten wird über eine Kosten- bzw. Verlustfunktion ermittelt. Die Ableitung der Kostenfunktion nach den Gewichtungen wird über den sogenannten Backpropagation Algorithmus bestimmt. So können die Gewichtungen angepasst werden, um die Kostenfunktion zu minimieren - der Kern des Trainingsprozesses [Wit19].

Eine grundsätzliche Voraussetzung für den Erfolg von künstlichen neuronalen Netzwerken ist eine hohe Qualität der verfügbaren Daten. Bei der Entwicklung der Modelle entfallen ca. 90 % der Arbeit auf die Vor- und Aufbereitung der Daten. Ein typisches Problem ist zudem die Überanpassung, engl. *overfitting*, der Modelle an die Trainingsdaten. Dabei werden die charakteristischen Merkmale der Trainingsdaten „zu gut“ gelernt, sodass eine Verallgemeinerung auf unbekannte Daten mit größeren Fehlern einhergeht.

Um der Überanpassung zu begegnen, werden die verfügbaren Datensätze in Trainings-, Validierungs- und Testdatensätze unterteilt. Das mit den Trainingsdaten entwickelte Modell wird anhand der Validierungsdaten geprüft, Parameter evtl. angepasst und abschließend durch den Testdatensatz getestet. Wie in Abbildung 2.11 zu sehen, kann eine Überanpassung durch abweichende Klassifizierungsgenauigkeiten in Trainings- und Validierungsdatensatz erkannt werden [Ng16].

Es gibt mehrere Methoden, um eine Überanpassung zu verhindern. Bei der Regularisierung sorgt ein zusätzlicher Term in der Kostenfunktion dafür, dass größere Werte der Gewichtungen vermieden werden. Bei sogenannten Dropout-Schichten wird der Ausgabewert zufällig ausgewählter Perzeptronen auf null gesetzt [Sri14]. Dies kann einer Überanpassung ebenso vorbeugen wie die künstliche Vergrößerung der Trainingsdatenmenge, Dataaugmentation genannt, durch randomisierte Mo-

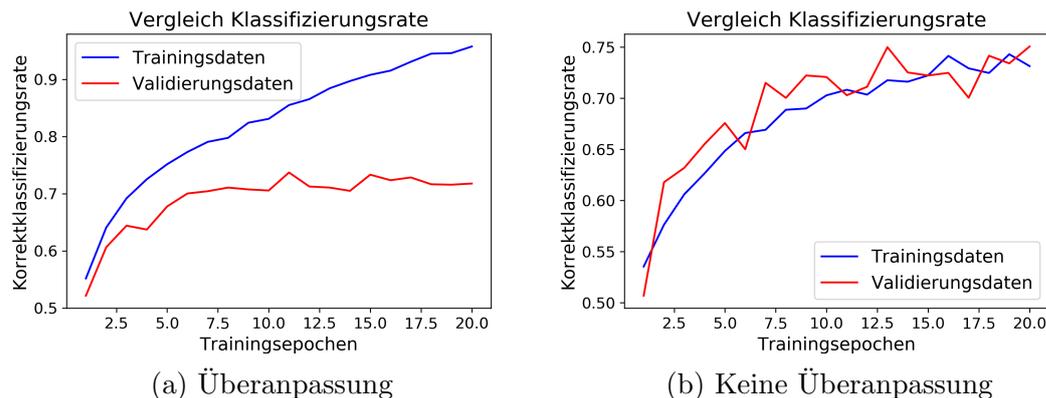


Abbildung 2.11: Lernkurven eines Neuronales Netzes zur binären Klassifizierung nach [Cho18].

difikation der Daten, beispielsweise bei Bildern eine Rotation oder Streckung. In Abbildung 2.11a erreicht das Modell eine höhere Klassifizierungsrate bei den Trainingsdaten als bei den Validierungsdaten - es kommt zur Überanpassung. Durch Datenaugmentation und Hinzufügen einer Dropout-Schicht kann eine Überanpassung beim ansonsten identischen neuronalen Netz, wie anhand der Lernkurven in Abbildung 2.11b zu sehen, verhindert werden. Eine Trainingsepoche entspricht hierbei der Berücksichtigung der gesamten Trainingsdatenmenge zur Anpassung der Gewichtungen.

In den letzten Jahren intensiver Forschung im Bereich des Deep Learnings haben sich für bestimmte Anwendungen spezialisierte Netzwerkarchitekturen etabliert. Zur Text- und Spracherkennung haben sich Recurrent Neural Networks (RNNs) durchgesetzt. Im Bereich des maschinellen Sehens haben Convolutional Neural Networks (CNNs) außerordentliche Erfolge verzeichnet. Da diese auch für die vorliegende Arbeit von Bedeutung sind, werde ich im folgenden Abschnitt noch näher auf sie eingehen.

Künstliche neuronale Netze sind prinzipiell lediglich Abbildungen von einem Vektorraum  $X$  in den Vektorraum  $Y$ . Die Weiterentwicklung von Algorithmen, die Verfügbarkeit großer Datenmengen durch das Internet und die spezielle Auslegung von Computerhardware auf das Training neuronaler Netze haben für eine immer größer werdende Bedeutung dieser Technologie gesorgt [Cho18].

### Convolutional Neural Networks

Für die automatisierte Bildverarbeitung stellte die Einführung von CNNs einen großen Fortschritt dar. Erstmals konnten zuverlässig und automatisiert Objekte auf Bildern erkannt werden, wie es zuvor nur Menschen möglich war - vorausgesetzt eine hohe Datenmenge und -qualität zum Training des Netzwerks war verfügbar [Zho20]. Die Besonderheit dieser Methode des Maschinellen Lernens drückt sich in der Anwendung einer Faltungsoperation (engl. *convolution*) aus, wie sie in Abb. 2.12 veranschaulicht wird. Eine Faltungsmatrix einer bestimmten Dimension, z.B.  $3 \times 3$ , wird dabei über das Bild bewegt und an jeder Stelle elementweise mit den Pixelwerten multipliziert. Die Summe dieser Produkte wird wiederum an die Aktivierungsfunktion weitergegeben. So entsteht die nächste Schicht des CNNs, die sogenannte Feature Map, die je nach Anzahl unterschiedlicher Faltungsmatrizen eine bestimmte Anzahl

an Kanälen aufweist. Auch die Faltungsmatrizen können mehrere Kanäle haben – drei im Falle von Farbbildern, was zu einer Dimension der Faltungsmatrizen von bspw.  $3 * 3 * 3$  führt.

Um die Größe des Netzwerks zu reduzieren, werden nach den Schichten der Faltungsoperation (Convolutional-Layer) häufig sogenannte Max-Pooling-Schichten angewandt. Dabei wird aus jedem  $2 * 2$  Bereich der Feature Map nur der maximale Wert weitergegeben – der Rest wird verworfen. So bestehen CNNs in den ersten Schichten abwechselnd aus Convolutional und Max-Pooling Schichten. Abb. 2.13 zeigt vereinfacht die Topologie eines CNNs.

In den Faltungsoperationen der ersten Schichten werden vor allem konkrete Merkmale wie beispielsweise Kanten detektiert. Die Faltungsmatrix  $M = \begin{pmatrix} 1 & 0 & 1 \\ 0 & -1 & 0 \\ -1 & -1 & -1 \end{pmatrix}$  könnte bspw. horizontale Kanten erkennen. In den späteren Schichten wiederum steigt die Abstraktion der erkannten Merkmale. Die Besonderheit ist, dass die Elemente der Faltungsmatrizen trainierbare Parameter sind, sodass nach dem Trainingsprozess solche Merkmale gut erkannt werden, die eine hohe Klassifizierungsgenauigkeit ermöglichen.

Zum Ende des Netzwerks, wenn sowohl konkrete als auch abstrakte Merkmale möglichst genau erkannt wurden, erfolgt die eigentliche Klassifizierung durch Schichten mit voll verknüpften Perzeptronen, wie sie oben schon beschrieben wurden. Oft werden zur Erkennung der Merkmale auch vortrainierte Schichten mit den Faltungsoperationen verwendet und nur die späteren voll verknüpften Schichten zur Klassifikation trainiert [Cho18].

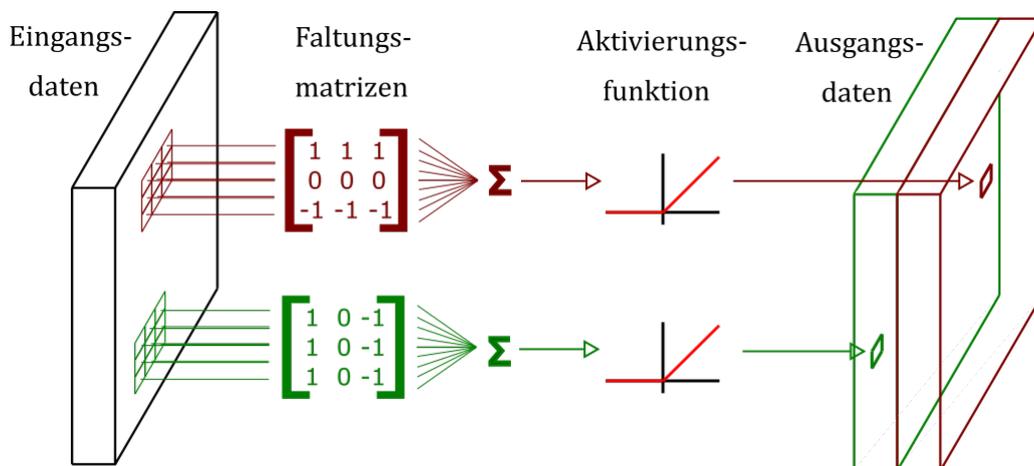


Abbildung 2.12: Faltungsoperation eines Convolutional Neural Networks: die Faltungsmatrizen werden über das Eingangsbild bewegt und dabei elementweise mit den Pixelwerten multipliziert. Die Summe wird an die Aktivierungsfunktion weitergegeben, deren Ausgangswert in der Feature Map abgelegt wird.

## Optimierungsfunktionen

Wie oben bereits erläutert werden die Gewichtungen bzw. Parameter des neuronalen Netzwerks während des Trainingsprozesses angepasst, um die Kostenfunktion zu minimieren. Dazu wird der Gradient der Kostenfunktion  $\nabla J(\theta)$  berechnet und die Gewichtungen bzw. Parameter  $\theta$  im sogenannten Gradientenabstiegsverfahren, engl. *gradient descent*, in die dem Gradienten entgegengesetzte Richtung

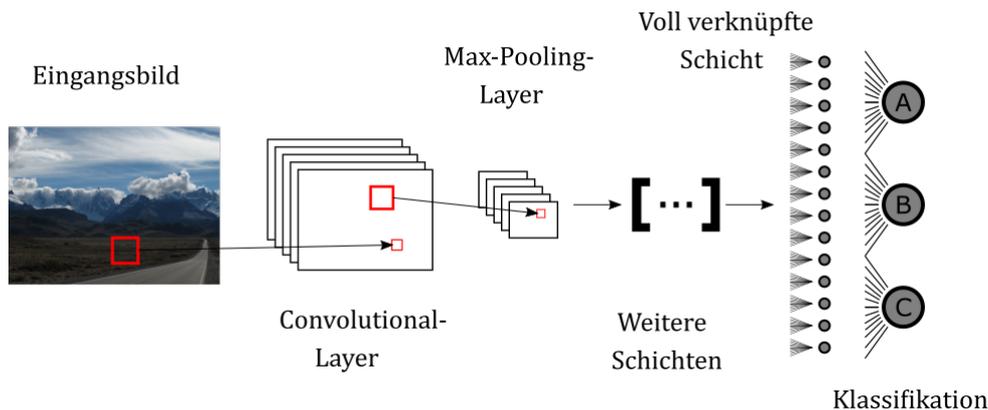


Abbildung 2.13: Topologie eines Convolutional Neural Networks.

verändert [Rud17]:

$$\theta := \theta - \eta \cdot \nabla J(\theta) \quad (2.9)$$

$\theta$ : Parameter/Gewichtungen;  $J(\theta)$ : Kostenfunktion;  $\eta$ : Lernrate

Zur Aktualisierung der Parameter gibt es allerdings eine Vielzahl von Optimierungsfunktionen, die auf unterschiedliche Art und Weise die Anpassung der Parameter vornehmen. Je nach Art des Modells, Eigenschaften der Daten sowie Anforderungen an Genauigkeit und Dauer zum Training des Modells sind verschiedene Optimierungsfunktionen zielführend einsetzbar. Beim sogenannten batch gradient descent wird der Gradient anhand des kompletten Datensatzes berechnet, ehe die Parameter gemäß Gleichung 2.9 aktualisiert werden. Effizienter ist häufig der stochastic gradient descent – dieser sorgt für eine Aktualisierung der Parameter nach jedem Trainingsbeispiel  $x^{(i)}$  mit Kennzeichnung  $y^{(i)}$  und ermöglicht somit auch online on-the-fly Anpassungen, wie sie bei flexibel wachsenden Datensätzen nötig sind [Rud17]:

$$\theta := \theta - \eta \cdot \nabla J(\theta, x^{(i)}, y^{(i)}) \quad (2.10)$$

$x^{(i)}$ : i-tes Trainingsbeispiel;  $y^{(i)}$ : i-te Kennzeichnung (Label)

Zudem gibt es mini-batch gradient descent, bei der jeweils eine bestimmte Anzahl an Trainingsbeispielen – die Batch-Größe – aus dem Gesamt-Datensatz zur Berechnung des Gradienten und der anschließenden Parameter-Anpassung verwendet wird.

Die Herausforderung bei der Minimierung der Kostenfunktion ist, das globale Minimum möglichst schnell zu finden. Dabei besteht stets die Gefahr, nur lokale Minima zu finden, aus dem die Optimierungsfunktion nicht mehr "heraus findet". Außerdem kann es passieren, dass bei falscher Lernrate die Kostenfunktion nicht zum Minimum konvergiert, sondern sich sogar weiter von diesem entfernt. Um diesen Herausforderungen zu begegnen, wurde eine Reihe von Optimierungsfunktionen wie Momentum, Nesterov accelerated gradient, Adagrad, Adadelta, RMSprop, Adam und Nadam entwickelt [Haj21]. Vor allem Adam und Nadam konnten im Zusammenhang mit Bildklassifizierungsaufgaben durch CNNs gute Ergebnisse erzielen [Dog18]. Da diese auch für den weiteren Verlauf dieser Arbeit von Bedeutung sind, sollen sie hier näher beleuchtet werden.

Adam steht für *Adaptive moment estimation* [Kin14] und die Idee hinter dieser Op-

timierungsfunktion ist die Anpassung der Lernrate für jeden Parameter. Jede Aktualisierung eines Parameters am Zeitschritt  $t$  erfolgt dabei unter Berücksichtigung exponentiell sinkender Durchschnittswerte vorheriger Gradienten. Dazu werden das erste und zweite Moment der Gradienten wie folgt abgeschätzt [Rud17]:

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) \nabla J(\theta) \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) (\nabla J(\theta))^2 \end{aligned} \quad (2.11)$$

$m_t, v_t$ : Abschätzungen erstes und zweites Moment;  $\beta_1, \beta_2$ : Zerfallsraten

Da  $m_t$  und  $v_t$  als Nullvektoren initialisiert werden, kann es zu einer Verzerrung in Richtung Null kommen. Diesem Effekt wird mit angepassten Termen für  $\hat{m}_t$  und  $\hat{v}_t$  entgegen gewirkt [Rud17]:

$$\begin{aligned} \hat{m}_t &= \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t} \end{aligned} \quad (2.12)$$

Dies führt schließlich zur Formel, die die Anpassungen der Parameter durch die Adam-Optimierungsfunktion vorgibt [Rud17]:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \quad (2.13)$$

$\epsilon$ : Ausgleichsterm, um Null-Nenner zu vermeiden

Für die Zerfallsraten wird für  $\beta_1$  ein Standardwert von 0,9, für  $\beta_2$  ein Wert von 0,999 und für den Ausgleichsterm  $\epsilon$  ein Wert von  $10^{-8}$  empfohlen [Rud17].

Die Adam-Optimierungsfunktion ist sehr verbreitet, denn sie erfordert relativ geringe Rechner- und Speicherkapazitäten. Eine Erweiterung davon ist die Nadam-Optimierungsfunktion, was für *Nesterov-accelerated adaptive moment estimation* steht [Haj21]. Durch einen zusätzlichen Term, der wiederum den Gradienten der Kostenfunktion enthält, kann der Lernprozess durch die Nadam-Optimierungsfunktion beschleunigt werden [Rud17]:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \left( \beta_1 \hat{m}_t + \frac{(1 - \beta_1) \nabla J(\theta)}{1 - \beta_1^t} \right) \quad (2.14)$$

Die Wahl der richtigen Optimierungsfunktion ist also entscheidend für einen erfolgreichen Trainingsprozess des Datenmodells. Deshalb ist es häufig sinnvoll, verschiedene Optimierungsfunktionen zu testen. Ob ein Modell konvergiert, kann trotz adaptiver Moment-Abschätzung auch damit zusammen hängen, welche Lernrate  $\eta$  gewählt wird.

## 2.5.2 Maschinelles Lernen in der additiven Fertigung

Die Methoden des maschinellen Lernens kommen teilweise auch in der additiven Fertigung bereits zum Einsatz. In der Literatur wird nicht nur der potentielle Nutzen zur Überwachung des Fertigungsprozesses, sondern auch zur Qualitätssicherung in der gesamten Fertigungskette betont [Sin21, Wan20]. So können beispielsweise Fehler beim Bauteildesign oder der Nachbearbeitung vermieden werden. Im Folgenden

wird allerdings nur auf solche Studien eingegangen, deren Gegenstand das maschinelle Lernen zur Evaluation von Emissionen des Laserstrahlprozesses ist.

Trainierbare Algorithmen sind insbesondere zur Klassifikation verschiedener Prozesszustände mittels einer Prozessüberwachung von großem Nutzen. Dabei können unterschiedliche Sensoriken und Algorithmen miteinander kombiniert werden. Abbildung 2.14 gibt einen Überblick über Sensoriken, Methoden der Datenerhebung sowie den verschiedenen Datenmodellen, die im Kontext der additiven Fertigung in einer Reihe von Studien untersucht werden. Zur Bewertung der Literatur ist wesentlich, die durch den jeweiligen Detektor bedingte Art der erhobenen Datensignale, die zur Datenkennzeichnung verwendete Analysetechnik sowie den Datenalgorithmus und die Bewertungsmetrik zu berücksichtigen. Abbildung 2.14 zeigt, dass sowohl klassische Verfahren des maschinellen Lernens, wie das Verfahren der Support Vector Machine (SVM), als auch Methoden des Deep Learning eingesetzt werden. Dabei werden neben herkömmlichen Kameras und Photodioden auch Pyrometer, Short-wave infrared (SWIR)-Kameras oder sogar Mikrophone zur Erfassung akustischer Signale verwendet [Qi19].

Der Ansatz von Gobert et al. [Gob18] zur Prozessüberwachung kommt beispielsweise ohne Deep Learning aus und setzt auf eine SVM. Mit einer Spiegelreflexkamera in Off-Axis Konfiguration werden mehrere Bilder pro Schicht aufgenommen. Mit Hilfe von CT-Scans können fehlerhafte Bereiche des Bauteils identifiziert und mit den Aufnahmen verknüpft werden. Multidimensionale Merkmale werden aus den Bildern extrahiert und zum Training der SVM genutzt. So kann eine Binärklassifikation in iO- und niO-Bauteile mit einer Genauigkeit von 80 % erreicht werden, wobei Anbindefehler, Porosität, Einschlüsse und Risse erkannt werden. Scime et al. [Sci19]

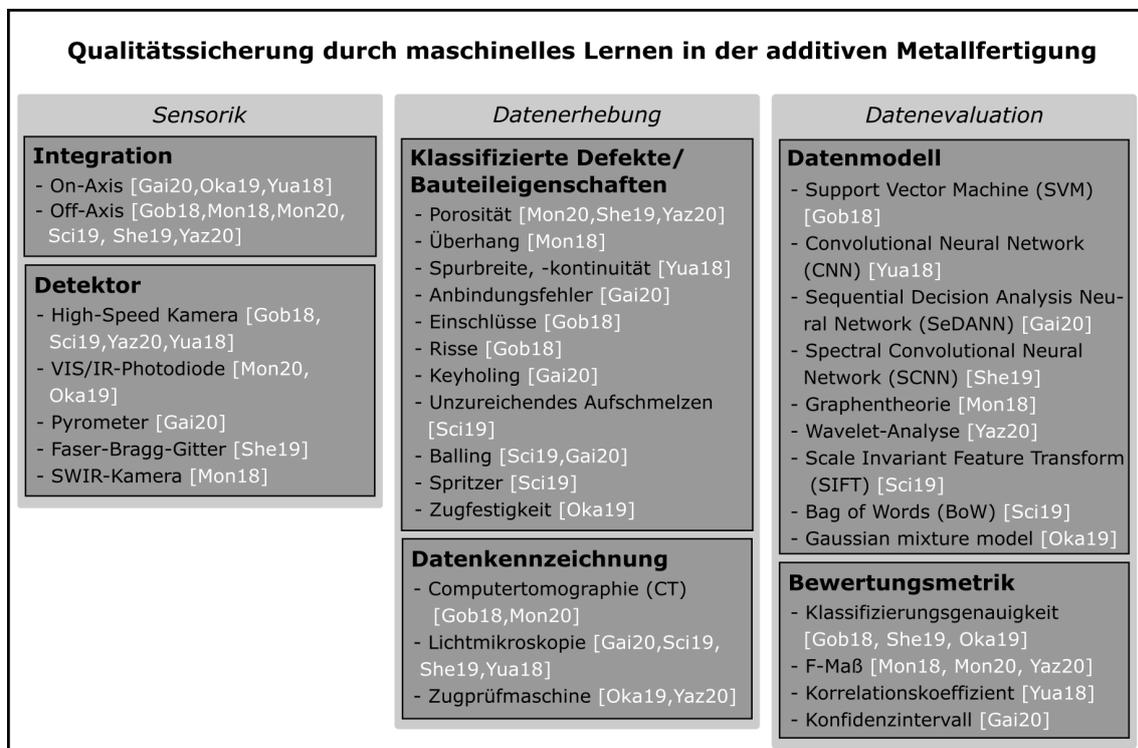


Abbildung 2.14: Überblick über Studien zum maschinellen Lernen in der additiven Metallfertigung.

berichten ebenfalls vom Einsatz einer SVM, wozu sie mit einer Off-Axis High-Speed Kamera die fünf Schmelzbadzustände wünschenswert, balling, schweres keyholing, keyholing Porosität sowie unzureichendes Aufschmelzen klassifizieren. Zunächst erfolgt unüberwachtes Lernen zur Erkennung charakteristischer Unterschiede, wozu ein Scale Invariant Feature Transform (SIFT) eingesetzt wird, um Merkmale der Schmelzbadmorphologie unabhängig von der Schmelzbadgröße zu extrahieren. Mit der Bag-of-Words Technik werden die Daten anschließend weiterverarbeitet, bevor sie im überwachten Training durch die SVM klassifiziert werden.

Das maschinelle Lernen wird im Kontext der additiven Fertigung aber nicht nur für Kameradaten eingesetzt. Convolutional Neural Networks beispielsweise werden auch zur Verwertung akustischer Signale verwendet [She19]. Diese werden über Faser-Bragg-Gitter aufgezeichnet, die sich in der Baukammer in 20 cm Abstand von der Prozesszone befinden. So können drei verschiedene Porositätsniveaus (0,07%, 0,3 % und 1,42 %) mit Hilfe bewährter Datenmodelle wie ResNet und Xception mit einer Genauigkeit von 78 - 91 % klassifiziert werden.

Yuan et al. [Yua18] wiederum verwerten mit Hilfe von Convolutional Neural Networks Daten einer On-Axis High-Speed Kamera. Der Durchschnitt und die Standardabweichung der Schmelzspurbreite können mittels Regression jeweils mit einem Bestimmtheitsmaß von  $R^2 = 0.93$  und  $R^2 = 0.70$  vorhergesagt werden. Zudem kann die Kontinuität der Schmelzspurbreite mit einer Genauigkeit von 93,1 % klassifiziert werden. Gaikwad et al. [Gai20] setzen neben einer On-Axis High-Speed Kamera auch ein On-Axis Pyrometer ein. Deren Signale werden zusammengeführt und in einem sogenannten Sequential Decision Analysis Neural Network (SeDANN) verarbeitet. Dieses Datenmodell erlaubt anders als üblich beim maschinellen Lernen die Integration von Vorwissen über den physikalischen Prozessablauf. Beim Laserstrahlschmelzen von Einzelspuren kann so beispielsweise die Spurbreite mit einem Bestimmtheitsmaß von  $R^2 = 0.87$  vorhergesagt werden.

Auch zur Klassifizierung eindimensionaler Daten aus On-Axis Photodioden wird maschinelles Lernen eingesetzt [Oka19]. Dabei werden Daten von jeweils einer IR- und VIS-Photodiode in einem sogenannten halbüberwachten (semi-supervised) Gaussian mixture model zur Vorhersage der Zugfestigkeit benutzt. Hierzu werden sowohl gekennzeichnete Daten von zertifizierten als auch ungekennzeichnete Daten von unzertifizierten Prozessen verwendet, was die Methode besonders kostengünstig macht. So können iO-Bauteile mit einer Genauigkeit von 77 % erkannt werden.

Für den weiteren Verlauf der vorliegenden Arbeit sind vor allem solche Studien von Relevanz, die die Anomalie-Detektion im LPBF-Prozess untersuchen und als Bewertungsmetrik das sogenannte F-Maß verwenden. Zur Bewertung der Erkennungszuverlässigkeit von Prozessdefekten wird häufig dieses F-Maß, engl. *F-score* oder *F1-score*, verwendet, welches sich als harmonisches Mittel aus Genauigkeit und Sensitivität berechnet. Insbesondere im Hinblick auf unausgewogene Datensätze, die deutlich mehr iO- als niO-Daten enthalten, stellt das F-Maß eine sinnvolle Metrik zur Bewertung des Datenmodells dar.

Tabelle 2.3 fasst mehrere Studien zur Erkennung von Prozessfehlern beim Pulverbettverfahren zusammen, deren Ergebnisse in Form des F-Maßes als Referenz für die Untersuchungen dieser Arbeit dienen sollen. Montazeri et al. [Mon18] verfolgen den Ansatz, eine Kombination mehrerer Sensoriken zu untersuchen, mit dem Ziel, teure Kameras möglichst durch günstige Sensoren, wie Photodioden, ersetzen zu können. Dazu werden eine Photodiode, eine High-Speed Kamera sowie eine short-wave in-

Tabelle 2.3: Studien zur Erkennung von Prozessfehlern beim Laser Powder Bed Fusion

Quelle	F-Maß	Erkennung von...	Datenmodell
Montazeri et al. 2018 [Mon18]	Photodetektor: 79 % High-Speed VIS-Kamera: 83 % SWIR-Thermokamera: 95 %	Überhang	Graphentheorie
Montazeri et al. 2020 [Mon20]	Multispektraler Photodetektor: 90 %	Poren	Maschinelles Lernen
Yazdi et al. 2020 [Yaz20]	High-Speed Kamera: 97 %	Poren	Maschinelles Lernen Wavelet- und Texturanalyse

frared (SWIR) Kamera off-axial in die LPBF-Anlage integriert. Es wird ermittelt, inwiefern die Sensoren verschiedene Prozesszustände, insbesondere die bei Überhang veränderte thermische Signatur, erkennen. Zur Verarbeitung der Sensorsignale werden neben verschiedenen Methoden des maschinellen Lernens weitere Verfahren zur Datenverarbeitung angewandt. Das höchste F-Maß zur Unterscheidung von Vollmaterial und Überhängen von  $40,5^\circ$  wird dabei mit der Graphentheorie erzielt. Mit den Daten des Photodetektors, der High-Speed Kamera sowie der SWIR-Kamera werden damit F-Maße von 79 %, 83 % und 95 % erzielt.

Um die Erkennungszuverlässigkeit auch ohne Kameras zu erhöhen, setzen Montazeri et al. in einer weiteren Studie [Mon20] zwei Off-Axis Photodioden simultan ein. Beim Aufbau von Zylindern detektieren die Dioden das Prozessleuchten bei einer Wellenlänge von 520 und 530 nm mit einer Halbwertsbreite von jeweils 10 nm. Zur Datenkennzeichnung werden CT-Aufnahmen der Zylinder erstellt und die Porosität schichtweise erfasst, wobei die Porosität  $P$  aus dem Verhältnis der an Poren beteiligten Pixeln zur Gesamtzahl der Pixel bestimmt wird. Aus den Sensordaten werden Graph Fourier Transform Koeffizienten gebildet, die wiederum als Eingangsgrößen für Methoden des maschinellen Lernens dienen. Bei der Unterscheidung zwischen drei Porositätsniveaus – gering:  $P < 0,5\%$ , mittel:  $0,5\% < P < 1,2\%$  und hoch:  $P > 1,2\%$  – kann auf diese Weise ein F-Maß von 80 % erreicht werden. Geht es lediglich darum, vorherzusagen, ob die Porosität über oder unter 0,5 % liegt, kann ein F-Maß von 90 % erreicht werden.

Desweiteren wird vom Einsatz eines hybriden neuronalen Netzes berichtet, das mit zwei Arten von Eingangsgrößen darauf trainiert wird, Poren beim Aufbau von Zylindern zu erkennen [Yaz20]. Statistische Merkmale, die durch Wavelet-Transformation und Texturanalyse extrahiert werden, in Kombination mit ursprünglichen Pulverbettaufnahmen einer Off-Axis Kamera verhelfen dem Datenmodell zu erhöhter Erkennungsgenauigkeit. Es werden mehrere Methoden des maschinellen Lernens miteinander verglichen, wobei der vorgeschlagene Ansatz ein F-Maß von 97 % bei der Erkennung von Poren erreicht.

## 2.6 Fazit

Der dargestellte Stand der Forschung und Technik macht deutlich, dass das erhebliche Potenzial der additiven Metallfertigung noch nicht in vollem Maße industriell ausgeschöpft werden kann. Ein wesentliches Hindernis ist dabei die teils eingeschränkte Reproduzierbarkeit sowie fehlende Qualitätssicherung während des additiven Fertigungsprozesses.

Die beträchtlichen Fortschritte sowohl im Bereich der Sensorik, als auch bezüglich der Möglichkeiten der intelligenten Datenauswertung legen deren Einsatz zur Qualitätssicherung in der additiven Fertigung nahe. Erste Untersuchungen zeigen, dass Prozessemissionen in Form von elektromagnetischer Strahlung reichhaltige Informationen über die Qualität des Prozesses enthalten. Die hyperspektrale Bildgebung ermöglicht eine genauere Aufschlüsselung dieser Informationen in spektrale Bänder. Dass dadurch auch genauere Informationen über den Fertigungsprozess gewonnen werden können, ist die Arbeitshypothese der vorliegenden Arbeit. Es wird zwar nicht erwartet, chemische Spektrallinien zu detektieren, aber der spezifische Emissionsgrad eines realen Strahlers kann auch bei Wärmestrahlung zu einem charakteristischen Spektrum führen. Zur Entschlüsselung dieser Informationen bietet sich der Einsatz von Methoden des maschinellen Lernens an. Insbesondere CNNs eignen sich zur Bilderkennung von Merkmalen, die zur Klassifizierung eingesetzt werden können. Diese Methoden zur Datenauswertung sind bereits mit andersartigen Sensoren erfolgreich zur Vorhersage von Bauteileigenschaften und Prozessfehlern in der additiven Fertigung eingesetzt worden.

# 3 Zielsetzung und Vorgehensweise

## 3.1 Lösungsweg

Der Ausgangspunkt dieser Arbeit ist der in der Einleitung sowie im Stand der Technik identifizierte Handlungsbedarf zur in situ Erhebung industriell relevanter Messdaten in der additiven Metallfertigung. Bisher untersuchte Methoden zur Prozessüberwachung zeigten diesbezüglich zwar bereits Erfolge. Fortschritte in der Sensortechnologie sowie bei Methoden zur intelligenten Datenauswertung könnten die Zuverlässigkeit einer solchen Qualitätssicherung aber weiter steigern.

Im Folgenden soll deshalb systematisch untersucht werden, inwiefern eine Flächen-Scan Hyperspektralkamera, deren Daten über ein CNN ausgewertet werden, die Vorhersage wichtiger Bauteileigenschaften auf der Grundlage von Prozessaufnahmen ermöglicht. Die Vorgehensweise hierzu ist in Abbildung 3.1 illustriert: Nach Beschreibung der Ausgangssituation und des Standes der Forschung erfolgt eine Charakterisierung der neuartigen Sensorik. Zunächst wird in Kapitel 4 geprüft, ob die Kamera reproduzierbare Messergebnisse liefert. Dazu werden Aufnahmen eines Schwarzstrahlers mit denen eines einfachen Laserschweißprozesses verglichen. Anschließend folgt in Kapitel 5 die spektrale Charakterisierung der Kamera, wobei Aufnahmen eines Monochromators bei verschiedenen Wellenlängen von der Kamera und von einem Spektrometer verglichen werden.

In Kapitel 6 wird untersucht, inwiefern die Oberflächenrauheit  $R_z$  beim Laserstrahlschmelzen der Magnesiumlegierung WE43 vorhergesagt werden kann. Dafür werden mehrere Parametersätze angewandt, um einzelne Schichten zu erzeugen. Die Prozessaufnahmen werden mit den durch ein Konfokalmikroskop ermittelten Oberflächenrauheiten gekennzeichnet. Die gekennzeichneten Prozessaufnahmen dienen dem Training eines speziell ausgelegten CNNs. Die Genauigkeit der Vorhersage durch das CNN wird schließlich über Testdaten bewertet, die nicht für das Training verwendet werden.

Für das eigentliche Ziel – Fertigungsdefekte und Bauteileigenschaften orts aufgelöst zu erkennen – werden die Prozessaufnahmen der Kamera mit Maschinendaten wie die Galvanometer-Laserscanner Position in Kapitel 7 zusammengeführt. Dazu wird ein Field Programmable Gate Array (FPGA) ausgelegt und programmiert sowie eine Platine als Interface entworfen und gefertigt. Die Hyperspektralkamera kann somit gezielt bei bestimmten Scanner Positionen getriggert werden. So können Aufnahmen von künstlich erzeugten Fertigungsdefekten durch ins Pulverbett gelegte Eisenspäne

gewonnen werden. Das CNN wird im Anschluss darauf trainiert, diese Defekte zu erkennen. Die entscheidende Herausforderung bei dieser Anomalie-Detektion besteht in der Unausgewogenheit des Datensatzes, denn es stehen deutlich weniger niO-, also Fehler-Aufnahmen des Prozesses als iO-Aufnahmen zur Verfügung. Dieses System zur Prozessüberwachung wird anschließend hinsichtlich verschiedener Metriken und insbesondere dem F-Maß bewertet.

Im abschließenden Kapitel 8 werden die Untersuchungen zusammengefasst, die neuen Erkenntnisse bewertet und in den Kontext des bisherigen Standes der Forschung gesetzt. Zudem wird der mögliche industrielle Nutzen beleuchtet sowie ein Ausblick auf zukünftige Forschungsarbeiten in dem Bereich gegeben.

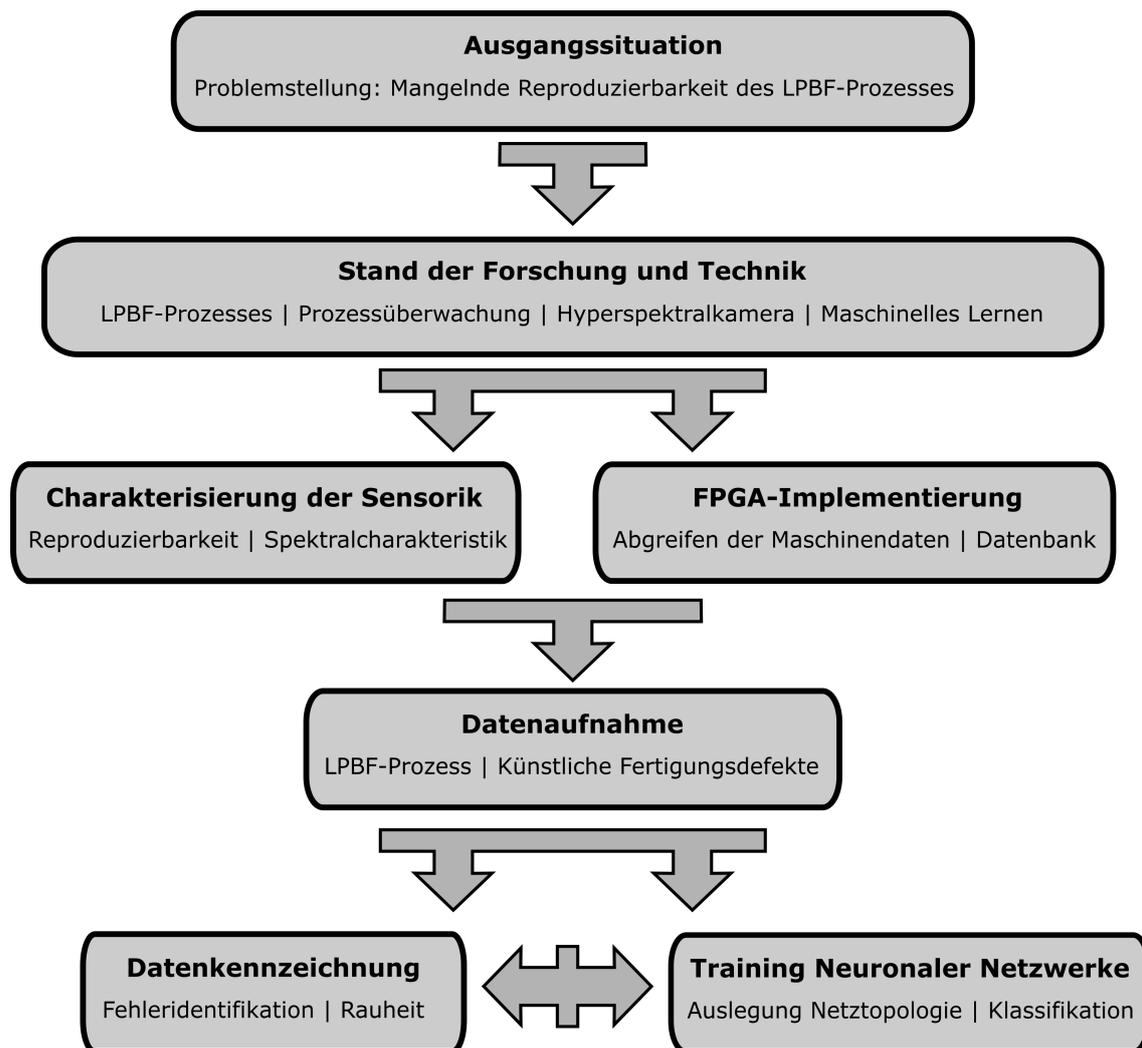


Abbildung 3.1: Lösungsplan zur ortsaufgelösten Erkennung von Fertigungsdefekten.

# 4 Hyperspektralkamera und Reproduzierbarkeit der Messergebnisse

## 4.1 Flächen-Hyperspektralkamera

Die in dieser Arbeit eingesetzte Sensorik ist das Modell MQO22HG-IM-SM5X5-NIR der Firma Ximea GmbH. Diese Flächen-Hyperspektralkamera beruht auf einem CMOS-Sensor, der 2048 \* 1088 Pixel umfasst. Wie in Abschnitt 2.4.2 beschrieben, wird die spektrale Aufteilung des eintreffenden Lichts durch Fabry-Pérot Interferometer erreicht, die in der Funktion eines Filters auf die Pixel der Kamera beschichtet sind. Abbildung 4.1a zeigt schematisch den Aufbau der Kamera einschließlich Schutzfenster, Filter-Array und CMOS-Chip. Abbildung 4.1b veranschaulicht die Anordnung der 25 verschiedenen Fabry-Pérot Interferometer (FPI), die in Mosaiken von 5 \* 5 mit einem x- und y-offset auf dem CMOS-Bildsensor liegen.

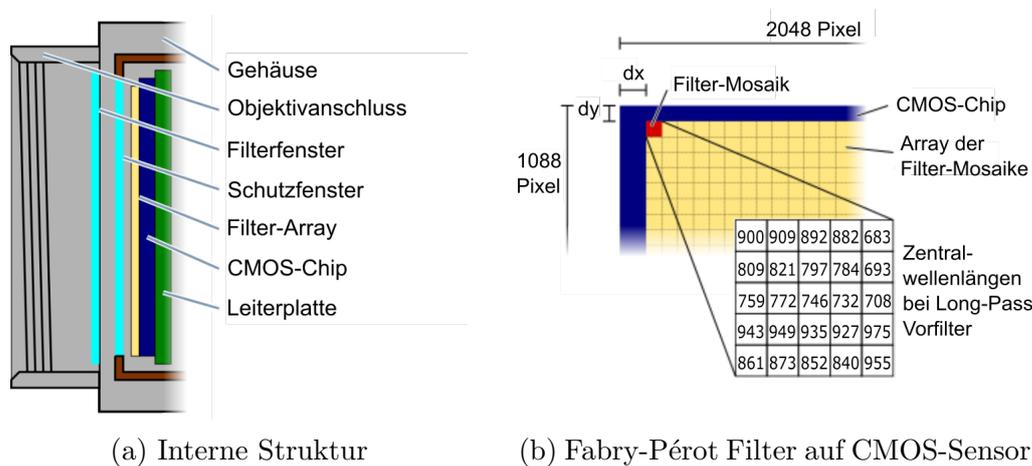


Abbildung 4.1: Interne Struktur der Hyperspektralkamera: Die Beschichtung durch Fabry-Pérot Interferometer ermöglicht pixelgenaue Wellenlängenselektivität

Die Spezifikationen der Hyperspektralkamera sind in Tabelle 4.1 dargestellt. Die kompakte Kamera kann per C-Mount Anschluss mit einem Objektiv verbunden und mit einer Grauwertauflösung von wahlweise acht oder zehn Pixeln betrieben werden. Bei Ausnutzung aller Pixel und somit voller Auflösung ist eine Bildrate von 170 Frames per second (fps) möglich, die bei geringerer Auflösung gesteigert werden kann. Weitere Spezifikationen zum CMOS-Sensor der Kamera sind in Anhang A.1

Tabelle 4.1: Spezifikationen der Flächen-Hyperspektralkamera.

Spezifikation	<b>Ximea MQO22HG-IM-SM5X5-NIR</b>
Auflösung	Original: 2048 x 1088 Räumlich: 409 x 217
Sensortyp	2/3" CMOS, mit FPI-Filtern beschichtet
Spektralbereich	600 - 975 nm; 25 Bänder
Bildrate	170 fps bei voller Auflösung
Bit-Tiefe	Wahlweise 8 oder 10
Maße	26 mm * 26 mm * 31 mm
Gewicht	32 g

zu finden.

Das zur Verwendung mit der Hyperspektralkamera empfohlene Objektiv hat eine Festbrennweite von 35 mm. Die genauen Spezifikationen sind in Tabelle 4.2 gelistet. Der minimale Arbeitsabstand beträgt 165 mm und kann durch Variation des Abstands zwischen Objektiv und Sensor mit Hilfe eines Drehrads beliebig vergrößert werden.

## 4.2 Reproduzierbarkeit der Messergebnisse

Die Voraussetzung für eine Qualitätssicherung mit Hilfe einer Sensorik ist die Reproduzierbarkeit ihrer Messergebnisse. Die Reproduzierbarkeit der mit der Hyperspektralkamera aufgenommenen Rohdaten soll in diesem Kapitel anhand von einfachen Versuchsaufbauten untersucht werden.

Im ersten Schritt werden dazu Aufnahmen eines Schwarzstrahlers bei bestimmter Temperatur erfasst und die Abweichungen in jedem Pixel ermittelt. Um die Reproduzierbarkeit von Aufnahmen eines einfachen Laserstrahlschmelzprozesses zu bewerten, werden im zweiten Schritt Punktschweißungen durchgeführt.

### 4.2.1 Schwarzstrahler

Ein Schwarzstrahler im thermodynamischen Gleichgewicht strahlt zeitinvariant konstante Strahlung aus. Insofern eignet sich diese Art von Lichtquelle, um die Streuung der mit der Hyperspektralkamera gemessenen Grauwerte zu untersuchen.

Für die Messungen wird ein Schwarzstrahler auf die Temperaturen 1000°C, 1050°C und 1100°C eingestellt, sodass an der Öffnung mehrere Messreihen mit der Kamera

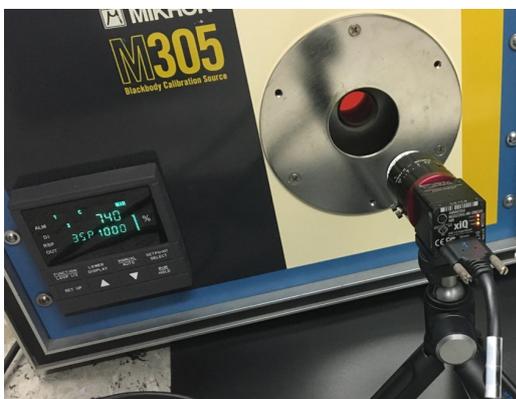
Tabelle 4.2: Spezifikationen des mitgelieferten Standard-Objektivs.

Spezifikation	Edmund Optics Objektiv mit Festbrennweite
Brennweite	35 mm
Arbeitsabstand	165 mm - $\infty$
Numerische Apertur	0,021
Horizontales Bildfeld	39,2 mm – 14,2°
Blende	f/1,65 – f/22

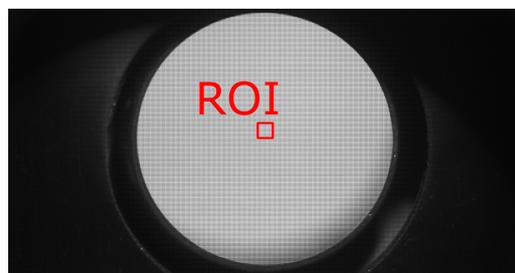
aufgenommen werden können. Abbildung 4.2a zeigt den Versuchsaufbau, Abbildung 4.2b das entsprechende Kamerabild. Die Belichtungszeit wird so eingestellt, dass der Dynamikbereich der Kamera vollständig ausgenutzt wird.

Um dieselbe Datenmenge wie in den folgenden Punktschmelzungen zu erzeugen, werden pro Temperatur 60.000 Aufnahmen gemacht. Nach jeweils 20.000 Aufnahmen wird die Kamera aus- und wieder eingeschaltet, um dadurch entstehende Streuungen mit zu berücksichtigen. Abbildung 4.3 zeigt in 4.3a ein Rohbild der Region of Interest (ROI) und in 4.3b die relative Standardabweichung des Grauwerts je Pixel. Die relative Standardabweichung ist der Quotient aus Standardabweichung und Mittelwert. Im Folgenden wird sie in Prozent berechnet.

Im Rohbild lassen sich die  $5 * 5$  Muster der Mosaike erkennen, die durch die 25 Interferenzfilter mit unterschiedlich wellenlängenabhängiger Transmission bedingt sind. Auch in der Abbildung der relativen Standardabweichung lassen sich die Muster der Mosaike erkennen. Sie ist in solchen Pixeln am niedrigsten, deren Interferenzfilter im entsprechenden Wellenlängenbereich die höchste Transmission aufweisen und somit zu den höchsten Grauwerten führen. Dies lässt darauf schließen, dass die absolute



(a) Versuchsaufbau



(b) Kamerabild

Abbildung 4.2: Versuchsaufbau für Messungen am Schwarzstrahler.

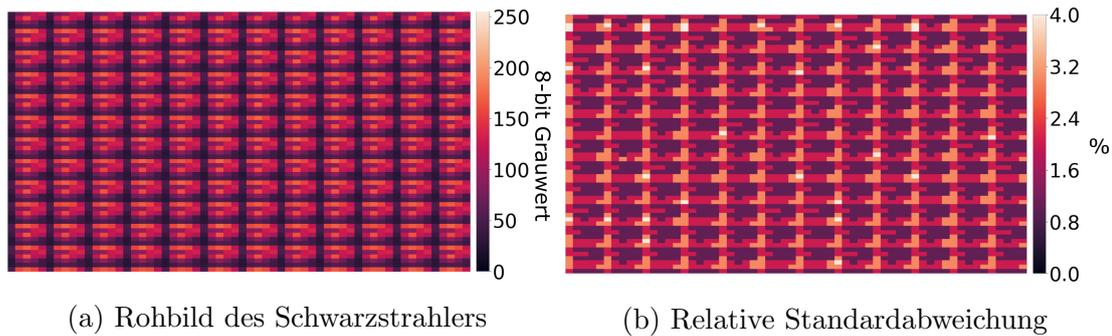


Abbildung 4.3: Aufnahmen des Schwarzstrahlers bei 1100 °C bei einem 60 \* 60 Pixel großen Ausschnitt. (a) zeigt das Rohbild mit Grauwerten von 0 – 255 und (b) die relative Standardabweichung der Grauwerte in Prozent über 60.000 Aufnahmen.

Standardabweichung unabhängig vom Grauwert ist.

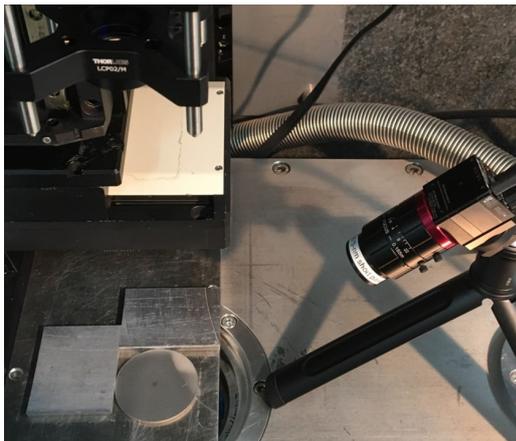
Tabelle 4.3 bestätigt, dass die Streuung der Grauwerte unabhängig vom Absolutwert im Bereich von 1 – 2 8-bit Grauwerten liegt. Die hohen relativen Standardabweichungen von bis zu 7 % werden somit nur bei kleinen Grauwerten gemessen. Die relative Standardabweichung bei mittleren und höheren Grauwerten liegt mit 1 – 4 % im für eine Messsensorik akzeptablen Bereich. Die Messergebnisse der Hyperspektralkamera sind also auf Basis dieser Ergebnisse innerhalb eines hinreichend kleinen Toleranzbereiches reproduzierbar. Die inhärente Streuung der Kamera für diese Umgebungsbedingungen entspricht somit maximal den hier bestimmten Werten, denn es wird angenommen, dass auch die gemessene Schwarzkörperstrahlung einer gewissen Streuung unterliegt.

Tabelle 4.3: Reproduzierbarkeit der Messergebnisse am Schwarzstrahler.

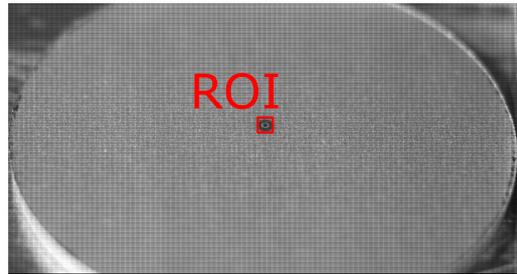
Temperatur	Anzahl Aufnahmen	Rel. Standardabweichung der Grauwerte	Abs. Standardabweichung der Grauwerte [8-bit Wert]
1000°C	60.000	2 – 7 %	1 – 2
1050°C	60.000	1 – 6 %	1 – 2
1100°C	60.000	1 – 4 %	1 – 2

## 4.2.2 Punktschweißungen

Die statische Exposition eines Lasers auf eine Metalloberfläche stellt den einfachsten Fall eines Laserstrahlschmelzprozesses dar. Insofern eignen sich solche Punktschweißungen insbesondere zur Bewertung der Reproduzierbarkeit der Prozessaufnahmen. Es werden 30 Punktschweißungen am Mittelpunkt ebenso vieler baugleicher Edelstahlsubstrate durchgeführt, sodass die Ausgangstemperatur konstant gehalten wird. Bei jeder Schweißung wird also ein neues, sandgestrahltes und mit Ethanol gereinigtes Substrat verwendet. Die Hyperspektralkamera wird seitlich platziert, die Prozesszone fokussiert und die ROI definiert. In Probeaufnahmen wird eine Belichtungszeit von 40  $\mu$ s festgelegt. Abbildung 4.4a zeigt den Versuchsaufbau mit Hyperspektralkamera, Edelstahlsubstrat und Optikhalterung. In Abbildung 4.4b ist das Kamerabild der Hyperspektralkamera bei hoher Belichtungszeit zu sehen. Zudem ist der kleine



(a) Versuchsaufbau



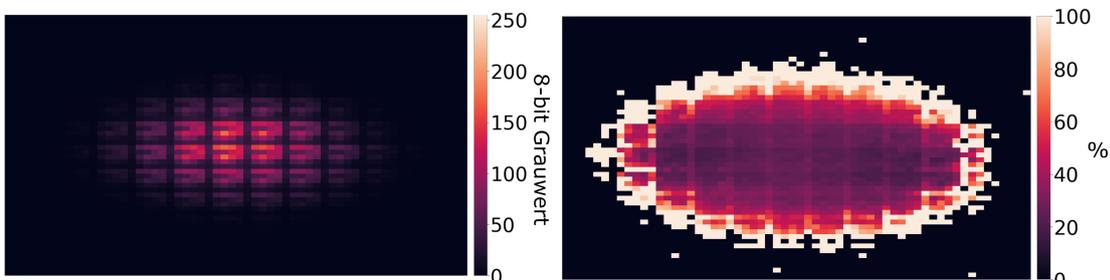
(b) Kamerabild

Abbildung 4.4: Versuchsaufbau für Punktschweißungen an Edelstahlsubstraten.

Bereich der ROI hervorgehoben, die während der Versuche eingestellt wird.

Ein Diodenlaser (nlight e18.1400976105) mit einer zentralen Wellenlänge von 981,6 nm wird mit einem Diodenstrom von 8,6 A betrieben, was ca. 100 W entspricht. Weitere Spezifikationen des Diodenlasers befinden sich in Anhang A.2. Eine einzelne Laserbelichtung dauert fünf Sekunden, wobei die Aufnahme der Kamera über ein Trigger-Signal zeitgleich mit dem Einschalten des Lasers für vier Sekunden bei 500 Aufnahmen pro Sekunde gestartet wird. Die Spotgröße des Lasers beträgt ca. 1 mm. So können für jede der 30 Punktschweißungen 2000 Aufnahmen gespeichert werden. Jede Aufnahme entspricht einem bestimmten Zeitpunkt in der Belichtung, sodass jeweils 30 Aufnahmen miteinander verglichen und zur Bewertung der Reproduzierbarkeit verwendet werden können. Abbildung 4.5 zeigt Informationen über Aufnahmen, die nach  $t = 700 \cdot 2 \text{ ms} = 1400 \text{ ms}$  nach Auslösung des Trigger-Signals aufgenommen werden. In 4.5a ist eines der Rohbilder zu sehen, während 4.5b die relative Standardabweichung der Grauwerte in jedem Pixel über alle 30 Aufnahmen zeigt, die zu diesem Zeitpunkt einer Punktschmelzung aufgenommen werden. Es ist zu erkennen, dass die Streuung in den Randbereichen des Laserspots ganz besonders hoch ist und zum Zentrum hin abnimmt.

Abbildung 4.6 zeigt sowohl die absolute als auch die relative Standardabweichung



(a) Rohbild der Punktschmelzung

(b) Relative Standardabweichung

Abbildung 4.5: Aufnahmen von Punktschweißungen auf Edelstahlsubstraten. (a) zeigt das Rohbild der 700. Aufnahme einer Messreihe und (b) die relative Standardabweichung in jedem Pixel über alle 700. Aufnahmen der 30 Messreihen.

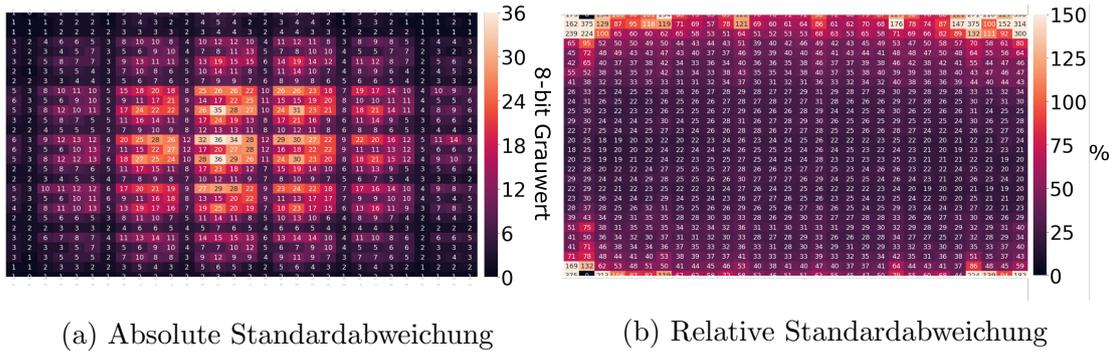


Abbildung 4.6: Absolute sowie relative Standardabweichung der Grauwerte mit Vergrößerung des relevanten Bereichs sowie Angabe der Pixelwerte.

der Grauwerte in vergrößerter Form, sodass die dunklen Ränder abgeschnitten sind. Im Bild der absoluten Standardabweichung lassen sich sehr deutlich die  $5 * 5$  Muster der Mosaike erkennen. Interessanterweise sind anders als bei den Messungen am Schwarzstrahler also die absoluten Standardabweichungen in den neun zentralen Mosaiken stark schwankend, die relativen Standardabweichungen liegen aber konstant bei 20 – 30 %. Dies zeigt, dass die gemessene Streuung eine Charakteristik des Prozesses ist, der unterschiedlich viel Licht emittiert, denn bei den Messungen am Schwarzstrahler in Abschnitt 4.1 wird eine konstante absolute Streuung der Grauwerte von 1 – 2 8-bit Werten gemessen. Die hohen Werte jenseits von 100 % am Rand des Laserspots zeigen zudem, dass dort bei einigen Punktschmelzungen viel, bei anderen gar kein Licht vom Kameradetektor gemessen wird.

Einen weiteren Anhaltspunkt dafür, ob die Streuung durch die Kamera oder den Prozess bedingt ist, liefert Abbildung 4.7. Für ein bestimmtes Mosaik sind hier die Intensitätsverteilungen über die 25 Bänder für jedes der 30 aufgenommen Bilder am Zeitpunkt  $t = 1400 \text{ ms}$  zu sehen. Die dünneren Linien in verschiedenen Farben stellen jeweils die Intensität der Bänder innerhalb eines Mosaiks bei einer Aufnahme dar. Die hervorgehobene rote Linie steht für den Durchschnitt über die 30 Linien, wobei die Fehlerbalken die Standardabweichung darstellen.

Es ist zu erkennen, dass die Grauwerte einer Aufnahme in verschiedenen Bändern konsistent über oder unter dem Durchschnitt liegen. Dies lässt wiederum darauf schließen, dass die Streuung der Grauwerte über die Messwiederholungen einer dem Prozess inhärenten Streuung der Lichtintensität zuzuschreiben ist, statt einer der Kamera inhärenten Messstreuung.

Abbildung 4.8 zeigt die zeitliche Entwicklung der Intensitäten in den 25 Bändern eines bestimmten Mosaiks während der Punktschmelzung. Neben dem zu erwartenden Anstieg der Grauwerte fällt auf, dass dieser in den verschiedenen Bändern unterschiedlich hoch ist. Es kommt im Laufe der Punktschmelzung also nicht nur zu einer höheren Intensität der Prozessemissionen, sondern auch zu einer Verschiebung des Spektrums. Die Möglichkeiten einer Quantifizierung des Spektrums werden im nachfolgenden Kapitel besprochen.

Schon diese Ergebnisse zeigen aber, dass der Prozess zwar eine beträchtliche Streuung in der Lichtintensität der Prozessemissionen aufweist, die Form des Spektrums allerdings weniger stark streut. Trotzdem ändert sich die Form des Spektrums über die Dauer des Schmelzvorgangs signifikant. Diese Erkenntnisse legen die begründete Vermutung nahe, dass die hier untersuchte Sensorik Potenzial bietet, Fehler in La-

serstrahlschmelzprozessen zu detektieren. Die Überprüfung dieser Vermutung ist Gegenstand nachfolgender Kapitel.

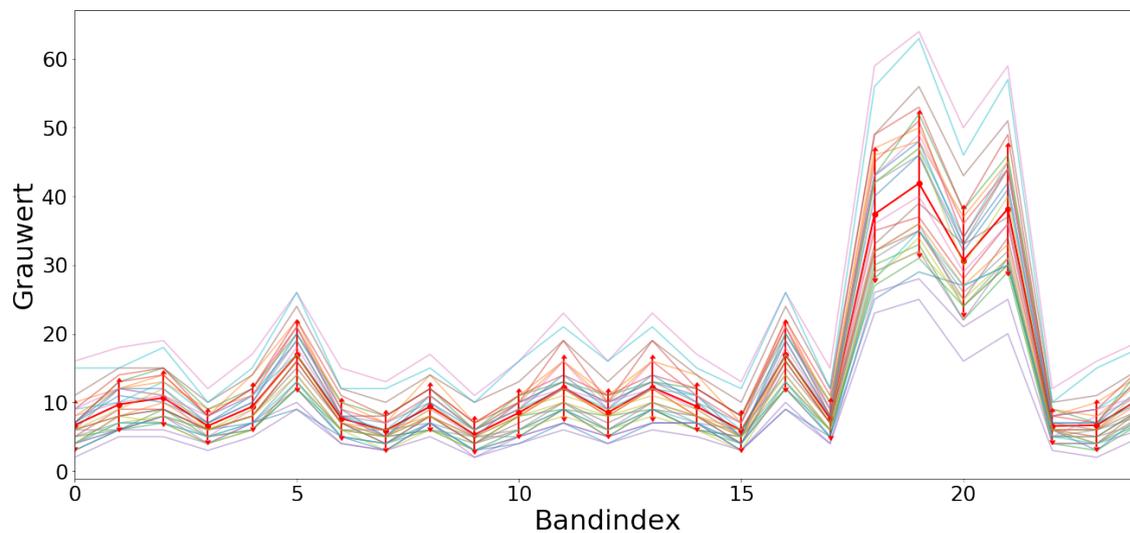


Abbildung 4.7: Intensitätsverteilungen eines bestimmten Mosaiks für alle 700. Aufnahmen der 30 Messreihen. Die rote Linie zeigt den Durchschnitt sowie die Standardabweichung als Fehlerbalken.

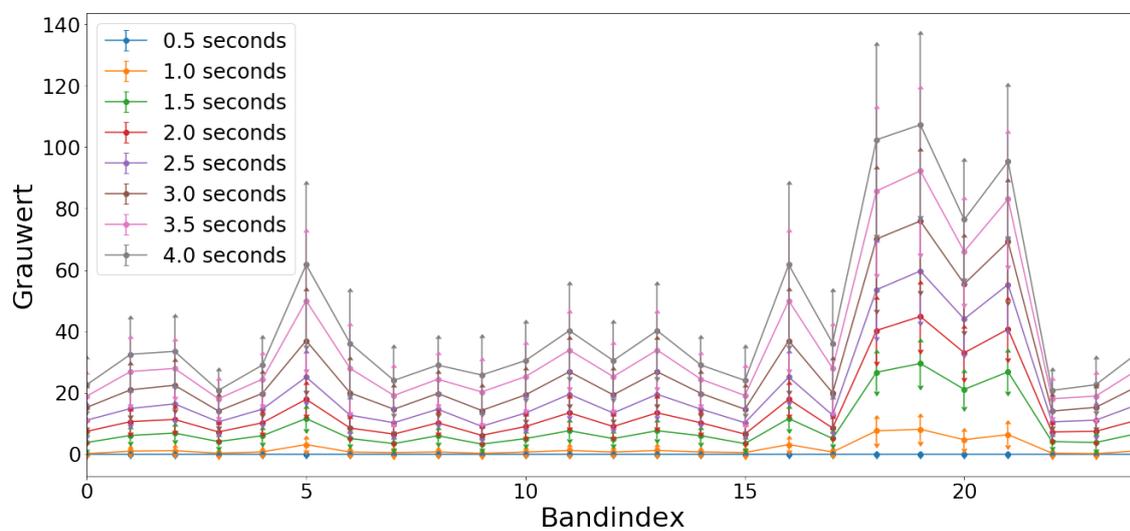


Abbildung 4.8: Durchschnittliche Intensitätsverteilungen eines bestimmten Mosaiks zu unterschiedlichen Zeitpunkten der Punktschmelzung. Die Fehlerbalken zeigen die Standardabweichung über 30 Aufnahmen.



# 5 Charakterisierung der Hyperspektralkamera

Die besondere Eigenschaft einer Flächen-Hyperspektralkamera ist es, räumliche Bildinformationen auch spektral aufzulösen. Das Ziel des folgenden Kapitels ist, qualitativ aufzuzeigen, welche Faktoren die hyperspektrale Bildgebung beeinflussen, wie daraus entstehende Verzerrungen korrigiert werden können und welche Sensorantwort bei monochromatischem Licht messbar ist. Nachdem in Kapitel 4 die Reproduzierbarkeit der Messergebnisse untersucht wurde, wird in diesem Kapitel also die Kamera hinsichtlich der Fähigkeit bewertet, das eintreffende Licht räumlich aufgelöst in spektrale Bänder zu unterteilen.

Zunächst wird im ersten Teil des Kapitels auf die Auswahl eines für die Überwachung des LPBF-Prozesses geeigneten Kameraobjektivs eingegangen. Anschließend wird die Korrektur der Sensordaten ausführlich erörtert. Abschließend werden Messergebnisse von einem Spektrometer und der Hyperspektralkamera verglichen, um so eine qualitative Aussage über die räumliche und insbesondere spektrale Auflösungsfähigkeit der Kamera zu treffen.

## 5.1 Auswahl des Kameraobjektivs

Die Qualität jedes zum Zwecke der Bildgebung entworfenen optischen Systems hängt maßgeblich von den Eigenschaften des verwendeten Objektivs ab. Dieses erfüllt die wichtige Aufgabe, das von jedem Punkt des Objektes ausgestrahlte Licht an den jeweiligen Punkt der Detektoroberfläche zu leiten. Das Objektiv bestimmt also, wie viel und welches Licht den Detektor überhaupt erreicht und so für Messzwecke zur Verfügung steht.

Verschiedene Aspekte sind bei der Wahl des Objektivs von Bedeutung. Der Durchmesser der Eintrittspupille beeinflusst nicht nur die Menge des erfassbaren Lichts, sondern auch die erzielbare räumliche Auflösung sowie die Tiefenschärfe. Je höher die Vergrößerung des Objektivs, desto kleiner der Sichtbereich der Kamera. Der Arbeitsabstand ist bei manchen Objektiven über den Abstand zwischen Objektiv und Detektoroberfläche justierbar, häufig aber fix und muss somit für die jeweilige Zielanwendung berücksichtigt werden.

Bei der Prozessüberwachung im LPBF-Verfahren mittels Flächen-Hyperspektralkamera ist die Vergrößerung des Kameraobjektivs ein wesentlicher Faktor. Durch den Kompromiss zwischen spektraler und räumlicher Auflösung muss sichergestellt werden, dass von jedem zu beobachtenden Flächenelement des Pulverbetts eine aus-

reichende Zahl an Kamerapixeln belichtet werden. Es muss also eine Abwägung zwischen Informationsdichte und Sichtbereich vorgenommen werden. Hinzu kommt, dass aufgrund der Filterung des Lichts erst durch einen Vorfilter und dann durch die Fabry-Pérot Filter verhältnismäßig wenig Licht bei den einzelnen Pixeln ankommt. Bei der Auswahl des Objektivs muss also gewährleistet werden, dass noch genügend Licht für ausreichenden Kontrast beim Detektor ankommt.

Das vom Kamerahersteller mitgelieferte Objektiv der Fa. Edmund Optics, das für die Untersuchungen in Kapitel 4 eingesetzt wurde, hat einen variablen Arbeitsabstand und einen relativ großen Sichtbereich. Der für die Kamera sichtbare Bereich des Laserprozesses ist somit auf einen kleinen Teil dieses Sichtbereichs beschränkt. Zudem wird von der Laser-Interaktions-Zone eine hohe Lichtintensität emittiert, so dass die entsprechenden Pixel schnell saturieren, umliegende Pixel aber kaum Licht detektieren. Gerade zur Erfassung des Spektrums müssen aber alle Pixel eines Mosaiks ausgeleuchtet werden und für räumliche Informationen auch möglichst mehrere Mosaik. Deshalb wird das mitgelieferte Standard-Objektiv für die Überwachung des LPBF-Prozesses als ungeeignet eingestuft. Insbesondere ist eine deutlich höhere Vergrößerung erforderlich. Als Alternative wird ein Objektiv mit fester Brennweite und festem Arbeitsabstand der Fa. Qioptiq (Qioptiq Photonics GmbH & Co. KG) ausgewählt. Die Spezifikationen dieses Objektivs sind in Tabelle 5.1 gelistet.

Tabelle 5.1: Spezifikationen des auf den Prozess ausgelegten Objektivs.

Spezifikation	<b>Qioptiq Objektiv mit Festbrennweite</b>
Brennweite	200 mm
Arbeitsabstand	190 mm (fest)
Numerische Apertur	0,045
Horizontales Bildfeld	8,8 mm
Vergrößerung	1x
Tiefenschärfe	0,28 mm

Um die Eignung des neuen Objektivs im Vergleich zum Standard-Objektiv zu testen, werden Punktschweißungen mit beiden Objektiven im selben Versuchsaufbau beobachtet. Abbildung 5.1 zeigt jeweils Versuchsaufbau, Sichtfeld auf Substrat bei hoher Belichtungszeit sowie Aufnahme einer Laser-Punktschweißung. Durch den festen Arbeitsabstand des neuen Objektivs von 190 mm muss die Positionierung entsprechend eingestellt werden. Dieser qualitative Vergleich zeigt eindrücklich, dass das Standard-Objektiv einen großen Sichtbereich und damit einhergehend eine geringe Auflösung des zu beobachtenden Laserspots erzeugt. Im Gegensatz dazu erzeugt das Objektiv mit festem Arbeitsabstand ein kleines Sichtfeld und eine deutlich höhere Auflösung

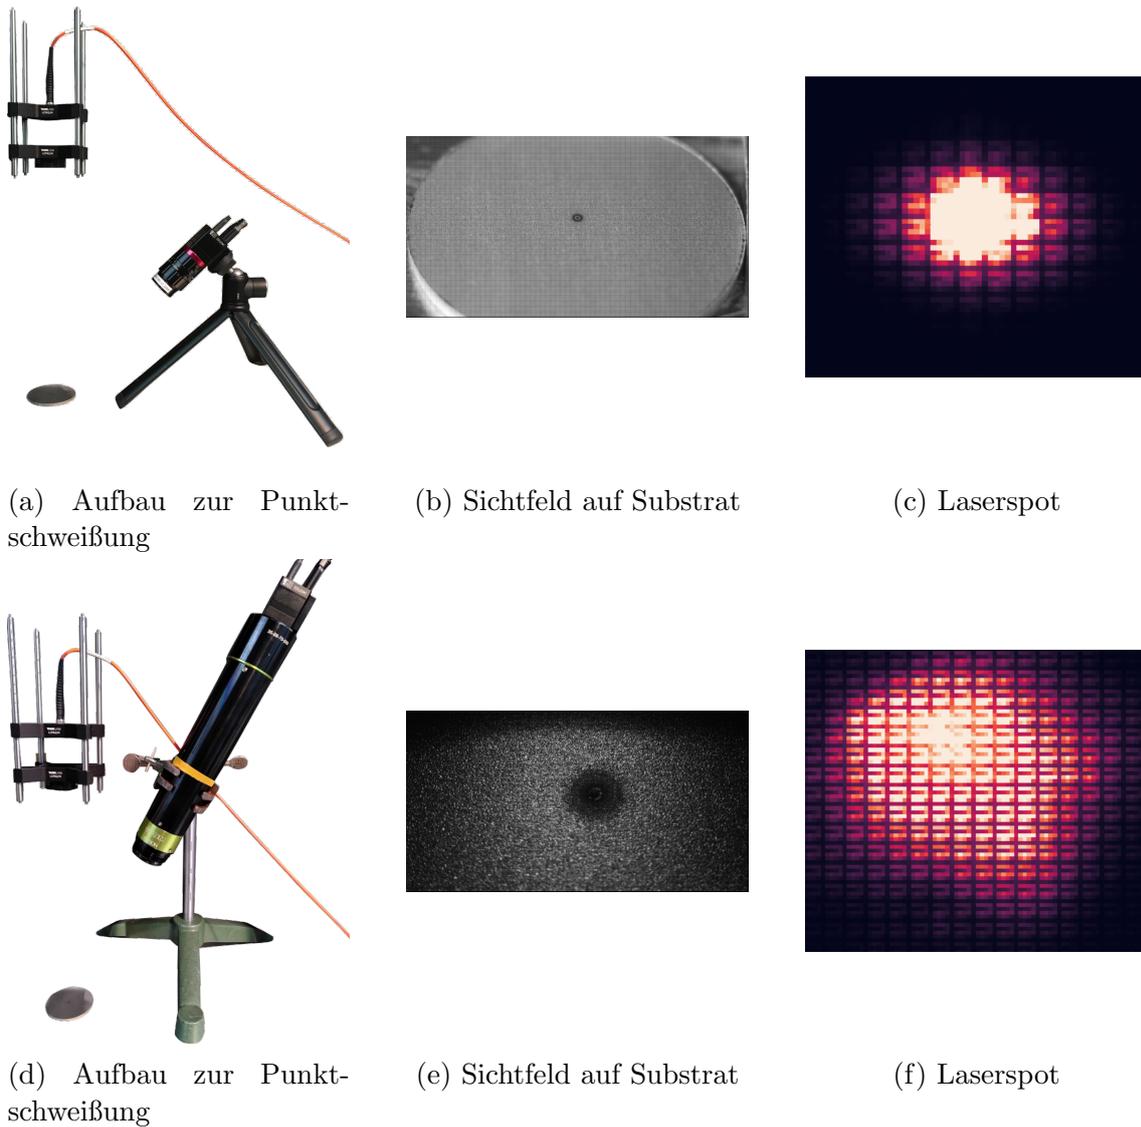


Abbildung 5.1: Vergleich der beiden Objektive: die oberen Abbildungen entsprechen dem Standard-Objektiv mit variablem Arbeitsabstand. Die unteren Abbildungen zeigen analog das Objektiv zur Beobachtung des LPBF-Prozess mit 1-facher Vergrößerung und festem Arbeitsabstand.

des Schweißprozesses. Das Licht wird über mehrere Mosaik verteilt, sodass sowohl höhere räumliche als auch spektrale Auflösung ermöglicht wird. Außerdem kommt es zu weniger saturierten Pixeln.

Um eine möglichst hohe Informationsdichte der hyperspektralen Bildgebung während des LPBF-Prozesses zu gewährleisten, wird im Rahmen dieser Arbeit mit dem Objektiv der Fa. Qioptiq gearbeitet. Abbildung 5.1d zeigt, dass dieses Objektiv um ein Vielfaches länger ist, was entsprechende Anforderungen an die Integration in die Fertigungsmaschine stellt. Deshalb wird für die Versuche dieser Arbeit als Fertigungsmaschine eine Laboranlage ausgewählt, die eine hohe Zugänglichkeit ermöglicht und somit den Abmessungen und dem Arbeitsabstand des Objektivs gerecht wird.

Die 1-fache Vergrößerung des Objektivs bedingt zwar, dass nur ein kleiner Teil des

Pulverbetts im Sichtbereich der Kamera liegt. Das Ziel dieser Arbeit ist aber, das Potenzial der hyperspektralen Bildgebung für die Prozessüberwachung in der additiven Metallfertigung zu untersuchen. Eine Anpassung und Skalierung zur Anwendbarkeit auf industrielle Prozesse muss daran anknüpfen.

## 5.2 Korrektur der Sensordaten

Auf dem Weg vom Objekt zum Sensor erfährt das zu messende Licht eine Reihe von Einflüssen, die bei der Interpretation und Auswertung der Messergebnisse zu berücksichtigen sind. Abbildung 5.2 zeigt die Abfolge von optischen Komponenten, die die Lichtpropagation verändern und das Messergebnis verzerren können. Neben den durch die Aberrationen der lichtformenden Komponenten bedingten Einflüssen spielt auch die Sensitivität des Detektors eine wesentliche Rolle.

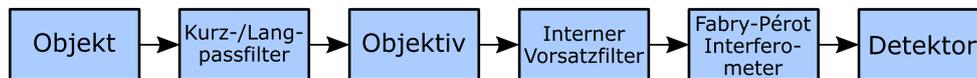


Abbildung 5.2: Weg des Lichts, das durch verschiedene optische Komponenten auf dem Weg zum Sensor beeinflusst wird.

Der Kamerahersteller empfiehlt eine bestimmte Abfolge von Korrekturschritten zur Aufbereitung der Kameraaufnahmen. Abbildung 5.3 zeigt diese Reihenfolge notwendiger (blau) und optionaler (weiß) Korrekturmaßnahmen. Jeder einzelne dieser Korrekturschritte sowie ihre jeweilige Notwendigkeit wird im Folgenden näher erläutert. Die Korrekturschritte sind teilweise rechenintensiv und werden in dieser Arbeit im Anschluss an die Erhebung der Rohdaten vorgenommen. Für eine Echtzeitverarbeitung sind entsprechend leistungsfähige Elektronikkomponenten notwendig.

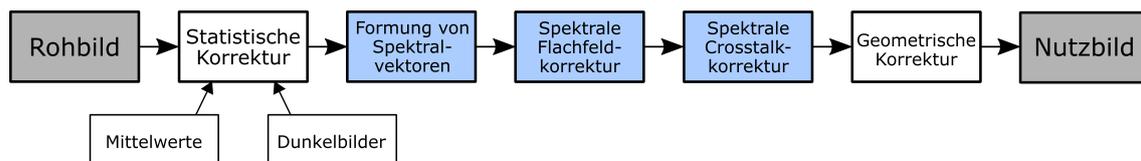


Abbildung 5.3: Korrekturschritte, die aus einem Rohbild ein Nutzbild erzeugen.

### 5.2.1 Statistische Korrektur

Zur statistischen Korrektur zählen die sogenannte Dunkelbildkorrektur sowie in bestimmten Fällen die Mittelung über eine gewisse Anzahl von Kameraaufnahmen. Eine Dunkelbildkorrektur ist notwendig, da CMOS-Sensoren auch ohne Lichteinwirkung ein Messsignal ausgeben. Dieses ist meistens sehr gering, sodass eine nicht erfolgte Dunkelbildkorrektur die Messergebnisse nur unwesentlich verzerrt. Aus diesem Grund gilt dieser Korrekturschritt als optional. Er erfordert allerdings geringen Aufwand und ist somit einfach in die Bildnachbearbeitung zu integrieren. Es wird eine bestimmte Anzahl von Dunkelbildern aufgenommen, gemittelt und von den erhobenen Aufnahmen abgezogen.

### 5.2.2 Spektralvektoren

Es ist hilfreich, die räumlichen und spektralen Informationen einer hyperspektralen Bildaufnahme zu entkoppeln. Dazu kann jedes Mosaik als ein Flächenpunkt mit der Koordinate  $(i, j)$  und der Index des jeweiligen Filters innerhalb eines Mosaiks als Bildvariable  $k$  betrachtet werden. Für ein gegebenes Tupel  $(i, j)$  stellt  $\vec{S}_S$  den Spektralvektor der Sensordaten mit den gemessenen Intensitätswerten als Komponenten  $\lambda_{S,k}$  mit  $k = 1, \dots, 25$  dar. Dabei entspricht  $k$  dem jeweiligen Index des betreffenden Filterelements.

So können also alle Pixelintensitätswerte der Sensoroberfläche  $a_{n,m} \in A^{2045 \times 1080}$  einem Element des Hyperspektralbildes  $b_{i,j,k} \in B^{409 \times 216 \times 25}$  zugeordnet werden. Abbildung 5.4 veranschaulicht diese Erzeugung von Spektralvektoren aus den Mosaiken der hyperspektralen Bildaufnahme.

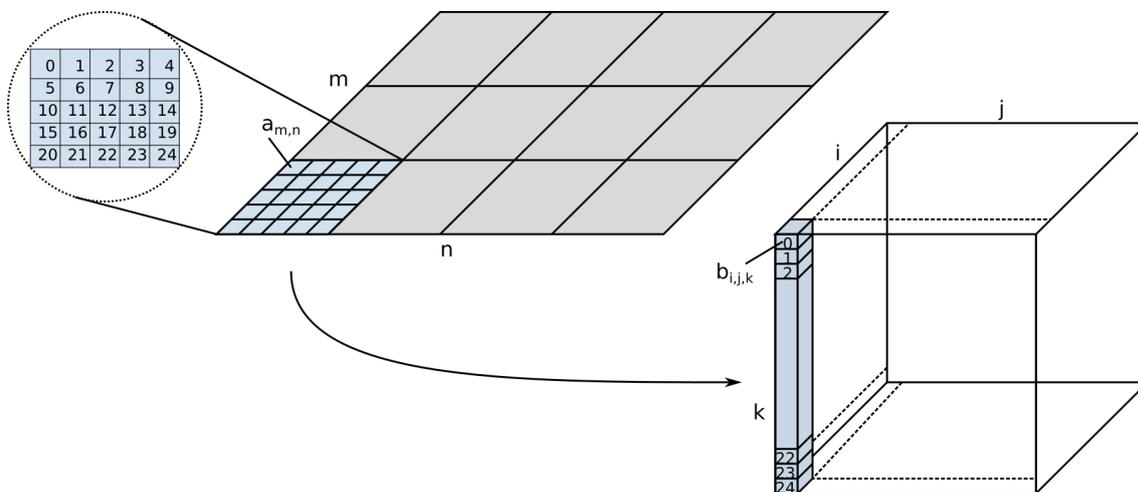


Abbildung 5.4: Zerlegung der Mosaik in einen Spektralvektor.

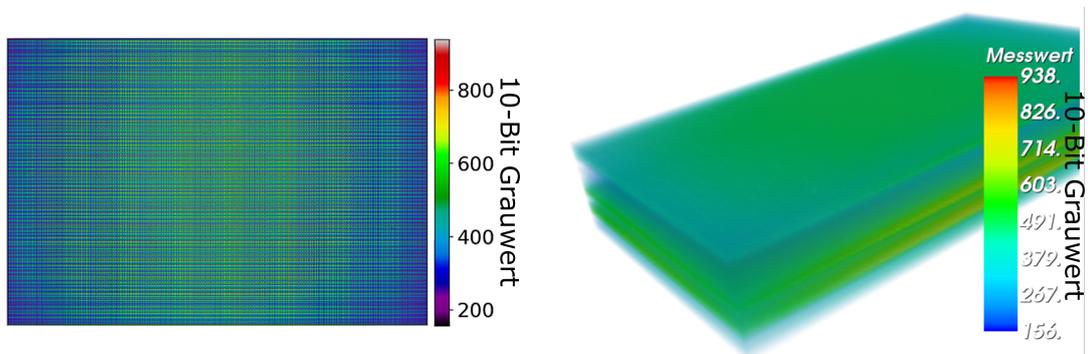
### 5.2.3 Spektrale Flachfeldkorrektur

Ein in der Bildgebung häufig zu beobachtender Effekt ist der Abfall der Messintensitäten zum Rand des Bildes. Dieser Effekt wird Vignettierung genannt und tritt in Verbindung mit den Aperturen innerhalb des Objektivs auf. Bei einer Flächen-Hyperspektralkamera kann dadurch nicht nur die Intensität, sondern auch das zum Rand des Bildes gemessene Spektrum verzerrt werden. Insofern wird eine Korrektur der spektralen Signatur umso wichtiger. Diese erfolgt in Form einer bandspezifischen Flachfeldkorrektur.

Für einen solchen Korrekturschritt wird die Bildaufnahme einer Fläche benötigt, die eine homogene Verteilung der Intensität und der spektralen Signatur aufweist. Es wird also ein abzubildender Körper benötigt, der idealerweise in seinem Emissionsspektrum unabhängig vom Betrachtungswinkel eine konstante Leuchtdichte und spektrale Signatur erzeugt. Ein solcher Körper ist ein ideal diffuser Reflektor und wird als Lambertstrahler bezeichnet. Die Eigenschaften eines solchen idealen Lambertstrahlers können mit bestimmten realen Reflexionskörpern z.B. aus Polytetrafluorethylen (PTFE) oder Bariumsulfat angenähert werden.

In dieser Arbeit wird ein Streukörper aus Bariumsulfat verwendet, der unter freiem

Himmel bei leichter Bewölkung homogen vom breitbandigen Sonnenlicht ausgeleuchtet wird. Abbildung 5.5a zeigt das Rohbild dieses Streukörpers. Die Volumendarstellung in Abbildung 5.5b wird erzeugt, indem die aus den Mosaiken geformten Spektralvektoren in die dritte Dimension projiziert werden. Dadurch wird vor allem auch die Veränderung des gemessenen Spektrums zu den Bildrändern hin deutlich.

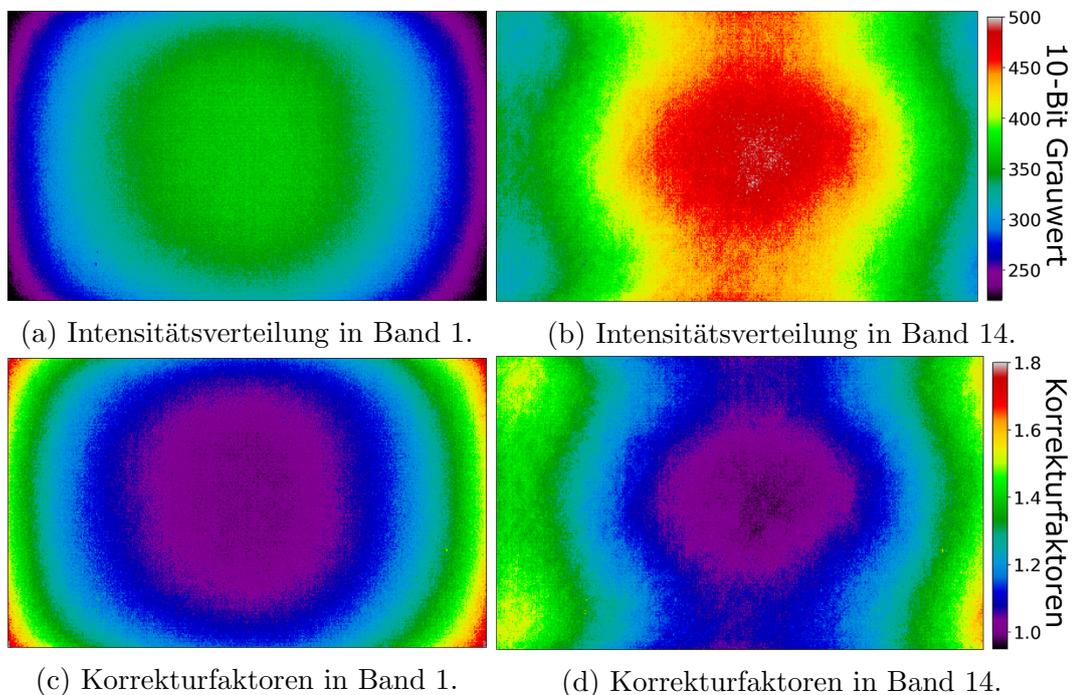


(a) Rohbild des mit Sonnenlicht beleuchteten Streukörpers.

(b) Durch Formung von Spektralvektoren erzeugte Volumendarstellung.

Abbildung 5.5: Das Rohbild und dessen Volumendarstellung verdeutlichen den durch das Objektiv bedingten Vignettierungseffekt.

Um diesen Vignettierungseffekt zu korrigieren, werden  $20 * 20$  Mosaik aus dem Zentrum der Referenzaufnahme verwendet und ihre Messwerte für jedes Band gemittelt. Für jedes Band gibt es also einen Mittelwert, aus dem für alle Pixel dieses Bands der jeweils zur Angleichung der Intensität benötigte Korrekturfaktor ermittelt



(a) Intensitätsverteilung in Band 1.

(b) Intensitätsverteilung in Band 14.

(c) Korrekturfaktoren in Band 1.

(d) Korrekturfaktoren in Band 14.

Abbildung 5.6: Veranschaulichung der bandspezifischen Flachfeldkorrektur: a) und b) zeigen für Band 1 und 14 jeweils die Rohbilder wohingegen c) und d) die entsprechenden Korrekturfaktoren darstellen.

telt werden kann. Abbildung 5.6 verdeutlicht diesen Prozess: 5.6a und 5.6b zeigen jeweils die Rohbilder für Band 1 und Band 14. In den Abbildungen 5.6c und 5.6d sind wiederum die zugehörigen Korrekturfaktoren zu sehen. Diese Korrekturfaktoren werden nun für jedes neue, in anderen Umgebungsbedingungen mit der Hyperspektralkamera aufgenommene Bild verwendet.

Abbildung 5.7 zeigt die Volumendarstellung des korrigierten Hyperspektralbildes des Streukörpers aus Bariumsulfat. Die spektrale Signatur ist nun über das gesamte Bild – auch zu den Bildrändern – identisch.

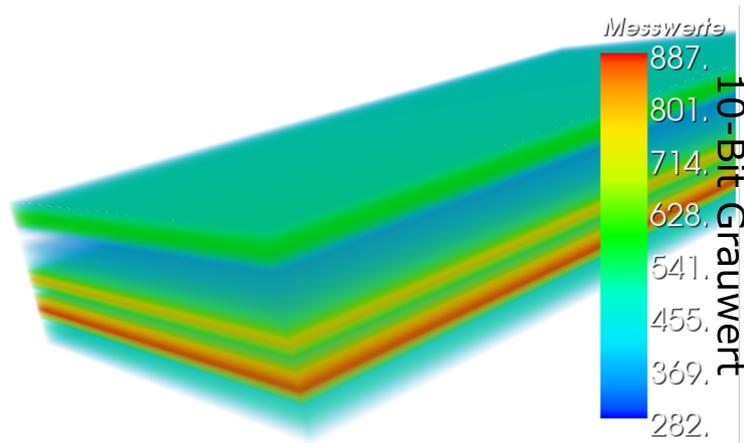


Abbildung 5.7: Volumendarstellung des hinsichtlich des Vignettierungseffektes korrigierten Hyperspektralbildes.

### 5.2.4 Spektrale Korrekturmatrix

Das messbare Sensorsignal hängt von der Quanteneffizienz sowie Konversionsverstärkung des CMOS-Sensors ab. Die Quanteneffizienz beschreibt das Verhältnis von zur Signalspannung beitragenden Elektronen zur Anzahl der eingestrahnten Photonen. Die Konversionsverstärkung wiederum beschreibt die pro Elektron messbare Signalspannung in Volt. Zur wellenlängenabhängigen Sensitivität jedes Pixels eines Mosaiks trägt aber vor allem auch die in Abschnitt 2.4.2 beschriebene Charakteristik der Fabry-Pérot Interferometer bei. Um die relative Sensitivität der einzelnen Bänder zu bestimmen wird der Sensor vom Hersteller mit kollimiertem, monochromatischem Licht im Wellenlängenbereich zwischen 400 und 1000 nm in Inkrementen von 1 nm bestrahlt und die Sensorreaktion hierauf gemessen. Die Messwerte stehen in Form einer XML-Datei zur Verfügung. Tabelle 5.2 listet die Wellenlängen maximaler Sensitivität jedes Filterindizes auf. Abbildung 5.8 zeigt die bestimmten relativen Sensitivitäten der 25 Pixel eines Mosaiks.

Abbildung 5.8 macht deutlich, dass die maximalen Sensitivitäten der Bänder einerseits unterschiedlich hoch sind und es andererseits einen gewissen Überlapp bzw. Crosstalk zwischen den Bändern gibt. Wie in Abschnitt 2.4.2 erläutert, hat jedes Band außerdem eine 2. Harmonische, sodass einzelne Pixel auf mehrere Spektralkomponenten des einfallenden Feldes mit der Erzeugung eines Messsignals reagieren können. Um diesen Effekt zu kompensieren, werden Vorfilter vor dem Kameraobjektiv verwendet, die jeweils entweder die Grundwellenlänge oder die 2. Harmonische unterdrücken.

Tabelle 5.2: Filterindizes innerhalb eines Mosaiks und zugehörige Zentralwellenlängen maximaler Sensitivität.

Index	$\lambda[nm]$	Index	$\lambda[nm]$	Index	$\lambda[nm]$	Index	$\lambda[nm]$
1	882,10	8	777,15	15	685,04	22	853,21
2	891,60	9	763,23	16	922,04	23	831,64
3	873,35	10	670,11	17	929,48	24	819,79
4	863,29	11	737,44	18	914,41	25	936,42
5	949,49	12	751,11	19	905,37	—	—
6	788,50	13	724,70	20	943,85	—	—
7	801,37	14	710,15	21	842,10	—	—

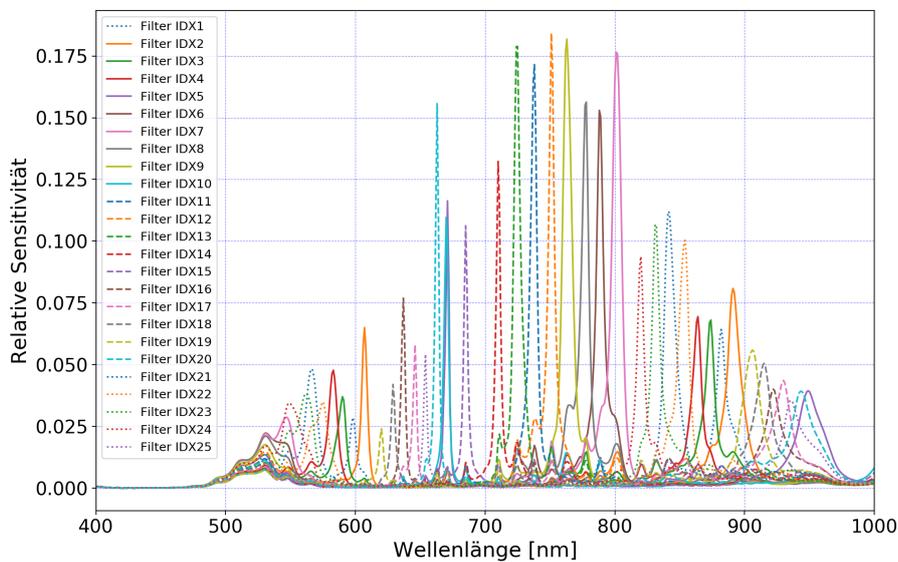


Abbildung 5.8: Sensorantwort aller Filterelemente unter Einwirkung von monochromatischem Licht.

Abbildung 5.9 zeigt den Effekt des Kurz- (Short-Pass Filter) bzw. Langpassfilters (Long-Pass Filter) auf drei exemplarisch dargestellte Bänder. Die Transmissionseigenschaften der Vorfilter werden ebenfalls in Form einer XML-Datei vom Hersteller zur Verfügung gestellt. Durch den Short-Pass Filter werden alle Wellenlängen über 875 nm unterdrückt, sodass die Pixel nur bei Licht innerhalb eines bestimmten Wellenlängenbereiches ein Messsignal erzeugen. Der Long-Pass Filter wiederum unterdrückt alle Wellenlängen unter 675 nm, sodass auch so jedes Band nur bei einer Wellenlänge ein Maximum der Sensitivität aufweist. Beim Einsatz der Hyperspektralkamera zur Überwachung des LPBF-Prozesses wird in dieser Arbeit mit dem Short-Pass Filter gearbeitet, da dieser die für den Detektor gefährliche Laserstrahlung bei einer Wellenlänge von 1070 nm unterdrückt.

Durch die exemplarische Darstellung von nur drei Spektralbändern wird in Abbildung 5.9 außerdem deutlich, wie die einzelnen Bänder teilweise hinsichtlich ihrer sensitiven Wellenlängenbereiche überlappen.

Der Kamerahersteller stellt für beide Vorfilter jeweils eine Korrekturmatrix zur Verfügung, mit denen die Rohmessdaten des Sensors korrigiert und die Intensitäten

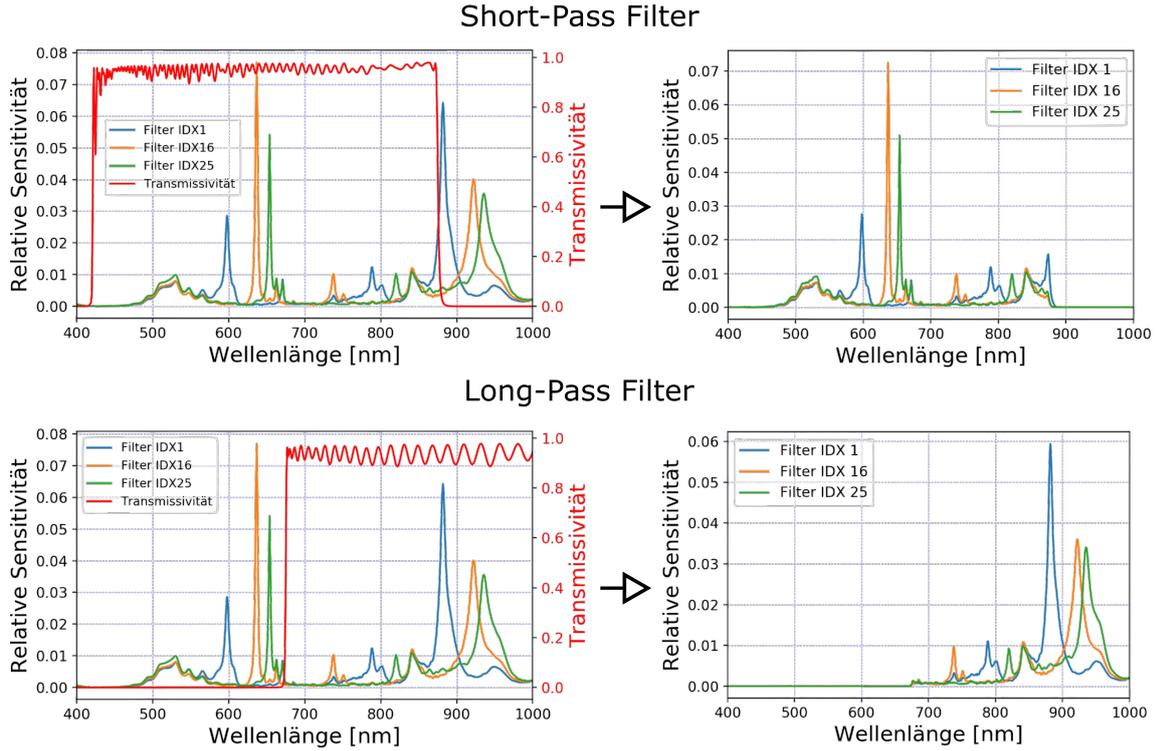


Abbildung 5.9: Einfluss der Passfilter auf die Sensitivitäten der einzelnen Bänder.

von einem auf die Filterelemente bezogenen Spektrum  $\vec{S}_S$  auf ein wellenlängenbezogenes Spektrum  $\vec{S}_C$  umgerechnet werden können. Diese Korrekturmatri­zen dienen vor allem dazu, das erwähnte Übersprechen bzw. Crosstalk zwischen den Bändern zu korrigieren. Die beiden Korrekturmatri­zen sind jeweils auf die optischen Eigenschaften des entsprechenden Vorfilters angepasst und müssen auf die gemäß Abschnitt 5.2.2 geformten Spektralvektoren  $\vec{S}_S$  angewendet werden. Die Korrekturmatri­ze für den Long-Pass Filter ist quadratisch (25 x 25) und bildet die Messwerte der 25 Pixel eines Mosaiks auf 25, nach Wellenlänge sortierte, virtuelle Bänder ab. Der korrigierte Spektralvektor wird mit  $\vec{S}_C$  bezeichnet. Die Korrekturmatri­ze für den Short-Pass Filter bildet die Messdaten der 25 Pixel auf einen Spektralvektor mit 23 Komponenten ab (23 x 25). Hier werden nur 23 virtuelle Bänder erzeugt, da einige Bänder aufgrund ihres Überlapps zu einem Band vereint werden. Aus dem mit der Kamera erfassten Spektralvektor  $\vec{S}_S$  wird also mit Hilfe der Korrekturmatri­ze  $M^{N_C \times N_S}$  der korrigierte Spektralvektor  $\vec{S}_C$ :

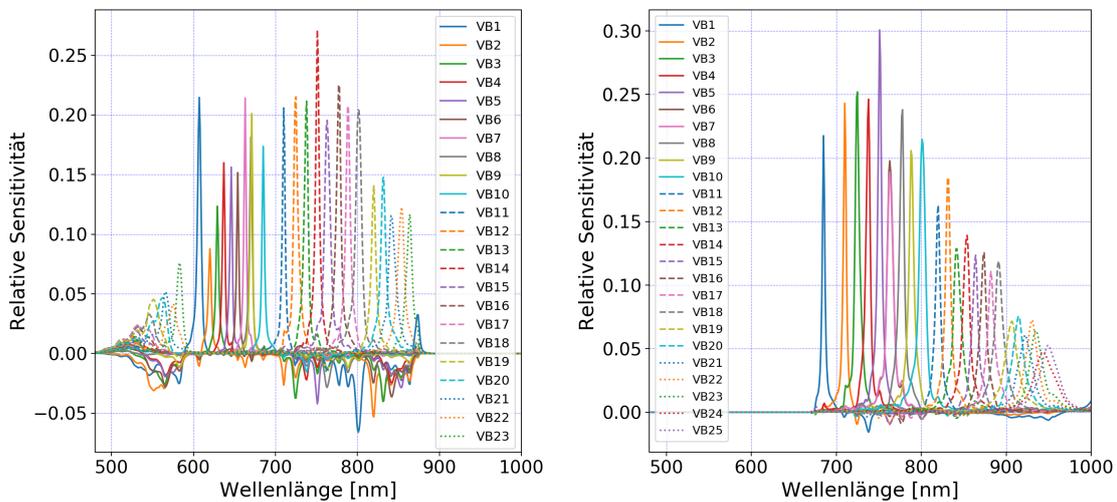
$$\vec{S}_C = M^{N_C \times N_S} \vec{S}_S \quad (5.1)$$

Hierbei steht  $N_C$  für die Anzahl der im Spektralvektor umfassten virtuellen Bänder (23 oder 25) und  $N_S$  für die Anzahl der Komponenten des Spektralvektors der sensorbezogenen Filterindizes (25). Die Elemente des korrigierten Spektralvektors  $\vec{S}_C$  sind nach Wellenlängen sortiert. Um die Wirkung der Korrekturmatri­zen auf die Sensorantworten zu untersuchen, werden die durch den jeweiligen Vorfilter bedingten Sensitivitäten mit der entsprechenden Matrix korrigiert. Abbildung 5.10 zeigt die sich daraus ergebenden Sensitivitäten der virtuellen Bänder und Tabelle 5.3 die entsprechenden vom Hersteller angegebenen Zentralwellenlängen. In Anhang A.3 in Abbildung A.1 sind die berechneten Sensitivitäten für alle virtuellen Bänder bei

Einsatz des Short-Pass-Filters einzeln dargestellt.

Tabelle 5.3: Zentralwellenlängen der virtuellen Bänder nach Anwendung der Korrekturmatriizen für Short-Pass (SP) und Long-Pass (LP) Filter.

Virtuelles Band	$\lambda_{SP}[nm]$	$\lambda_{LP}[nm]$	Virtuelles Band	$\lambda_{SP}[nm]$	$\lambda_{LP}[nm]$
1	607,64	685,08	14	751,13	852,96
2	619,89	710,14	15	763,23	863,49
3	629,07	724,78	16	777,10	873,13
4	636,82	737,55	17	788,52	882,32
5	645,82	751,17	18	801,36	891,39
6	653,95	763,34	19	819,77	905,76
7	662,94	763,47	20	831,67	914,14
8	670,08	777,26	21	842,15	922,26
9	670,88	788,47	22	853,20	929,74
10	685,06	801,14	23	863,36	935,82
11	710,11	819,73	24	—	943,84
12	724,70	831,60	25	—	950,15
13	737,48	842,3	—	—	—



(a) Virtuelle Bänder nach Korrektur, Short-Pass Filter.

(b) Virtuelle Bänder nach Korrektur, Long-Pass Filter.

Abbildung 5.10: Relative Sensitivitäten der virtuellen Bänder infolge der Korrektur der Rohdaten durch Korrekturmatriix.

Die Korrektur zur Verwendung des Long-Pass Filters erzeugt überwiegend Sensitivitäts-Maxima, die klar definiert und sauber voneinander getrennt sind. Nur bei höheren Wellenlängen gibt es einen stärkeren Überlapp. Die Korrektur der kurzpassgefilterten Spektralinformation weist wiederum ein paar besondere Merkmale auf. In den Bändern 1-6, 8 und 23 treten vor allem im Bereich um 800 nm negative

Sensitivitäten auf. Die Ursache hierfür wird vom Kamerahersteller nicht benannt und kann aus der Datenlage nicht identifiziert werden. Es liegt jedoch nahe, dass die Korrektur zu einer Überkompensation in diesem Bereich führt, da die Sensitivitäten der unkorrigierten Sensorinformationen im Bereich von ca. 720 bis 800 nm maximale Werte erreichen. Über die Korrekturmatrix werden zur Kompensation des Überlapps die Sensitivitätskurven über den gesamten Wellenlängenbereich addiert oder subtrahiert, sodass diese Nebeneffekte auftreten können. Sowohl für den Short-Pass als auch für den Long-Pass Filter stimmen die ermittelten Sensitivitätskurven aber mit den vom Hersteller angegebenen Zentralwellenlängen der virtuellen Bänder überein.

Wird die Reflektanz eines Objektes mit der Hyperspektralkamera bestimmt, so müssen zusätzlich die Einflüsse der Optik und insbesondere der Beleuchtungsquelle berücksichtigt werden. Dazu wird ein idealer Referenzkörper verwendet, welcher im betrachteten Spektralbereich unabhängig von der Wellenlänge und vom Betrachtungswinkel reflektiert. Mit der Kamera werden dann Referenzkörper und Messobjekt im identischen optischen Aufbau aufgenommen. Da im Rahmen dieser Arbeit das Prozessleuchten untersucht wird, kommt der Analyse der Reflektanz jedoch keine Bedeutung zu.

#### 5.2.5 Geometrische Korrektur

Dieser Korrekturschritt bezieht sich auf geometrische Verzerrungen, die durch die Ausrichtung des Kameraobjektivs zum Messobjekt entstehen können. Liegt das Bildobjekt bspw. nicht parallel zur Sensoroberfläche, kommt es zu stürzenden Linien. Dieser Effekt kann entweder schon während der Aufnahme durch ein sogenanntes Tilt-Shift-Objektiv oder im Anschluss im Rahmen einer digitalen Nachbearbeitung korrigiert werden. Aufgrund des relativ geringen Verkippwinkels des Kameraobjektivs von ca.  $15^\circ$  wird im Rahmen dieser Arbeit auf eine geometrische Korrektur verzichtet.

### 5.3 Sensorantwort bei monochromatischem Licht

Um die spektralen Eigenschaften der Hyperspektralkamera zu validieren, wird im Rahmen dieser Arbeit mit Hilfe eines Monochromators monochromatisches Licht erzeugt und die Sensorantwort der Kamera mit der eines Spektrometers verglichen. Durch die Messung an monochromatischem Licht kann die spektrale Auflösungsfähigkeit der Kamera bewertet sowie die Wirkungsweise der Korrekturmatrixen untersucht werden. Der Vergleich der Messergebnisse mit einem Spektrometer lässt zudem eine Einschätzung zu, inwiefern auch das Spektrum von breitbandigem Licht mit der Hyperspektralkamera erfasst werden kann.

#### 5.3.1 Versuchsaufbau

Der Versuchsaufbau ist in Abbildung 5.11 und dessen 2D-Zeichnung in Abbildung 5.12 dargestellt. Der Monochromator der Firma Carl Zeiss vom Typ M4 QIII wird durch eine 60 W Halogenlampe mit breitbandigem Licht versorgt. Die Verbindungsstrecke zwischen Eingangsapertur und Lichtquelle wird mit einem schwarz beschichteten Verbindungsrohr abgedichtet. Als mechanisches Verbindungselement zwischen

Monochromator und den optischen Komponenten wird ein Aluminiumprofil verwendet. Das Spektrometer wird direkt vor dem Ausgangsspalt des Monochromators auf einem mehrachsigen Linearsystem platziert. Das Spektrometer kann somit aus der optischen Achse des Aufbaus verfahren werden, sodass das Licht des Ausgangsspalts auf die Kamera trifft. Die Vorfilter werden von einer gedruckten Halterung aufgenommen und können wie die Kamera in der Höhe verstellt werden.

### 5.3.2 Spektrometer

Für die Untersuchungen wird das AvaSpec-Mini4096CL Spektrometer der Firma Avantes BV verwendet. Dieses Spektrometer ist nach dem symmetrischen Czerny-Turner Prinzip konstruiert und vereint ein Gitter als dispersives Element, eine Schlitzeblende sowie einen CMOS-Sensor. Der Strahlengang wird über zwei konkave Spiegel geführt und so der Eingangsspalt auf den optischen Sensor abgebildet.

Mit Hilfe des Monochromators wird das Spektrometer mit Licht bei Wellenlängen von 425 bis 1075 nm in Inkrementen von 25 nm beschienen. Zusätzlich werden die Zentralwellenlängen der virtuellen Bänder der Kamera erzeugt. Abbildung 5.13 zeigt die dabei gemessenen Zählraten. Die Belichtungszeit wird auf 30 ms eingestellt, denn bei diesem Wert kann der Messbereich des Geräts vollständig ausgenutzt werden, ohne dass es zu Sättigungseffekten kam. Die höchsten Zählraten können bei Wellenlängen um die 600 nm gemessen werden, wohingegen die Zählraten gegen 1000 nm Wellenlänge stark abnehmen. Dies deckt sich mit der spektralen Empfindlichkeit des CMOS-Sensors, wie sie vom Hersteller angegeben wird [Ham20].

Es ist wichtig, hervorzuheben, dass die Messdaten des Spektrometers keinerlei Kor-

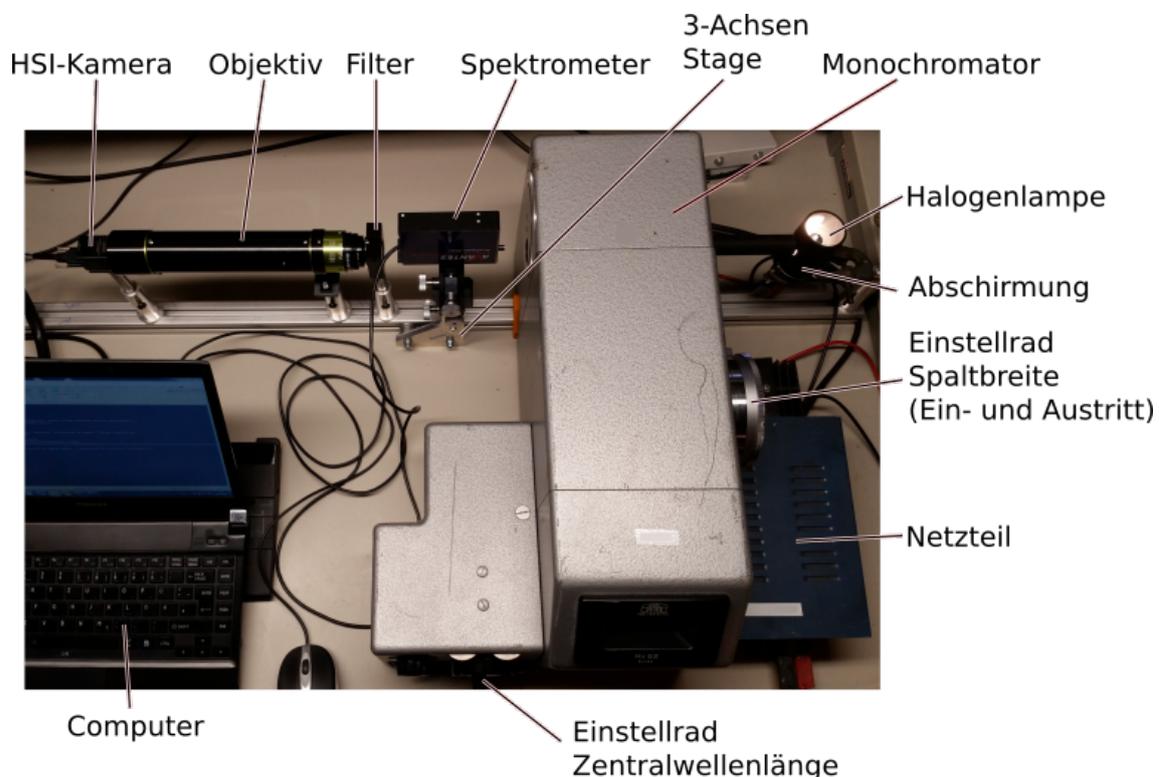


Abbildung 5.11: Versuchsaufbau zur Spektralcharakterisierung der Hyperspektralkamera.

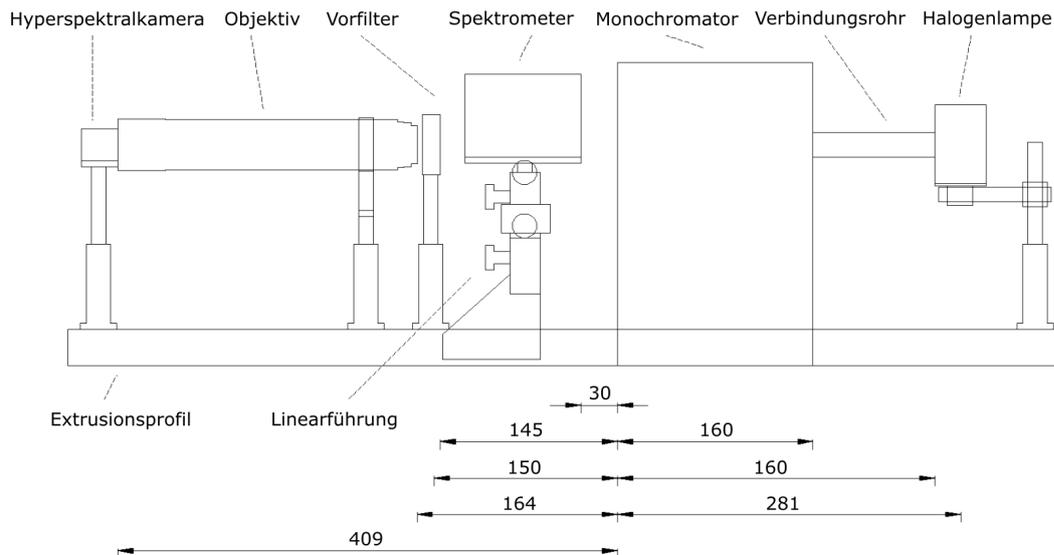


Abbildung 5.12: Zeichnung des Versuchsaufbaus (Angaben in Millimetern).

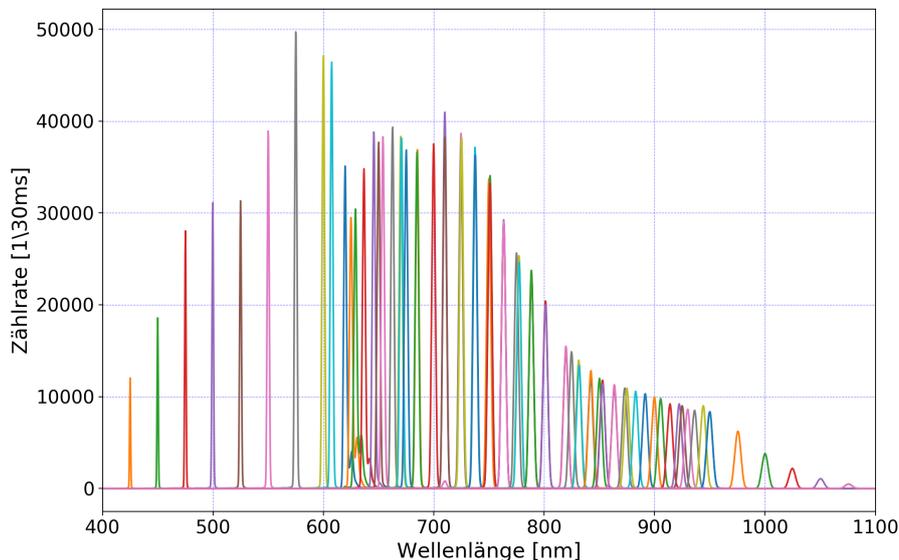


Abbildung 5.13: Mit dem Spektrometer gemessene Spektralverteilungen der mit dem Monochromator erzeugten Stimuli.

rekturen hinsichtlich der Zählraten erfahren – sie stellen somit die Rohdaten des CMOS-Sensors dar. Mit Hilfe zweier Diodenlaser (rot und blau) kann zwar verifiziert werden, dass die Wellenlängen, an denen eine bestimmte Lichtintensität auftritt, mit dem Spektrometer zuverlässig und präzise bestimmt werden können. Die Höhe der Lichtintensität kann jedoch nicht zuverlässig bestimmt werden und insbesondere nicht mit der Intensität bei anderen Wellenlängen verglichen werden. Demnach bildet auch der mit dem Spektrometer gemessene Verlauf eines Spektrums nicht die tatsächliche Physik ab. Für den Vergleich der Sensorsignale von Spektrometer und Kamera heißt das, dass eine qualitative Analyse hinsichtlich der detektierten Wellenlängen zwar möglich ist, eine quantitative Analyse aber aufgrund des unbekannt Systemverhaltens (Spiegel, Blenden, Gitter etc.) des Spektrometers entfallen muss. Zur Beschreibung der Lichtstimuli werden die Messergebnisse des Spektrometers

unter Verwendung der Gauß'schen Dichtefunktion gefittet [Rüs14]:

$$g(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5.2)$$

$\mu$ : Erwartungswert;  $\sigma$ : Standardabweichung

Wie in Abbildung 5.14 zu sehen, stimmt der Fit bei verschiedenen Wellenlängen in hohem Maße mit den Messwerten überein. In Abbildung 5.14a zeigt sich allerdings, dass sich der Verlauf der Messwerte in einem gewissen Wellenlängenbereich nicht mehr mit der Dichtefunktion deckt. Die wahrscheinlichste Ursache hierfür ist eine Fehlfunktion des Monochromators, wobei der gleiche Effekt bei den zentralen Wellenlängen von 619,77 nm, 628,11 nm, 629,12 nm und 636,76 nm zu beobachten ist. Bei allen anderen untersuchten Wellenlängen können die Messwerte des Spektrometers aber präzise durch die Dichtefunktion abgebildet werden, wie Abbildungen 5.14b, 5.14c und 5.14d verdeutlichen. Die Halbwertsbreite bzw. das FWHM nimmt zwar für höhere Wellenlängen zu, sie ist für niedrigere Wellenlängen wie sie für die

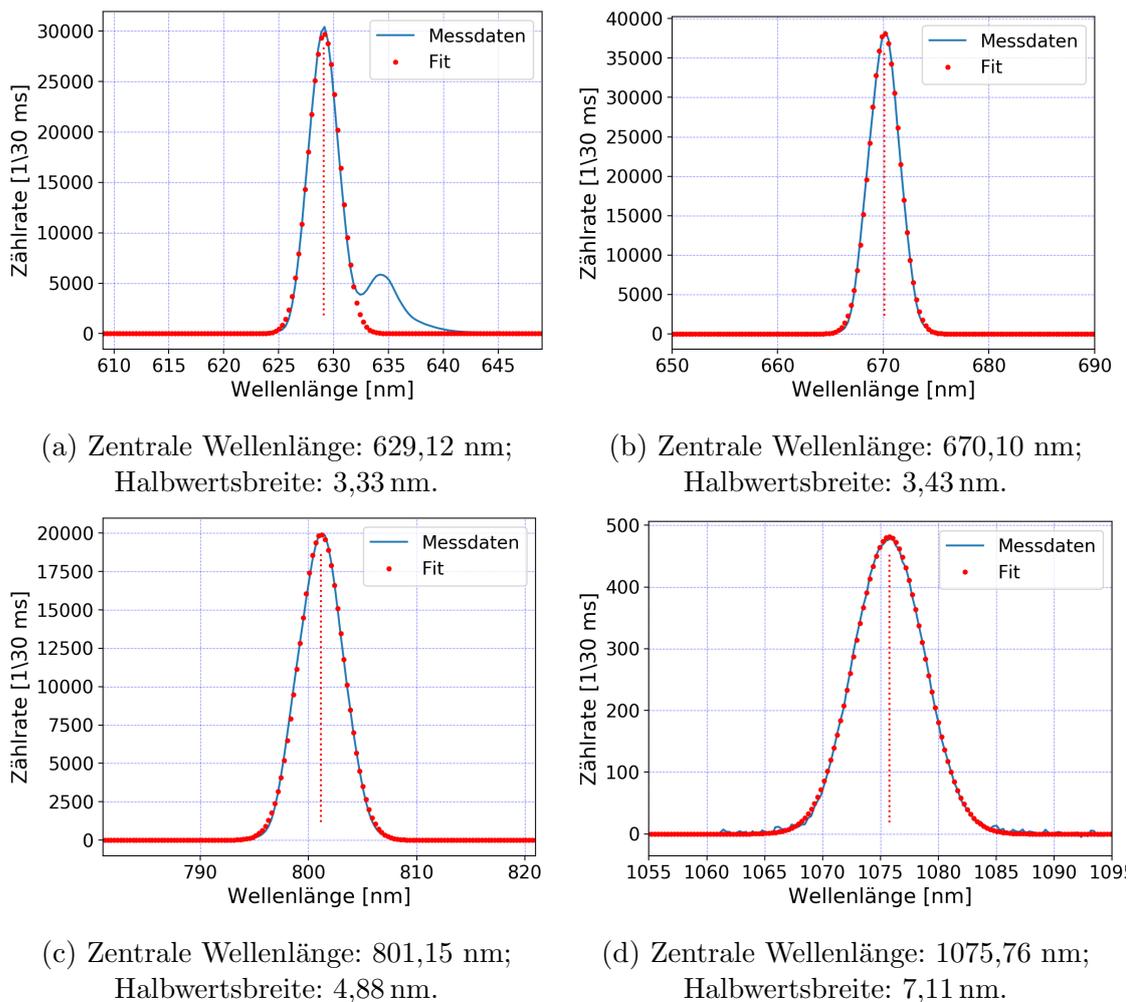


Abbildung 5.14: Spektrometer-Sensorantworten auf vier verschiedene Einstellungen des Monochromators. Mit Hilfe der Dichtefunktion kann jeweils ein Fit zur Bestimmung der zentralen Wellenlänge sowie der Halbwertsbreite erzeugt werden.

Untersuchungen mit dem Short-Pass Filter von Relevanz sind aber ausreichend gering.

Anzumerken ist ferner, dass die Justierung der Wellenlänge mit Hilfe eines Handrades am Monochromator erfolgt. So kann eine Einstellgenauigkeit von maximal 1 nm erreicht werden, wie anhand der Spektrometer-Messung deutlich wird. Die einzustellenden zentralen Wellenlängen können somit leicht von den Zielwerten abweichen. Die Lichtstimuli des Monochromators können also vom Spektrometer gemessen und mit Hilfe eines Fits durch die Dichtefunktion charakterisiert werden. Auf diese Weise werden die zentrale Wellenlänge sowie die Halbwertsbreite des Lichts bestimmt. Das wesentliche Ziel ist, die Hyperspektralkamera dem so charakterisierten Licht auszusetzen und dessen Sensorantwort zu analysieren.

#### 5.3.3 Kamera-Signal

Mit dem in Abschnitt 5.3.1 beschriebenen Versuchsaufbau kann nun die Sensorantwort der Hyperspektralkamera auf denselben Lichtstimulus des Monochromators, der zuvor mit dem Spektrometer charakterisiert wurde, untersucht werden.

Da die zur Bildaufnahme vom Kamerahersteller zur Verfügung gestellte Software nur unzureichende Flexibilität bietet und zudem die darin integrierte automatische Belichtungseinstellung Sättigungseffekte nicht zuverlässig verhindert, wird mit der Programmiersprache Python ein eigenes Aufnahme-Skript geschrieben. Mit Hilfe der Python-Application Programming Interface (API) kann die Kamera in das Python-Programm eingebunden werden. Dieses strukturiert sich in drei Klassen, die jeweils Funktionalitäten für Grundfunktionen der Kamera, Aufnahme-Optionen sowie Auswertungs- bzw. Korrekturmethode bereit stellen.

#### Datenerhebung

Nachdem mit Hilfe des Spektrometers das Licht am Austrittsspalt des Monochromators auf die gewünschte Wellenlänge eingestellt wurde, erfolgt die Messung dieses Lichts mit der Hyperspektralkamera. Das Spektrometer wird dazu aus dem Strahlengang verfahren.

Die Datenerhebung durch die Kamera erfolgt entsprechend des links in Abbildung 5.15 gezeigten Programmablaufplans. Im ersten Schritt wird eine geeignete Belichtungszeit ermittelt, sodass der Dynamikbereich der Kamera vollständig ausgenutzt wird, ohne dass es zu Verzerrungen durch Sättigung kommt. Im folgenden Schritt wird eine vorgegebene Anzahl an Dunkelbildern und darauf folgend die gleiche Anzahl an Nutzbildern erhoben. Sowohl Dunkel- als auch Nutzbilder werden anschließend als Listen abgelegt und im Pickle-Format zusammen mit Versuchs-Metadaten abgespeichert. Die Struktur ist in Abbildung 5.16 veranschaulicht. Die Metadaten enthalten neben der verwendeten Belichtungszeit, dem Aufnahmedatum und dem eingesetzten Vorfilter weitere Parameter, die die Randbedingungen der Versuchsdurchführung allumfassend beschreiben.

#### Datennachbearbeitung und Korrektur

Die rechte Seite von Abbildung 5.15 zeigt den Verlauf der automatisierten Datennachbearbeitung, die auch die erläuterten Korrekturschritte enthält. Die zuvor abgelegte Pickle-Datei wird dazu geladen und die enthaltenen Daten für die Bearbei-

tung aufbereitet. Wenn die Daten im erwarteten Format vorliegen, werden im ersten Schritt die Mittelwerte und Standardabweichungen der Dunkel- und Nutzbilder über die Gesamtzahl der jeweils erhobenen Bilder ermittelt. Im nächsten optionalen Schritt erfolgt die Subtraktion des im Mittel gemessenen Dunkelbilds. Dieser optionale Schritt wird in den Untersuchungen am Monochromator durchgeführt. Im nächsten Schritt erfolgt wiederum optional die Normalisierung der Nutzbilder hinsichtlich der Belichtungszeit. Auch dieser Schritt wird im Rahmen der in diesem Kapitel vorgestellten Arbeiten durchgeführt, sodass die bei verschiedenen Wellenlängen gemessenen Intensitäten vergleichbar werden.

Schließlich erfolgen die wesentlichen Korrekturschritte. Die zweidimensionalen Nutzbilder werden in dreidimensionale Hyperspektralbilder überführt, die an jedem Ortspunkt Spektralvektoren enthalten. Diese Hyperspektralbilder werden dann bezüglich des Vignettierungseffekts durch die spektrale Flachfeldkorrektur korrigiert. Abschließend erfolgt die Anwendung der Korrekturmatrix, sodass die orts aufgelösten Spektren des Hyperspektralbildes zur Auswertung zur Verfügung stehen.

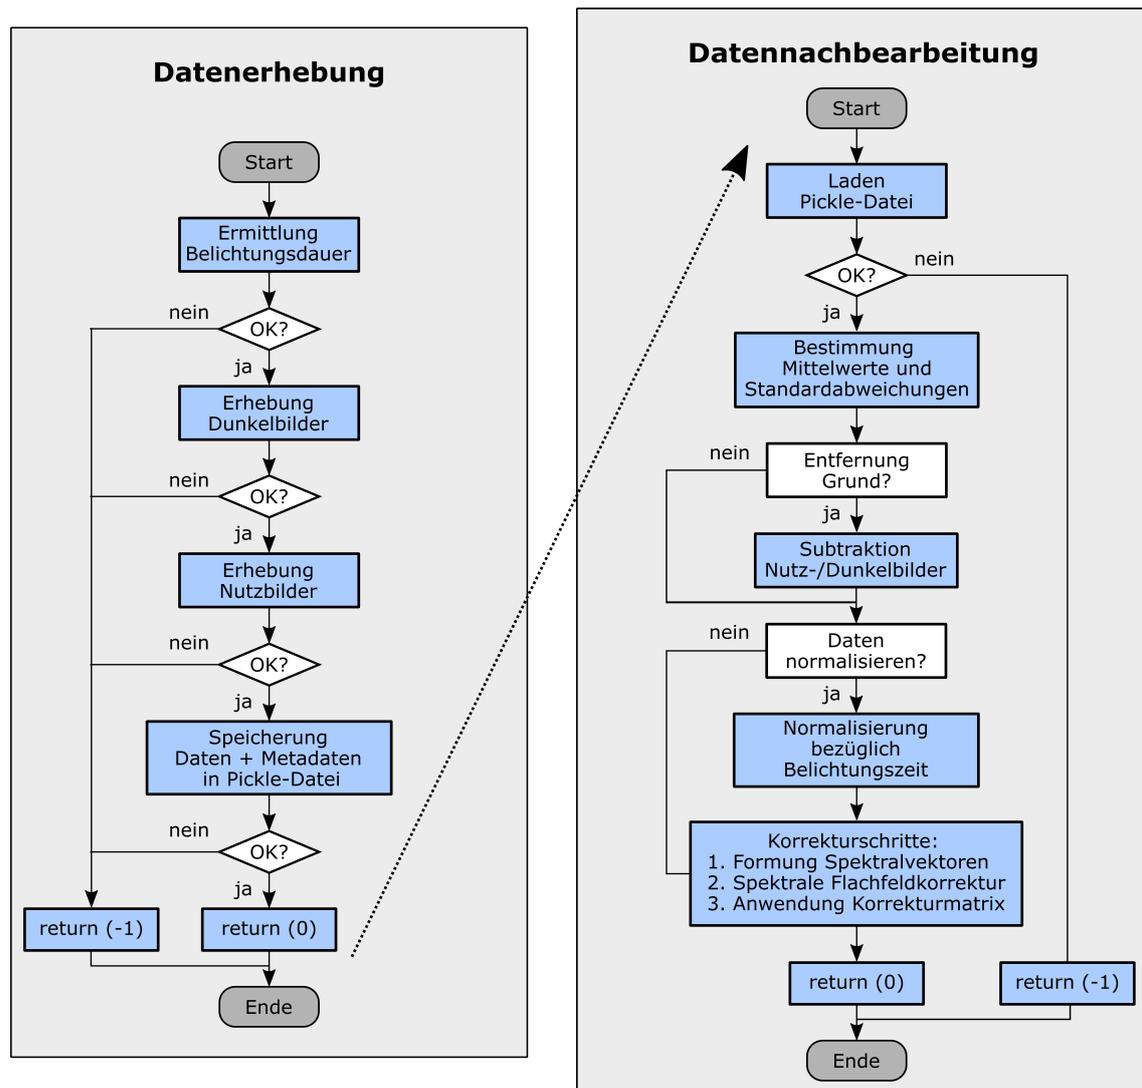


Abbildung 5.15: Programmablaufplan der Datenakquise und -nachbearbeitung.

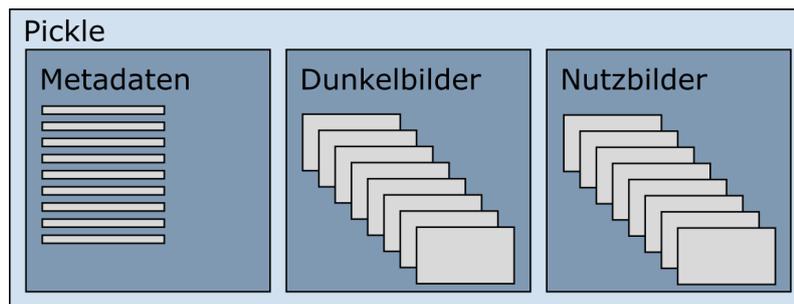


Abbildung 5.16: Struktur einer bei der Datenakquise erstellten Pickle-Datei.

### Kamera-Spektren

Zur Bewertung der spektralen Charakteristik der Hyperspektralkamera kann nun der in Abschnitt 5.3.1 beschriebene Versuchsaufbau eingesetzt werden. Mit Hilfe des Monochromators können die Kamera-Messwerte bei monochromatischem Licht analysiert werden. Das Kameraobjektiv wird dazu im Arbeitsabstand vor den Austrittsspalt des Monochromators platziert, sodass dieser scharf abgebildet wird. Die Spaltöffnung des Monochromators wird auf 0,05 mm eingestellt, damit bedingt durch die Vergrößerung des Objektivs eine ausreichende Anzahl an Pixeln zum Messsignal beitragen kann. Andererseits kann bei dieser Spaltbreite gewährleistet werden, dass die Halbwertsbreite der Lichtstimuli für eine Charakterisierung ausreichend gering bleibt. Im Zuge der Untersuchungen wird auch eine Spaltbreite von 0,1 mm untersucht. Diese wird aber aufgrund einer deutlichen Verbreiterung des messbaren Spektralbereichs für die Analyse nicht berücksichtigt.

Der Austrittsspalt des Monochromators wird also entlang einer vertikalen Linie auf dem Kamerasensor abgebildet. Es wird sichergestellt, dass mindestens zwei Mosaik vollständig belichtet werden. Zur Analyse des mit der Kamera bestimmten Spektrums wird der Spektralvektor mit den höchsten gemessenen Intensitäten ermittelt. Dazu wird in Form eines Suchalgorithmus die maximale Messwertsumme  $I_{max}$  über die Intensitäten der einzelnen Bänder ermittelt. Die Messwertsumme  $I_{i,j}$  des Mosaiks der Koordinate (i,j) wird wie folgt bestimmt:

$$I_{i,j} = \sum_{k=1}^{23} \lambda_{i,j,k} \quad \text{mit } \vec{S}_{i,j} = (\lambda_{i,j,1}, \lambda_{i,j,2}, \dots, \lambda_{i,j,k}) \quad (5.3)$$

$\vec{S}_{i,j}$ : Spektralvektoren

Der Spektralvektor mit maximaler Messwertsumme wird schließlich als Spektralinformation zur Analyse verwendet.

Die spektrale Charakterisierung der Hyperspektralkamera mit Short-Pass Vorfilter wird mit den in Tabelle 5.4 gezeigten Wellenlängen durchgeführt. Sie entsprechen einerseits den Sensitivitäts-Maxima der virtuellen Bänder bei diesem Vorfilter und andererseits einem regelmäßigem Inkrement von 25 nm zwischen 600 und 875 nm.

Zur Bewertung der Kamera-Spektren werden diese mit den aus den Spektrometer-Daten des identischen Lichtstimulus ermittelten Fits verglichen. Da die Messwerte der beiden Sensoren nicht ohne Weiteres vergleichbar sind, soll hier lediglich ein qualitativer Vergleich erfolgen. Dazu wird in der graphischen Darstellung der Messwerte die Skalierung insofern aufeinander angepasst, als beide Maxima sichtbar werden.

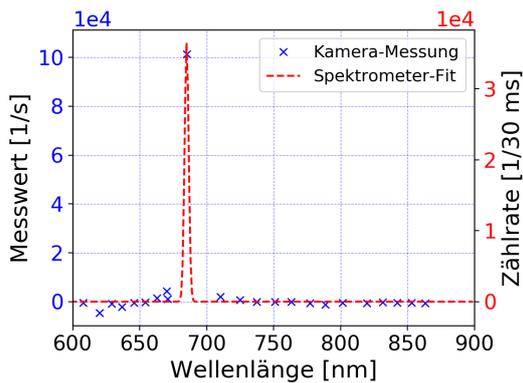
Tabelle 5.4: Eingestellte zentrale Wellenlängen zur Untersuchung des Kamera-Signals bei Einsatz des Short-Pass Filters.

Zentrale Wellenlängen [nm]							
600,0	607,6	619,8	625,0	629,0	636,8	645,8	650,0
653,9	662,9	670,0	670,8	675,0	685,0	700,0	710,1
724,7	725,0	737,4	750,0	751,1	763,2	775,0	777,1
788,5	800,0	801,4	819,7	825,0	831,6	842,1	850,0
853,1	863,3	875,0	—	—	—	—	—

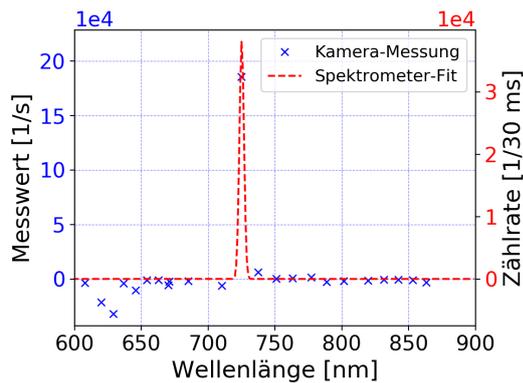
Dies basiert auf der Annahme, dass die Sensitivitäten beider Sensoren im Spektralbereich des Lichtstimulus unabhängig von der Wellenlänge konstant sind. Da die Lichtstimuli wie bereits untersucht eine spektrale Halbwertsbreite von lediglich einigen wenigen Nanometern aufweisen, wird diese Annahme als valide eingeschätzt. Somit müsste über die Anpassung der Skalierungen zumindest dann eine Angleichung der Spektren zu beobachten sein, wenn die Kamera das monochromatische Licht korrekt aufzulösen vermag.

Die Ergebnisse der Untersuchungen sind in Abbildung 5.17 exemplarisch an sechs verschiedenen Wellenlängen dargestellt. Die Kamera-Spektren aller untersuchten und in Tabelle 5.4 aufgeführten Wellenlängen sind in Anhang A.3 dargestellt. Aufgrund der in Kapitel 4 innerhalb eines zu vernachlässigenden Fehlerbereichs gezeigten Reproduzierbarkeit der Messergebnisse wird in den Abbildungen zugunsten erhöhter Klarheit auf Fehlerbalken verzichtet. Für Abbildungen 5.17a, 5.17c und 5.17e entsprechen die untersuchten Wellenlängen den Sensitivitäts-Maxima von virtuellen Bändern der Kamera. Bei den Abbildungen 5.17b, 5.17d und 5.17f liegen die Wellenlängen jeweils abseits der virtuellen Bänder. Die gemessenen Intensitätsverteilungen der Hyperspektralkamera können je nach Übereinstimmung mit dem Spektrometer-Fit in drei Kategorien eingeteilt werden:

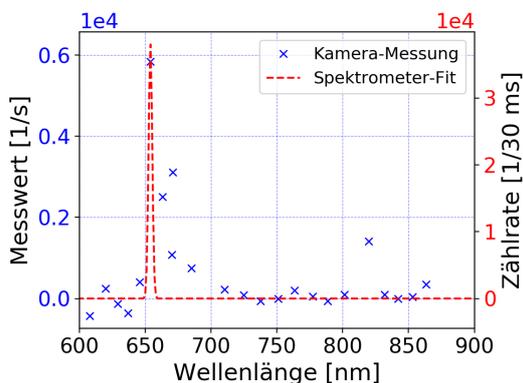
- **Hohe Übereinstimmung:** Kontrastreiches Signal einer einzelnen Spektralkomponente. Neben den in Abbildung 5.17 dargestellten zentralen Wellenlängen von 685,1 und 725,1 nm wird dies bei 607,0 nm, 636,8 nm, 645,8 nm, 662,9 nm, 670,0 nm sowie bei 670,8 nm beobachtet.
- **Eingeschränkte Übereinstimmung:** Deutliche Verbreiterung des gemessenen Spektrums durch Intensitäten in mehreren Filterkomponenten. Beispiele sind Abbildungen 5.17c und 5.17d bei 653,9 und 650,0 nm. Obwohl der Lichtstimulus eine Halbwertsbreite von 3,3 nm aufweist und die benachbarten virtuellen Bänder jeweils rund 9 nm entfernt liegen, tragen mehrere Bänder zum Signal bei. Zwar liegt der maximal gemessene Intensitätswert bei der zu erwartenden Wellenlänge, es sollte aber nur in diesem Band überhaupt Intensität gemessen werden können. Ähnliche Effekte werden bei den Wellenlängen 600,0 nm, 619,8 nm, 625,1 nm, 629,1 nm, 710,0 nm, 724,6 nm, 725,1 nm, 737,3 nm, 749,9 nm, 750,9 nm, 763,2 nm, 774,9 nm, 777,2 nm, 788,4 nm, 801,1 nm sowie bei 819,6 nm beobachtet.
- **Geringe Übereinstimmung:** Bei einigen Intensitätsverteilungen ist die Wellenlänge der Lichtstimuli wenn überhaupt nur deutlich erschwert zu ermit-



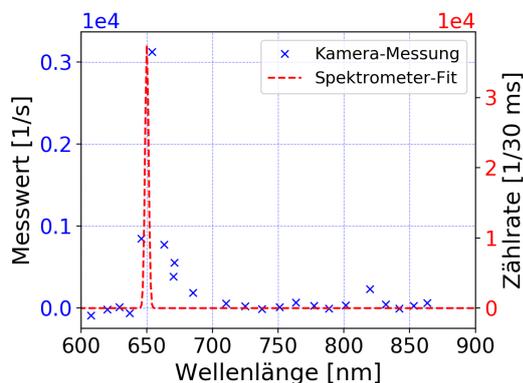
(a) Zentrale Wellenlänge: 685,1 nm.



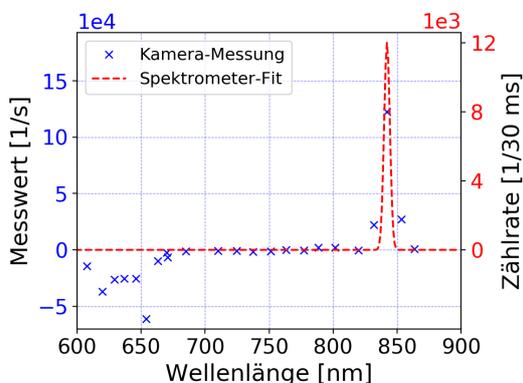
(b) Zentrale Wellenlänge: 725,1 nm.



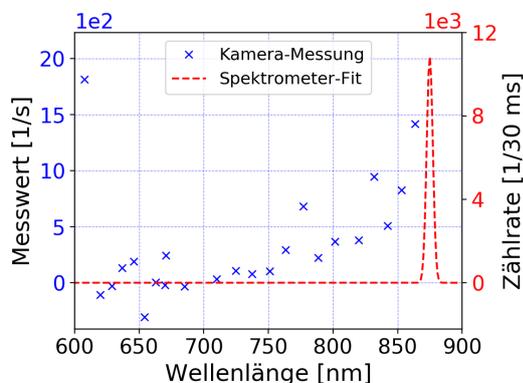
(c) Zentrale Wellenlänge: 653,9 nm.



(d) Zentrale Wellenlänge: 650,0 nm.



(e) Zentrale Wellenlänge: 842,1 nm.



(f) Zentrale Wellenlänge: 875,9 nm.

Abbildung 5.17: Beispielhafte Kamerasignale bei unterschiedlichen Wellenlängen und bei Einsatz des Short-Pass Filters. Für a), c) und e) entsprechen die untersuchten Wellenlängen den Sensitivitäts-Maxima von virtuellen Bändern der Kamera. Die restlichen Wellenlängen liegen abseits der virtuellen Bänder. Die Aussagequalitäten variieren zum Teil stark.

teln. Das ausgeprägteste Beispiel hierfür ist bei den Untersuchungen die in Abbildung 5.17f dargestellte Verteilung bei 874,9 nm. Hier scheint die Unterdrückung der Harmonischen durch den Vorfilter nicht auszureichen, denn bei ungefähr 600 nm ist die höchste Intensität zu beobachten. Des Weiteren

sind bei einigen Wellenlängen durch die KorrekturmatriX bedingte negative Intensitätswerte in mehreren Bändern abseits der zentralen Wellenlänge des Lichtstimulus zu beobachten. Ein Beispiel hierfür zeigt Abbildung 5.17e. Dies tritt zusätzlich bei den Wellenlängen 675,0 nm, 700,0 nm, 824,8 nm, 831,3 nm, 850,1 nm, 853,0 nm sowie 863,6 nm auf.

Hinsichtlich der Bewertung der spektralen Auflösungsfähigkeit und -genauigkeit der Hyperspektralkamera ergibt sich somit ein gemischtes Bild. Bei der Detektion von monochromatischem Licht hängt es von der Wellenlänge ab, ob diese eindeutig von der Kamera erkannt werden kann. Bei der Detektion von breitbandigerem Licht, wie es in den meisten potentiellen Messszenarien für Flächen-Hyperspektralkameras vorkommt, kommt es somit zwangsläufig zu Verzerrungen des gemessenen Spektrums. Für viele Anwendungen der Qualitätssicherung muss dies kein Nachteil sein. Für eine analytische Verwendung des Sensors müssten die Ursachen für die Abweichungen der Kameraspektren von den erwarteten Verteilungen allerdings genauer untersucht werden. Hierbei sollte vor allem der Einfluss der Fabry-Pérot-Filterstruktur in Verbindung mit dem Short-Pass-Vorfilter betrachtet werden. Eine solche Untersuchung wird für die Ziele dieser Arbeit jedoch nicht als prioritär eingestuft.

## 5.4 Fazit

Das Ziel dieser Arbeit ist, den Einsatz einer Flächen-Hyperspektralkamera zur Prozess- und somit Qualitätsüberwachung in der pulverbettbasierten additiven Metallfertigung zu untersuchen. Die Grundlage dafür ist, dass die Eigenschaften der Sensorik insbesondere hinsichtlich Reproduzierbarkeit der Messergebnisse sowie räumlichem und spektralem Auflösungsvermögen bekannt sind.

Kapitel 4 zeigt, dass die Messergebnisse der Hyperspektralkamera bei stabiler Lichtquelle in einem hinreichenden Toleranzbereich reproduzierbar sind. Hyperspektrale Bildaufnahmen von Laser-Punktschweißungen verdeutlichten hingegen die in der Lasermaterialbearbeitung üblichen starken Schwankungen der Lichtentstehung. Nichtsdestotrotz wird während der Punktschweißungen stets ein kontinuierlicher, aber über die verschiedenen Wellenlängen unterschiedlich starker Anstieg der Intensitäten beobachtet.

In diesem Kapitel geht es darum, die Hyperspektralkamera hinsichtlich ihrer besonderen Eigenschaft – der Kombination von örtlicher und spektraler Auflösung – zu charakterisieren. Dabei wird analysiert, welchen Weg das Licht zurücklegt, bevor es vom Detektor erfasst wird und zu welchen Verzerrungen des Messsignals es folglich kommen kann.

Das Prinzip der hyperspektralen Bildgebung durch Beschichtung der Sensorpixel mit Fabry-Pérot Filtern verlangt einige besondere Korrekturschritte. Aus einem zweidimensionalen Bild wird ein dreidimensionales Bild durch Formung von Spektralvektoren. Die Flachfeldkorrektur erfolgt bei Hyperspektralbildern bandspezifisch, um die durch Vignettierung bedingte Verzerrung des Spektrums zu den Bildrändern hin zu korrigieren.

Der zur Bestimmung des Spektrums wesentliche Korrekturschritt ist aber die Anwendung der KorrekturmatriX auf die Spektralvektoren. Dadurch werden die Transmissivitäten der 25 Fabry-Pérot Filter mit Hilfe von Koeffizienten so aufaddiert, dass möglichst nur an einer Wellenlänge ein möglichst schmales Sensitivitäts-Maximum

entsteht. Dadurch werden die sogenannten virtuellen Bänder erzeugt. Abschnitt 5.2.4 dieses Kapitels zeigt, dass beim Short-Pass Filter in einigen virtuellen Bändern zusätzliche negative Sensitivitäten auftreten, die das Messsignal potentiell verfälschen können.

In Abschnitt 5.3.3 wird schließlich das Kamera-Signal bei monochromatischem Licht unterschiedlicher Wellenlänge untersucht. Das Licht am Austrittsspalt eines Monochromators wird dabei mit einem Spektrometer erfasst und das Messergebnis durch die gauß'sche Dichtefunktion angenähert. So kann die zentrale Wellenlänge ermittelt und mit dem Messergebnis der Hyperspektralkamera verglichen werden. Bei einem Großteil der betrachteten Wellenlängen kann mit der Kamera die Spektralinformation gemäß dem Spektrometer-Signal korrekt erfasst werden. Bei vielen weiteren Wellenlängen wird hingegen entweder ein verbreitertes oder zum Teil sogar stark verfälschtes Spektrum gemessen. Die Ursachen dafür liegen einerseits im unzureichenden Effekt der Korrekturmatrix begründet, müssten für ein genaueres Verständnis aber tiefergehend untersucht werden.

Im Hinblick auf das Ziel dieser Arbeit wird die korrekte spektrale Charakterisierung der Prozessemissionen jedoch nicht als prioritär eingestuft. Im Vordergrund steht nicht die analytische Betrachtung physikalischer oder chemischer Prozesse, die anhand ihrer spektralen Signatur verstanden werden sollen. Vielmehr geht es darum, zu untersuchen, ob durch die Kombination räumlicher und spektraler Auflösung, wie sie durch die Flächen-Hyperspektralkamera möglich wird, Merkmale zur Bewertung der Qualität des Laserschmelzprozesses erfassbar werden. Insofern liegt der weitere Schwerpunkt dieser Arbeit nicht darauf, eine möglichst exakte Kalibrierung der Hyperspektralkamera zu erreichen. Stattdessen werden Methoden untersucht, die es ermöglichen, in den komplexen Daten der Hyperspektralkamera Hinweise auf Bauteileigenschaften und Prozessfehler zu finden. Neben der Integration der Sensorik in die Prozessanlage sowie dem Aufbau einer Infrastruktur zur Datenerfassung liegt der Fokus deshalb auf Methoden des maschinellen Lernens. Diese sind dazu prädestiniert, für die Zielgröße relevante Merkmale aus den Daten zu extrahieren. Welche Merkmale und insbesondere welche spektralen Informationen zur Vorhersage der Prozessqualität führen ist bei solchen lernfähigen Algorithmen letztlich nicht mehr nachvollziehbar.

Demnach können die Kamera-Spektren zwar nicht auf physikalische Größen abgebildet werden. Gleichwohl können die Kamera-Spektren – durch das vom Prozess ausgesendete Spektrum bedingt – relevante Daten über das Prozessgeschehen enthalten.



# 6 Hyperspektrale Prozessüberwachung zur Vorhersage der Oberflächenrauheit durch ein Convolutional Neural Network

In diesem Kapitel wird die wissenschaftliche Fragestellung adressiert, inwiefern hyperspektrale Aufnahmen Informationen über die Qualität des LPBF-Prozesses liefern. Anhand der Magnesiumlegierung WE43 wird die hyperspektrale Prozessüberwachung zur Vorhersage der Oberflächenrauheit  $R_z$  untersucht.

Die Sensorik wird dazu an eine LPBF-Laboranlage integriert, sodass das verwendete Objektiv einen definierten Sichtbereich der Bauplattform erfasst. Bei den Untersuchungen wird während des Bauprozesses nur eine Schicht erzeugt, währenddessen kontinuierlich Prozessaufnahmen erfolgen. Um einen Zusammenhang zwischen den Intensitäten des Prozessleuchtens in verschiedenen Wellenlängenbändern und der Oberflächenrauheit zu finden, wird ein Convolutional Neural Network angewandt. Die Prozessaufnahmen dienen zum Training des Convolutional Neural Networks, das dabei nach Merkmalen zur Erkennung der Oberflächenrauheit sucht. Die Vorhersagegenauigkeit wird abschließend anhand mehrerer Netzwerktopologien untersucht und bewertet.

## 6.1 LPBF-Anlage und Integration der Sensorik

Zur Durchführung der Versuche des Laserstrahlschmelzens wird eine Laboranlage ausgewählt, die eine hohe Flexibilität hinsichtlich Zugänglichkeit und Prozesssteuerung aufweist. Die Daten der gewählten Anlage sind Tabelle 6.1 zu entnehmen. Der CW-Faserlaser hat mit 50 W eine relativ geringe maximale Leistung, durch den kleinen Fokusbereich von 19  $\mu\text{m}$  ist die Intensität aber ausreichend. Die Wellenlänge des Lasers liegt im LPBF-typischen IR-Bereich bei 1070 nm. Durch die Integration des 875 nm Short-Pass Filters in das Objektiv kann die Laserstrahlung ausgefiltert und die Kamera geschützt werden.

Für die Integration der Kamera in der Off-Axis Konfiguration ist entscheidend, dass der Arbeitsabstand des Objektivs von 190 mm genau eingestellt werden kann und der Abstand zur optischen Achse des Lasers und somit der Verkippwinkel gering sind. Abbildung 6.1 zeigt die Laboranlage sowie schematisch das Sichtfeld der Kamera

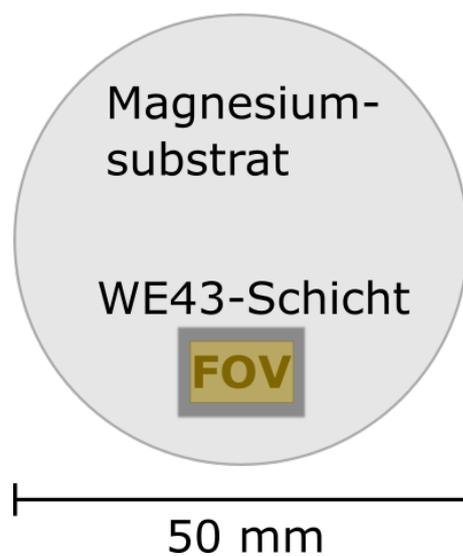
in Relation zu der Bauplattform und dem aufgeschmolzenen Bereich. In Abbildung 6.1a ist das Objektiv rechts oben neben dem Scan-System, weiter unten die Bauplattform und der Beschichter zu sehen. Der Verkippwinkel des Objektivs liegt bei ca.  $15^\circ$ , sodass in einer Fläche von  $10\text{ mm} \times 6\text{ mm}$  durch die Tiefenschärfe des Objektivs ausreichend scharf aufgelöste Prozessaufnahmen erhoben werden können. Die Fertigung der Proben erfolgt durch Belichtung in einer Fläche von  $14\text{ mm} \times 10\text{ mm}$ , sodass nur aus dem zentralen Bereich der Probe emittiertes Licht die Kamera erreicht.

Tabelle 6.1: Eckdaten der LPBF-Laboranlage zur Verarbeitung der Magnesiumlegierung WE43.

<b>Laserstrahlquelle</b>	Faserlaser YLR-50 (IPG Photonics) 50 W, 1070 nm
<b>Laser-Scansystem</b>	intelliScan 14 (Scanlab AG)
<b>Scanner-Objektiv</b>	Fokusabstand 100 mm, telezentrisch Fokusbildmesser $19\ \mu\text{m}$
<b>Schutzgasatmosphäre</b>	Argon bis 200 ppm Restsauerstoff
<b>Beschichtung</b>	automatisiert Beschichter aus Kohlenstofffaser
<b>Bauplattform</b>	AZ31-Substrat $\varnothing 50\text{ mm}$
<b>Steuerung</b>	RTC-5 Karte (Scanlab AG) SL2-100 Protokoll



(a) Labor-LPBF-Anlage



(b) Kamerabild

Abbildung 6.1: LPBF-Laboranlage mit Off-Axis Kamera Integration.

## 6.2 Versuchsdurchführung

### 6.2.1 LPBF von Magnesium

Die additive Fertigung von Magnesiumlegierungen im Pulverbettverfahren stellt hohe Anforderungen an die Prozessführung. Durch die hohe Oxidationsneigung muss bei jeder Schicht MgO aufgeschmolzen werden, das eine relativ hohe Schmelztemperatur von 2800 °C im Vergleich zur Verdampfungstemperatur von Reinmagnesium von 1090 °C aufweist [Kam00]. Das Prozessfenster ist somit sehr klein und es kommt während des Prozesses verstärkt zu Rauchbildung. Dadurch motiviert gibt es bereits Untersuchungen zum Einsatz höherer Prozessdrücke sowie wasserstoffhaltiger Prozessgase [Gie15]. Dennoch bietet insbesondere die Magnesiumlegierung WE43 durch gute Biokompatibilität sowie -resorbierbarkeit die Perspektive, Implantate patientenindividuell additiv zu fertigen. Im LPBF-Verfahren können mit dieser Legierung bereits hohe relative Materialdichten von bis zu 99,9 % erreicht werden [Gie13].

Auf der Grundlage früherer Arbeiten mit WE43 [Gie15] an derselben Laboranlage werden drei Prozessparameter für die Untersuchungen ausgewählt. Wie in Abb. 6.2 zu sehen, können je nach Ausprägung der aufgeschmolzenen Spur verschiedene Parameterbereiche für die Laserleistung und Vorschub- bzw. Scangeschwindigkeit definiert werden. Demnach werden 50 W Laserleistung bei 75 mm/s Scangeschwindigkeit für eine saubere Spur, 20 W und 75 mm/s für eine unterbrochene Spur mit Ansinterungen sowie 50 W und 40 mm/s für eine übermäßig aufgeschmolzene Spur gewählt. Die drei Parameter sollen unterschiedliche Oberflächenrauheiten  $R_z$  erzeugen, deren Detektion mit Hilfe hyperspektraler Prozessaufnahmen untersucht werden soll. Für eine statistisch ausreichende Probenzahl sollen 20 Proben mit dem ersten und jeweils 10 Proben mit den anderen beiden Parametern gefertigt werden.

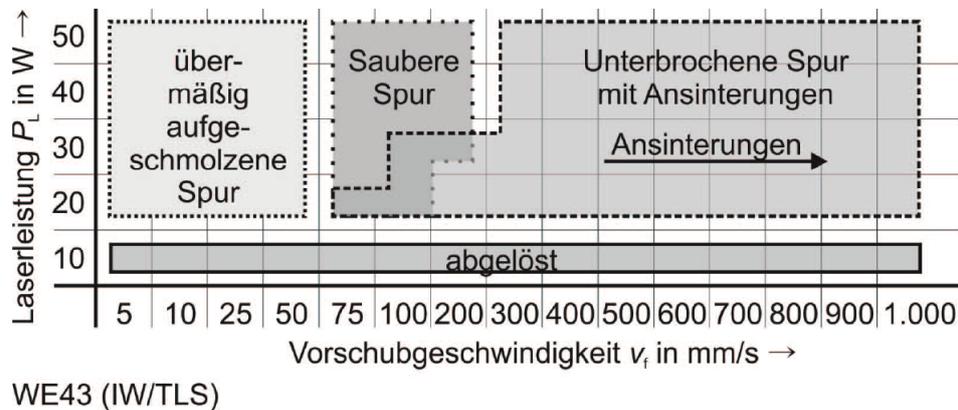


Abbildung 6.2: Prozesskarte für WE43 aus [Gie15].

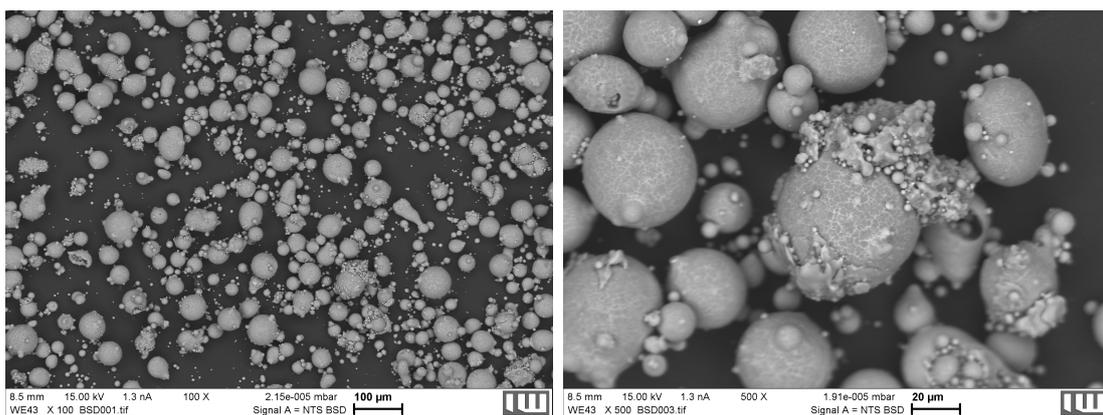
### 6.2.2 Pulverwerkstoff

Da die Pulvereigenschaften für die Bauteilgüte und die Reproduzierbarkeit des LPBF-Prozesses einen signifikanten Einfluss haben, wird das WE43-Pulver in mehreren Messverfahren charakterisiert. Tabelle 6.2 fasst die wichtigsten Testergebnisse zusammen. Das LPBF-Verfahren ist am leistungsfähigsten, wenn die Pulverpartikel möglichst sphärisch und dadurch fließfähig sind und das Material eine geringe

Feuchtigkeit aufweist. Die Sphärizität kann qualitativ anhand der REM-Aufnahmen (Abb. 6.3) und quantitativ durch Ergebnisse des sogenannten Dynamic Particle Image Analysis Verfahrens bewertet werden. Dabei zeigt sich, dass die Partikel für den Prozess ausreichend rund sind, was durch den Hausner-Faktor - ein Maß für die Fließfähigkeit - bestätigt wird. Die Feuchtigkeit ist zudem ausreichend niedrig, was durch angemessene Lagerbedingungen erhalten werden muss. Außerdem liegt die Korngrößenverteilung bezüglich absoluter Partikelgröße sowie Streuung der Größen in einem angemessenen Bereich. Der Feinanteil des Pulvers mit Partikeln  $< 5 \mu\text{m}$  ist gering, sodass die Fließfähigkeit nicht beeinträchtigt wird.

Tabelle 6.2: Magnesiumlegierung WE43: Eigenschaften des für die Untersuchungen verwendeten Pulverwerkstoffs.

Pulverwerkstoff WE43		Messverfahren
Material-Zusammensetzung	Mg: 92,2; Y: 4,3 Nd: 3,4 (in Gew.-%)	EDX
Korngrößenverteilung	$D_{10}$ : 13,6; $D_{50}$ : 31,4 $D_{90}$ : 58,5 (in $\mu\text{m}$ )	Dynamic Particle Image Analysis
Sphärizität	SHP $< 0,8$ : 15,3 % SHP $< 0,9$ : 53,1 %	
Hausner-Faktor	1,26	ISO 3953
$H_2O$ -Gehalt	0,05 %	Karl Fischer Titration



(a) 100-fache Vergrößerung

(b) 500-fache Vergrößerung

Abbildung 6.3: REM-Aufnahmen des WE43-Pulverwerkstoffes bei verschiedenen Vergrößerungen. Die Partikel sind überwiegend sphärisch; es gibt einen gewissen Feinanteil. Die Aufnahmen sind am Institut für Werkstoffkunde der Leibniz Universität Hannover entstanden.

## 6.3 Aufnahme hyperspektraler Prozessdaten und Datenvorverarbeitung

### 6.3.1 Datenaufnahme und -verarbeitung

Zur Programmierung eines Skripts zur Datenaufnahme und -verarbeitung wird die vom Kamerahersteller zur Verfügung gestellte API für die Programmiersprache Python verwendet. Dies ist insofern vorteilhaft, als auch die Datenauswertung durch Methoden des maschinellen Lernens in dieser Sprache erfolgt.

Abb. 6.4 zeigt schematisch die Organisation der Akquise, Speicherung und Weiterverarbeitung der Prozessaufnahmen. Ein wesentliches Kriterium für eine effektive Datenverarbeitung ist, die Datenmengen möglichst klein zu halten. Bei Prozessstart werden kontinuierlich Bilddaten aufgenommen und der maximale Grauwert ermittelt. Sobald der Laserspot im Field of View (Sichtbereich) (FOV) der Kamera liegt, erhöht sich schlagartig der maximale Grauwert. Deshalb wird die Speicherung der Aufnahmen gestartet, sobald dieser Wert für eine Zeit von 20 Millisekunden (entspricht bei einer Belichtungszeit von vier Millisekunden fünf aufeinanderfolgenden

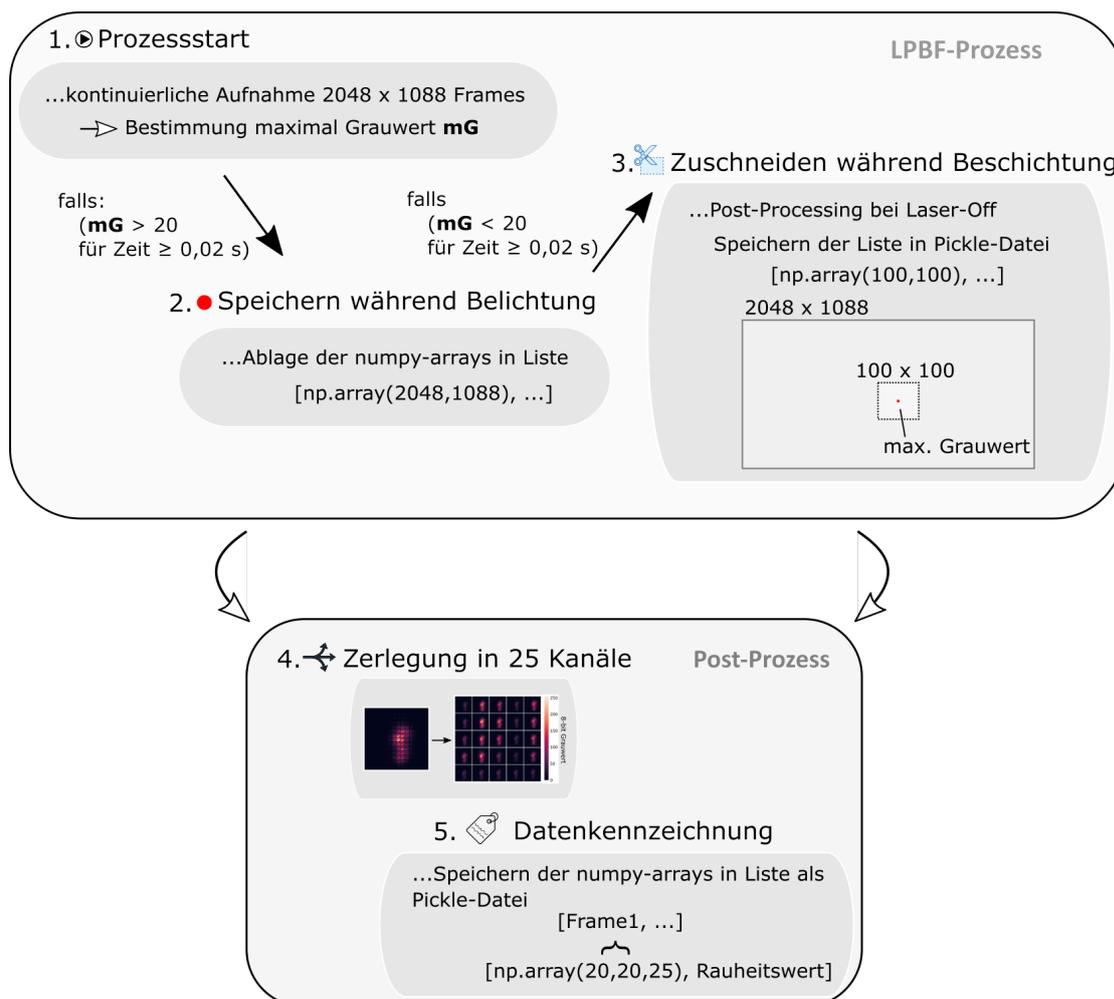


Abbildung 6.4: Schema der Datenaufnahme und -weiterverarbeitung während des LPBF-Prozesses und danach.

Aufnahmen) über 20 liegt. Die Aufnahmen werden dann bei voller Auflösung von  $2048 * 1088$  Pixeln als Datentyp Numpy-array nacheinander in eine Python-Liste gelegt, solange bis der maximale Grauwert für eine Zeit von 20 Millisekunden wieder unter 20 fällt. Dies ist der Fall, sobald der Laserspot sich aus dem FOV hinaus bewegt und der Beschichtungsvorgang startet. Während der Beschichtung erfolgt nun die erste Datennachbearbeitung, indem bei jeder Aufnahme die Pixelkoordinaten des maximalen Grauwerts bestimmt werden und diese als Mittelpunkt eines  $100 * 100$  Ausschnitts fungieren. Um die weitere Datenauswertung zu vereinfachen, wird dieser Bereich so ausgeschnitten, dass der Rand eines Mosaiks immer mit der Schnittstelle zusammen fällt. Der Rest der Aufnahme wird verworfen.

Alle Aufnahmen einer Schicht werden nach dem Zuschneiden in einer Datei im sogenannten Pickle-Format gespeichert, das jegliche Python-Objekte aufnehmen kann und in diesem Falle als Container der Python-Liste dient. Das Zuschneiden der Aufnahmen wird unterbrochen, sobald der Laser die nächste Schicht belichtet. In den Untersuchungen dieses Kapitels wird jedoch je Baujob nur eine Schicht gefertigt.

Die weiteren Schritte der Datenaufbereitung erfolgen nach Abschluss des Fertigungsprozesses. Die  $100 * 100 * 1$  Aufnahmen werden zunächst in  $20 * 20 * 25$  Bilder zerlegt, um die Spektralbänder in unterschiedliche Kanäle zu sortieren bzw. die Spektralvektoren zu erzeugen. Abb. 6.5 zeigt diesen Vorgang. Sobald die Auswertung der Proben erfolgt ist – in diesem Falle die Bestimmung der Oberflächenrauheit  $R_z$  – können die Daten gekennzeichnet werden. Das Ergebnis ist eine Python-Liste, in der jeder Eintrag wiederum eine Liste enthält, die sowohl die Aufnahme als Numpy-array als auch die Kennzeichnung als Float-Wert beinhaltet. Diese Liste kann als Eingang für ein Convolutional Neural Network verwendet werden.

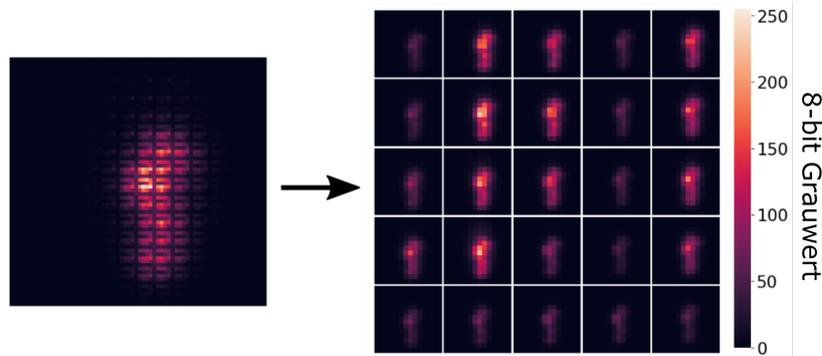


Abbildung 6.5: Beispiel einer Aufnahme während des Laserschmelzens von WE43-Pulver. Die  $100 * 100$  Bilder werden in  $20 * 20$  Bilder mit 25 Kanälen konvertiert.

### 6.3.2 Bestimmung der Belichtungszeit

Die Wahl der Belichtungszeit ist kritisch, um den höchstmöglichen Informationsgehalt aus den Aufnahmen zu erhalten. Dabei gilt es einerseits, genügend Licht einzufangen, um überhaupt Intensitäten messen zu können und andererseits, eine Sättigung der Pixel durch zu hohe Belichtungszeiten zu vermeiden. Der Dynamikbereich der Kamera erstreckt sich bei 8-bit Aufnahmen in Grauwerten von 0 bis 255. Das Ziel ist es somit, dass bei den Prozessaufnahmen möglichst viele Pixel einen Wert zwischen 0 und 255 annehmen. Über eine Anpassung der Belichtungszeit kann zudem gesteuert werden, welche Teile des Laserprozesses beobachtet werden.

Bei kurzen Belichtungszeiten liegt durch die hohen Lichtintensitäten im Laserspot dieser Bereich im Dynamikbereich der Kamera, wobei die übrigen Pixel der Aufnahmen dunkel bleiben. Bei höheren Belichtungszeiten kommt es im Laserspot zur Sättigung während die umliegenden Bereiche sichtbar werden. Zusätzlich muss allerdings bedacht werden, dass geringere Belichtungszeiten eine höhere Ortsauflösung und schnellere Information liefern.

Zur Bestimmung einer geeigneten Belichtungszeit werden sowohl Aufnahmen bei Blindschweißungen ohne Pulver, als auch beim eigentlichen LPBF-Prozess mit WE43-Pulver durchgeführt. Mehrere Belichtungszeiten werden eingestellt und anschließend der durchschnittliche maximale Pixelwert sowie die durchschnittliche Anzahl an Pixeln mit einem Wert von über fünf bestimmt. Alle Aufnahmen erfolgen bei identischen Prozessparametern von 50 W Laserleistung und 75 mm/s Scangeschwindigkeit. Tabelle 6.3 zeigt die Ergebnisse dieser Untersuchungen beim Laserschmelzen von WE43-Pulver. Für Belichtungszeiten von 4 - 100 ms kann eine unterschiedliche Zahl an Aufnahmen gewonnen werden. Zur Bewertung der Informationsdichte dieser Aufnahmen werden der durchschnittliche maximale Grauwert sowie die durchschnittliche Anzahl an Pixeln mit einem Grauwert von über fünf errechnet. Es zeigt sich, dass die Informationsdichte bei höheren Zeiten zwar zunimmt, allerdings in geringem Maße und erst ab 25 ms. Solch hohe Belichtungszeiten führen aber zu einer deutlich geringeren Zahl an Aufnahmen und schlechter lokalisiertem Laserspot. Deshalb wird 4 ms als Belichtungszeit für weitere Untersuchungen bestimmt.

Bei noch geringeren Belichtungszeiten ist die Intensität so niedrig, dass das Aufnahmeskript der Kamera (siehe Abschnitt 6.3) nicht erkennen kann, dass die Laserbelichtung startete. Es ist bemerkenswert, dass die Lichtintensität bei Blindschweißungen deutlich höher ist als beim Pulverschmelzen, wie in Abbildung 6.6 deutlich wird. Dies ist durch die höhere Absorption [Kra17] und Streuung von Pulverwerkstoffen gegenüber Feststoffen erklärbar.

Tabelle 6.3: Übersicht über Aufnahmen der Hyperspektralkamera beim Laserschmelzen von WE43-Pulver bei verschiedenen Belichtungszeiten.

Belichtungszeit	# Aufnahmen	durchschnittl. max. Grauwert	durchschnittl. # Pixel > 5
4 ms	1607	46	88
8 ms	1273	41	76
15 ms	969	43	77
25 ms	634	51	117
50 ms	426	82	196
100 ms	238	75	225

## 6.4 Bestimmung der Oberflächenrauheit

Die Oberflächenrauheit  $R_z$  wird mit Hilfe eines Konfokalmikroskops des Typs Keyence VK X1050 gemäß DIN EN ISO 4288 bestimmt. Jede der 40 Proben wird bei einer geringen Vergrößerung von 2,5x ausgerichtet und bei einer Vergrößerung von 5x durch

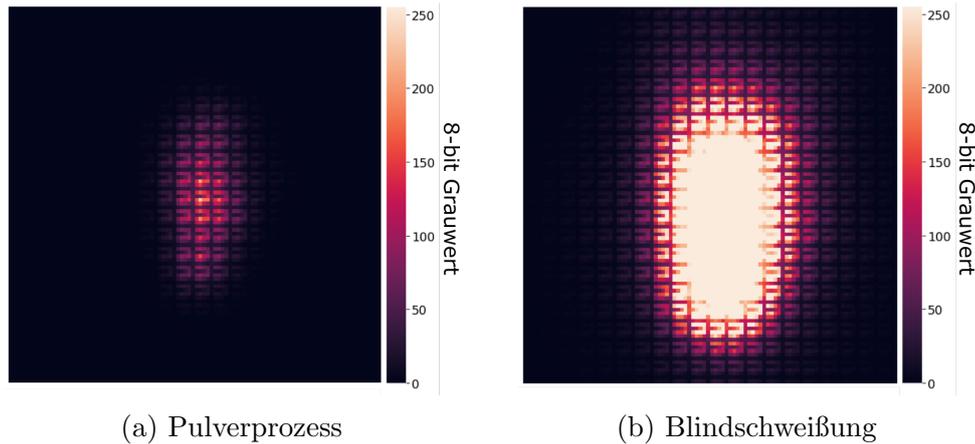


Abbildung 6.6: Vergleich der Aufnahmen bei einer Belichtungszeit von 4 ms und identischen Laserparametern (50 W; 75 mm/s) (a) beim LPBF-Prozess mit WE43-Pulver und (b) bei Blindschweißungen ohne Pulver auf AZ31-Substrat.

eine Fokusvariation abgescannt. Um die gesamte Probe der Fläche  $14 \text{ mm} * 10 \text{ mm}$  zu erfassen, werden jeweils  $6 * 6$  Bilder aneinander gefügt, was ein Gesamtbild von  $5506 * 4131$  Pixeln für jede Probe ergibt.

Abb. 6.7 zeigt sowohl die Aufnahme einer Probe als auch die Anordnung der Messstrecken. Die Grenzwellenlänge  $\lambda_c$  wird auf 2,5 mm und der Kurzwellenfilter  $\lambda_S$  auf  $8 \mu\text{m}$  festgelegt. Gemäß DIN EN ISO 4288 ergibt sich daraus eine Messstrecke  $l_n$  von 12,5 mm. Fünf Messstrecken werden zentral und äquidistant auf der Probe ausgerichtet. Für die weiteren Analysen wird der Mittelwert über die fünf Messergebnisse je Probe verwendet. Mögliche Verkippungen oder Verdrehungen der Oberflächen werden mit einem Korrekturalgorithmus korrigiert, wodurch sichergestellt wird, dass die fünf Messstrecken jeweils an der gleichen Stelle jeder Probe angesetzt werden.

Tabelle 6.4 zeigt die gemessenen Rauheiten der additiv gefertigten Proben. Sortiert nach Parametersatz wird für jede Probe der Mittelwert von  $R_z$  über die fünf Messstrecken angegeben. In Klammern steht die Anzahl an Aufnahmen der Hyperspektralkamera, die für diese Probe gespeichert werden kann. In der rechten Spalte werden schließlich die mittleren Rauheiten aller Proben eines Parametersatzes sowie deren mean absolute error (mittlerer absoluter Fehler) (MAE) aufgeführt. Diese Werte helfen in Abschnitt 6.5 bei der Bewertung, ob das Convolutional Neural Network tatsächlich Merkmale für unterschiedliche Rauheiten in den Aufnahmen findet oder lediglich eine Änderung der Prozessparameter erkennt.

## 6.5 Regression der Oberflächenrauheit durch ein Convolutional Neural Network

Im Folgenden soll der Zusammenhang zwischen den hyperspektralen Prozessaufnahmen und der Oberflächenrauheit untersucht werden. Wie in den vorherigen Abschnitten dargestellt, enthalten die Aufnahmen sowohl räumliche als auch spektrale Informationen über das Prozessleuchten. Diese Informationen könnten wiederum wesentliche Merkmale zur Vorhersage der Rauheit beinhalten. Da diese Merkmale unbekannt sind, wird eine Methode des maschinellen Lernens, ein sogenanntes Con-

## 6.5. REGRESSION DER OBERFLÄCHENRAUHEIT DURCH EIN CONVOLUTIONAL NEURAL NETWORK

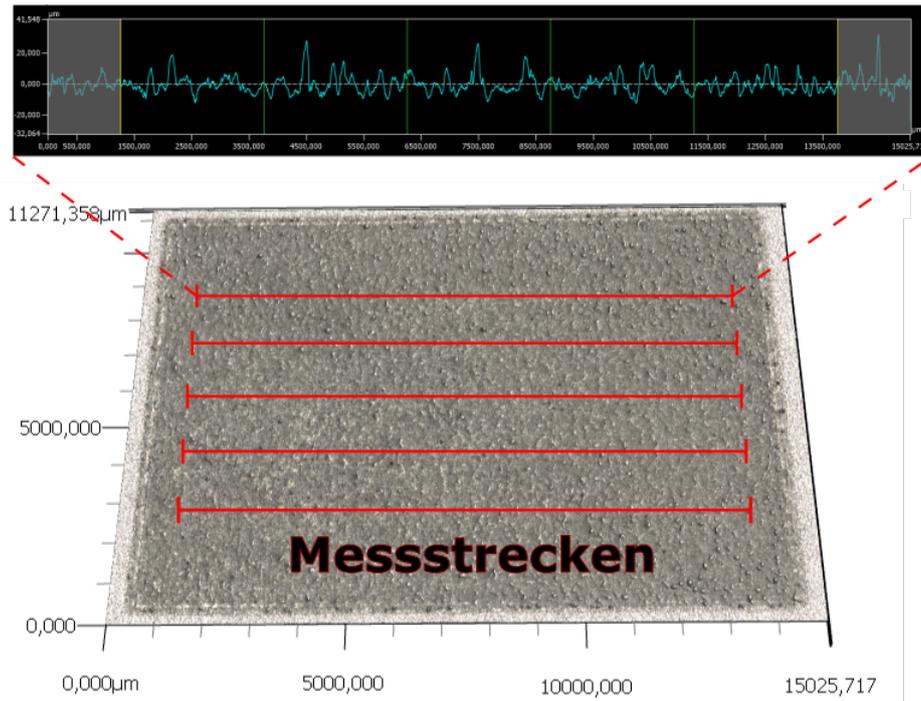


Abbildung 6.7: Bild einer WE43-Probe, die mit dem Konfokalmikroskop aufgenommen wird. Die Rauheit  $R_z$  wird an fünf verschiedenen Messstrecken bestimmt.

volutional Neural Network, angewandt.

Die Eingangsdaten für ein typisches CNN sind Bilder mit einem oder drei Farbkännen. Die Prozessaufnahmen enthalten in diesem Fall aber 25 Kanäle, sodass die Netzwerktopologie speziell auf diesen Sonderfall ausgelegt wird. Vortrainierte Netzwerke, die in anderen Bereichen hohe Klassifikationsgenauigkeiten erzielt haben (z.B. ResNet-Modelle) können nicht verwendet werden.

Das Netzwerk soll einerseits eine hohe Vorhersagewahrscheinlichkeit bieten, aber andererseits die verfügbaren Rechenressourcen für den Trainingsprozess nicht überfordern. Deshalb wird ein Ansatz für das Netzwerk gewählt, der wie in Abb. 6.9 dargestellt, vier Convolutional-Layer enthält, deren Anzahl an Kanälen sich bis auf die letzte Schicht jeweils verdoppelt. Die Dimension der Faltungsmatrizen wird auf  $3 * 3$  festgelegt. Als Aktivierungsfunktion wird die bewährte ReLU-Funktion gewählt. Die Eingangsdaten in Form der Prozessaufnahmen weisen zwar eine hohe Anzahl an Kanälen auf (25), sind ansonsten aber sehr klein ( $20 * 20$ ), weshalb keine Max-Pooling-Layer [Cho18] verwendet werden.

Um einer Überanpassung des Netzwerks auf die Trainingsdaten vorzubeugen, wird ein Dropout-Layer hinzugefügt. Es folgt eine vollständig verknüpfte Schicht (fully-connected layer), ehe der finale Wert als Vorhersage der Oberflächenrauheit ausgegeben wird. Für die Verlustfunktion wird der mittlere quadratische Fehler (mean squared error) gewählt, damit vor allem hohe Abweichungen zwischen Vorhersage und Kennzeichnung der Prozessaufnahme im Training berücksichtigt werden. Zur Bewertung der Vorhersagegenauigkeit wird als Maß wiederum der mittlere absolute Fehler (mean absolute error) verwendet.

Um die Vorhersagegenauigkeit verschiedener Netzwerktopologien miteinander vergleichen zu können, wird ein Hyperparameter-Tuning durchgeführt. Dabei werden die Dropout-Rate (0,4 und 0,6), die Anzahl der Perzeptonen in der vollständig ver-

## 6.5. REGRESSION DER OBERFLÄCHENRAUHEIT DURCH EIN CONVOLUTIONAL NEURAL NETWORK

Tabelle 6.4: Übersicht über die gemessenen Oberflächenrauheiten aller Proben bei drei unterschiedlichen Parametersätzen.

Parametersatz	Rauheiten $R_z[\mu m]$ (Anzahl Aufnahmen)	
<b>A:</b> 20 Proben 50 W Laserl. 75 mm/s Scang.	30,8 (3606); 32,4 (3593); 25,8 (3567) 37,5 (3592); 31,4 (3579) 31,6 (3611) 32,3 (3611); 33,2 (3585); 36,4 (3602) 33,9 (3599); 33,3 (3583); 31,2 (3620) 37,7 (3600); 31,3 (3589); 29,6 (3593) 35,4 (3606); 30,4 (3598); 33,9 (3591) 30,8 (3584); 35,0 (3587)	$\overline{R_z} = 32,7\mu m$ $MAE = 2,2\mu m$
<b>B:</b> 10 Proben 50 W Laserl. 40 mm/s Scang.	49,3 (6272); 36,2 (6689); 43,0 (6672) 34,3 (6749); 31,7 (6069); 38,0 (6764) 32,4 (6773); 40,3 (6770); 26,9 (6778) 30,9 (6800)	$\overline{R_z} = 36,3\mu m$ $MAE = 5,1\mu m$
<b>C:</b> 10 Proben 20 W Laserl. 75 mm/s Scang.	64,6 (1146); 70,1 (2109); 63,2 (2131) 57,8 (3343); 77,4 (1530); 75,4 (3075) 81,4 (3077); 92,4 (2243); 67,3 (2037) 61,8 (1821)	$\overline{R_z} = 71,1\mu m$ $MAE = 8,4\mu m$

knüpften Schicht (8, 16, 32) sowie die Optimierungsfunktion (Adam und Nadam) variiert. Die Lernrate beträgt für alle Trainingsdurchläufe 0,001. Tabelle 6.5 zeigt die Ergebnisse des Trainings für jeweils 10 Epochen bei einer Batch-Größe von 20 mit den jeweiligen Hyperparametern. Von den verfügbaren Daten werden dabei 70 % für das Training, 20 % zur Validierung sowie 10 % als Testdatensatz verwendet, mit dem die in der Tabelle gezeigten Vorhersagegenauigkeiten ermittelt werden.

Für eine bessere Übersichtlichkeit werden die Ergebnisse in Abb. 6.8 visualisiert, sodass der Einfluss einzelner Hyperparameter deutlich wird. Es zeigt sich beispielsweise, dass die Nadam-Optimierungsfunktion höhere Vorhersagegenauigkeiten erzeugt als die Adam-Optimierungsfunktion. Der geringste mittlere absolute Fehler und damit die höchste Vorhersagegenauigkeit kann mit einer Dropout-Rate von 0,6, der Nadam-Optimierungsfunktion und 16 Perzeptronen in der vollständig verknüpften Schicht erzielt werden. Ein vereinfachtes Schema der Netzwerktopologie mit diesen Parametern wird in Abb. 6.9 dargestellt.

Mit diesen Hyperparametern wird nun ein längerer Trainingsprozess von 40 Epochen durchgeführt. Um sicherzustellen, dass aus jedem der drei Prozessparametersätze die gleichen Anteile in die Trainings-, Validierungs- und Testsätze entfallen, werden diese zunächst separat aufgeteilt. Für jeden der Prozessparametersätze werden also 70 % den Trainings-, 20 % den Validierungs- und 10 % den Testdaten zugeordnet. Erst danach werden die Trainings- und Validierungsdaten gemischt. Die Testdaten werden getrennt gehalten, damit die Vorhersagegenauigkeit für jeden Prozessparametersatz getrennt bewertet werden kann. So lässt sich feststellen, ob das CNN tatsächlich zwischen verschiedenen Rauheiten oder nur zwischen verschiedenen Prozessparametern unterscheiden kann.

## 6.5. REGRESSION DER OBERFLÄCHENRAUHEIT DURCH EIN CONVOLUTIONAL NEURAL NETWORK

Tabelle 6.5: Vorhersagegenauigkeit verschiedener Netzwerktopologien, mit jeweils unterschiedlicher Anzahl an Perzeptronen im Dense-Layer, Dropout-Rate sowie Optimierungsalgorithmus. Die Netzwerke werden jeweils für 10 Epochen trainiert.

Anzahl Perzeptronen im Dense-Layer	Dropout-Rate	Optimierungsalgorithmus	MAE $R_z[\mu m]$ CNN-Vorhersage
8	0,4	Adam	4,70
8	0,4	Nadam	4,21
8	0,6	Adam	4,20
8	0,6	Nadam	4,18
16	0,4	Adam	4,25
16	0,4	Nadam	4,37
16	0,6	Adam	4,20
16	0,6	Nadam	4,12
32	0,4	Adam	4,21
32	0,4	Nadam	4,15
32	0,6	Adam	4,20
32	0,6	Nadam	4,14

Abbildung 6.10 zeigt die Entwicklung der Verlustfunktion während des Trainingsprozesses für die Trainings- und Validierungsdaten. Trotz der hohen Dropout-Rate von 0,6 kann ungefähr ab Epoche 22 eine Überanpassung beobachtet werden. Das Netz lernt die Merkmale der Trainingsdaten „zu gut“. Tabelle 6.6 zeigt, wie präzise das CNN die Rauheiten anhand der Testdaten vorhersagen kann. Für den kompletten Datensatz werden die Testdaten aller drei Prozessparametersätze verwendet. Die Vorhersagegenauigkeit des CNN liegt mit einem mittleren absoluten Fehler von

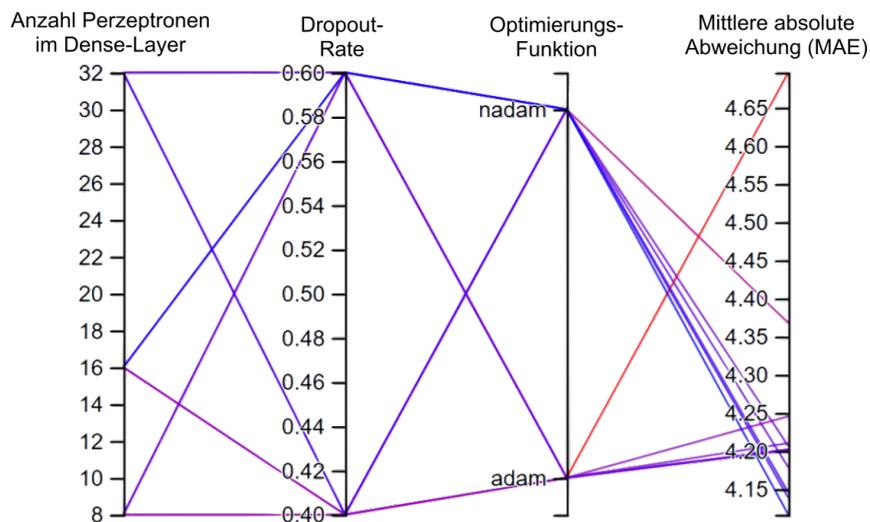


Abbildung 6.8: Veranschaulichung des Hyperparameter-Tunings: Je dunkler die Verbindungslinie, desto geringer ist die von der entsprechenden Netzwerktopologie erzielte mittlere absolute Abweichung.

## 6.5. REGRESSION DER OBERFLÄCHENRAUHEIT DURCH EIN CONVOLUTIONAL NEURAL NETWORK

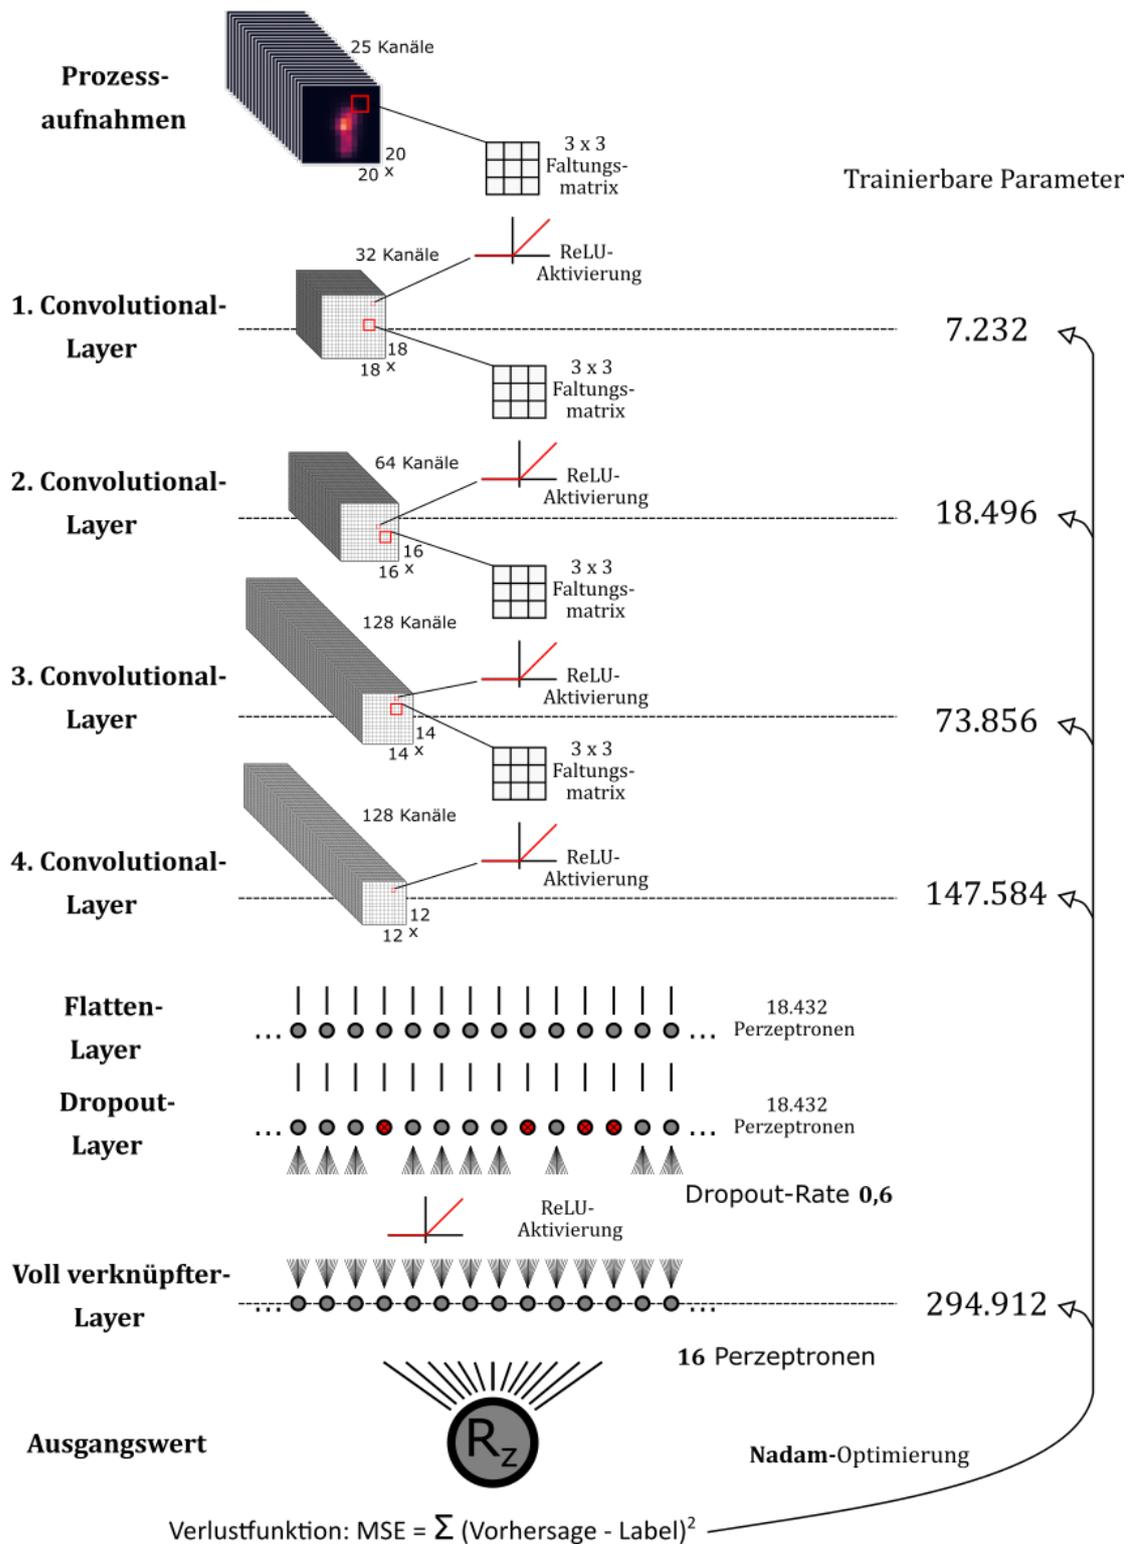


Abbildung 6.9: Netzwerktopologie des CNN zur Vorhersage der Oberflächenrauheit. Im Rahmen des Hyperparameter-Tunings werden die Dropout-Rate (0,4; 0,6), die Optimierungsfunktion (Adam; Nadam) sowie die Anzahl der Perzeptronen (8; 16; 32) in der letzten voll verknüpften Schicht variiert, was wiederum die Anzahl trainierbarer Parameter beeinflusst.

## 6.5. REGRESSION DER OBERFLÄCHENRAUHEIT DURCH EIN CONVOLUTIONAL NEURAL NETWORK

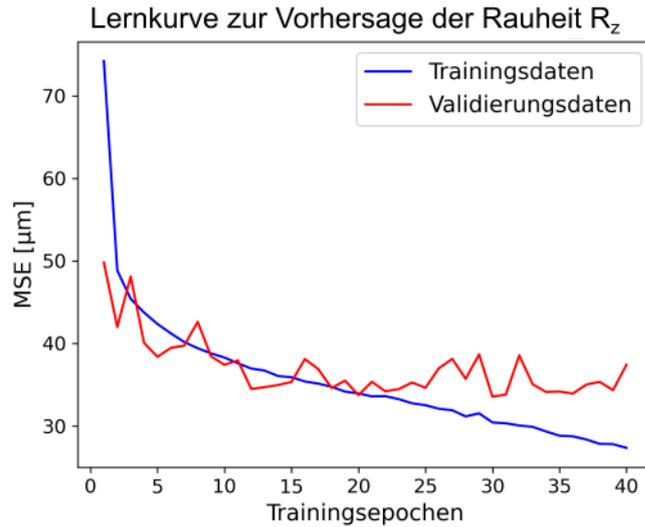


Abbildung 6.10: Entwicklung der Verlustfunktion (mean squared error) während des Trainings des CNN für Trainings- und Validierungsdaten.

4,1  $\mu\text{m}$  deutlich unter der mittleren absoluten Abweichung der Rauheit von 14,3  $\mu\text{m}$  innerhalb des Datensatzes. Anschließend werden die einzelnen Testdatensätze, die jeweils nur Aufnahmen identischer Prozessparameter enthielten, als Eingangsdaten für das trainierte CNN verwendet. Es zeigt sich, dass bei Parameter A (50 W; 75 mm/s) zwar erkannt wird, dass dieser Parameter verwendet wird, die Rauheit allerdings nicht präziser bestimmt werden kann als es die mittlere Abweichung ohnehin schon hergibt. Bei Parameter B (50 W; 40 mm/s) wiederum zeigt sich, dass die Rauheit etwas präziser als durch die Streuung vorgegeben vorhergesagt werden kann. Bei diesem Parametersatz muss es in den Aufnahmen Merkmale geben, die Informationen über die Oberflächenrauheit enthalten. Parametersatz C (20 W; 75 mm/s) zeigt eine hohe Streuung und die Oberflächenrauheit kann sogar noch weniger präzise vorhergesagt werden.

Tabelle 6.6: Vorhersagegenauigkeit des Convolutional Neural Networks bei den verschiedenen Parametersätzen verglichen mit der jeweiligen Streuung innerhalb eines Parametersatzes.

Parametersatz	MAE $R_z$ [ $\mu\text{m}$ ] gemessen	MAE $R_z$ [ $\mu\text{m}$ ] CNN-Vorhersage
Kompletter Datensatz	14,3	4,1
A (50 W; 75 mm/s)	2,2	2,3
B (50 W; 40 mm/s)	5,1	4,3
C (20 W; 75 mm/s)	8,4	9,6

Diese Ergebnisse zeigen zunächst, dass die unterschiedlichen Parameter sehr gut erkannt werden können, denn die Streuung der CNN-Vorhersage ist nur für Parametersatz C höher als die mittlere absolute Abweichung der gemessenen Rauheit. Innerhalb der Parametersätze können die Oberflächenrauheiten allerdings unterschiedlich präzise vorhergesehen werden. Parametersatz A weist eine geringe Streuung der Oberflächenrauheit auf, was eine genauere Vorhersage erschwert. Parametersatz C beinhaltet eine sehr geringe Laserleistung, sodass nicht genügend Licht für eine genauere Vorhersage verfügbar ist. Parametersatz B weist eine ausreichende Streuung sowie genügend Licht auf, sodass die Vorhersage genauer als die Streuung ist. Zudem stehen für Parametersätze A und B deutlich mehr Trainingsdaten zur Verfügung als für Parametersatz C.

Für hyperspektrale Prozessaufnahmen von Parametersatz B kann die Rauheit  $R_z$  also mit einer mittleren absoluten Abweichung von  $4,3 \mu\text{m}$  vorhergesagt werden. Eine Vorhersage des CNN von  $30 \mu\text{m}$  müsste demnach als  $R_z = 30 \pm 4,3 \mu\text{m}$  interpretiert werden. Diese Ergebnisse lassen den Schluss zu, dass die Daten der Hyperspektralkamera in einem bestimmten Parameterbereich Informationen über die Rauheit der Oberfläche und somit über ein wesentliches Qualitätsmerkmal beinhalten. Inwiefern sich diese Erkenntnis auch auf weitere Qualitätsmerkmale verallgemeinern lässt, bleibt dabei zunächst offen.

# 7 Ortsaufgelöste Klassifikation von Prozessfehlern durch ein Convolutional Neural Network

In diesem Kapitel soll untersucht werden, inwiefern hyperspektrale Prozessaufnahmen Informationen zur Fehlerdetektion im LPBF-Prozess enthalten. Die Voraussetzung für eine solche Untersuchung ist die ortsaufgelöste Erhebung von Prozessaufnahmen, sodass diese jeweils einem fehlerfreien Prozess – als sogenannte iO-Aufnahmen (iO - in Ordnung) – oder einem fehlerbehafteten Prozess – als niO-Aufnahmen – zugeordnet werden können. Zu diesem Zwecke wird eine auf einem FPGA beruhende Infrastruktur zur Datenerhebung geschaffen, die es ermöglicht, Maschinendaten der LPBF-Anlage zeitgenau mit den Prozessaufnahmen zu verknüpfen. Dieses System wird anschließend zur Datenerhebung genutzt, wozu künstliche Prozessfehler erzeugt werden. Die dadurch gewonnenen Daten werden wiederum zum Training eines CNN verwendet, dessen Klassifikationsgenauigkeit abschließend anhand von Testdaten bewertet wird.

## 7.1 Akquise-System zur Verknüpfung von Prozess- und Maschinendaten

Für die Erkennung von Prozessfehlern im LPBF-Prozess wird ein Akquise-System geschaffen, das eine automatische Erhebung von Prozess- und Maschinendaten ermöglicht. Die erfassten Daten können somit zeitlich aufeinander bezogen und einem Modell zur Datenauswertung zugänglich gemacht werden. Zur ortsaufgelösten Erhebung von Prozessdaten sind die Steuerdaten des Galvanometer-Scanners von kritischer Bedeutung, denn sie legen fest, an welchem Ort im Pulverbett sich der Laserspot zu einem gegebenen Zeitpunkt befindet. Im Folgenden soll deshalb näher auf das XY2-100-E Protokoll eingegangen werden, mit dessen Hilfe die Steuerkarte des Galvanometer-Scanners die Positionsdaten der Spiegel übermittelt. Diese sollen während des Prozesses in Echtzeit mitgeschnitten werden, um sie mit den Prozessaufnahmen zeitlich korrelieren zu können.

### 7.1.1 XY2-100-E Protokoll

Der Bearbeitungsrechner einer LPBF-Anlage enthält eine Steuerkarte, die dem Galvanometer-Scanner die Auslenkpositionen der Spiegelachsen vorgibt. Zur Übertragung dieser Information gibt es verschiedene Protokolle wie z.B. das XY2-100 oder das neuere SL2-100 Protokoll. Das im Rahmen dieser Arbeit erstellte Akquise-System beruht auf dem XY2-100 Protokoll, da für einen Großteil der im Einsatz befindlichen Industrie-Anlagen dieses Protokoll verwendet wird. Bei Anlagen, die auf dem SL2-100 Protokoll beruhen, wie die in dieser Arbeit eingesetzte Labor-Anlage, kann ein Adapter zur Umwandlung benutzt werden, sodass der Einsatzbereich des Akquise-Systems von der Wahl des zu verarbeitenden Protokolls unbeschränkt bleibt. Außerdem ist das System für das erweiterte XY2-100-E Protokoll (E für enhanced) einsetzbar, welches zusätzliche Befehle und Statusrückgaben erlaubt. Die Struktur des Protokolls ist in Abbildung 7.1 dargestellt: ein Datenframe besteht aus 20 Bits, die wiederum unterteilt sind in 16 Datenbits, drei Steuerbits sowie ein Paritätsbit. Die Steuerbits kennzeichnen die Bedeutung der Datenbits. Diese wiederum enthalten die Ablenkposition einer von drei (x, y, z) ansteuerbaren Achsen in einem Wertebereich von 0 bis  $2^{16} - 1$ . Das Paritätsbit dient zur Prüfung der Datenintegrität [Ray13].

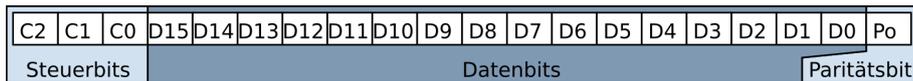


Abbildung 7.1: Aufteilung eines Datenframe in Steuer-, Daten- und Paritätsbits gemäß XY2-100-E Protokoll.

Die Übertragungsgeschwindigkeit ist über ein Taktsignal mit einer Frequenz von 2 MHz festgelegt. Ein Synchronisationssignal leitet den Anfang eines neuen Datenframes über eine steigende Flanke ein. Abbildung 7.2 zeigt den zeitlichen Zusammenhang dieser Signale zu den Datenframes der einzelnen Kanäle, die zu den Ausgangsleitungen und Statusrückgaben der Achsen gehören. Takt- und Synchronisationssignal werden unabhängig von der Achsbewegungen kontinuierlich ausgesandt, sodass diese als globale Synchronisationsquellen für das gesamte Akquise-System genutzt werden können.

Die Position des Laserspots im Scanfeld wird also für jede Achse mit einem Wert

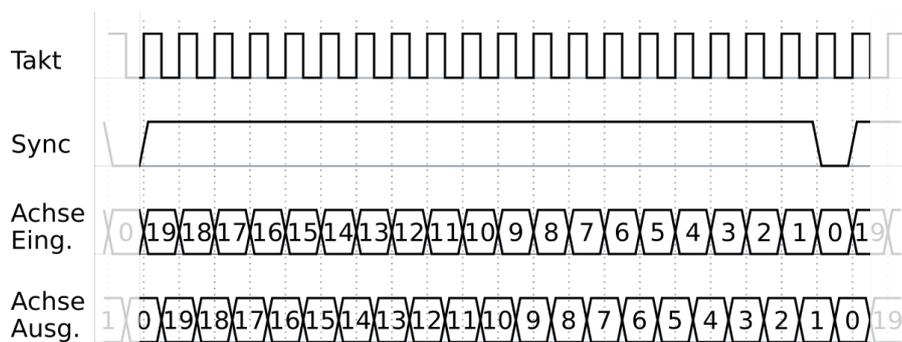


Abbildung 7.2: Zeitlicher Zusammenhang zwischen Takt- und Synchronisationssignal sowie weiteren Kanälen des XY2-100-E Protokolls.

## 7.1. AKQUISE-SYSTEM ZUR VERKNÜPFUNG VON PROZESS- UND MASCHINENDATEN

---

zwischen 0 und 65535 definiert. Abbildung 7.3 zeigt Beispielpositionen im Scanfeld mit den zugehörigen Steuerwerten in Tabelle 7.1. Durch den Strahlverlauf im Galvanometer-Scan-Kopf und die Eigenschaften des verwendeten Objektivs kommt es zu Feldverzerrungen der Abbildungsebene. Diese müssen durch eine Korrektur-Datei über die Ansteuerung kompensiert werden.

Zur Übertragung der Signale wird eine DB-25 Steckverbindung als elektrische Schnittstelle genutzt. Dabei werden die Signale in differentieller, galvanisch nicht getrennter Form parallel übermittelt. Die differentielle Übertragungsweise bedingt die Nutzung zweier Leitungen pro Signal. Insgesamt fungieren also Takt- und Synchronisationssignal sowie die drei Sollwert-Achssignale als Eingänge und die Statusrückgaben der drei Achsen als Ausgänge des Galvanometers.

Tabelle 7.1: Positionen des Laserspot gemäß XY2-100 Protokoll.

Position	X-Bit-Wert	Y-Bit-Wert
	Kanal 1	Kanal 2
0	32768	32768
1	65535	32768
2	65535	65535
3	0	0

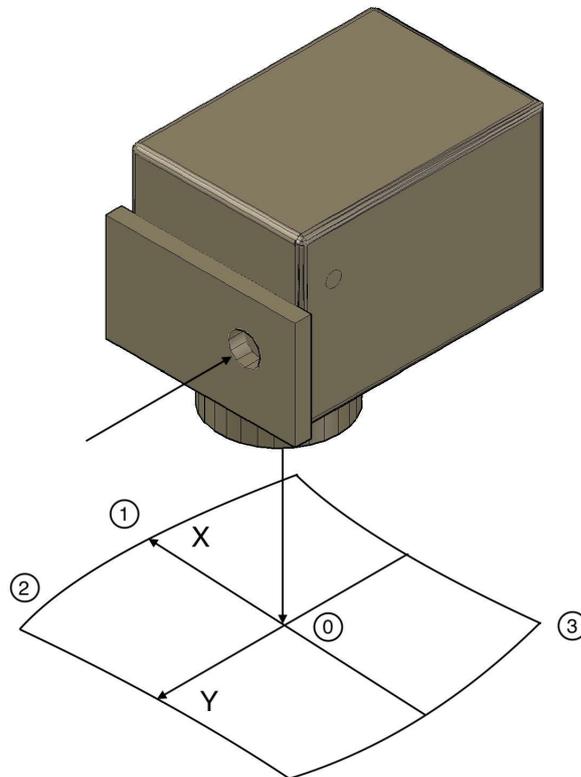


Abbildung 7.3: Scanfeld-Positionen des Galvanometer-Scanners. Die markierten Positionen entsprechen den Bit-Werten aus Tabelle 7.1. Es sind außerdem die Verzerrungen der idealerweise quadratischen Abbildungsebene zu erkennen.

### 7.1.2 Struktur des Akquise-Systems

Die Aufgabe des Akquise-Systems ist es, Maschinen- und Prozessdaten zu erheben, diese zeitlich aufeinander zu beziehen und zur weiteren Bearbeitung und Auswertung zur Verfügung zu stellen. Die dazu ausgelegte Systemstruktur ist in Abbildung 7.4 dargestellt. Die drei zentralen Komponenten des Akquise-Systems sind die elektrische Schnittstelle, die FPGA-Implementierung sowie die Benutzerschnittstelle auf dem Bearbeitungsrechner.

Zum Abgreifen der Datensignale wird eigens eine Leiterplatte mit entsprechenden elektronischen Komponenten ausgelegt, die hier als elektrische Schnittstelle bezeichnet wird. Sie nimmt Informationen der LPBF-Anlage auf, empfängt oder sendet Trigger-Signale an die Kamera und wandelt die Daten in eine für die weitere Verarbeitung angemessene Form um.

Die FPGA-Implementierung wiederum erfasst die von der elektrischen Schnittstelle weitergegebenen Signale, dekodiert diese und legt sie mit einem Zeitstempel versehen in einem Zwischenspeicher ab. Die FPGA-Implementierung fungiert damit als Verbindungsglied zwischen elektrischer Schnittstelle und dem Bearbeitungsrechner, auf dem die hinterlegten Daten abgerufen und die Funktionsweise der Schaltung gesteuert werden kann. Durch die ihr inhärente Parallelität der Schaltungsmethodik ist die FPGA-Implementierung insbesondere zur zeitgenauen Erfassung der Galvanometer-Scanner Steuerbefehle von wesentlicher Bedeutung.

Das Benutzer-Programm auf dem Bearbeitungsrechner erlaubt das Abrufen der mittels FPGA-Implementierung erhobenen Daten. Zudem wird über die Benutzeroberfläche mit der Kamera kommuniziert, was neben der Einstellung von Kamera-Parametern wie z.B. der Belichtungszeit die Aufnahme von Bilddaten umfasst. Über die graphische Benutzeroberfläche können außerdem Positionen des Galvanometer-Scanners bestimmt werden, an denen während des Prozesses ein Trigger-Signal an die Kamera gesendet werden soll. Die von der Kamera zurückgegebenen Signale

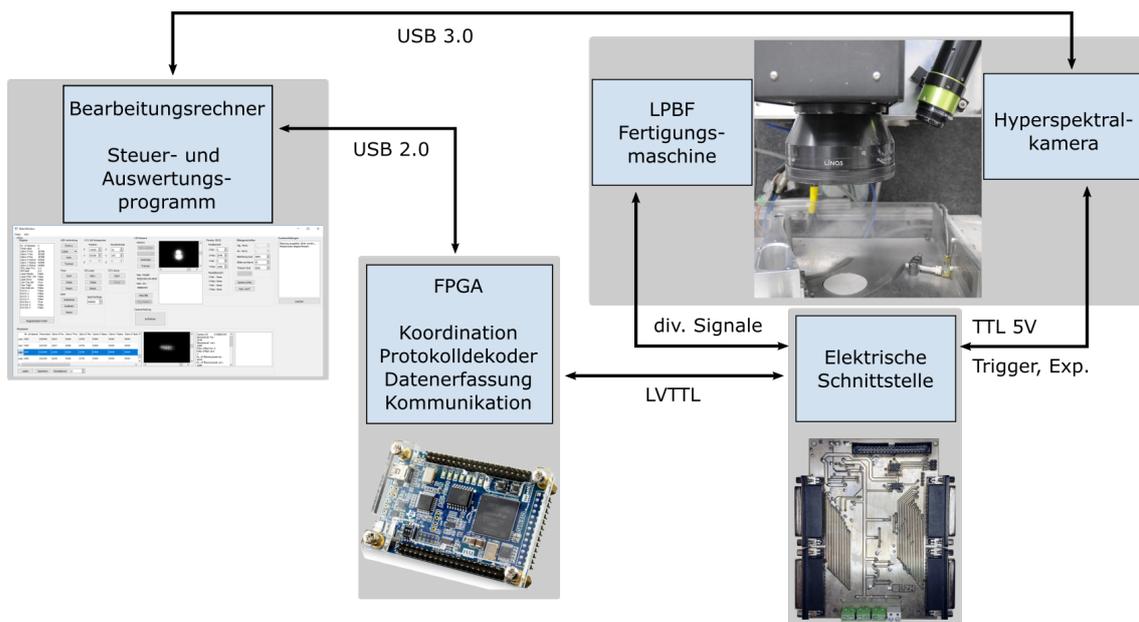


Abbildung 7.4: Übersicht über die Struktur des Akquise-Systems sowie dessen Schnittstellen.

können als Belichtungszeitpunkte den Steuerdaten zugeordnet werden. So kann der Benutzer einen Datensatz abspeichern, in dem alle hyperspektralen Prozessaufnahmen zeitlich korreliert mit den Maschinendaten vorliegen. Die weiterführende Auswertung und Analyse der Daten kann anschließend anhand dieses Datensatzes mit beliebigen Software-Werkzeugen fortgesetzt werden.

### Elektrische Schnittstelle

Die Funktion der elektrischen Schnittstelle ist es, die Steuersignale der LPBF-Anlage ohne Störung des Systems abzugreifen und an die FPGA-Implementierung weiterzuleiten. Abbildung 7.5 zeigt eine gerenderte Darstellung der Platine, die für diesen Zweck erstellt wird. Die Funktionsgruppen und Anschlüsse sind markiert und werden im Folgenden näher erläutert:

1. Steckverbindung zum Anschluss an den FPGA
2. Digitale Ausgänge (5V TTL) u.a. zum Triggern des Prozessstarts
3. Stiftleiste für den Anschluss der Hyperspektralkamera
4. DB25-Steckverbindungen für den Anschluss des Galvanometer-Scanners
5. Galvanisch getrennte Eingänge
6. Steckverbindungen zum Anschluss des Faserlasers
7. Funktionsgruppe für die analog-digital-Wandlung
8. Spannungsversorgung und -regler

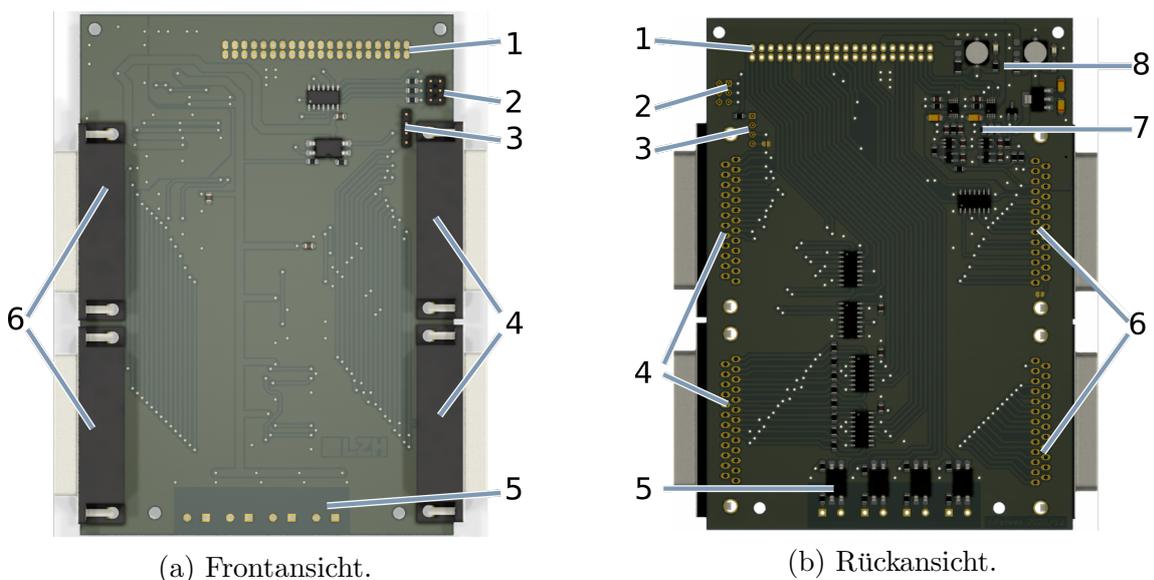


Abbildung 7.5: Front- und Rückansicht der elektrischen Schnittstelle. Die jeweiligen Funktionsgruppen und Anschlüsse der Platine sind gekennzeichnet.

Die Signalspannungen und Ströme werden an die jeweilige Funktionseinheit angepasst oder vollkommen galvanisch getrennt. Zur Weitergabe der Signale an den FPGA müssen diese gemäß dem Low voltage transistor-transistor logic (LVTTL) Standard auf maximal 3,3 V ausgelegt werden. Die vier unabhängigen Baugruppen der elektrischen Schnittstelle dienen der Verarbeitung und Weitergabe folgender Steuersignale:

- **Galvanometer-Scanner:** Positionsbefehle gemäß XY2-100-E Protokoll
- **Faserlaser:** Gate-Signal (ON/OFF) sowie Leistung (0 - 10 V)
- **Hyperspektralkamera:** Triggersignale und Belichtungszeitpunkte
- **PIO:** Programmable input/output für allgemeine Zustandsinformationen

Um zu gewährleisten, dass der Betrieb der Fertigungsanlage von dem Akquise-System unbeeinträchtigt bleibt, werden die Schaltungsteile in bestehende Verbindungen eingeschleift. Dazu werden die Verbindungsleitungen mit hochohmigen Eingängen störungsarm abgetastet.

Die elektrischen Informationen zur Steuerung des Galvanometer-Scanners werden über DB-25 Steckverbinder gemäß XY2-100-E Protokoll übertragen. Die Pin-Belegung ist in Tabelle 7.2 dargestellt. Bedingt durch die differenzielle Signalübertragung sind pro Kanal zwei Verbindungsleitungen notwendig. Zur Weitergabe an den FPGA erfolgt eine Wandlung der Signale gemäß LVTTL Standard auf 3,3 V.

Die Auslegung des Akquise-Systems erlaubt außerdem, die Steuerdaten des Lasers mitaufzuzeichnen. Das umfasst ein digitales 5 V TTL-Signal (Laser ON/OFF) sowie das analoge Signal (0 - 10 V) zur Leistungsvorgabe. Da diese Signale für die spätere Datenauswertung keine Rolle spielen, soll hierauf nicht weiter eingegangen werden. Die Hyperspektralkamera verfügt sowohl über einen Eingangskontakt zur zeitgenauen Triggerung der Aufnahme sowie über einen Ausgangskontakt zur Erfassung der Belichtungszeitpunkte. Tabelle 7.3 zeigt die entsprechenden Kontaktbelegungen an der Kamera. Diese Kontakte werden mit der dafür vorgesehenen Stiftleiste auf der Platine verbunden. Die Kontaktbelegungen der Stiftleiste sind in Tabelle 7.4 dargestellt und analog zu denen der Hyperspektralkamera.

Darüber hinaus bietet die als elektrische Schnittstelle zwischen Anlage und FPGA fungierende Platine frei programmierbare Ein- und Ausgänge. Die vier Eingänge

Tabelle 7.2: Elektrische Kontakte der DB-25 Steckverbindung gemäß XY2-100-E Spezifikation.

Kontakt	Signal	Spezifikation
1, 14	Eingang	Takt
2, 15	Eingang	Sync-Signal
3-5, 16-18	Eingang	Datenübertragung für X-, Y- und Z-Achse
6-8, 19-21	Ausgang	Statusübertragung für X-, Y- und Z-Achse
11, 23, 24	GND	GND

## 7.1. AKQUISE-SYSTEM ZUR VERKNÜPFUNG VON PROZESS- UND MASCHINENDATEN

---

Tabelle 7.3: Ein- und Ausgangskontakte der Hyperspektralkamera.

Kontakt	Signal	Spezifikation
1	Digitaler Eingang (GPI)	Low: 0-2 V; High: 4-24 V
2	Masse (GND)	Common I/O
3	Digitaler Ausgang (GPO)	Open-Collector-Ausgang
Schirmung		Common I/O

Tabelle 7.4: Kontaktbelegung der Stiftleiste zur Kommunikation mit der Hyperspektralkamera.

Kontakt	Signal	Spezifikation
1	Ausgang	Trigger
2	Versorgung	GND
3	Eingang	Rückgabesignal
4	Versorgung	Schirmung

sind galvanisch entkoppelt. Die digitalen Ausgänge sind TTL-konform (5 V) und werden während der Versuchsprozesse dazu genutzt, den Prozessablauf aus dem Benutzerprogramm heraus synchron mit der Kameraaufnahme und Datenaufzeichnung starten zu lassen. Tabelle 7.5 zeigt die Kontaktbelegungen der Stiftleiste für die digitalen Signalausgänge.

Tabelle 7.5: Kontaktbelegung der Stiftleiste für die digitalen Signalausgänge. Diese werden zum synchronisierten Prozessstart verwendet.

Kontakt	Signal	Spezifikation
1	Ausgang	GPO 1
2	Versorgung	GND
3	Ausgang	GPO 2
4	Versorgung	GND
5	Ausgang	GPO 3
6	Versorgung	GND

### 7.1.3 FPGA-Implementierung zur Datenerhebung

Die zentrale Anforderung an das Akquise-System ist, die Steuerdaten der LPBF-Anlage aufzuzeichnen und in geeigneter Form abzuspeichern. Zudem sollen in Abhängigkeit der Steuerdaten – insbesondere der des Galvanometer-Scanners – Trigger-Signale in Echtzeit an die Kamera gesendet werden können. Um eine somit notwendige Echtzeitverarbeitung parallel auftretender Daten zu realisieren wird ein sogenannter Field Programmable Gate Array (FPGA) als zentraler Hardware-Baustein des Akquise-Systems eingesetzt. Ein solcher Mikrochip zeichnet sich im Gegensatz zu einem Mikroprozessor dadurch aus, dass die interne Struktur in hohem Maße an die Anforderungen der jeweiligen Anwendung anpassbar ist. Dies wird durch eine

Vielzahl programmierbarer Logikeinheiten, Speicherelemente sowie einem Netzwerk konfigurierbarer Verbindungsleitungen möglich.

Bei dem in dieser Arbeit verwendeten FPGA handelt es sich um den Cyclone® IV EP4CE22F17C6N der Firma Intel Inc., der in die Entwicklungsplattform DE0-Nano der Firma Terasic Inc. integriert ist. Die Vorteile dieser Entwicklungsplattform sind einerseits der integrierte, direkt über den FPGA ansprechbare RAM-Speicher und andererseits die verhältnismäßig etwas geringere Komplexität des Entwicklungsprozesses. Um die hohe Anpassbarkeit eines FPGA nutzen zu können, wird in dieser Arbeit die Hardwarebeschreibungssprache Very High Speed Integrated Circuit Hardware Description Language (VHDL) verwendet. Anders als die weitverbreiteten sogenannten höheren Programmiersprachen wie Python oder Java können mit ihr voneinander unabhängige Hardwarestrukturen beschrieben werden, die simultan in Bezug auf einen globalen Systemtakt ausgeführt werden.

### Systemstruktur

Abbildung 7.6 zeigt schematisch die Struktur des Akquise-Systems. Der grau hinterlegte zentrale Teil zeigt die einzelnen Module und Funktionsgruppen des FPGAs. Diese können über ein Bussystem, das Avalon® Interface, untereinander kommunizieren und Daten austauschen. Der externe SDRAM-Speicher ermöglicht mit einer Speicherkapazität von 32 MByte die Zwischenspeicherung der Maschinendaten.

Der schnellste vom Akquise-System zu erfassende Prozess ist die Steuerung des Galvanometer-Scanners. Das alle  $10 \mu\text{s}$  von der Steuerkarte übermittelte Synchronisationssignal des XY2-100-E Protokolls dient deshalb als globaler Taktgeber für die Datenerhebung. Bei jedem Synchronisationssignal werden alle Maschinendaten sowie der Kamerazustand erfasst, die Daten ggf. prozessiert und anschließend gespeichert oder an eine nachfolgende Verarbeitungseinheit weitergereicht.

Die Funktionseinheiten des FPGAs fungieren als eigenständige Empfangs- und Verarbeitungsmodul für die unterschiedlichen Maschineninformationen. Die in Abbildung 7.6 dunkelgrau hinterlegten Module werden speziell für die in dieser Arbeit durchgeführten Untersuchungen ausgelegt. Die hellgrau hinterlegten Module sind, abgesehen von der 50 MHz Taktquelle, proprietäre Einheiten der Firma Intel Inc., die wichtige Funktionalitäten bereitstellen, wie sie in vielen Projekten benötigt werden. Das NIOS® II Modul stellt beispielsweise eine Prozessorstruktur zur Verfügung, die mit der Programmiersprache C programmiert werden kann. In dieser Arbeit wird dieser Prozessor dazu genutzt, um den Datenfluss der FPGA-Module zu steuern und die Kommunikation mit dem Anwendungsprogramm auf dem Benutzerrechner zu ermöglichen.

Der Datenaustausch zwischen den Modulen erfolgt über das Bussystem mit Hilfe eines klar definierten Adressraums. Jedem Modul ist ein Teil dieses Adressraums zugeordnet, innerhalb dessen Daten übermittelt werden können. Tabelle 7.6 zeigt für einige der Funktionseinheiten die jeweils zugehörigen Adressräume, dargestellt als Hexidezimalzahlen. Werden Daten über eine bestimmte Adresse an einem Modul angefragt, so erfolgt die Übermittlung in Form eines Datenwortes einer Breite von 16 Bit. Bei größeren Daten muss der Basisadresse zusätzlich ein Offset hinzugefügt werden. Die im XY2-100-E Modul erfasste Sollposition der X-Achse wird beispielsweise über die Adresse 0x900000 abgefragt, die der Y-Achse wiederum über die Adresse 0x900001. Der schreibende Zugriff auf die Module funktioniert analog.

## 7.1. AKQUISE-SYSTEM ZUR VERKNÜPFUNG VON PROZESS- UND MASCHINENDATEN

Tabelle 7.6: Adressräume der FPGA-Module dargestellt als Hexadezimalzahlen.

Modul	Adressbereich
Laser	0x00700000 – 0x0070001f
PIO	0x01000000 – 0x0100001f
RegToRam	0x00010000 – 0x0001001f
Timer	0x00500000 – 0x0050001f
XY2-100-E	0x00900000 – 0x0090001f
OnChip-Speicher	0x00000000 – 0x0000bfff
PIO_IN	0x00600000 – 0x0060001f
PIO_OUT	0x00800000 – 0x0080001f
SDRAM-Controller	0x04000000 – 0x05ffff
UART-Com	0x00400000 – 0x0040001f

Das RegToRam-Modul ist dafür verantwortlich, die in den einzelnen Modulen in Registern abgelegten Daten in geordneter Form in den SDRAM-Speicher zu legen, sodass sie von dort dem Benutzerprogramm per Abruf zur Verfügung stehen. Dies erfolgt mit Hilfe einer Masterschnittstelle am Bussystem, mit der das Modul aktiv Informationen von anderen Busteilnehmern abrufen kann.

Sobald das XY2-100-E Modul einen Datensatz vom Galvanometer-Scanner ausgewertet hat, versetzt es das RegToRam-Modul per steigender Flanke in einen Warte-

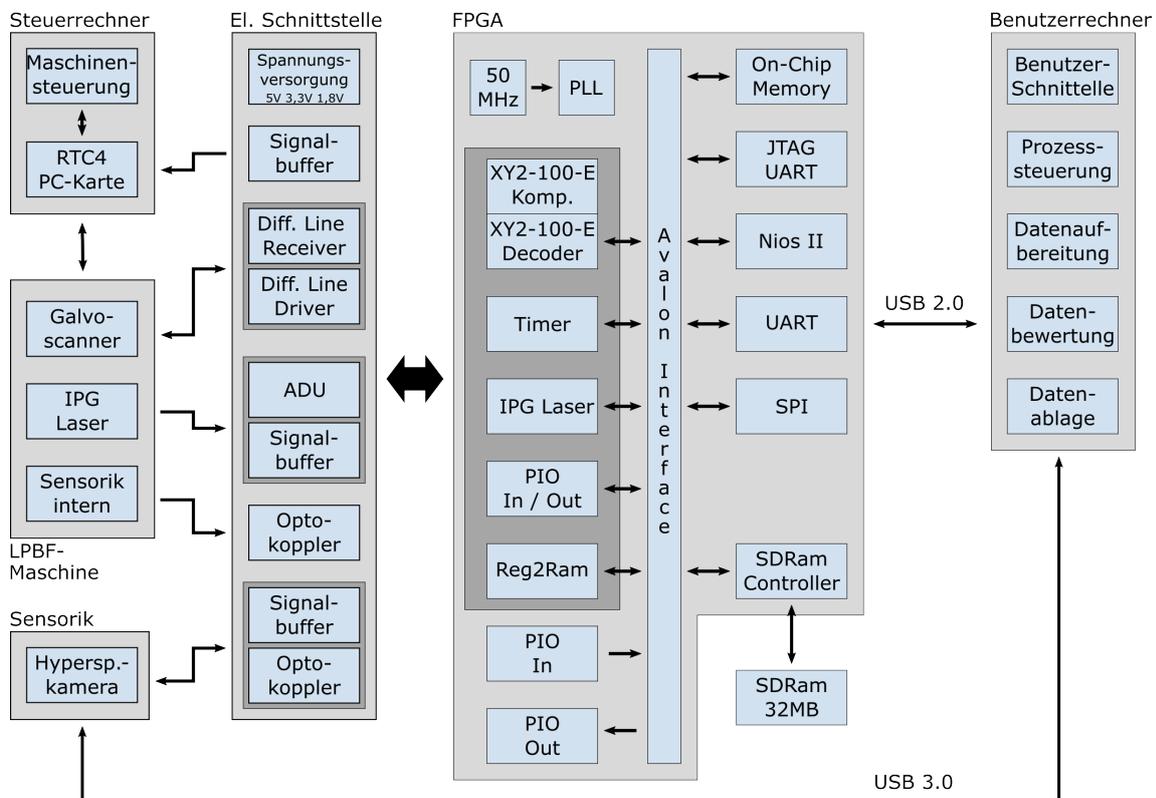


Abbildung 7.6: Schema des gesamte Akquise-Systems inkl. grau hinterlegten Modulen im FPGA-Teil.

zustand. Dieser endet, wenn alle datenerfassenden Module die Ablage ihrer Daten in das jeweilige Register signalisiert haben. Dann legt das RegToRam-Modul sukzessive die jeweiligen Adressen auf den Adressbus, liest die in diesen enthaltenen Daten aus und legt sie in einen Zwischenspeicher. Anschließend werden die im Zwischenspeicher hinterlegten Daten an den SDRAM-Controller und folglich dem SDRAM-Speicher übergeben.

Mit Blick auf die von der elektrischen Schnittstelle bereitgestellten Signale und der durch das XY2-100-E Protokoll vorgegebenen Erfassungsrates erfordert die Ablage der Datensätze einen kontinuierlichen Datenstrom von 2,8 MByte/s. Die in dieser Arbeit zur Übersendung der Maschinendaten an das Benutzerprogramm verwendete Universal Asynchronous Receiver Transmitter (UART)-Schnittstelle weist eine maximale Datenrate von 115.200 Bits/s auf. Dementsprechend können die erhobenen Daten nicht genauso schnell aus dem Speicher abgerufen werden, wie sie hineingelegt werden. Bedingt durch die Speicherkapazität des SDRAM-Speichers von 32 MByte ist die Aufnahmedauer des Akquise-Systems somit auf ca. 12 Sekunden begrenzt.

Während der Aufnahme wird der Speicherbaustein zwischen einem Adressstart- und einem Adressendpunkt beschrieben. Sobald der Adressraum ausgenutzt ist, endet die Datenaufzeichnung. Zukünftig könnte statt der UART-Schnittstelle eine Ethernet-Schnittstelle unter Verwendung des UDP/IP-Protokolls für höhere Datenübertragungsrates sorgen. Mit Hilfe eines Ringspeichers wäre das System dann nicht mehr durch die Speicherkapazität des SDRAM-Speichers begrenzt.

### 7.1.4 Benutzeroberfläche des Akquise-Systems

Die Benutzer-Interaktion mit dem Akquise-System erfolgt über eine graphische Benutzeroberfläche, die mit der Programmiersprache Python und dem dafür verfügbaren Paket PyQt5 implementiert wird. Abbildung 7.7 zeigt diese Oberfläche, die sich in Anzeigeflächen zur Darstellung von Informationen oder Bildern sowie Schaltflächen zur Steuerung des Akquise-Systems unterteilt. Die auf der Abbildung markierten Bereiche der Oberfläche haben folgende Funktionen:

1. Anzeige des aktuellen Inhalts der Ausgangsregister der FPGA-Module
2. Verbindungseinstellungen zum FPGA-System
3. Konfiguration der FPGA-Module
4. Verbindungseinstellungen zur Hyperspektralkamera
5. Bildvorschau der Hyperspektralkamera
6. Konfiguration der Hyperspektralkamera
7. Anzeige von Systeminformationen
8. Kamera-Status während Datenaufnahme
9. Anzeige aufgenommener Bilder
10. Schaltfläche zur Auslösung des Akquise-Prozesses
11. Anzeige erfasster Maschinendaten

## 7.1. AKQUISE-SYSTEM ZUR VERKNÜPFUNG VON PROZESS- UND MASCHINENDATEN

12. Navigation durch Prozessdatensätze

13. Speichern und Laden der Prozessdatensätze

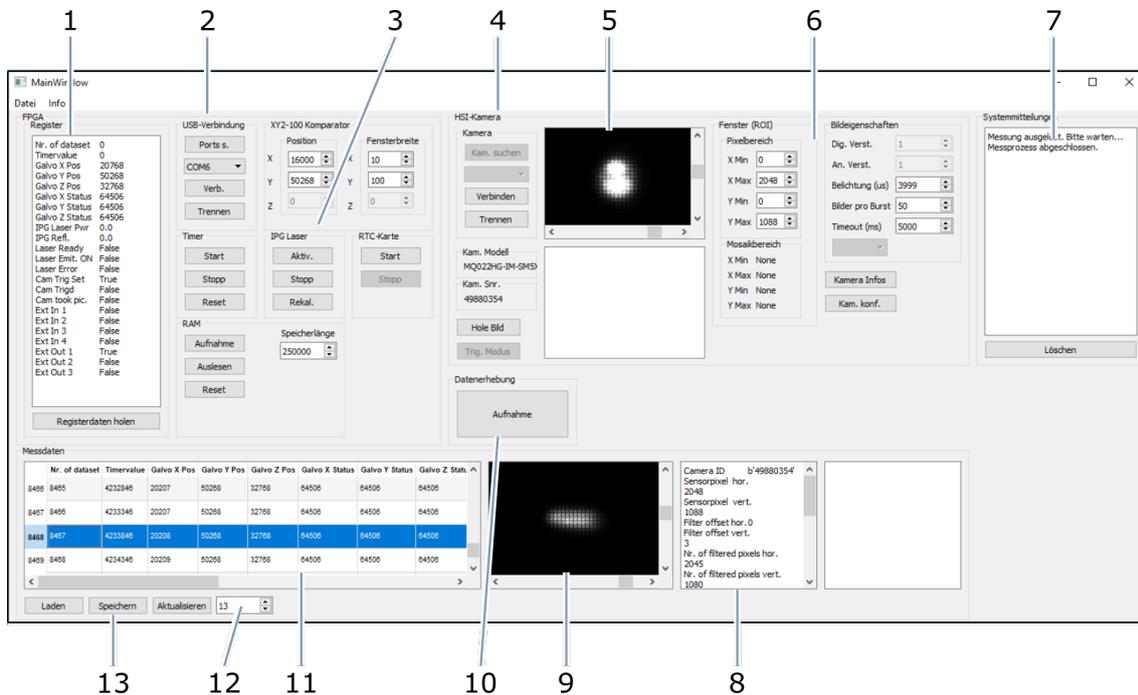


Abbildung 7.7: Software-Benutzeroberfläche zur Kommunikation mit FPGA und Kamera, Datenakquise und -ablage.

Typischerweise wird zunächst die Hyperspektralkamera eingebunden (4) und bezüglich Belichtungszeit und weiteren Parametern konfiguriert (6). Die ordnungsgemäße Bilderfassung kann über ein Fenster (5) verifiziert werden. Parallel erfolgt die Einbindung des FPGA-Systems (2). Die Übertragung der Maschinendaten kann wiederum über ein Fenster zur Anzeige des aktuellen Maschinenzustands (1) überprüft werden. Sobald die Hyperspektralkamera und das FPGA-System konfiguriert sind, kann ein automatischer Akquise-Prozess ausgelöst werden. Dieser sendet ein Trigger-Signal an die Steuerkarte, sodass ein vordefiniertes Scan-Muster abgefahren wird. Gleichzeitig werden die Maschinen- und Bilddaten während des Laserprozesses aufgenommen, bei bestimmter Scanner-Position ein Trigger-Signal an die Kamera gesendet und die Rückgabe-Signale der Kamera in Form von fallenden Flanken erfasst. Diese Rückgabe-Signale ermöglichen eine präzise Zuordnung der Bild- und Maschinendaten.

Nachdem sowohl Kameraaufnahmen als auch Maschinendaten zeitlich korreliert erfasst wurden, können diese Informationen in den dafür vorgesehenen Anzeigefeldern (9 und 11) der Oberfläche eingesehen werden. Mit Hilfe der Wahlschalter (12) kann zwischen den Kameraaufnahmen gewechselt werden, wobei gleichzeitig die korrespondierenden Maschinendaten angezeigt werden.

### Kommunikation zwischen Benutzerprogramm und FPGA-System

Die Grundlage für die oben vorgestellten Funktionalitäten des Benutzerprogramms ist die Kommunikation zwischen dem Programm und dem FPGA-System. Die im

FPGA realisierte NIOS<sup>®</sup> II Prozessorstruktur dient dabei als Verbindungsglied zwischen Benutzerprogramm und den weiteren FPGA-Modulen. Bedingt durch die UART-Schnittstelle erfolgt die Kommunikation zwischen NIOS<sup>®</sup> II und dem Programm zeichenbasiert. Dementsprechend wird ein Kommunikationsprotokoll verwendet, in dem alle zu übermittelnden Informationen entsprechend dem ASCII-Standard als Zeichenketten kodiert werden. Solche Zeichenketten können nicht nur über das implementierte Programm, sondern ebenso über eine beliebige Terminal-Software übermittelt werden.

Vom Benutzerprogramm an den NIOS<sup>®</sup> II Prozessor übertragene Daten müssen einerseits eine bestimmte Befehlsanweisung und andererseits Nutzdaten enthalten. Kommandozeichen und Nutzdaten werden also jeweils als Zeichenketten und durch einen Doppelpunkt getrennt übermittelt. Das Ende des Datensatzes wird mit dem line feed <LF> Steuerzeichen gekennzeichnet.

Zur Datenübertragung in die andere Richtung, also vom NIOS<sup>®</sup> II zum Benutzerprogramm, werden wiederum Zeichenketten verwendet. Die zu übermittelnden Maschinendaten werden also als Zeichenketten kodiert, wozu jede 16-Bit breite Datenzeile jeweils durch zwei als Zeichen kodierte Hexadezimalzahlen repräsentiert wird. Für jeden Datenblock überträgt der Prozessor also eine Zeichenkette aus 64 Zeichen, wiederum gefolgt von einem line feed, der den Zeilenabschluss markiert. Außerdem kennzeichnet ein Präfix die Nummer des transferierten Blocks innerhalb des gesamten Speicherabbilds. Abbildung 7.8 veranschaulicht die Kommunikation zwischen NIOS<sup>®</sup> II und Benutzerprogramm und zeigt die Syntax der zu übertragenen Zeichenketten.



Abbildung 7.8: Veranschaulichung der Kommunikation zwischen Benutzerprogramm und Prozessor-Struktur.

## Datenablage

Aus dem Benutzerprogramm können die erhobenen Daten exportiert werden, damit sie anschließend zur weiteren Datenauswertung zur Verfügung stehen. Ähnlich wie in Kapitel 6 wird dazu auf die für Python spezifischen Listen und das Pickle-Format zurückgegriffen. Jedes Python-Datenobjekt kann als Pickle-Datei abgespeichert werden.

Abbildung 7.9 zeigt die Struktur der Liste, die mit Hilfe des Benutzerprogramms im Pickle-Format abgespeichert werden kann. Python-Listen haben die besondere Eigenschaft, dass ihre Listenelemente unterschiedliche Datentypen enthalten können. In diesem Fall bestehen die vier Listenelemente aus zwei weiteren Listen sowie zwei Objekten des Python-Datentyps Dictionary. Ein Dictionary besteht aus Schlüsselwörtern, denen ein bestimmter Wert zugeordnet wird. Die Elemente der Liste der Bilddaten enthalten jeweils die Bildaufnahme als Numpy-array sowie das manuell hinzugefügte Label. Dieses Label bzw. die Kennzeichnung des jeweiligen Bildes

## 7.1. AKQUISE-SYSTEM ZUR VERKNÜPFUNG VON PROZESS- UND MASCHINENDATEN

nimmt entweder den Wert 0 für ein fehlerfreies Bild und den Wert 1 für ein Fehlerbild an. Die Zuschneidung auf ein Bild mit 20 \* 20 Pixeln bei 25 Kanälen erfolgt mit Hilfe des in Kapitel 6 beschriebenen Algorithmus. Das nächste Listenelement enthält die Maschinendaten, die anhand des darauf folgenden Listenelements, der Korrelationstabelle, den Bilddaten zugeordnet werden können. Das letzte Listenelement stellt die Konfigurationseinstellungen der Hyperspektralkamera wie bspw. die Belichtungszeit zur Verfügung.

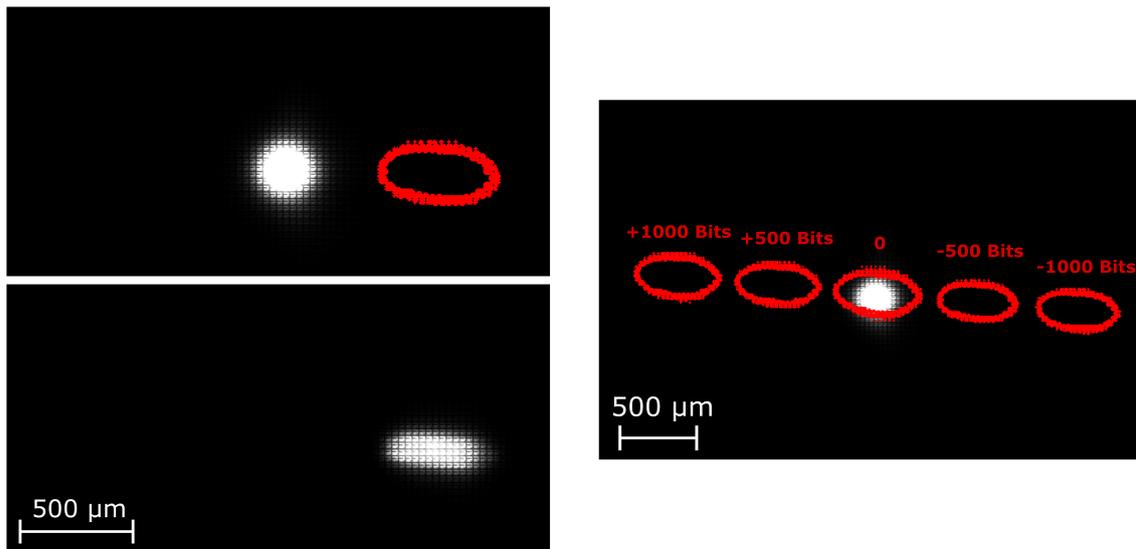
<i>Python-Liste</i>			<b>Pickle-Datei</b>
<b>[</b> Bild- daten	, Maschinen- daten	, Korrelations- tabelle	, Kamera- Konfig. <b>]</b>
<i>Liste</i>	<i>Dictionary</i>	<i>Liste</i>	<i>Dictionary</i>
[np.array(20,20,25), Label]	Galvo X Pos : 20678	12	Exposure [µs]: 4000
[np.array(20,20,25), Label]	Galvo Y Pos : 50628	25	ROIOffsetwidth: 0
...	...	...	...

Abbildung 7.9: Struktur der exportierbaren Pickle-Datei, die alle erhobenen Bild- und Maschinendaten enthält.

### 7.1.5 Positionsabhängiges Triggern von Prozessaufnahmen

Das beschriebene Akquise-System erlaubt ein von der Position des Laserspots abhängiges Triggern der Hyperspektralkamera. Durch den Vergleich der aktuellen Steuerbefehle mit den zuvor als 16-Bit-Wert festgelegten Positionsdaten erfolgt bei Übereinstimmung die sofortige Übersendung einer steigenden Flanke an die Kamera. Der Benutzer kann somit genau einstellen, an welchem Punkt des Prozesses eine Aufnahme oder der Start mehrerer Aufnahmen erfolgt.

Abbildung 7.10 veranschaulicht den Trigger-Mechanismus. In Abbildung 7.10a ist oben ein statischer Spot sowie die Kontur des unteren, sich bewegenden Spots zu sehen. In Abbildung 7.10b sind der statische Spot und die Konturen mehrerer, zu verschiedenen Zeitpunkten getriggerten Spots zu sehen. Diese bewegten sich mit einer Vorschubgeschwindigkeit von 75 mm/s, was zur Verarbeitung von Magnesium an dieser Anlage ein üblicher Wert ist. Die Belichtungszeit betrug 4 ms. Die Aufnahme kann auf ein Bit genau getriggert werden, sodass die Belichtung der Kamera durch den sich bewegenden Spot bei entsprechender Festlegung der Position direkt an der Stelle des statischen Spots erfolgt. Dies verdeutlicht die Bedeutung des FPGA, der eine punktgenaue Aufnahme zum richtigen Zeitpunkt möglich macht.



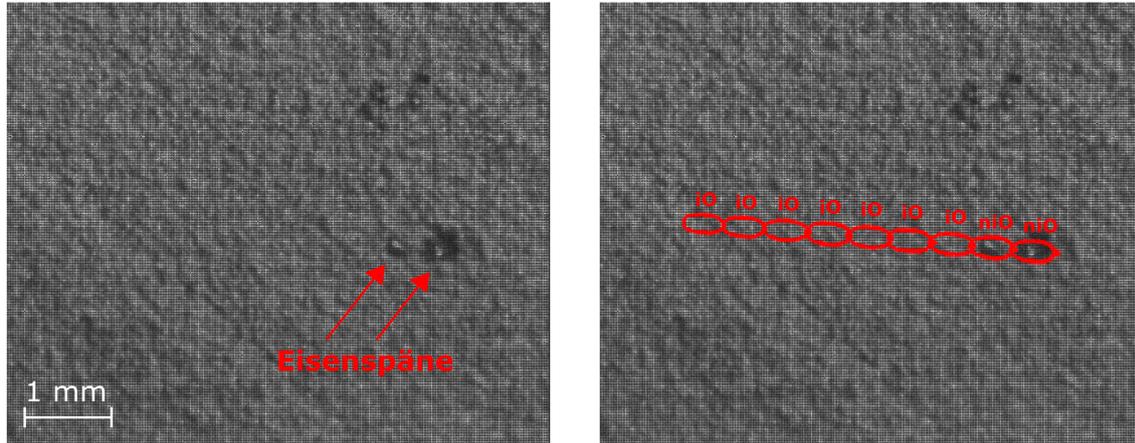
(a) Oben: statischer Laserspot und Kontur des unteren Spots. Unten: getriggerte Aufnahme des sich bewegenden Laserspots. Die Bildausschnitte sind identisch.

(b) Konturen der sich bewegenden Laserspots bei unterschiedlichen Triggerzeitpunkten. Der statische Spot ist in der Mitte zu sehen. Die Kamera kann auf einen Bit der Scannersteuerung genau getriggert werden.

Abbildung 7.10: Veranschaulichung der Kamera-Triggerung.

## 7.2 Künstliche Erzeugung von Prozessfehlern

Die Implementierung des Akquise-Systems stellt die nötige Infrastruktur bereit, um künstliche Prozessfehler zu erzeugen und diese orts aufgelöst durch die Hyperspektralkamera aufzunehmen. Hierzu werden Eisenspäne mit einem Durchmesser von  $100 - 300 \mu\text{m}$  als Fremdpartikel im Pulverbett platziert. Abbildung 7.11 zeigt eine Aufnahme mit der Hyperspektralkamera des Pulverbetts bei einer Belichtungszeit von ca. einer Sekunde. In Abbildung 7.11a sind die Eisenpartikel an einigen Orten als dunklere Partikel zu erkennen. Auf der rechten Abbildung 7.11b sind zusätzlich die zuvor mit der Kamera erfassten Konturen der Laserspots bei einer Belichtungszeit von 4 ms eingezeichnet. Der Laserspot kommt von rechts und nähert sich dabei der Fehlstelle an. Sobald er diese erreicht, wird die Aufnahme gestartet und eine Reihe von Bildern in direkter Abfolge aufgenommen. Man kann erkennen, dass die Schweißspur des Lasers nahezu lückenlos durch die Kameraaufnahmen erfasst wird. Die ersten beiden Aufnahmen können direkt als Fehlerbilder gekennzeichnet werden. Zur Platzierung der Eisenspäne in das Pulverbett wird der Pilot-Laser als Hilfestellung genutzt. Mit einer Pinzette wird dabei der Span so genau wie möglich auf den Laserspot des Pilot-Lasers platziert. Anschließend wird bei hoher Belichtungszeit der Ort des Spans anhand des Kamerabildes verifiziert. Falls der Laserspot des Pilot-Lasers nicht getroffen wird, kann dieser auf den Span bewegt werden. Anschließend wird die neue Position des Spots, also die Spiegel-Ausrichtung des Galvanometer-Scanners, als Trigger-Zeitpunkt berücksichtigt. Dabei muss beachtet werden, dass die Wellenlänge des Pilot-Lasers bei  $633 \text{ nm}$ , die des Prozesslasers aber bei  $1070 \text{ nm}$  liegt, was bedingt durch die chromatische Aberration der F-Theta Optik zu einer leichten Verschiebung der beiden Laserspots zueinander führt.



(a) Aufnahme vom Pulverbett bei hoher Belichtungszeit. Rechts im Zentrum sind künstlich eingebrachte Eisenspäne zu sehen.

(b) Konturen aufeinanderfolgender Laserspots, die bei 4 ms Belichtungszeit erfasst werden. Die Konturen, die Eisenspäne umschließen, werden als niO gekennzeichnet.

Abbildung 7.11: Datenakquise und -kennzeichnung zur Detektion von Prozessfehlern.

Für die Untersuchungen wird jeweils eine Schicht der Magnesiumlegierung WE43 mit künstlich eingebrachten Fehlern prozessiert. Dabei werden die gleichen Prozessparameter wie in Kapitel 6 verwendet, die als geeignete Parameter für eine möglichst hohe Bauteilqualität identifiziert wurden. Die Laserleistung beträgt dementsprechend 50 W und die Vorschubgeschwindigkeit des Laserspots 75 mm/s. Es wird auch der gleiche Pulverwerkstoff eingesetzt, dessen Eigenschaften in Tabelle 6.2 aufgelistet sind. Die eingebrachten Eisenspäne führen zu Oberflächendefekten, die mit Hilfe eines Konfokalmikroskops visualisiert werden können. Abbildung 7.12 zeigt die Oberfläche einer solchen Schicht und vergrößert jeweils einen fehlerfreien Bereich sowie eine Zone der Probe mit deutlich erkennbaren Oberflächendefekten. In diesem Fall liegen die Fehlstellen an der Oberfläche. Fremdpartikel können aber ebenso im Inneren der Bauteile für Fehlstellen sorgen, die das Gefüge und die mechanischen Eigenschaften beeinträchtigen. Abbildung 7.12 zeigt außerdem, dass neben den einzelnen Fehlstellen in Form von aus der Oberfläche hervortretenden Partikeln auch die umliegende Oberfläche weniger gleichmäßig ist als in einer Umgebung ohne Fehlstellen. Ein Grund hierfür könnte sein, dass die Fremdpartikel für zusätzliche Spritzer- und Schmaucheinflüsse sorgen und damit den Prozess insgesamt instabiler machen. Wie in den Abbildungen 7.13 und 7.14 zu sehen, wird mittels einer energiedispersiven Röntgenanalyse (EDX) die Oberfläche an einer fehlerfreien Stelle der Probe sowie an einer Fehlstelle spektroskopisch untersucht. Die WE43-Legierung enthält neben Magnesium die seltenen Erden Yttrium und Neodym, die in der Materialanalyse sichtbar werden. Die Fehlstelle wiederum weist einen hohen Eisenanteil auf, der belegt, dass sie durch die zugefügten Eisenspäne erzeugt wurde. Die Aufnahmen des Rasterelektronenmikroskops verdeutlichen zudem die veränderte Oberflächenbeschaffenheit in der Umgebung der Fehlstelle: das Bild der Oberfläche rechts in Abbildung 7.13 zeigt eine deutlich glattere und von weniger Ansinterungen umgebene Oberfläche als das Bild der Fehlstelle rechts in Abbildung 7.14.

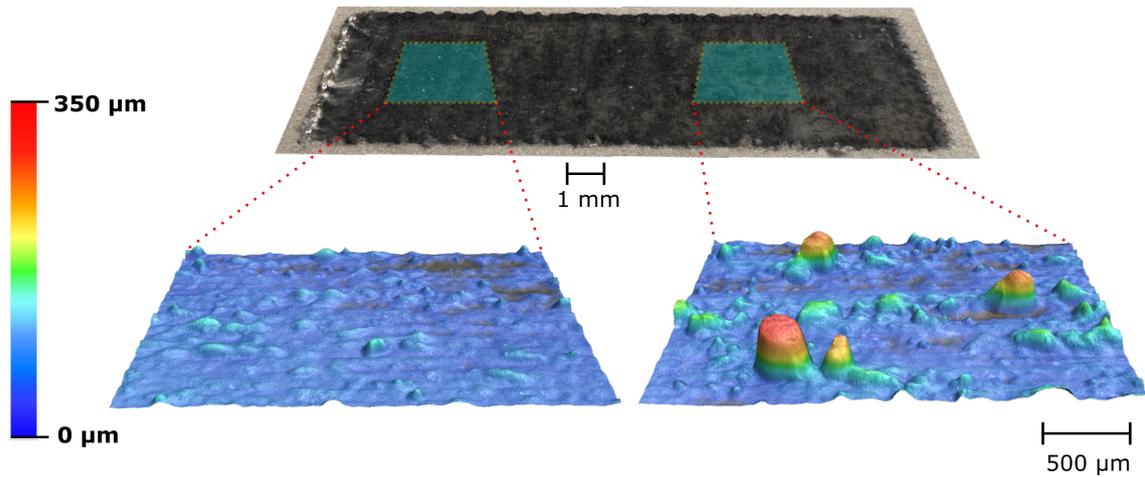


Abbildung 7.12: Oberflächenprofil additiv gefertigter Proben. Während die linke Darstellung einen Oberflächenbereich ohne Fehler zeigt, sind rechts künstlich eingebrachte Fehler zu sehen.

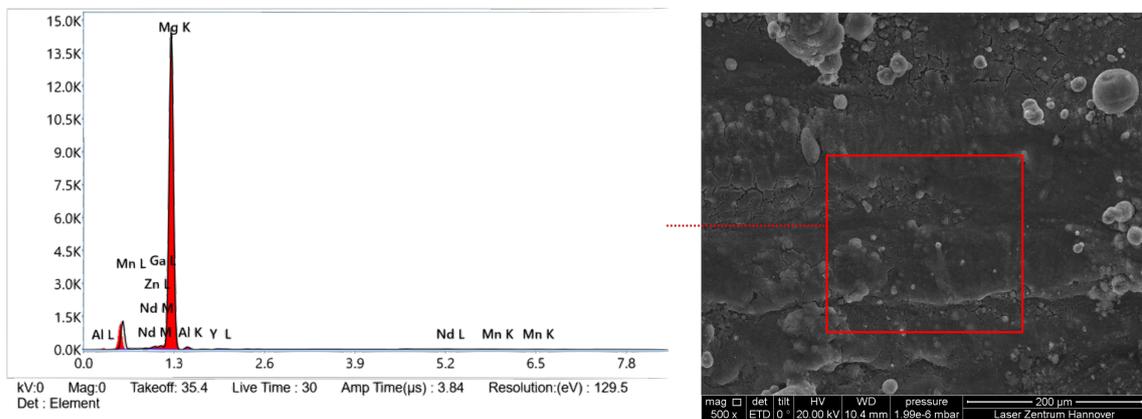


Abbildung 7.13: Materialanalyse von der additiv gefertigten Probe mit Hilfe des Rasterelektronenmikroskops. Die Probe wurde mit der Magnesiumlegierung WE43 gefertigt.

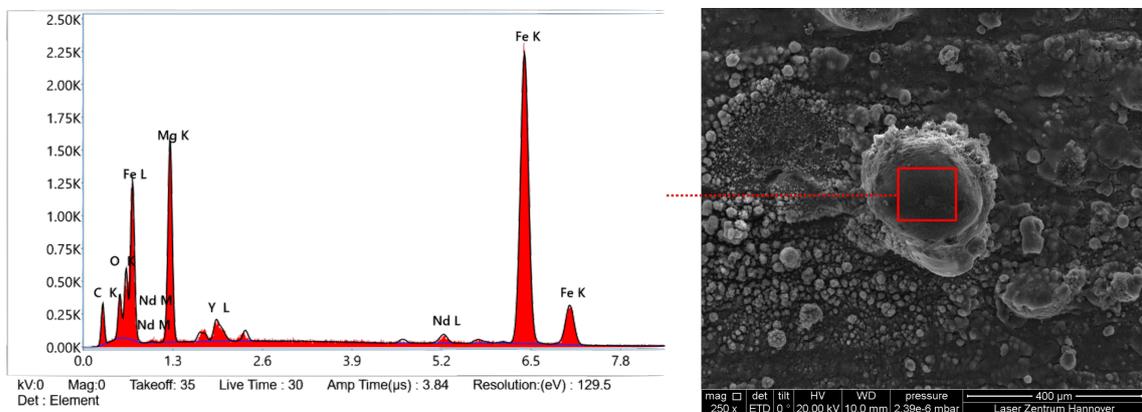


Abbildung 7.14: Materialanalyse des Prozessdefekts mit Hilfe des Rasterelektronenmikroskops. Der Defekt wurde künstlich durch Einbringung eines Eisenspanns erzeugt.

## 7.3 Ortsaufgelöste Vorhersage von Prozessfehlern

Das im Zuge dieser Arbeit entwickelte und in Abschnitt 7.1 beschriebene Akquisitionssystem wird dazu genutzt, hyperspektrale Prozessaufnahmen der in Abschnitt 7.2 beschriebenen künstlich erzeugten Prozessfehler zu erheben. Dies dient dem Ziel, ein Modell zu entwickeln, das Prozessfehler anhand der hyperspektralen Prozessaufnahmen erkennt.

### 7.3.1 Datensatz

Abbildung 7.15 zeigt je ein Beispiel einer hyperspektralen Prozessaufnahme eines fehlerfreien Prozesses sowie die eines künstlich induzierten Fehlers. Obwohl hierbei zunächst klare Unterschiede auszumachen sind, lassen die Schwankungen innerhalb der insgesamt 250 niO- und 12.500 iO-Prozessaufnahmen für das menschliche Auge keine offensichtliche Trennlinie erkennen.

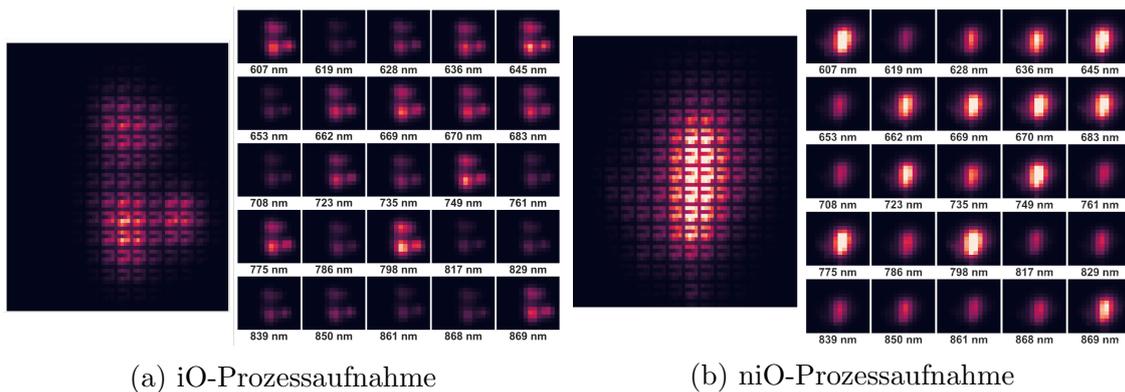


Abbildung 7.15: Beispiele für hyperspektrale Prozessaufnahmen bei der Verarbeitung einer WE43-Legierung.

Tabelle 7.7 fasst den akquirierten Datensatz zusammen. Die Unausgewogenheit des Datensatzes – er umfasst 50-mal mehr iO-Aufnahmen als niO-Aufnahmen – ist bedingt durch die deutlich aufwendigere Erhebung von Fehlerbildern und eine gewöhnliche Problemstellung bei der Anomalie-Detektion. Alle Prozessaufnahmen werden gemischt, bevor sie zu 70 % dem Trainings-, zu 15 % dem Validierungs- und zu 15 % dem Testdatensatz zugeordnet werden.

Tabelle 7.7: Übersicht über den Datensatz aus insgesamt 12.750 hyperspektralen Prozessaufnahmen. Die Aufnahmen werden gemischt und anschließend in die entsprechenden Anteile für Training, Validierung und Test aufgeteilt.

Daten	Training		70 %
	iO	niO	Validierung
Gesamt	12.500	250	15 %
			Test
			15 %

### 7.3.2 Anpassung des CNN auf unausgewogenen Datensatz

Zur Vorhersage von Prozessfehlern wird auf dem Modell aus Kapitel 6 aufgebaut, das mit den erhobenen Daten trainiert wird. Die erwähnte Unausgewogenheit des Datensatzes macht allerdings einige Anpassungen bezüglich des Trainings des CNN nötig.

Als Kosten- bzw. Verlustfunktion für die binäre Klassifikation wird die Kreuzentropie verwendet, die insofern angepasst wird, als Falschklassifizierungen von niO-Aufnahmen 50-mal höher bestraft werden. Abbildung 7.16 verdeutlicht dies und zeigt die letzte Schicht sowie den Ausgangswert des CNN. Alle Prozessaufnahmen des Datensatzes werden mit einer 0 für eine iO- oder einer 1 für eine niO-Aufnahme gekennzeichnet. Der Ausgangswert des CNN liegt zwischen 0 und 1 und steht für die Wahrscheinlichkeit, dass die jeweilige Prozessaufnahme einem Prozessfehler zuzuordnen ist. Liegt diese Wahrscheinlichkeit über der Entscheidungsschwelle, so wird die jeweilige Aufnahme einem fehlerbehafteten, andernfalls einem fehlerfreien Prozess zugeordnet. Die Entscheidungsschwelle liegt, wie oft üblich, anfangs bei 0,5, was allerdings nicht unbedingt die akkurateste Klassifizierung ergibt, wie später noch ausgeführt wird.

Die Darstellung der Verlustfunktion rechts in Abbildung 7.16 zeigt, wie sich der Wert und vor allem auch der Gradient der Verlustfunktion erhöht, je kleiner diese Wahrscheinlichkeit während des Trainings für ein niO-Fehlerbild vom CNN berechnet wird. Diese Anpassung der Verlustfunktion ist insofern von wesentlicher Bedeutung, als der Trainingsprozess auf das alleinige Ziel der Minimierung der Verlustfunktion ausgerichtet ist. Alle Gewichtungen bzw. trainierbaren Parameter des Modells werden dementsprechend angepasst.

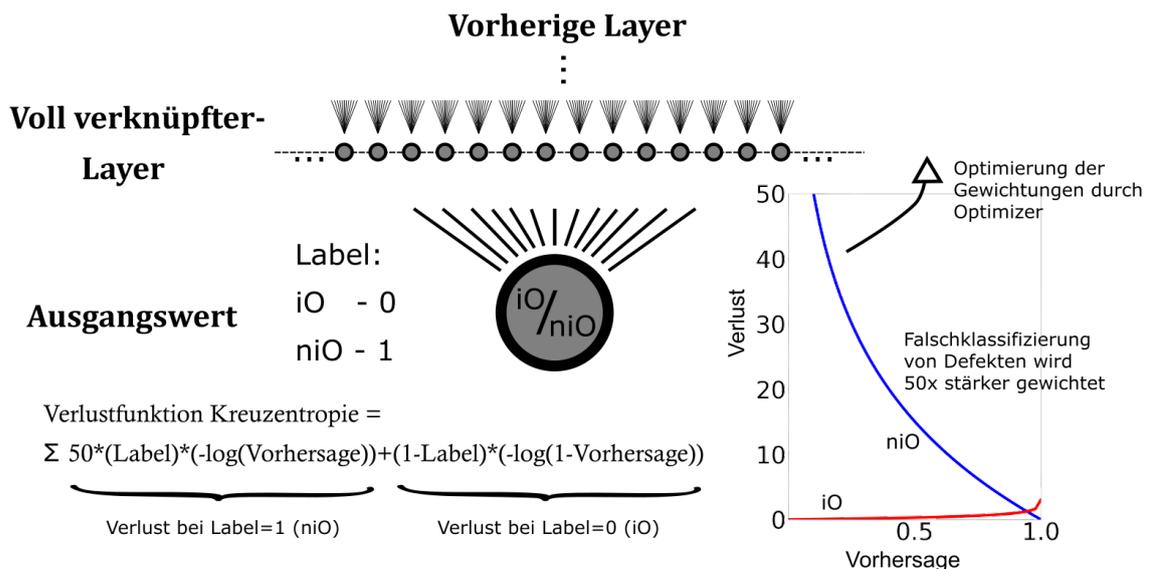


Abbildung 7.16: Endteil des CNN zur Fehlererkennung.

### 7.3.3 Metriken zur Bewertung der Klassifizierungsgenauigkeit

Eine weitere durch die Unausgewogenheit des Datensatzes bedingte Anpassung bei der Auslegung des Modells betrifft die Metrik zur Bewertung der Klassifizierungsgenauigkeit. Der Anteil richtig klassifizierter Aufnahmen ist keine gute Metrik, denn da nur 2 % der Daten aus niO-Aufnahmen bestehen, könnten 98 % der Aufnahmen korrekt klassifiziert werden, wenn alle ausschließlich als iO bewertet würden. Deshalb werden für die Anomalie-Detektion besser geeignete Metriken definiert, die das Verhältnis zwischen der Anzahl richtig-positiv ( $R_p$ ), falsch-positiv ( $F_p$ ) sowie falsch-negativ ( $F_n$ ) bewerteter Proben berücksichtigen [Mon18]:

$$\text{Genauigkeit} = \frac{R_p}{R_p + F_p} \quad \text{Sensitivität} = \frac{R_p}{R_p + F_n} \quad (7.1)$$

Um sowohl Genauigkeit und Sensitivität in einer Metrik zu berücksichtigen, wird häufig das harmonische Mittel dieser beiden Größen verwendet. Diese Metrik wird F-Maß genannt, engl. *F-score* oder *F1-score* [Mon18]:

$$\text{F-Maß} = 2 \cdot \frac{\text{Genauigkeit} \cdot \text{Sensitivität}}{\text{Genauigkeit} + \text{Sensitivität}} \quad (7.2)$$

### 7.3.4 Hyperparameter-Tuning

Mit der Anpassung der Verlustfunktion und dem F-Maß als Metrik kann folglich der Datensatz zum Training des CNN verwendet werden. Wie in Abbildung 6.9 gezeigt, umfasst das Modell vier Convolutional-Layer, 3 \* 3 Faltungsmatrizen, ReLU-Aktivierungsfunktionen und einen Dropout-Layer zur Vermeidung von Überanpassung. Zur Bestimmung einer auf die Fehlerdetektion spezialisierte Netzwerktopologie wird wiederum ein Hyperparameter-Tuning durchgeführt. Durch die geringere Datenmenge und die wie sich zeigte geringere Anzahl von Epochen bis zur Konvergenz der Verlustfunktion kann eine umfangreiche Untersuchung der Hyperparameter durchgeführt werden. So werden die Anzahl der Perzeptronen in der letzten Schicht (8, 16, 32), die Dropout-Rate (0,2; 0,4; 0,6), die Optimierungsfunktion (Adam, Nadam und Stochastic Gradient Descent (SGD)) sowie die Lernrate (0,0005; 0,001; 0,002) variiert und das CNN in der jeweiligen Konfiguration für jeweils vier Epochen bei einer Batch-Größe von 20 trainiert. Die Variation der Lernrate ist wichtig, denn für bestimmte Netzwerktopologien kam es je nach Lernrate nicht zu einer abnehmenden Verlustfunktion.

Nach dem Training der Netzwerke mit dem Trainingsdatensatz wird das F-Maß anhand der Validierungsdaten bestimmt. Abbildung 7.17 zeigt eine Visualisierung des Hyperparameter-Tunings. Die Farbe der Linien steht dabei für das erreichte F-Maß, blau für gering bis rot für hoch. So lässt sich beispielsweise erkennen, dass die SGD-Optimierungsfunktion im Durchschnitt zu deutlich höheren Werten des F-Maßes führt als die beiden anderen untersuchten Optimierungsfunktionen. In Anhang A.4 ist eine tabellarische Übersicht über die Ergebnisse des Hyperparameter-Tunings aufgeführt.

Das höchste F-Maß bei den Validierungsdaten erreicht allerdings die Nadam-Optimierungsfunktion. Die weiteren ermittelten Hyperparameter sind in Tabelle 7.8 aufgeführt. Diese Netzwerk-Topologie erreicht ein F-Maß bei der Klassifikation der

Tabelle 7.8: Netzwerktopologie mit dem höchsten F-Maß bei der Klassifizierung der Validierungsdaten nach vier Trainingsepochen im Hyperparameter-Tuning.

Perzeptronen in letzt. Sch.	Dropout- Rate	Optimierungs- Funktion	Lernrate	F-Maß
32	0,4	Nadam	0,0005	0,935

Validierungsdaten von 0,935. Es kann zwar davon ausgegangen werden, dass bedingt durch den kleinen Datensatz – die Validierungsdaten enthalten 1912 Aufnahmen, wovon im Mittel ein Fünzigstel Fehlerbilder sind – die Ergebnisse einer gewissen Streuung unterliegen. Dennoch wird angenommen, dass das so ermittelte Netzwerk eine sinnvolle Grundlage zur weiteren Untersuchung bildet.

Dementsprechend wird die Netzwerktopologie mit den benannten Hyperparametern für insgesamt 10 Epochen trainiert. Wie in Abbildung 7.18 dargestellt, nimmt die Verlustfunktion jedoch bei konstanter Lernrate von  $5 \cdot 10^{-4}$  ab der sechsten Trainingsepoche nicht mehr ab, sondern steigt sogar wieder kontinuierlich bis zur zehnten Epoche. Die Kreuzentropie, berechnet aus den Kennzeichnungen der Trainingsaufnahmen und der vorhergesagten Wahrscheinlichkeit für einen Fehler, nähert sich also zunächst einem Minimum und wird dann sowohl für Trainings- als auch Validierungsdaten wieder größer. Dies deutet darauf hin, dass die trainierbaren Parameter des CNN ab der sechsten Epoche nahe an einem lokalen Minimum liegen und die Lernrate dann zu hoch ist, sodass diese Parameter sich von dem Minimum wieder entfernen. Trotz der in Abschnitt 2.5.1 beschriebenen adaptiven Anpassung der Nadam-Optimierungsfunktion „springt“ die Verlustfunktion also ab der siebten Trainingsepoche aus einem lokalen Minimum. Um dies zu vermeiden, wird die Lernrate  $\eta$  bei einem erneuten Trainingsprozess jeweils ab der fünften und zehnten Epoche halbiert. Eine anfangs höhere Lernrate ist wichtig, um die Verlustfunktion in größeren Schritten zu minimieren. Ab einem gewissen Punkt sind kleinere Lernraten jedoch sinnvoller.

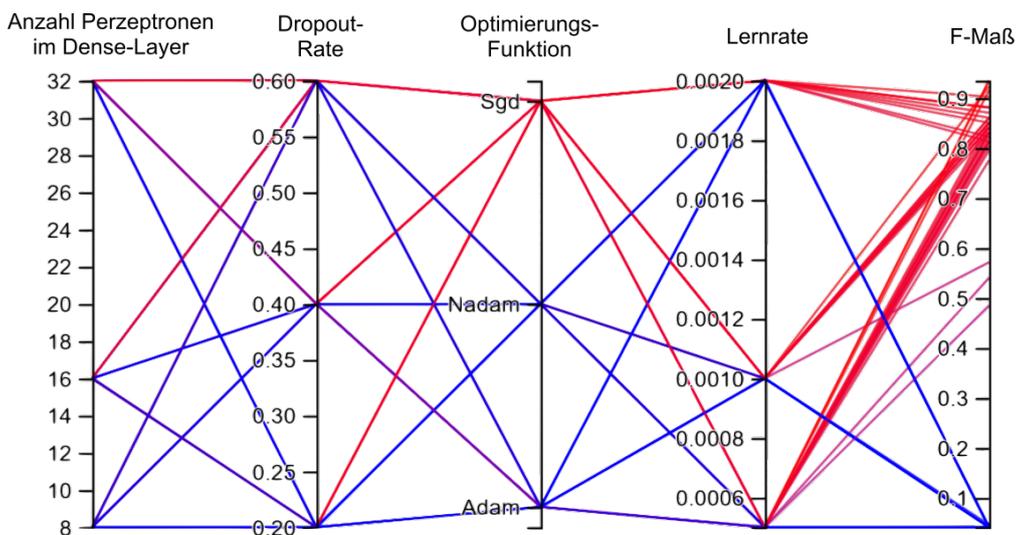


Abbildung 7.17: Hyperparameter-Optimierung zur Festlegung der Netzwerktopologie. Je heller die Verbindungslinie, desto höher das von der entsprechenden Netzwerktopologie erzielte F-Maß.

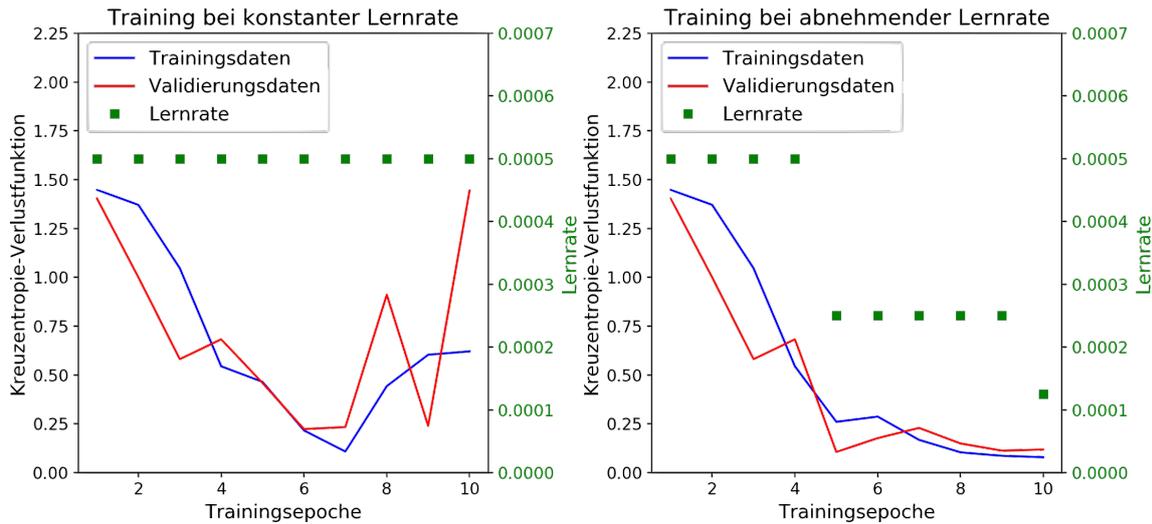


Abbildung 7.18: Bei konstanter Lernrate „springt“ die Verlustfunktion ab der siebten Trainingsepoch aus einem lokalen Minimum. Bei abnehmender Lernrate nähert sie sich dem Minimum weiter an.

Rechts in Abbildung 7.18 ist zu erkennen, dass sich die Verlustfunktion für Trainings- und Validierungsdaten in den ersten Epochen wie zuvor verhält, dann bei abnehmender Lernrate aber nicht wieder steigt, sondern sich weiter dem lokalen Minimum annähert und spätestens ab der neunten Epoche nicht mehr sinkt. Die Kreuzentropie konvergiert also und befindet sich im lokalen Minimum. Die geringe Diskrepanz zwischen der Verlustfunktion für Trainings- und Validierungsdaten spricht für eine leichte Überanpassung des Netzwerks an die Trainingsdaten. Die Anpassung der Lernrate während des Trainingsprozesses erweist sich demnach als geeignete Maßnahme zur Minimierung der Verlustfunktion.

Der Trainingsprozess und insbesondere das Optimierungsverfahren durch die Optimierungsfunktion ist darauf ausgelegt, die Verlustfunktion durch Anpassung der trainierbaren Parameter zu minimieren. Deshalb ist die Entwicklung der Verlustfunktion ein elementarer Aspekt zur Bewertung des Trainingsprozesses. Wie zuvor bereits erwähnt stehen aber die Metriken Genauigkeit, Sensitivität und F-Maß im Fokus der Untersuchungen. Deshalb lohnt es sich, auch deren Entwicklung während des Trainings zu analysieren. Abbildung 7.19 zeigt den Verlauf dieser Metriken und der Verlustfunktion bei beschriebener abnehmenden Lernrate.

Die Sensitivität ist von vornherein hoch, was darauf hindeutet, dass durch die Initialisierung des Modells alle Aufnahmen vorwiegend positiv bewertet werden. Dies bestätigt sich durch die Verläufe falsch-negativ und falsch-positiv bewerteter Aufnahmen, wie sie auch in Abbildung 7.19 gezeigt sind. Dementsprechend ist die Anzahl Falsch-positiver anfangs sehr hoch und somit die Genauigkeit sehr gering. Dies ändert sich am deutlichsten in der dritten Epoche. Mit der Genauigkeit steigt dann auch das F-Maß stark an, wobei es für die Validierungsdaten zunächst sogar einen noch höheren Wert als für die Trainingsdaten erreicht. Dies ist ein zufälliger Effekt, der wie erwähnt auch mit der geringen Größe des Gesamt-Datensatzes und insbesondere der niedrigen Anzahl an  $niO$ -Prozessaufnahmen in den Validierungsdaten zusammenhängt. Später im Trainingsprozess gleichen sich Trainings- und Validierungsdaten aber an. Nach 10 Trainingsepochen beträgt das F-Maß bei den Trainingsdaten 0,918 und bei den Validierungsdaten 0,935.

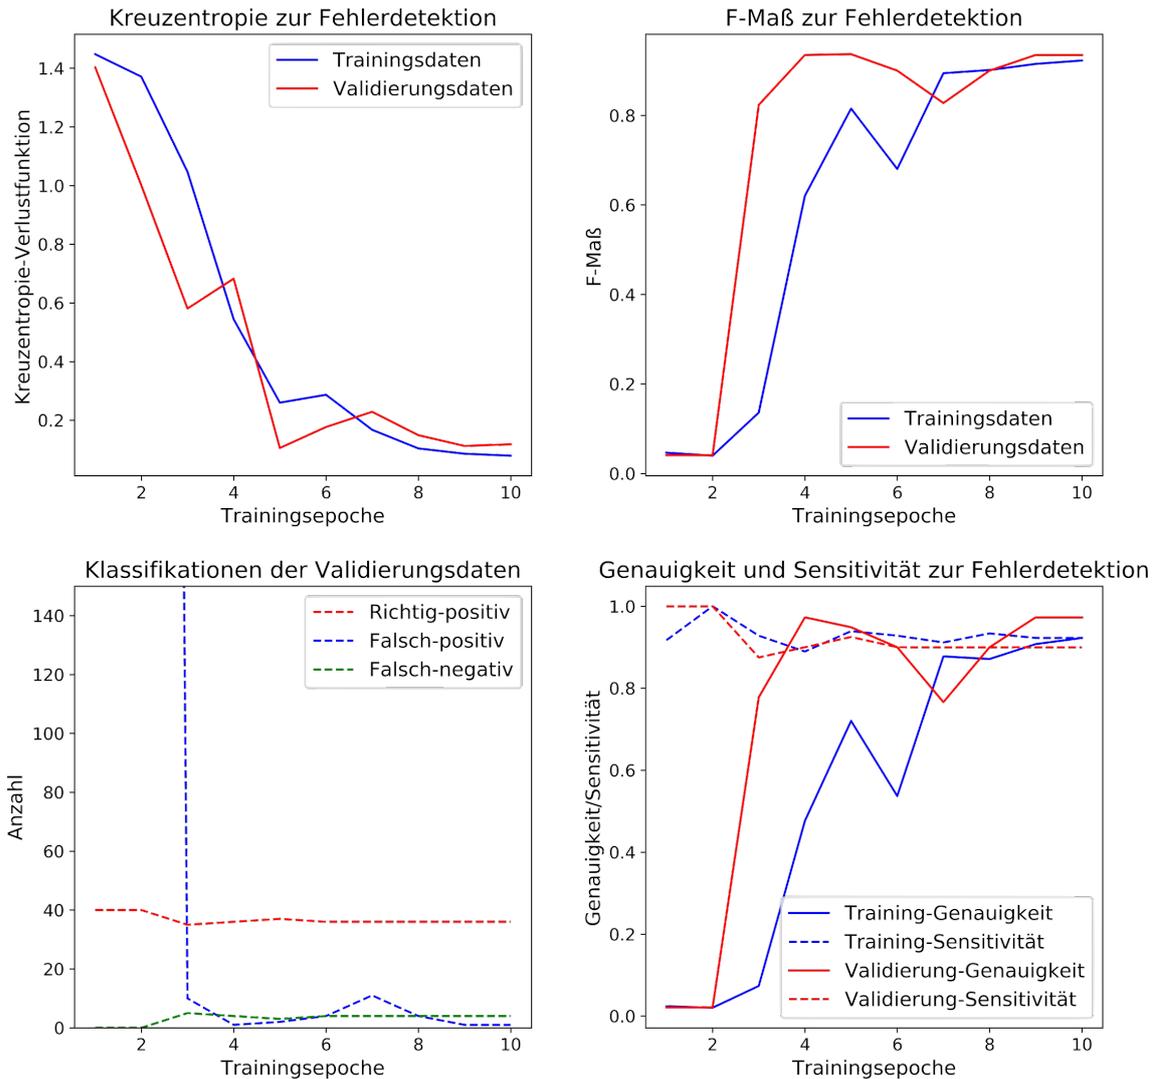


Abbildung 7.19: Entwicklung wesentlicher Metriken während der Trainingsphase des Convolutional Neural Networks.

Die Qualität der Klassifikation hängt insbesondere bei unausgewogenen Datensätzen von der Entscheidungsschwelle des Klassifikators ab. Die Entscheidungsschwelle wird anfangs auf 0,5 festgelegt, sodass alle Prozessaufnahmen, deren vom CNN berechnete Wahrscheinlichkeit, einen fehlerhaften Prozess zu zeigen, über 0,5 liegt, als niO-Aufnahmen deklariert werden. Nun soll bei der oben ermittelten Netzwerktopologie evaluiert werden, inwiefern andere Entscheidungsschwellen zwischen 0 und 1 genauere Klassifizierungsergebnisse liefern. Dazu wird die sogenannte Genauigkeit-Sensitivitäts-Kurve ermittelt, wozu die Genauigkeit und Sensitivität jeweils für verschiedene Entscheidungsschwellen anhand der Trainings- und Validierungsdaten bestimmt werden. Abbildung 7.20 zeigt die Kurve, wobei für ein hohes F-Maß beide Werte möglichst hoch sein müssen. Es lässt sich somit ein Punkt ermitteln, an dem das F-Maß maximal wird. Dieser ist in der Abbildung 7.20 eingezeichnet und entspricht einer Entscheidungsschwelle von 0,999993. Wird nun diese Entscheidungsschwelle zur Klassifizierung der Trainings- und Validierungsdaten angewandt, kann ein erhöhtes F-Maß von 0,939 erreicht werden. Wenn also nur solche Aufnahmen als Prozessfehler deklariert werden, für die das CNN mindestens diese sehr hohe Feh-

lerwahrscheinlichkeit errechnet hat, wird die Klassifizierung am genauesten. Tabelle 7.9 fasst die Ergebnisse zusammen.

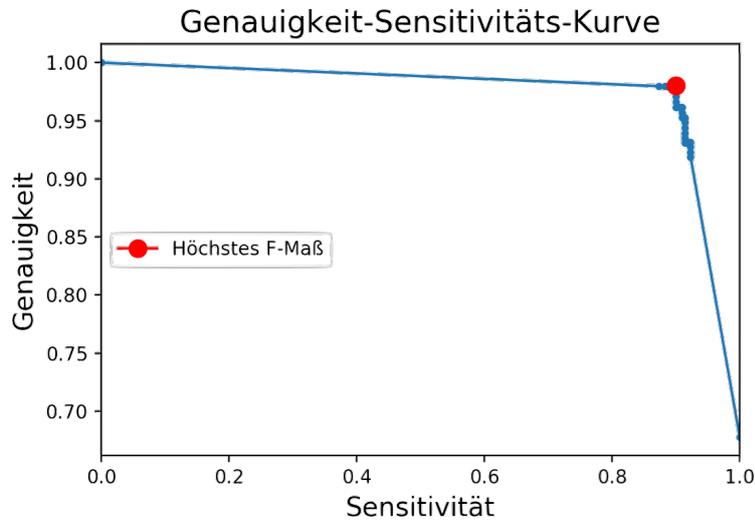


Abbildung 7.20: Genauigkeit-Sensitivitäts-Kurve für Trainings- und Validierungsdaten zur Identifizierung der optimalen Entscheidungsschwelle.

Tabelle 7.9: F-Maß bei Trainings- und Validierungsdaten nach Training der im Hyperparameter-Tuning ermittelten Netzwerktopologie für 10 Epochen und angepasster Lernrate.

Datensatz	Entscheidungsschwelle	F-Maß
Training	0,5	0,918
Validierung	0,5	0,935
Training + Validierung	0,999993	0,939

### 7.3.5 Bewertung der Klassifikationsgenauigkeit

Schlussendlich wird die ermittelte Netzwerktopologie mit aktualisierter Entscheidungsschwelle anhand des Testdatensatzes bewertet. Die Testdaten werden nach Erhebung und Kennzeichnung beiseite gelegt, sodass das Modell mit diesen vor der abschließenden Bewertung nicht in Berührung kommen. Tabelle 7.10 zeigt die Wahrheitsmatrix der Klassifikation der Testdaten. Die insgesamt 1912 hyperspektralen Prozessaufnahmen des Testdatensatzes werden in richtig-positive, richtig-negative, falsch-positive und falsch-negative Klassifikationen eingeteilt.

Damit ergeben sich für Genauigkeit, Sensitivität und F-Maß folgende Werte:

$$\text{Genauigkeit} = \frac{25}{25 + 1} = 0,96 \quad \text{Sensitivität} = \frac{25}{25 + 4} = 0,86 \quad (7.3)$$

$$\text{F-Maß} = 2 \cdot \frac{\frac{25}{25} \cdot \frac{25}{26}}{\frac{25}{25} + \frac{26}{26}} = 0,909 \approx \underline{\underline{91\%}} \quad (7.4)$$

Tabelle 7.10: Wahrheitsmatrix ermittelt aus Testdaten, die das CNN während des Trainingsprozesses nicht gesehen hat.

	Prozess in Ordnung (iO)	Prozessfehler (niO)	
iO - klassifiziert	1882	4	$\Sigma$ 1886
niO - klassifiziert	1	25	$\Sigma$ 26
	$\Sigma$ 1883	$\Sigma$ 29	

Dieses Ergebnis bestätigt die ursprüngliche Arbeitshypothese: hyperspektrale Prozessaufnahmen enthalten Merkmale über Prozessfehler, für dessen Erkennung ein CNN trainiert werden kann. Bei der Klassifikation der zuvor unbekanntes Testdaten kann das CNN aus den insgesamt 29 Prozessfehlern 25 als solche erkennen. Von allen 26 als Prozessfehler bewerteten Aufnahmen sind 25 tatsächlich Prozessfehlern zugehörig. Je nach Anwendungsfall kann die Entscheidungsschwelle gemäß Abbildung 7.20 angepasst werden, um entweder Genauigkeit oder Sensitivität zu erhöhen. So kann beispielsweise die Sensitivität zulasten des F-Maßes erhöht werden, wenn möglichst viele Prozessfehler erkannt werden sollen und die Zahl der falsch-positiven Klassifikationen weniger relevant ist.

Diese Ergebnisse lassen die Schlussfolgerung zu, dass die hyperspektrale Bildgebung sinnvoll für die Prozessüberwachung und Qualitätssicherung im LPBF-Verfahren eingesetzt werden kann. Die für den Sensor charakteristische Kombination aus spektraler und räumlicher Auflösung liefert wertvolle Informationen über das Prozessgeschehen, die mit Hilfe eines CNN entschlüsselt werden können. Die künstlich eingebrachten Fremdpartikel repräsentieren Pulververunreinigungen wie sie im Fertigungsalltag vorkommen können.

Der Vergleich mit der Literatur zeigt, dass das untersuchte System mit dem erreichten F-Maß von 91 % durchaus wettbewerbsfähig ist. Wie im Stand der Technik, Abschnitt 2.5.2 in Tabelle 2.3 ersichtlich, werden mit anderen Sensoriken und Verfahren zur Datenauswertung teils geringere und teils höhere Werte des F-Maß bei der Fehlerdetektion erreicht. Allerdings zielen diese auf die Erkennung von Poren oder Überhängen ab, nicht auf die Detektion von Fremdpartikeln im Pulverbett. Montazeri et al. [Mon20] setzen mit einem multispektralen Photodetektor und Methoden des maschinellen Lernens eine ähnliche Sensorik und Methodik zur Datenauswertung ein. Sie erreichen bei der Detektion von Poren ein F-Maß von 90 %, also vergleichbar mit den hier vorgestellten Ergebnissen. Ein deutlich höheres F-Maß von 97 % erreichen Yazdi et al. [Yaz20] bei der Detektion von Poren. Sie verwenden dabei eine High-Speed Kamera und neben Methoden des maschinellen Lernens auch eine Wavelet-Transformation und Textur-Analyse.

Die Arbeitshypothese kann also erfolgreich bestätigt werden. Es sollte aber erwähnt werden, dass die Ergebnisse nicht ohne Weiteres auf industrielle Prozesse übertragen werden können. Die Aufnahmen werden mit einem speziellen Objektiv mit 1-facher

Vergrößerung erhoben, was dazu führt, dass das Sichtfeld der Kamera auf einen kleinen Teil des Pulverbetts beschränkt bleibt. Die Versuche werden außerdem an einer Labor-LPBF-Anlage durchgeführt, die über einen relativ kleinen Laserspot und geringe Laserleistung verfügt. Dadurch bedingt enthalten die zur Verarbeitung der Magnesium-Legierung WE43 ermittelten Prozessparameter eine relativ geringe Vorschubgeschwindigkeit von 75 mm/s. Im Gegensatz dazu sind im industriellen Umfeld Vorschubgeschwindigkeiten um die 1000 mm/s üblich. Durch die maximale Bildrate der Kamera von 170 fps bei voller Auflösung ist die Übertragung der hyperspektralen Prozessüberwachung auf Prozesse mit höherer Vorschubgeschwindigkeit nicht trivial. Die eingeschränkte Lichtempfindlichkeit des Sensors bedingt durch Vorfilter und Fabry-Pérot Filter erfordert zudem hohe Belichtungszeiten und der kleine Sensitivitätsbereich kann dazu führen, dass nur kleine Bereiche des Schmelzbads weder über- noch unterbelichtet sind.

Kapitel 5 hat gezeigt, dass die Spektralbänder der Kamera zwischen 600 und 875 nm ungleichmäßig verteilt sind und die Wellenlänge selbst von monochromatischem Licht oft nur fehlerhaft bestimmt werden kann. Zwar kann das CNN dennoch auf Fehler verweisende Merkmale in den Kameradaten erkennen. Aber es besteht die Vermutung, dass Flächen-Hyperspektralkameras mit genauerer und fehlerfreier Spektralauflösung noch höheres Potenzial zur Fehlererkennung im LPBF-Prozess aufweisen.

Zusammenfassend kann festgehalten werden, dass der hier untersuchte Ansatz zur Prozessüberwachung ein hohes Potenzial für die Qualitätssicherung im LPBF-Verfahren darstellt. Dies wird untermauert durch die aufgezeigte Fähigkeit des Systems, Prozessfehler in Form von Fremdpartikeln mit einem F-Maß von 91 % zu erkennen. Koaxial integrierte Sensoren mit genauerer und zuverlässigerer Spektralauflösung sowie höherer Zeitauflösung könnten in Zukunft für noch höhere Erkennungsgenauigkeiten sorgen und die Übertragung auf industrielle Fertigungsprozesse möglich machen.



# 8 Schlussbetrachtung

## 8.1 Zusammenfassung

Die additive Metallfertigung bietet durch Geometriefreiheit, werkzeuglose Fertigung „on-demand“ sowie die Möglichkeit zur gezielten Gefügebeeinflussung enormes Potenzial – insbesondere für den Leichtbau und die Medizintechnik. So können beispielsweise ganze Bauteilgruppen in einem Bauteil vereint werden. Die Corona-Krise hat zudem die Bedeutung dezentraler, digitaler Fertigung, wie sie durch die additive Fertigung möglich wird, hervorgehoben. Nichtsdestotrotz kann sich die Technologie trotz anfänglichem Hype bislang nicht flächendeckend industriell etablieren. Schlechte Oberflächeneigenschaften, eingeschränkte Strukturauflösungen sowie mangelhafte Reproduzierbarkeit bremsen den breiteren Einsatz des LPBF-Verfahrens.

Die vorliegende Arbeit adressiert diesen Befund und befasst sich mit der Qualitätssicherung des LPBF-Prozesses durch hyperspektrale Bildgebung und Methoden des maschinellen Lernens. Um den Ausgangspunkt der Arbeit darzustellen wird im Stand der Forschung und Technik ein Einblick in die Technologie des Pulverbett-Verfahrens gegeben. Dabei werden vor allem die Wirkmechanismen und Ursachen typischer Prozessfehler wie Poren- und Rissbildung, Gefügeunregelmäßigkeiten sowie Oberflächenfehler diskutiert. Um diese bereits während des Prozesses zu erkennen, werden in der Forschung mehrere Ansätze zur Prozessüberwachung untersucht, wobei unterschiedliche Sensoriken sowie Methodiken zur Datenauswertung eingesetzt werden. Diese Arbeit verfolgt den neuartigen Ansatz, mittels einer Flächen-Hyperspektralkamera gleichzeitig Orts- und Spektralinformationen zu erheben und diese mit Methoden des maschinellen Lernens zu klassifizieren. Die Grundlagen der hyperspektralen Bildgebung und des maschinellen Lernens sind zu diesem Zwecke im Stand der Forschung und Technik dargelegt.

In Kapitel 4 wird die Funktionsweise der Flächen-Hyperspektralkamera beschrieben sowie dessen Eignung zur Erhebung reproduzierbarer Messergebnisse untersucht. Dabei zeigt sich, dass die Kamera bei stabiler Lichtquelle in hinreichendem Maße reproduzierbare Messwerte liefert. Der Vergleich mit Messungen an Laser-Punktschweißungen offenbart wiederum die starken Fluktuation der optischen Emissionen des Laserprozesses.

Daran anschließend werden in Kapitel 5 die spektralen Eigenschaften der Hyperspektralkamera beleuchtet und anhand von Messungen an monochromatischem Licht überprüft. Zur Integration einer hyperspektralen Prozessüberwachung in den LPBF-Prozess wird außerdem die Verwendung eines geeigneten Objektivs untersucht, dessen Vergrößerung eine für die Zielanwendung angemessene räumliche und spektrale Auflösung bietet. Der Weg des Lichts von der Prozesszone zum Detektor wird

betrachtet und mögliche Verzerrungen durch Störeinflüsse werden analysiert. Die hyperspektrale Bildgebung erfordert einige spezifische Korrekturschritte der Bilddaten wie die bandspezifische Flachfeldkorrektur zum Ausgleich von Vignettierungseffekten sowie die Anwendung einer Korrekturmatrix zur Kompensation der jeweiligen Transmissionskurven der Fabry-Pérot Filter. Bei der Analyse der Wellenlängensensitivitäten einzelner Bänder wird deutlich, dass auch nach der Korrektur verschiedene Wellenlängenbereiche zum Signal beitragen können. Die Anwendung der Korrekturmatrix sorgt sogar dafür, dass bei Einsatz eines Kurzpass-Vorfilters vereinzelt negative Sensitivitäten bei bestimmten Bändern auftreten.

Um die Funktionsfähigkeit der Hyperspektralkamera zu validieren, wird in Kapitel 5 zudem das Kamera-Signal bei monochromatischem Licht betrachtet und mit der Messung durch ein Spektrometer verglichen. Da das Spektrometer bezüglich der Lichtintensität unkalibrierte Rohdaten liefert, kann hierbei nur ein qualitativer Vergleich erfolgen. Die Zentralwellenlängen der Lichtstimuli können aber bestimmt werden, indem die Messdaten des Spektrometers mit Hilfe eines Fits durch die gauß'sche Dichtefunktion angenähert werden. Die Wellenlänge des monochromatischen Lichts kann durch die Messdaten der Kamera je nach Wellenlänge präzise, unpräzise oder nur sehr ungenau ermittelt werden. Somit wird deutlich, dass die Hyperspektralkamera für die analytische Betrachtung physikalischer und chemischer Prozesse nur eingeschränkt einsetzbar ist. Den Einsatzzweck der Qualitätssicherung muss dies aber nicht einschränken.

Kapitel 6 beschreibt die Integration der Hyperspektralkamera in eine LPBF-Laboranlage und die Erhebung von Prozessaufnahmen während der Verarbeitung der WE43 Magnesium-Legierung. Zur Vorhersage der Oberflächenrauheit  $R_z$  werden Bildaufnahmen bei drei verschiedenen Prozessparametern erfasst und ein Convolutional Neural Network auf die Verarbeitung hyperspektraler Bilddaten ausgelegt. Durch das CNN können die Parametersätze deutlich erkannt und die Oberflächenrauheit je nach Parametersatz in einem gewissen Fehlerbereich vorhergesagt werden. Die mittlere absolute Abweichung über den Gesamtdatensatz beträgt  $14,3 \mu\text{m}$  während der mittlere absolute Fehler der CNN-Vorhersage bei  $4,1 \mu\text{m}$  liegt. In Kapitel 7 wird die Implementierung eines Akquise-Systems beschrieben, das auf einem Field Programmable Gate Array beruht und die orts aufgelöste Erhebung von Prozessaufnahmen ermöglicht. Das Akquise-System schreibt die auf dem XY2-100-E Protokoll beruhenden Steuerbefehle des Galvanometer-Scanners mit und erlaubt so die zeitliche Verknüpfung von Maschinen- und Kameradaten. Die Infrastruktur des Akquise-Systems umfasst eine Platine, die als elektrische Schnittstelle fungiert sowie eine Benutzeroberfläche zur Steuerung der Datenerhebung. So können orts aufgelöste Prozessaufnahmen von Prozessfehlern erfasst werden, die in Form von Eisenspänen künstlich in das Pulverbett der Magnesium-Legierung eingebracht werden.

Um Prozessfehler anhand von hyperspektralen Prozessaufnahmen vorhersagen zu können, wird das in Kapitel 6 eingesetzte CNN auf die binäre Klassifikation der Bilddaten ausgelegt. Wie in der Anomalie-Detektion üblich stehen für das Training des CNN deutlich weniger Aufnahmen von Fehlern als vom einwandfreien Prozess zur Verfügung, weshalb die Kostenfunktion falsch klassifizierte Fehleraufnahmen im Trainingsprozess entsprechend höher gewichtet. Zur Konvergenz der Kostenfunktion wird die Lernrate während des Trainingsprozesses manuell verringert und für eine höhere Klassifizierungsgenauigkeit die Entscheidungsschwelle der binären Klassifizierung anhand einer Genauigkeit-Sensitivitäts-Kurve angepasst. Bei der Klassifi-

zierung von 1912 Aufnahmen aus dem Testdatensatz erreicht das CNN ein F-Maß von 91 %. Die künstlich eingebrachten Prozessfehler können somit mit relativ hoher Zuverlässigkeit erkannt werden. Der Vergleich mit der Literatur bestätigt die Wettbewerbsfähigkeit der eingesetzten Technologie, denn die höchsten mit anderen Sensoren erreichten F-Maße zur Erkennung von Prozessfehlern liegen bei 95 % [Mon18] bzw. 97 % [Yaz20].

Die Arbeitshypothese dieser Arbeit kann somit bestätigt werden – durch die hyperspektrale Bildgebung werden qualitätsrelevante Prozessinformationen erfasst. Die Spektralcharakterisierung der Flächen-Hyperspektralkamera zeigt zwar, dass das Spektrum des erfassten Lichts nur verzerrt bestimmt werden kann, sodass analytische Verwertungen der Messergebnisse erschwert werden. Dennoch können durch Methoden des maschinellen Lernens Merkmale aus den Aufnahmen extrahiert werden, die auf Prozessfehler und eine bestimmte Oberflächenrauheit hindeuten. Bei der Bewertung dieser Ergebnisse sollte bedacht werden, dass für die Versuche ein Objektiv mit hoher Vergrößerung eingesetzt wird, sodass nur ein kleiner Teil des Pulverbetts erfasst wird. Aufgrund des kleinen Laserspots der Laboranlage werden geringere (75 mm/s) als im industriellen Prozessumfeld übliche Vorschubgeschwindigkeiten verwendet. Außerdem erfordert die durch Vor- und Fabry-Pérot Filter bedingte geringe Lichtempfindlichkeit der Hyperspektralkamera relativ hohe Belichtungszeiten (4 ms), wobei der eingeschränkte Dynamikbereich dafür sorgt, dass nur aus bestimmten Teilen der Laser-Interaktions-Zone Informationen erfasst werden. Alles in allem unterstreichen die Ergebnisse dieser Arbeit aber den Nutzen hyperspektraler Bildgebung zur Adressierung der teils mangelhaften Reproduzierbarkeit des LPBF-Verfahrens. Die Erkennung von Prozessfehlern sowie Vorhersage von Bauteileigenschaften machen den Additiv-Prozess wirtschaftlicher und können in Zukunft dessen industriellen Einsatz fördern.

## 8.2 Ausblick

Die Ergebnisse dieser Arbeit sind in hohem Maße mit den Eigenschaften der zur Verfügung stehenden Flächen-Hyperspektralkamera verknüpft. Eine Weiterentwicklung der Sensorik hinsichtlich spektralem Empfindlichkeitsbereich, Dynamikumfang, Bildrate sowie räumlichem und spektralem Auflösungsvermögen wird auch die Möglichkeiten einer Prozessüberwachung entscheidend erweitern. Für den Einsatz hyperspektraler Prozessüberwachung im industriellen Umfeld bietet sich zudem eine koaxiale Integration der Kamera an. Je nach optischem System entstehen dabei zwar chromatische Aberrationen, die das Messsignal potentiell verzerren, aber die Überwachung des gesamten Pulverbetts wird so möglich. Neben der Erkennung von Pulververunreinigungen könnten so auch weitere Prozessfehler wie Risse, Poren oder Gefügeunregelmäßigkeiten detektiert werden. Insofern werden zukünftig zur Weiterentwicklung der hyperspektralen Prozessüberwachung optische Systeme nötig, die bspw. durch Vorfokussierung ohne F-Theta Linse auskommen und durch entsprechende Optik-Beschichtungen die Übermittlung breiter Wellenlängenbereiche zur Detektoroberfläche ermöglichen.

Der hohe Datendurchsatz innovativer Sensorik stellt zukünftig erhöhte Anforderungen an das Datenmanagement dar, zumal die Prozessdaten möglichst in Echtzeit ausgewertet werden sollen. Dementsprechend wird es wichtig, zu untersuchen, welche Merkmale das Convolutional Neural Network zur Klassifizierung der Prozessauf-

nahmen hoch gewichtet. Dies ist bisher nur bedingt möglich. So könnte die Datenerfassung auf diese Merkmale beschränkt und somit der Datenfluss reduziert werden. Dabei ist auch zu untersuchen, inwiefern die wesentlichen Qualitätsinformationen durch die spektrale Auflösungsfähigkeit bereitgestellt werden, oder ggf. mit konventionellen Kameras gleichwertige Ergebnisse erzielt werden können.

Die Reduzierung der zu verarbeitenden Datenmengen würde auch die Weiterentwicklung der Prozessüberwachung zu einem Regelsystems vereinfachen. Dabei müsste nicht nur die Klassifizierung der Prozessdaten, sondern auch die Anpassung der Stellgrößen im laufenden Betrieb in Echtzeit erfolgen.

# Abbildungsverzeichnis

2.1	Prinzipskizze einer LPBF-Anlage. . . . .	3
2.2	Querschliffe von Proben der Mg-Legierung WE43. . . . .	7
2.3	Grundlage der Prozessüberwachung: Störgrößen, die die Bauteileigenschaften beeinflussen, sollen möglichst von der Sensorik erkannt werden. . . . .	8
2.4	Prozessüberwachung im LPBF-Prozess. . . . .	9
2.5	Das Planck'sche Strahlungsgesetz und das daraus abgeleitete Wien'sche Verschiebungsgesetz berechnet nach Gleichung 2.1. . . . .	11
2.6	Vergleich der spektralen Ausstrahlung eines idealen, grauen und realen Strahlers berechnet nach Gleichungen 2.1 und 2.4. . . . .	12
2.7	Prinzip von Flächen-Hyperspektralkameras mit durch Fabry-Pérot Filter beschichtetem CMOS-Sensor. Diese erreichen wellenlängenabhängige Transmission durch Vielstrahlinterferenz [Dem13]. . . . .	14
2.8	Transmissivität eines Fabry-Pérot Interferometers in Abhängigkeit der Wellenlänge für unterschiedliche Reflexionskoeffizienten bei gegebener Länge des Interferometers und wellenlängenunabhängigem Brechungsindex [Dem13]. . . . .	15
2.9	Unterbegriffe der Künstlichen Intelligenz und wann sie ungefähr Gegenstand wissenschaftlicher Forschung wurden [Wit19]. . . . .	16
2.10	Struktur eines Künstlichen Neuronalen Netzwerks. Die Aktivierungsfunktionen bestimmter Perzeptronen sind hervorgehoben. Sie hängen sowohl vom jeweiligen Eingabewert als auch der jeweiligen Gewichtung ab. . . . .	18
2.11	Lernkurven eines Neuronalen Netzes zur binären Klassifizierung nach [Cho18]. . . . .	19
2.12	Faltungsoperation eines Convolutional Neural Networks: die Faltungsmatrizen werden über das Eingangsbild bewegt und dabei elementweise mit den Pixelwerten multipliziert. Die Summe wird an die Aktivierungsfunktion weitergegeben, deren Ausgangswert in der Feature Map abgelegt wird. . . . .	20
2.13	Topologie eines Convolutional Neural Networks. . . . .	21
2.14	Überblick über Studien zum maschinellen Lernen in der additiven Metallfertigung. . . . .	23
3.1	Lösungsplan zur orts aufgelösten Erkennung von Fertigungsdefekten. . . . .	28
4.1	Interne Struktur der Hyperspektralkamera: Die Beschichtung durch Fabry-Pérot Interferometer ermöglicht pixelgenaue Wellenlängenselektivität . . . . .	29

4.2	Versuchsaufbau für Messungen am Schwarzstrahler. . . . .	31
4.3	Aufnahmen des Schwarzstrahlers bei 1100 °C bei einem 60 * 60 Pixel großen Ausschnitt. (a) zeigt das Rohbild mit Grauwerten von 0 – 255 und (b) die relative Standardabweichung der Grauwerte in Prozent über 60.000 Aufnahmen. . . . .	32
4.4	Versuchsaufbau für Punktschweißungen an Edelstahlsubstraten. . . .	33
4.5	Aufnahmen von Punktschweißungen auf Edelstahlsubstraten. (a) zeigt das Rohbild der 700. Aufnahme einer Messreihe und (b) die relative Standardabweichung in jedem Pixel über alle 700. Aufnahmen der 30 Messreihen. . . . .	33
4.6	Absolute sowie relative Standardabweichung der Grauwerte mit Vergrößerung des relevanten Bereichs sowie Angabe der Pixelwerte. . . .	34
4.7	Intensitätsverteilungen eines bestimmten Mosaiks für alle 700. Aufnahmen der 30 Messreihen. Die rote Linie zeigt den Durchschnitt sowie die Standardabweichung als Fehlerbalken. . . . .	35
4.8	Durchschnittliche Intensitätsverteilungen eines bestimmten Mosaiks zu unterschiedlichen Zeitpunkten der Punktschmelzung. Die Fehlerbalken zeigen die Standardabweichung über 30 Aufnahmen. . . . .	35
5.1	Vergleich der beiden Objektive: die oberen Abbildungen entsprechen dem Standard-Objektiv mit variablem Arbeitsabstand. Die unteren Abbildungen zeigen analog das Objektiv zur Beobachtung des LPBF-Prozess mit 1-facher Vergrößerung und festem Arbeitsabstand. . . . .	39
5.2	Weg des Lichts, das durch verschiedene optische Komponenten auf dem Weg zum Sensor beeinflusst wird. . . . .	40
5.3	Korrekturschritte, die aus einem Rohbild ein Nutzbild erzeugen. . . .	40
5.4	Zerlegung der Mosaik in einen Spektralvektor. . . . .	41
5.5	Das Rohbild und dessen Volumendarstellung verdeutlichen den durch das Objektiv bedingten Vignettierungseffekt. . . . .	42
5.6	Veranschaulichung der bandspezifischen Flachfeldkorrektur: a) und b) zeigen für Band 1 und 14 jeweils die Rohbilder wohingegen c) und d) die entsprechenden Korrekturfaktoren darstellen. . . . .	42
5.7	Volumendarstellung des hinsichtlich des Vignettierungseffektes korrigierten Hyperspektralbildes. . . . .	43
5.8	Sensorantwort aller Filterelemente unter Einwirkung von monochromatischem Licht. . . . .	44
5.9	Einfluss der Passfilter auf die Sensitivitäten der einzelnen Bänder. . .	45
5.10	Relative Sensitivitäten der virtuellen Bänder infolge der Korrektur der Rohdaten durch Korrekturmatrix. . . . .	46
5.11	Versuchsaufbau zur Spektralcharakterisierung der Hyperspektralkamera. . . . .	48
5.12	Zeichnung des Versuchsaufbaus (Angaben in Millimetern). . . . .	49
5.13	Mit dem Spektrometer gemessene Spektralverteilungen der mit dem Monochromator erzeugten Stimuli. . . . .	49
5.14	Spektrometer-Sensorantworten auf vier verschiedene Einstellungen des Monochromators. Mit Hilfe der Dichtefunktion kann jeweils ein Fit zur Bestimmung der zentralen Wellenlänge sowie der Halbwertsbreite erzeugt werden. . . . .	50

5.15	Programmablaufplan der Datenakquise und -nachbearbeitung. . . . .	52
5.16	Struktur einer bei der Datenakquise erstellten Pickle-Datei. . . . .	53
5.17	Beispielhafte Kamerasignale bei unterschiedlichen Wellenlängen und bei Einsatz des Short-Pass Filters. Für a), c) und e) entsprechen die untersuchten Wellenlängen den Sensitivitäts-Maxima von virtuellen Bändern der Kamera. Die restlichen Wellenlängen liegen abseits der virtuellen Bänder. Die Aussagequalitäten variieren zum Teil stark. . . . .	55
6.1	LPBF-Laboranlage mit Off-Axis Kamera Integration. . . . .	60
6.2	Prozesskarte für WE43 aus [Gie15]. . . . .	61
6.3	REM-Aufnahmen des WE43-Pulverwerkstoffes bei verschiedenen Vergrößerungen. Die Partikel sind überwiegend sphärisch; es gibt einen gewissen Feinanteil. Die Aufnahmen sind am Institut für Werkstoffkunde der Leibniz Universität Hannover entstanden. . . . .	62
6.4	Schema der Datenaufnahme und -weiterverarbeitung während des LPBF-Prozesses und danach. . . . .	63
6.5	Beispiel einer Aufnahme während des Laserschmelzens von WE43-Pulver. Die 100 x 100 Bilder werden in 20 x 20 Bilder mit 25 Kanälen konvertiert. . . . .	64
6.6	Vergleich der Aufnahmen bei einer Belichtungszeit von 4 ms und identischen Laserparametern (50 W; 75 mm/s) (a) beim LPBF-Prozess mit WE43-Pulver und (b) bei Blindschweißungen ohne Pulver auf AZ31-Substrat. . . . .	66
6.7	Bild einer WE43-Probe, die mit dem Konfokalmikroskop aufgenommen wird. Die Rauheit $R_z$ wird an fünf verschiedenen Messstrecken bestimmt. . . . .	67
6.8	Veranschaulichung des Hyperparameter-Tunings: Je dunkler die Verbindungslinie, desto geringer ist die von der entsprechenden Netzwerktopologie erzielte mittlere absolute Abweichung. . . . .	69
6.9	Netzwerktopologie des CNN zur Vorhersage der Oberflächenrauheit. Im Rahmen des Hyperparameter-Tunings werden die Dropout-Rate (0,4; 0,6), die Optimierungsfunktion (Adam; Nadam) sowie die Anzahl der Perzeptronen (8; 16; 32) in der letzten voll verknüpften Schicht variiert, was wiederum die Anzahl trainierbarer Parameter beeinflusst. . . . .	70
6.10	Entwicklung der Verlustfunktion (mean squared error) während des Trainings des CNN für Trainings- und Validierungsdaten. . . . .	71
7.1	Aufteilung eines Datenframe in Steuer-, Daten- und Paritätsbits gemäß XY2-100-E Protokoll. . . . .	74
7.2	Zeitlicher Zusammenhang zwischen Takt- und Synchronisationssignal sowie weiteren Kanälen des XY2-100-E Protokolls. . . . .	74
7.3	Scanfeld-Positionen des Galvanometer-Scanners. Die markierten Positionen entsprechen den Bit-Werten aus Tabelle 7.1. Es sind außerdem die Verzerrungen der idealerweise quadratischen Abbildungsebene zu erkennen. . . . .	75
7.4	Übersicht über die Struktur des Akquise-Systems sowie dessen Schnittstellen. . . . .	76

7.5	Front- und Rückansicht der elektrischen Schnittstelle. Die jeweiligen Funktionsgruppen und Anschlüsse der Platine sind gekennzeichnet.	77
7.6	Schema des gesamte Akquise-Systems inkl. grau hinterlegten Modulen im FPGA-Teil.	81
7.7	Software-Benutzeroberfläche zur Kommunikation mit FPGA und Kamera, Datenakquise und -ablage.	83
7.8	Veranschaulichung der Kommunikation zwischen Benutzerprogramm und Prozessor-Struktur.	84
7.9	Struktur der exportierbaren Pickle-Datei, die alle erhobenen Bild- und Maschinendaten enthält.	85
7.10	Veranschaulichung der Kamera-Triggerung.	86
7.11	Datenakquise und -kennzeichnung zur Detektion von Prozessfehlern.	87
7.12	Oberflächenprofil additiv gefertigter Proben. Während die linke Darstellung einen Oberflächenbereich ohne Fehler zeigt, sind rechts künstlich eingebrachte Fehler zu sehen.	88
7.13	Materialanalyse von der additiv gefertigten Probe mit Hilfe des Rasterelektronenmikroskops. Die Probe wurde mit der Magnesiumlegierung WE43 gefertigt.	88
7.14	Materialanalyse des Prozessdefekts mit Hilfe des Rasterelektronenmikroskops. Der Defekt wurde künstlich durch Einbringung eines Eisenpens erzeugt.	88
7.15	Beispiele für hyperspektrale Prozessaufnahmen bei der Verarbeitung einer WE43-Legierung.	89
7.16	Endteil des CNN zur Fehlererkennung.	90
7.17	Hyperparameter-Optimierung zur Festlegung der Netzwerktopologie. Je heller die Verbindungslinie, desto höher das von der entsprechenden Netzwerktopologie erzielte F-Maß.	92
7.18	Bei konstanter Lernrate „springt“ die Verlustfunktion ab der siebten Trainingsepoche aus einem lokalen Minimum. Bei abnehmender Lernrate nähert sie sich dem Minimum weiter an.	93
7.19	Entwicklung wesentlicher Metriken während der Trainingsphase des Convolutional Neural Networks.	94
7.20	Genauigkeit-Sensitivitäts-Kurve für Trainings- und Validierungsdaten zur Identifizierung der optimalen Entscheidungsschwelle.	95
A.1	Relative Sensitivitäten der virtuellen Bänder laut Herstellerangaben (blau) und nach Berechnung (orange) aus Sensorantwort, Short-Pass Filter und Korrekturmatrix.	120
A.2	Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 600 bis 663 nm.	121
A.3	Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 670 bis 750 nm.	122
A.4	Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 751 bis 831 nm.	123

A.5 Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 842 bis 875 nm. . . . . 124

A.6 Korrigierte und normierte Kameraspektren (blau) bei verschiedenen Wellenlängen verglichen mit Fit der Spektrometer-Messung (rot) bei Einsatz des Short-Pass Filters. Zentrallwellenlängen von 600 bis 700 nm. . . . . 125

A.7 Korrigierte und normierte Kameraspektren (blau) bei verschiedenen Wellenlängen verglichen mit Fit der Spektrometer-Messung (rot) bei Einsatz des Short-Pass Filters. Zentrallwellenlängen von 710 bis 831 nm. . . . . 126

A.8 Korrigierte und normierte Kameraspektren (blau) bei verschiedenen Wellenlängen verglichen mit Fit der Spektrometer-Messung (rot) bei Einsatz des Short-Pass Filters. Zentrallwellenlängen von 842 bis 875 nm. . . . . 127



# Tabellenverzeichnis

2.1	Typische Prozessfehler und ihre Ursachen im LPBF-Verfahren . . . . .	6
2.2	Sensoren und Verfahren zur Prozessüberwachung im LPBF-Verfahren	10
2.3	Studien zur Erkennung von Prozessfehlern beim Laser Powder Bed Fusion . . . . .	25
4.1	Spezifikationen der Flächen-Hyperspektralkamera. . . . .	30
4.2	Spezifikationen des mitgelieferten Standard-Objektivs. . . . .	31
4.3	Reproduzierbarkeit der Messergebnisse am Schwarzstrahler. . . . .	32
5.1	Spezifikationen des auf den Prozess ausgelegten Objektivs. . . . .	38
5.2	Filterindizes innerhalb eines Mosaiks und zugehörige Zentralwellenlängen maximaler Sensitivität. . . . .	44
5.3	Zentralwellenlängen der virtuellen Bänder nach Anwendung der Korrekturmatriizen für Short-Pass (SP) und Long-Pass (LP) Filter. . . . .	46
5.4	Eingestellte zentrale Wellenlängen zur Untersuchung des Kamera-Signals bei Einsatz des Short-Pass Filters. . . . .	54
6.1	Eckdaten der LPBF-Laboranlage zur Verarbeitung der Magnesiumlegierung WE43. . . . .	60
6.2	Magnesiumlegierung WE43: Eigenschaften des für die Untersuchungen verwendeten Pulverwerkstoffs. . . . .	62
6.3	Übersicht über Aufnahmen der Hyperspektralkamera beim Laserschmelzen von WE43-Pulver bei verschiedenen Belichtungszeiten. . . . .	65
6.4	Übersicht über die gemessenen Oberflächenrauheiten aller Proben bei drei unterschiedlichen Parametersätzen. . . . .	68
6.5	Vorhersagegenauigkeit verschiedener Netzwerktopologien, mit jeweils unterschiedlicher Anzahl an Perzeptronen im Dense-Layer, Dropout-Rate sowie Optimierungsalgorithmus. Die Netzwerke werden jeweils für 10 Epochen trainiert. . . . .	69
6.6	Vorhersagegenauigkeit des Convolutional Neural Networks bei den verschiedenen Parametersätzen verglichen mit der jeweiligen Streuung innerhalb eines Parametersatzes. . . . .	71
7.1	Positionen des Laserspot gemäß XY2-100 Protokoll. . . . .	75
7.2	Elektrische Kontakte der DB-25 Steckverbindung gemäß XY2-100-E Spezifikation. . . . .	78
7.3	Ein- und Ausgangskontakte der Hyperspektralkamera. . . . .	79
7.4	Kontaktbelegung der Stiftleiste zur Kommunikation mit der Hyperspektralkamera. . . . .	79

---

7.5	Kontaktbelegung der Stiftleiste für die digitalen Signalausgänge. Diese werden zum synchronisierten Prozessstart verwendet. . . . .	79
7.6	Adressräume der FPGA-Module dargestellt als Hexadezimalzahlen. . . . .	81
7.7	Übersicht über den Datensatz aus insgesamt 12.750 hyperspektralen Prozessaufnahmen. Die Aufnahmen werden gemischt und anschließend in die entsprechenden Anteile für Training, Validierung und Test aufgeteilt. . . . .	89
7.8	Netzwerktopologie mit dem höchsten F-Maß bei der Klassifizierung der Validierungsdaten nach vier Trainingsepochen im Hyperparameter-Tuning. . . . .	92
7.9	F-Maß bei Trainings- und Validierungsdaten nach Training der im Hyperparameter-Tuning ermittelten Netzwerktopologie für 10 Epochen und angepasster Lernrate. . . . .	95
7.10	Wahrheitsmatrix ermittelt aus Testdaten, die das CNN während des Trainingsprozesses nicht gesehen hat. . . . .	96
A.1	Eigenschaften des CMOS-Sensors der Flächen-Hyperspektralkamera laut Herstellerangaben. . . . .	119
A.2	Eigenschaften der Laserdiode laut Herstellerangaben. . . . .	119
A.3	Ergebnisse des Hyperparameter-Tunings zur Erkennung künstlich eingebrachter Prozessfehler. . . . .	128
A.3	Ergebnisse des Hyperparameter-Tunings zur Erkennung künstlich eingebrachter Prozessfehler. . . . .	129
A.3	Ergebnisse des Hyperparameter-Tunings zur Erkennung künstlich eingebrachter Prozessfehler. . . . .	130

# Literaturverzeichnis

- [Alb16] D. Alberts, D. Schwarze, and G. Witt. *High speed melt pool & laser power monitoring for selective laser melting (slm®)*. In *9th International Conference on Photonic Technologies LANE*, vol. 2016. 2016
- [Bad06] M. Badrossamay and T. Childs. *Layer formation studies in selective laser melting of steel powders*. In *Proc. SFF Symp., Austin, Texas, USA*, pp. 268–279. 2006
- [Ber14] F. Bernhard. *Handbuch der technischen Temperaturmessung*. Springer-Verlag, 2014
- [Beu07] Beuth-Verlag. *Schweißen und verwandte Prozesse - Einteilung von geometrischen Unregelmäßigkeiten an metallischen Werkstoffen - Teil 1: Schmelzschweißen (ISO 6520-1:2007); Dreisprachige Fassung EN ISO 6520-1:2007*, 2007. DIN EN ISO 6520-1:2007-11
- [Buc14] D. Buchbinder, W. Meiners, N. Pirch, K. Wissenbach, and J. Schrage. *Investigation on reducing distortion by preheating during manufacture of aluminum components using selective laser melting*. *Journal of Laser Applications*, vol. 26(1):p. 012004, 2014
- [Che16] B. Cheng, S. Shrestha, and Y. K. Chou. *Stress and deformation evaluations of scanning strategy effect in selective laser melting*. In *ASME 2016 11th International Manufacturing Science and Engineering Conference*, pp. V003T08A009–V003T08A009. American Society of Mechanical Engineers, 2016
- [Cho18] F. Chollet. *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. MITP-Verlags GmbH & Co. KG, 2018
- [Cli14] S. Clijsters, T. Craeghs, S. Buls, K. Kempen, and 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*, vol. 75(5-8):pp. 1089–1101, 2014
- [Cop16] M. Copeland. *What's the difference between artificial intelligence. Machine Learning, and Deep Learning*, 2016
- [Cre93] D. Crevier. *AI: the tumultuous history of the search for artificial intelligence*. Basic Books, 1993

- [Del12] J. Delgado, J. Ciurana, and C. A. Rodríguez. *Influence of process parameters on part quality and mechanical properties for dmls and slm with iron-based materials*. The International Journal of Advanced Manufacturing Technology, vol. 60(5-8):pp. 601–610, 2012
- [Dem08] W. Demtröder and I. Experimentalphysik. *Mechanik und Wärme*. Springer, 2008
- [Dem13] W. Demtröder. *Interferenz, Beugung und Streuung*, pp. 299–345. Springer Berlin Heidelberg, Berlin, Heidelberg, 2013. ISBN 978-3-642-29944-5. doi: 10.1007/978-3-642-29944-5
- [Dog18] E. Dogo, O. Afolabi, N. Nwulu, B. Twala, and C. Aigbavboa. *A comparative analysis of gradient descent-based optimization algorithms on convolutional neural networks*. In *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)*, pp. 92–99. IEEE, 2018
- [Eve16] S. K. Everton, M. Hirsch, P. Stravroulakis, R. K. Leach, and A. T. Clare. *Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing*. Materials & Design, vol. 95:pp. 431–445, 2016
- [Fer12] B. Ferrar, L. Mullen, E. Jones, R. Stamp, and C. Sutcliffe. *Gas flow effects on selective laser melting (slm) manufacturing performance*. Journal of Materials Processing Technology, vol. 212(2):pp. 355–364, 2012
- [Fos15] B. Foster, E. Reutzler, A. Nassar, B. Hall, S. Brown, and C. Dickman. *Optical, layerwise monitoring of powder bed fusion*. In *Solid Freeform Fabrication Symposium, Austin, TX, Aug*, pp. 10–12. 2015
- [Fox16] J. C. Fox, S. P. Moylan, and B. M. Lane. *Effect of process parameters on the surface roughness of overhanging structures in laser powder bed fusion additive manufacturing*. Procedia CIRP, vol. 45:pp. 131–134, 2016
- [Gai20] A. Gaikwad, B. Giera, G. M. Guss, J.-B. Forien, M. J. Matthews, and P. Rao. *Heterogeneous sensing and scientific machine learning for quality assurance in laser powder bed fusion—a single-track study*. Additive Manufacturing, vol. 36:p. 101659, 2020
- [Gar18] M. R. Gardner, A. Lewis, J. Park, A. B. McElroy, A. D. Estrada, S. Fish, J. J. Beaman Jr, and T. E. Milner. *In situ process monitoring in selective laser sintering using optical coherence tomography*. Optical Engineering, vol. 57(4):p. 041407, 2018
- [Gie13] M. Gieseke, C. Noelke, S. Kaieler, V. Wesling, and H. Haferkamp. *Selective laser melting of magnesium and magnesium alloys*. In *Magnesium Technology 2013*, pp. 65–68. Springer, 2013
- [Gie15] M. Gieseke. *Entwicklung des selektiven Laserstrahlschmelzens von Magnesium und Magnesiumlegierungen zur Herstellung von individuellen und bioresorbierbaren Implantaten*. PZH Verlag, TEWISS-Technik und Wissen GmbH, 2015

- [Gob18] C. Gobert, E. W. Reutzel, J. Petrich, A. R. Nassar, and S. Phoha. *Application of supervised machine learning for defect detection during metallic powder bed fusion additive manufacturing using high resolution imaging*. Additive Manufacturing, vol. 21:pp. 517–528, 2018
- [Gör20] H. Görg, S. Möhle, T. Petersen, H. Egger, K. Kilic, D. Marin, L. Flach, R. Aichele, M. Braml, R. Wiechers et al. *Neustart der Industrie unter dem Einfluss von COVID-19: Wie bereit ist die globale Lieferkette?* ifo Schnelldienst, vol. 73(05):pp. 03–34, 2020
- [Gra07] H. Grahn and P. Geladi. *Techniques and applications of hyperspectral image analysis*, 2007. OCLC: ocm84150890
- [Gra18] M. Grasso, A. Demir, B. Previtali, and B. Colosimo. *In situ monitoring of selective laser melting of zinc powder via infrared imaging of the process plume*. Robotics and Computer-Integrated Manufacturing, vol. 49:pp. 229–239, 2018
- [Haj21] S. H. Haji and A. M. Abdulazeez. *Comparison of optimization techniques based on gradient descent algorithm: A review*. PalArch’s Journal of Archaeology of Egypt/Egyptology, vol. 18(4):pp. 2715–2743, 2021
- [Ham20] P. K. Hamamatsu. *Cmos linear image sensor*. URL: <https://www.hamamatsu.com/resources/pdf/ssd/s13496kmpd1164e.pdf> (besucht am 01.06.2021), 2020
- [Jad19] S. Jadhav, S. Dadbakhsh, L. Goossens, J. Kruth, J. Van Humbeeck, and K. Vanmeensel. *Influence of selective laser melting process parameters on texture evolution in pure copper*. Journal of Materials Processing Technology, vol. 270:pp. 47–58, 2019
- [Kam00] C. Kammer and D. Aluminium-Zentrale. *Magnesium Taschenbuch*. Aluminium-Verlag, 2000
- [Kin14] D. P. Kingma and J. Ba. *Adam: A method for stochastic optimization*. arXiv preprint arXiv:1412.6980, 2014
- [Kle12] S. Kleszczynski, J. Zur Jacobsmühlen, J. Sehart, and G. Witt. *Error detection in laser beam melting systems by high resolution imaging*. In *Proceedings of the Solid Freeform Fabrication Symposium*, vol. 2012. 2012
- [Kle18] S. Kleszczynski. *Potenziale der bildgestützten Prozessüberwachung zur Steigerung des technologischen Reifegrades von Laser-Strahlschmelzverfahren*. Ph.D. thesis, 2018
- [Koc17] P. Kocovic. *3D printing and its impact on the production of fully functional components: emerging research and opportunities: emerging research and opportunities*. IGI Global, 2017
- [Kod81] H. Kodama. *A scheme for three-dimensional display by automatic fabrication of three-dimensional model*. IEICE Trans. on Electronics, pp. 237–241, 1981

- [Kra17] H. Krauss. *Qualitätssicherung beim Laserstrahlschmelzen durch schichtweise thermografische In-Process-Überwachung*, vol. 325. Herbert Utz Verlag, 2017
- [Kru12] J.-P. Kruth, J. Deckers, E. Yasa, and R. Wauthlé. *Assessing and comparing influencing factors of residual stresses in selective laser melting using a novel analysis method*. Proceedings of the institution of mechanical engineers, Part B: Journal of Engineering Manufacture, vol. 226(6):pp. 980–991, 2012
- [Küs11] Y. Küsters, M. Schäfer, and G. Witt. *Robuster Strahlschmelzprozess durch methodische Parameterfindung*. In *RTEjournal-Forum für Rapid Technologie*, vol. 8. 2011
- [Led19] V. N. Lednev, P. A. Sdvizhenskii, R. D. Asyutin, R. S. Tretyakov, M. Y. Grishin, A. Y. Stavertiy, and S. M. Pershin. *In situ multi-elemental analysis by laser induced breakdown spectroscopy in additive manufacturing*. additive manufacturing, vol. 25:pp. 64–70, 2019
- [Li12] R. Li, J. Liu, Y. Shi, L. Wang, and W. Jiang. *Balling behavior of stainless steel and nickel powder during selective laser melting process*. The International Journal of Advanced Manufacturing Technology, vol. 59(9-12):pp. 1025–1035, 2012
- [Lip18] R. B. Lippert. *Restriktionsgerechtes Gestalten gewichtsoptimierter Strukturbauteile für das Selektive Laserstrahlschmelzen*. TEWISS, 2018
- [Liu15] Y. Liu, Y. Yang, S. Mai, D. Wang, and C. Song. *Investigation into spatter behavior during selective laser melting of aisi 316l stainless steel powder*. Materials & Design, vol. 87:pp. 797–806, 2015
- [Lot11] P. Lott, H. Schleifenbaum, W. Meiners, K. Wissenbach, C. Hinke, and J. Bültmann. *Design of an optical system for the in situ process monitoring of selective laser melting (slm)*. Physics Procedia, vol. 12:pp. 683–690, 2011
- [Mal18] E. Malekipour and H. El-Mounayri. *Common defects and contributing parameters in powder bed fusion am process and their classification for online monitoring and control: a review*. The International Journal of Advanced Manufacturing Technology, vol. 95(1-4):pp. 527–550, 2018
- [Mei08] H. Meier and C. Haberland. *Experimental studies on selective laser melting of metallic parts*. Materialwissenschaft und Werkstofftechnik, vol. 39(9):pp. 665–670, 2008
- [Mer06] P. Mercelis and J.-P. Kruth. *Residual stresses in selective laser sintering and selective laser melting*. Rapid prototyping journal, vol. 12(5):pp. 254–265, 2006
- [Mer07] P. Mercelis, J.-P. Kruth, and J. Van Vaerenbergh. *Feedback control of selective laser melting*. In *Proceedings of the 15th International Symposium on Electromachining*, pp. 421–426. UNIV NEBRASKA-LINCOLN, 2007

- [Mon18] M. Montazeri and P. Rao. *Sensor-based build condition monitoring in laser powder bed fusion additive manufacturing process using a spectral graph theoretic approach*. Journal of Manufacturing Science and Engineering, vol. 140(9):p. 091002, 2018
- [Mon20] M. Montazeri, A. R. Nassar, A. J. Dunbar, and P. Rao. *In-process monitoring of porosity in additive manufacturing using optical emission spectroscopy*. IISE Transactions, vol. 52(5):pp. 500–515, 2020
- [Nel14] J. A. Nelson, G. Galloway, A. Rennie, T. Abram, and G. R. Bennett. *Effects of scan direction and orientation on mechanical properties of laser sintered polyamide-12*. International Journal of Advanced Design and Manufacturing Technology, vol. 7(3):pp. 19–25, 2014
- [Ng16] A. Ng. *Machine learning*. Coursera, 2016
- [Ngo18] T. D. Ngo, A. Kashani, G. Imbalzano, K. T. Nguyen, and D. Hui. *Additive manufacturing (3d printing): A review of materials, methods, applications and challenges*. Composites Part B: Engineering, vol. 143:pp. 172–196, 2018
- [Oka19] I. A. Okaro, S. Jayasinghe, C. Sutcliffe, K. Black, P. Paoletti, and P. L. Green. *Automatic fault detection for laser powder-bed fusion using semi-supervised machine learning*. Additive Manufacturing, vol. 27:pp. 42–53, 2019
- [Qi19] X. Qi, G. Chen, Y. Li, X. Cheng, and C. Li. *Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives*. Engineering, vol. 5(4):pp. 721–729, 2019
- [Ray13] *Ss-iii dokumentation of the xy2-100-e-interface*. [http://www.alaser.com.tw/db/upload/webdata4/5alaser\\_2014124225415-19318.pdf](http://www.alaser.com.tw/db/upload/webdata4/5alaser_2014124225415-19318.pdf) (besucht am 29.07.2021), 2013
- [Rud17] S. Ruder. *An overview of gradient descent optimization algorithms*. cs.LG 1609.04747, arXiv, 2017
- [Rüs14] L. Rüschendorf. *Mathematische statistik*, vol. 62. Springer, 2014
- [Sam16] W. J. Sames, F. List, S. Pannala, R. R. Dehoff, and S. S. Babu. *The metallurgy and processing science of metal additive manufacturing*. International Materials Reviews, vol. 61(5):pp. 315–360, 2016
- [Sch17] M. Schmidt, M. Merklein, D. Bourell, D. Dimitrov, T. Hausotte, K. Wegener, L. Overmeyer, F. Vollertsen, and G. N. Levy. *Laser based additive manufacturing in industry and academia*. CIRP Annals, vol. 66(2):pp. 561–583, 2017
- [Sch20] G. Schuh, T. Schröer, and D. Pause. *Schlüsselfaktoren für den industriellen Einsatz Additiver Fertigung in produzierenden Unternehmen*. ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb, vol. 115(7-8):pp. 463–466, 2020

- [Sci19] L. Scime and J. Beuth. *Using machine learning to identify in-situ melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process*. Additive Manufacturing, vol. 25:pp. 151–165, 2019
- [She19] S. A. Shevchik, G. G. Masinelli, C. Kenel, C. Leinenbach, and K. Wasmer. *Deep learning for in situ and real-time quality monitoring in additive manufacturing using acoustic emission*. IEEE Transactions on Industrial Informatics, 2019
- [Sin21] S. Sing, C. Kuo, C. Shih, C. Ho, and C. Chua. *Perspectives of using machine learning in laser powder bed fusion for metal additive manufacturing*. Virtual and Physical Prototyping, vol. 16(3):pp. 372–386, 2021
- [Spe16] T. G. Spears and S. A. Gold. *In-process sensing in selective laser melting (slm) additive manufacturing*. Integrating Materials and Manufacturing Innovation, vol. 5(1):p. 2, 2016
- [Sri14] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. *Dropout: a simple way to prevent neural networks from overfitting*. The journal of machine learning research, vol. 15(1):pp. 1929–1958, 2014
- [Swa93] E. A. Swanson, J. A. Izatt, M. R. Hee, D. Huang, C. Lin, J. Schuman, C. Puliafito, and J. G. Fujimoto. *In vivo retinal imaging by optical coherence tomography*. Optics letters, vol. 18(21):pp. 1864–1866, 1993
- [Tur50] A. Turing. *Computing machinery and intelligence*. Mind, vol. 59(236):pp. 433–460, 1950
- [Uri15] A. Uriondo, M. Esperon-Miguez, and S. Perinpanayagam. *The present and future of additive manufacturing in the aerospace sector: A review of important aspects*. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, vol. 229(11):pp. 2132–2147, 2015
- [Wan16] X. Wang, S. Xu, S. Zhou, W. Xu, M. Leary, P. Choong, M. Qian, M. Brandt, and Y. M. Xie. *Topological design and additive manufacturing of porous metals for bone scaffolds and orthopaedic implants: A review*. Biomaterials, vol. 83:pp. 127–141, 2016
- [Wan20] C. Wang, X. Tan, S. Tor, and C. Lim. *Machine learning in additive manufacturing: State-of-the-art and perspectives*. Additive Manufacturing, p. 101538, 2020
- [Who20] T. Wholers, R. Campbell, O. Diegel, R. Hutt, and J. Kowen. *Wohlers report 2020: 3d printing and additive manufacturing: Global state of the industry*, 2020
- [Wit19] V. Wittpahl. *Künstliche Intelligenz*. Springer, 2019
- [Yaz20] R. M. Yazdi, F. Imani, and H. Yang. *A hybrid deep learning model of process-build interactions in additive manufacturing*. Journal of Manufacturing Systems, vol. 57:pp. 460–468, 2020

- [Yua18] B. Yuan, G. M. Guss, A. C. Wilson, S. P. Hau-Riege, P. J. DePond, S. McMains, M. J. Matthews, and B. Giera. *Machine-learning-based monitoring of laser powder bed fusion*. *Advanced Materials Technologies*, vol. 3(12):p. 1800136, 2018
- [Zen14] G. Zenzinger, J. Bamberg, B. Henkel, T. Hess, and A. Ladewig. *Online-Prozesskontrolle bei der additiven Fertigung mittels Laserstrahlschmelzen*. *DGZfP Zeitung*, vol. 140:pp. 51–54, 2014
- [Zha16] B. Zhang, J. Ziegert, F. Farahi, and A. Davies. *In situ surface topography of laser powder bed fusion using fringe projection*. *Additive Manufacturing*, vol. 12:pp. 100–107, 2016
- [Zho20] D.-X. Zhou. *Universality of deep convolutional neural networks*. *Applied and computational harmonic analysis*, vol. 48(2):pp. 787–794, 2020



# A Anhang

## A.1 Ximea MQO22HG-IM-SM5X5-NIR

Tabelle A.1: Eigenschaften des CMOS-Sensors der Flächen-Hyperspektralkamera laut Herstellerangaben.

Spezifikation	Ximea MQO22HG-IM-SM5X5-NIR
Pixelpitch	5,5 $\mu\text{m}$
Full well capacity	12988 e-
Analoger Verstärkungsfaktor	3,2
Digitaler Verstärkungsfaktor	1
Gemessene Gesamtverstärkung	0,229426 10-Bit Grauwert/e-

## A.2 nlight element e18.1400976105

Tabelle A.2: Eigenschaften der Laserdiode laut Herstellerangaben.

Spezifikation	nlight element e18.1400976105
CW-Ausgangsleistung (in Faser)	140 W
CW-Ausgangsleistung (gemessen)	135 W
Zentrale Wellenlänge	981,6 nm
FWHM	4,4 nm
Faserkerndurchm.	105 $\mu\text{m}$
Faserhüllendurchm.	125 $\mu\text{m}$
Faser NA	0,22 NA

## A.3 Spektrale Charakterisierung der Kamera

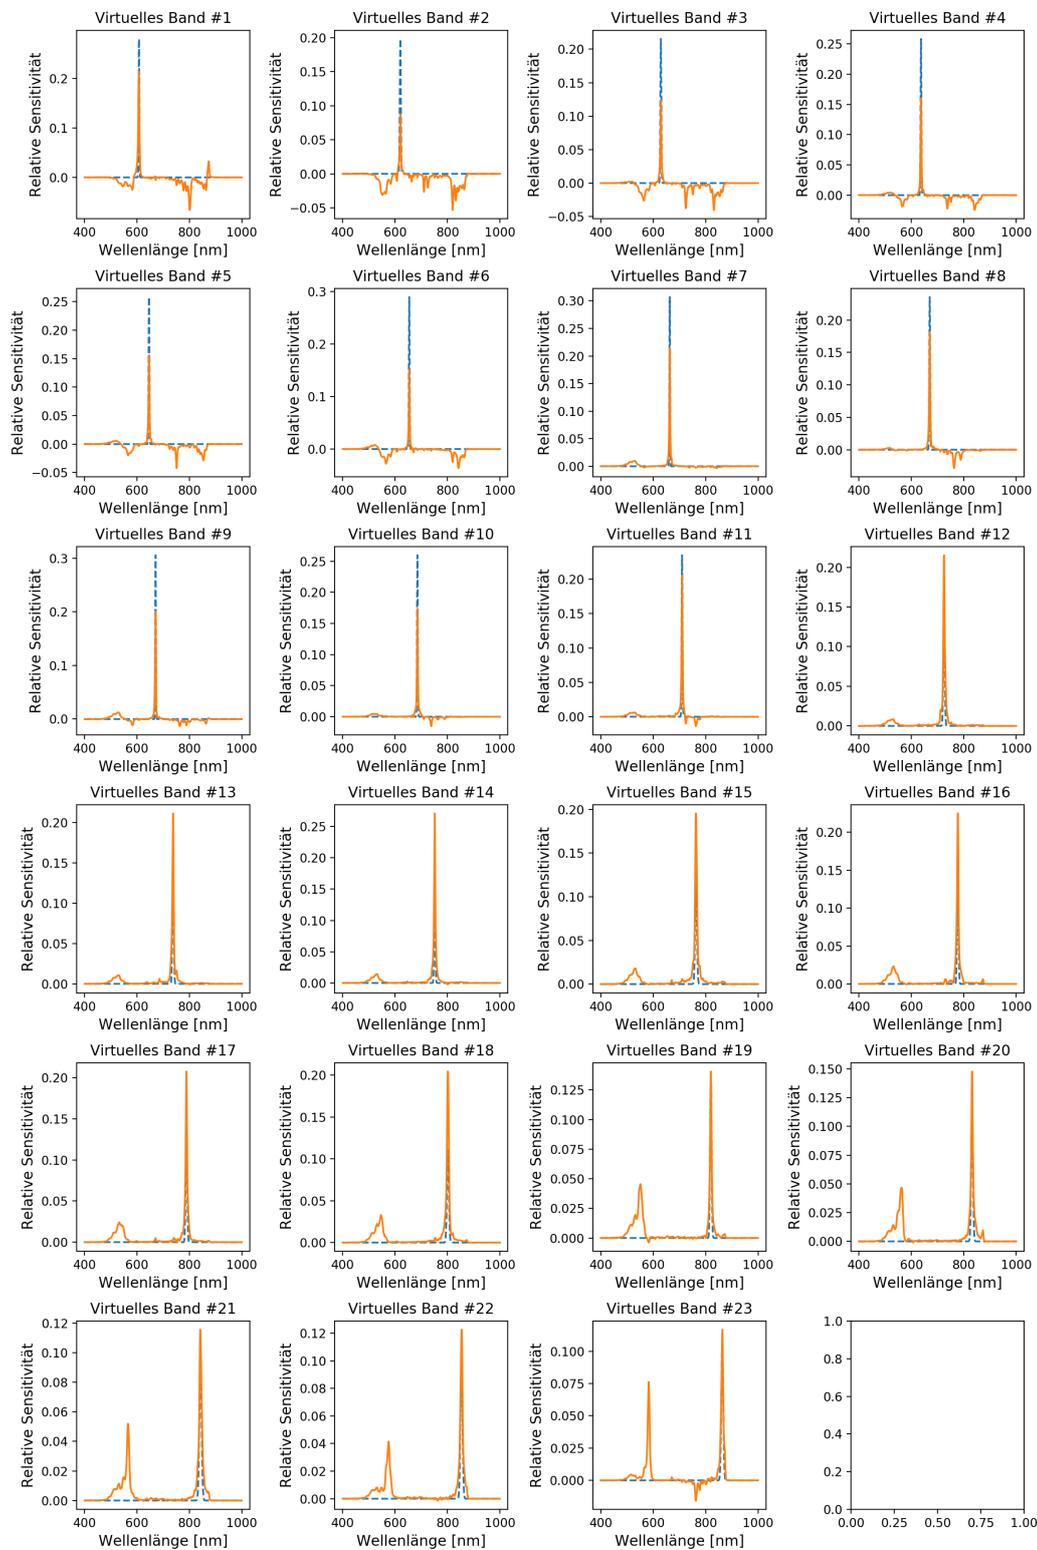


Abbildung A.1: Relative Sensitivitäten der virtuellen Bänder laut Herstellerangaben (blau) und nach Berechnung (orange) aus Sensorantwort, Short-Pass Filter und Korrekturmatrix.

### A.3. SPEKTRALE CHARAKTERISIERUNG DER KAMERA

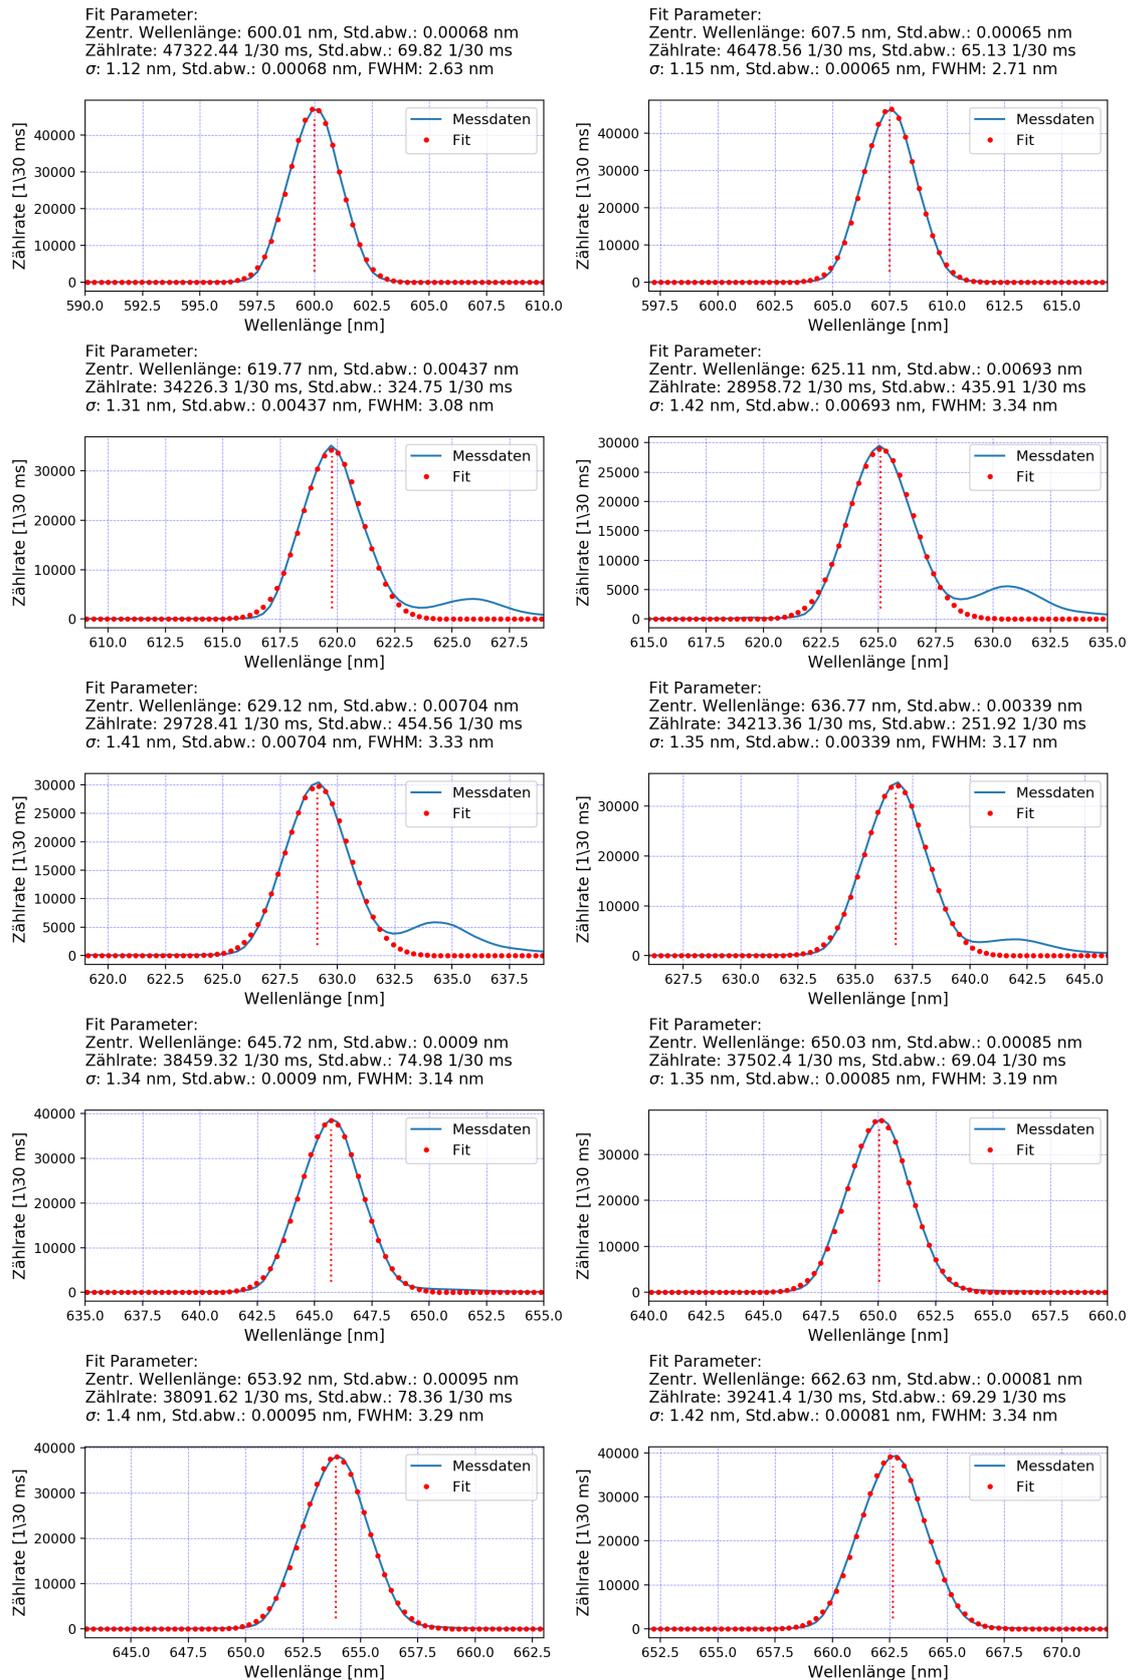


Abbildung A.2: Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 600 bis 663 nm.

### A.3. SPEKTRALE CHARAKTERISIERUNG DER KAMERA

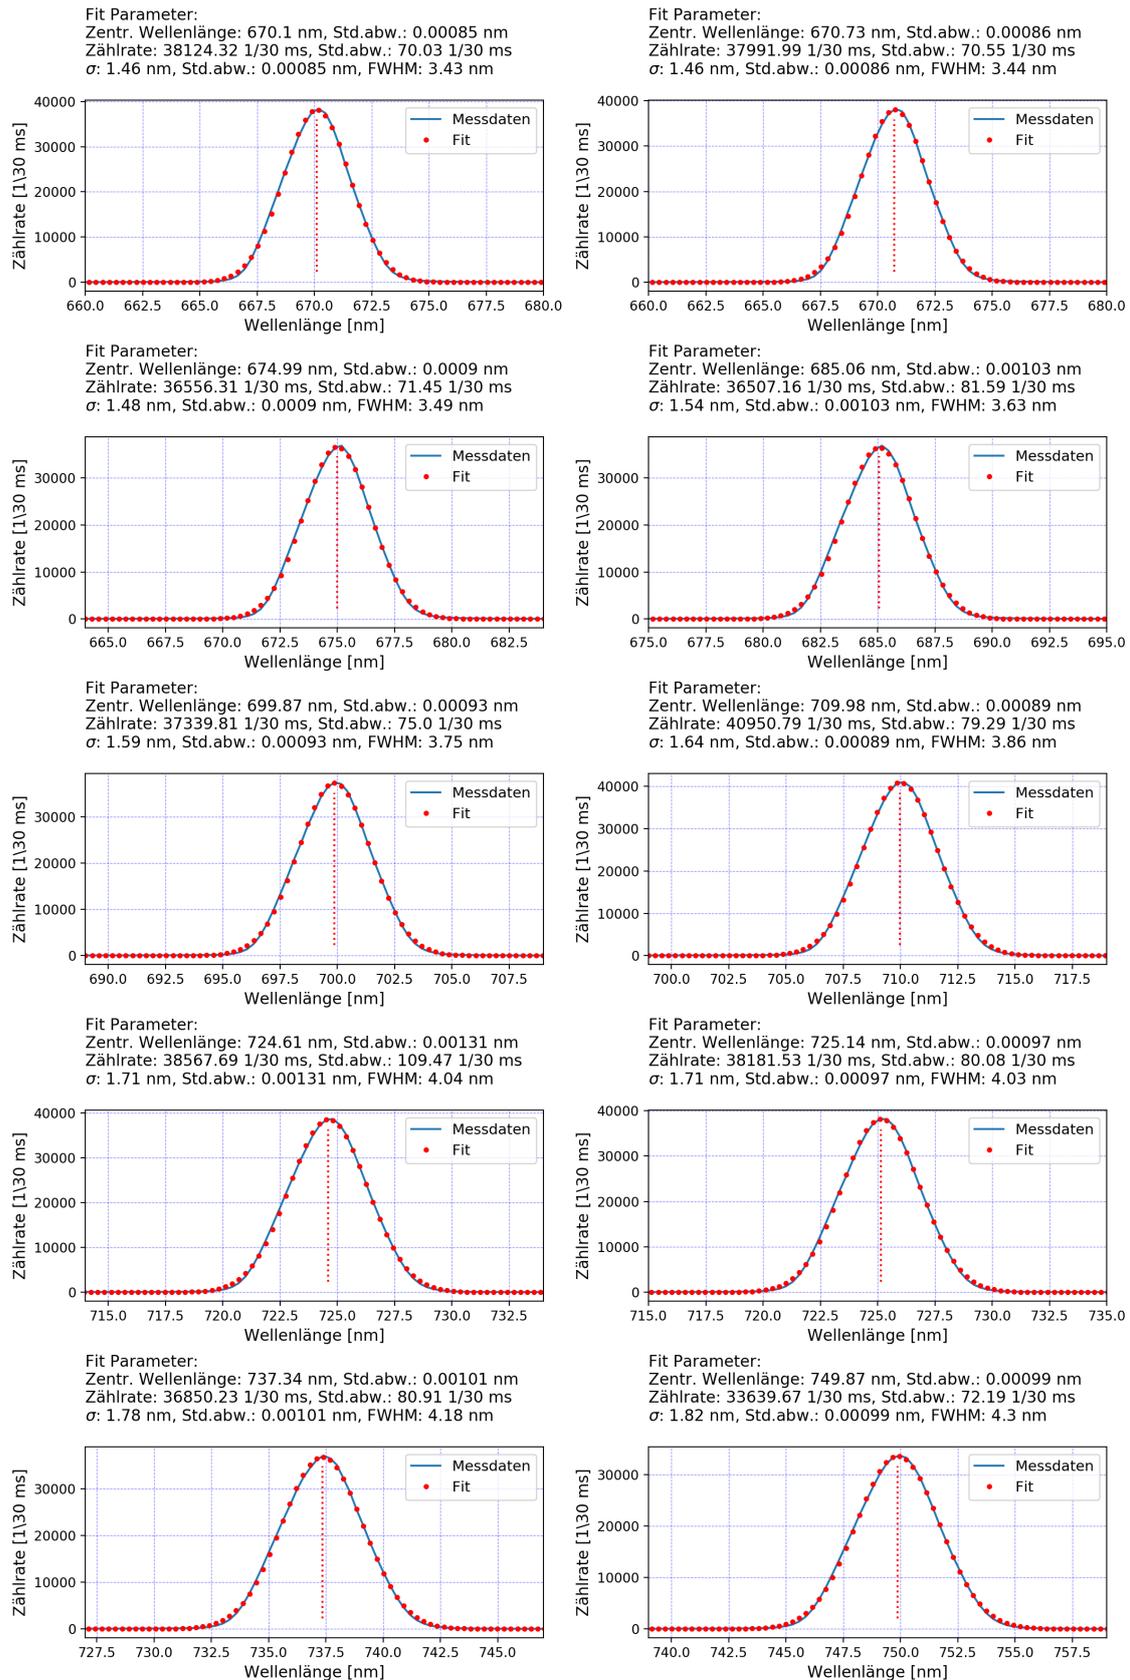


Abbildung A.3: Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 670 bis 750 nm.

### A.3. SPEKTRALE CHARAKTERISIERUNG DER KAMERA

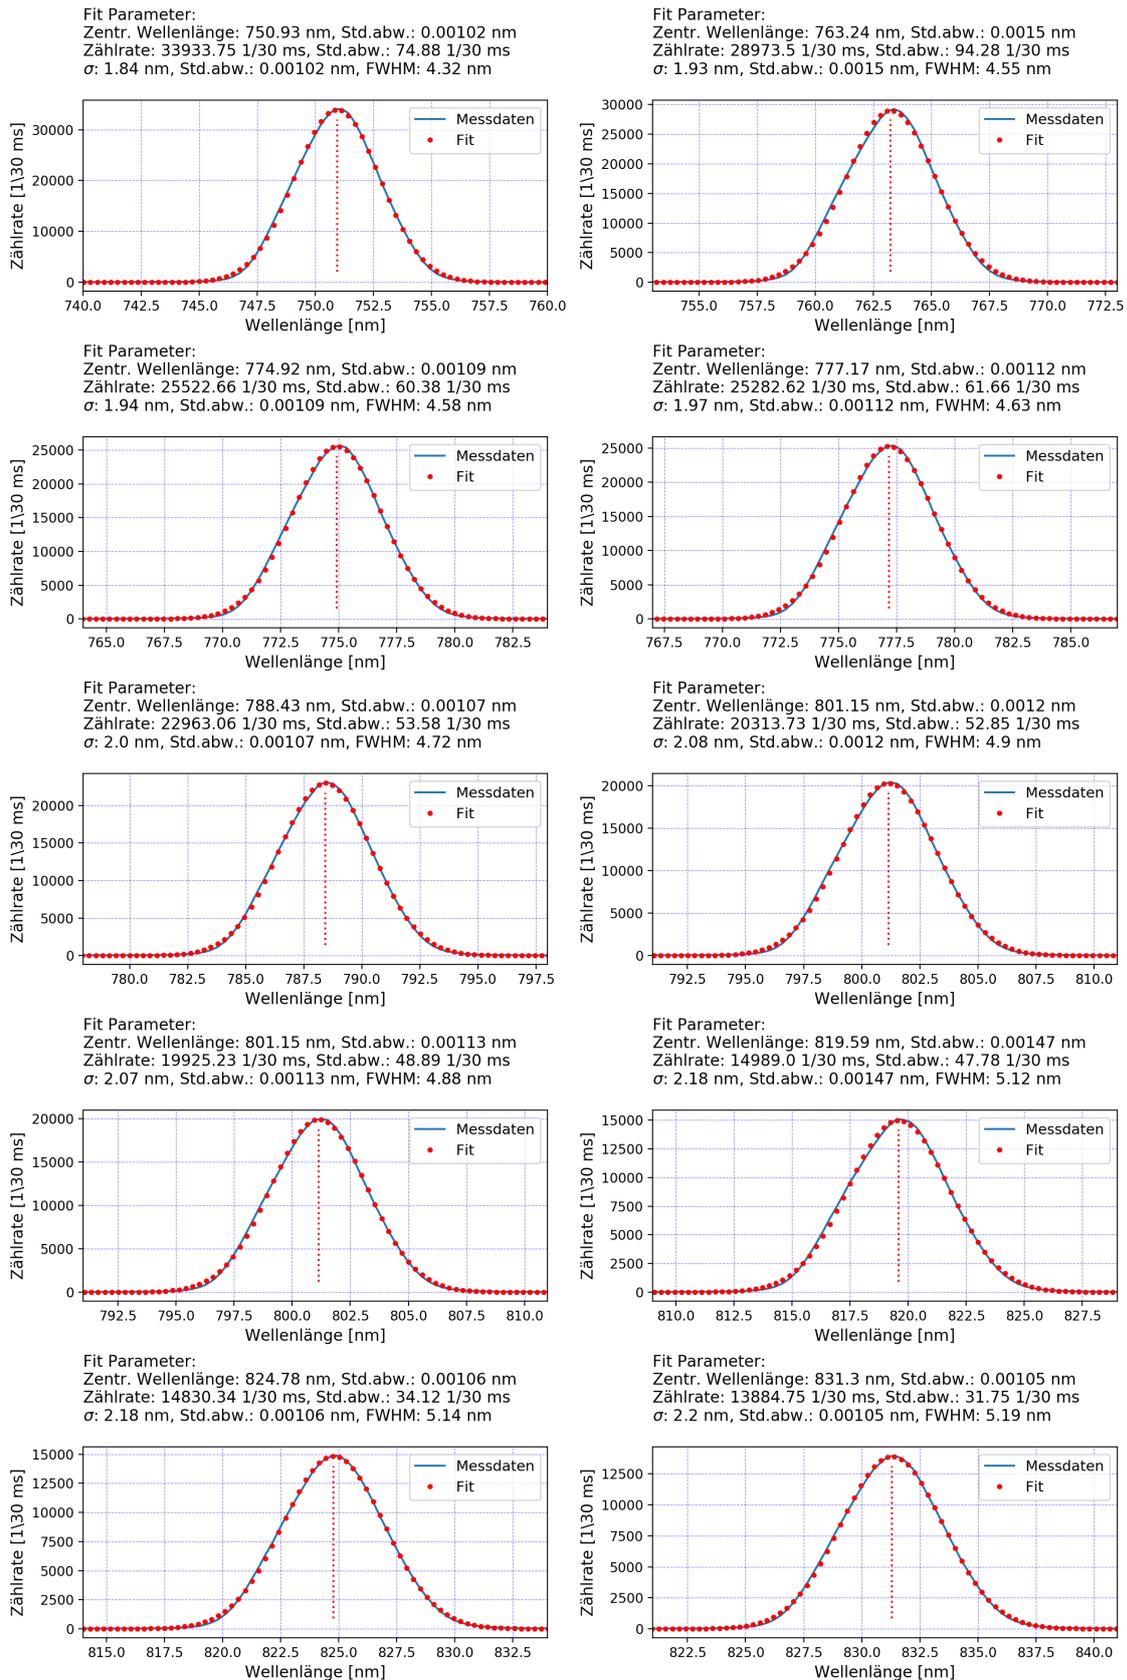


Abbildung A.4: Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 751 bis 831 nm.

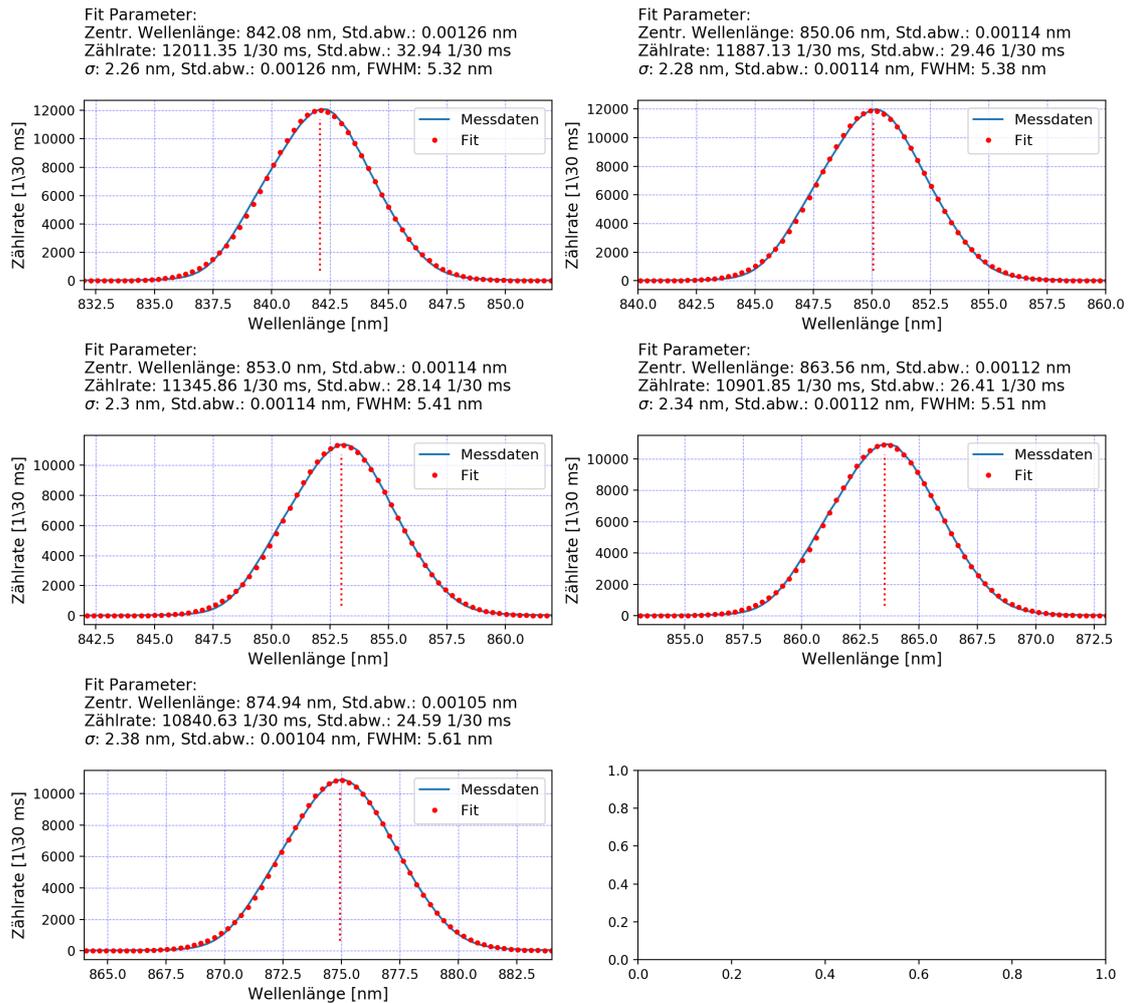


Abbildung A.5: Messdaten (blau) sowie Fit (rot) der Spektrometer-Messung bei den zur Untersuchung der Kameraspektren eingesetzten Wellenlängen. Zentralwellenlängen von 842 bis 875 nm.

### A.3. SPEKTRALE CHARAKTERISIERUNG DER KAMERA

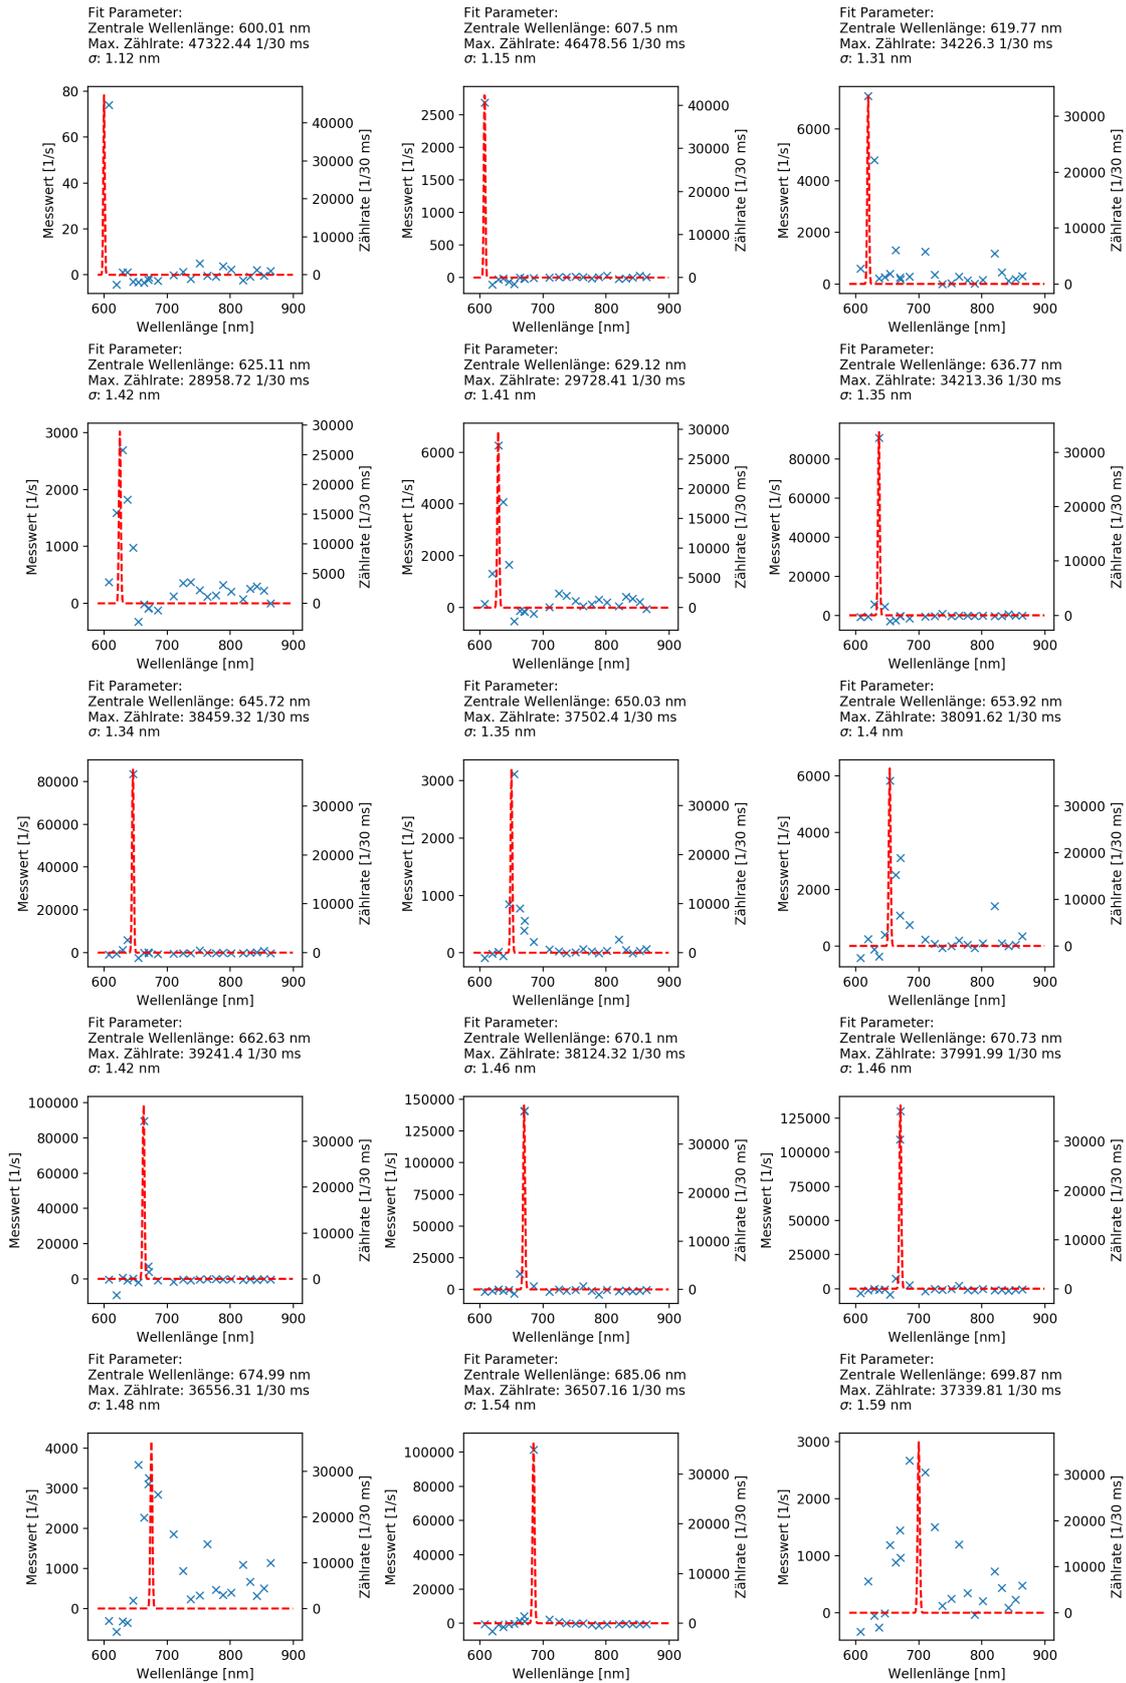


Abbildung A.6: Korrigierte und normierte Kameraspektren (blau) bei verschiedenen Wellenlängen verglichen mit Fit der Spektrometer-Messung (rot) bei Einsatz des Short-Pass Filters. Zentrallwellenlängen von 600 bis 700 nm.

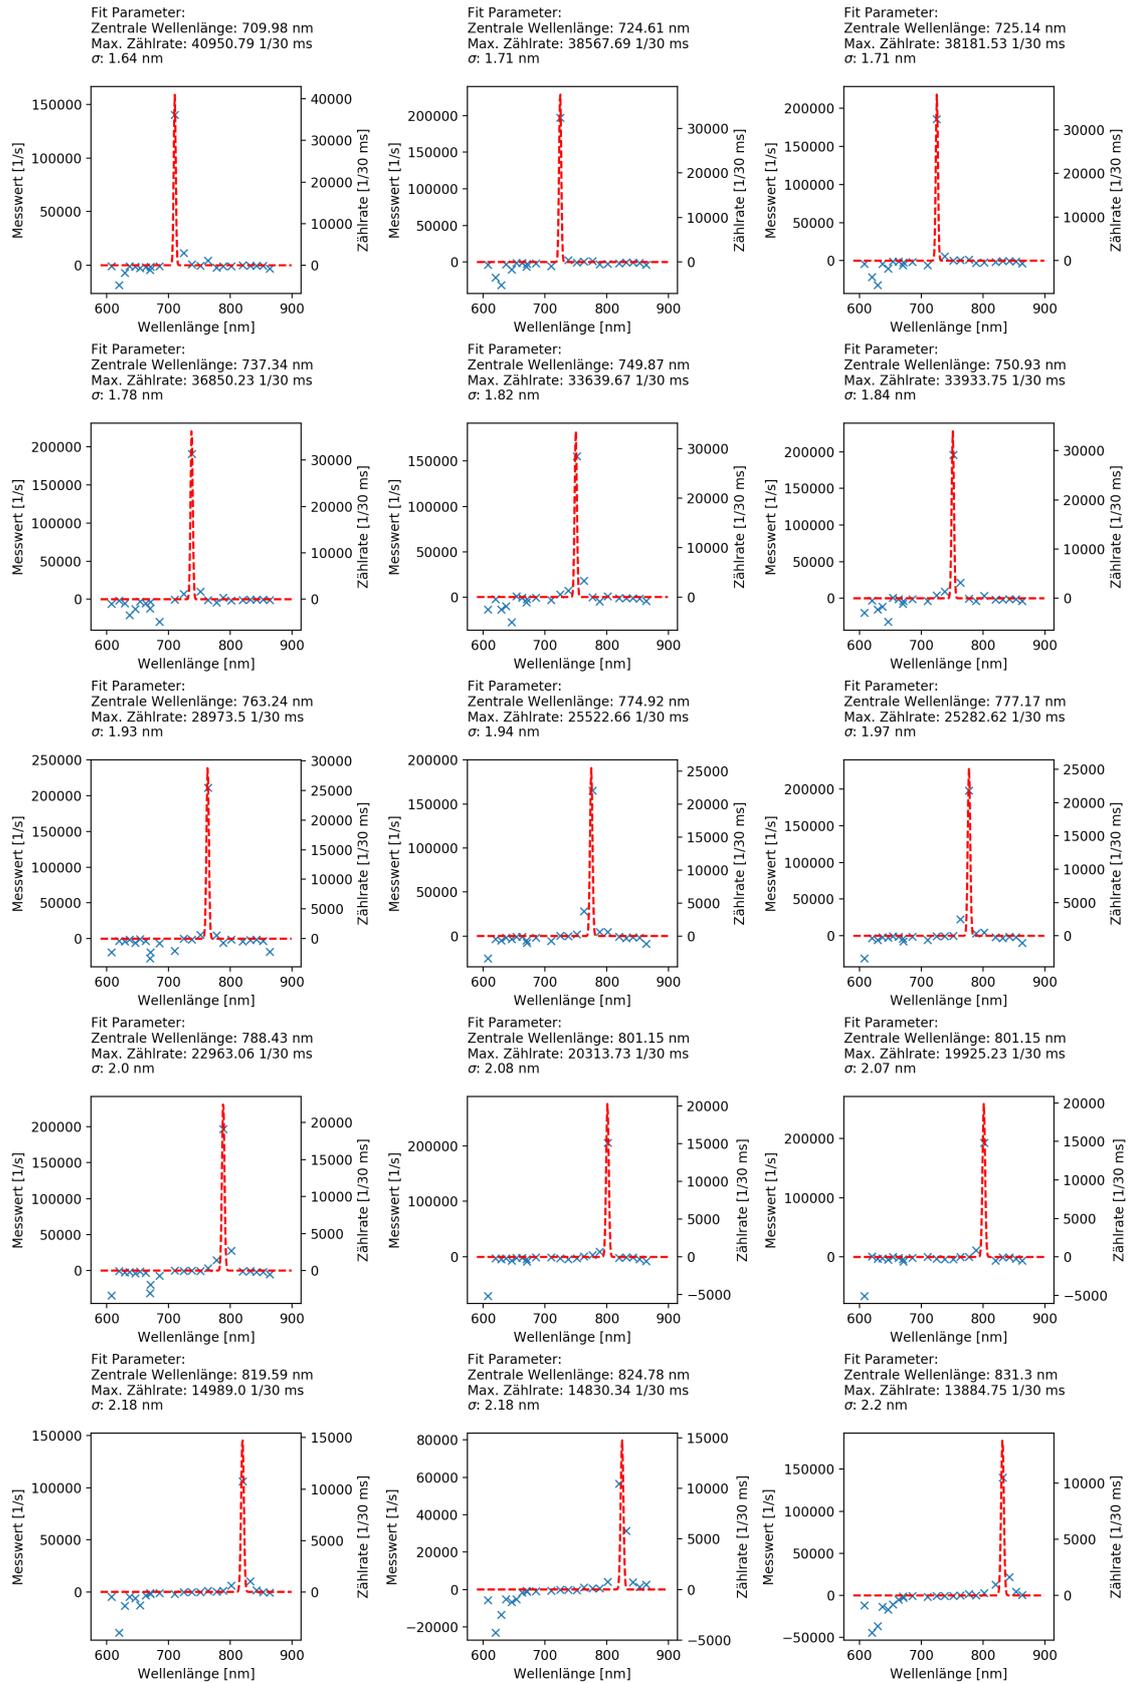


Abbildung A.7: Korrigierte und normierte Kameraspektren (blau) bei verschiedenen Wellenlängen verglichen mit Fit der Spektrometer-Messung (rot) bei Einsatz des Short-Pass Filters. Zentrallwellenlängen von 710 bis 831 nm.

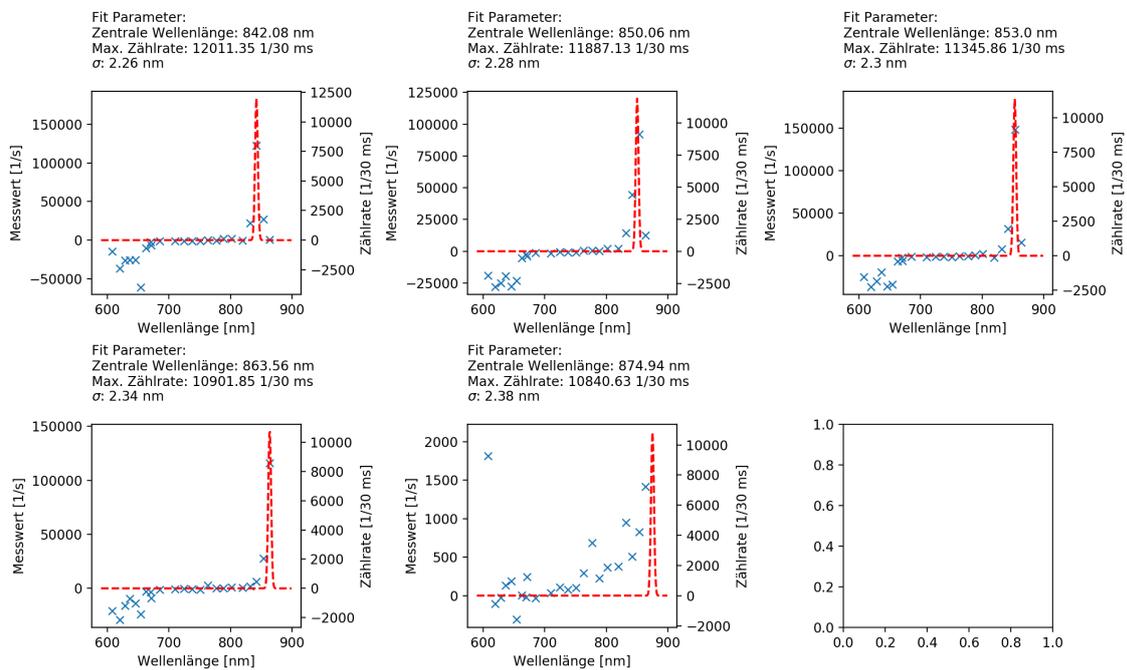


Abbildung A.8: Korrigierte und normierte Kameraspektren (blau) bei verschiedenen Wellenlängen verglichen mit Fit der Spektrometer-Messung (rot) bei Einsatz des Short-Pass Filters. Zentrallwellenlängen von 842 bis 875 nm.

## A.4 Hyperparameter-Tuning zur Erkennung künstlich eingebrachter Prozessfehler

Tabelle A.3: Ergebnisse des Hyperparameter-Tunings zur Erkennung künstlich eingebrachter Prozessfehler.

Anzahl Perzeptronen im Dense-Layer	Dropout- Rate	Optimierungs- algorithmus	Lernrate	F-Maß
32	0,4	Nadam	0,0005	0,935
16	0,6	Nadam	0,0005	0,935
32	0,6	Nadam	0,001	0,923
32	0,6	Adam	0,0005	0,916
8	0,4	SGD	0,002	0,902
8	0,6	SGD	0,002	0,881
32	0,2	SGD	0,002	0,881
8	0,2	SGD	0,002	0,881
32	0,4	SGD	0,002	0,871
32	0,4	SGD	0,001	0,860
8	0,4	SGD	0,001	0,860
16	0,2	SGD	0,002	0,860
32	0,6	SGD	0,002	0,851
32	0,2	SGD	0,001	0,851
32	0,4	SGD	0,0005	0,851
8	0,2	SGD	0,001	0,851
32	0,6	SGD	0,001	0,851
32	0,2	SGD	0,0005	0,841
16	0,4	SGD	0,001	0,841
8	0,6	SGD	0,001	0,841
16	0,2	SGD	0,001	0,841
16	0,6	Adam	0,0005	0,831
8	0,4	SGD	0,0005	0,831
16	0,6	SGD	0,001	0,831
32	0,6	SGD	0,0005	0,831
16	0,4	SGD	0,002	0,822
32	0,2	Adam	0,0005	0,822
16	0,6	SGD	0,002	0,813
16	0,4	SGD	0,0005	0,813
8	0,2	SGD	0,0005	0,813
16	0,2	SGD	0,0005	0,813
8	0,6	SGD	0,0005	0,813
16	0,2	Adam	0,0005	0,804

#### A.4. HYPERPARAMETER-TUNING ZUR ERKENNUNG KÜNSTLICH EINGEBRACHTER PROZESSFEHLER

Tabelle A.3: Ergebnisse des Hyperparameter-Tunings zur Erkennung künstlich eingebrachter Prozessfehler.

Anzahl Perzeptonen im Dense-Layer	Dropout- Rate	Optimierungs- algorithmus	Lernrate	F-Maß
16	0,6	SGD	0,0005	0,796
8	0,4	Adam	0,0005	0,776
32	0,6	Adam	0,001	0,571
8	0,6	Nadam	0,0005	0,540
32	0,4	Adam	0,0005	0,484
16	0,6	Nadam	0,001	0,046
16	0,2	Adam	0,002	0,041
8	0,6	Adam	0,001	0,041
8	0,4	Nadam	0,001	0,041
16	0,4	Nadam	0,002	0,041
32	0,4	Adam	0,001	0,041
8	0,4	Adam	0,001	0,041
8	0,2	Adam	0,002	0,041
16	0,6	Nadam	0,002	0,041
8	0,2	Adam	0,001	0,041
16	0,4	Nadam	0,0005	0,041
32	0,4	Adam	0,002	0,041
16	0,4	Adam	0,002	0,041
16	0,6	Adam	0,002	0,041
16	0,6	Adam	0,001	0,041
32	0,2	Nadam	0,002	0,041
32	0,4	Nadam	0,001	0,041
16	0,2	Nadam	0,0005	0,041
16	0,2	Nadam	0,001	0,041
32	0,2	Adam	0,001	0,041
32	0,6	Nadam	0,002	0,041
16	0,4	Adam	0,0005	0,041
32	0,2	Nadam	0,001	0,041
8	0,2	Adam	0,0005	0,041
32	0,2	Nadam	0,0005	0,041
8	0,2	Nadam	0,002	0,041
16	0,4	Nadam	0,001	0,041
16	0,4	Adam	0,001	0,041
8	0,4	Adam	0,002	0,041
16	0,2	Nadam	0,002	0,041
8	0,6	Adam	0,002	0,041
16	0,6	Nadam	0,0005	0,041

#### A.4. HYPERPARAMETER-TUNING ZUR ERKENNUNG KÜNSTLICH EINGEBRACHTER PROZESSFEHLER

---

Tabelle A.3: Ergebnisse des Hyperparameter-Tunings zur Erkennung künstlich eingebrachter Prozessfehler.

Anzahl Perzeptronen im Dense-Layer	Dropout- Rate	Optimierungs- algorithmus	Lernrate	F-Maß
8	0,2	Nadam	0,0005	0,041
8	0,6	Nadam	0,001	0,041
8	0,4	Nadam	0,002	0,041
32	0,2	Adam	0,002	0,041
8	0,4	Nadam	0,0005	0,041
32	0,4	Nadam	0,002	0,041
8	0,6	Adam	0,0005	0,041
8	0,6	Nadam	0,002	0,041
16	0,2	Adam	0,001	0,041

## Publikationsliste

### Hyperspektrale Prozessüberwachung

N. Gerdes, C. Hoff, J. Hermsdorf, S. Kaierle, L. Overmeyer: *Hyperspectral imaging for prediction of surface roughness in laser powder bed fusion*. The International Journal of Advanced Manufacturing Technology (2021), 1-10. DOI: 10.1007/s00170-021-07274-1.

N. Gerdes, C. Hoff, J. Hermsdorf, S. Kaierle, L. Overmeyer: *Quality Assurance in Metal Additive Manufacturing by Means of Hyperspectral Imaging and Methods of Machine Learning*. Lecture Notes in Networks and Systems, Springer Nature, eingereicht 09.2021.

N. Gerdes, C. Hoff, J. Hermsdorf, S. Kaierle, L. Overmeyer: *Snapshot hyperspectral imaging for quality assurance in Laser Powder Bed Fusion*. Procedia CIRP (2020), 94, 25-28. DOI: 10.1016/j.procir.2020.09.006.

### Sonstige

S. Julmi, A. Abel, N. Gerdes, C. Hoff, J. Hermsdorf, L. Overmeyer, C. Klose, J. H. Maier: *Development of a Laser Powder Bed Fusion Process Tailored for the Additive Manufacturing of High-Quality Components Made of the Commercial Magnesium Alloy WE43*. Materials (2021), 14(4), 887. DOI: 10.3390/ma14040887.

B. Reitz, C. Lotz, N. Gerdes, S. Linke, E. Olsen, K. Pflieger, S. Sohr, M. Ernst, P. Taschner, J. Neumann, E. Stoll, L. Overmeyer: *Additive Manufacturing Under Lunar Gravity and Microgravity*. Microgravity Science and Technology (2021), 33(2), 1-12. DOI: 10.1007/s12217-021-09878-4.

J. Neumann, M. Ernst, P. Taschner, N. Gerdes, S. Stapperfend, S. Linke, C. Lotz, J. Koch, P. Wessels, E. Stoll, L. Overmeyer: *The MOONRISE-payload for mobile selective laser melting of lunar regolith*. Proc. SPIE 11852, International Conference on Space Optics — ICSO 2020, 118526T (11 June 2021); DOI: 10.1117/12.2600322

C. Lotz, N. Gerdes, R. Sperling, S. Lazar, S. Linke, J. Neumann, E. Stoll, W. Ertmer, L. Overmeyer: *Tests of additive manufacturing and other processes under space gravity conditions in the Einstein-Elevator*. Logistics Journal: Proceedings, 2020(12). DOI: 10.2195/lj\_Proc\_lotz\_en\_202012\_01.

S. Kaierle, S. Pamin, N. Gerdes, J. Hermsdorf: *Laser Micro Cladding*. Handbook of Laser Micro- and Nano-Engineering (2020), 1-13, DOI: 10.1007/978-3-319-69537-2\_23-1.

S. Kaierle, M. Gieseke, N. Gerdes; V. Wesling, R. Reiter, S. Kamper: *Laserstrahllegieren von Umformwerkzeugen*. 3. Niedersächsisches Symposium für Materialtechnik, Band 7, S. 293 ff., 2019.

N. Gerdes, L. G. Fokken, S. Linke, S. Kaierle, O. Suttmann, J. Hermsdorf, E. Stoll, C. Trentlage, L. Overmeyer: *Selective Laser Melting for processing of regolith in support of a lunar base*. Journal of Laser Applications (2018), 30(3), 032018. DOI: 10.2351/1.5018576.

S. Kaierle, M. Gieseke, N. Gerdes; V. Wesling, R. Reiter, S. Kamper: *Erhöhung der Verschleißbeständigkeit von Umformwerkzeugen mit Hilfe des Laserstrahllegierens*. 2. Niedersächsisches Symposium für Materialtechnik, Band 4, S. 77 ff., 2017.

### **Im Rahmen dieser Arbeit betreute studentische Abschlussarbeit**

J. Perwas: *Untersuchungen von Prozessdaten eines additiven Metallfertigungsprozesses mittels einer Hyperspektralkamera*. Masterarbeit. Leibniz Universität Hannover (2021).

### **Danksagung**

Ich möchte an dieser Stelle Benedikt Hegedus und insbesondere Jan Perwas meinen besonderen Dank für ihren wertvollen Beitrag zu dieser Arbeit ausdrücken.

## Lebenslauf

### Persönliche Daten

Name	Niklas Gerdes
geboren am	26. Oktober 1989
in	Hannover
Staatsangehörigkeit	deutsch



### Berufliche Tätigkeit

seit 06/2016	Wissenschaftlicher Mitarbeiter in der Abteilung Werkstoff- und Prozesstechnik am Laser Zentrum Hannover e.V.
--------------	--

### Studium

10/2013 – 10/2015	Abschluss: Master of Science (M. Sc.) Erasmus Mundus Europhotonics – Optik und Photonik am Karlsruher Institut für Technologie (KIT), der Universität Polytècnica de Catalunya (UPC) sowie der Aix-Marseille Université (AMU)
08 – 09/2014	Fachpraktikum, Laser Zentrum Hannover e.V.
10/2010 – 06/2013	Abschluss: Bachelor of Science (B. Sc.) Physikstudium an der Jacobs University Bremen
06 – 08/2012	Fachpraktikum, University of Calgary

### Schulische Ausbildung

06/2009	Abschluss: Allgemeine Hochschulreife, Schillerschule Hannover
---------	--

Hannover, 21. Dezember 2021