

Forschungsberichte aus dem
wbk Institut für Produktionstechnik
Karlsruher Institut für Technologie (KIT)

Lukas Matthias Weiser

**In-Process Porositätserkennung
für den PBF-LB/M-Prozess**

Band 270



Forschungsberichte aus dem
wbk Institut für Produktionstechnik
Karlsruher Institut für Technologie (KIT)

Hrsg.: Prof. Dr.-Ing. Jürgen Fleischer
Prof. Dr.-Ing. Gisela Lanza
Prof. Dr.-Ing. habil. Volker Schulze

Lukas Matthias Weiser, M.Sc.

In-Process Porositätserkennung für den PBF-LB/M-Prozess

Band 270

In-Process Porositätserkennung für den PBF-LB/M-Prozess

Zur Erlangung des akademischen Grades eines
DOKTORS DER INGENIEURWISSENSCHAFTEN (Dr.-Ing.)

von der KIT-Fakultät für Maschinenbau des
Karlsruher Instituts für Technologie (KIT)
angenommene

DISSERTATION

von

M.Sc. Lukas Matthias Weiser

Tag der mündlichen Prüfung: 21.06.2023
Hauptreferentin: Prof. Dr.-Ing. Gisela Lanza
Korreferent: Prof. Dr.-Ing. Michael Schmidt

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

Zugl.: Karlsruhe, Karlsruher Institut für Technologie, Diss., 2023

Copyright Shaker Verlag 2023

Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, vorbehalten.

Printed in Germany.

ISBN 978-3-8440-9198-4

ISSN 0724-4967

Shaker Verlag GmbH • Am Langen Graben 15a • 52353 Düren
Telefon: 02421 / 99 0 11 - 0 • Telefax: 02421 / 99 0 11 - 9
Internet: www.shaker.de • E-Mail: info@shaker.de

Vorwort des Herausgebers

Die schnelle und effiziente Umsetzung innovativer Technologien wird vor dem Hintergrund der Globalisierung der Wirtschaft der entscheidende Wirtschaftsfaktor für produzierende Unternehmen. Universitäten können als "Wertschöpfungspartner" einen wesentlichen Beitrag zur Wettbewerbsfähigkeit der Industrie leisten, indem sie wissenschaftliche Grundlagen sowie neue Methoden und Technologien erarbeiten und aktiv den Umsetzungsprozess in die praktische Anwendung unterstützen.

Vor diesem Hintergrund wird im Rahmen dieser Schriftenreihe über aktuelle Forschungsergebnisse des Instituts für Produktionstechnik (wbk) am Karlsruher Institut für Technologie (KIT) berichtet. Unsere Forschungsarbeiten beschäftigen sich sowohl mit der Leistungssteigerung von additiven und subtraktiven Fertigungsverfahren, den Produktionsanlagen und der Prozessautomatisierung sowie mit der ganzheitlichen Betrachtung und Optimierung der Produktionssysteme und -netzwerke. Hierbei werden jeweils technologische wie auch organisatorische Aspekte betrachtet.

Prof. Dr.-Ing. Jürgen Fleischer

Prof. Dr.-Ing. Gisela Lanza

Prof. Dr.-Ing. habil. Volker Schulze

Vorwort des Verfassers

Die vorliegende Arbeit entstand während meiner Zeit am wbk Institut für Produktionstechnik. Diese Arbeit hätte nicht ohne die Hilfe von zahlreichen Personen entstehen können.

Zunächst möchte ich mich bei Frau Prof. Dr.-Ing. Gisela Lanza für die Betreuung dieser Arbeit, insbesondere aber auch für die Schaffung eines Umfelds an Ihrem Lehrstuhl, welches nicht nur zielgerichtete und relevante Forschung im Bereich der Produktionstechnik ermöglicht, sondern auch die persönliche Weiterentwicklung Ihrer Mitarbeiter in den Fokus stellt. Weiterhin möchte ich mich bei der Arbeitsgruppe Produktionssysteme (PRO) für die freundschaftliche Zusammenarbeit und gegenseitige Unterstützung bedanken. Gesonderte Erwähnung soll die Montag-Mittwoch-Freitag-Gruppe im Walk-In finden, welche für einen willkommenen Ausgleich zur Schreibtischarbeit sorgt. Für fachliche Diskussionen und das Lektorat dieser Arbeit möchte ich mich bei Katja Höger, Jork Groenewold und Fabian Sasse bedanken.

Weiterhin möchte ich mich herzlichst bei meinen Eltern für die bedingungslose Unterstützung während des Studiums und während der Zeit am wbk bedanken. Ohne sie würde ich heute nicht dort stehen, wo ich stehe. Mein herzlicher Dank gilt ebenfalls meiner Schwester Amelie, die auch in schwierigen Zeiten immer mit Worten des Rats und der Unterstützung für mich da ist.

Abschließend möchte ich mich bei meiner Freundin Melissa Özcü für die bedingungslose und selbstlose Unterstützung während des Studiums, aber insbesondere während meiner Zeit am wbk bedanken. Die gemeinsame Zeit und die Ablenkung durch ihren unbeschreiblichen Humor haben auch die anstrengendsten Zeiten erträglich gemacht.

Karlsruhe, im Juni 2023

Lukas Matthias Weiser

Kurzfassung

Das Fertigungsverfahren des selektiven Laserschmelzens mit Metallen (PBF-LB/M) wird zunehmend auch für die Herstellung von hochbelastbaren Bauteilen in einer Serienfertigung eingesetzt. Die fehlende Reproduzierbarkeit von Prozessergebnissen und das stochastische Auftreten des Defektes Porosität stellen dabei eine besondere Herausforderung dar, da dieser Defekt einen wesentlichen Einfluss auf die mechanischen Kennwerte eines Bauteils hat. Dies kann in der Folge ein Versagen des Bauteils unter Last zur Folge haben. Aus diesem Grund ist für solche hochbelasteten Bauteile die Qualitätssicherung unerlässlich. Die zerstörungsfreie Prüfung auf Porosität erfolgt im industriellen Kontext oftmals durch die Röntgen-Computertomografie (CT). Aufgrund langer Messzeiten entstehen hohe Kosten durch die Qualitätssicherung, welche die Wirtschaftlichkeit des PBF-LB/M-Fertigungsverfahrens einschränken. Je nach verwendetem Material und Bauteilgröße ist eine Porositätsanalyse mittels CT auch technisch nicht möglich. Aus diesen Gründen können alternative in-process Prozessüberwachungen für die industrielle Nutzung des PBF-LB/M-Fertigungsverfahrens einen Vorteil bringen.

Bestehende Forschungsansätze zur in-process Porositätserkennung weisen vor allem Defizite im Bereich der industriellen Anwendbarkeit und in der quantitativen Defektcharakterisierung auf. Im Rahmen der vorliegenden Arbeit wird mithilfe von Methoden der datengetriebenen Modellbildung eine Prozessüberwachung auf Basis optischer Sensoren und akustischer Körperschallmesstechnik entwickelt, welche die Porositätsverteilung innerhalb eines Bauteils während des Fertigungsprozesses vorhersagen kann. Dazu werden 104 Probekörper additiv gefertigt und die Sensordaten aufgezeichnet. Die Probekörper werden nachfolgend mittels Computertomographie auf Porosität untersucht. Diese Informationen werden im Rahmen der datengetriebenen Modellbildung mittels künstlicher neuronaler Netze als Label für das Training genutzt. Die trainierten Modelle sind in der Lage, Bauteile räumlich aufgelöst hinsichtlich ihrer Porosität zu klassifizieren. Dabei können variable Schwellwerte als Klassengrenze genutzt werden. Die quantitative Vorhersage der numerischen Porosität durch Regression sowie die Einzeldefekterkennung bedarf weiterführender Forschungsarbeit. Die Datenfusion von optischer und akustischer Sensorik wurde im Rahmen der Arbeit betrachtet, konnte aber keine besseren Ergebnisse als die separate Betrachtung der Sensoren erzielen. Die Rohdaten der Arbeit werden im Rahmen des Promotionsverfahrens ebenfalls veröffentlicht, um weiterführende Forschungsarbeiten zu ermöglichen.

Abstract

The manufacturing process of selective laser melting with metals (PBF-LB/M) is increasingly used for the production of highly stressable components in a series production. The lack of reproducibility of process results and the stochastic occurrence of the defect porosity pose a particular challenge, as this defect has a significant influence on the mechanical properties of a component. This can result in failure of the component under load. For this reason, quality assurance is essential for such highly stressed components. In an industrial context, non-destructive testing for porosity is often performed using X-ray computed tomography (CT). Due to long measuring times, high costs are incurred by quality assurance, which limit the economic viability of the PBF-LB/M manufacturing process. Depending on the material and component size used, porosity analysis by CT is also not technically feasible. For these reasons, alternative in-process monitoring may provide an advantage for the industrial use of the PBF-LB/M manufacturing process.

Existing research approaches for in-process porosity detection mainly show deficits in industrial applicability and in quantitative defect characterization. Within the scope of the present work, a process monitoring system based on optical sensors and acoustic structure-borne sound measurement technology is developed using methods of data-driven modeling, which can predict the porosity distribution within a component during the manufacturing process. For this purpose, 104 test specimens are additively manufactured and the sensor data are recorded. The test specimens are then examined for porosity using computed tomography. This information is used as a label for training within the framework of data-driven model building using artificial neural networks. The trained models can classify components spatially resolved with respect to their porosity. Variable threshold values can be used as class boundaries. Quantitative prediction of numerical porosity by regression as well as single-cell defect detection requires further research. Data fusion of optical and acoustical sensors did not yield better model predictions than models based on the individual sensors. The raw data of the work will also be published as part of the doctoral process to enable further research work.

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Abkürzungen und Formelzeichen	V
1 Einleitung	1
1.1 Motivation	1
1.2 Zielsetzung	3
1.3 Aufbau der Arbeit	3
2 Grundlagen	5
2.1 Laser-Strahlschmelzen (PBF-LB/M)	5
2.1.1 Prozessablauf	5
2.1.2 Anlagenaufbau	6
2.1.3 Prozessparameter	7
2.1.4 Defekte beim PBF-LB/M Prozess	10
2.2 Produktionsintegrierte Messtechnik	13
2.3 Sensorik	15
2.3.1 Grundlagen Sensorik	15
2.3.2 Optische Sensorik	16
2.3.3 Akustische Sensorik	17
2.4 Datenanalyse	18
2.4.1 Modellbildung	18
2.4.2 Datenvorverarbeitung	19
2.4.3 Künstliche Neuronale Netze	21
2.4.4 Metriken zur Bewertung der Modellgüte	24
3 Stand der Forschung und Technik	29
3.1 Anforderungen an eine Prozessüberwachung für das PBF-LB/M Verfahren	29
3.2 Bestehende Ansätze zur Prozessüberwachung im PBF-LB/M Prozess	32
3.2.1 Optische on-axis Prozessüberwachungen	32
3.2.2 Optische off-axis Prozessüberwachungen	36
3.2.3 Akustische Prozessüberwachungen	39

3.2.4	Weitere Prozessüberwachungen	42
3.2.5	Herstelleransätze	43
3.3	Zusammenfassende Bewertung der Ansätze	49
4	Forschungsdefizit	53
5	Eigener Ansatz	54
5.1	Überblick über den eigenen Ansatz	54
5.2	Sensorauswahl und Sensorintegration in die PBF-LB/M Anlage	54
5.2.1	Vorstellung der verwendeten PBF-LB/M Anlage	55
5.2.2	Sensorauswahl	57
5.2.3	Sensorintegration in industrielle PBF-LB/M Anlage	59
5.3	Erzeugung von Probekörpern mit Datenaufnahme	63
5.3.1	Vorgehen zur Einbringung von Porosität	63
5.3.2	Geometrie der Probekörper	67
5.3.3	Material der Probekörper	70
5.3.4	Druck der Probekörper	70
5.4	Referenzmessung	72
5.4.1	Validierung der Referenzmessung	73
5.4.2	Durchführung der Referenzmessung	88
5.5	Datenanalyse zur Vorhersage der orts aufgelösten Porosität	93
5.5.1	Konvertierung der Positionsdaten des Lasers	94
5.5.2	Zeitkorrektur der Sensordaten	96
5.5.3	Segmentierung der Sensordaten in Einheitszellen	99
5.5.4	Merkmalsextraktion	100
5.5.5	Datensatzerstellung für Modellbildung	103
5.5.6	Modellbildung	107
5.5.7	Modellevaluation	109
6	Ergebnisse der Datenanalyse	110
6.1	Darstellung der Druckjobergebnisse	110
6.2	Einfluss der Datenkomprimierung	115

6.3	Klassifikation der Zellporosität auf Gesamtdatensatz	117
6.3.1	Akustik: Körperschall	117
6.3.2	Optik: Fotodiodenarray	126
6.3.3	Vergleich von Körperschall und Fotodiodenarray	129
6.4	Regression der Zellporosität auf Gesamtdatensatz	130
6.4.1	Akustik: Körperschall	130
6.4.2	Optik: Fotodiodenarray	133
6.4.3	Vergleich von Körperschall und Fotodiodenarray	136
6.5	Modellübertragbarkeit auf einzelne Druckjobs	136
6.6	Datenfusion von Körperschall und Fotodiodenarray	139
6.6.1	Klassifikation	140
6.6.2	Regression	142
6.7	Optimales Modell	143
7	Kritische Diskussion und Ausblick	145
7.1	Kritische Diskussion der Ergebnisse	145
7.2	Kritische Diskussion der Anforderungserfüllung	147
7.3	Ausblick	149
8	Zusammenfassung	151
	Liste der eigenen Publikationen	I
	Literaturverzeichnis	III
	Abbildungsverzeichnis	XVIII
	Tabellenverzeichnis	XXIV
	Anhang	XXVI
	A1 Materialdatenblatt Pulvercharge 316l	XXVI
	A2 Schnittansichten der Probekörper (Testdatensatz)	XXVII
	A2.1 Klassifikation Körperschall	XXVII
	A2.2 Klassifikation Fotodiodenarray	LXIII
	A2.3 Regression Körperschall	LXIX
	A2.4 Regression Fotodiodenarray	LXXV

A2.5 Datenfusion Klassifikation	LXXXI
A2.6 Datenfusion Regression	XCIII

Abkürzungen und Formelzeichen

AM	Additive Fertigung, engl. <i>additive manufacturing</i>
ASTM	American Society for Testing and Materials
AUC	Area under Curve
CAD	Computer-Aided Design
CCD	Charge-Coupled Device
CMOS	Complementary Metal-Oxide-Semiconductor
CNN	Convolutional Neural Network
COW	Cut-On/Cut-Off Wellenlänge
CT	Röntgen-Computertomographie
CWL	Center Wavelength - Mittenwellenlänge
DFT	Diskrete Fourier-Transformation
DIN	Deutsches Institut für Normung
EN	Europäische Norm
FBG	Faser Bragg Gitter
FFT	Fast Fourier Transform – schnelle Fourier-Transformation
FN	false negative
FP	false positive
FPGA	Field Programmable Gate Array
FPGA	Field Programmable Gate Array
FWHM	Full-Width-at-Half-Maximum
InGaAs	Indium-Gallium-Arsenid
ISO	International Organization for Standardization
KNN	Künstliche Neuronale Netze
KOS	Koordinatensystem
LWIR	Langwelliger Infrarotbereich engl. <i>longwave infrared</i>
MCC	Matthews Correlation Coefficient
MLP	Multi Layer Perzeptrom
MSE	Mittlerer quadratischer Fehler
MTF	Modulationstransferfunktion
Yb:YAG Laser	Ytterbium-dotierter Yttrium-Aluminium-Granat Laser
NIR	Nah-Infrarot
OCT	Optische Kohärenztomographie
PBF-LB/M	engl. <i>powder bed fusion – laser beam / metal</i> , etwa Laserbasierte Pulverbettfusion von Metallen
PCA	Principal Component Analysis – Hauptkomponentenanalyse
R^2	Bestimmtheitsmaß
RMSE	Root-Mean-Square Error
ROC	Receiver Operating Characteristic
ROI	Region-of-Interest
SD-OCT	Spectral Density Optical Coherence Tomography
SMB	Server Message Block
SNR	Signal-to-Noise Ratio – Signal-Rausch-Verhältnis
SPI	Serial Peripheral Interface
SPS	Speicherprogrammierbare Steuerung

SRAS	Spatially Resolved Acoustic Spectroscopy
SSD	Solid State Disk
STFT	Short Time Fourier Transform – Kurzzeit-Fourier-Transformation
SVM	Support Vector Machine
TED	Thermal Energy Density
TEP	Thermal Energy Planck
TN	True Negative
TP	True Positive
TTL	Transistor-Transistor-Logik
VDI	Verein Deutscher Ingenieure
YAG	Yttrium-Aluminium-Granat

Formelzeichen	Größe	Einheit
$\hat{x}_{n,dB}$	Datenpunkt der <i>FFT-Segment-Reduced</i> in dB	[dB]
\hat{x}_n	Datenpunkt der <i>FFT-Segment-Reduced</i>	
\hat{y}_i	Vorhersage	
A_{Pore}	Fläche einer Pore im Schliffbild	[mm ²]
C_{Pore}	Zirkularität einer Pore	
C_S	Sperrschichtkapazität	[F]
E_{vol}	Volumetrischer Energieeintrag	[J/mm ³]
I_P	Fotostrom	[A]
KOS_{Anlage}	Anlagen-Koordinatensystem	
$KOS_{Bauteil}$	Bauteil-Koordinatensystem	
$KOS_{Scanner}$	Scanner-Koordinatensystem	
N_t	Zeitauflösung	
P_{Laser}	Laserleistung	[W]
P_{Pore}	Umfang einer Pore im Schliffbild	[mm]
R_P	Parallelwiderstand der Fotodiode	[Ω]
R_m	Zugfestigkeit	[MPa]
$R_m^{P=0}$	Zugfestigkeit im porenfreien Zustand	[MPa]
R_r	Rückkopplungswiderstand	[Ω]
S_{max}	Maximale Empfindlichkeit einer Fotodiode	[A/lx] oder [A/W]
U_{out}	Ausgangsspannung	[V]
$d_{Hatching}$	Schraffurabstand	[mm]
d_{Layer}	Schichtdicke	[mm]
f_s	Abtastrate	[Hz]
v_{Scan}	Belichtungsgeschwindigkeit	[mm/s]
var_{Σ}	Kumulierte Varianz	
var_i	Varianz einer Hauptkomponente	
$x_{i,dB}$	Datenpunkt der <i>FFT-Segment</i> in dB	[dB]

x_i	Datenpunkt der <i>FFT-Segment</i>	
\bar{y}	Empirischer Mittelwert	
y_i	Wahrer Wert	
\mathbf{M}_{roh}	Matrix Rohdaten	
\mathbf{M}_{trans}	Transformierte Matrix	
\mathbf{x}_n	Amplitudenvektor der Länge n	
$\lambda_{10\%}$	Wellenlängenbereich, bei der die Empfindlichkeit 10 % der maximalen Empfindlichkeit beträgt	[nm]
$\lambda_{50\%}$	Wellenlängenbereich, bei der die Empfindlichkeit 50 % der maximalen Empfindlichkeit beträgt	[nm]
λ_i	Eigenwert einer Hauptkomponente	
Δf	Frequenzauflösung	[Hz]
N	Reduktionsfaktor	
P	Porosität	[%]
s	Zerklüftung	
\mathbf{T}	Transformationsmatrix	

1 Einleitung

Das nachfolgende Kapitel legt die grundlegende Motivation der vorliegenden Arbeit sowie die Zielsetzung und den strukturellen Aufbau der Arbeit dar.

1.1 Motivation

Die additive Fertigung (engl. *additive manufacturing* – AM) gewinnt zunehmend an Bedeutung in der industriellen Wertschöpfung. Mit dem Fertigungsverfahren des pulverbettbasierten Schmelzens von Metallen mittels Laserstrahl (auch: selektives Laserschmelzen oder engl. *powder bed fusion – laser beam/metal* - PBF-LB/M) können metallische Werkstoffe verarbeitet werden, was besonders vor dem Hintergrund einer industriellen Nutzung additiv gefertigter Bauteile von hohem Interesse ist. Dies ist unter anderem am steigenden Marktvolumen dieser Technologie zu erkennen. Das Marktvolumen der additiven Fertigung mit Metallen betrug im Jahr 2021 ca. 2,51 Milliarden US-Dollar und soll auf ca. 11,45 Milliarden US-Dollar im Jahr 2030 ansteigen¹.

Dieses wachsende Interesse begründet sich unter anderem in den Vorteilen additiver Fertigungsverfahren mit Metallen wie beispielsweise PBF-LB/M: (I) durch die *Funktionsintegration* können Funktionen, welche sonst auf mehrere Bauteile verteilt sind, in ein Bauteil integriert werden; (II) durch eine *endkonturnahe Fertigung* der Bauteile wird weniger Material benötigt; (III) die *Freiheitsgrade in der Bauteilgestaltung* sind gegenüber den konventionellen Fertigungsverfahren² gesteigert und (VI) die Möglichkeit der Bauteilkonsolidierung erlaubt eine *Verringerung der Bauteilkomplexität*. (DIN EN ISO/ASTM 52911-1)

Mittels PBF-LB/M Fertigungsverfahren hergestellte Bauteile weisen prozesstypische Defekte wie Risse / Delaminationen, Balling (bei welchem sich das Schmelzbad kugelförmig zusammenzieht) oder Porosität auf (Zhang et al. 2017). Vor allem Poren stellen einen kritischen Defekt dar, da diese Defektart klein und innenliegend ist und einen erheblichen Einfluss auf die mechanischen Kennwerte eines Bauteils hat (Ladewig et al. 2016; Rehse et al. 2013). Dies steht in Konflikt zum Bestreben, additiv gefertigte

¹ Statistik von: <https://www.precedenceresearch.com/metal-additive-manufacturing-market> (05.07.2022)

² Unter konventionellen Fertigungsverfahren werden im Rahmen dieser Arbeit umformende, urformende und zerspanende Fertigungsverfahren zusammengefasst.

Metallbauteile in hochbelasteten Anwendungen zu nutzen. Damit diese Bauteile im geforderten Anwendungsfall nicht unter Last versagen, müssen diese einer Qualitätssicherung unterzogen werden, welche Kenntnis über eventuell vorhandene Porosität im Bauteil gibt (Craeghs et al. 2011).

Neben der prozentualen Gesamtporosität ist für eine Bewertung der vorhandenen Porosität hinsichtlich des Einflusses auf die mechanischen Kennwerte eines Bauteils Kenntnis über die Form und Lage dieser notwendig (Rehse et al. 2016; Stroppe 2000). Die Form lässt sich durch geeignete Geometrieparameter wie die Sphärizität beschreiben. Die Lage resultiert in einer Porositätsverteilung innerhalb des Bauteils, sodass Bereiche mit lokal erhöhter Porosität identifiziert werden können. Dies ist vor allem in Kombination mit Simulationsergebnissen des angestrebten Belastungsfalls von besonderem Interesse, um Bereiche zu identifizieren, in denen das Auftreten von Porosität unbedingt vermieden werden muss.

Bisher erfolgt die Untersuchung auf Porosität meist durch zerstörende Verfahren wie Schliffbilder oder im Bereich der zerstörungsfreien Verfahren durch Röntgen-Computertomographie (CT) (Schild et al. 2023; Spierings & Levy 2009) oder optische und akustische Sensorik (Eschner 2021).

Zerstörende Verfahren zur Qualitätssicherung eignen sich nur bedingt für industrielle Bauteile, da die Reproduzierbarkeit der Prozessergebnisse des PBF-LB/M Verfahrens eingeschränkt ist (Dowling et al. 2020). Die Prozessergebnisse und damit das Auftreten von Defekten wie Poren wird durch eine Vielzahl von Parametern beeinflusst, die oftmals weder steuerbar noch regelbar sind und starke Wechselwirkungen aufeinander haben. Diese nicht steuer- bzw. regelbaren Parameter und Wechselwirkungen verursachen Prozessunsicherheiten, welche für eine stochastische Verteilung der Prozessergebnisse sorgen. Es kann daher nicht von der Qualität eines einzelnen Bauteils auf die Qualität anderer Bauteile geschlossen werden. Jedes Bauteil muss einer eigenständigen Qualitätssicherung unterzogen werden. Für eine Industrialisierung ist eine 100 %-Kontrolle notwendig. (Spears & Gold 2016; Vendra et al. 2020; Weiser et al. 2020)

Die notwendige Qualitätssicherung ist daher durch zerstörungsfreie Verfahren durchzuführen. Im Bereich der Prototypenfertigung, bei der nur geringe Stückzahlen vorliegen, kann die Qualitätssicherung durch bspw. die Röntgen-Computertomographie er-

folgen. Das Erstellen eines CT-Scans ist durch die lange Messdauer und den zugrundeliegenden Maschinenstundensatz jedoch für die Serienproduktion unwirtschaftlich. Erfolgt die Qualitätssicherung erst nach dem Fertigungsprozess, ist beim Vorhandensein von kritischen Defekten Wertschöpfung an Ausschuss betrieben worden. Je nach Füllgrad des Bauraums der PBF-LB/M Anlage und in Abhängigkeit der verwendeten Prozessparametern können mehrere Stunden vergehen, ehe der Fertigungsprozess abgeschlossen ist. Der Maschinenstundensatz ist gegenüber konventionellen Fertigungsverfahren (noch) höher, was zu höheren Kosten der Bauteile führt. Diese Problematiken machen einen wirtschaftlichen Einsatz dieser Technologie in der industriellen Serienfertigung bisher kaum möglich. (Jacob 2021; Kopf 2018)

Eine Lösung zur wirtschaftlichen Qualitätssicherung kann hierbei im Einsatz einer sogenannten in-process Prozessüberwachung liegen, welche in der Lage ist, hauptzeitparallel zum Fertigungsverfahren eine Aussage über die momentane Qualität der Bauteile zu treffen (Eschner et al. 2019). Somit können Defekte frühzeitig im Fertigungsverfahren detektiert werden. Beim Auftreten von Defekten kann der Prozess gestoppt oder nachgeregelt werden, was bessere Bauteile oder geringere Kosten zur Folge hat. Weiterhin kann so auf eine kostspielige *End-of-Line* Qualitätssicherung verzichtet werden. (Lanza et al. 2019; Weiser et al. 2023)

1.2 Zielsetzung

Das Ziel der Arbeit ist die Entwicklung einer quantitativen in-process Prozessüberwachung für das PBF-LB/M Fertigungsverfahren, welche die Entstehung von Porosität hauptzeitparallel erkennen kann, die Porositätsverteilung des Bauteils zur Laufzeit des Prozesses vorhersagt und für den industriellen Einsatz in einer Serienfertigung geeignet ist.

1.3 Aufbau der Arbeit

In Kapitel 1 sind die Motivation, die Zielsetzung und der Aufbau der Arbeit festgehalten. Kapitel 2 stellt die notwendigen Grundlagen zum Verständnis dieser Arbeit dar. In Kapitel 3 werden die Anforderungen an eine Prozessüberwachung aufgezeigt, die bestehenden Ansätze zur Prozessüberwachung aus Forschung und Industrie vorgestellt und zusammengefasst. Nachfolgend wird in Kapitel 4 das aus dem Stand der Forschung und Technik abgeleitete Forschungsdefizit formuliert. In Kapitel 5 erfolgt die detaillierte

Vorstellung des eigenen Ansatzes zur Behebung des Forschungsdefizits. In Kapitel 6 werden die Ergebnisse der in dieser Arbeit durchgeführten Datenanalyse vorgestellt. Kapitel 7 widmet sich der kritischen Diskussion der vorliegenden Arbeit sowie der Anforderungserfüllung und schafft einen Ausblick auf mögliche Anschlussarbeiten zur weiterführenden Bearbeitung des Themenkomplexes. In Kapitel 8 erfolgt eine Zusammenfassung der Arbeit.

Literaturquellen, die gemäß dem Schema (A_<Nachname> Jahr) dargestellt sind, beziehen sich auf studentische Arbeiten, die vom Verfasser dieser Arbeit inhaltlich und organisatorisch angeleitet und betreut wurden.

2 Grundlagen

In diesem Kapitel werden die notwendigen Grundlagen zum Verständnis der Arbeit dargestellt. In Kapitel 2.1 wird zunächst das PBF-LB/M Fertigungsverfahren vorgestellt. Im darauffolgenden Kapitel 2.2 werden die Grundlagen der produktionsintegrierten Messtechnik dargelegt. Kapitel 2.3 widmet sich den Grundlagen der Sensorik. In Kapitel 2.4 werden die wesentlichen Grundlagen für die im Rahmen dieser Arbeit durchgeführte Datenanalyse vorgestellt.

2.1 Laser-Strahlschmelzen (PBF-LB/M)

Das Fertigungsverfahren des Laser-Strahlschmelzens, nach VDI 3405 / DIN EN ISO/ASTM 52911-1 auch als PBF-LB/M bezeichnet, gehört zur Gruppe der additiven Fertigungsverfahren. In der Folge wird der Prozessablauf, der grundlegende Anlagenaufbau, die wichtigsten Prozessparameter und die im Fertigungsverfahren entstehenden Defekte vorgestellt.

2.1.1 Prozessablauf

Beim PBF-LB/M Verfahren wird ein pulverförmiger, metallischer Werkstoff mittels eines Lasers selektiv aufgeschmolzen. Durch das Erstarren des Werkstoffs entsteht ein Festkörper. In Abbildung 2-1 ist der prinzipielle Prozessablauf visualisiert. Ein volumetrisches CAD-Modell eines Bauteils wird entlang der (vertikalen) z-Achse durch den Vorgang des *Slicens* in Schichten zerlegt. Der Laser fährt dann die Kontur und Schnittfläche der aktuellen Schicht nach (auch als *belichten* oder *scannen* bezeichnet) und sorgt so für die Formgebung des Bauteils. Nachdem eine Schicht aufgeschmolzen wurde, wird die in der Höhe verfahrbare Bauplattform um eine Schichthöhe abgesenkt und es wird mit einem Beschichter eine neue Schicht Pulver aufgetragen. Dieser Vorgang wird iterativ wiederholt, bis alle Schichten des 3D-Modells belichtet wurden und das Bauteil fertiggestellt ist. Dies kann je nach Bauteilgeometrie und Anzahl der Bauteile mehrere Stunden dauern und wird im Wesentlichen durch die Anzahl der Schichten sowie die aufzuschmelzende Fläche beeinflusst. Das Aufschmelzen des Pulvers erfolgt unter einer Schutzgasatmosphäre, um die Oxidation des Werkstoffs zu verhindern. Als Schutzgas werden dabei häufig Argon oder Stickstoff eingesetzt. (Bremen et al. 2012)

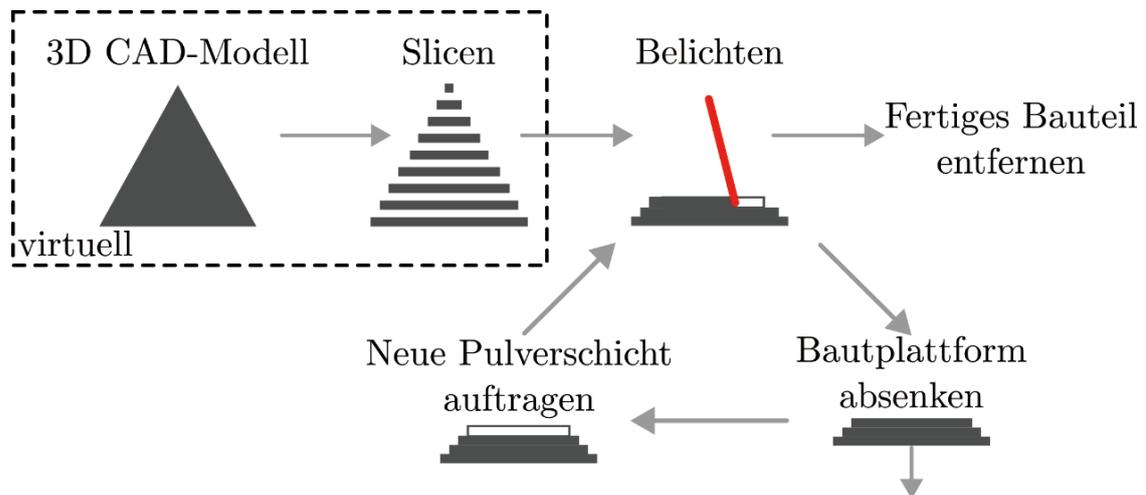


Abbildung 2-1: Prinzipieller Prozessablauf des PBF-LB/M Verfahrens – eigene Darstellung nach (Bremen et al. 2012)

2.1.2 Anlagenaufbau

Der schematische Aufbau einer PBF-LB/M Anlage mit seinen wesentlichen Komponenten ist in Abbildung 2-2 dargestellt. Eine Laserquelle (1) (meistens YAG-Laser mit Wellenlängen im Bereich um 1064 nm) erzeugt einen Laserstrahl, der durch diverse Linsen (2) fokussiert wird. Zwei Galvanometer-Scanner (3) lenken den Laser gezielt um, um die Bewegungsbahnen (auch als Scanvektoren bezeichnet) auf der Bauplattform (5) einstellen und das Bauteil (6) aufschmelzen zu können. Zwischen der Bauplattform und den Galvanometer-Scannern ist oftmals eine F-Theta-Linse (4) zu finden, die für eine konstante Fokusslage des Lasers auf der Bauplattform sorgt. Bei neueren PBF-LB/M Anlagen wird die F-Theta-Linse durch Fokussiersysteme (*VarioScan*) ersetzt, welche hochdynamisch die Fokusslage entlang der z-Achse des Systems anpassen können.

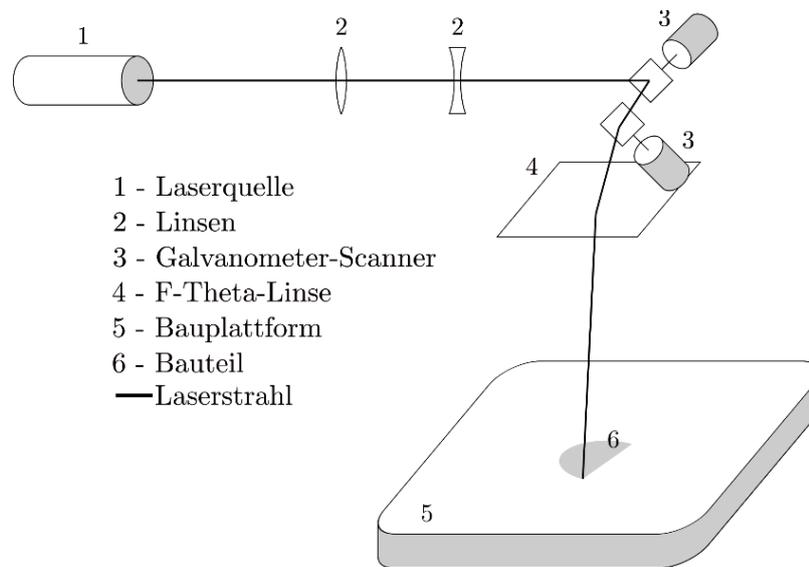


Abbildung 2-2: Vereinfachter exemplarischer Aufbau einer PBF-LB/M Anlage – eigene Darstellung

2.1.3 Prozessparameter

Das PBF-LB/M Verfahren weist einen sehr großen Parameterraum auf. In der Literatur werden mindestens vier Hauptgruppen prozessrelevanter Parameter und mehr als 50 einzelne Prozessparameter diskutiert (Spears & Gold 2016). Diese lassen sich in steuerbare und vordefinierte Parameter einteilen. In Abbildung 2-3 sind die Hauptgruppen Belichtung, Pulver, Prozessumgebung sowie Pulverbett / Beschichter sowie exemplarische Prozessparameter aus den Hauptgruppen als Ishikawa-Diagramm dargestellt. Die Vielzahl an Parametern und fehlendes Verständnis über die Wechselwirkungen derselben führen zu einer eingeschränkten Reproduzierbarkeit der Prozessergebnisse sowie einem stochastischen Auftreten von Defekten.

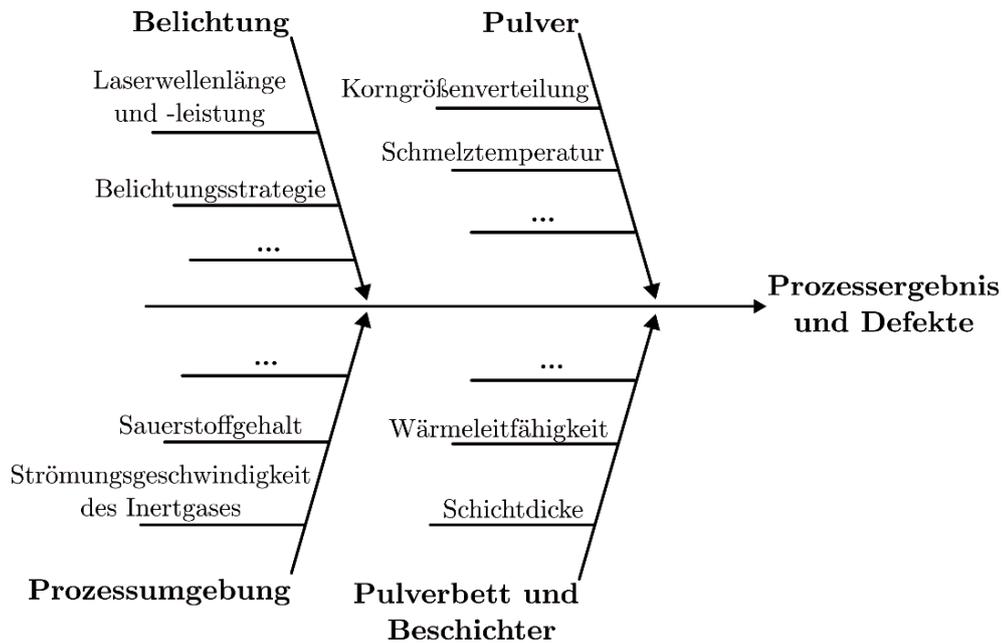


Abbildung 2-3: Ishikawa-Diagramm für den PBF-LB/M Prozess – eigene Darstellung nach (Spears & Gold 2016)

Nach der Darstellung des großen Parameterraums des PBF-LB/M-Prozesses, werden in der Folge die Parameter **volumetrischer Energieeintrag**, die **Prozessnebenprodukte** und die **Belichtungsstrategie** vorgestellt, da diese nach Thijs et al. (2010), Shi et al. (2020), Kasperovich et al. (2016) und A_Bauder (2020) einen wesentlichen Einfluss auf die Entstehung von Porosität haben.

Die wesentliche Prozesscharakteristik wird durch den **volumetrischen Energieeintrag** E_{vol} in den Prozess und der dazugehörigen Prozessdynamik bestimmt. Nach Formel 2-1 gehen die **Laserleistung** P_{Laser} [W], die **Belichtungsgeschwindigkeit** v_{Scan} [mm/s], die **Schichtdicke** d_{Layer} [mm] und der **Schraffurabstand** $d_{Hatching}$ [mm] in den volumetrischen Energieeintrag ein.

$$E_{vol} = \frac{P_{Laser}}{v_{scan} * d_{Layer} * d_{Hatching}} \quad [J/mm^3] \quad \text{Formel 2-1}$$

In Abbildung 2-4 ist die Prozessdynamik schematisch dargestellt. Diese beschreibt das Verhalten, dass gleiche volumetrische Energieeinträge bei unterschiedlichen Verhältnissen der Belichtungsgeschwindigkeit v_{scan} und der Laserleistung P_{Laser} nicht das gleiche Prozessergebnis zur Folge haben. Es gibt Prozessfenster, in denen ein zu hoher Energieeintrag oder ein zu geringer Energieeintrag vorliegt.

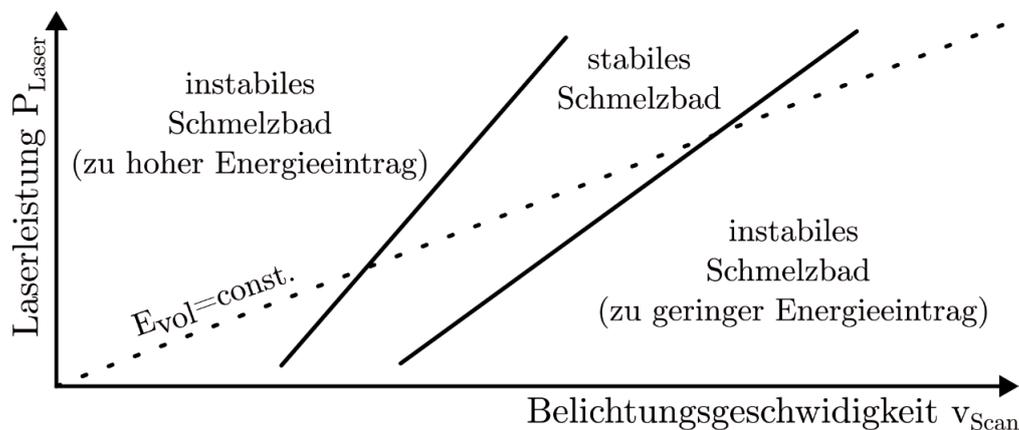


Abbildung 2-4: Prozessdynamik durch unterschiedliches Schmelzbadverhalten bei konstantem Energieeintrag – eigene Darstellung nach (Ahn 2019)

Unter die **Prozessnebenprodukte**, welche während des PBF-LB/M Prozess entstehen, fallen die *Plasmafahne*, *verdampfte Metalle*, *Schweißspritzer* und *herausgeschleudertes Metallpulver*.

Die *Plasmafahne* entsteht durch Ionisierung des Gases oberhalb des Schmelzbades durch den Laserstrahl. Durch den hohen Energieeintrag in diesem Bereich entsteht nicht nur ionisiertes Gas, sondern es werden auch bestimmte Legierungsanteile im Schmelzbad verdampft. Die *verdampften Metalle* kondensieren in der Baukammer und bilden Partikel mit einer Größe von 10 bis 150 nm. Die Partikel können aneinander anhaften und so deutlich größere Agglomerate bilden. Durch die Dynamik der Plasmafahne und der Verdampfung von Legierungsanteilen können umliegende Pulverpartikel mitgerissen und herausgeschleudert werden. Dieses *herausgeschleuderte Pulver* lagert sich im Pulverbett ab und beeinflusst so die Bereiche, welche noch mit dem Laser aufgeschmolzen werden sollen. Die Ursache für das Auftreten von *Schweißspritzern* ist noch nicht abschließend geklärt: flüchtige Legierungselemente oder Instabilitäten im Schmelzbad fördern deren Auftreten. In der chemischen Gesamtkompositionen entsprechen die Schweißspritzer dem Pulver, sind aber deutlich größer als Pulverteilchen. Schweißspritzer lagern sich ebenso wie herausgeschleudertes Pulver im Pulverbett ab und beeinflussen so der Laser-Material-Interaktion. (Spears & Gold 2016)

Die **Belichtungsstrategie** gibt die Art und Weise vor, wie der Laser die aktuelle Schicht belichtet. In Abbildung 2-5 sind beispielhaft die flächige Belichtung, die Streifenbelichtung und die Schachbrettbelichtung dargestellt. Je nach zu belichtender Fläche kann die Nutzung einer alternativen Belichtungsstrategie das Prozessergebnis verbessern, da beispielsweise Eigenspannungen im Bauteil vermindert werden können oder das

Entstehen von Poren beeinflusst werden kann. Weiterhin ist es üblich, unterschiedliche Parameter für die Belichtung der Kontur und der Fläche (auch *Infill* genannt) zu nutzen, da dies die Oberflächenqualität des Bauteils verbessern kann. (Klahn 2015; Robinson et al. 2019)

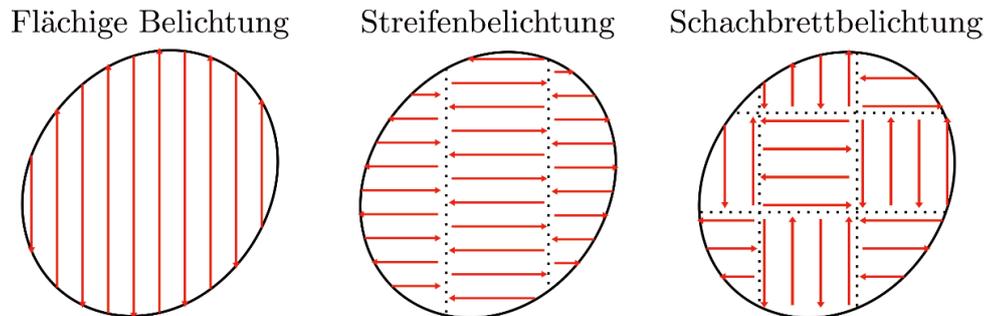


Abbildung 2-5: Mögliche Belichtungsstrategien im PBF-LB/M Prozess – eigene Darstellung nach (Klahn 2015)

2.1.4 Defekte beim PBF-LB/M Prozess

Viele der Prozessparameter sind nicht regelbar, was zu einer starken stochastischen Verteilung der Prozessergebnisse führt. Weiterhin sind noch nicht alle Wechselwirkungen zwischen den Parametern bekannt, was die Stochastik des Prozessergebnisses zusätzlich verstärkt. Bedingt durch die Vielzahl an Prozessparametern und der starken Stochastik treten beim PBF-LB/M Verfahren Defekte auf. Im Wesentlichen treten drei Defektarten auf: das **Balling**, **Risse / Delaminationen** und **Poren / Porosität**. (Eschner et al. 2018)

Durch die Oberflächenspannung des Schmelzbades kann es vorkommen, dass sich das Schmelzbad zu unregelmäßigen Kugeln verformt. Dies wird **Balling** genannt. Die Kugelform entsteht, da sie den Zustand mit der geringsten Oberflächenenergie darstellt. Balling ist einem zu geringen Energieeintrag im Prozess geschuldet und führt dazu, dass keine zusammenhängende Schmelzspur gebildet wird. Dies wiederum kann in folgenden Schichten die Bildung von Porosität fördern. (Yadroitsev et al. 2010; Zhang et al. 2017)

Thermische Spannungen, die durch hohe Temperaturgradienten innerhalb des Bauteils hervorgerufen werden, können **Risse** verursachen und deren Ausbreitung begünstigen. Die mechanischen Eigenschaften des Bauteils verschlechtern sich und es kann zur **Delamination** oder dem Versagen unter Last kommen. (Cain et al. 2015; Zhang et al. 2017)

Die vorliegende Arbeit befasst sich mit dem Defektyp Porosität, weshalb dieser im Fokus des Kapitels liegt.

2.1.4.1 Entstehung von Porosität

Poren im PBF-LB/M Verfahren lassen sich in zwei grundlegende Porenarten einteilen: Gasporen und Fusionsporen.

Gasporen sind Poren, welche durch einen zu hohen volumetrischen Energieeintrag entstehen. Dabei verdampfen Legierungsanteile des Pulvers und hinterlassen eine kleine, vorwiegend runde Pore. Die typische Größe von Gasporen liegt zwischen 20 μm und 50 μm . (Everton et al. 2016; Hu et al. 2017)

Fusionsporen, auch *Lack-of-Fusion* Poren genannt, sind Bereiche mit unzureichendem volumetrischem Energieeintrag. In diesen Bereichen wird das Pulver nicht komplett aufgeschmolzen, sodass durch angesinterte Pulverteilchen größere, teilweise noch mit Pulver gefüllte, scharfkantige Poren entstehen. Fusionsporen sind typischerweise größer als 50 μm . (Hu et al. 2017)

Die Gesamtheit aller Poren in einem Bauteil wird als Porosität bezeichnet. Dabei wird üblicherweise das Gesamtvolumen aller Poren summiert und ins prozentuale Verhältnis zum Bauteilvolumen im porenfreien Zustand gesetzt.

2.1.4.2 Einfluss der Porosität auf die mechanischen Eigenschaften von Bauteilen

Der Einfluss von Porosität auf die mechanischen Eigenschaften soll anhand der Zugfestigkeit betrachtet werden, da diese den einfachsten Belastungsfall darstellt. Die Zugfestigkeit R_m eines Bauteils hängt von der Zugfestigkeit $R_m^{P=0}$ im porenfreien Zustand, der Zerklüftung s der Poren sowie der Porosität P ab (vgl. Formel 2-2). (Rehse et al. 2013; Rehse et al. 2016; Stroppe 2000)

$$R_m = R_m^{P=0} * (1 - s * P) \text{ [MPa]} \quad \text{Formel 2-2}$$

Aus Formel 2-2 ist erkennbar, dass neben der Porosität auch die Zerklüftung, also die Form der Poren, von maßgeblicher Bedeutung für eine Aussage über das mechanische Verhalten im jeweiligen Lastfall ist. Der Kehrwert der Zerklüftung wird auch als Zirkularität $C_{\text{Pore}} = 1/s$ bezeichnet. Die Zerklüftung s lässt sich für den dreidimensionalen Fall aus dem Verhältnis der realen Porenoberfläche zur Oberfläche einer idealen Kugel mit gleichem Volumen der Pore bestimmen. In Abbildung 2-6 sind verschiedene Zerklüftungen von Poren schematisch dargestellt.

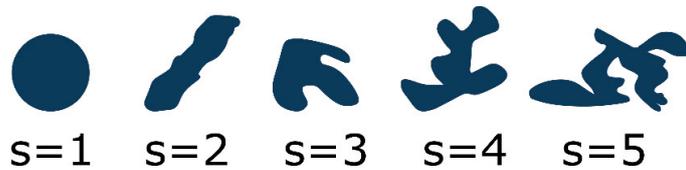


Abbildung 2-6: Anschauliche Darstellung der Zerklüftung s von Poren – eigene Darstellung nach (Rehse et al. 2016)

In Abbildung 2-7 ist der Einfluss der Zerklüftung und der Porosität auf die Zugfestigkeit von Edelstahl 316L dargestellt. Dieser besitzt im porenfreien Zustand eine Zugfestigkeit $R_m^{P=0}$ von 640 MPa. Bei einer Zerklüftung von $s=4$ und nur 2 % Porosität fällt die Zugfestigkeit auf etwa 589 MPa ab.

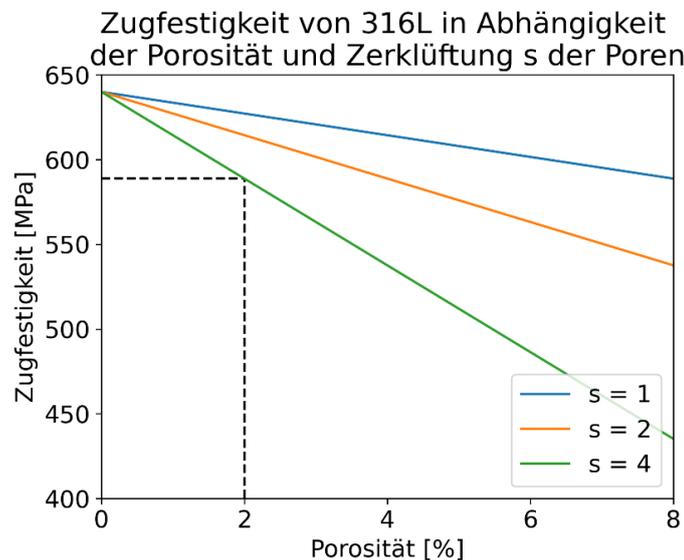


Abbildung 2-7: Zugfestigkeit von 316L in Abhängigkeit der Porosität und Zerklüftung s der Poren – eigene Darstellung

Dies verdeutlicht den wesentlichen Einfluss, welchen die Porosität auf die mechanischen Eigenschaften eines Bauteils hat. Erfolgt statt einer statischen eine dynamische Belastung, ist dieser Einfluss noch stärker ausgeprägt (Yang et al. 2019).

Um eine Aussage über die mechanischen Eigenschaften in einem komplexen Spannungsfall bei realen Bauteilen treffen zu können, muss weiterhin die Lage der vorhandenen Porosität bekannt sein. Liegen in einem Bereich des Bauteils Druckspannungen im angedachten Einsatzfall vor, so kann in diesem Bereich höhere Porosität akzeptiert werden, während in Bereichen mit Zugspannungen die Porosität zu einer erheblichen Spannungsüberhöhung durch die Kerbwirkung führt und somit einen stärkeren Einfluss auf die mechanischen Eigenschaften hat. (Du Plessis et al. 2020)

2.2 Produktionsintegrierte Messtechnik

Nach (Lanza et al. 2019) können Qualitätssicherungssysteme in einen Qualitätsregelkreis eingeordnet werden. Solch ein Qualitätsregelkreis ist in Abbildung 2-8 dargestellt.

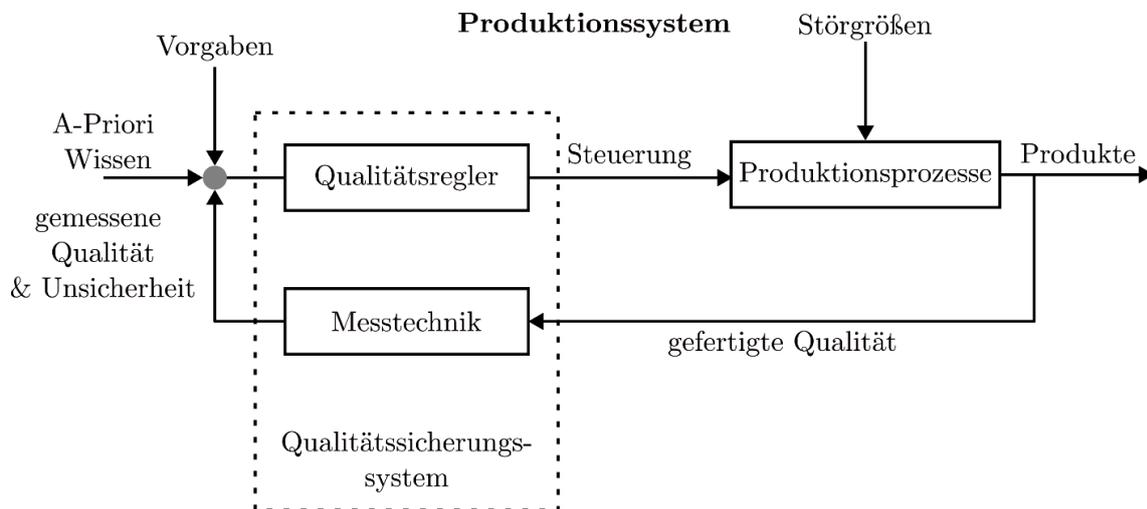


Abbildung 2-8: Qualitätssicherungssystem im Qualitätsregelkreis – eigene Darstellung nach (Lanza et al. 2019)

Die Aufgabe der Messtechnik besteht in der Erfassung der momentan gefertigten Qualität. Nach (Lanza et al. 2019) kann die Messtechnik weiterführend in Sensor und Datenanalyse untergliedert werden. Dabei werden vier Ebenen von Integrationsgraden unterschieden. Eine Übersicht der möglichen Integrationsgrade nach (Lanza et al. 2019) ist in Abbildung 2-9 dargestellt.

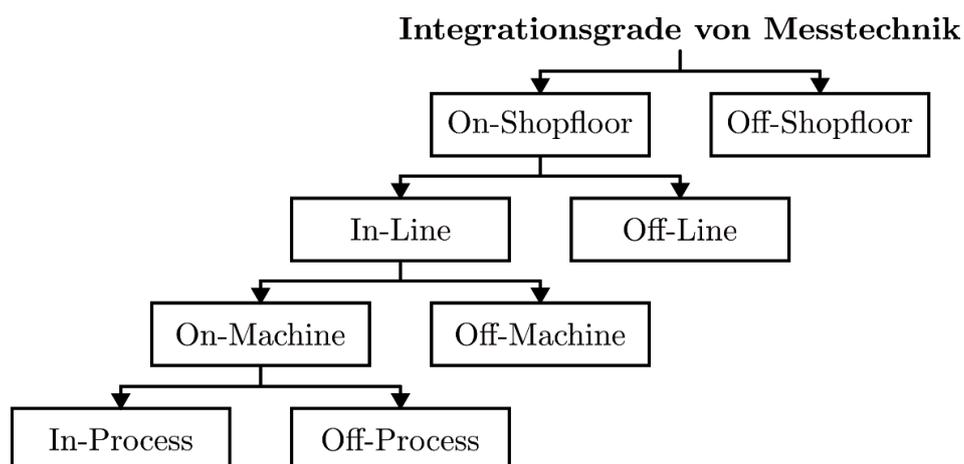


Abbildung 2-9: Schematische Darstellung der Integrationsgrade von Messtechnik - eigene Darstellung nach (Lanza et al. 2019)

Off-Shopfloor umfasst Messtechniken, die räumlich getrennt von der Produktion eingesetzt werden. Dies kann beispielweise Messtechnik in einem separaten Messraum sein. *On-Shopfloor* umfasst Messtechniken, welche ohne räumliche Trennung zur Produktion genutzt werden. Diese lassen sich wiederum in *In-Line* und *Off-Line* einteilen. *Off-Line* Messtechniken sind nicht in der Produktionslinie eingebunden, sondern befinden sich lediglich in deren räumlichen Nähe. *In-Line* Messtechniken sind in die Produktionslinie eingebunden. Dabei lässt sich wiederum zwischen *On-Machine* und *Off-Machine* unterscheiden. *Off-Machine* Messtechniken stellen eine separate Messstation in der Linie dar, während *On-Machine* Messtechniken in eine Produktionsanlage integriert sind. Die abschließende Unterscheidung von *On-Machine* in *In-Process* und *Off-Process* erfolgt dabei über die Entscheidung, ob die Messung hauptzeitparallel ausgeführt wird (*In-Process*) oder nicht (*Off-Process*). Je höher der Integrationsgrad einer Messtechnik ist, desto weniger Totzeit ist im Qualitätsregelkreis enthalten und das Qualitätssicherungssystem kann schneller auf Abweichungen und Störungen reagieren. Aus diesem Grund ist die in-process Messtechnik zu bevorzugen.

Neben der schnelleren Reaktion bietet in-process Messtechnik auch wirtschaftliche Vorteile. In Abbildung 2-10 ist das finanzielle Einsparpotential gegenüber einer End-of-Line Qualitätssicherung durch eine möglichst frühe Defekterkennung mit einer in-process Prozessüberwachung dargestellt. Dabei sind die Kosten im Fall der End-of-Line Qualitätssicherung während des Prozesses geringer, dafür fallen für diese am Ende des Prozesses gesteigerte Kosten an. Das Einsparpotential durch eine in-process Prozessüberwachung resultiert aus der frühen Erkennung von Defekten, mit der Möglichkeit den Prozess abubrechen oder korrigierend gegenzusteuern. (Lanza et al. 2019; Schmidt & Damm 2008)

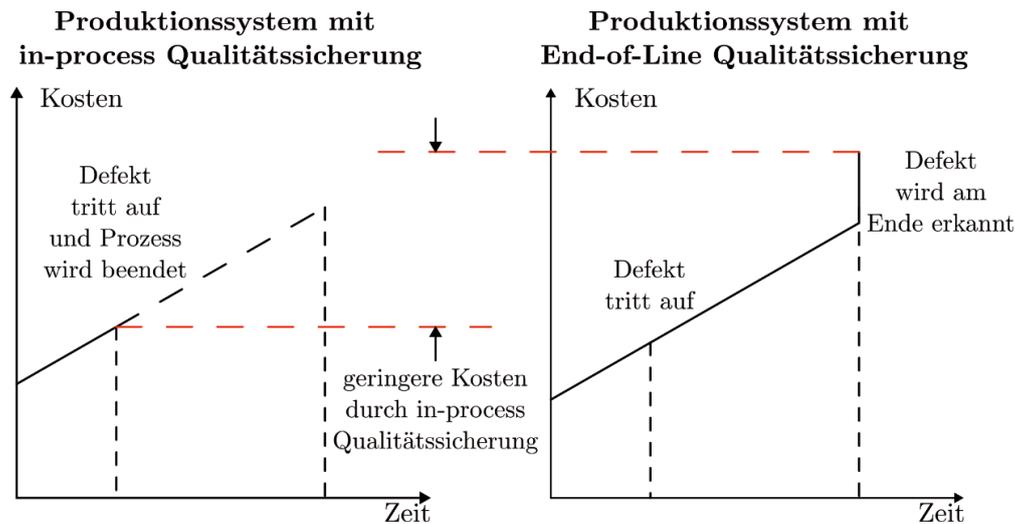


Abbildung 2-10: Kosteneinsparung durch in-process Qualitätssicherung – eigene Darstellung nach (Lanza et al. 2019; Schmidt & Damm 2008)

2.3 Sensorik

In Kapitel 2.2 wurde gezeigt, dass sich die Messtechnik in einem Qualitätssicherungssystem in die Aspekte Sensor und Datenanalyse untergliedern lässt. In diesem Kapitel wird als erstes in Kapitel 2.3.1 Sensorik grundlegend vorgestellt. Nachfolgend werden in Kapitel 2.3.3 und 2.3.2 die im Rahmen dieser Arbeit verwendeten Sensorprinzipien vorgestellt. Die ausführliche Begründung zur Auswahl der vorgestellten Sensorprinzipien erfolgt in Kapitel 5.2.

2.3.1 Grundlagen Sensorik

Der von (Lanza et al. 2019) genutzte Begriff Sensorik stellt in der Mess- und Regelungstechnik üblicherweise eine gesamte Messkette dar. Eine Messkette besteht dabei aus Messgliedern und Hilfsgeräten, welche die Aufgaben Messgrößenaufnahme, Messsignalverarbeitung und Messwertausgabe durchführen (Czichos & Daum 2020). In Abbildung 2-11 ist eine Messkette schematisch dargestellt.



Abbildung 2-11: Schematische Darstellung einer Messkette – eigene Darstellung nach (Czichos & Daum 2020)

Nach (Czichos & Daum 2020) stellen Sensoren Messwertaufnehmer dar, welche zur Gewinnung von Informationen über Messobjekte bedeutsame Eingangssignale aufnehmen und diese in ein meist elektrisches Ausgangssignal überführen. Dabei ist von besonderer Bedeutung, dass Messwerte durch eine durchgängige Kette auf Vergleichsmessungen mit bekannten Messunsicherheiten rückgeführt werden können. Dabei wird von der *messtechnischen Rückführung* gesprochen. Zur Erfassung der Eingangssignale und Umwandlung in Ausgangsgrößen können verschiedene Prinzipien genutzt werden. Diese können mechanisch, thermisch, elektrisch, magnetisch oder optisch sein. Dazu werden diverse physikalische Effekte und Prinzipien zur Wandlung genutzt.

Die größte Anzahl der Sensoriken, die im Stand der Forschung und Technik zur Erfassung von Porosität genutzt wird, basiert auf optischen Eingangsgrößen. Durch den Photoeffekt werden diese in ein elektrisches Signal gewandelt. Diese werden in Kapitel 2.3.2 zusammengefasst als *optische Sensorik* vorgestellt. Quantitativ auf dem nachfolgenden Platz befindet sich *akustische Sensorik*, welche ein mechanisches Eingangssignal durch den Piezoeffekt in ein elektrisches Ausgangssignal wandelt.

2.3.2 Optische Sensorik

Optische Sensorik erfüllt die Funktion eines Photodetektors. Dieser dient zur Detektion von Photonen. Photodetektoren werden in Quantendetektoren oder thermische Detektoren unterteilt. (Heering 2004)

Quantendetektoren setzen Elektronen frei oder erzeugen Elektronenlöcher. Das Detektorsignal weist eine Proportionalität zur Photonenrate auf. Quantendetektoren liegt der Photoeffekt (auch photoelektrischer Effekt) zugrunde. Dieser wandelt Photonen in ein elektrisches Signal um. Es existieren drei Arten des photoelektrischen Effekts: (I) der innere photoelektrische Effekt beschreibt die Steigerung der elektrischen Leitfähigkeit in Halbleitern bei Bestrahlung; (II) beim äußeren photoelektrischen Effekt werden Elektronen durch Bestrahlung aus Halbleitern oder Metallen herausgelöst und (III) die Photoionisation beschreibt die Ionisation von Molekülen oder Atomen durch ausreichend hochfrequente Strahlung. (Klassen 2011) Zur Prozessüberwachung des PBF-LB/M Fertigungsverfahrens kommen die nachfolgenden Quantendetektoren zum Einsatz.

Fotodioden nutzen den inneren Photoeffekt. Je nach verwendetem Halbleitermaterial (bspw. Silizium, Germanium oder Indium-Gallium-Arsenid) weist eine Fotodiode einen anderen empfindlichen Wellenlängenbereich auf. **CCD-Sensoren** (engl. *charge-coupled device*) basieren auf dem inneren Photoeffekt. Aufgebaut sind diese aus einem Array an Fotodioden. **CMOS-Sensoren** (engl. *complementary metal-oxide-semiconductor*) bestehen ebenfalls aus einem Array an Fotodioden, enthalten aber eine integrierte Verstärkerschaltung für diese. CCD-Sensoren und CMOS-Sensoren werden üblicherweise in Kameras, wie z.B. Hochgeschwindigkeitskameras verbaut. (Fossum & Hondongwa 2014) Optische **Spektrometer** sind entweder als Absorptions- oder Emissionsspektrometer ausgeführt. Dabei können neben Fotodioden auch **Fotokathoden** eingesetzt werden. Diese basieren auf dem äußeren photoelektrischen Effekt. (Avrutsky et al. 2006; O’Keefe & Deacon 1988)

Bei thermischen Detektoren erhöht sich die Detektortemperatur durch einfallende Photonen proportional zur Strahlungsleistung. **Bolometer** basieren auf Bolometer-Effekt, bei welchem eine Widerstandsänderung proportional zur Temperaturerhöhung der absorbierten Strahlung auftritt. (Jones 1953)

2.3.3 Akustische Sensorik

Akustische Sensorik wandelt ein mechanisches Eingangssignal (Schallwellen) durch den Piezoeffekt in ein elektrisches Ausgangssignal. Die messtechnische Erfassung von Schallwellen kann unter anderem durch Piezokeramiken erfolgen. Diese haben die Eigenschaft, dass sie bei einer Verformung aufgrund einer Ladungsverschiebung eine elektrische Spannung aufbauen. Dies wird als direkter piezoelektrischer Effekt bezeichnet. Diese aufgebaute elektrische Spannung kann gemessen werden und hat einen definierten Zusammenhang zur Verformung. Beim inversen piezoelektrischen Effekt kann durch das Anlegen einer Spannung eine Verformung der Piezokeramik erzeugt werden. Auf diese Weise können mit einer hochfrequenten Wechselspannung Ultraschallwellen erzeugt werden. (Martin 1972)

Werden Schallwellen durch ein gasförmiges Medium übertragen, so wird von Luftschall gesprochen. Erfolgt die Übertragung nicht durch ein gasförmiges Medium, sondern durch einen Festkörper, so wird dieser Schall als Körperschall bezeichnet. Im Gegensatz zu gasförmigen Medien umfasst Körperschall Longitudinal- und Transversalwellen. Dies ist bedingt durch die Tatsache, dass Festkörper neben Normalspannungen auch

Schubspannungen übertragen können. Im Vergleich zum Luftschall findet bei Körperschall eine deutlich geringere Dämpfung von höherfrequenten Signalanteilen statt und die Schallgeschwindigkeit liegt um ein Vielfaches höher. (Demtröder 2015)

2.4 Datenanalyse

In Kapitel 2.2 erfolgte die Untergliederung von Messtechnik in die Punkte Sensor und Datenanalyse. Nach der Darlegung der Grundlagen zu Sensorik in Kapitel 2.3 erfolgt in diesem Kapitel die Vorstellung der relevanten Grundlagen zum Punkt Datenanalyse. Dabei werden in Kapitel 2.4.1 Arten der Modellbildung vorgestellt. Kapitel 2.4.2 widmet sich den Ansätzen der Datenvorverarbeitung, wie sie im Rahmen der vorliegenden Arbeit genutzt werden. In Kapitel 2.4.3 werden die Grundlagen für künstliche neuronale Netze gelegt. Abschließend werden in Kapitel 2.4.4 Metriken zur Bewertung der Modellgüte vorgestellt.

2.4.1 Modellbildung

Zunächst werden zwei grundlegende Arten der Modellbildung vorgestellt: die *physikalische Modellbildung* und die *datengetriebene Modellbildung*.

2.4.1.1 Physikalische Modellbildung

Bei der physikalischen Modellbildung werden physikalische Zusammenhänge ausgenutzt, um ein Modell zur Systembeschreibung zu erstellen. Durch die Verknüpfung von mehreren Modellen können auch komplexere Zusammenhänge abgebildet werden. Die Validierung von Modellen auf Basis der physikalischen Modellbildung erfolgt in der Regel auf Basis empirischer Experimente. (Trächtler & Gausemeier 2018)

2.4.1.2 Datengetriebene Modellbildung

Im Gegensatz zur physikalischen Modellbildung wird bei der datengetriebenen Modellbildung die Suche nach mathematischen Zusammenhängen auf Basis einer experimentell erstellten Datenmenge durchgeführt. Diese Art der Modellbildung bietet sich an, wenn es für die gesuchten Zusammenhänge noch keine etablierten physikalischen Modelle gibt oder die Zusammenhänge eine besonders hohe Komplexität aufweisen. (Trächtler & Gausemeier 2018)

2.4.2 Datenvorverarbeitung

Das Extrahieren von neuen Einzelmerkmalen aus vorhandenen Daten wird **Merkmalsextraktion** genannt. Viele Verfahren im Bereich der künstlichen neuronalen Netze arbeiten nicht zufriedenstellend direkt auf Zeitreihendaten. Dies ist in der Anzahl der Datenpunkte begründet: Zeitreihen müssen mindestens mit der *Nyquist-Frequenz* abgetastet werden, um nach dem *Nyquist-Shannon-Abtasttheorem* exakt rekonstruiert werden zu können. Die hohe Anzahl an Datenpunkte würde in einer hohen Anzahl an Modellparametern der künstlichen neuronalen Netze resultieren, was wiederum zu längeren Trainingszeiten und einer reduzierten Konvergenz der Modelle führen würde. Aus diesem Grund werden oftmals Einzelmerkmale für das Training von künstlichen neuronalen Netzen verwendet, was die Durchführung einer Merkmalsextraktion notwendig macht. Versteckte Zusammenhänge in den Daten werden durch eine geeignete Merkmalsextraktion erkennbar und nutzbar gemacht. Bei der **MerkmalsTransformation** wird der Merkmalsraum reduziert, während ein möglichst hoher Informationsgehalt bewahrt wird. Dazu werden meist Projektionsverfahren genutzt, die höherdimensionale Merkmalsräume mittels einer Transformationsmatrix auf einen niederdimensionalen Merkmalsraum abbilden. (Lerner et al. 1999)

In den folgenden zwei Kapiteln werden die beiden im Rahmen dieser Arbeit angewandten Ansätze, die Fourier-Transformation als Merkmalsextraktion und die Hauptkomponentenanalyse als MerkmalsTransformation, vorgestellt.

2.4.2.1 Fourier-Transformation

Die Fourier-Transformation überführt ein Signal aus dem Zeitbereich in den Frequenzbereich. Die diskrete Fourier-Transformation (DFT) ist dabei auf Zeitreihen anwendbar, die in abgetasteter, diskreter Form vorliegen. Dabei wird ein Signal in seine reinen Sinusschwingungen zerlegt, sodass die Amplitude der Frequenzanteile (Realteil der Fourier-Transformation) dem Betrag nach und die Phase (Imaginärteil der Fourier-Transformation) des Signals bestimmt werden können. (Nussbaumer 1981)

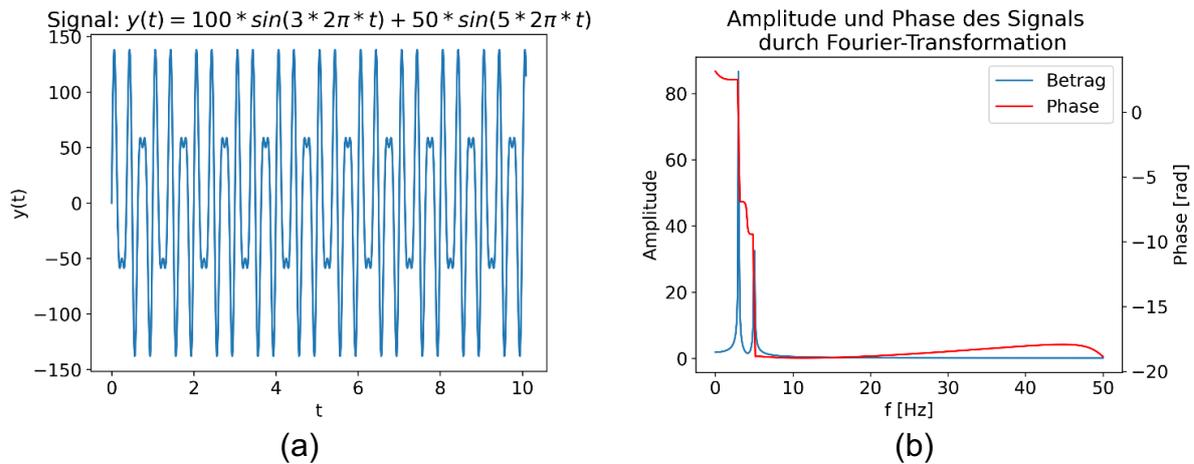


Abbildung 2-12: Beispielhaftes Signal (a) sowie Realteil der Fourier-Transformation des Signals (b)

Die schnelle Fourier-Transformation (engl. *fast Fourier transform* - FFT) ist eine Möglichkeit, die DFT effizient zu berechnen. Voraussetzung dabei ist, dass die Daten eine Länge von 2^n , $n \in \mathbb{Z}$ haben. (Nussbaumer 1981)

Die Kurzzeit-Fourier-Transformation (engl. *short time Fourier transform* - STFT) wird genutzt, um den zeitlichen Verlauf der Frequenzanteile eines Signals darzustellen. Dazu wird das zu betrachtende Signal in viele Abschnitte zerlegt, mit einer Fensterfunktion belegt und danach die FFT für jeden dieser Abschnitte berechnet. Die Darstellung erfolgt üblicherweise als zweidimensionales Spektrogramm, bei dem der zeitliche Verlauf auf der Abszisse und die Frequenzanteile auf der Ordinate aufgetragen sind. Die Amplitude wird über eine Farbskala dargestellt. Die Zeit- und Frequenzauflösung kann nicht unabhängig voneinander angepasst werden. In Formel 2-3 ist der Zusammenhang zwischen der Frequenzauflösung Δf , der Abtastrate f_s und der Zeitauflösung (ausgedrückt über die Anzahl der Datenpunkte N_t je betrachtetem Abschnitt) dargestellt. (Durak & Arikan 2003)

$$\Delta f = \frac{f_s}{N_t} \quad \text{Formel 2-3}$$

Die Abtastrate f_s ist für einen gegebenen Sensor als konstant anzusehen, da sie in der Regel während einer Messung nicht verändert wird. Es zeigt sich somit, dass bei einer Zunahme der Frequenzauflösung Δf die Zeitauflösung N_t geringer wird.

2.4.2.2 Hauptkomponentenanalyse

Die Hauptkomponentenanalyse (engl. *principal component analysis* - PCA) ist eine Merkmalstransformation, bei der die Transformation in einen niedrigerdimensionalen

Merkmalsraum mit einem möglichst guten Erhalt der Streuung (auch: Varianz) einhergehen soll. Bei der Hauptkomponentenanalyse wird eine Transformationsmatrix T bestimmt, die die Merkmale der Rohdaten M_{roh} in ein neues Koordinatensystem überführt, in welchem die transformierten Merkmale M_{trans} möglichst unkorreliert sind (vgl. dazu auch Formel 2-4). Jede Hauptkomponente stellt dabei einen Eigenvektor dar. (Abdi & Williams 2010)

$$M_{trans} = TM_{roh} \quad \text{Formel 2-4}$$

Die Varianz var ist ein statistisches Maß dafür, wie viel Variation in einem Datensatz auf jede der durch die Hauptkomponentenanalyse erzeugten Hauptkomponenten (Eigenvektoren) zurückgeführt werden kann. Die Varianz einer Hauptkomponente errechnet sich aus dem Verhältnis des Eigenwertes der Hauptkomponente zur Summe der der Eigenwerte aller Hauptkomponenten (vgl. Formel 2-5). (Bro & Smilde 2014)

$$var_i = \frac{\lambda_i}{\sum_{j=1}^n \lambda_j} \quad \text{Formel 2-5}$$

Die Hauptkomponenten können anhand ihrer Varianz in absteigender Wichtigkeit sortiert werden. Je weniger Varianz eine Hauptkomponente ausdrückt, desto unwichtiger ist diese. Die kumulierte Varianz var_{Σ} ist die summierte Varianz, welche alle betrachteten Hauptkomponenten insgesamt ausdrücken. (Bro & Smilde 2014)

$$var_{\Sigma} = \sum_{i=1}^n var_i \quad \text{Formel 2-6}$$

2.4.3 Künstliche Neuronale Netze

Künstliche neuronale Netze (KNN) sind eine Möglichkeit, die in Kapitel 2.4.1.2 vorgestellte datengetriebene Modellbildung zu realisieren. Die grundlegende Funktionsweise eines künstlichen neuronalen Netzes zeichnet sich dadurch aus, dass Eingangsdaten schichtweise mithilfe von künstlichen Neuronen mit lernbaren Gewichten verarbeitet und schließlich als Ausgang ausgegeben werden. Sie bestehen aus einer Vielzahl von schichtweise miteinander verbundenen künstlichen Neuronen. Dabei werden die Eingänge eines Neurons gewichtet summiert und ggf. noch ein konstantes Bias addiert. Danach wird der Wert an eine Aktivierungsfunktion übergeben. (Krogh 2008) In Abbildung 2-13 ist der vorgestellte Aufbau eines künstlichen Neurons schematisch dargestellt.

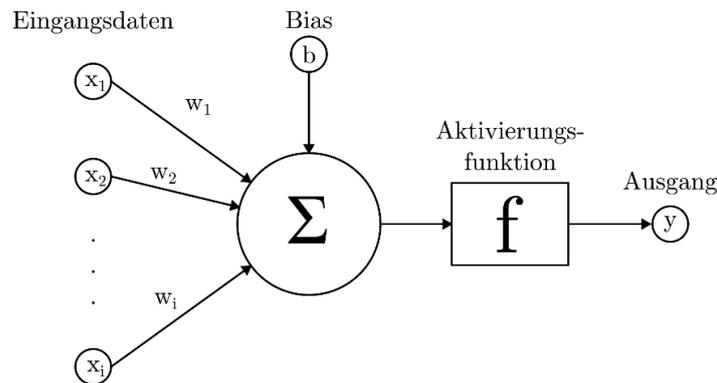


Abbildung 2-13: Schematischer Aufbau eines künstlichen Neurons mit Gewichten w_i , Bias b und Aktivierungsfunktion f – eigene Darstellung nach (Krogh 2008)

Ein einfaches künstliches neuronales Netz stellt das *Multi-Layer-Perzeptron* dar. Ein weit verbreitetes künstliches neuronales Netz ist das *Convolutional Neural Network* (CNN). Beide Arten werden in der Folge vorgestellt.

2.4.3.1 Multi-Layer-Perzeptron (MLP)

Das *Multi-Layer-Perzeptron* ist ein *Feed-Forward* Netz, welches aus einer Eingabeschicht (engl. *input*), einer oder mehrerer verdeckten Schichten (engl. *hidden layers*) und einer Ausgabeschicht (engl. *output*) besteht. (Ramchoun et al. 2016) Bei der Erstellung eines MLPs müssen die folgenden Strukturentscheidungen für die Topologie des Netzwerkes getroffen werden (Gardner & Dorling 1998):

- Anzahl der Neuronen in einer Schicht
- Anzahl der verdeckten Schichten
- Art der verwendeten Aktivierungsfunktion
- Anzahl und Lage im Netz von besonderen Schichten wie *Dropout*³
- Art der Vorhersage: Klassifikation oder Regression
- Verwendete Verlustfunktion zur Bewertung der Modellabweichung
- Verwendeter Optimierer zur Minimierung der Verlustfunktion
- Verwendete Metriken als Nebenbedingung für Optimierung

Zusätzlich zu den Strukturentscheidungen müssen die Hyperparameter für das sogenannte Training des Netzes, bei welchem eine Anpassung der Gewichte erfolgt, für die zuvor ausgewählte Topologie optimiert werden. Die **Lernrate** (engl. *learning rate*) gibt

³ Dropout-Schichten deaktivieren mit einer gewissen Wahrscheinlichkeit ein Neuron und beugen so einer Überanpassung des Modells vor.

die Schrittweite des Optimierers an. Die verwendeten Optimierer sind in der Regel gradientenbasierte Verfahren zur Bestimmung des Minimums einer Verlustfunktion. Das sog. **learning rate decay** beschreibt die zunehmende Abnahme der Lernrate mit Fortschreiten des Modelltrainings. Der **Dropout-Faktor** gibt die Wahrscheinlichkeit an, mit der eine Dropout-Schicht ein Neuron inaktiv schaltet. Der **L2-Faktor** beschreibt einen Regularisierungsterm, welcher der Verlustfunktion angehängt wird und so eine Überanpassung des Modells verhindern soll. (Gardner & Dorling 1998)

Beim Einsatz des MLP zur Klassifikation wird in der Ausgabeschicht die Wahrscheinlichkeit für das Vorliegen einer Klasse ausgegeben, während beim Einsatz zur Regression ein numerischer Vorhersagewert ausgegeben wird.

2.4.3.2 Convolutional Neural Networks (CNN)

Convolutional Neural Networks sind künstliche neuronale Netze, welche auf der mathematischen Operation der Faltung (engl. *convolution*) beruhen. (Albawi et al. 2017) Im Gegensatz zu MLPs kommen beim CNN Faltungsschichten sowie sogenannte *Pooling Layer* zum Einsatz. In den Faltungsschichten wird eine Faltungsmatrix (auch: *Kernel*) über die Eingabematrix bewegt und führt so die diskrete Faltung durch (vgl. auch Abbildung 2-14). (Albawi et al. 2017)

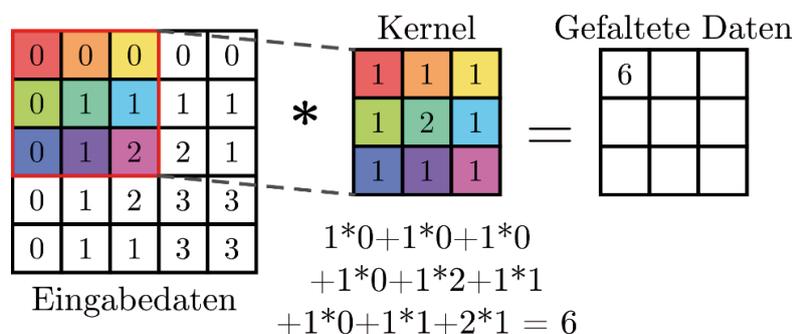


Abbildung 2-14: Beispielhafte Faltungsoperation in einer Faltungsschicht bei einem CNN mit einem 3x3 Kernel – eigene Darstellung nach (Albawi et al. 2017)

Die *Pooling Layer* sorgen für eine Dimensionsreduktion der Daten, in dem durch das überwiegend angewandte *Max Pooling* die Maximalwerte eines zu definierenden Bereichs extrahiert und weiterverwendet werden (vgl. auch Abbildung 2-15). (Albawi et al. 2017)

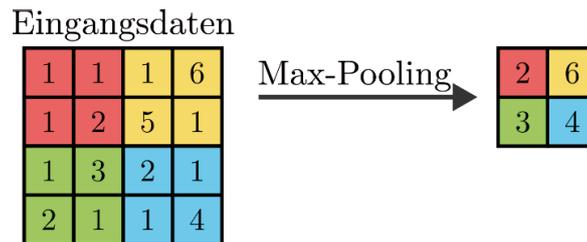


Abbildung 2-15: Beispielhafte Anwendung einer 2x2 Max-Pooling Operation bei einem CNN – eigene Darstellung nach (Albawi et al. 2017)

Abgeschlossen wird die Topologie eines CNNs häufig mit nachgeschalteten vollvernetzten Schichten wie beim MLP. Hier erfolgt wie beim MLP die Ausgabe als Wahrscheinlichkeit für das Vorliegen einer Klasse im Klassifikationsfall oder als numerischer Wert bei der Regression. Ein Vorteil des CNN gegenüber MLP ist die Möglichkeit, Inputdaten mit variierender Größe verarbeiten zu können, während bei MLP der Eingangsvektor eine feste Länge haben muss. Weiterhin sind CNNs in der Lage, durch die Faltungsoperation auch die Struktur der Daten besser zu erfassen. (Gu et al. 2018; O'Shea & Nash 2015)

2.4.4 Metriken zur Bewertung der Modellgüte

Zur Bewertung der Modellgüte von künstlichen neuronalen Netzen werden diverse Metriken verwendet. Nachfolgend werden Metriken zur Bewertung von Klassifikations- und Regressionsmodellen vorgestellt.

2.4.4.1 Konfusionsmatrix

Die Konfusionsmatrix wird genutzt, um Klassifikationsergebnisse anschaulich darzustellen (vgl. Abbildung 2-16). Bei dieser wird die tatsächliche Klasse gegen die vorhergesagte Klasse aufgetragen. In der entstehenden Matrix sind korrekte Vorhersagen auf der Spur zu finden (auch *True Negative* – TN und *True Positive* – TP bezeichnet). Der Fehler erster Ordnung liegt vor, wenn Klasse 0 fälschlicherweise als Klasse 1 vorhergesagt wird (auch als *false positive* – FP bezeichnet). Ein Fehler zweiter Ordnung ist dann vorzufinden, wenn Klasse 1 fehlerhaft als Klasse 0 vorhergesagt wird (auch als *false negative* – FN bezeichnet). Aus den Verhältnissen von TN, TP, FP und FN können weitere Metriken abgeleitet werden. (Luque et al. 2019)

		Vorhergesagte Klasse	
		Negativ (0)	Positiv (1)
Tatsächliche Klasse	Negativ (0)	True Negative (TN)	False Positive (FP)
	Positiv (1)	False Negative (FN)	True Positive (TP)

Abbildung 2-16: Konfusionsmatrix mit Fehler erster Ordnung (FP) und Fehler zweiter Ordnung (FN) – eigene Darstellung nach (Luque et al. 2019)

Die Genauigkeit (engl. *precision*) stellt ein Maß für den Fehler erster Ordnung dar und bestimmt den Anteil korrekt positiver Klassifikationen an der Menge der gesamten positiven Klassifikationen (vgl. Formel 2-7). (Luque et al. 2019)

$$\text{Genauigkeit} = \frac{TP}{TP + FP} \quad \text{Formel 2-7}$$

Die Sensitivität (engl. *recall* oder *true positive rate*) stellt hingegen ein Maß für den Fehler zweiter Ordnung dar und bestimmt den Anteil korrekt positiver Klassifikationen an der Menge der tatsächlich positiven Datenmenge (vgl. Formel 2-8). (Luque et al. 2019)

$$\text{Sensitivität} = \frac{TP}{TP + FN} \quad \text{Formel 2-8}$$

2.4.4.2 F1-Score

Der F1-Score setzt den Fehler erster Ordnung in einem Verhältnis zum Fehler zweiter Ordnung. Dazu wird das harmonische Mittel von Sensitivität und Spezifität gebildet (vgl. Formel 2-9). (Luque et al. 2019)

$$F1 = \frac{2 * \text{Genauigkeit} * \text{Sensitivität}}{\text{Genauigkeit} + \text{Sensitivität}} \quad \text{Formel 2-9}$$

Der F1-Score ist im Intervall [0, 1] definiert und erreicht im Idealfall den Wert 1. Damit der F1-Score aussagekräftig ist, sollten die Klassen möglichst gleich verteilt sein. Bei unausgeglichenen Klassengrößen verliert der F1-Score an Aussagekraft. (Luque et al. 2019)

2.4.4.3 Phi-Koeffizient / Matthews Correlation Coefficient

Eine alternative Metrik, welche bei unausgeglichenen Klassengrößen besser zur Bewertung der Modellgüte geeignet ist als der F1-Score, ist der Phi-Koeffizient. Im Fall einer binären Klassifikation wird auch dieser auch *Matthews Correlation Coefficient* (MCC) genannt. Der MCC kann nach Formel 2-10 direkt aus der Konfusionsmatrix berechnet werden. (Chicco & Jurman 2020; Luque et al. 2019)

$$MCC = \frac{TP * TN + FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad \text{Formel 2-10}$$

Der MCC ist im Intervall [-1, 1] definiert. Ein Wert von 1 stellt eine perfekte Modellgüte dar, ein Wert von 0 stellt eine rein zufällige Vorhersage dar und ein Wert von -1 eine gegensätzliche Abweichung zwischen Vorhersage des Modells und tatsächlicher Beobachtung. (Chicco & Jurman 2020)

2.4.4.4 ROC-Kurve

Die *Receiver-Operator-Characteristics*-Kurve (ROC-Kurve) wird zur Bewertung und Optimierung der Trennschärfe von Klassifikationsmodellen verwendet. Neben der Sensitivität wird noch die Falsch-Positiv-Rate FPR (auch engl. *fall-out* genannt) benötigt, die sich nach Formel 2-11 berechnen lässt.

$$FPR = \frac{FP}{FP + TN} \quad \text{Formel 2-11}$$

Die ROC-Kurve trägt die Sensitivität eines Modells gegen die Falsch-Positiv-Rate auf. In Abbildung 2-17 ist eine beispielhafte ROC-Kurve dargestellt. Die in grün dargestellte Winkelhalbierende stellt ein Modell dar, bei welchem eine komplett randomisierte Vorhersage erfolgt. Ein perfektes Modell mit idealer Trennschärfe würde bei einer Falsch-Positiv-Rate von 0 eine Sensitivität von 1 aufweisen. Solch ein Modellverhalten stellt die rote Kurve dar. Ein reales, nicht perfektes Modell stellt die blaue Kurve dar. Ein Maß für die Trennschärfe ist die Fläche unter der Kurve (engl. *area under curve* - AUC). Ein perfektes Modell weist einen AUC-Wert von 1 auf, während ein komplett randomisiertes Modell einen AUC-Wert von 0,5 aufweist. (Hoo et al. 2017; Mandrekar 2010)

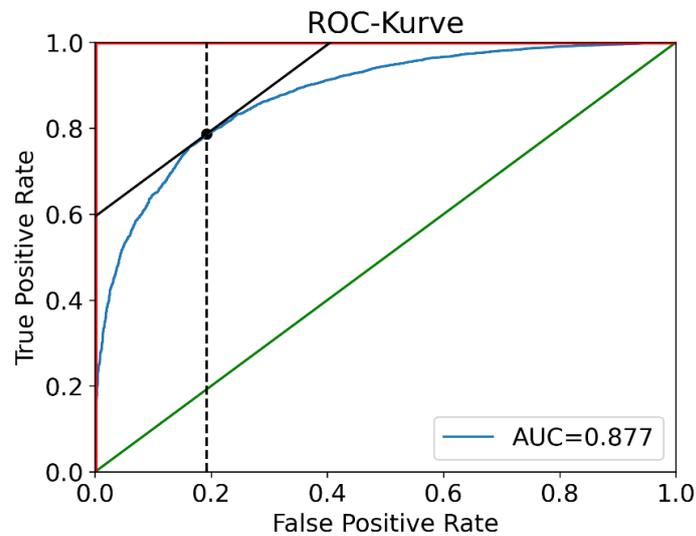


Abbildung 2-17: Exemplarische ROC-Kurve mit realem Modell (blau), perfektem Modell (rot) und zufälligem Modell (grün) – eigene Darstellung nach (Mandrekar 2010)

Mithilfe von ROC-Kurven können Grenzwerte der Modelle zur Trennschärfe optimiert werden. In Kapitel 2.4.3.1 und 2.4.3.2 wurde dargelegt, dass Klassifikationsmodelle eine Wahrscheinlichkeit für die Klassenzugehörigkeit einer Vorhersage ausgeben. Der Schwellwert, ab welcher Wahrscheinlichkeit eine Klassenzuordnung erfolgt, kann mittels einer ROC-Kurve optimiert werden. Der Kontaktpunkt einer Tangente mit der Steigung von 45° an die ROC-Kurve stellt das trennschärfste Modell dar, da dieser Punkt am nächsten zum Punkt des perfekten Modells bei (0, 1) liegt. In Abbildung 2-17 ist der Kontaktpunkt und die Tangente schwarz dargestellt. Im dargestellten Fall erreicht das Modell eine bessere Trennschärfe bei der Nutzung einer Klassengrenze von 0,192 gegenüber der Standardgrenze von 0,5. (Hajian-Tilaki 2013)

2.4.4.5 Bestimmtheitsmaß R^2

Zur Bewertung von Regressionsmodellen können die vorherigen Metriken nicht verwendet werden, da diese nur für Klassifikationen geeignet sind. Zur Bewertung einer Regression bietet sich die Kennzahl R^2 (auch Bestimmtheitsmaß genannt) an. Die Berechnung erfolgt nach Formel 2-12 mit dem empirischen Mittelwert $\bar{y} = \frac{1}{n} * \sum_i^n y_i$, der Vorhersage \hat{y}_i und dem wahren Wert y_i . Der R^2 ist im Intervall $[0, 1]$ definiert. Ein Wert von 1 stellt eine perfekte Regression dar. (Helland 1987)

$$R^2 = \frac{\sum_i (\hat{y}_i - \bar{y})^2}{\sum_i (y_i - \bar{y})^2} \quad \text{Formel 2-12}$$

2.4.4.6 Root-Mean-Square Error (RMSE)

Die Quadratwurzel des mittleren quadratischen Fehlers (engl. *root-mean-square error* - RMSE) ist ein weiteres Maß zur Bewertung der Modellgüte von Regressionen. Der mittlere quadratische Fehler (engl. *mean-square error* - MSE) kann nach Formel 2-13 berechnet werden. Dabei stellt n die Anzahl an Vorhersagen dar, y_i den wahren Wert und \hat{y}_i den vorhergesagten Wert. Der RMSE kann nach Formel 2-14 durch die Quadratwurzel des MSE berechnet werden. (Karunasingha 2022; Nevitt & Hancock 2000)

$$MSE = \frac{1}{n} * \sum_{i=1}^n y_i - \hat{y}_i \quad \text{Formel 2-13}$$

$$RMSE = \sqrt{MSE} \quad \text{Formel 2-14}$$

3 Stand der Forschung und Technik

Nachdem in Kapitel 2 die notwendigen Grundlagen zum Verständnis dieser Arbeit aufgezeigt wurden, wird im nachfolgenden Kapitel der aktuelle Stand der Forschung und Technik in Bezug auf Prozessüberwachungsmethoden für Porosität dargestellt. Zuerst werden in Kapitel 3.1 die Anforderungen an eine industrielle Prozessüberwachung für das PBF-LB/M Fertigungsverfahren hergeleitet. In Kapitel 3.2 werden die bestehenden Ansätze zur Prozessüberwachung vorgestellt. Diese werden dabei einmal durch das zugrunde liegende Messprinzip sowie über die Art des Ansatzes (wissenschaftlicher Forschungsansatz in Kapitel 3.2.1 bis 3.2.4 oder industrielle, kommerziell erhältliche Herstellerlösungen in Kapitel 3.2.5) unterschieden. In Kapitel 3.3 erfolgt eine Zusammenfassung der vorgestellten Ansätze mit Bezug auf die in Kapitel 3.1 dargestellten Anforderungen. Das daraus resultierende Forschungsdefizit wird in Kapitel 4 dargestellt.

3.1 Anforderungen an eine Prozessüberwachung für das PBF-LB/M Verfahren

Damit eine Prozessüberwachung für das PBF-LB/M Verfahren im industriellen Maßstab einen Mehrwert darstellt, muss diese gewissen Anforderungen genügen. Diese Anforderungen sollen in der Folge hergeleitet werden.

Die additive Fertigung mittels PBF-LB/M Verfahren weist im Kontext einer industriellen Serienfertigung wirtschaftliche Nachteile auf: bedingt durch lange Prozesszeiten in Kombination mit einem höheren Stundensatz der Anlagen sind die Stückkosten in der additiven Fertigung höher im Vergleich zu konventionellen Fertigungsverfahren (Jacob 2021; Kopf 2018). Sollten in einer nach dem Druckprozess (End-of-Line) durchgeführten Qualitätssicherung interne Defekte identifiziert werden, so ist Wertschöpfung an Ausschuss betrieben worden. Nacharbeit ist in der Regel nicht möglich, sodass Bauteile mit Defekten als Ausschuss aussortiert werden müssen. Dies führt dazu, dass die Auswahl einer geeigneten Qualitätssicherungsstrategie direkt mit wirtschaftlichen Aspekten des Verfahrens korreliert. Die wirtschaftlichen Nachteile des PBF-LB/M Verfahrens können durch eine hauptzeitparallele Qualitätssicherung verbessert werden. Eine derartige hauptzeitparallele Qualitätssicherung kann durch den Einsatz einer **in-process Prozessüberwachung** realisiert werden. (Weiser et al. 2023)

Wie bereits in Kapitel 2.1.4.2 sowie Abbildung 2-7 dargestellt wurde, ist der Einfluss von prozessbedingter Porosität auf die mechanischen Kennwerte durch drei wesentliche Kennzahlen bestimmt: (I) die Größe bzw. das Volumen, (II) die Form und (III) die Lage der Poren im Bauteil. Die Summation der Größe bzw. des Volumens aller Poren resultiert in einer Gesamtporosität des Bauteils. Die Gesamtporosität eines Bauteils lässt sich nach aktuellem Stand der Technik nach dem Fertigungsprozess erfassen (Eschner 2021). Für eine Aussage über die mechanischen Kennwerte eines Bauteils ist die Kenntnis der Gesamtporosität allein jedoch nicht ausreichend.

Die Form der Poren hat durch die daraus resultierende Kerbwirkung einen signifikanten Einfluss auf die mechanischen Kennwerte eines Bauteils. Damit die Form der Pore in die Bestimmung des Einflusses auf die mechanischen Kennwerte einfließen kann, muss die im Bauteil vorhandene Porosität hinsichtlich ihrer Form **quantitativ charakterisiert** werden.

Durch den Einsatz von Finite-Elemente-Methoden in der Produktentwicklung sind die besonders belasteten Bereiche in einem Bauteil im angedachten Anwendungsfall oftmals bekannt. Um zu untersuchen, ob Porosität in für das mechanische Versagen kritischen Bereichen liegt, muss deshalb die Lage erfasst werden. Dazu muss das Messsignal selbst eine Positionskomponente enthalten oder es muss eine Rückführung auf Positionsdaten möglich sein. Dies kann beispielsweise durch eine Datenfusion mit Positionsdaten erfolgen. Damit solch eine Lagebestimmung der Porosität möglich ist, ist der Einsatz einer **ortaufgelösten Messtechnik** notwendig.

Für den Einsatz des PBF-LB/M Prozesses in der industriellen Serienfertigung ist es notwendig, dass das zugrundeliegende Verfahren und die genutzte Messtechnik besonderen Anforderungen genügen. Diese sollen in der Folge hergeleitet werden. Für eine erfolgreiche industrielle Anwendung muss der Einsatz einer Prozessüberwachung einen Vorteil für den Anwender bieten. Eine Quantifizierung von Vorteilen lässt sich auf der monetären Ebene vornehmen. Der Einsatz eines Prozessüberwachungssystem soll dem Anwender jetzt oder in der Zukunft einen monetären Vorteil gegenüber Marktbegleitern geben, die solch ein System nicht anwenden. Zur Quantifizierung eines monetären Vorteils werden die Kostenarten nach Westkämper & Schloske (2020) betrachtet: Personalkosten, Kapitalkosten, Betriebsmittelkosten, Werkstoff- und Materialkosten, Energie- und Medienkosten sowie sonstige Kosten.

Monetäre Vorteile bei den *Personalkosten* durch den Einsatz einer Prozessüberwachung können dann erreicht werden, wenn das Personal durch diese einen geringeren Aufwand hat. Dies kann durch eine **automatisierte Auswertung** der Sensordaten mit möglichst wenig Nutzerinteraktion erreicht werden. Weitere Vorteile werden erreicht, wenn für den Einsatz eine geringere **Personalqualifikation** für den Betrieb der Prozessüberwachung erforderlich ist. Bei den **Kapitalkosten** kann ein Vorteil erreicht werden, wenn die Anschaffung des Prozessüberwachungssystem mit **geringen Anschaffungskosten** verbunden ist. Dies kann beispielweise durch simplere Sensorprinzipien oder günstigere Hardware erreicht werden. Die **Betriebsmittelkosten** werden durch eine Prozessüberwachung dann gesenkt, wenn eine Prozessüberwachung in der Lage ist, einen **Druckjob abzubrechen**, sobald diese erkennt, dass ein **kritischer Defekt** aufgetreten ist und Ausschuss produziert werden würde. Auf diese Art kann Maschinenzeit eingespart werden. Werkstoff- und Materialkosten sowie Energie und Medienkosten lassen sich ebenfalls durch einen rechtzeitigen Abbruch eines fehlgeschlagenen Druckjobs reduzieren. Unter der potenziellen **industriellen Anwendbarkeit** werden deshalb die folgenden Kriterien zusammengefasst:

- Möglichkeit der automatisierten Auswertung
- Geringe Personalqualifikation notwendig
- Geringe Anschaffungskosten des Prozessüberwachungssystem
- Erkennen von kritischen Defekten und darauffolgendem Abbrechen des Druckjobs

Zusammengefasst werden deshalb im Rahmen dieser Arbeit die folgenden vier Anforderungen an eine Prozessüberwachung für das PBF-LB/M Verfahren im Rahmen einer industriellen Serienfertigung gestellt:

1. in-process Prozessüberwachung
2. quantitative Defektcharakterisierung
3. orts aufgelöste Messtechnik
4. industrielle Anwendbarkeit des Ansatzes

Die bestehenden Ansätze zur Prozessüberwachung im Stand der Forschung und Technik im nachfolgenden Kapitel werden deshalb an diesen vier Anforderungen gemessen und abschließend hinsichtlich des Erfüllungsgrads evaluiert.

3.2 Bestehende Ansätze zur Prozessüberwachung im PBF-LB/M Prozess

Im folgenden Kapitel werden bestehende Forschungsansätze zur Prozessüberwachung von Porosität dargestellt. Veröffentlichungen und Ansätze zur Prozessüberwachung, die keinen konkreten Bezug zum Fehlerbild Poren oder Porosität haben, wurden aus der Betrachtung ausgeschlossen. Die Bewertung orientiert sich an den in Kapitel 3.1 vorgestellten Anforderungen an Prozessüberwachungen.

Für die Prozessüberwachung von Porosität im PBF-LB/M Fertigungsverfahren haben sich im Wesentlichen zwei Messprinzipien etabliert: die optische und die akustische Prozessüberwachung. In Kapitel 3.2.1 und Kapitel 3.2.2 werden als erstes optische Prozessüberwachungen vorgestellt. Diese können nochmals nach ihrer Einbauposition unterschieden werden. Optische Prozessüberwachungen werden als erstes vorgestellt, da diese die größte Anzahl an Ansätzen ausmachen. In Kapitel 3.2.3 werden die Forschungsansätze mittels akustischer Prozessüberwachungen vorgestellt. Alle weiteren Sensorprinzipien (Röntgenstrahlung und Wirbelstrom) werden in Kapitel 3.2.4 betrachtet. Abschließend werden in Kapitel 3.2.5 bestehende kommerziell erhältliche Prozessüberwachungen in alphabetischer Reihenfolge vorgestellt.

3.2.1 Optische on-axis Prozessüberwachungen

Unter on-axis (auch: koaxialen) Prozessüberwachungen werden Systeme verstanden, bei denen die verwendete Sensorik koaxial im Strahlengang integriert ist. Der prinzipielle Aufbau eines solchen Systems ist in Abbildung 3-1 dargestellt. Die von der Bauplattform reflektierten Prozessemissionen werden dabei durch den Strahlengang der Anlage zurückgeführt, durch semitransparente Spiegel ausgekoppelt und schließlich durch einen Sensor erfasst.

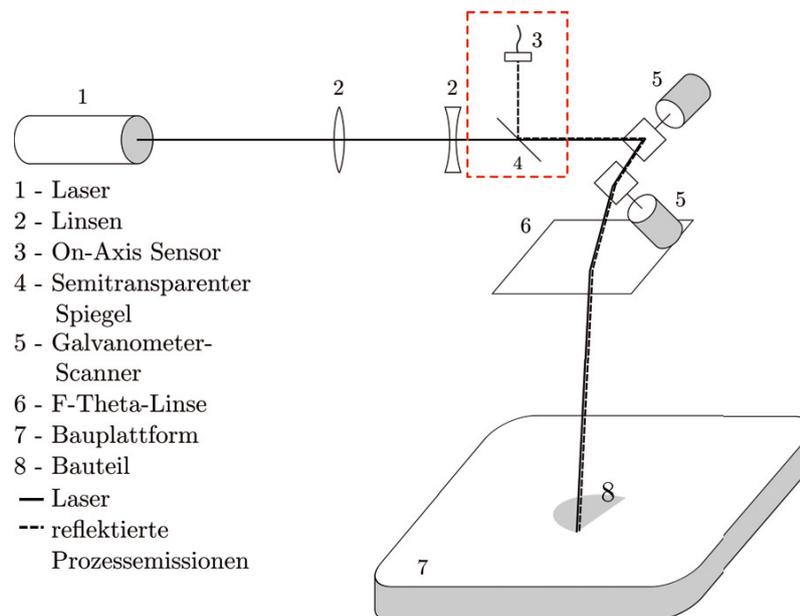


Abbildung 3-1: Prinzipieller Aufbau von on-axis Prozessüberwachungen – eigene Darstellung

Clijsters et al. (2014) nutzen als Grundlage für ihren Ansatz eine selbstgebaute PBF-LB/M Anlage, welche Vollzugriff auf die Steuerung erlaubt. Als Sensoren werden dabei eine Fotodiode und eine Hochgeschwindigkeits-CMOS-Kamera im Nahinfrarotbereich verwendet. Beide Sensoren sind dabei für den Wellenlängenbereich 400 – 1000 nm ausgelegt. Mit der Sensorik wird das Schmelzbad während des Prozesses überwacht. Als minimale Abtastrate geben die Autoren dabei 10 kHz an. Die Aufnahme und Verarbeitung der Daten erfolgt mit einem *Field Programmable Gate Array* (FPGA) während des Druckprozesses. Dabei werden die Strahlungsintensität des Schmelzbades, die Schmelzbadfläche und die Schmelzbadhöhe und -breite erfasst und für die weitere Verarbeitung gespeichert. Alle Druckjobs werden fünfmal wiederholt. Als Referenzmessungen stehen Daten von Koordinatenmessgeräten und CT-Scans der Bauteile zur Verfügung. Als alternative Referenzmessung steht auch eine Klassifikation einzelner Scanvektoren zur Verfügung, bei denen zwischen *Infill*- und Konturvektoren unterschieden wird. Zur weiteren Auswertung werden die einzelnen Messwerte basierend auf ihrer Position (bestimmt durch die Laserposition) einem regulären Gitter zugeordnet. Pro Schicht entsteht dabei ein Pixelbild, welches zu einem dreidimensionalen Voxelbild zusammengesetzt wird. Die weitere Auswertung erfolgt durch statistische Methoden. Es wird ein 95 % Konfidenzintervall für die Sensorwerte auf Basis der Referenzdaten festgelegt. Auffälligkeiten in den Signalen werden in der Folge mit Schlibbdaten und CT-Scans abgeglichen, um die Position von Poren zu bestimmen. Eine Quantifizierung der

detektierten Poren sowie ganzheitliche Validierung des Ansatzes findet nicht statt. Die Bewertung der Poren hinsichtlich ihrer Kritikalität erfolgt über den Maschinenbediener, sodass dieser über umfangreiche Qualifikation verfügen sollte. Die verwendete Fotodiode ist deutlich günstiger in der Anschaffung als die verwendete Hochgeschwindigkeitskamera. Grundsätzlich ist das Vorgehen für eine Automatisierung geeignet. Die industrielle Anwendbarkeit ist somit eingeschränkt vorhanden.

DePond et al. (2018) nutzen als Basis für ihre Untersuchungen eine *Aconity* PBF-LB/M Anlage, welche gegenüber den meisten kommerziell erhältlichen System eine offene Architektur für Forschungsanwendungen bereitstellt. Das zugrundeliegende Messprinzip der Prozessüberwachung ist die optische Kohärenztomographie im Frequenzbereich (engl. *spectral density optical coherence tomography* - SD-OCT). Die Datenaufnahme erfolgt nach Belichtung einer einzelnen Schicht, wenn der Hauptlaser ausgeschaltet ist und stellt somit eine off-process Prozessüberwachung dar. Die SD-OCT Daten werden im Anschluss mit *LabView* nachbearbeitet und danach mittels *ImageJ* und *Python* analysiert. Als Referenzmessung werden auf einer anderen PBF-LB/M Anlage Hochgeschwindigkeitskameraaufnahmen von Einspurversuchen erzeugt. Die Daten des SD-OCT werden bei der Analyse fouriertransformiert. Aus diesen Daten kann nachfolgend eine Bestimmung der Oberflächenrauheit durchgeführt werden. Die Autoren vermuten einen starken Zusammenhang zwischen der Oberflächenrauheit einer Schicht und dem Entstehen von Porosität. Eine quantitative Charakterisierung von entstandener Porosität führen die Autoren nicht durch. Die Auswertung ist nicht automatisiert und die Kosten für ein OCT-System sowie die Integration ist mit erhöhtem finanziellem Aufwand verbunden. Darüber hinaus muss ein Maschinenbediener über umfangreiches Wissen verfügen, sodass die industrielle Anwendbarkeit für diesen Ansatz nicht gegeben ist.

Hooper (2018) verwendet in seinem Ansatz eine kommerzielle *Renishaw AM250* PBF-LB/M Anlage. Als Sensoren werden zwei Hochgeschwindigkeitskameras verwendet, die mittels Bandpassfilter die Prozessemissionen im Bereich von 700 nm und 900 nm aufnehmen. Aufgrund der vorhandenen F-Theta-Linse in der Anlage wurde eine Positionskorrektur der Schmelzbadüberwachung implementiert, welche die x- und y-Position des Schmelzbades korrigiert. Mit der verwendeten Sensorik soll eine Bestimmung der Schmelzbadtemperatur und der dazugehörigen Abkühlraten ermöglicht werden. Die Auswertung der Daten erfolgt durch zeitliche Auswertung der aufgenommenen Schmelzbadaten. Dabei werden vor allem die Position, die geometrische Form und

die Temperatur des Schmelzbades betrachtet. Der Autor beobachtete bei bestimmten Schmelzbaddynamiken die Entstehung von Porosität. Eine dedizierte Vorhersage oder Quantifizierung von Porosität nimmt der Autor nicht vor. Da keine dedizierte Defektvorhersage durchgeführt wird und die Nutzung von zwei Hochgeschwindigkeitskameras mit erheblichem finanziellem Aufwand verbunden ist, wird die industrielle Anwendbarkeit bei diesem Ansatz verneint.

Pavlov et al. (2010) verwenden in ihrem Ansatz eine industrielle *Phenix PM100* PBF-LB/M Anlage. Ein Pyrometer für zwei Wellenlängen dient als Sensorik zur Prozessüberwachung. Mit dem Versuchsaufbau untersuchen Pavlov et al. (2010) vor allem den Einfluss des Abstands zwischen zwei Scanvektoren auf das Pyrometersignal. Dabei ist zu erkennen, dass das Pyrometersignal bei zunehmendem Abstand zwischen den Scanvektoren eine höhere Amplitude aufweist. Eine Korrelation der Messdaten mit Positionsdaten des Lasers findet nicht statt. Die aufgenommenen Daten werden dabei manuell durch die Autoren ausgewertet und in Zusammenhang mit Referenzuntersuchungen auf Basis von Schliffbildern gebracht. In Abhängigkeit des Pyrometersignals machen die Autoren unterschiedlich starke Ausprägungen von Porosität im Bauteil aus. Eine weitergehende Untersuchung der entstandenen Porosität sowie deren dedizierte Vorhersage erfolgt in diesem Ansatz nicht. Aus diesem Grund wird die industrielle Anwendbarkeit des Ansatzes verneint.

Tao et al. (2023) nutzen für ihren Ansatz den Versuchsaufbau von Clijsters et al. (2014). Als Sensor wird lediglich die vorhandene Fotodiode genutzt. Als Probekörper wird ein Würfel aus Ti-6Al-4V gedruckt und nach dem Druck mittels Computertomographie auf Poren untersucht. Die Defektanalyse erfolgt dabei mit der Software *VGStudio Max 2022.1* des Herstellers *Volume Graphics* und dem Analysealgorithmus *VGDefX*. Die Daten der Fotodiode werden schichtweise erfasst und auf 1000x1000 Pixel interpoliert. Aus diesen Pixeln werden nun 50x50 Pixel große Segmente ausgeschnitten und einzeln verarbeiten. Für jedes Segment werden 33 Wavelet-Transformationen, 25 statistische Merkmale, Kurzzeit-Fourier-Transformationen, die spektrale Entropie und der Phasengang aus den Sensordaten berechnet und als Eingang für die datengetriebene Modellbildung verwendet. Das Label besteht aus der Information aus der Defektanalyse, ob in einem 50x50 Pixel Segment eine Pore vorhanden ist. Insgesamt werden 13 verschiedene Modellarten aus dem Bereich der datengetriebenen Modellbildung verwendet. Die Modelle zur binären Vorhersage zum Vorhandensein von Poren in einem Segment erreichen einen F1-Score zwischen 0 und 0,29. Durch die verwendete

Sensorik und die Auswertung mit datengetriebener Modellbildung ist der Ansatz für eine industrielle Anwendung geeignet.

3.2.2 Optische off-axis Prozessüberwachungen

Unter off-axis Prozessüberwachungen werden Systeme verstanden, welche die verwendete Sensorik explizit nicht im Strahlengang koaxial integriert haben. Der prinzipielle Aufbau eines solchen Systems ist in Abbildung 3-2 dargestellt. Die Sensorik wird häufig im Bauraum oder außerhalb des Bauraums untergebracht und erfasst die Prozessemissionen.

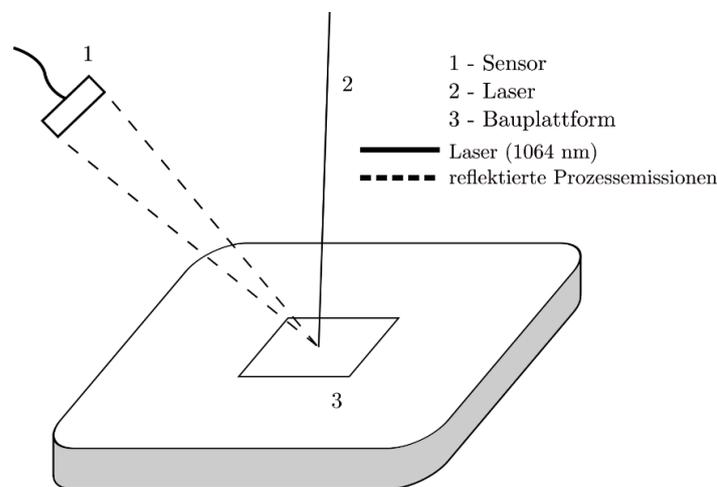


Abbildung 3-2: Prinzipieller Aufbau von off-axis Prozessüberwachungen – eigene Darstellung

Bisht et al. (2018) verwenden in ihrem Ansatz eine Germanium-Fotodiode, welche mittels Hochpassfilter sensitiv im Wellenlängenbereich von 1150 – 1850 nm ist. Die Fotodiode ist im Bauraum der PBF-LB/M Anlage untergebracht. Als Probengeometrie verwenden Bisht et al. Zugproben. Es wird keine Aussage über eine Nachbearbeitung der Probengeometrie vor der Durchführung von Zugversuchen gemacht. Es wird keine Variation der Prozessparameter durchgeführt, da dies, nach Ansicht der Autoren, nicht die industrielle Praxis im Rahmen der additiven Fertigung wiedergibt. Während des Druckjobs wird die Intensität der Strahlung im Bauraum erfasst und als Zeitreihe abgespeichert. Die Sensordaten werden in Intervalle von 20 μ s eingeteilt. Für jedes Intervall wird dann die Gesamtintensität des Fotodiodensignals berechnet. Die Bauplatzform wird anschließend in ein regelmäßiges Gitter von 1000x1000 Pixel eingeteilt und das aggregierte Sensorsignal auf die entsprechenden Pixel bezogen. Die entstehenden schicht-

weisen Darstellungen werden manuell durch die Autoren analysiert. Die Autoren suchen nach Auffälligkeiten im Signal, die entweder in neben- oder übereinander liegenden Scanvektoren auftreten. Nach Meinung der Autoren sind solche Auffälligkeiten ein Indikator für die Entstehung von Porosität. Nach der manuellen Analyse aller Schichten haben die Autoren das Verhältnis des Volumens mit Auffälligkeiten (welche über mehrere Schichten aufgetreten sind) zum Gesamtbauteilvolumen bestimmt. Dieses Verhältnis korrelieren die Autoren mit der erzielten plastischen Dehnung aus dem durchgeführten Zugversuch. Dabei stellt sich raus, dass ein inverser Zusammenhang zwischen Volumen mit Auffälligkeiten und der plastischen Dehnung im Zugversuch besteht. Eine automatisierte Auswertung erfolgt nicht. Ebenso findet keine quantitative Bewertung der detektierten Auffälligkeiten statt, sodass bei diesem Ansatz die industrielle Anwendbarkeit verneint wird.

Foster et al. (2015) verwenden für ihren Ansatz eine kommerzielle *EOS M280* PBF-LB/M Anlage. Als Sensor für die Prozessüberwachung wird eine *Nikon D800E* Spiegelreflexkamera verwendet, welche innerhalb der Baukammer angebracht wird. Zusätzlich zur Spiegelreflexkamera werden Blitzmodule verbaut, um direkt nach dem Beschichten und nach dem Belichten Aufnahmen machen zu können. Die Bilddaten werden nachbearbeitet und analysiert; dieser Vorgang wird jedoch nicht genauer spezifiziert. Aus diesen Daten wird dann eine dreidimensionale Repräsentation der Bauteile geschaffen. In diesen Daten finden die Autoren manuell Anzeichen für Defekte wie eine ungleichmäßige Beschichtung des Pulverbetts oder Bereiche mit erhöhter Porosität. Eine weitere Untersuchung der möglichen Defekte findet nicht statt. Die verwendete Sensorik ist eine Consumer-Spiegelreflexkamera und somit günstig in der Anschaffung. Aufgrund fehlender Automatisierung und fehlender Bewertung möglicher Defekte wird die industrielle Anwendbarkeit dieses Ansatzes verneint.

Krauss et al. (2012) verwenden eine kommerzielle *EOS M270* PBF-LB/M Anlage. Die Sensorik für die Prozessüberwachung besteht aus einer ungekühlten Thermografiekamera im langwelligen Infrarotbereich (engl. *longwave infrared* - LWIR). Dieses System kann Bilder mit einer Frequenz von 50 Hz aufnehmen. Um Poren im Prozess zu detektieren, haben Krauss et al. diese künstlich in den Prozess eingebracht, indem sphärische Bereiche von der Belichtung ausgeschlossen wurden. Diese Bereiche werden über mehrere Schichten aufgebaut und anschließend verschlossen, indem die ganze Schicht belichtet wird. Über Abweichungen im Thermografiebild zum porenfreien Zu-

stand können die Autoren die Bereiche mit den künstlich eingebrachten Poren detektieren. Eine weiterführende Quantifizierung der Defektbereiche findet nicht statt. Auch ist nicht erkenntlich, ob die Auswertung der Daten manuell oder automatisiert erfolgt. Aus diesem Grund wird die industrielle Anwendbarkeit des Ansatzes verneint.

Basierend auf dem gleichen Versuchsaufbau von 2012 haben **Krauss et al. (2014)** eine weiterführende Arbeit erstellt, die statt einer schichtweisen Betrachtung der Sensordaten eine volumetrische Betrachtung der Daten vornimmt. Die weitere Auswertung der volumetrischen Daten erfolgt mit mathematischen Methoden der Wärmeleitung. Dabei zeigt sich, dass Defekte wie Porosität oder Delamination die thermische Diffusion beeinflussen und somit durch das zugrundeliegende mathematische Modell erfasst werden können. Krauss et al. definieren für die Porosität den Qualitätsparameter „*imperfection level Δ* “, der eine Korrelation mit der thermischen Diffusion aufweist. Mit diesem Qualitätsparameter können Krauss et al. eine Aussage darüber treffen, ob Fehler im Bauteil vorhanden sind, die die thermische Diffusion bzw. Wärmeleitung beeinflussen. Eine quantitative Charakterisierung und genauere Einordnung der Defekte werden mit dem vorgestellten Modell nicht vorgenommen. Wie auch beim ersten Ansatz der Autoren wird aus denselben Gründen die industrielle Anwendbarkeit verneint.

Zenzinger et al. (2014) setzen für Ihren Ansatz eine kommerzielle Anlage des Herstellers EOS ein. Als Sensoren kommen CMOS oder CCD-Kameras zum Einsatz, mit denen die Strahlungsintensität während des Prozesses orts aufgelöst aufgezeichnet wird. Die geometrische Auflösung des Systems beträgt etwa 0,1 mm pro Pixel. Eine genauere Spezifikation der verwendeten Sensorik ist in der Veröffentlichung nicht enthalten. Die Bilder werden in der Form aggregiert, dass für jede Schicht ein gesamtes Bild zur Auswertung vorliegt. Da thermisch stabilisierte Sensorik verwendet wird, kann das Gesamtbild einer Schicht quantitativ ausgewertet werden. Aus den Bildern je Schicht kann dann ein dreidimensionales Voxelvolumen erstellt werden. Dieses wird mit 3D-Analyse-Software dargestellt und manuell nach Auffälligkeiten in den Daten durchsucht. Diese Auffälligkeiten können auf Prozessfehler wie Poren hinweisen. Eine Validierung des Vorgehens erfolgt über das Anfertigen von Schliffbildern, bei denen in Bereichen mit Auffälligkeiten auch Prozessfehler gefunden werden. Eine Quantifizierung der gefundenen Defekte findet nicht statt. Aufgrund der Auswertung mit bestehender 3D-Analysesoftware und der günstigen Sensorik ist die industrielle Anwendbarkeit bedingt gegeben

3.2.3 Akustische Prozessüberwachungen

Akustische Prozessüberwachungen basieren auf der Messung von Schallwellen zur Prozessüberwachung. Die Systeme können dabei eine aktive Anregung des Bauteils mit Schallwellen vornehmen oder passiv die akustischen Prozessemissionen aufzeichnen.

Eschner et al. (2020) und **Eschner (2021)** verwenden in ihrem Ansatz eine selbstentwickelte PBF-LB/M Versuchsanlage, die eine flexible Einstellung der Prozessparameter erlaubt. Die betrachteten Probekörper umfassen drei Geometrien, die drei unterschiedliche Komplexitätsstufen aufweisen. Die Zunahme an Komplexität wird durch verschiedene Aussparungen im würfelförmigen Grundkörper erreicht. Als Sensor kommt ein passiver Körperschallsensor des Herstellers QASS zum Einsatz, der samt Vorverstärker an die Auswerteeinheit des Sensorherstellers angebunden ist. Der Sensor selbst ist unterhalb der Bauplattform mit einer Schraubverbindung angebracht. Das Körperschallsignal wird durch den Sensor während des Fertigungsprozesses aufgezeichnet. Eine orts aufgelöste Messung wird nicht durchgeführt. Das Rohsignal wird mittels Fourier-Transformation vom Zeit- in den Frequenzbereich überführt. Die Modellbildung erfolgt durch den Einsatz eines Multi-Layer-Perzeptrons, welches ein einfaches neuronales Netz darstellt. Als Label für das Training wird die Gesamtporosität der Bauteile in drei gleich große Klassen eingeteilt (gut, mittel, schlecht). Das Modell versucht die zugewiesene Klasse auf Basis der Fourier-transformierten Sensordaten vorherzusagen. Die Modelle erreichen einen F1-Score von ca. 0,85 – 0,88.

Hirsch et al. (2017) verwenden in ihrem Ansatz eine kommerzielle *Realizer SLM50* PBF-LB/M Anlage. Als Sensorik wird die orts aufgelöste akustische Spektroskopie (engl. *spatially resolved acoustic spectroscopy* - SRAS) verwendet. Dabei werden akustische Oberflächenwellen durch einen separaten Laser erzeugt und dann mit einem weiteren Detektionslaser erkannt. Die Messung erfolgt nach Belichtung einer Schicht. Das System erzeugt zwei Arten von Daten je Schicht: ein optisches Bild und eine Geschwindigkeitskarte. Als Referenzmessung stehen Schliiffbilder der Bauteile zur Verfügung. Anhand dieser werden Defekte im Bauteil in die Klassen Riss und Pore eingeteilt. Die Daten des SRAS-Systems werden nachfolgend über nicht näher detaillierte Schwellwertmethoden ausgewertet und anhand dieser eine Analyse über das Auftreten von Poren und Rissen getroffen. Eine Metrik zur Bewertung der Analysen ist nicht vorhanden. Die Analyse sagt die vorhandene Bauteilgesamtporosität und die Risslänge

vorher. Da die verwendete Sensorik teuer in der Anschaffung sowie in der Integration ist und keine Metrik zur Bewertung der Analysen vorhanden ist, wird die industrielle Anwendbarkeit verneint

Rieder et al. (2015) verwenden in ihrem Ansatz eine kommerzielle *EOSINT M280* PBF-LB/M Anlage. Als Sensor wird ein aktiver Ultraschallsensorkopf verwendet, welcher unter der Bauplatzform verklebt wird und in der Lage ist, Longitudinalwellen mit einer Frequenz von 10 MHz zu erzeugen. Die Sensordaten werden schichtweise nach der Belichtung aufgenommen. Ziel des Systems ist es, Abweichungen von einem definierten Normalzustand des Prozesses zu erkennen. Eine künstlich eingebrachte Pore im Bauteil ist dabei durch die aufgezeichneten A-Scans⁴ des Ultraschallsensors nicht zu erkennen. Dies wird auf eine fehlerhafte Platzierung des Sensors relativ zum Bauteil zurückgeführt. Aufbauend auf der Arbeit von 2015 haben **Rieder et al. (2016)** ihren Ansatz verbessert. Statt A-Scans werden B-Scans⁵ zur Erkennung von Bereichen mit Porosität genutzt. Der verwendete Probekörper besitzt in Aufbaurichtung Bereiche, in denen künstliche Schichten mit erhöhter Porosität erzeugt wurden. Diese Bereiche sind in den dargestellten Visualisierungen der B-Scans eindeutig zu erkennen. Eine genaue Quantifizierung der Porosität findet nicht statt. Eine automatisierte Auswertung der Daten wurde nicht vorgestellt. Eine quantifizierbare Bewertung der Modellperformance ist somit nicht möglich.

Smith et al. (2016) verwenden für ihren Ansatz eine kommerzielle PBF-LB/M Anlage des Herstellers *Renishaw* (Modell: *AM 250*). Als Sensor wird ein SRAS-System des Herstellers *AOT lasers* (Modell: *AOT-YAG-10Q*) verwendet. Als Probekörper werden Würfel mit einer Kantenlänge von 10 mm verwendet. Die Probekörper werden erst vollständig gedruckt, bevor eine Seite poliert und mit dem SRAS-Sensorsystem untersucht wird. Mit Methoden der Bildverarbeitung werden die erzeugten Aufnahmen des SRAS-Systems mit Mikroskopaufnahmen verglichen. Der Vergleich erfolgt dabei rein optisch, eine Metrik zur Bewertung des Ansatzes wird nicht genutzt. Die quantitative Einordnung des Systems ist somit nicht möglich. Die automatisierte Auswertung der Daten sowie eine Anwendung des Systems während des Druckvorgangs wurden in diesem Ansatz nicht betrachtet.

⁴ 1D Messung an einem einzelnen Punkt.

⁵ 2D Linienmessung durch mehrere Ultraschallköpfe.

Wasmer et al. (2018) verwenden eine industrielle PBF-LB/M Anlage vom Typ *Concept M2* des Herstellers *Concept Laser*. Das verwendete Sensorsystem zur Prozessüberwachung besteht aus einem Faser Bragg Gitter (FBG) (Hill & Meltz 1997). Der Sensor wird innerhalb der Baukammer angebracht. Durch das akustische Signal des Prozesses wird eine Änderung des Brechungsindex innerhalb des FBG hervorgerufen. Das akustische Signal wird während des PBF-LB/M Prozesses aufgezeichnet. Die Verarbeitung der Daten erfolgt dabei durch das Berechnen von sog. *M-band Wavelet-Spektrogrammen*, welche nachfolgend durch ein Convolutional Neural Network ausgewertet werden. Die Wavelet-Spektrogramme werden mit zwei unterschiedlichen Zeitfenstern erzeugt: ein langlaufendes und ein kurzlaufendes Zeitfenster. Durch diese werden unterschiedliche Auflösungen in den Daten erreicht. Beide Spektrogramme werden dann zunächst in einem jeweils separaten Ast eines CNNs verarbeitet und danach zusammengeführt. Die Probekörper werden in drei unterschiedliche Qualitätsklassen (schlecht, mittel, gut) eingeteilt, welche direkt aus den verwendeten Prozessparametern abgeleitet werden. Das CNN wird genutzt, um eine Vorhersage der Qualitätsklasse vorzunehmen. Das Modell erreicht eine Genauigkeit von 79 – 84 % (in Abhängigkeit von der betrachteten Qualitätsklasse). Eine orts aufgelöste Auswertung der Daten findet nicht statt. Die Autoren stellen fest, dass das langlaufende Spektrogramm bei einer Einzelbetrachtung eine bessere Klassifikationsgenauigkeit als das kurzlaufende Spektrogramm erreicht. Dies wird auf die Anwesenheit von stärkerem Rauschen im kurzlaufenden Spektrogramm zurückgeführt. Durch die einfache Integration des Sensors und die automatisierte Auswertung durch CNN sowie der Erkennung von kritischen Defektklassen besitzt der Ansatz industrielle Anwendbarkeit. In **Wasmer et al. (2019)** nutzen die Autoren denselben Prozessaufbau wie in Wasmer et al. (2018). Es wird der Einsatz von Reinforcement Learning zur Prozessüberwachung untersucht. Dabei wird der gleiche Datensatz wie in der vorherigen Veröffentlichung verwendet. Mittels eines Q-Learning-Ansatzes werden die Spektrogrammdaten ausgewertet. Das erzeugte Modell erreicht eine Genauigkeit zwischen 74 – 82 %, was leicht schlechter als der initiale Ansatz ist. Eine orts aufgelöste Auswertung der Daten findet nicht statt.

Ye et al. (2018) verwenden in ihrem Ansatz einen selbst hergestellten Versuchsaufbau für den PBF-LB/M Prozess. Als Sensor wird ein Mikrofon (Modell *378C1* des Herstellers *PCB Piezotronics*) verwendet, welches oberhalb der Bauplatzform angebracht ist. Die Datenaufzeichnung erfolgt während des Prozesses. Bei der Durchführung des Prozes-

ses werden die Prozessparameter Laserleistung und Belichtungsgeschwindigkeit variiert. Es werden keine Probekörper hergestellt, sondern Einspurversuche durchgeführt. Die erzeugten Spuren werden in fünf Klassen eingeteilt: Balling, leichtes Balling, normal, leichtes Überhitzen und Überhitzen. Die Autoren nehmen an, dass Poren unter anderem durch Balling entstehen können. Durch den Einsatz eines Deep-Belief-Networks (DBN) soll die vorliegende Klasse der Spur vorhergesagt werden. Als Eingang in das Netzwerk werden die Rohdaten, die Fourier-Transformation sowie die Fourier-Transformation mit Entrauschung verwendet. Das DBN wird dabei mit Modellen basierend auf Multi-Layer-Perzeptren und Support-Vektor-Maschinen (SVM) verglichen. Das DBN erreicht eine Klassifikationsgenauigkeit von 95 %, das MLP 82 % und die SVM 98 %. Eine Anwendung des Modells auf einen dreidimensionalen Körper findet nicht statt. Da der Ansatz nur Einspurversuche betrachtet, wird die industrielle Anwendbarkeit verneint.

3.2.4 Weitere Prozessüberwachungen

In diesem Kapitel werden Prozessüberwachungen vorgestellt, welche sich nicht in die optischen on- und off-axis Prozessüberwachungen oder die akustischen Prozessüberwachungen einteilen lassen.

Calta et al. (2018) nutzen einen eigenen Versuchsaufbau, basierend auf einem *YLR-500-WC-Y14* Laser (*IPG Photonics*) in Kombination mit einem *3XB* (*Nutfield Technology*) Galvanometer-Scanner, um mittels Röntgenstrahlung den PBF-LB/M Prozess zu untersuchen. Dazu werden Einspurversuche durchgeführt, die orthogonal von einer Röntgenquelle durchstrahlt werden. Die Datenaufzeichnung erfolgt während der Belichtung der Spur. In den aufgenommenen Daten ist u.a. die Entstehung von Poren zu erkennen. Die Autoren betonen, dass es sich bei diesem Ansatz um einen rein wissenschaftlichen Ansatz handelt, der dazu dient, den PBF-LB/M Prozess besser zu verstehen und nicht um einen Ansatz, welcher für die industrielle Prozessüberwachung geeignet ist.

Du et al. (2018) untersuchen in ihrem Ansatz den Einsatz von Wirbelstrom zur Defekterkennung im Bereich der hybriden additiven Fertigung. Dazu wird zunächst ein Probekörper additiv gefertigt. Obwohl in diesem Ansatz das Laserauftragsschweißen als AM-Verfahren verwendet wird, soll dieser Ansatz der Vollständigkeit halber Erwähnung finden. Während des subtraktiven Abtragens des Bauteils wird nach jeder Schicht ein

Wirbelstromsensor über die zu bearbeitende Oberfläche geführt. Anhand der Signalantwort des Sensors können Poren mit einem Durchmesser von mehr als 0,2 mm erkannt werden. Beim Erkennen einer offenen Pore durch den Wirbelstromsensor kann diese somit durch erneuten additiven Materialauftrag geschlossen werden.

Todorov et al. (2018) untersuchen die Nutzbarkeit eines Wirbelstromarrays direkt im PBF-LB/M Prozess. Dazu wird das Wirbelstromarray in die Beschichterlippe einer Versuchsanlage eingebaut. Die Datenaufnahmen des Wirbelstromarrays erfolgt zwischen den Belichtungsphasen der einzelnen Schichten. Die Autoren untersuchen in ihrem Ansatz, inwieweit sich künstlich eingebrachte Poren in den Daten des Wirbelstromarrays wiederfinden lassen. Dabei zeigt sich, dass sich die eingebrachten Poren in einem ort aufgelösten C-Scan⁶ des Wirbelstromarrays erkennen lassen. Eine Aussage über die Genauigkeit des Systems oder eine automatisierte Auswertung wird nicht vorgenommen.

Wang et al. (2022) entwickeln einen analytischen Ansatz zur Vorhersage von Porosität. Ein zweidimensionales Modell nutzt Informationen über die Schmelzbadgeometrie, die durchschnittliche Porengröße im Bauteil, Aufschmelzgeschwindigkeiten und die Entstehungshäufigkeit von Poren. Auf Basis dieser Informationen wird eine Temperaturverteilung innerhalb des Bauteils analytisch berechnet. Aus diesem wird mit Literaturangaben zu Schmelztemperaturen das Schmelzbad berechnet. Die durchschnittliche Porengröße wird durch eine Regressionsanalyse auf Basis von Laserleistung und Schliffbildern ermittelt. Aufschmelzgeschwindigkeiten und Entstehungshäufigkeiten werden aus der Literatur abgeleitet. Das Modell ist in der Lage, für einen zweidimensionalen Anwendungsfall die prozentuale Gesamtporosität in Abhängigkeit des volumetrischen Energieeintrages vorherzusagen. Eine Quantifizierung des Modellfehlers erfolgt nicht. Die Autoren stellen eine Erweiterung des Ansatzes auf drei Dimensionen in Aussicht.

3.2.5 Herstelleransätze

Nach der Darstellung der Forschungsansätze wird auf die Ansätze und Lösungen der PBF-LB/M-Anlagenhersteller eingegangen. Die Ansätze werden in alphabetischer Reihenfolge des Herstellernamens vorgestellt. Die hier dargestellten Informationen umfas-

⁶ 3D Messung durch Sensoranordnung in einer Matrix

sen lediglich der Öffentlichkeit zugängliche Informationen. Aufgrund vieler fehlender Informationen werden die Ansätze der Hersteller aus der in Kapitel 3.3 folgenden Zusammenfassung der Ansätze ausgeschlossen.

3D Systems - DMP-Monitoring⁷ / Coeck et al. (2019)

3D Systems integriert eine optische Prozessüberwachung (Produktname: *DMP-Monitoring*) in seine Anlagen. Das System wurde entwickelt, um Prozessfehler beim Belichten der Schicht (*DMP Meltpool*) sowie Beschichtungsfehler zu erkennen. Die Prozessüberwachung besteht aus zwei nicht weiter spezifizierten Fotodioden, welche rechts und links innerhalb des Bauraums der Anlage angebracht sind. Diese analysieren während des Belichtungsvorgangs die auftretenden Prozessemissionen mit einer Abtastrate von 50 kHz. Gleichzeitig wird die Laserposition aufgezeichnet. Dadurch können räumlich und zeitlich aufgelöste Daten erfasst werden. Mit einer nicht näher spezifizierten Kamera wird der Zustand des Pulverbettes nach dem Auftragen einer neuen Pulverschicht dokumentiert. Auffälligkeiten aus dem Prozesssignal während des Belichtungsvorgangs können mit CT-Daten abgeglichen werden. Der genaue Algorithmus zur Datenauswertung wird nicht offengelegt. Das System kann Lack-of-Fusion-Poren mit einem Volumen größer als $0,001 \text{ mm}^3$ mit einer Sensitivität von 90 % erkennen. Das *DMP-Monitoring* System basiert auf dem Ansatz von Bisht et al. (2018). Weiterführende Informationen sind in Coeck et al. (2019) ersichtlich.

Additive Assurance - AMiRIS⁸

Additive Assurance hat mit *AMiRIS* eine anlagenherstellerunabhängige Prozessüberwachung entwickelt. Diese verwendet ein optisches off-axis-Sensormodul. Das optische System überwacht die Bauplatte mit Abmessungen von bis zu $250 \times 250 \text{ mm}^2$. Die Sensoren können bis zu vier Laser erkennen, sodass ein Multi-Laser-Setup möglich ist. Zur Überwachung werden mehrere hochauflösende optische Sensoren eingesetzt. CMOS-Sensoren werden zur Erfassung von Wellenlängen im nahen Infrarot und im sichtbaren Bereich eingesetzt. Die Sensoren haben eine Auflösung von $10 \text{ }\mu\text{m}/\text{Pixel}$. Diese Methode misst die Intensität der Strahlung des Prozesses. Es handelt sich um ein räumlich und zeitlich aufgelöstes Messverfahren während des Belichtungsvorgangs. Mit Hilfe von Softwaretools wird der geometrische Versatz des Sensorarrays in

⁷ <https://de.3dsystems.com/dmp-monitoring-solution> (11.06.2022)

⁸ <https://www.additiveassurance.com/product.html> (11.06.2022)

Echtzeit korrigiert. Ziel des Systems ist es, ein breites Spektrum an Prozessinstabilitäten zu erkennen. *Additive Assurance* bietet zwei mögliche Analysemethoden: Prozessstabilität oder Fehlererkennung. Die Prozessstabilität verwendet die Energiedichte-Methode zur Verarbeitung der Prozessdaten und regelt Prozessparameter so, dass diese in einem definierten Bereich bleiben. Die Defekterkennung hingegen verwendet nicht näher beschriebene Algorithmen des maschinellen Lernens. Schmelzbademissions- und Schmelzbadmorphologiedaten werden verwendet, um unzureichendes Aufschmelzen, Überhitzen, Störungen der Pulverbeschichtung oder Laserscanfehler zu erkennen. Der Algorithmus ermöglicht die Fehlerverfolgung über mehrere Schichten und bei Verwendung von mehreren Lasern. 2D- und 3D-Prozesskarten werden für ein Live-Feedback an den Anwender verwendet, indem die erkannten Defekte visualisiert werden. Die Prozessüberwachung kann den Druckjob automatisch stoppen, wenn ein Fehler entdeckt wird. Dazu muss der Benutzer einen Schwellwert für die Fehlererkennung festlegen. Der Prozess stoppt, wenn dieser Schwellwert überschritten wird.

Concept Laser - QM Meltpool 3D⁹

QM Meltpool 3D ist eine in-process Prozessüberwachung des Anlagenherstellers *Concept Laser*. Das System wurde entwickelt, um Prozessfehler und Defekte während des Druckjobs zu erkennen. Eine Fotodiode und eine Infrarot-Hochgeschwindigkeits-CMOS-Kamera sind hinter einem Strahlteiler im Strahlengang der Anlage angeordnet. Die während des Belichtungsvorgangs emittierte Strahlung wird in den Strahlengang reflektiert und von der Kamera-Fotodioden-Anordnung analysiert. Die maximale Abtastrate der Kamera beträgt 15 kHz. Die Fotodiode hat eine maximale Abtastrate von 50 kHz. Die Sensorauflösung hängt von der Scangeschwindigkeit des Lasers ab. Bei einer Scan-Geschwindigkeit von 1500 mm/s beträgt die Auflösung 100 µm. Bei einer Scan-Geschwindigkeit von 3000 mm/s sinkt die Auflösung auf 200 µm. Es sind keine Informationen zur verwendeten weiterführenden Datenanalyse veröffentlicht. Der Maschinenbediener kann die erfassten Daten und Bilder über Graustufenkarten überprüfen. Es ist auch möglich, ein 3D-Modell aus den Bildstapeln der Kamera und der Fotodiode zu rekonstruieren. Zu diesem Zweck kann eine kommerzielle CT-Software verwendet werden.

⁹ <https://www.directindustry.de/prod/concept-laser/product-15662-1827524.html> (11.06.2022)

EOS – EOSTATE Monitoring¹⁰

Zur Sicherstellung der Bauteilqualität hat EOS die Prozessüberwachung *EOSTATE Monitoring* für den PBF-LB/M Prozesses entwickelt. Das System besteht aus den Komponenten *EOSTATE PowderBed*, *EOSTATE MeltPool* und *EOSTATE Exposure OT (Optical Thermography)*. *EOSTATE PowderBed* nimmt nach der Neubeschichtung des Pulverbetts Bilder auf. *EOSTATE MeltPool* sammelt hochauflösende Informationen über die Dynamik des Schmelzbads in einem on-axis-Setup. *EOSTATE Exposure OT* verfügt über eine off-axis CMOS-Kamera. Eine nicht näher spezifizierte Kamera wird zur Überwachung des Zustands des Pulverbetts nach der Wiederbeschichtung verwendet. Die im Strahlengang platzierten Sensoren werden nicht weiter beschrieben. Die CMOS-Kamera für die optische Tomographie misst die qualitätsrelevanten Wärmeemissionen in Echtzeit. *EOSTATE Exposure OT* erzeugt eine Liste von Indikatoren, die der Benutzer auswerten kann. Der Analysealgorithmus kann an individuelle Interessen angepasst werden. Die Schichtüberwachung kann als Videoclip von der Anlage zur weiteren Untersuchung exportiert werden. *EOSTATE MeltPool* zeigt mittels Grafik und Liste Bereiche im Bauteil mit potenzieller Unter- oder Überbelichtung an und markiert diese. *EOSTATE Exposure OT* zeigt die gesamten Daten in einem Diagramm an.

Open Additive - AMSENSE¹¹

Open Additive entwickelt *AMSENSE*, ein Multisensor-Datenerfassungs- und Analysepaket zur Überwachung des PBF-LB/M Fertigungsverfahrens. Das System ist ein konfigurierbares off-axis-Überwachungssystem mit der Möglichkeit, verschiedene optische Sensormodule zu kombinieren. Das System ist herstellerunabhängig.

Der optische Beschichtungsbild-Sensor verwendet einen 12 Megapixel CMOS-Sensor, der oberhalb der Prozesskammer angebracht ist (off-axis). Das System erstellt je ein Bild vor und nach dem Beschichten, die zur Erkennung von Beschichtungsfehlern verglichen werden können. Die Beschichtungsfehler umfassen fehlendes Pulver, Delaminationen und ungleichmäßige Beschichtung.

Für die thermische Tomographie wird ein CMOS-Sensor mit 12 Megapixeln verwendet. Der Sensor nimmt Wellenlängen im Nah-Infrarot (NIR)-Spektrum auf. Der Sensor weist eine Abtastrate von 4 Hz auf und hat eine Belichtungszeit von 250 ms. Der Sensor

¹⁰ <https://www.eos.info/de/additive-fertigung/software-3d-druck/monitoring-software-am> (11.06.2022)

¹¹ <https://openadditive.com> (11.06.2022)

misst die Intensität der Prozessemissionen und ist oberhalb der Baukammer angebracht (off-axis). Die gemessene Emissionsintensität wird analysiert und für jede Schicht wird eine Emissionskarte erstellt. Diese Karten sind die Ausgabe für den Benutzer und können in Graustufen oder als Falschfarbendarstellung erfolgen.

Der Sensor zur Spritzerverfolgung basiert auf einem CMOS-Sensor mit einer Auflösung von 2 Megapixeln, welcher ebenfalls oberhalb der Baukammer angebracht ist (off-axis). Er nimmt 150 Bilder pro Sekunde auf. Die erfassten Wellenlängen liegen im NIR-Spektrum. Die Spritzerverfolgung schneidet Bilder von der Bauplattform aus und platziert das Schmelzbad in der Mitte. Ein nicht näher beschriebener Algorithmus erkennt jedes Spritzerereignis und misst dessen Position, Dauer, Wegstrecke und Größe. Für das Benutzerfeedback werden sowohl Bilder als auch die Spritzerstatistiken verwendet.

Renishaw - InfiniAM Spectral¹²

Renishaw hat *InfiniAM Spectral* entwickelt, um das PBF-LB/M Fertigungsverfahren in ihren Anlagen optisch zu überwachen. Zwei Fotodioden werden axial im Strahlengang platziert, um die emittierte Wärmestrahlung während des Belichtungsprozesses zu analysieren. Jede der beiden verwendeten Fotodioden ist in der Lage, unterschiedliche Wellenlängen zu analysieren. Einer der Sensoren misst die Emissionen mit Wellenlängen zwischen 700 und 1040 nm (NIR). Der andere Infrarot-Wärmesensor analysiert Wellenlängen von 1090 bis 1700 nm. Die Konvertierung von Rohdaten in 2D- und 3D-Volumendateien erfolgt mittels der proprietären Software *InfiniAM spectral* nach dem Druckvorgang durch den Maschinenbediener und wird nicht näher beschrieben.

Renishaw - InfiniAM Sonic¹³

InfiniAM Sonic ist eine Überwachungssoftware für das PBF-LB/M Fertigungsverfahren, die an der Bauplattform befestigte akustische Sensoren verwendet. Sie soll die bestehende *InfiniAM*-Suite ergänzen. Vier Hochfrequenz-Schallenergiesensoren werden an verschiedenen Stellen der Baukammer angebracht. Die Position und die Stärke des emittierten Schalls können durch Triangulation bestimmt werden. Es liegen keine wei-

¹² <https://www.renishaw.de/de/infiniam-spectral--42310> (11.06.2022)

¹³ <https://3dprintingindustry.com/news/renishaw-launches-infiniam-sonic-using-sound-to-monitor-additive-manufacturing-builds-166213/> (abgerufen am 27.10.2022)

teren Informationen über die verwendeten Sensoren vor. Es konnten keine Informationen zur Datenanalyse gefunden werden. Intensität und Position der erfassten Schalldaten werden über ein 3D-Säulendiagramm visualisiert.

Sigma Labs Inc. - PrintRite3D¹⁴

Sigma Labs Inc. bietet eine Prozessüberwachung mit dem Namen *PrintRite3D* an. Es verwendet ein zusätzliches optisches Sensorarray mit zugehöriger Software, welches herstellerunabhängig ist.

Ein zusätzlicher Strahlteiler wird in den Hauptstrahlengang einer bestehenden Anlage platziert, auf dem das Sensorarray montiert wird. Das Array besteht aus einem sekundären und einem tertiären Teiler, die die reflektierte Prozessstrahlung auf drei verschiedene Fotodioden aufteilen. Die erfassten Daten werden entweder lokal gespeichert und verarbeitet oder zur Weiterverarbeitung an eine Cloud Plattform gesendet. Auf der Grundlage der gesammelten Daten werden zwei Hauptwerte erstellt: die so genannte *Thermal Energy Density* (TED) und die *Thermal Energy Planck* (TEP). Die drei Fotodioden erfassen und analysieren jeweils ein bestimmtes Band von Wellenlängen. Die erste Fotodiode aggregiert ein breites Band von Wellenlängen über ein gepixeltes Gitter und wird zur Bestimmung des TED-Wertes verwendet. Die beiden anderen Fotodioden messen jeweils ein schmales Band spektraler Wärmesignaturen über ein gepixeltes Raster und dienen der Bestimmung des TEP-Wertes. Die Auswertungsstrategie ist nicht genau beschrieben. Der TED-Wert soll auf Änderungen der Eingangsparameter, wie Laserleistung und -geschwindigkeit, Belichtungsstrategie und Gasfluss reagieren. Der TED-Wert korreliert mit Dichte, Zähigkeit, Porosität und Oberflächengüte. Der TEP-Wert ermöglicht es dem Benutzer, thermische Signaturen zu erkennen, die mit Diskontinuitäten im Pulverbett korrelieren, bevor diese in einem Kamerabild des Pulverbettes sichtbar werden. Es dient zur Visualisierung von kurzen Zuführungen, Überhängen, Gasflussvariationen, Verformungen und der Interaktion mit dem Beschichter. Die TED- und TEP-Daten werden entweder in 2D-Diagrammen, in einem 2D-Scan-Viewer oder mit 3D-Wärmepunktwolkenbildern dargestellt.

¹⁴ <https://sigmaadditive.com/printrite3d/> (abgerufen am 27.10.2022)

Trumpf TruPrint Serie¹⁵

Trumpf integriert optische Prozessüberwachungswerkzeuge (nicht näher bezeichnete Kameras und Sensoren) in seine PBF-LB/M Anlagen. Diese umfassen eine Pulverbett- und Schmelzbadüberwachung. Die Pulverbettüberwachung erfolgt durch ein Kamerasystem, welches vom Hersteller nicht genauer spezifiziert wird. Das System bietet eine automatische Nachbeschichtung beim Erkennen von Beschichtungsfehler. Die dem System zugrundeliegende Bildverarbeitung und -auswertung wird nicht offengelegt. Die Schmelzbadüberwachung erfolgt durch nicht weiter spezifizierte Sensorik. Die Daten der Schmelzbadüberwachung können mit einem Referenzbaujob verglichen werden, um Abweichungen zu detektieren.

Velo 3D – Assure¹⁶

Velo3D bietet zwei verschiedene PBF-LB/M Anlagen an. Die Drucker sind mit *Velo3D's Assure* ausgestattet. Das System nutzt eine Schmelzbadüberwachung. Die Sensorik des Systems wird nicht weiter vom Hersteller spezifiziert. Die Ausgabe der Daten erfolgt als Falschfarbenbild. Weiterführende Analysen werden vom Hersteller nicht offengelegt.

3.3 Zusammenfassende Bewertung der Ansätze

Nach der Vorstellung der bestehenden Ansätze zur Prozessüberwachung aus dem Bereich Forschung (Kapitel 3.2.1 bis 3.2.4) und Industrie (Kapitel 3.2.5) werden die Forschungsansätze zusammengefasst bewertet. Die Prozessüberwachungsansätze der Hersteller sind aufgrund unzureichender Informationslage von der weiteren Betrachtung ausgeschlossen und werden nachfolgend separat betrachtet.

Im Bereich der **optischen on-axis Prozessüberwachungen** mit Fokus auf Porosität kommen Fotodioden, Hochgeschwindigkeitskameras, die optische Kohärenztomographie sowie Pyrometer zum Einsatz. Vier von fünf Ansätzen (Clijsters et al. 2014; Hooper 2018; Pavlov et al. 2010; Tao et al. 2023) zur Prozessüberwachung sind in der Lage, als **in-process Prozessüberwachung** zu agieren. Bei der quantitativen Charakterisierung zeigt sich, dass lediglich ein Ansatz (Clijsters et al., 2014) eine teilweise **Quantifizierung** der Porosität vornimmt. Die **ortsaufgelöste Messung** findet bei vier von fünf

¹⁵ https://www.trumpf.com/de_DE/produkte/services/services-maschinen-systeme-und-laser/monitoring-analyse/monitoring-truprint/ (abgerufen am 27.10.2022)

¹⁶ <https://velo3d.com/product-brief-assure-quality-assurance-software/> (abgerufen am 27.10.2022)

Ansätzen statt (Clijsters et al. 2014; DePond et al. 2018; Hooper 2018; Tao et al. 2023). Die **industrielle Anwendbarkeit** ist bei einem von fünf Ansätzen (Clijsters et al. 2014) bedingt gegeben und bei einem von fünf (Tao et al. 2023) vollständig gegeben.

Die **optischen off-axis Prozessüberwachungen** mit Zieldefekt Porosität setzen sensorseitig auf Fotodioden, Thermografiekameras und CMOS- oder CCD-Kameras. Die Möglichkeit der **in-process Prozessüberwachung** ist bei vier von fünf Ansätzen (Bisht et al., 2018; Krauss et al., 2012, 2014; Zenzinger et al., 2014) komplett gegeben, ein Ansatz (Foster et al. 2015) erfüllt dies nur bedingt. Die **quantitative Charakterisierung** der im Prozess entstehenden Porosität findet in keinem der Ansätze statt. Alle Ansätze aus der Kategorie off-axis Prozessüberwachungen sind zumindest teilweise in der Lage, eine **ortsaufgelöste Messung** durchzuführen. Die **industrielle Anwendbarkeit** ist lediglich bei zwei (Foster et al. 2015; Zenzinger et al. 2014) von fünf Ansätzen bedingt gegeben.

Akustische Ansätze zur Prozessüberwachung der Porosität nutzen Sensoren aus dem Bereich Körperschall, SRAS, aktive Ultraschalldurchschallung, Faser-Bragg-Gitter sowie Mikrofone. Eine **in-process Prozessüberwachung** ist bei sechs von sieben Ansätzen möglich, lediglich bei (Smith et al., 2016) ist dies nicht möglich. Die **quantitative Defektcharakterisierung** ist bei keinem der acht Ansätze gegeben. Die Möglichkeit der **ortsaufgelösten Messung** ist bei zwei von acht Ansätzen (Hirsch et al., 2017; Smith et al., 2016) komplett gegeben, bei einem weiteren Ansatz (Rieder et al. 2016) ist dies bedingt möglich. Die **industrielle Anwendbarkeit** ist bei drei von sechs Ansätzen (Eschner et al. 2020; Eschner 2021; Rieder et al. 2016; Wasmer et al. 2019; Wasmer et al. 2018) möglich.

Die **weiteren Ansätze** zur Prozessüberwachung nutzen Röntgenstrahlung oder Wirbelstromsensoren, um die Möglichkeit einer Prozessüberwachung zu untersuchen. Weiterhin erfolgt in Wang et al. (2022) der Versuch einer analytischen Betrachtung. Die **in-process Prozessüberwachung** ist lediglich bei (Calta et al. 2018) möglich. Die **quantitative Defektcharakterisierung** ist bei keinem der Ansätze gegeben. Die Messung erfolgt bei allen vier vorgestellten Ansätzen zumindest teilweise **ortsaufgelöst**. **Industrielle Anwendbarkeit** wird den beiden Ansätzen mit Wirbelstromsensorik (Du et al., 2017; Evgueni Todorov et al., 2018) sowie dem analytischen Ansatz von Wang et al. (2022) teilweise zugesprochen.

Die vorgestellten **Herstelleransätze** sind allesamt **in-process** Prozessüberwachungen, welche eine **ortsaufgelöste Messung** ermöglichen. Die technischen Spezifikationen werden von den Herstellern nur eingeschränkt offengelegt: die genaue verwendete Sensorik (Hersteller und Modell bzw. Typenbezeichnung der Sensoren) wird nicht angegeben. Ebenso wird in vielen Ansätzen auch das zugrundeliegende Sensorprinzip nicht angegeben. Durch den Einbauort der Sensoren können jedoch Rückschlüsse auf das Sensorprinzip getroffen werden. Die Ansätze sind bis auf einen Ansatz (*Renishaw InfiniAM Sonic* - akustisch) optischer Natur: entweder on-axis im Strahlengang oder off-axis. Alle Herstelleransätze bieten dem Anwender eine Form von Rückmeldung über das aktuelle Prozessgeschehen, überwiegend in Form von Bildern in Falschfarben. Dort werden Defekte, Bereiche mit möglichen Fehlern sowie Prozessabweichungen dargestellt. Eine dedizierte Rückführung auf einzelne Defekttypen wie in Kapitel 2.1.4 vorgestellt erfolgt nicht. Dies bedingt auch, dass **keine Quantifizierung von Defekten** wie bspw. Poren erfolgt. Die Hersteller legen die verwendeten Analysealgorithmen nicht offen, sodass die Nutzung im wissenschaftlichen Kontext, v.a. von herstellerunabhängigen Systemen, problematisch ist, da die Nachvollziehbarkeit der Datenauswertung nicht gegeben ist.

Tabelle 3-1: Zusammenfassung der betrachteten Forschungsansätze

○	Nicht erfüllt / keine Aussage				
◐	Bedingt erfüllt				
●	erfüllt				
		In-Process Prozessüberwachung	Quantitative Defektcharakterisie- rung	Ortsaufgelöste Messtechnik	Industrielle Anwendbarkeit
Optik: On-Axis	Clijsters et al. (2014)	●	◐	●	◐
	DePond et al. (2018)	○	○	●	○
	Hooper (2018)	●	○	●	○
	Pavlov et al. (2010)	●	○	○	○
	Tao et al. (2023)	●	○	●	●
Optik: Off-Axis	Bisht et al. (2018)	●	○	●	○
	Foster et al. (2015)	◐	○	◐	◐
	Krauss et al. (2012)	●	○	◐	○
	Krauss et al. (2014)	●	○	●	○
	Zenzinger et al. (2014)	●	○	●	◐
Akustik	Eschner et al. (2020) Eschner (2021)	●	○	○	●
	Hirsch et al. (2017)	●	○	●	○
	Rieder et al. (2016)	●	○	◐	●
	Smith et al. (2016)	○	○	●	○
	Wasmer et al. (2018) Wasmer et al. (2019)	●	○	○	●
	Ye et al. (2018)	●	○	○	○
Weitere	Calta et al. (2018)	●	○	◐	○
	Du et al. (2018)	○	○	●	◐
	Todorov et al. (2018)	○	○	●	◐
	Wang et al. (2022)	○	◐	◐	◐

4 Forschungsdefizit

In Tabelle 3-1 sind die betrachteten **Forschungsansätze** sowie deren Bewertung in Bezug auf die Anforderungen an Prozessüberwachungen aus Kapitel 3.1 zusammengefasst. Es ist zu erkennen, dass die Mehrheit der Ansätze (14 von 20) die Anforderung einer **in-process Prozessüberwachung** vollständig erfüllt, ein Ansatz nur bedingt. Bei elf von 20 Ansätzen findet eine vollständige, bei fünf von 20 eine teilweise **ortausaufgelöste Messung** mit der verwendeten Sensorik statt. Die **industrielle Anwendbarkeit** der Ansätze ist lediglich bei vier von 20 Ansätzen vollständig gegeben, weitere sechs sind teilweise für eine industrielle Nutzung geeignet. In Bezug auf die **quantitative Defektcharakterisierung** ist erkennbar, dass nur zwei Ansätze diese Anforderung teilweise erfüllen. Alle anderen Ansätze erfüllen diese Anforderung gar nicht.

Die kommerziell erhältlichen **Herstelleransätze** erfüllen die Anforderung nach industrieller Anwendbarkeit inhärent und sind ortaufgelöst sowie in-process. Jedoch ermöglicht keiner der betrachteten Herstelleransätze eine quantitative Defektcharakterisierung, sodass auch hier Potential zur Weiterentwicklung besteht.

Es zeigt sich, dass es bisher keinen ganzheitlichen Ansatz zur Prozessüberwachung hinsichtlich Porosität im PBF-LB/M Fertigungsverfahren gibt, welche alle Anforderungen erfüllt. Die in-process Prozessüberwachung samt einer ortsaufgelösten Messung stellt den Stand der Forschung dar. Eine weiterentwickelte Prozessüberwachung muss zusätzlich die Anforderung an eine quantitative Defektcharakterisierung erfüllen und industrielle Anwendbarkeit besitzen.

5 Eigener Ansatz

Nachdem in Kapitel 4 das dieser Arbeit zugrunde liegenden Forschungsdefizit vorgestellt wurde, widmet sich Kapitel 5 der Vorstellung des eigenen Ansatzes zur Behebung des Forschungsdefizites.

5.1 Überblick über den eigenen Ansatz

In Abbildung 5-1 ist der strukturelle Ablauf des eigenen Ansatzes dargestellt. Zunächst wird konkrete Sensorik ausgewählt und in eine industrielle PBF-LB/M Anlage integriert. Danach werden Probekörper erzeugt und währenddessen mit der Sensorik die Daten für die datengetriebene Modellbildung erfasst. Nach Erzeugung der Probekörper werden diese mittels Computertomographie auf Porosität untersucht, sodass eine Referenzmessung vorliegt. Mit den während der Fertigung der Probekörper erfassten Daten der Sensoren sowie der Referenzmessung wird abschließend die Datenanalyse durchgeführt.

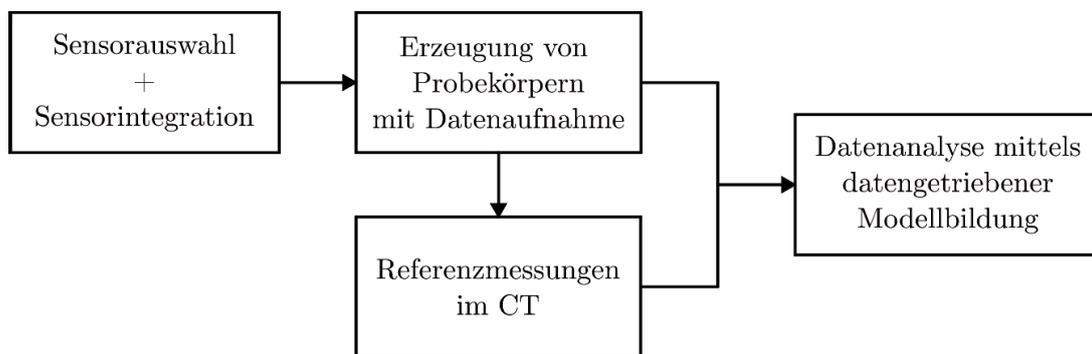


Abbildung 5-1: Struktureller Ablauf des eigenen Ansatzes

5.2 Sensorauswahl und Sensorintegration in die PBF-LB/M Anlage

Damit im Rahmen der datengetriebenen Modellbildung Daten während des PBF-LB/M-Fertigungsverfahrens erfasst werden können, muss geeignete Sensorik ausgewählt und in eine PBF-LB/M-Anlage integriert werden. Die verwendete PBF-LB/M-Anlage wird deshalb in Kapitel 5.2.1 vorgestellt. In Kapitel 5.2.2 werden geeignete Sensorprinzipien zur Detektion von Porosität ausgewählt. In Kapitel 5.2.3 wird die technische Integration der ausgewählten Sensorik in die PBF-LB/M-Anlage vorgestellt.

5.2.1 Vorstellung der verwendeten PBF-LB/M Anlage

Die Durchführung aller praktischen Arbeiten erfolgt an einer PBF-LB/M Anlage (nachfolgenden nur noch Anlage genannt) des Typs *Realizer SLM125* des Herstellers *Realizer* bzw. *DMG Mori*¹⁷. Die Anlage besitzt ein Bauvolumen von 125 x 125 x 200 mm³ (LxBxH). Als Schutzgas wird im Prozess Argon verwendet. Das maximale Restsauerstofflevel beträgt 0,3 %. Die Beschichtung erfolgt durch eine radial ausgeführte Beschichtereinheit. Der Aufbau des Bauraums der Anlage ist in Abbildung 5-2 dargestellt.

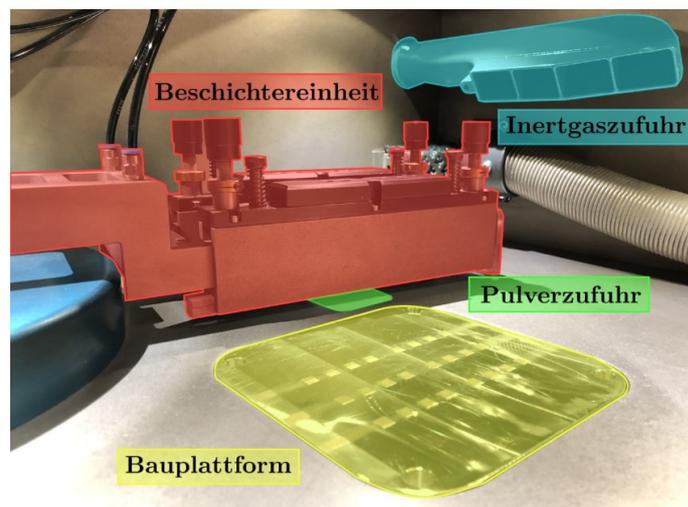


Abbildung 5-2: Komponenten im Bauraum der Realizer SLM125 – eigene Darstellung

Der Laser stammt vom Hersteller *IPG Laser GmbH*. Genutzt wird das Modell *YLM-200*. Der Laser ist ein Yb:YAG-Laser, welcher einen konstanten Emissionsmodus hat (CW-Laser) und eine maximale Laserleistung von 200 Watt mit einer Wellenlänge von 1070 nm aufweist. Das optische System besteht aus einer verstellbaren Fokusvariation, zwei Galvanometerscannern (Hersteller: *Cambridge Technology Inc.*) sowie einer F-Theta-Linse. Der prinzipielle Aufbau des optischen Pfads ist in Abbildung 5-3 dargestellt.

¹⁷ Der ursprüngliche Hersteller der Anlage *SLM125* war die *Realizer GmbH* mit Sitz in Borchon. Die Gesellschaft wurde von der *DMG Mori Additive GmbH* übernommen.

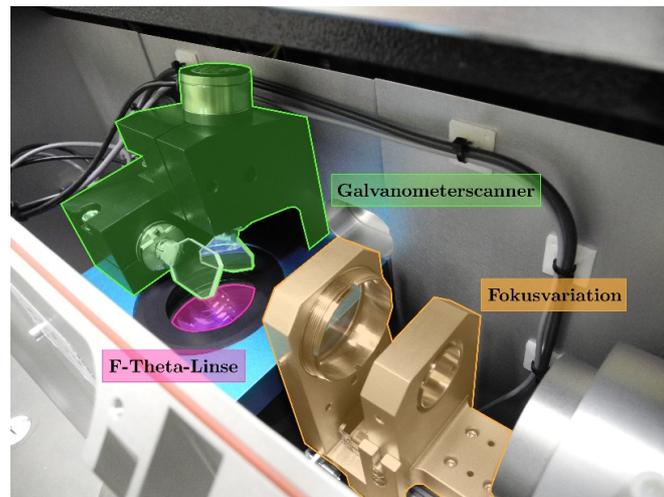


Abbildung 5-3: Komponenten im optischen Pfad der Realizer SLM125 – eigene Darstellung

Die Anlagensteuerung besteht im Wesentlichen aus den folgenden Kernkomponenten:

- Bedienerrechner für Nutzereingaben
- Speicherprogrammierbare Steuerung (SPS) der Herstellers *Beckhoff*
- DOS-basierter Steuerungsrechner für die Kommunikation mit Laser und Galvanometer-Scannersystem

Der Aufbau sowie die verwendeten Kommunikationsprotokolle zwischen den Komponenten sind in Abbildung 5-4 dargestellt.

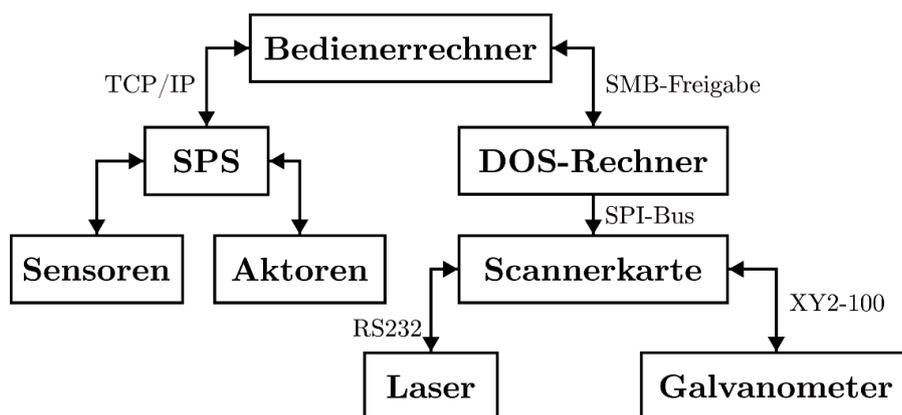


Abbildung 5-4: Vereinfachtes Kommunikationsmodell der Anlage Realizer SLM125 – eigene Darstellung

5.2.2 Sensorauswahl

Zur Erfassung von Prozessemissionen, welche die Datengrundlage für die Prozessüberwachung liefern, soll in diesem Kapitel geeignete Sensorik identifiziert und ausgewählt werden.

Im Stand der Forschung zeigt sich, dass **akustische Sensorik** geeignet ist, den Prozess grundlegend zu charakterisieren (vgl. Kapitel 3.2.3). Zur akustischen Erfassung der Prozessemissionen kommen zwei Verfahren in Betracht: die Nutzung von Körperschall oder Luftschall. Die Nutzung von Körperschallsensorik hat gegenüber einer Nutzung von Luftschallsensorik Vorteile: aufgrund der geringeren Dämpfung (vor allem von höherfrequenten Frequenzanteilen) in Feststoffen gegenüber gasförmigen Medien kann mittels Körperschall ein breiteres Prozessspektrum untersucht werden. Weiterhin ist die Datenerfassung von Körperschall robuster gegenüber Störeinflüssen aus dem Prozess, wie beispielsweise der Inertgasströmung. Zusätzlich ist durch Körperschall eine bessere Betrachtung von innenliegenden Defekten möglich. Dies führt in Summe dazu, dass im Rahmen dieser Arbeit eine passive Körperschallsensorik als akustisches Sensorprinzip ausgewählt wird. (A_Wilkes 2019; Eschner et al. 2020)

Neben der akustischen Körperschallsensorik wird im Rahmen dieser Arbeit ebenfalls untersucht, ob eine Datenfusion der verfügbaren Sensorik einen Vorteil in der erreichbaren Modellperformance bringt. Deshalb soll ein weiteres Sensorprinzip betrachtet werden. Im Stand der Forschung und Technik (vgl. Kapitel 3.2) zeigt sich, dass die zahlenmäßig meisten Ansätze im Bereich der optischen Prozessüberwachungen zu finden sind. Aus diesem Grund wird als weiteres Sensorprinzip ein **optisches Verfahren** ausgewählt, da so ein besserer Vergleich der erreichbaren Modellperformance durchgeführt werden kann und das optische Verfahren als Vergleichsgrundlage genutzt werden kann. Im Stand der Forschung und Technik zeigen sich zwei grundsätzliche Ansätze zur Integration von optischer Messtechnik. Die Entscheidung, ob die optische Sensorik im Rahmen dieser Arbeit on- oder off-Axis eingebaut wird, erfolgt über den technischen Aufbau der eingesetzten PBF-LB/M Anlage.

Die *Realizer SLM125* besitzt eine F-Theta-Linse. Diese sorgt dafür, dass der eingestellte Fokus des Lasers positionsunabhängig immer in der Ebene der obersten Pulverschicht liegt. Nachteilig wirkt sich aus, dass der Einsatz einer F-Theta-Linse eine Bildfeldwölbung bedingt. Die F-Theta-Linse muss immer passend zur Wellenlänge des verwendeten Lasers dimensioniert werden, da die gewünschten Eigenschaften der F-

Theta-Linse nur für monochromatisches Licht einer bestimmten Wellenlänge gelten. Die optischen Prozessemissionen, welche während der Belichtung entstehen, sind in drei Wellenlängenbereiche einteilbar: Prozessemissionen im sichtbaren Wellenlängenbereich (400 – 700 nm), Prozessemissionen im Wellenlängenbereich des Lasers (1070 nm) sowie Prozessemissionen im Infrarotbereich (900 – 2300 nm). Sollen diese Prozessemissionen durch den optischen Pfad der Anlage geleitet werden, werden die sichtbaren und infraroten Prozessemissionen in der F-Theta-Linse unterschiedlich gebrochen und umgelenkt als die Prozessemissionen des Lasers. Dies führt dazu, dass ein nicht unerheblicher Positionsfehler in das Signal eingebracht wird, sodass für die beiden Wellenlängenbereiche außerhalb der Spezifikation der F-Theta-Linse nicht mehr das Schmelzbad, sondern das umliegende Pulverbett betrachtet wird. Weiterhin ist die Integration von notwendigen Strahlteilern und der optischen Sensorik selbst in den Strahlengang mit umfangreichen konstruktiven Änderungen und einer erneuten Sicherheitsabnahme der Anlage verbunden, was in hohen Kosten¹⁸ resultieren würde. Aufgrund dieser beiden Tatsachen soll die optische Sensorik als off-axis Sensorik ausgeführt werden.

Um möglichst nah an der Prozesszone und dem Schmelzbad zu sein, wird die optische Sensorik in den Bauraum über der Bauplattform eingebracht. Damit die drei vorhandenen Wellenlängenbereiche separat betrachtet werden können, wird für jeden dieser Bereiche ein eigener Sensor verwendet. Um solche Spektralbereiche zu erfassen, eignen sich grundsätzlich Fotowiderstände, Fototransistoren und Fotodioden.

Fotowiderstände sind nicht für dynamische Messungen geeignet. Die Ansprechzeit dieser liegt zwischen 10 und 100 ms. Fototransistoren haben eine ausreichend schnelle Ansprechzeit und weisen eine hohe Empfindlichkeit auf, sodass auf eine Verstärkung des Messsignals verzichtet werden könnte. Fototransistoren sind jedoch nur mit Silizium als Halbleitermaterial erhältlich, was deren nutzbares Spektrum einschränkt. Fotodioden werden in unterschiedlichen Spektralbereichen angeboten, müssen aber aufgrund einer geringeren Empfindlichkeit als Fototransistoren in der Regel noch an eine Verstärkerschaltung angeschlossen werden. Basierend auf den verfügbaren Spektral-

¹⁸ Nach einem Kostenvoranschlag des Herstellers wären die Umbaumaßnahmen teurer als der Neupreis der Anlage.

bereichen werden für die optische Prozessüberwachung drei unterschiedliche Fotodioden genutzt. Dabei ist der Wellenlängenbereich, in der die Fotodiode sensitiv ist, das wichtigste Kriterium zur Auswahl einer spezifischen Fotodiode.

5.2.3 Sensorintegration in industrielle PBF-LB/M Anlage

Nachdem in Kapitel 5.2 der Aufbau der PBF-LB/M Anlage vorgestellt wurde und in Kapitel 5.2.2 die Auswahl geeigneter Sensorik erfolgte, wird in diesem Kapitel die technische Integration der Sensorik in die Anlage vorgestellt.

5.2.3.1 Akustische Körperschallsensorik

Als akustische Körperschallsensorik wird das *Analyzer4D* System des Hersteller QASS verwendet. Das System besteht aus einer Auswerteeinheit, einem Vorverstärker sowie dem Sensor selbst. Der Sensor wird unter der Bauplattform verschraubt und das Koaxialkabel vom Vorverstärker zum Anschluss des Sensors unter der Bauplattform hinausgeführt. Der Sensor wird mit einem konstanten Drehmoment von 6 Nm verschraubt. Zwischen Bauplattform und Sensor wird Glycerin als Koppelmedium für eine bessere Schallübertragung verwendet. Die Integration des Sensors unter der Bauplattform ist in Abbildung 5-5 dargestellt.

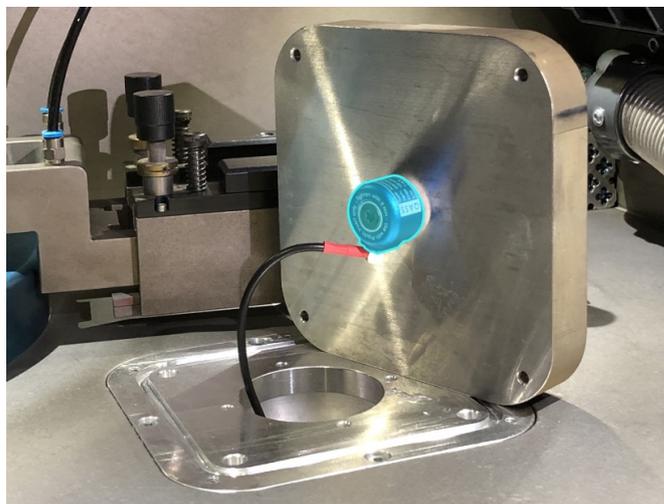


Abbildung 5-5: Körperschallsensor der Firma QASS, welcher unter der Bauplattform verschraubt wird.

Der Vorverstärker des Körperschallsystems ist im Schaltschrank der Anlage untergebracht. Die Auswerteeinheit selbst in einem Serverrack außerhalb der Anlage untergebracht und schließt den Vorverstärker kabelgebunden am Messeingang an.

5.2.3.2 Optische Sensorik

In Kapitel 5.2.2 wurde dargelegt, dass der Spektralbereich von Fotodioden den wesentlichen Auswahlfaktor einer konkreten Fotodiode darstellt. Basierend auf den drei Spektralbereichen, welche aufgezeichnet werden sollen, werden die folgenden Fotodioden ausgewählt:

Tabelle 5-1: Ausgewählte Fotodioden, um die gewünschten Wellenlängenbereiche λ aufzunehmen.

Modell	Hersteller	Typ	$\lambda_{50\%}$ ¹⁹ [nm]	$\lambda_{10\%}$ ¹⁹ [nm]	S_{max} ²⁰	Fläche [mm ²]
BPW21R	Vishay	Silizium PN	420 – 675	<350 – 750	9 nA/lx	7,5
FGA015	Thorlabs	InGaAs ²¹	930 – 1670	800 – 1700	1 A/W	0,0177
FD05D	Thorlabs	InGaAs ²¹	1450 – 2570	<900 – 2600	1,3 A/W	0,2

Da sich die Spektralbereiche der Fotodioden teilweise überlappen, muss auf optische Filter zurückgegriffen werden, damit eine getrennte Betrachtung der Wellenlängenbereiche möglich ist. Zur Erfassung der Laseremissionen wird ein enges Bandpassfilter verwendet. Zur Betrachtung des sichtbaren und des infraroten Wellenlängenbereichs kommen Langpassfilter zur Anwendung. Die genauen Bezeichnungen und Kennwerte der Filter können Tabelle 5-2 entnommen werden. (A_Meyer Garcia 2020)

Tabelle 5-2: Optische Filter zur genauen Einstellung der aufgezeichneten Wellenlängenbereiche λ .

Modell	Hersteller	Typ	CWL ²² [nm]	FWHM ²³ [nm]	COW ²⁴ [nm]
FB1070-10	Thorlabs	Bandpassfilter	1070 ± 2	10 ± 2 nm	-
FESH0750	Thorlabs	Kurzpassfilter	-	-	750 nm
FEL1150	Thorlabs	Langpassfilter	-	-	1150 nm

¹⁹ Wellenlängenbereich, bei der die Empfindlichkeit 50 % bzw. 10 % der maximalen Empfindlichkeit beträgt.

²⁰ Die Empfindlichkeit S_{max} ist bei der Diode für den sichtbaren Wellenlängenbereich auf die Beleuchtungsstärke in Lux angegeben.

²¹ Indium-Gallium-Arsenid

²² Center Wavelength: Mittenfrequenz / Mittenwellenlänge stellt das geometrische Mittel der unteren und oberen Grenzwellenlänge/-frequenz dar.

²³ Full-Width-at-Half-Maximum: Die volle Breite bei halbem Maximum ist der Abstand zwischen zwei benachbarten 50%-Kantenpunkten und wird auch als 50%-Bandbreite bezeichnet.

²⁴ Cut-On/Cut-Off Wavelength: Cut-On/Cut-Off Wellenlänge beschreibt einen Kantenübergang eines optischen Filters, bei dem die Transmission über einen zunehmenden Wellenlängenbereich stark ansteigt (Langpassfilter)/abfällt (Kurzpassfilter).

Die Fotodioden und optischen Filter wurden auf einer speziell angefertigten Platine befestigt, welche durch eine entsprechend konstruierte Halterung im Bauraum angebracht werden kann. Das System aus den drei Fotodioden und Filtern, nachfolgend *Fotodiodenarray* genannt, wird per Koaxialkabel, welches gasdicht aus dem Bauraum hinausgeführt wird, an drei Verstärker angeschlossen. Die Fotodioden stellen im elektrischen Schaltbild eine Stromquelle dar. Der auftretende Strom ist dabei von der Intensität der Bestrahlung abhängig. Das anliegende Stromsignal soll in eine Ausgangsspannung gewandelt werden, welche durch einen Analog-Digital-Wandler im Messaufnehmer erfasst werden kann. Der Verstärkungsfaktor der Verstärkerschaltung hat die Einheit $\Omega = V/A$. Dies stellt die Einheit einer Impedanz dar, weshalb die vorliegende Schaltung auch Transimpedanzverstärker genannt wird. In Abbildung 5-6 ist das Schaltbild des Transimpedanzverstärkers dargestellt. (Ferrari et al. 2009; Razavi 2019)

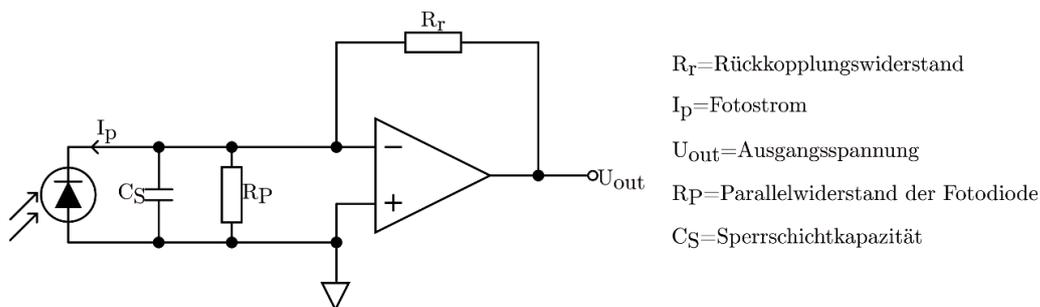


Abbildung 5-6: Schaltbild eines Transimpedanzverstärkers – eigene Darstellung nach (Ferrari et al. 2009; Razavi 2019)

Der Messgrößenaufnehmer wird auf Basis eines *STM32*-Microcontrollers (*STM32F373*) des Herstellers *STMicroelectronics* realisiert. Dieser enthält drei 16-bit Analog-Digital-Wandler, welche mit bis zu 50 kHz abgetastet werden können. Die drei Kanäle werden in ein gemeinsames Datenpaket überführt und als Byte-Stream per USB an einen zentralen Messrechner übertragen. Dort werden die Datenpakete mit einem Python-Skript wieder in die zugehörigen Kanäle decodiert und auf der Festplatte des Messrechners gespeichert.

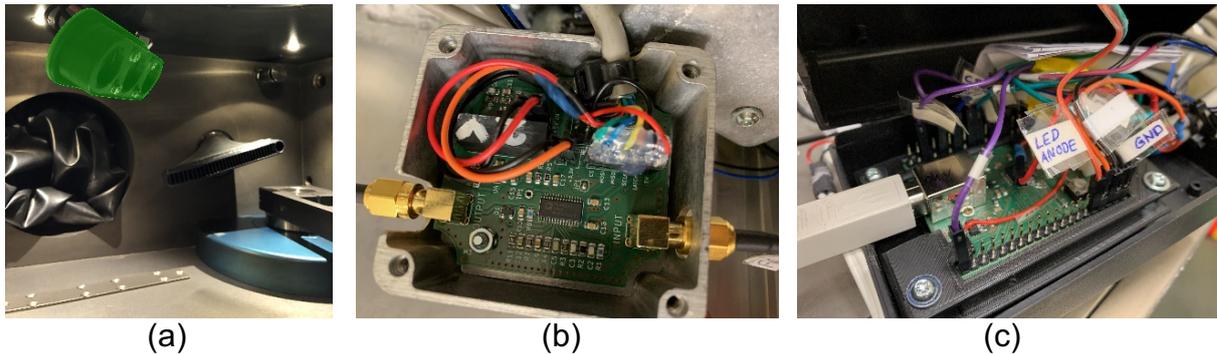


Abbildung 5-7: (a) Fotodiodenarray im Bauraum (grün eingefärbt), (b) Transimpedanzverstärker mit angeschlossener Sensorik, (c) Messgrößenaufnehmer auf Basis eines STM32-Microcontrollers

5.2.3.3 Anpassung der Anlagenhardware

Im Zuge der Messtechnikintegration in die PBF-LB/M Anlage wurden ebenfalls hardwaretechnische Anpassungen an der Anlage vorgenommen. Diese werden in der Folge vorgestellt.

Konfigurierbarer Trigger-Pin

In der Anlage wurde eine eigens angefertigte Platine verbaut, die es ermöglicht, per Steuerbefehl in der Druckdatei, die durch die Druckjobvorbereitung erstellt wird, einen Pin gezielt auf 0 V oder 5 V (Transistor-Transistor-Logik - TTL) zu schalten. Mit diesem Pin können alle angeschlossenen Messgeräte synchronisiert durch die Erkennung von steigenden und fallenden Flanken die Datenaufzeichnung starten.

Positionsaufzeichnung

Damit die Sensordaten der akustischen Körperschallsensorik und des optischen Fotodiodenarrays orts aufgelöst betrachtet werden können, muss die Position des Lasers aufgezeichnet werden. Die Laserposition auf der Bauplatzform wird dabei durch Galvanometerscanner bestimmt. Da nach der Ablenkung durch die Galvanometerscanner noch die Objektfeld-Wölbung durch die F-Theta-Linse erfolgt, muss das Eingangssignal für die Galvanometerscanner die Inverse der Übertragungsfunktion enthalten. So wird sichergestellt, dass eine korrekte geometrische Abbildung durch den Laser auf der Bauplatzform erfolgt. Das Signal zur Ansteuerung der Galvanometer in der Anlage ist als SPI-Bus ausgeführt. Dieses Signal wird abgegriffen und mittels eines weiteren STM32-Microcontrollers (STM32F373) decodiert und als Rohbitwerte per USB an den Messrechner gesendet. Die Positionsaufzeichnung kann über den Trigger-Pin gestartet und

gestoppt werden. Die Positionsdaten werden mit einer Abtastrate von 47.059 Hz erfasst. Wichtig ist zu beachten, dass die Positionsdaten die Soll-Position und nicht die Ist-Position des Lasers darstellen. Die verwendeten Galvanometerscanner sind nur gesteuert und nicht geregelt, sodass die Erfassung der Ist-Position des Lasers nicht möglich ist. Die konkrete Umrechnung der Rohpositionsdaten in die verschiedenen Koordinatensysteme wird in Kapitel 5.5.1 vorgestellt.

5.2.3.4 Anpassung der Anlagensoftware

Die Kommunikation zwischen dem Bedienerrechner und dem DOS-Rechner erfolgt über eine SMB-Freigabe (vgl. Abbildung 5-4). Die beiden Rechner kommunizieren über das Anlegen und Quittieren von Dateien miteinander. An dieser Stelle können beliebige Befehle in die Kommunikation eingeschleust werden.

Dazu wird die Anlagensoftware so umprogrammiert, dass der Bedienerrechner die Dateien nicht im Freigabeordner des DOS-Rechners erstellt, sondern diese in einem anderen Ordner ablegt. Mittels einer selbstgeschriebenen Software auf Basis der Programmiersprache Python werden beide Ordner überwacht und die Dateien in den jeweils anderen Ordner gelegt. Während dieses Vorgangs können die Befehle verändert und angepasst werden, um beliebiges Anlagenverhalten erzeugen zu können.

5.3 Erzeugung von Probekörpern mit Datenaufnahme

In Kapitel 5.3.1 wird zunächst vorgestellt, wie Porosität in die Probekörper im Rahmen der vorliegenden Arbeit eingebracht werden soll. In Kapitel 5.3.2 wird dann dargelegt, wie die Geometrie der Probekörper gestaltet ist. Kapitel 5.3.3 stellt dar, welches Material für die Herstellung der Probekörper genutzt wird. Die Durchführung der Druckjobs samt Datenaufnahme wird in Kapitel 5.3.4 vorgestellt.

5.3.1 Vorgehen zur Einbringung von Porosität

In der Literatur wird zur gezielten Einbringung von Porosität sehr häufig eine Parametervariation der Prozessparameter des PBF-LB/M Verfahrens durchgeführt. Dabei werden Parameter wie die Belichtungsgeschwindigkeit, die Laserleistung, der Spurabstand oder die Schichtdicke in einem so großen Prozessfenster variiert, dass nicht mehr die vom Hersteller für die Anlage und das Material empfohlenen Parameter eingehalten werden. Diese Parametervariation ermöglicht es, Bauteile mit erhöhter Porosität herzu-

stellen, da der volumetrische Energieeintrag das Prozessfenster in einen Bereich verschiebt, bei dem Porosität auftritt (vgl. Kapitel 2.1.4.1). Im Rahmen der datengetriebenen Modellbildung führt dieses Vorgehen zur Einbringung von erhöhter Porosität jedoch zu einem Problem: es kann nicht sichergestellt werden, dass das entwickelte Modell sensitiv auf das Auftreten von Porosität ist. Vielmehr kann es ebenso sein, dass das Modell sensitiv auf Prozessparameterkombinationen ist und lernt, diese in den Sensordaten wiederzuerkennen. Weiterhin ist das Vorgehen der Parametervariation in der industriellen Produktion nicht üblich, da in der Regel mit Herstellerparametersätzen oder eigenentwickelten Parametersätzen gearbeitet wird, welche nicht zwischen den Druckjobs verändert werden. Ist ein Parametersatz für ein Material freigegeben und qualifiziert worden, so wird dieser in der Produktion als fixer Parametersatz verwendet. (Coeck et al. 2019)

Im Rahmen dieser Arbeit wird deshalb ein Vorgehen zur Einbringung von Porosität verwendet, das serienfertigungsnahe Defektmechanismen nutzt. Ziel dabei ist es, eine Datengrundlage für die datenbasierte Modellbildung zu schaffen, in welcher die Modelle sensitiv auf zugrundeliegende Defektmechanismen reagieren.

Wie im vorigen Teil dargestellt, ist aus der industriellen Praxis bekannt, dass die Parameter, sobald diese qualifiziert sind, nicht verändert werden. Aus diesem Grund wird im Rahmen dieser Arbeit der empfohlene Herstellerparametersatz für das verwendete Material für alle Probekörper verwendet.

Durch das Anpassen anderer Einflussgrößen als der Prozessparameter soll die im Prozess vorhandene Stochastik in der Art gefördert werden, dass dennoch verschiedene Porosität in den Probekörpern auftreten. Dazu können beispielsweise die folgenden Einflussgrößen variiert werden:

Belichtungsreihenfolge

Die Belichtungsreihenfolge von mehreren Probekörpern auf einer Bauplatzform wird idealerweise so gewählt, dass die Belichtungsreihenfolge entgegen der Richtung der Inertgasströmung ist. So wird vermieden, dass Prozessnebenprodukte durch die Inertgasströmung auf Bereichen des Pulverbetts verteilt wird, die noch für andere Probekörper zu belichten sind. Sind in noch zu belichtenden Bereichen Prozessnebenprodukte abgelagert, so führt dies zu einem veränderten volumetrischen Energieeintrag in diesem Bereich und die Wahrscheinlichkeit für das Auftreten von Porosität steigt. In der Praxis kann, trotz der Belichtung entgegen der Inertgasströmung nicht ausgeschlossen

werden, dass keine Prozessnebenprodukte in noch zu belichteten Bereichen des Pulverbetts vorhanden sind.

Dieses Verhalten kann ausgenutzt werden, um so trotz idealer Prozessparameter das Auftreten von Porosität zu fördern. Dazu wird eine Belichtungsreihenfolge gewählt, bei der die Belichtungsrichtung entlang der Inertgasströmung liegt, sodass mehr Prozessnebenprodukte in den noch zu belichtenden Bereich getragen werden. Dies führt in der Folge zu einem verstärkten Auftreten von Porosität in diesem Bereich.

Belichtungsstrategie

Durch die Wahl der angewandten Belichtungsstrategie kann ebenfalls das stochastische Auftreten von Porosität beeinflusst werden. In Kapitel 2.1.3 sind die verschiedenen Arten der Belichtungsstrategie vorgestellt worden. Durch eine geeignete Parametrierung der Belichtungsstrategie kann das Auftreten von Porosität gefördert werden. So kann bspw. bei der Schachbrett-Strategie die Überlappung der einzelnen Bereiche so parametrisiert werden, dass in den Randgebieten das Auftreten von Defekten gefördert wird (vgl. (A_Bauder 2020)).

Füllgrad der Bauplatzform

Durch die Variation des Füllgrads der Bauplatzform kann ebenfalls Einfluss auf das Auftreten von Porosität genommen werden. Dabei sind zwei Möglichkeiten vorhanden, den Füllgrad zu variieren: (I) den Anteil der zu belichtenden Fläche an der Gesamtfläche der Bauplatzform zu variieren oder (II) den Abstand zwischen einzelnen Probekörper variieren. In beiden Fällen werden der lokale Energieeintrag und die Abkühlraten verändert, sodass unterschiedliche Prozessbedingungen vorherrschen.

Inertgasströmung

Die Inertgasströmung hat einen wesentlichen Einfluss auf das erreichbare Prozessergebnis. Dabei soll sie eine Inertgasatmosphäre bereitstellen, sodass keine Oxidation des geschmolzenen Pulvers stattfindet. Weiterhin soll sie die entstehende Prozessnebenprodukte abziehen und idealerweise aus der Prozesszone und dem Bauraum entfernen.

Damit die Inertgasströmung ideal wirken kann, sollte diese einen möglichst laminaren Fluss über der Bauplatzform haben und eine Mindestgeschwindigkeit aufweisen, aber nicht mit dem Pulver auf der Bauplatzform interagieren. Bei modernen Anlagen sorgen dedizierte Beruhigungsstrecken für eine Laminarisierung der Strömung.

Eine gezielte Variation der Inertgasströmung ist durch das Beeinflussen und Verändern der Beruhigungsstrecken möglich. Durch beispielsweise 3D-gedruckte Aufsätze für die Inertgaszufuhr (vgl. Abbildung 5-2) kann gezielt das Auftreten einer turbulenten Inertgasströmung hervorgerufen werden.

Anteil an Recyclingpulver

Bereits im Prozess genutztes Pulver wird für eine gesteigerte Wirtschaftlichkeit und Nachhaltigkeit des Fertigungsverfahrens aufbereitet und dem Pulverkreislauf wieder zugeführt. Das Pulver wird nach dem Druckjob aus der Baukammer entfernt und gesiebt. Dies soll Grobanteile, die aus den Prozessnebenprodukten stammen, entfernen. Die Filterung erfolgt dabei häufig über ein Ultraschallsieb. Das Recyclingpulver weist trotz Filterung auf mikroskopischer Ebene Veränderungen wie etwa Anhaftungen auf. Diese sorgen für ein verändertes Prozessverhalten sowie eine schlechtere Fließfähigkeit des Pulvers. Zur Beeinflussung des Prozessergebnisses kann gezielt Recyclingpulver in einem definierten Verhältnis mit Frischpulver gemischt und dem Prozess zugeführt werden. Bei zunehmendem Anteil an Recyclingpulver ist von einer Zunahme an Defekten auszugehen.

Aus den oben genannten möglichen Parametern sollen die zu betrachtenden Parameter ausgewählt werden. Zunächst wird begründet, welche Parameter **nicht** variiert werden.

Die **Inertgasströmung** in der genutzten Anlage muss nicht künstlich verändert werden. Die vorliegende konstruktive Gestaltung der Inertgasführung hat weder notwendige Beruhigungsstrecken noch ist diese für einen möglichst laminare Strömung optimiert. Dies führt zu einer stark turbulenten Strömung innerhalb der Baukammer der Anlage, was sich deutlich an den Bereichen der Baukammer zeigt, welche nach einem Druckjob gereinigt werden müssen, da diese mit Prozessnebenprodukten kontaminiert sind.

Der **Anteil an Recyclingpulver** wird ebenfalls nicht betrachtet, da die angestrebte Anzahl an Probekörpern mit einer Pulvertankfüllung der Anlage realisiert werden kann.

Es wird weiterhin keine Veränderung der **Belichtungsstrategie** vorgenommen. Damit eine positionsaufgelöste Messung möglichst einfach realisiert werden kann, soll im Rahmen dieser Arbeit eine simple Belichtungsstrategie wie die Streifenbelichtung verwendet werden. Bei komplexeren Belichtungsstrategien mit Sprüngen und Überlappungen ist der rechentechnische Aufwand in der Datenauswertung signifikant erhöht.

Verändert wird der **Füllgrad der Bauplattform**. Durch die Anpassung des Abstands zwischen den Probekörpern wird einmal eine veränderte Wärmeleitung im Pulverbett hervorgerufen und die Prozessnebenprodukte lagern sich nicht so einfach auf noch zu belichtenden Bereichen ab. Der Abstand zwischen den Probekörpern soll in zwei Parameterstufen variiert werden: (+) maximaler Abstand zwischen den Probekörpern durch gleichmäßige Verteilung auf der Bauplattform und (-) minimaler Abstand zwischen den Probekörpern, sodass der vom Hersteller vorgegebene minimale Abstand von 4 mm zwischen Bauteilen eingehalten wird. Der Anteil der zu belichtenden Fläche an der Gesamtfläche der Bauplattform wird nicht nennenswert variiert (vgl. Abbildung 5-10), um die Anzahl der Drucke auf ein überschaubares Maß zu begrenzen und den zeitlichen Aufwand für Druckjobvorbereitung und Reinigung der PBF-LB/M Anlage zu reduzieren.

Als weiterer Parameter, der variiert werden soll, wird die **Belichtungsreihenfolge** ausgewählt. Auch hier sollen, wie schon beim Füllgrad der Bauplattform, zwei Parameterstufen genutzt werden. Im Rahmen der Probekörperherstellung sollen die ideale Druckreihenfolge entgegen der Inertgasströmung genutzt werden (+) sowie die direkt umgekehrte Belichtungsreihenfolge mit der Inertgasströmung (-). So sollen Prozessnebenprodukte gezielt in noch zu belichtenden Bereichen abgelegt werden.

Die beiden zu betrachtenden Parameter Belichtungsreihenfolge und Füllgrad der Bauplattform werden jeweils in zwei Parameterstufen durchgeführt, sodass in Summe vier Druckjobs aus den Parameterstufen resultieren. Die ausgewählten Parameterkombinationen für jeden Druckjob sind in Tabelle 5-3 dargestellt. In Verlauf der vorliegenden Arbeit wird auf die hier dargestellte Nummerierung der Druckjobs referenziert.

Tabelle 5-3: Parameterstufen zur serienfertigungsnahen Erzeugung von Porosität

Druckjob	Parameter	Belichtungsreihenfolge auf Bauplattform	Füllgrad der Bauplattform
Druckjob 1		+	-
Druckjob 2		-	-
Druckjob 3		+	+
Druckjob 4		-	+

5.3.2 Geometrie der Probekörper

Zur Ableitung einer geeigneten Geometrie sollen zunächst die Anforderungen an die Probekörper im Rahmen der vorliegenden Arbeit dargestellt werden:

Referenzmessung im Computertomographen

Im Bereich der zerstörungsfreien Prüfung hat sich die Computertomographie etabliert, um additiv gefertigte Bauteile auf das Vorhandensein von Porosität zu untersuchen. Die Computertomographie mit der dazugehörigen Auswertesoftware ist in der Lage, die verschiedenen Kenngrößen der Porosität auch im Volumen zu erfassen. Durch das Registrieren des Bauteils kann ein Bauteilkoordinatensystem erstellt werden, was die Untersuchung der Porosität mit einer räumlichen Auflösung zulässt. Die wichtigsten Kernanforderungen aus diesem Punkt sind deshalb:

- Maximale Durchstrahlungslänge für CT geeignet
- Marker / Merkmale für Registrierung notwendig

Möglichkeit zur Untersuchung der mechanischen Eigenschaft

Eine der grundlegenden Motivationen hinter dem Einsatz einer Prozessüberwachung ist das Bestreben, die additive Fertigung auch für hochbelastete Bauteile einzusetzen. Die Gestaltung der Probekörper sollte es deshalb ermöglichen, eine Untersuchung der mechanischen Kennwerte des Probekörpers durchzuführen und somit auch den Einfluss der Porosität quantifizieren zu können (vgl. Kapitel 2.1.4.2). Die wichtigsten Kernanforderungen aus diesem Punkt sind deshalb:

- Untersuchung der mechanischen Kennwerte nach Norm
- Gleiche Geometrie für alle Probekörper entsprechend der Norm

Einfache Geometrie zur Auswertung

Um den Aufwand in der Auswertung zu reduzieren, wird zunächst auf die Betrachtung komplexer Strukturen, wie bspw. Gitter- oder Wabenstrukturen verzichtet. Die additive Fertigung ist grundsätzlich in der Lage, solche Strukturen herzustellen. Die Betrachtung dieser Strukturen liefert keinen methodischen Mehrwert, weshalb sich diese Arbeit auf einfachere geometrische Strukturen fokussiert. Die wichtigsten Kernanforderungen aus diesem Punkt sind deshalb:

- Keine Gitter- oder Wabenstrukturen
- Einfach Grundgeometrie wie Zylinder oder Quader

In Abbildung 5-8 ist die technische Zeichnung des Probekörpers dargestellt, der die genannten Anforderungen erfüllt.

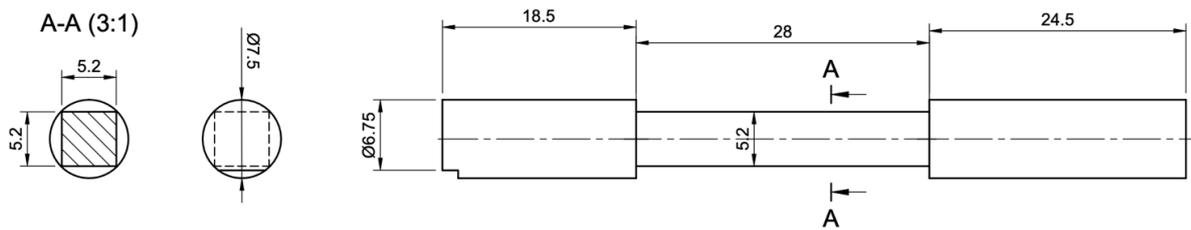


Abbildung 5-8: Technische Zeichnung der Probekörpergeometrie (alle Maße in mm).

Die vorliegende Probekörpergeometrie stellt einen additiv fertigen Rohling für eine Zugprobe nach DIN 50125 Typ A dar. Die Probe wird endkonturnah gefertigt, muss aber, um der Spezifikation der Norm zu genügen noch spanend nachbearbeitet werden. Die Fertigung eines Zugprobenrohlings ermöglicht die **Untersuchung der mechanischen Eigenschaften** der Probe. Der mittlere Teil der Probe ist der Bereich, der während der Durchführung eines Zugversuchs mechanisch versagen wird. Aus diesem Grund soll dieser Bereich auf Porosität untersucht werden. Die Zugprobe nach DIN 50125 Typ A weist in diesem Bereich einen runden Querschnitt auf. In der Schnittdarstellung A-A in Abbildung 5-8 ist jedoch ein quadratischer Querschnitt in diesem Bereich erkenntlich, was ebenfalls eine **einfache Grundgeometrie** darstellt. Der quadratische Querschnitt wurde gewählt, um einheitliche Länge der Scanvektoren des Lasers zu ermöglichen. Dies führt zu einem einfacher abbildbaren Prozess und Datenstrukturen in der nachgelagerten Datenanalyse. Die **maximale Durchstrahlungslänge** des Probekörper bei einer Rotation im CT um die Mittelachse liegt bei 7,5 mm, was mit dem zur Verfügung stehenden CT-Gerät (*Zeiss Metrotom 800 225kV*) selbst bei Bauteilen mit hoher Dichte wie bspw. Stahl als Werkstoff noch eine ausreichende Voxelgröße, Auflösung, Schärfe und Kontrast bietet, um Poren typischer Größe (vgl. Kapitel 2.1.4.1) zuverlässig erkennen zu können. Das Vorgehen zur Validierung der Referenzmessung wird in Kapitel 5.4.1 vorgestellt. Am kürzeren zylindrischen Ende der Probe wird eine Kerbe eingebracht, welche als **Marker für eine eindeutige Registrierung** des Bauteilkoordinatensystems im CT-Scan dient. Die Kerbe wird parallel zum quadratischen Mittelstück orientiert, wie in Abbildung 5-8 dargestellt ist. Das zugehörige Bauteilkoordinatensystem $KOS_{Bauteil}$ ist in Abbildung 5-9 dargestellt.

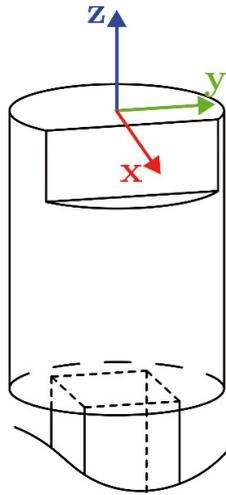


Abbildung 5-9: CT-Marker für Registrierung mit eingetragem xyz-Bauteilkoordinatensystem $KOS_{Bauteil}$

5.3.3 Material der Probekörper

Vom Hersteller der PBF-LB/M Anlage sind Parametersätze für aluminium- und eisenbasierte Werkstoffe vorhanden. Für aluminiumbasierte Pulver ist dies AISi10Mg, für eisenbasierte Pulver Edelstahl 316L (1.4404).

Der Edelstahl 316L hat eine höhere Dichte als AISi10Mg, sodass bei Bauteilen aus diesem Werkstoff die Untersuchbarkeit auf Defekte mittels Computertomographie auf geringere Durchstrahlungslängen eingeschränkt ist. Für solche Bauteile ist eine alternative Qualitätssicherung durch eine in-process Prozessüberwachung von umso größerer Relevanz. Aus diesem Grund wird im Rahmen dieser Arbeit der Werkstoff Edelstahl 316L (1.4404) verwendet. Das Datenblatt der verwendeten Pulvercharge ist dem Anhang dieser Arbeit beigefügt.

5.3.4 Druck der Probekörper

Damit alle Probekörper eindeutig identifizierbar sind und es in allen Schritten die Möglichkeit der Nachverfolgbarkeit gibt, wird jedem Probekörper eine individuelle numerische Seriennummer hinzugefügt. Diese Seriennummer wird auf der Stirnseite des Markers angebracht, sodass diese auch im CT-Scan zu erkennen ist.

Zur Druckjobvorbereitung wird im Rahmen dieser Arbeit das mit der PBF-LB/M Anlage ausgelieferte Programm *RDesigner*²⁵ verwendet. Die verwendeten Parameter sind in Tabelle 5-4 dargestellt.

Tabelle 5-4: Verwendete Prozessparameter zur Probenherstellung

Parameter	Kontur	Infill
Laserleistung	80	140 W
Belichtungsgeschwindigkeit	500 mm/s	1000 mm/s
Fokusbildung ²⁶	0 mm/100	140 mm/100
Schraffurabstand	-	0,08 mm
Schraffurüberlappung	-	0,02 mm
Rotation je Schicht	-	90°
Belichtungsstrategie	-	Flächige Belichtung
Inertgas	Argon	
Schichtdicke	50 µm	

Die Belichtung erfolgt in zwei separaten Phasen: als erstes wird die Kontur für alle Probekörper belichtet, danach das *Infill* für alle Probekörper. Durch dieses Vorgehen wird erheblich Zeit eingespart, da die Fokusbildung nicht durch die Fokusvariation zwischen dem Parametersatz *Kontur* und *Infill* zwischen jedem Probekörper umgestellt werden muss.

In Tabelle 5-3 wurde dargelegt, dass zur Realisierung der geplanten Defekteinbringung vier Druckjobs durchgeführt werden. Auf diese vier Druckjobs werden insgesamt 104 Probekörper (zwei Druckjobs mit 3x9 Probekörper sowie zwei Druckjobs mit 5x5 Probekörper) verteilt. Die gewählte Belichtungsreihenfolge und die konkrete Positionierung der einzelnen Probekörper auf der Bauplatzform sind in Abbildung 5-10 dargestellt. Die Belichtungsreihenfolge ist anhand der Nummerierung der Bauteile erkennbar. Wie in Kapitel 5.3.1 dargestellt, wird die Inertgasströmung nicht künstlich gestört und kommt konstant entgegen der x-Achse.

²⁵ Das Programm *RDesigner* wird in der Version 1.23.01 verwendet.

²⁶ Die Fokusbildung stellt eine Einstellung für die in der Anlage verwendete Fokusvariation mittels Schrittmotoren statt (vgl. Abbildung 5-3).

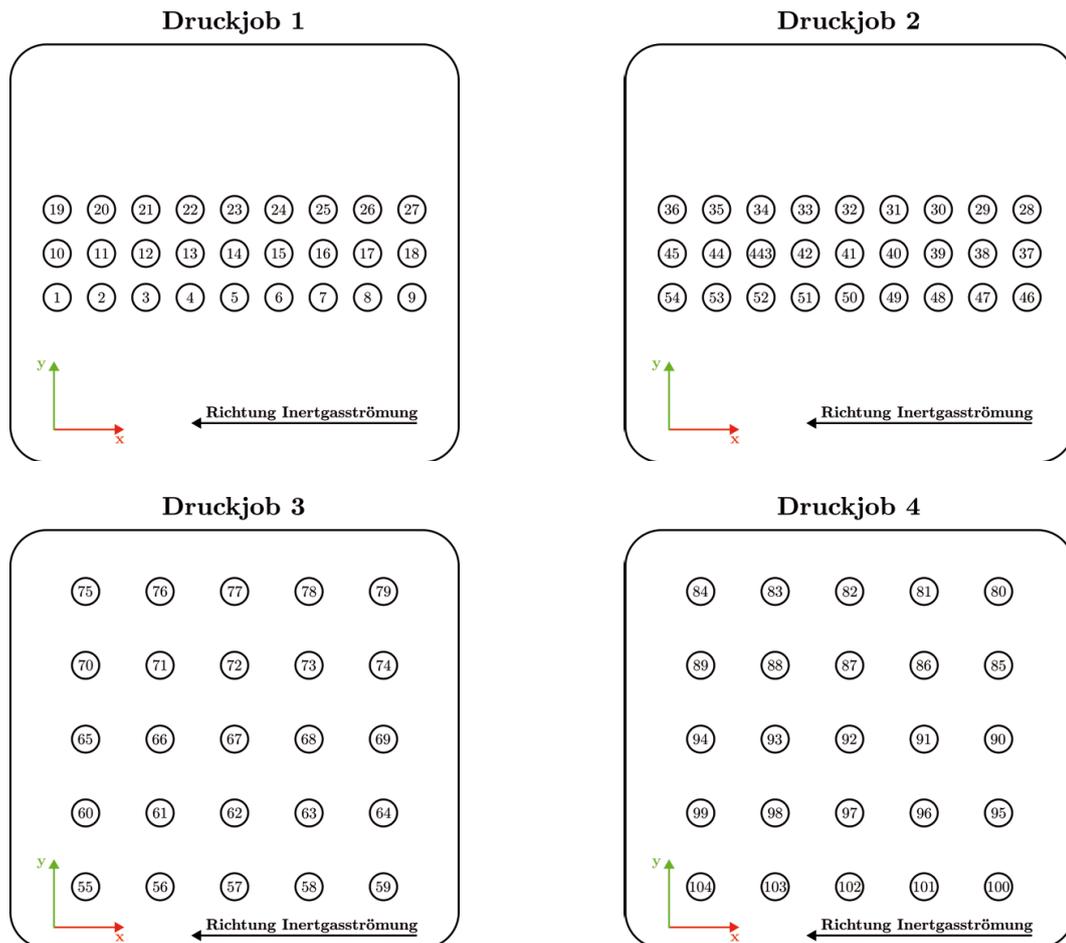


Abbildung 5-10: Anordnung der Probekörper und Belichtungsreihenfolge in den Druckjobs 1-4

Die während des Drucks erzeugte Datengrundlage besteht aus einer Messdatei pro Bauteil und Schicht. Um Speicherplatz zu sparen, werden die Messdaten der integrierten Sensorik nicht während des Drucks des unteren zylindrischen Teils aufgezeichnet, sondern erst kurz vor dem Erreichen des rechteckigen Bereichs.

5.4 Referenzmessung

Für die datengetriebene Modellbildung muss eine Referenzmessung vorliegen. Im Rahmen dieser Arbeit wird dazu die Röntgencomputertomographie genutzt. In Kapitel 5.4.1 wird zunächst eine Validierung der Referenzmessung durchgeführt. In Kapitel 5.4.1.9 erfolgt die Beschreibung der konkret durchgeführten Referenzmessung.

5.4.1 Validierung der Referenzmessung

Die industrielle Röntgencomputertomographie ist besonders vielversprechend für den Nachweis und die Charakterisierung von Porosität in additiv gefertigten Bauteilen. Diese zerstörungsfreie Messtechnik erlaubt es, ganze Bauteile zu digitalisieren und auf innere und äußere Fehler zu untersuchen. Obwohl die Möglichkeiten der Computertomographie vielfältig sind und diese bereits häufig in der Industrie zur Defektdetektion verwendet wird, ist sie noch eine vergleichsweise neue Messtechnik, bei welcher die Grenzen bei der Defektdetektion wissenschaftlich noch nicht ausreichend untersucht sind und die gewählten Parameter der Messkette einen Einfluss auf die Qualität der Defektdetektion haben. Aus diesem Grund wird im Rahmen dieser Arbeit eine Validierung des Vorgehens zur Auswahl der Parameter für die verwendete Messkette aus Computertomograph und Auswertesoftware zur Nutzung als Referenzmesstechnik durchgeführt.

Nach DIN EN ISO 9000 ist die Validierung als „*Bestätigung durch Bereitstellung eines objektiven Nachweises (3.8.3), dass die Anforderungen (3.6.4) für einen spezifischen beabsichtigten Gebrauch oder eine spezifische beabsichtigte Anwendung erfüllt worden sind*“ definiert. Der objektive Nachweis erfolgt dabei durch *Beobachtung, Messung (3.11.4), Test (3.11.8) oder andere Mittel*.

Ein Test ist dabei als „*Bestimmung (3.11.1) entsprechend den Anforderungen (3.6.4) an einen spezifischen beabsichtigten Gebrauch oder eine spezifische beabsichtigte Anwendung*“ definiert. Weist ein Testergebnis Konformität auf, so kann es als Validierung verwendet werden. Die Konformität ist als „*Erfüllung einer Anforderung (3.6.4)*“ definiert. Folglich wird deshalb die Definition einer Anforderung dargelegt: „*Erfordernis oder Erwartung, das oder die festgelegt, üblicherweise vorausgesetzt oder verpflichtend ist*“.

Die Anforderung im Rahmen dieser Arbeit an die Referenzmesstechnik ist, dass diese geeignet ist, Porosität aus dem PBF-LB/M Fertigungsverfahren zuverlässig zu detektieren.

Schliffbilder werden als hochaufgelöste Referenzmesstechnik für Computertomographieanwendungen verwendet (Leonard et al. 2016; Wits et al. 2016). Aus diesem Grund wird in der Folge ein auf Schliffbildern basierendes Vorgehen vorgestellt. Die Schritte des Vorgehens sind in Abbildung 5-11 dargestellt und werden in den folgenden Kapiteln vorgestellt.

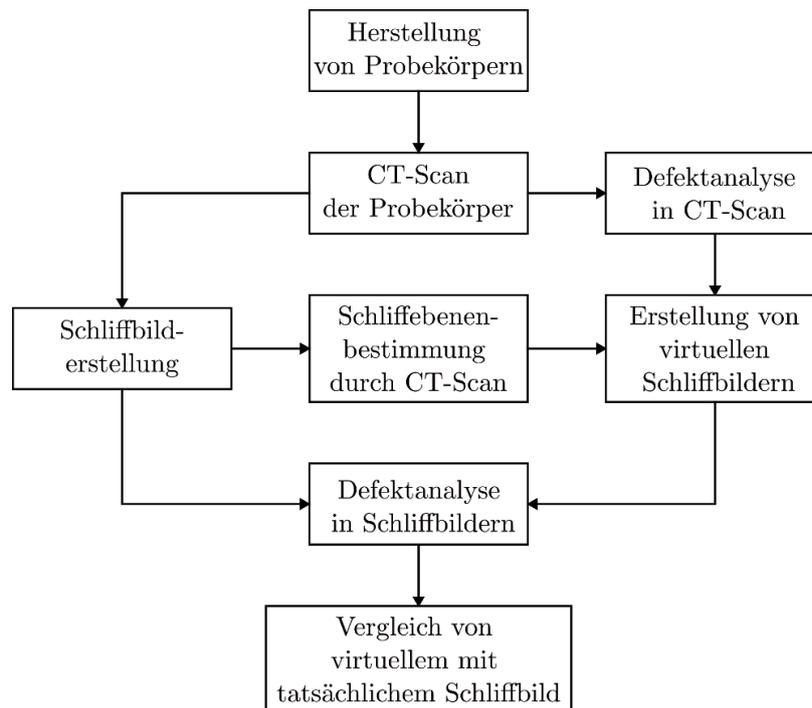


Abbildung 5-11: Vorgehen zur Validierung der Referenzmesstechnik

5.4.1.1 Herstellung von Probekörpern

Im Rahmen des vorgestellten Vorgehens werden Probekörper verwendet, welche von der in Kapitel 5.3.2 vorgestellten Geometrie geringfügig abweichen, um eine einfachere Herstellung der Schliffbilder zu ermöglichen. Die Abweichungen bestehen aus einer reduzierten z-Höhe der Probekörper, um die Menge des abzuschleifenden Materials bei der Schliffbilderstellung zu reduzieren. Die veränderte z-Höhe hat keinen Einfluss auf die Erstellung des CT-Scans, da der Körper im CT um die z-Achse gedreht wird. Weiterhin haben die Körper einen zylinderförmigen Hauptkörper statt eines eckigen wie in Kapitel 5.3.2. Damit wird die Grundform von Zugproben nach DIN 50125 Typ A verwendet. Der Durchmesser sowie die Kantenlänge beider Probekörper ist mit 5 mm identisch. Die Durchstrahlungslänge wird somit nur geringfügig verändert, sodass das grundsätzliche Verhalten im CT vergleichbar ist. Als Material wird analog zur Probekörpergeometrie aus Kapitel 5.3.2 Edelstahl 316L verwendet (aus der gleichen Pulvercharge wie in Kapitel 5.3.3 vorgestellt). Der Marker zur Registrierung ist gleich wie bei der in Kapitel 5.3.2 Probekörpergeometrie ausgestaltet. Eine technische Zeichnung der zur Validierung verwendeten Probekörpergeometrie ist in Abbildung 5-12 (a) zu finden.

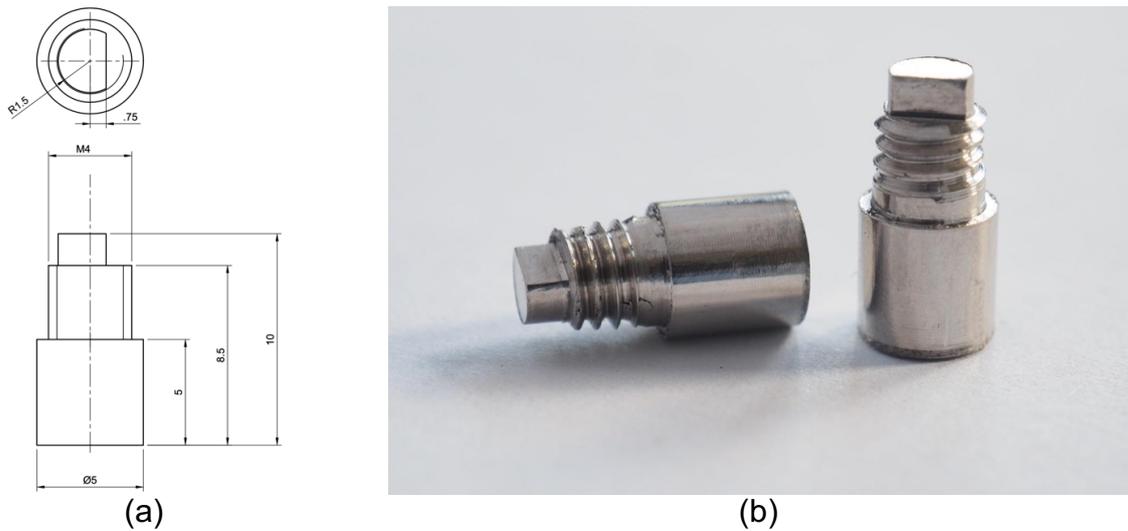


Abbildung 5-12: (a) Technische Zeichnung der Schliffbild-Probekörper sowie (b) Bild von zwei gefertigten Probekörpern – Bildquelle: Leonard Schild (wbk)

Die Probekörper verfügen unter dem Marker zur Registrierung über ein Gewinde, so dass eine Hutmutter auf die Oberseite des Probekörpers geschraubt werden kann, um die Merkmale für die Registrierung zu schützen. Die Hutmutter ermöglicht es, die Probekörper aus dem in der Schliffbildherstellung verwendeten Harz zu befreien, ohne dass die Gefahr besteht, dass die Registrierungsmerkmale beschädigt werden. Der untere zylindrische Teil des Probekörpers wird verwendet, um das Schliffbild zu erstellen. Für den Druckprozess auf der PBF-LB/M Anlage wurden die Abmessungen der Teile mit einem Aufmaß versehen. Die finale Probekörpergeometrie wurde nach dem Druck spanend hergestellt. Die fertigen Probekörper sind in Abbildung 5-12 (b) dargestellt. Insgesamt werden fünf Probekörper hergestellt.

5.4.1.2 CT-Scan der Probekörper

Nach der Herstellung der Probekörper werden diese mit einem *Metrotom 800 130kV* CT-Gerät der *Zeiss IMT GmbH* gescannt. Der CT-Scan erfolgt in einem einzigen 360-Grad-Scan ohne Stitching²⁷. Die Rekonstruktion wurde auf dem CT-Gerät mit der Software *Metrotom OS 3.2* der *Zeiss IMT GmbH* berechnet. Für den CT-Scan werden zwei verschiedene Einstellungen für die Röntgenquelle und den Detektor des CT-Geräts betrachtet. Diese sind in Tabelle 5-5 dargestellt. Die Wahl der Einstellungen basiert auf den Arbeiten von Schild (2022) und Schild et al. (2023). Es werden zwei verschiedene

²⁷ Stitching bezeichnet das Zusammenfügen von Einzelaufnahmen zu einer Gesamtaufnahme. Dafür muss eine ausreichende Überlappung der Einzelaufnahmen vorhanden sein.

Einstellungen betrachtet. Bei beiden Einstellungen wird ein Kupferfilter mit einer Dicke von 0,5 mm verwendet, da dieser bei vergleichbaren Messungen mit dem verwendeten CT-Gerät gute Ergebnisse erzielt hat.

1. Der erste Satz von Einstellungen (nachfolgend *Kontrast-optimiert* genannt) wird in der Art gewählt, dass das Signal-Rausch-Verhältnis (engl. *signal to noise ratio* - SNR) der Rekonstruktionen erhöht wird. Dies wird durch die Verwendung der maximal zulässigen Werte für Röhrenspannung und -strom (130 kV, 300 μ A) erreicht, die der maximalen Ausgangsleistung der Röntgenröhre (39 kW) entsprechen. Auf diese Weise wurden helle Projektionen und damit ein höheres SNR gewährleistet, was zu einem besseren Kontrast innerhalb der Scans führt. Die resultierende Brennfleckgröße beträgt 40 μ m. Die Detektorverstärkung wird auf 2,5-fach eingestellt, um das Bildrauschen des Detektors zu verringern.
2. Der zweite Satz von Einstellungen (nachfolgend *Schärfe-optimiert* genannt) verbessert die Schärfe der Rekonstruktionen, d. h. es wird ein hoher Wert der Modulationstransferfunktion (MTF) zu erreichen. In dieser Arbeit wird davon ausgegangen, dass die Bildschärfe einen großen Einfluss auf die Leistung von Algorithmen zur Porenerkennung hat. Bei dem verwendeten CT-System führen Einstellungen, die einen geringen Stromverbrauch verursachen, zu einer Verringerung der Brennfleckgröße. Eine kleine Brennfleckgröße wiederum wird als Voraussetzung für eine scharfe Rekonstruktion angesehen. Die Einstellungen werden so gewählt, dass die Leistung der Röntgenröhre minimiert wird, der Probekörper aber trotzdem vollständig durchstrahlt werden kann. Dies führt zur Wahl der maximal zulässigen Spannung von 130 kV und des geringstmöglichen Stroms von 96 μ A. Die resultierende Brennfleckgröße beträgt 20 μ m.

Tabelle 5-5: Gewählte Einstellungen für die Erstellung der CT-Scans zur Schliffbildanalyse

Einstellung	Kontrast-optimiert	Schärfe-optimiert
Filtermaterial	Kupfer	Kupfer
Filterdicke	0,50 mm	0,50 mm
Röhrenstrom	300 μ A	96 μ A
Röhrenspannung	130 kV	130 kV
Resultierende Röhrenleistung	39 W	12,48 W
Rekonstruktionsalgorithmus	Feldkamp	Feldkamp
Detektorverstärkung	2.5x	8.0x
Integrationszeit	1000 ms	1000 ms
Brennfleckgröße	40 μ m	20 μ m
Resultierende Voxelgröße	7 μ m	7 μ m

5.4.1.3 Defektanalyse in CT-Scan

Zur Defektanalyse wird der *VGEasyPore*-Algorithmus aus der Software *VGStudio Max 3.4.5* von *Volume Graphics* verwendet. Dieser basiert auf einer Schwellwertanalyse der Grauwerte des Volumens. Die genaue Funktionsweise des Algorithmus ist von *Volume Graphics* nicht offengelegt. Bevor die Porenerkennung durchgeführt wird, müssen die Oberflächen der Probekörper bestimmt werden. Für die Oberflächenbestimmung wird die erweiterte Oberflächenbestimmung von *VGStudio Max* verwendet.

Die meisten *VGEasyPore*-Einstellungen auf werden auf ihren Standardwerten belassen. Die Einstellung "Kontrast" muss gegenüber des automatischen Vorhersagewerts der Software angepasst werden, um zufriedenstellende Ergebnisse zu erzielen. Außerdem unterscheiden sich die Kontrastparameter für CT-Rekonstruktionen, die mit unterschiedlichen CT-Einstellungen durchgeführt werden. Für die Einstellungen *Kontrast-optimiert* wird der Parameter auf den Wert 5000 gesetzt, für *Schärfe-optimiert* auf 7500. Um sicherzustellen, dass der Algorithmus optimal parametrisiert ist, werden die gewählten Parameter mit einem Anwendungsingenieur von *Volume Graphics* überprüft.

Tabelle 5-6: Parameter des VGEasyPore-Algorithmus zur Porositätsanalyse

Parameter ²⁸	Kontrast-optimiert	Schärfe-optimiert
Modus	Subvoxel	Subvoxel
Algorithmus	Absolut	Absolut
Kontrast	5000	7500
Größe lokaler Bereich	10 Voxel	10 Voxel
Analysebereich	Interne Bereinigung, klein	Interne Bereinigung, klein
Abstand zur Oberfläche	1 Voxel	1 Voxel

Anschließend werden die Ergebnisse der Porenerkennung exportiert. Da es keine vorgefertigte Funktion gibt, um eine binarisierte Rekonstruktion direkt aus *VGStudio Max* zu exportieren, wird von *Volume Graphics* das nachfolgende Verfahren vorgeschlagen. Zunächst wird eine *Region-of-Interest* (ROI) definiert, welche alle Voxel der detektierten Poren umfasst. Diese Voxel innerhalb der ROI werden in ein separates Volumen exportiert, das dann als Rekonstruktionsdatei exportiert wird. Alle Voxel in dieser Rekonstruktion, die noch einen Grauwert größer als 0 aufweisen, stellen Poren dar. Da nur die Grauwerte dieser Voxel größer als 0 sind, können diese Voxel mit Hilfe von Software wie *Python* oder *MATLAB* leicht identifiziert werden.

5.4.1.4 Schliffbilderstellung

Zum Schutz des Markers zur Registrierung wird eine Hutmutter auf das Gewinde geschraubt. Anschließend werden die Probekörper in Harz eingebettet und 2,5 mm des zylindrischen Teils der Probekörper abgeschliffen. Die Schliffebene wird anschließend poliert. Zur Erstellung der Schliffbilder wird ein Konfokalmikroskop (*Plu S Neox* von *Sensofar*) verwendet. Die Bilder des Mikroskops werden zu einem einzigen Schliffbild zusammengefügt.

5.4.1.5 Schliffebenenbestimmung durch CT-Scan

Nach der Erstellung der Schliffbilder werden die abgeschliffenen Probekörper erneut mit demselben CT-Gerät gescannt. Diese Scans dienen zur Bestimmung der Schliffebene in Bezug auf das lokale Bauteilkoordinatensystem. Das Harz und die Hutmutter werden vor dem Scan entfernt. Durch das Scannen der abgeschliffenen Probekörper

²⁸ Alle weiteren Parameter werden, sofern nicht angegeben, auf den Standardwerten belassen.

ohne Harz und Mutter können für den CT-Scan die gleichen Einstellungen wie in Tabelle 5-5 verwendet werden. Nach dem Scannen können mit *VGStudio Max* die Ebenenparameter der Schliffebene bestimmt und abgespeichert werden.

5.4.1.6 Erstellung von virtuellen Schliffbildern

In diesem Schritt werden aus den CT-Daten aus Schritt 2 und Schritt 3 virtuelle Schliffbilder extrahiert. Diese virtuellen Schliffbilder können direkt mit den tatsächlichen Schliffbildern verglichen werden. Ein virtuelles Schliffbild stellt die spezifische Ebene der CT-Rekonstruktion dar, die der Schliffebene aus Schritt 4 entspricht.

Zunächst werden die Parameter der Schliffebene aus Schritt 4 im lokalen Koordinatensystem des Probekörpers importiert. Mit diesen Parametern wird eine neue Ebene in der Rekonstruktion des CT-Scans aus Schritt 2 und Schritt 3 definiert. Die Daten der resultierenden Ebene können aus *VGStudio Max* exportiert und mit *MATLAB* verarbeitet werden.

5.4.1.7 Defektanalyse in Schliffbildern

Alle Poren, die in Schliffbildern, d. h. in den tatsächlichen Schliffbildern aus Kapitel 5.4.1.4 und den virtuellen Schliffbildern aus Kapitel 5.4.1.6 vorhanden sind, werden identifiziert und gekennzeichnet. Bei den Schliffbildern handelt es sich um binarisierte 2D-Bilder, bei denen der Wert *True* für einen Bereich steht, der zu einer Pore gehört. Jeder zusammenhängende Bereich von Pixeln in den Schliffbildern mit dem Wert *True*, d. h. jede Pore, wird identifiziert und erhält eine eindeutige Nummer. *MATLAB* wird für die Identifizierung und Kennzeichnung von Poren mit der Funktion *regionprops* verwendet. Neben der Vergabe einer eindeutigen Identifikationsnummer wird für jede Pore die Fläche A_{pore} , ihr Umfang P_{pore} und die Zirkularität C_{pore} bestimmt und gespeichert. Der Umfang P_{pore} ist die Länge der Randpixel einer Pore. Die Zirkularität C_{pore} ist ein Verhältnis zwischen der Fläche A_{pore} und dem Umfang P_{pore} , wie in Formel 5-1 dargestellt. C_{pore} ist im Intervall (0,1] definiert, wobei der Wert 1 einen perfekten Kreis darstellt.

$$C_{pore} = \frac{4\pi A_{pore}}{P_{pore}^2} \quad \text{Formel 5-1}$$

Der vom Mikroskop gelieferte Maßstab mm/px wurde zur Umrechnung von Pixelgrößen in tatsächliche Längen verwendet, um Größenmessungen in mm aus Pixellängen zu ermöglichen. Die Voxelgröße der Rekonstruktionen wird in ähnlicher Weise verwen-

det, um die aus den virtuellen Schliffbildern gewonnenen Pixellängen in mm umzurechnen. Nach der Kennzeichnung aller Poren und der Berechnung ihrer Eigenschaften werden die Ergebnisse abgespeichert.

5.4.1.8 Vergleich von virtuellem und tatsächlichem Schliffbild

Im letzten Schritt werden die Flächen, die Umfänge und die Zirkularitäten der Poren in den virtuellen Schliffbildern mit den entsprechenden Werten der Poren in den tatsächlichen Schliffbildern verglichen. Vor der Analyse werden noch Poren aus dem virtuellen Schliff, welche einer einzelnen großen Pore im tatsächlichen Schliffbild entsprechen, zusammengefasst.

Stimmen die Daten in einem zu definierenden Intervall überein, ist die Anforderung aus Kapitel 5.4.1 erfüllt und das Vorgehen zur Parameterwahl entlang der gesamten Messkette valide.

5.4.1.9 Ergebnisse

Zunächst wird die Porenanalyse der realen Schliffbilder vorgestellt, um den Ist-Zustand der Poren zu beschreiben. Anschließend wird die Porenanalyse der virtuellen Schliffbilder mit den realen Schliffbildern verglichen und die Unterschiede aufgezeigt. In Abbildung 5-13 ist das reale Schliffbild dem virtuellen Schliffbild exemplarisch gegenübergestellt. Dabei ist qualitativ erkennbar, dass Poren teilweise nicht im virtuellen Schliffbild erkannt werden oder sich die Größe und Form der Poren unterscheidet. In Abbildung 5-14 ist eine exemplarische Pore im realen Schliffbild sowie im virtuellen Schliff dargestellt. Hier ist qualitativ erkennbar, dass vor allem sehr kleine Poren sowie feine Details der Pore nicht korrekt durch den CT-Scan erfasst werden.

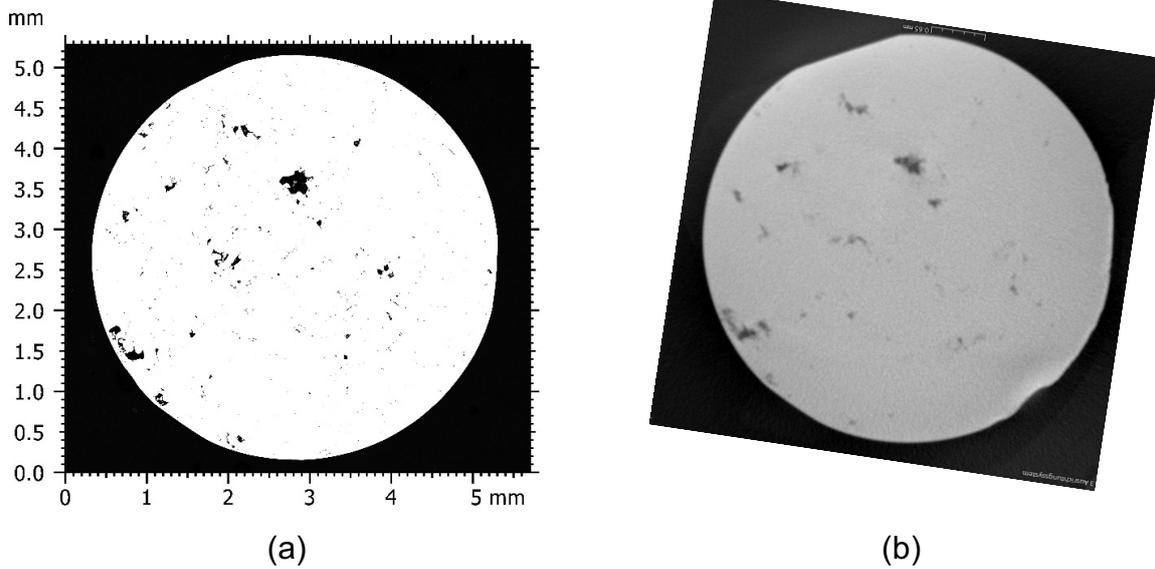


Abbildung 5-13: Gegenüberstellung des (a) realen Schliiffbilds und des (b) virtuellen Schliiffbilds aus dem Computertomographen

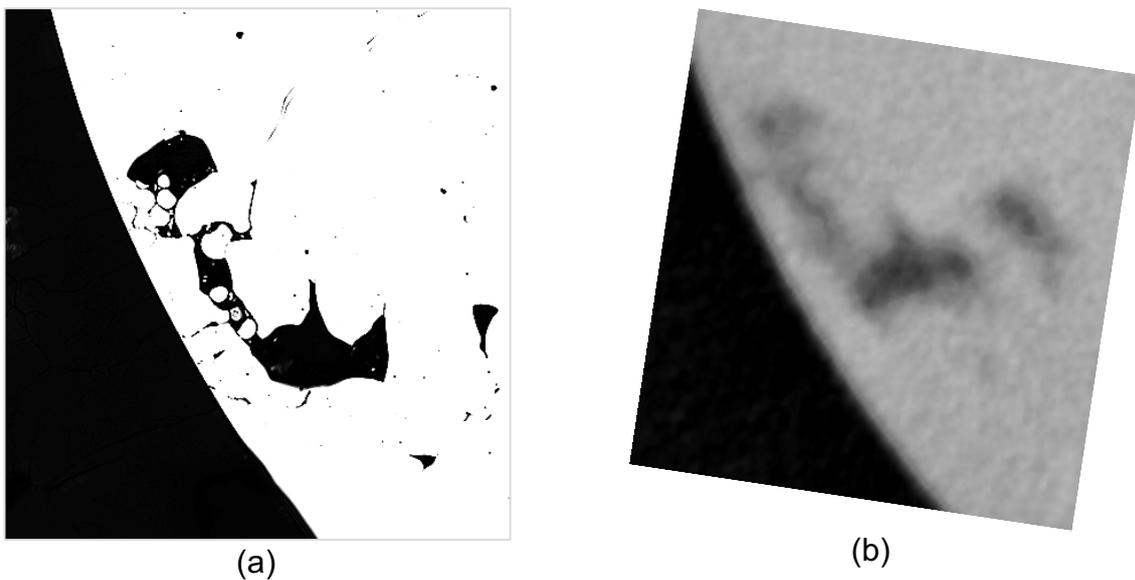


Abbildung 5-14: Exemplarische Pore im (a) realen Schliiffbild und im (b) virtuellen Schliiff gegenübergestellt.

Nach der kurzen qualitativen Betrachtung der virtuellen und realen Schliiffbilder erfolgt die quantitative Betrachtung der Defekterkennung. In den realen Schliiffbildern der fünf Probekörper werden insgesamt 189 individuelle Poren detektiert. In Abbildung 5-15 (a) ist die Verteilung der Porenfläche im realen Schliiffbild als Boxplot dargestellt. Bei der

Betrachtung zeigt sich, dass der überwiegende Anteil der Poren eine Fläche zwischen 0,01 und 0,001 mm² aufweist. Es finden sich aber weiterhin auch Ausreißer in Form von Poren mit großer Porenfläche.

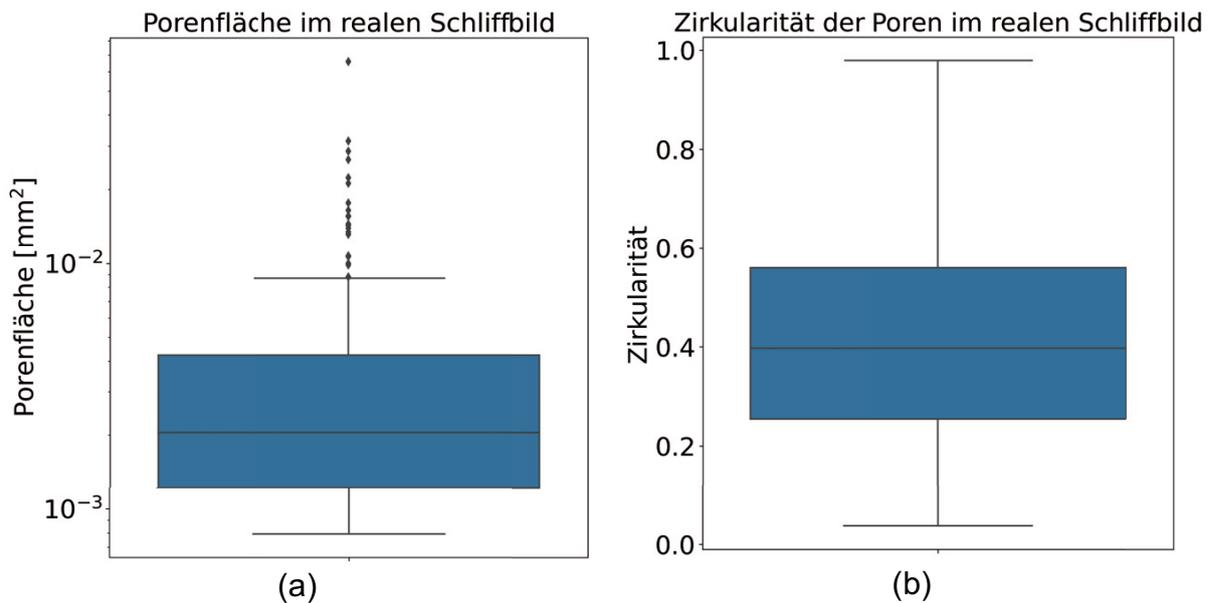


Abbildung 5-15: Boxplot der (a) Porenfläche und (b) Zirkularität in realem Schliffbild

In Abbildung 5-15 (b) ist die Verteilung der Zirkularität der Poren als Boxplot dargestellt. Die überwiegende Anzahl der Poren weist eine Zirkularität zwischen 0,2 und 0,6 auf. Jedoch treten Poren mit einer Zirkularität über fast das gesamte Intervall zwischen 0 und 1 auf.

Zunächst soll betrachtet werden, wie viele Poren aus dem realen Schliffbild von der Auswertung im virtuellen Schliff nicht erkannt wurden. Dazu sind in Abbildung 5-16 die prozentualen Anteile der nicht erkannten Poren im virtuellen Schliffbild für die beiden CT-Einstellungen dargestellt. Beim kontrast-optimierten Parametersatz werden rund 49 % der Poren nicht erkannt, beim schärfe-optimierten Parametersatz liegt dieser Wert bei 27 %. Dieser Parametersatz führt zu einer signifikant besseren Erkennungsrate von Poren.

Anteile der nicht erkannten Poren im virtuellen Schliffbild

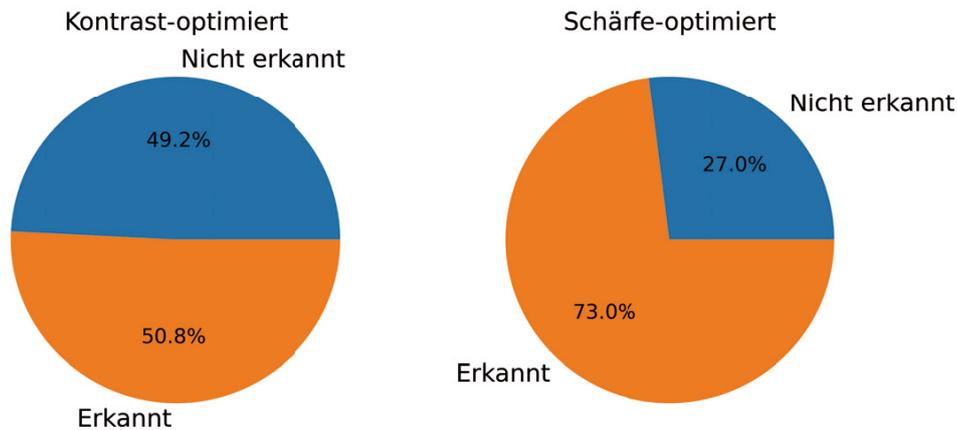


Abbildung 5-16: Anteile der im virtuellen Schliffbild nicht erkannten Poren

Nachfolgend wird die Erkennungsrate in Abhängigkeit der Voxelgröße betrachtet. Dazu werden im realen Schliffbild diejenigen Poren herausgefiltert, welche eine kleinere Fläche als die quadrierte Kantenlänge eines Voxels (Voxelgröße^2) haben. In Abbildung 5-17 ist der Verlauf der Porenerkennungsrate für die beiden CT-Einstellungen in Abhängigkeit der Voxelgröße dargestellt. Ab 6x6 Voxel hat der schärfe-optimierte Parametersatz eine Erkennungsrate von >90 %, während der kontrast-optimierte Parametersatz nur eine Erkennungsrate von 64 % aufweist. Eine Erkennungsrate von 100 % erreicht der schärfe-optimierte Parametersatz erst bei 10x10 Voxel. Der im Expertengespräch geäußerte Fakt, dass 2 bis 3 Voxel ausreichen, um eine Pore zu erkennen, kann auf Basis der vorliegenden Daten nicht bestätigt werden.

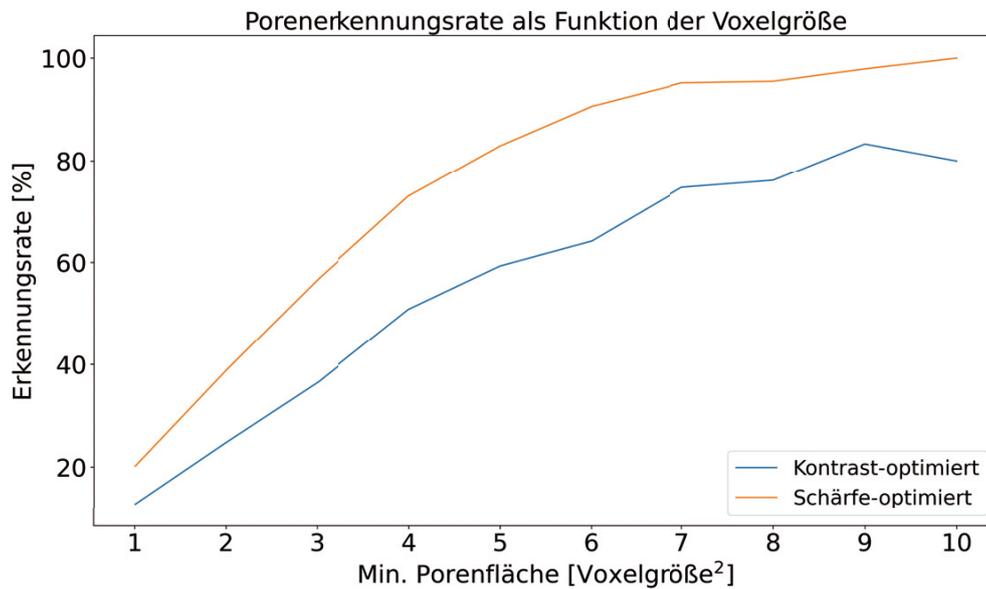


Abbildung 5-17: Porenerkennungsrate als Funktion der Voxelgröße

In der Folge werden die Parameter Porenfläche und Zirkularität detailliert untersucht. Zunächst wird untersucht, wie sich die Porenfläche, der nicht im virtuellen Schliff erkannten Poren, verhält. In Abbildung 5-18 ist die Fläche der nicht erkannten Poren als Boxplot in Abhängigkeit der verwendeten CT-Einstellungen dargestellt. Es ist zu erkennen, dass die nicht erkannten Poren beim schärfe-optimierten Parametersatz kleiner als beim kontrast-optimierten Parametersatz sind. Auch die Ausreißer haben beim schärfe-optimierten Parametersatz eine kleinere Fläche.

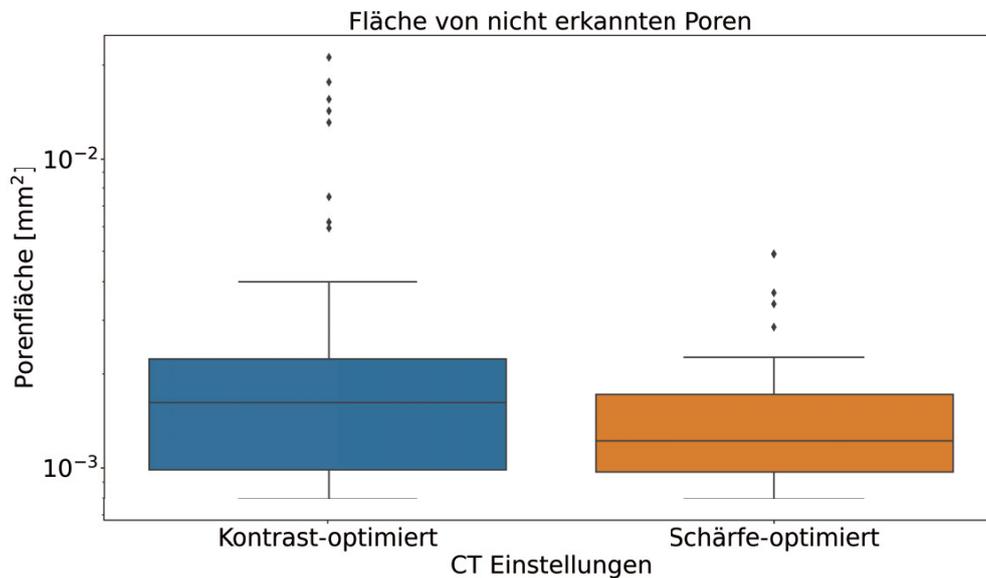


Abbildung 5-18: Porenfläche der nicht im virtuellen Schliffbild erkannten Poren

In Abbildung 5-19 ist der Unterschied der Porenfläche von im virtuellen Schliffbild erkannten Poren zu den korrespondierenden Poren im realen Schliffbild dargestellt. Der schärfe-optimierte Parametersatz hat eine geringere mittlere Abweichung sowie eine geringere Streuung der Abweichung. Die mittlere Abweichung ist leicht positiv, was darauf hinweist, dass Poren tendenziell größer erkannt werden, als sie tatsächlich sind. Dennoch sind sowohl positive als auch negative Abweichungen erkennbar.

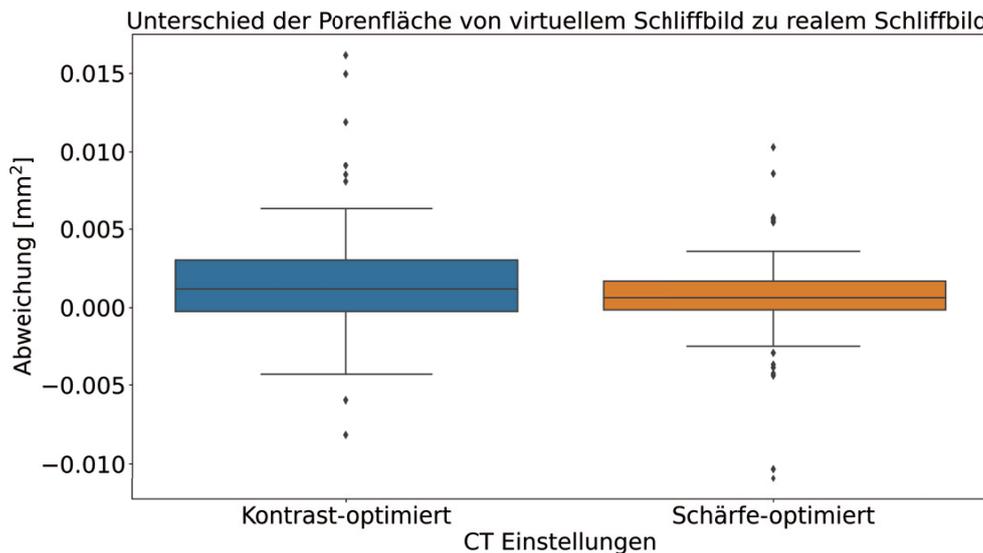


Abbildung 5-19: Abweichung der Porenfläche von im virtuellen Schliffbild erkannten Poren zum realem Schliffbild

Die Betrachtung des Parameters Zirkularität erfolgt analog zur Betrachtung der Porenfläche. Als erstes wird die Zirkularität von nicht erkannten Poren untersucht. Dazu ist in

Abbildung 5-20 die Zirkularität dieser Poren in Abhängigkeit der CT-Einstellungen als Boxplot dargestellt. Es ist erkennbar, dass bei beiden CT-Einstellungen Poren aus dem gesamten Zirkularitätsintervall zwischen 0 und 1 nicht erkannt werden.

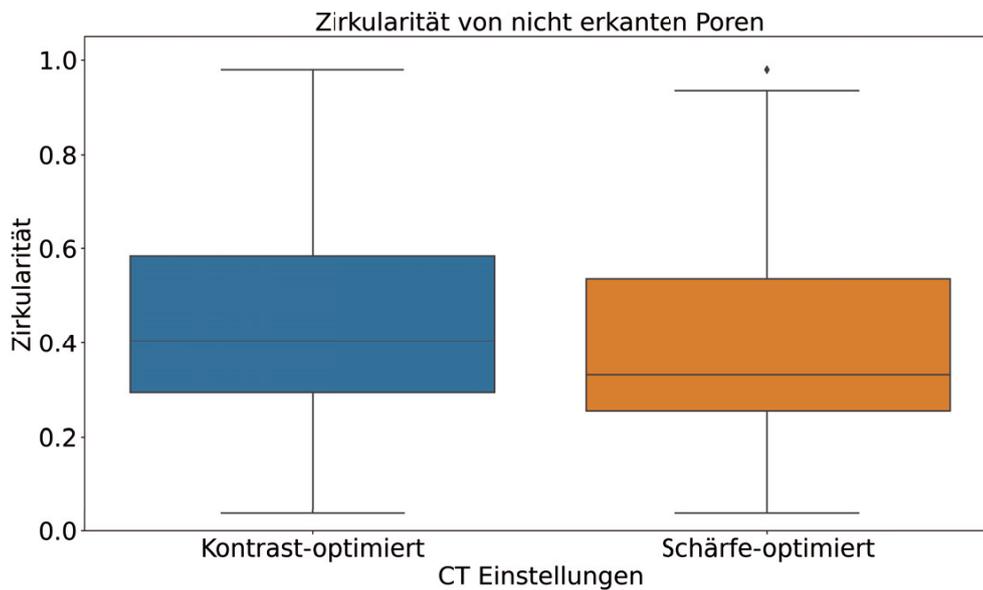


Abbildung 5-20: Zirkularität der nicht im virtuellen Schliffbild erkannten Poren

Nach Betrachtung der Zirkularität der nicht erkannten Poren wird die Abweichung der Zirkularität von im virtuellen Schliffbild erkannten Poren zu den zugehörigen Poren im realen Schliffbild betrachtet. In Abbildung 5-21 ist die Abweichung der Zirkularität als Boxplot dargestellt. Die Abweichung der ist überwiegend im Intervall $[-0,2; 0,2]$ zu finden. Die mittlere Abweichung liegt beim schärfe-optimieren Parametersatz etwas näher an Null als beim kontrast-optimierten Parametersatz.

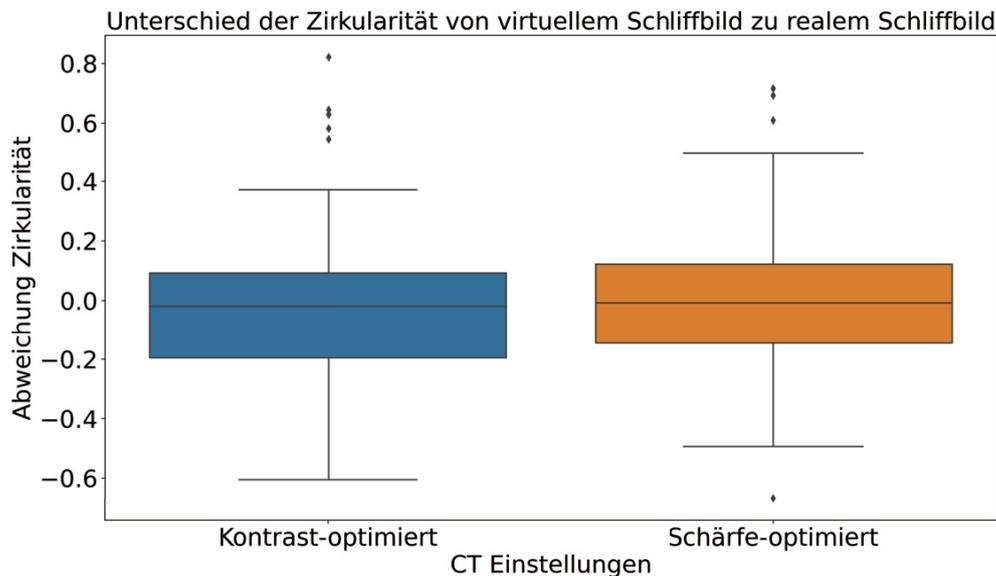


Abbildung 5-21: Abweichung der Zirkularität von im virtuellen Schliffbild erkannten Poren zum realem Schliffbild

Abschließend werden die wichtigsten Erkenntnisse und das Fazit der Betrachtung dargelegt. Der kontrast-optimierte Parametersatz erkennt weniger Poren als der schärfe-optimierte Parametersatz. Deshalb sollte bei der Wahl der Parameter die Schärfe optimiert werden. Dies wird durch das Nutzen einer möglichst geringen Röhrenleistung erreicht, da diese in einem kleineren Brennfleck resultiert. Dadurch gewinnen die CT-Scans an Schärfe.

Viele kleine Poren werden bei beiden Parametersätzen nicht erkannt. Dies liegt an der Voxelgröße des Scans. Beide Parametersätze haben eine Voxelgröße von $7\ \mu\text{m}$. Wie im Abschnitt zur voxelgrößenabhängigen Porenerkennungsrate dargestellt, ist die Erkennungsrate bei zwei bis drei Voxeln nicht zufriedenstellend. Die kleineren Gasporen haben eine Größe von typischerweise $20\ \mu\text{m}$ bis $50\ \mu\text{m}$. Dies stellt unter der Annahme einer kreisrunden Pore einen Flächenbereich von $314\ \mu\text{m}^2$ bis $1.963\ \mu\text{m}^2$ dar, unter Annahme einer perfekt rechteckigen Pore verändert sich der Bereich zu $400\ \mu\text{m}^2$ bis $2.500\ \mu\text{m}^2$. Der schärfe-optimierte Parametersatz erreicht bei 6×6 Voxeln eine Erkennungsrate von $>90\%$, was einer Mindestfläche bei $7\ \mu\text{m}$ Voxelgröße von $1.764\ \mu\text{m}^2$ entspricht. Aus diesem Grund kann, wie bereits erwähnt, die Aussage von zwei bis drei Voxeln Mindestgröße aus dem Expertengespräch nicht bestätigt werden. Auf Basis der Daten zeigt sich, dass kleinere Gasporen problematischer in der Detektion sind als Fusionsporen, die typischerweise größer als $50\ \mu\text{m}$ sind. Fusionsporen werden aufgrund ihrer Größe zuverlässiger als Gasporen erkannt. Für die Bewertung der mechanischen

Kennwerte sind die großen Fusionsporen aufgrund ihrer Größe und ihrer geringen Zirkularität aufgrund der hohen Zerklüftung von höherer Relevanz als Gasporen. Dennoch gibt es einige große Poren, die nicht im virtuellen Schliff erkannt werden. Mögliche Theorien zur Ursache lauten: (I) der Algorithmus zur Defekterkennung erkennt diese Pore nicht; (II) die Pore war aufgrund ihrer Größe mit unaufgeschmolzenem Pulver gefüllt, sodass diese im CT nicht erkennbar war und bei Schlifferstellung die Pore vom Pulver befreit wurde.

Im Zuge der Parametrierung des Auswertalgorithmus *VGEasyPore* hat sich gezeigt, dass die Wahl der Parameter einen wesentlichen Einfluss auf die Defektanalyse hat. Aus diesem Grund ist zu empfehlen, die Parameterwahl mit einem Experten durchzuführen. Erfolgt dies, ist bei konstanten Parametersätzen eine robuste und für den Anwendungsfall ausreichend genaue Auswertepipeline möglich.

Da nach DIN EN ISO 9000 die Anforderung für den Anwendungsfall erfüllt ist, weist der Test Konformität auf und erbringt so einen objektiven Nachweis. Das Vorgehen zur Parameterauswahl der Referenzmessung und die Auswertekette ist somit valide.

5.4.2 Durchführung der Referenzmessung

Aufgrund der Validität des Vorgehens zur Auswahl der Parameterauswahl entlang der Auswertekette wird das Vorgehen aus Kapitel 5.4.1 auf die Durchführung der Referenzmessung übertragen. Der Übertrag ist notwendig, da die Untersuchungen in Kapitel 5.4.1 mit dem institutseigenen CT-Gerät vom Typ *Zeiss Metrotom 800 130kV* durchgeführt wurden. Aufgrund des Umfangs der durchzuführenden Referenzmessungen und der Verfügbarkeit des institutseigenen CT-Geräts wurden die Referenzmessungen extern von der Firma *Zeiss* im Rahmen eines Projektes durchgeführt.

Die Referenzmessung der in Kapitel 5.3 hergestellten Probekörper wird mit einem *Zeiss Metrotom 800 225 kV HR²⁹* durchgeführt. Die Einstellungen des CT-Geräts werden so gewählt, dass diese bei möglichst kleinem Brennfleck eine maximale Schärfe ermöglichen. In Tabelle 5-7 sind die konkreten Einstellungswerte des CT-Geräts dargestellt. Der Scan wird als voller 360°-Scan ausgeführt.

²⁹ Das CT-Gerät zur Validierung der Referenzmessung aus Kapitel 5.4.1 war ebenfalls ein *Metrotom 800*, jedoch nur mit 130kV.

Tabelle 5-7: CT-Einstellungen der Referenzmessung mit Zeiss Metrotom 800 225kv HR

Einstellung	Wert
Filtermaterial	Kupfer
Filterdicke	1,0 mm
Röhrenstrom	97 μ A
Röhrenspannung	180 kV
Resultierende Röhrenleistung	17,46 W
Rekonstruktionsalgorithmus	Feldkamp
Detektorverstärkung	8,0x
Integrationszeit	1000 ms
Brennfleckgröße	dynamische Anpassung ³⁰
Resultierende Voxelgröße	15,7 μ m

Aufgrund der Höhe der Bauteile werden zwei Scans für jedes Bauteil durchgeführt, welche dann während der Rekonstruktion des Volumens durch *Stitching* zusammengefügt werden. So kann trotz der Höhe des Bauteils die notwendige Auflösung für eine Porositätsanalyse erreicht werden. Nach der Rekonstruktion auf dem CT-Gerät werden die Scans exportiert und mit der Software *VGStudio Max 3.4.5* des Herstellers *Volume Graphics* mittels des Algorithmus *VGEasyPore* auf Porosität untersucht. Nachfolgend werden die einzelnen Schritte der Defektanalyse vorgestellt.

5.4.2.1 Bestimmen der Oberfläche des Probekörpers im CT-Scan

Das Rohvolumen liegt als 16 bit unsigned Integer vor. Dieses wird in *VGStudio Max* geladen. Die Oberfläche des Probekörpers wird auf Basis des Histogramms der Grauwertverteilung durchgeführt. Dabei werden innenliegende Hohlkörper ausgeschlossen, sodass diese durch die Defektanalyse erkannt werden können.

5.4.2.2 Registrieren des Probekörpers im CT-Scan

Auf Basis der in Kapitel 5.3.2 vorgestellten Marker zur Registrierung kann in diesem Schritt das Bauteilkoordinatensystem $KOS_{Bauteil}$ definiert werden. Dazu werden die folgenden Geometrielemente bestimmt:

1. Für den zylinderförmigen Teil wird die Mittelachse des Zylinders bestimmt. Die Mittelachse definiert die Z-Achse des Koordinatensystems.

³⁰ Im Gegensatz zum *Zeiss Metrotom 800 130kV*, welches eine gestufte Brennfleckgröße hat, nutzt die *225kV Version* eine lineare, dynamisch an die Leistung angepasste, Brennfleckgrößeneinstellung.

2. Auf die Stirnseite des Zylinders wird eine Ebene gelegt.
3. Der Durchstoßpunkt der Mittelachse mit der in 2. definierten Ebene bildet den Ursprung des Bauteilkoordinatensystems.
4. In die Markerkerbe wird eine Ebene definiert.
5. Der Normalenvektor der in 4. definierten Ebene bildet die X-Achse des Koordinatensystems.
6. Aus dem Kreuzprodukt von X-Achse und Z-Achse kann die Y-Achse errechnet werden. Mit dem in 2. definierten Ursprung ist das Bauteilkoordinatensystem wohldefiniert.

In Abbildung 5-22 sind die Geometrieelemente und das daraus resultierende Koordinatensystem dargestellt. Durch die Registrierung kann sichergestellt werden, dass alle Probekörper das gleiche Koordinatensystem verwenden und eine Koordinatentransformation vom PBF-LB/M-Koordinatensystem in ein einheitliches Bauteilkoordinatensystem möglich ist.

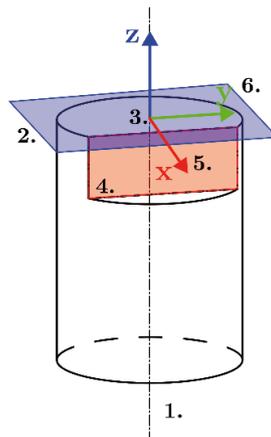


Abbildung 5-22: Definiertes Bauteilkoordinatensystem $KOS_{Bauteil}$ des Probekörpers nach Registrierung im CT

5.4.2.3 Definieren der Region-of-Interest im registrierten Probekörper

In dem registrierten Probekörper wird eine *Region-of-Interest* (ROI) festgelegt, in welcher die Porositätsanalyse durchgeführt werden soll. Da die Geometrie als Ausgangspunkt für die Fertigung von Zugproben dient, ist vor allem der Bereich mit geringerem Querschnitt in der Zugprobe von besonderem Interesse, da hier das Versagen zu erwarten ist. Aus diesem Grund umfasst die definierte ROI den rechteckigen Querschnittsbereich der Zugprobe, da in diesem Bereich das mechanische Versagen der Zugprobe bei der Durchführung des Zugversuches zu erwarten ist.

5.4.2.4 Definieren des regelmäßigen Integrationsnetzes in der ROI

Die Erkennung einzelner Poren und die genaue Quantifizierung der Eigenschaften dieser werden im Rahmen dieser Arbeit als zu anspruchsvoll eingestuft. Aus diesem Grund wird in der ROI ein *regelmäßiges Integrationsnetz*³¹, d. h. in ein regelmäßiges Gitter mit definierter Kantenlänge, festgelegt. In der Folge wird jedes durch das von 8 Gitterpunkten definierte Volumen als sogenannte *Einheitszelle* bezeichnet. Die Kantenlänge der Einheitszellen wird auf eine Länge von 1 mm festgelegt, da so eine ausreichende Anzahl an Einheitszellen als Referenzmessung für die datengetriebene Modellbildung zur Verfügung stehen, die Segmentierung der Daten aber noch mit überschaubarem Aufwand möglich ist. In der XY-Ebene wird der Querschnitt (5x5 mm) deshalb in 5x5 Einheitszellen zerlegt. Entlang der Z-Achse wird das Volumen in 27 Einheitszellen aufgrund der geometrischen Abmessungen zerlegt. In Summe wird die ROI in $5 \times 5 \times 27 = 675$ Einheitszellen zerlegt. Die ROI mit definierten Einheitszellen ist in Abbildung 5-23 dargestellt.

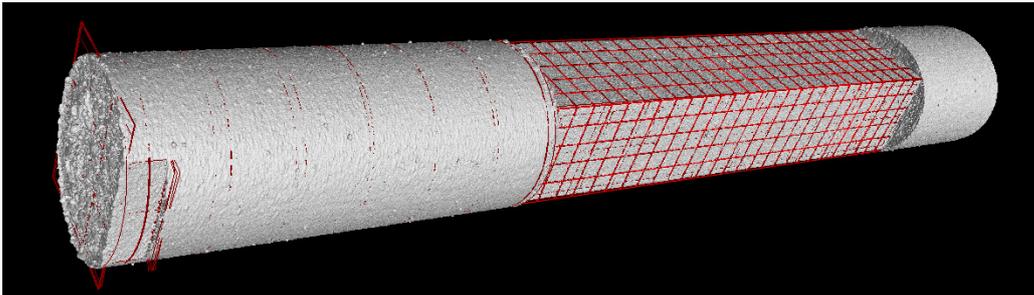


Abbildung 5-23: Probekörper mit definierten Einheitszellen (rot) in der ROI dargestellt in VGStudio Max

Durch die Nutzung des regelmäßigen Integrationsnetzes zur Bildung von Einheitszellen in VGStudio werden Poren, welche sich über Zellgrenzen hinweg erstrecken, anteilig den zugehörigen Einheitszellen zugeordnet. Die Nutzung von Einheitszellen sorgt weiterhin dafür, dass für eine datengetriebene Modellbildung ausreichen Datenpunkte zur Verfügung stehen, da jede Einheitszelle mit der zugehörigen Gesamtporosität in dieser als Datentupel genutzt wird.

³¹ Interne Bezeichnung von VGStudio Max für ein regelmäßiges Gitter mit definierter Kantenlänge

5.4.2.5 Durchführung der Porositätsanalyse mittels *VGEasyPore-Algorithmus*

Nach der Definition der ROI und des regelmäßigen Integrationsnetzes wird die Porositätsanalyse mit *VGStudio* durchgeführt. Dazu wird analog zur Auswertekette in Kapitel 5.4.1.3 der Algorithmus *VGEasyPore* verwendet. In Kapitel 5.4.1 wurde gezeigt, dass die Auswertekette prinzipiell als Referenzmessung geeignet ist und reproduzierbare Ergebnisse mit der für die Anwendung ausreichender Genauigkeit erzeugt. Die verwendeten Parameter des *VGEasyPore*-Algorithmus sind in Tabelle 5-8 dargestellt.

Tabelle 5-8: Parameter des *VGEasyPore*-Algorithmus zur Porositätsanalyse

Parameter ³²	Wert
Modus	Subvoxel
Algorithmus	Absolut
Kontrast	8700 ³³
Größe lokaler Bereich	10 Voxel
Analysebereich	Interne Bereinigung, klein
Abstand zur Oberfläche	1 Voxel

Im Vergleich zu den Parametern in Kapitel 5.4.1.3 (vgl. dazu auch Tabelle 5-6) muss aufgrund des geänderten CT-Gerätes der Wert für den Parameter Kontrast von 7500 für den schärfe-optimierten Parametersatz auf 8700 im vorliegenden Fall angepasst werden. Die Wahl des Parameters wurde erneut mit einem Anwendungingenieur des Herstellers *Volume Graphics* überprüft.

In der Porositätsanalyse ordnet *VGStudio Max* jede gefundene Pore der zugehörigen Einheitszelle anteilig zu. Dazu wird voxelgenau betrachtet, welche Anteile einer Pore zu einer Einheitszelle gehören.

5.4.2.6 Export der Porositätsanalyse zur weiteren Verwendung

Nach der Durchführung der Porositätsanalyse kann aus *VGStudio Max* die Referenzmessung exportiert werden. Im Rahmen dieser Arbeit werden die folgenden Exporte erstellt:

1. Analysereport: aus dem Analysereport wird die Gesamtporosität des Probekörpers extrahiert.

³² Alle weiteren Parameter werden, sofern nicht angegeben, auf den Standardwerten belassen.

³³ Der Kontrastwert wurde bei einigen wenigen Bauteilen manuell korrigiert, da Abweichungen in der Grauwertverteilung im CT-Scan festgestellt wurden. Die Ursache der Abweichungen konnte durch *Zeiss* nicht identifiziert werden.

2. Liste der Einheitszellen: Die Liste der Einheitszellen umfasst beschreibende Elemente der Einheitszelle wie Mittelpunkt und Ausdehnung, eine eindeutige numerische Identifikationsnummer sowie die vorliegende Gesamtporosität innerhalb der Einheitszelle.
3. Liste der Einzeldefekte: Die Liste der Einzeldefekte umfasst eine Vielzahl von Kennzahlen (bspw. Volumen, Oberfläche, Sphärizität, projizierte Flächen, ...) für jede einzelne Pore innerhalb des Bauteils.

Diese Informationen aus der Porositätsanalyse werden nachfolgend als Referenzmessung zur datengetriebenen Modellbildung verwendet.

5.5 Datenanalyse zur Vorhersage der orts aufgelösten Porosität

Nachdem die Datengrundlage für die Modellbildung geschaffen wurde, soll in diesem Kapitel das Vorgehen zur Vorhersage der ortsaufgelösten Porosität vorgestellt werden.

In Abbildung 5-24 ist das Vorgehen im Rahmen dieses Kapitels dargestellt.

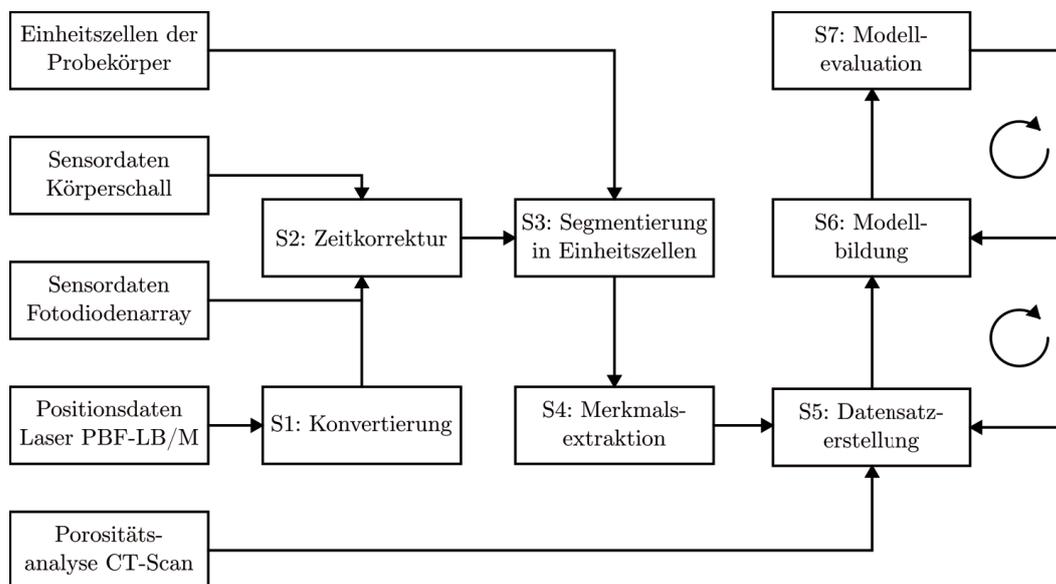


Abbildung 5-24: Vorgehen zur Datenanalyse mit den einzelnen Schritten S1-S7

In den vorherigen Kapiteln wurde die Datengrundlage für die Auswertung im Rahmen der datengetriebenen Modellbildung geschaffen: die Probekörper wurden gedanklich in Einheitszellen zerlegt (vgl. Kapitel 5.4.2.4), beim Druck der Probekörper wurden Sensordaten von Körperschall und Fotodiodenarray sowie die Position des Lasers aufgezeichnet (vgl. Kapitel 5.3.4). In Kapitel 5.4.1.9 wurde eine Porositätsanalyse der Probekörper auf Basis von CT-Scans durchgeführt.

Im ersten **Schritt S1** erfolgt eine Konvertierung der Positionsdaten des Lasers der PBF-LB/M Anlage von internen Anlagenkoordinatensystemen in das Bauteilkoordinatensystem des Probekörpers. Mit diesen Informationen kann in **Schritt S2** eine Zeitkorrektur der Sensordaten erfolgen, sodass diese zeitsynchron vorliegen. Diese zeitsynchronisierten Daten werden in **Schritt S3** segmentiert, sodass einzelne Segmente der Sensordaten den einzelnen Einheitszellen zugewiesen werden. In **Schritt S4** werden aus diesen Daten Merkmale extrahiert, welche als Eingangsvektoren für die Modellbildung genutzt werden. Zusammen mit der Porositätsanalyse der CT-Daten als Referenzmessung wird in **Schritt S5** der Datensatz für die Modellbildung erstellt. In **Schritt S6** erfolgt die Modellbildung. Nachfolgend werden in **Schritt S7** die Modelle evaluiert. Die Schritte S5, S6 und S7 können iterativ mehrfach durchlaufen werden. Die Schritte werden nachfolgend detailliert vorgestellt.

5.5.1 Konvertierung der Positionsdaten des Lasers

Die Positionsdaten des Lasers werden, wie in Kapitel 5.2.3.3 dargestellt, durch Abgreifen des SPI-Busses der Galvanometerscanneransteuerung erfasst. Diese Positionsdaten liegen im internen Scannerkoordinatensystem $KOS_{Scanner}$ vor. Alle relevanten Koordinatensysteme sind in Abbildung 5-25 abgebildet. $KOS_{Scanner}$ ist ein rein positiv definiertes Koordinatensystem bestehend aus Bitwerten. Die Bitwerte sind von 0 bis maximal $2^{16} - 1 = 65535$ definiert. Das kleinste Inkrement, um welches der Laser verfahren werden kann, ist ein Bit. Der Bitwertebereich umfasst 150 mm und wurde vom Anlagenhersteller etwas größer als die Bauplatzform mit 125 mm Kantenlänge gewählt. Das kleinste Inkrement des Galvanometerscanners beträgt daher $150 \text{ mm} / (2^{16} - 1) \approx 2,29 \mu\text{m}$.

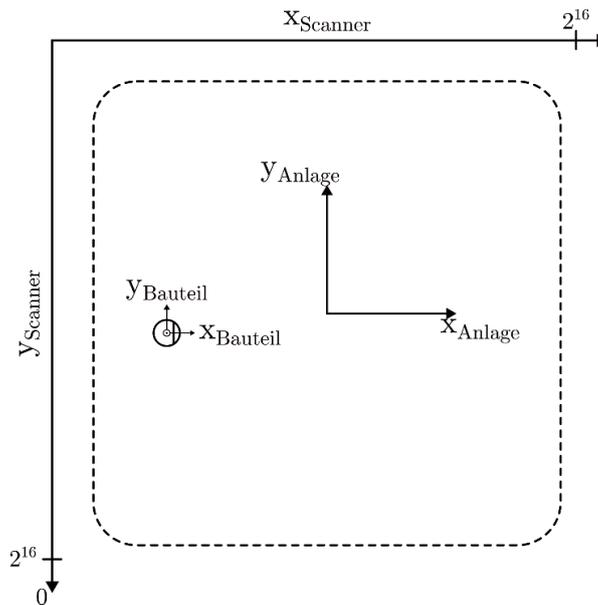


Abbildung 5-25: Darstellung der verschiedenen Koordinatensysteme mit schematischer Bauplatzform (gestrichelt dargestellt) und exemplarischem Probekörper

Im Zuge der Konvertierung wird auch die Korrektur des Verhaltens der F-Theta-Linse durchgeführt. Das Verhalten der F-Theta-Linse kann näherungsweise durch eine Spline-Funktion $f_{Spline}(x, y)$ beschrieben werden. In der Anlagensteuerung wird auf die gewünschten Koordinaten die Inverse der Spline-Funktion $f_{Spline}(x, y)^{-1}$ angewandt, damit nach dem Durchlaufen der F-Theta-Linse eine Abbildung auf sich selbst erfolgt: $f_{Spline}(f_{Spline}(x, y)^{-1}) = (x, y)$. Aus dem Anlagencode der PBF-LB/M Anlage ist nur die Inverse der Spline-Funktion bekannt. Aus diesem Grund muss während der Konvertierung die Inverse der Inversen gebildet werden, da $(f^{-1})^{-1} = f$ gilt. Durch den daraus entstehenden Interpolator für die x- und y-Koordinate im Anlagenkoordinatensystem KOS_{Anlage} erfolgt eine Konvertierung von Bitwerten in Millimeterwerte mit integrierter F-Theta-Korrektur.

Die Transformation der Positionsdaten von KOS_{Anlage} zum Bauteilkoordinatensystem $KOS_{Bauteil}$ erfolgt durch die Anwendung einer linearen Transformation als reine Translation des Koordinatensystems KOS_{Anlage} . Dazu wird von allen Positionsdaten der Vektor zum Mittelpunkt der umhüllenden *Bounding-Box* des Bauteils abgezogen. Die *Bounding-Box* kann aus dem Druckjobvorbereitungsprogramm exportiert werden und ist somit bekannt.

5.5.2 Zeitkorrektur der Sensordaten

Beim Druck der Probekörper (vgl. Kapitel 5.3.4) erfolgt bei der Belichtung zum Zeitpunkt des Einschaltsignals des Lasers ein zentraler Trigger-Impuls für alle angeschlossenen Messsysteme (Positionsaufzeichnung, Körperschall, Fotodiodenarray). Der Trigger ist zeitsynchron für alle Messsysteme. Eine Zeitasynchronität entsteht jedoch durch die Tatsache, dass zwischen Trigger-Signal und Start der Messung in allen Systemen eine nicht-deterministische Zeitspanne von etwa drei bis sieben Millisekunden vergeht. Die Ursache liegt darin, dass alle verwendeten Teilsysteme keine Echtzeitsysteme sind. Aus diesem Grund muss eine Synchronisierung der aufgezeichneten Messdaten durch eine Zeitkorrektur durchgeführt werden. Damit ausreichend Zeit zum Start einer Messung bleibt, wird nach dem Trigger-Signal und dem Einschalten des Lasers eine Zeitverzögerung von 200 Millisekunden eingefügt.

Als Hauptzeit wird dabei die Positionsaufzeichnung genutzt und der Zeitversatz von sowohl Fotodiodenarray (siehe Kapitel 5.5.2.1) als auch Körperschallsensor (siehe Kapitel 5.5.2.2) zur Zeit der Positionsaufzeichnung berechnet. Der Startzeitpunkt des Belichtungsvorgangs kann in der Positionsaufzeichnung durch Bestimmung des Startzeitpunkts des ersten Scan-Vektors bestimmt werden. Zur Bestimmung des Zeitversatzes wird beim Fotodiodenarray das Signal im Zeitbereich verwendet, beim Körperschallsignal wird das Signal im Frequenzbereich betrachtet. Nach Bestimmung der Zeitversatzwerte werden alle Signale um den entsprechenden Wert korrigiert und die somit synchronisierten Signale gespeichert.

5.5.2.1 Bestimmung des Zeitversatzes für das Fotodiodenarray

Das Verhalten des Sensorsignals des Fotodiodenarrays beim Einschalten des Lasers kann ähnlich zu einer Sprungfunktion betrachtet werden. In Abbildung 5-26 ist der exemplarische Verlauf des Sensorsignals des Fotodiodenarrays für (a) die Wellenlänge des Lasers und (b) den sichtbaren Wellenlängenbereich für ein Bauteil in einer Schicht dargestellt. Der Zeitpunkt des Signalsprungs kann durch den Zeitpunkt des Überschreitens eines Schwellwerts für eine Mindestzeit zuverlässig detektiert werden. Der Zeitpunkt kann anhand der Daten des sichtbaren Spektrums besser detektiert werden, da das Signal weniger Rauschen aufweist.

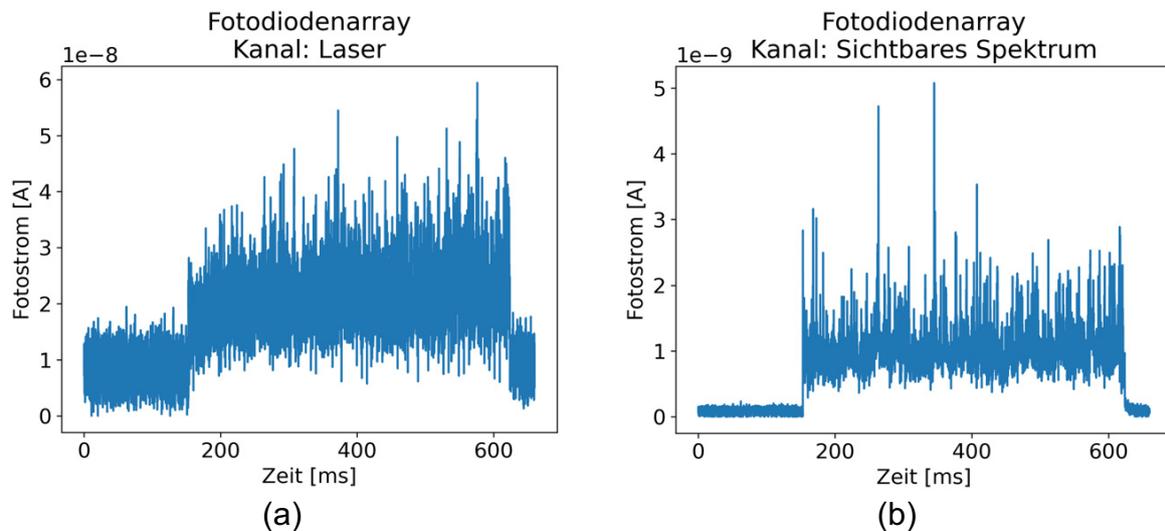


Abbildung 5-26: Exemplarischer Sensordatenverlauf des Fotodiodenarrays für ein Bauteil in einer Schicht für den (a) Laser und (b) das sichtbare Spektrum.

Zusammen mit dem Startzeitpunkt des Belichtungsvorgangs auf Basis der Positionsdaten kann so der Zeitversatz für das Fotodiodenarray bestimmt werden und in der Folge dieser Zeitversatz korrigierend zur Synchronisation der Daten genutzt werden.

5.5.2.2 Bestimmung des Zeitversatzes für den Körperschallsensor

In Abbildung 5-27 ist das Rohsignal des akustischen Körperschallsensors im Zeitbereich für ein Bauteil in einer Sicht dargestellt³⁴. Zur Bestimmung des Zeitversatzes für den Körperschallsensor kann im Gegensatz zum Fotodiodenarray nicht das Sensorsignal im Zeitbereich verwendet werden, da kein eindeutiger Intensitätssprung beim Einschalten des Lasers erkennbar ist. Bei der Durchführung einer Kurzzeit-Fourier-Transformation ist im resultierenden Spektrogramm der Einschaltzeitpunkt des Lasers eindeutig zu erkennen (vgl. Abbildung 5-28 (a)).

³⁴ Die in Abbildung 5-27 dargestellte Amplitude ist durch die Vorverstärkung und AD-Wandlung im QASS System nicht mehr zweifelsfrei in eine physikalische Größe rückführbar und wird deshalb einheitenlos angegeben.

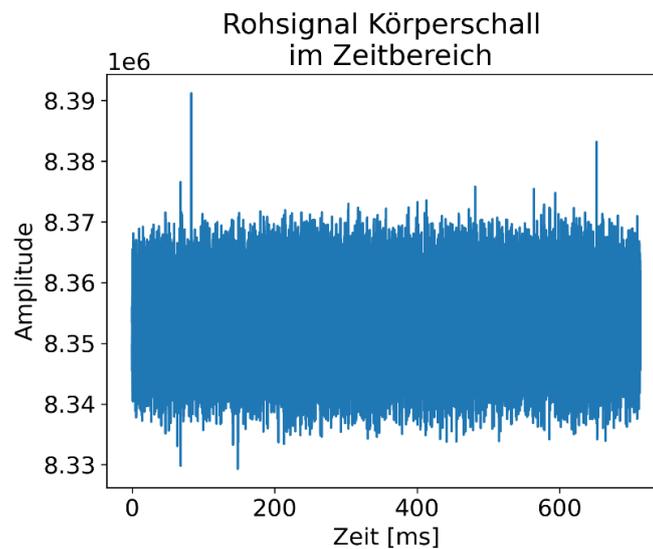


Abbildung 5-27: Rohsignal des Körperschalls im Zeitbereich

Für jeden Zeitpunkt wird die Gesamtintensität des Signals durch Summation der Amplituden für alle Frequenzen bestimmt, sodass eine näherungsweise Sprungfunktion wie beim Fotodiodenarray zu erkennen ist. In Abbildung 5-28 (b) ist die aus dem Spektrogramm abgeleitete Gesamtintensität des Körperschallsignals dargestellt.

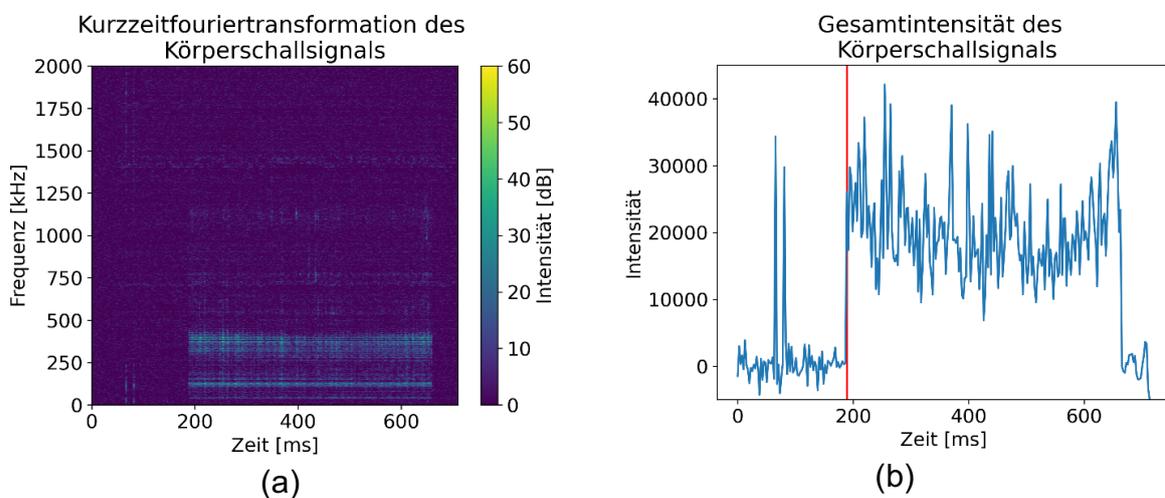


Abbildung 5-28: Spektrogramm der Kurzzeit-Fourier-Transformation des Körperschallsignals (a) und resultierender Verlauf der Gesamtintensität (b)

Durch die Erzeugung eines ähnlichen Signalverlaufs wie für das Fotodiodenarray kann der Zeitversatz für das Körperschallsignal analog zum Fotodiodenarray bestimmt werden. Überschreitet die Gesamtintensität einen gewissen Schwellwert für einen gewissen Zeitraum, kann der Startzeitpunkt zuverlässig detektiert werden. In Abbildung 5-28 (b) ist der resultierende Startzeitpunkt rot eingezeichnet.

5.5.3 Segmentierung der Sensordaten in Einheitszellen

Die Daten des Körperschallsensors und des Fotodiodenarrays liegen als Zeitreihe für einen Probekörper und eine Schicht vor. Im Querschnitt besteht jeder Probekörper aus $5 \times 5 = 25$ Einheitszellen. Die Reihenfolge der Nummerierung ist in Abbildung 5-29 (a) dargestellt. Den Einheitszellen werden anteilig die zugehörigen Sensorsignale zugewiesen. Dazu wird der Scanvektor einer Schicht basierend auf den Positionsdaten des Lasers in die Einheitszellen segmentiert. Für jeden Scanvektor werden die verschiedenen Ein- und Austrittszeitpunkte für jede Einheitszelle in jeder Schicht bestimmt. Der segmentierte Scanvektor ist in Abbildung 5-29 (b) vereinfacht dargestellt.

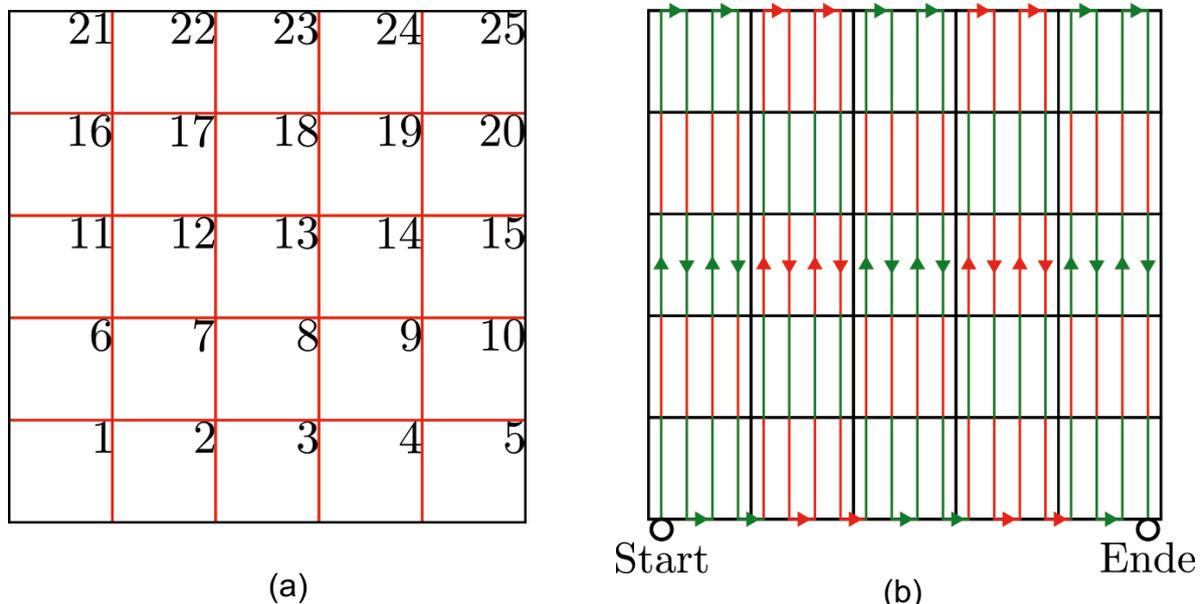


Abbildung 5-29: (a) Reihenfolge der Nummerierung von Einheitszellen in einer Schicht und (b) Segmentierung des Scanvektors (vereinfacht dargestellt) einer Schicht in die Einheitszellen

Die so bestimmten Ein- und Austrittszeitpunkte werden genutzt, um die Rohsensordaten von der Körperschallsensorik und dem Fotodiodenarray zu segmentieren. Die zwischen Ein- und Austrittszeitpunkt liegenden Daten werden in der Folge als Segment bezeichnet. Die Segmentierung ist möglich, da in Schritt 2 (vgl. Kapitel 5.5.2) eine Korrektur des Zeitversatzes zwischen den Sensoren und somit eine Synchronisierung durchgeführt wurde. Aufgrund der Lage einer Zelle sind unterschiedlich viele Segmente in den Zellen vorhanden, da unterschiedlich viele oder gar keine Wendepunkte in den jeweiligen Zellen liegen. Dies führt dazu, dass drei verschiedene Arten von Einheitszellen voneinander abgegrenzt werden können:

1. Innenliegende Einheitszellen: diese Einheitszellen liegen im Inneren des Probekörpers und sind auf allen Seiten von weiteren Einheitszellen umgeben.
2. Rand-Einheitszellen: Randeinheitszellen sind auf genau einer Seite von keinen weiteren Einheitszellen umgeben.
3. Eck-Einheitszellen: ECKeinheitszellen sind an mindestens zwei Seiten von keinen weiteren Einheitszellen umgeben.

In Abbildung 5-30 sind die verschiedenen Einheitszelltypen exemplarisch für den Querschnitt des Probekörpers eingezeichnet. Die Segmente des Sensorsignals einer Einheitszelle werden zur weiteren Verarbeitung abgespeichert.

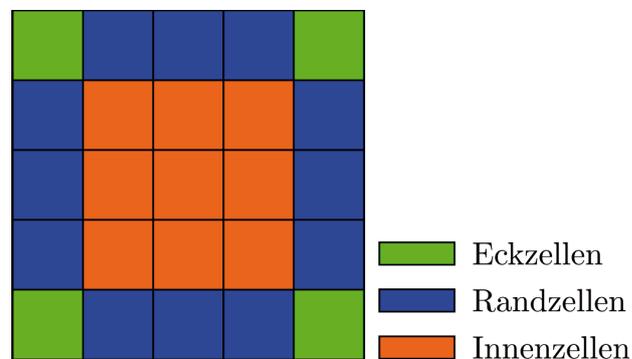


Abbildung 5-30: Einteilung der Einheitszellen in Rand-, Eck- und Innenzellen

5.5.4 Merkmalsextraktion

Die **Körperschallsensorik** nimmt Daten mit einer Abtastrate von 4 MHz auf. Dies führt zu einer großen Anzahl an Datenpunkten nach der Segmentierung in den Einheitszellen. Da diese Datenpunkte im Rahmen der datengetriebenen Modellbildung in das Modell eingehen, führt eine hohe Anzahl an Datenpunkten zu komplexeren Modellen, da mehr Parameter in den Modellen angepasst werden müssen. Aus diesem Grund wird vor der Modellbildung eine Merkmalsextraktion und Merkmalstransformation ausgeführt (vgl. Kapitel 2.4.2), um einen höherdimensionalen Merkmalsraum in einen niedrigerdimensionalen Merkmalsraum zu überführen. Dies führt zu einer höheren Informationsdichte der Datenpunkte, sodass ein effizienteres Modelltraining ermöglicht wird.

Der Stand der Forschung zu akustischen Daten hat gezeigt (vgl. Kapitel 3.2.3), dass die Transformation vom Zeitbereich in den Frequenzbereich mittels Fourier-Transformation deutliche Vorteile in der erreichbaren Modellgüte ermöglicht (Eschner et al. 2020; Eschner 2021). Aus diesem Grund wird auch im Rahmen dieser Arbeit eine Fourier-Transformation der akustischen Daten in den Frequenzbereich durchgeführt.

Bei der diskreten Fourier-Transformation erfolgt eine Zerlegung des Signals in seine Frequenzanteile. In der Folge geht der Zeitbezug und damit auch der Positionsbezug in den Daten verloren. Somit ist eine orts aufgelöste Vorhersage nicht möglich.

Die Kurzzeit-Fourier-Transformation erlaubt das Erstellen eines Spektrogramms, in welchem neben der Amplitude der jeweiligen Frequenzanteile auch noch der zeitliche Verlauf der Amplituden der jeweiligen Frequenzanteile enthalten ist. In Abbildung 5-28 (a) ist exemplarisch das Spektrogramm einer kompletten Schicht eines Probekörpers dargestellt.

In Kapitel 2.4.2.1 wurde der grundlegende Zielkonflikt zwischen Frequenz- und Zeitauflösung bei der Durchführung der Kurzzeit-Fourier-Transformation dargestellt. Zur Beurteilung der Zeit- und Frequenzauflösung wird eine STFT mit der Funktion *specgram* aus dem Python-Paket *Matplotlib* verwendet. Die Funktion wurde mit den in Tabelle 5-9 dargestellten Parametern³⁵ für die gesamten akustischen Körperschalldaten einer Schicht für einen Probekörper durchgeführt.

Tabelle 5-9: Parameter der Funktion specgram aus Python zur Berechnung der Kurzzeit-Fourier-Transformation

Parameter	Wert
Fs (Abtastrate)	4.000.000 Hz
NFFT	20.000
noverlap	10.000
scale	default
mode	psd

Aufgrund der hohen Prozessgeschwindigkeit von 1000 mm/s und der Kantenlänge der Einheitszellen von 1 mm ist die zeitliche Auflösung der reinen STFT nicht ausreichend, um eine orts aufgelöste Messung durchzuführen. Die zeitliche Auflösung beträgt nur noch 0,0025s. Das bedeutet, dass pro Messzeitpunkt in der STFT 2,5 Einheitszellen durchlaufen werden. Die ausreichende Erhöhung der zeitlichen Auflösung geht mit einer zu großen Reduktion der Frequenzauflösung einher, sodass eine rein STFT-basierte Auswertung der Einheitszellen nicht möglich ist.

Aus diesem Grund wird ein alternatives Merkmal verwendet, was auch bei einer orts aufgelösten Messung die Transformation in den Frequenzbereich erlaubt. In Kapitel 5.5.3 wurde dargestellt, wie die Rohsensordaten der akustischen Körperschallsensorik

³⁵ Nicht explizit erwähnte Parameter der Funktion werden auf den Standardwerten des Pakets belassen.

in die Einheitszellen segmentiert wurden. Jeder Einheitszelle sind somit mehrere Segmente aus mehreren Schichten der akustischen Körperschalldaten zugeordnet. Jedes Segment wird einzeln mittels einer Fourier-Transformation in den Frequenzbereich überführt. Die entstehenden Spektren können zweidimensional als Pseudo-Spektrogramm dargestellt werden, indem die einzelnen Spektren entlang der Ordinate aneinandergereiht werden. Somit existiert für jede dreidimensionale Einheitszelle eine zweidimensionale, repräsentative Darstellung. Dieses Merkmal wird im Rahmen dieser Arbeit als *FFT-Segment* bezeichnet. In Abbildung 5-31 ist exemplarisch ein Pseudo-Spektrogramm des *FFT-Segment*-Merkmals für eine Einheitszelle dargestellt. Entlang der Ordinate ist eine zunehmende z-Höhe innerhalb der Einheitszelle festgemacht.

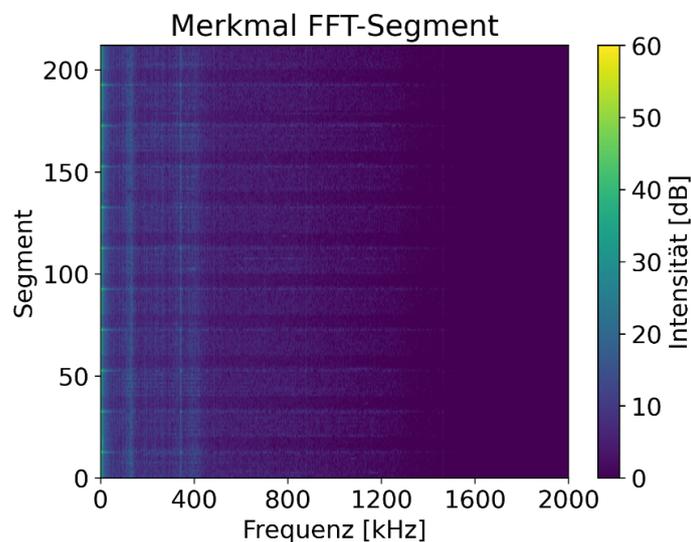


Abbildung 5-31: Exemplarische Darstellung des *FFT-Segment*-Merkmals für eine Einheitszelle

Das **Fotodiodenarray** nimmt Sensordaten mit 50 kHz auf. Optische Prozesssignaturen wurden ebenfalls im Stand der Forschung auf deren sinnvolle Weiterverarbeitung untersucht. Im Gegensatz zu akustischen Daten ist die Transformation in den Frequenzbereich nicht vorteilhaft. Aus diesem Grund wird mit einer Hauptkomponentenanalyse gearbeitet, die eine Reduktion auf wesentliche Datenpunkte durchführt. Die Anzahl der Hauptkomponenten wurde in Vorarbeiten (A_Fink 2021; A_Knipper 2021; A_Liebetau 2021) anhand der kumulierten Varianz (vgl. Kapitel 2.4.2.2) untersucht. Dabei ergeben sich bei 80 % kumulierte Varianz die besten Ergebnisse, sodass dieser Wert zur Bestimmung der Hauptkomponentenanzahl herangezogen wird.

5.5.5 Datensatzerstellung für Modellbildung

Damit die datengetriebene Modellbildung durchgeführt werden kann, muss ein finaler Datensatz erstellt werden. Für diesen werden noch Vorverarbeitungsschritte durchgeführt, bevor die Zusammenstellung von Merkmalen und Labels erfolgt.

5.5.5.1 Vorstellung der verwendeten Recheneinheit zur Modellbildung

Im Rahmen dieser Arbeit soll eine datengetriebene Modellbildung durchgeführt werden. Zur Erstellung der Modelle wird eine *DGX-Station* von *Nvidia* verwendet. Diese Workstation beinhaltet vier Grafikkarten (GPU) und ist für den Einsatz im Bereich des maschinellen Lernens optimiert. Die wichtigsten Spezifikationen der Komponenten in der *DGX-Station* sind in Tabelle 5-10 dargestellt.

Tabelle 5-10: Spezifikationen des verwendeten Rechners *DGX-Station* von *Nvidia*

Komponente	Details
Prozessor (CPU)	Intel Xeon E5-2698
Grafikkarten (GPU)	4x Nvidia Tesla V100 mit 4x32 GByte = 128 GByte VRAM
Arbeitsspeicher (RAM)	256 GByte
Massenspeicher	10 TByte (Solid State Disk)

5.5.5.2 Kompression der akustischen Körperschalldaten

Das in Kapitel 5.5.4 erstellte Merkmal *FFT-Segment* für die akustischen Körperschalldaten umfasst für alle Probekörper in Summe 1,29 TByte Daten. Im Rahmen der datengetriebenen Modellbildung muss diese Datenmenge iterativ verarbeitet werden. Die in Kapitel 5.5.5.1 vorgestellte Recheneinheit *DGX-Station* hat lediglich einen Arbeitsspeicher von 256 GByte, sodass der Datensatz aller Probekörper nicht in den Arbeitsspeicher geladen werden kann. Obwohl die *DGX-Station* mit Solid State Disks (SSDs) ausgestattet ist, sind die Schreib- und Lesegeschwindigkeiten von SSDs gegenüber dem Arbeitsspeicher um ein Vielfaches geringer. Benchmarks auf der *DGX-Station* ergeben für die SSDs³⁶ eine Lesegeschwindigkeit von 125,8 MiByte/s, während der RAM eine Lesegeschwindigkeit von 1,00 GiByte/s erreicht. Die Leseraten des RAMs sind also etwa achtmal so hoch wie die der SSDs. Bei 1,29 TByte an Daten würde es mindestens 22h 56min dauern, die Daten von der SSD zu lesen. Da die datengetriebene

³⁶ Die SSDs der *DGX-Station* sind per Software-RAID zu einem RAID10 zusammengeschaltet.

Modellbildung stark auf iterativem Modelltraining beruht, ist erkenntlich, dass eine Komprimierung der Daten stattfinden sollte, sodass diese in den RAM der *DGX-Station* passen um die Trainingszeiten der Modelle auf ein nutzbares Maß zu reduzieren.

Die Daten des *FFT-Segment*-Merkmals liegen als 2D-Array vor. Die Anzahl der Spalten stellt die einzelnen Frequenzen dar, die Anzahl der Reihen die Anzahl der Segmente in der jeweiligen Einheitszelle. Aus Kapitel 5.5.3 ist bekannt, dass jede Einheitszelle eine unterschiedliche Anzahl an Segmenten enthält. Die Anzahl der Segmente bewegt sich im Bereich von 110 bis 298 Segmenten. Entlang der Abszisse wird eine konstante Anzahl an Datenpunkten benötigt, um die weitere Auswertung mit Python zu vereinfachen. Die Anzahl der Datenpunkte entlang der Abszisse wird durch die Parametrierung der FFT auf konstante 10.001 Datenpunkte festgelegt. Insgesamt ergibt sich ein Array mit den Dimensionen $(n_{\text{Segmente}}, 10.001)$. In der Folge werden zwei Ansätze dargelegt, wie die Datenmenge auf ein Maß komprimiert werden kann, sodass die Daten bei möglichst großem Informationserhalt in den Arbeitsspeicher der *DGX-Station* passen. Auf Basis der Datenstruktur des Merkmals *FFT-Segment* werden zwei verschiedene Arten der Kompression betrachtet.

Der erste Ansatz setzt auf die Kompression durch Größenänderung des Gesamtarrays, analog zur Größenänderung von Bildern. Dabei erfolgt die Kompression entlang beider Achsen des Arrays. Das so erhaltene Merkmal wird in der Folge *FFT-Segment-Resized* genannt. Dieser Ansatz verwendet das Python-Paket *scikit-image* mit der Funktion *resize* aus dem Modul *scikit-image.transform*. Die Daten werden auf 224x224 Datenpunkte reduziert. Es ergibt sich für den Gesamtdatensatz eine Größe von etwa 27,5 GByte, sodass der Datensatz problemlos in den Arbeitsspeicher der *DGX-Station* passt. In Abbildung 5-32 ist das Merkmal *FFT-Segment-Resized* für eine Einheitszelle exemplarisch dargestellt. Im Vergleich zum nicht komprimierten *FFT-Segment*-Merkmal aus Abbildung 5-31 weist das Merkmal *FFT-Segment-Resized* in Abbildung 5-32 eine veränderte Anzahl an Datenpunkten auf (224x224 statt 212x10.001).

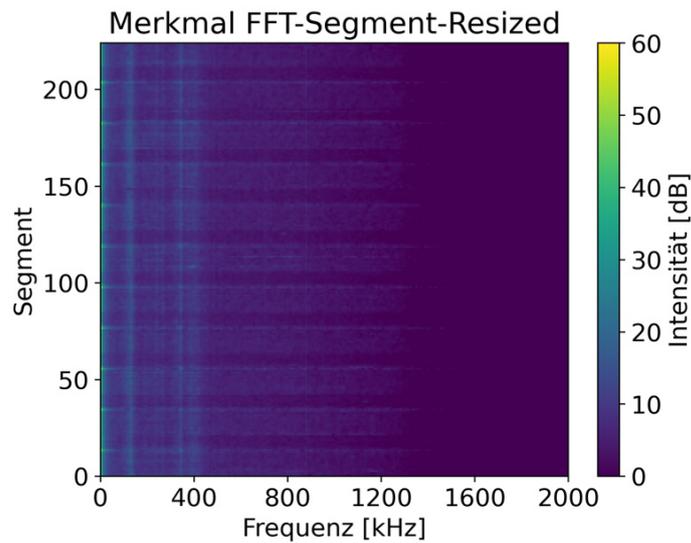


Abbildung 5-32: Exemplarische Darstellung des FFT-Segment-Resized Merkmals für eine Einheitszelle

Als zweiter Ansatz erfolgt eine Kompression entlang der Frequenzachse des Datenarrays. Eine Kompression entlang der Segmentachse wird nicht betrachtet, da die Anzahl der Segmente gegenüber der Anzahl der Datenpunkte entlang der Frequenzachse deutlich kleiner ist. Ziel der Kompression entlang der Frequenzachse ist es, N Datenpunkte repräsentativ zusammenzufassen. Somit erfolgt eine Kompression um den Faktor N . Das Vorgehen zur Kompression wird in Tabelle 5-11 dargestellt. Das so errechnete neue Merkmal wird in der Folge als *FFT-Segment-Reduced* bezeichnet. In der vorliegenden Arbeit wird $N=100$ gewählt. Der resultierende Datensatz nimmt noch eine Größe von 11,96 GByte ein, sodass auch dieser Datensatz in den Arbeitsspeicher der *DGX-Station* geladen werden kann. In Abbildung 5-33 ist die *FFT-Segment-Reduced* für eine Einheitszelle exemplarisch dargestellt. Im Vergleich zum nicht komprimierten *FFT-Segment-Merkmal* aus Abbildung 5-31 weist die *FFT-Segment-Reduced* eine reduzierte Anzahl an Datenpunkten auf (212×100 statt 212×10.001).

Tabelle 5-11: Vorgehen zur Berechnung des Merkmals *FFT-Segment-Reduced*

Schritt	Berechnung	Erklärung
1	$x_i = 10^{x_{i,dB}/10}, i = 0,1, \dots, 10000$	Datenpunkte des <i>FFT-Segment</i> -Merkmals werden von der dB-Skala in eine Amplitude umgewandelt.
2	$\mathbf{x}_n = \begin{pmatrix} x_{nN} \\ x_{nN+1} \\ \vdots \\ x_{(n+1)N-1} \end{pmatrix}, n = 0,1, \dots, \left\lfloor \frac{10001}{N} \right\rfloor$	Bestimmen der Amplitudenvektoren aus je N nebeneinanderliegenden <i>FFT-Segment</i> Datenpunkten.
3	$\hat{x}_n = \frac{1}{N} \mathbf{x}_n^T \mathbf{x}_n$	Zusammenfassen der Datenpunkte
4	$\hat{x}_{n,dB} = 10 \log_{10}(\hat{x}_n)$	Umwandlung der Amplitudenwerte zurück zu dB.

Dabei sind

x_i bzw. $x_{i,dB}$: Datenpunkte der *FFT-Segment* als Amplitude bzw. in dB

\mathbf{x}_n : Amplitudenvektor der Länge N

N: Reduktionsfaktor

\hat{x}_n bzw. $\hat{x}_{n,dB}$: Datenpunkte der *FFT-Segment-Reduced* als Amplitude bzw. in dB

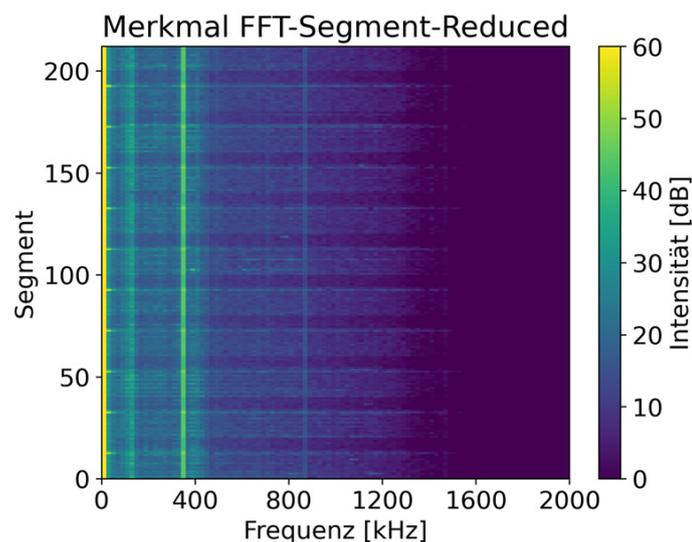


Abbildung 5-33: Exemplarische Darstellung des *FFT-Segment-Reduced* Merkmals für eine Einheitszelle

Die optischen Sensordaten des Fotodiodenarrays müssen keiner Komprimierung unterzogen werden, da diese lediglich mit 50 kHz abgetastet werden und somit eine wesentlich niedrigere Gesamtdatenmenge vorliegt. Die Rohdaten sowie daraus abgeleitete Merkmale können in den Speicher der verwendeten *DGX-Station* (vgl. Kapitel 5.5.5.1) geladen werden.

5.5.5.3 Einteilung in Test- und Trainingsdaten

Im Rahmen der datengetriebenen Modellbildung erfolgt eine Aufteilung der Datenmenge in Trainings-, Validierungs- und Testdaten. Grundsätzlich sind zwei Arten der Aufteilung im vorliegenden Anwendungsfall denkbar. Es kann entweder eine Aufteilung auf Einheitszellenebene stattfinden, bei der die Gesamtheit an Einheitszellen randomisiert aufgeteilt wird oder es erfolgt die Aufteilung auf Probekörpererebene, bei welcher komplette Probekörper randomisiert in die Datensätze aufgeteilt werden. Da in einer möglichen Aufteilung auf Einheitszellebene nicht ausgeschlossen werden kann, dass Zellen auf Basis von darüberliegenden und somit noch zu druckenden Einheitszellen vorhergesagt werden, soll im Rahmen dieser Arbeit die Aufteilung auf Probekörpererebene durchgeführt werden. Nach gängiger Praxis (Rashidi et al. 2019) werden 80 % der Probekörper (und alle dazugehörigen Einheitszellen) den Trainingsdaten zugeordnet. Die restlichen 20 % werden dem Testdatensatz zugewiesen. Vom Trainingsdatensatz werden nochmals randomisiert 10 % der Probekörper dem Validierungsdatensatz zugordnet, welcher genutzt wird, um nach jeder Epoche eine Validierung des Modells durchzuführen. Da die Aufteilung randomisiert erfolgt, wäre es statistisch denkbar, dass alle Testdaten aus nur einem Druckjob stammen. Um dies zu vermeiden, wird beim Aufteilen sichergestellt, dass alle Druckjobs in den entsprechenden Datensätzen vertreten sind. Die konkrete Zuweisung der Probekörper zu Trainings- und Testdatensatz wird in Kapitel 6.1 dargestellt.

5.5.6 Modellbildung

Die datengetriebene Modellbildung im Rahmen dieser Arbeit soll mit Methoden des maschinellen Lernens durchgeführt werden. Aufgrund der großen Datenmenge und der Komplexität der Daten werden künstliche neuronale Netze verwendet. Bei der Verwendung von künstlichen Neuronalen Netzen können zwei Vorhersagearten unterschieden werden: die Klassifikation und die Regression (vgl. Kapitel 2.4.3).

Bei der Klassifikation erfolgt eine binäre Einteilung der Einheitszellen auf Basis der vorliegenden Gesamtporosität in der Zelle. Dazu wird ein Schwellwert in % Porosität in der Zelle festgelegt. Unterhalb dieser Schwelle wird die Zelle als *defektfrei* betrachtet, oberhalb der Schwelle wird die Zelle als *defektbehaftet* angesehen. In Abbildung 5-34 sind die relativen Häufigkeiten der Zellporosität basierend auf der Referenzmessung mittels Computertomographie dargestellt. Es ist erkenntlich, dass das Porositätsintervall $[0,1]$ % überproportional häufig vertreten ist. Aus diesem Grund wird im Rahmen dieser Arbeit als Schwellwert zur Klasseneinteilung initial 1 % Zellporosität genutzt. Dieses Vorgehen hat insofern industrielle Relevanz, als es im Zuge der Qualitätssicherung von Bauteilen oft unerheblich ist, wie weit ein Schwellwert überschritten ist, sondern nur, ob er überschritten ist.

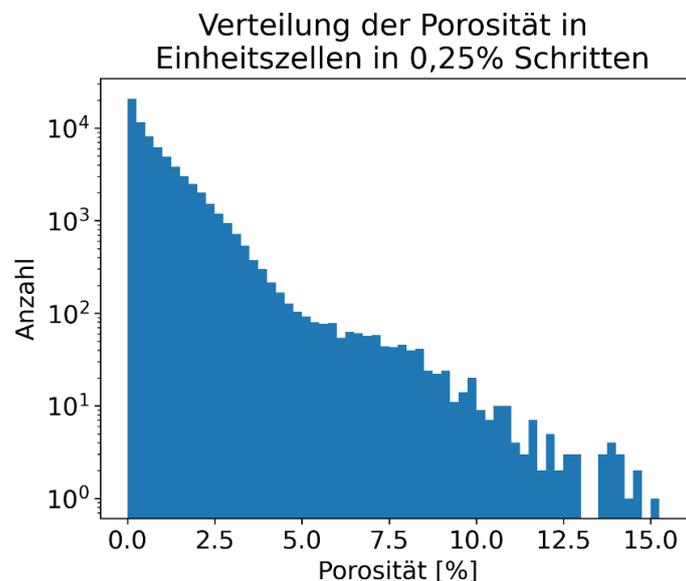


Abbildung 5-34: relative Häufigkeiten der Zellporosität auf Basis der Referenzmessung mittels Computertomographie

Bei der Regression erfolgt eine Vorhersage der konkreten numerischen Porosität in einer Einheitszelle. Diese Werte wurden in Kapitel 5.4.1.9 durch das Durchführen der Referenzmessung mittels Computertomographie bestimmt.

Das Finden von optimierten Modelltopologien wird iterativ durch ein Grid Search durchgeführt. Dabei werden die relevanten Parameterstufen der Modellhyperparameter festgelegt und ein vollfaktorielles Training innerhalb des aufgestellten Parameterraums durchgeführt. Dabei wird *Early Stopping* verwendet. Erfolgt innerhalb von 10 Epochen während des Trainings keine weitere Verbesserung der Verlustfunktion, so wird das

Training beendet und das Modell mit der besten Performance abgespeichert. Alle Modelle werden anhand der Metriken aus Kapitel 5.5.7 bewertet.

5.5.7 Modellevaluation

Nachdem in Kapitel 5.5.6 dargelegt wurde, dass im Rahmen der Modellbildung sowohl eine Klassifikation als auch eine Regression der Zellporosität durchgeführt werden soll, werden die ausgewählten Metriken zur Evaluation der Modelle vorgestellt.

Im Fall der Klassifikation werden die folgenden Kennzahlen als Metrik zur Modellbewertung herangezogen (vgl. auch Kapitel 2.4.4):

- F1-Score: der F1-Score stellt das harmonische Mittel von Precision und Recall dar.
- *Matthews Correlation Coefficient* (MCC): für unausgeglichene Datensätze bei einer binären Klassifikation ist der MCC gegenüber dem F1-Score vorteilhaft, da dieser den unausgegleichenen Klassengrößen Rechnung trägt.
- ROC-Kurve sowie AUC zur Bewertung und Optimierung der Trennschärfe des Modells.

Als Metrik zur Bewertung der Modellperformance im Falle der Regression bieten sich die folgenden zwei Metriken an:

- R^2 / Bestimmtheitsmaß: gibt an, wie gut die Vorhersage einer Regression ist, indem die Residuen betrachtet werden.
- RMSE: Wurzel des mittleren Abweichungsquadrat

Die Modellevaluation und somit die Ergebnisse der Datenanalyse werden ausführlich in Kapitel 6 vorgestellt.

6 Ergebnisse der Datenanalyse

In diesem Kapitel werden die Ergebnisse der Datenanalyse vorgestellt. Kapitel 6.1 stellt die Ergebnisse der Druckjobs detailliert vor. In Kapitel 6.2 wird dargestellt, welchen Einfluss die Datenkomprimierung auf das Vorhersageergebnis hat. Die Klassifikation der Porosität in den Einheitszellen wird in Kapitel 6.3 vorgestellt, während die Darstellung der Regression in Kapitel 6.4 erfolgt. Die Modellübertragbarkeit auf einzelne Druckjobs wird in Kapitel 6.5 betrachtet. In Kapitel 6.6 erfolgt die Darstellung der Ergebnisse einer Datenfusion von akustischen Körperschalldaten und den optischen Daten des Fotodiodenarrays. Abschließend wird in Kapitel 6.7 das leistungsfähigste Modell der untersuchten Modelle vorgestellt.

6.1 Darstellung der Druckjobergebnisse

Zum besseren Verständnis der Ergebnisse der Datenanalyse und als Grundlage zur Interpretation erfolgt zunächst eine Diskussion der Ergebnisse der Druckjobs auf Basis der Referenzmessung aus Kapitel 5.4.1.9.

In Abbildung 6-1 bis Abbildung 6-4 sind die Verteilungen der Gesamtbauteilporosität der einzelnen Probekörper für die Druckjobs 1 bis 4 dargestellt. Abbildung 6-5 zeigt Boxplots³⁷ für die Porosität der Einheitszellen je Probekörper sowie die Aufteilung der Daten in Trainings- und Testdatensatz für die Modellbildung.

Druckjob 1 weist eine maximale Porosität von etwa 8 % in den Einheitszellen der Probekörper auf. Die Anordnung der Probekörper in drei Reihen findet sich auch in der Porosität der Probekörper wieder. Zu Beginn und am Ende jeder Reihe ist die Porosität erhöht.

Druckjob 2 weist eine maximale Porosität von ca. 5 % in den Einheitszellen der Probekörper auf. Im Gegensatz zu Druckjob 1 korrelieren die einzelnen Reihen nur bedingt mit der resultierenden Porosität. Druckjob 2 hat im Vergleich zu den anderen drei Druckjobs das beste Prozessergebnis erzielt. In Abbildung 6-5 ist erkennbar, dass die Probekörper dieses Druckjobs die geringste Gesamtporosität aufweisen und auch die

³⁷ Box mit 25 % (Q₁) und 75 % (Q₃) Quartilen sowie Whisker mit 1,5-mal Interquartilsabstand Q₃ – Q₁

geringste Streuung der Porosität innerhalb der Einheitszellen eines Probekörpers vorliegt. Dies ist konträr zur Erwartungshaltung aus Kapitel 5.3.1 (vgl. Tabelle 5-3), dass Druckjob 2 das schlechteste Prozessergebnis aller Druckjobs aufweisen sollte.

Druckjob 3 weist eine maximale Porosität von ca. 15 % in den Einheitszellen der Probekörper auf. Im Gegensatz zu Druckjob 1 und Druckjob 2 ist in den Boxplots in Abbildung 6-5 eine deutlich stärkere Streuung und Gesamtporosität der Probekörper zu erkennen. In Abbildung 6-3 ist erkennbar, dass Probekörper 75 in der oberen linken Ecke eine deutlich erhöhte Gesamtporosität aufweist. Abbildung 6-5 zeigt außerdem, dass Probekörper 75 neben einer erhöhten Gesamtporosität auch eine stärkere Streuung der Porosität der Einheitszellen als andere Probekörper in Druckjob 3 aufweist.

Druckjob 4 weist eine maximale Porosität bis ca. 16 % in den Einheitszellen der Probekörper auf. Wie auch schon bei Druckjob 3 streut die Porosität der Probekörper stärker als bei Druckjob 1 und 2. Wie bei Druckjob 3 ist der Probekörper 84, welcher an derselben Position wie Probekörper 75 gedruckt wurde, mit einer erhöhten Porosität und Streuung behaftet. Die manuelle Überprüfung der Defektanalyse des CT-Scans hat ergeben, dass die Werte nicht durch eine fehlerhafte Defektanalyse bedingt sind. An dieser Stelle liegt nahe, dass das Prozessergebnis durch die PBF-LB/M Anlage bedingt ist. Bei Betrachtung der Bauplatzform nach Abschluss des Druckjobs ist aufgefallen, dass viele Prozessnebenprodukte durch die Beschichterlippe im Bereich der Probekörper 75 und 84 abgelegt wurden. Dies könnte zur erhöhten Porosität und Streuung derselben beitragen. Dafür spricht auch, dass angrenzende Probekörper (Probekörper 70 und 76 sowie 83 und 89) eine erhöhte Porosität aufweisen.

In Abbildung 6-5 ist die Aufteilung der Probekörper in Trainings- und Testdaten für die Erstellung der Modelle dargestellt. Alle rot eingefärbten Probekörper sind Bestandteil des Testdatensatzes, während die blau eingefärbten Probekörper dem Trainingsdatensatz zugewiesen sind.

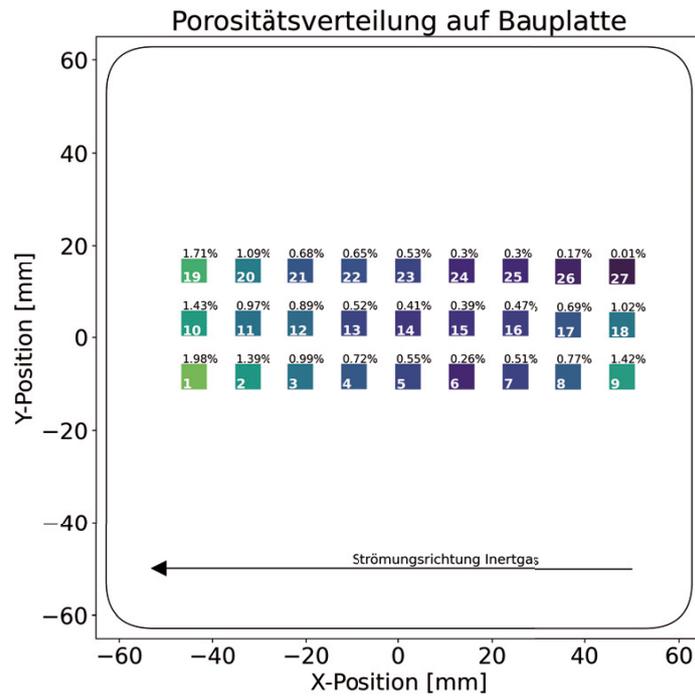


Abbildung 6-1: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 1

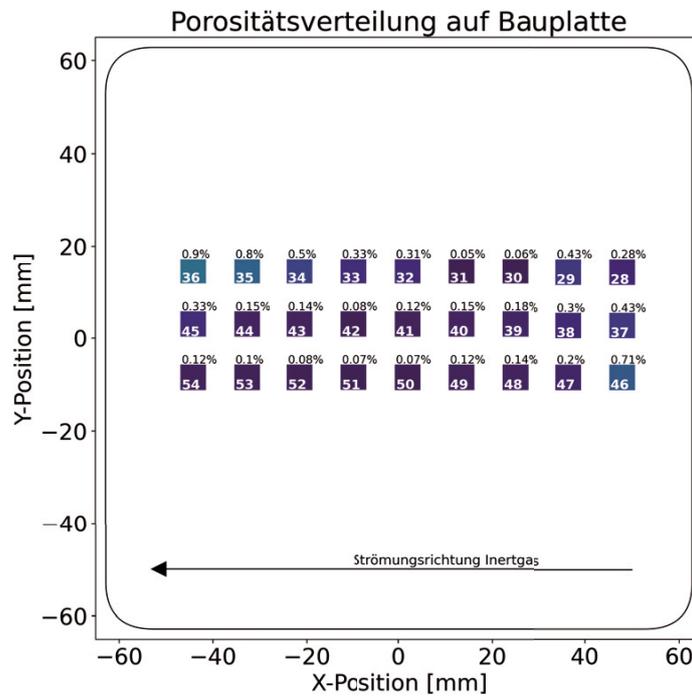


Abbildung 6-2: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 2

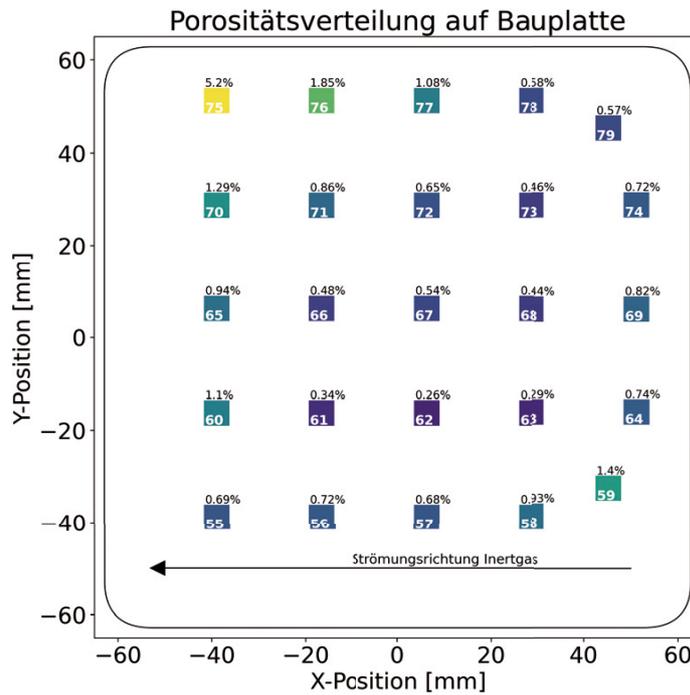


Abbildung 6-3: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 3

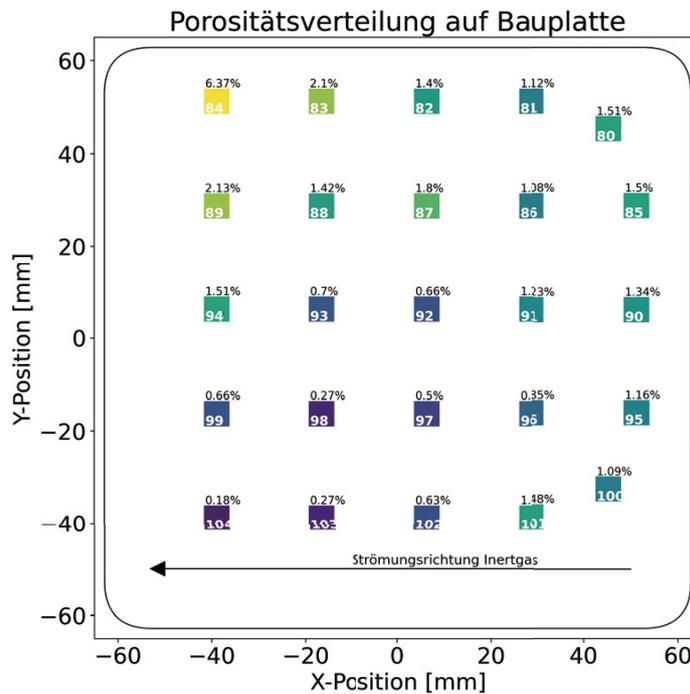


Abbildung 6-4: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 4

Aufteilung der Probekörper in Trainings-(blau) und Testdaten (rot) sowie Porosität in den Einheitszellen

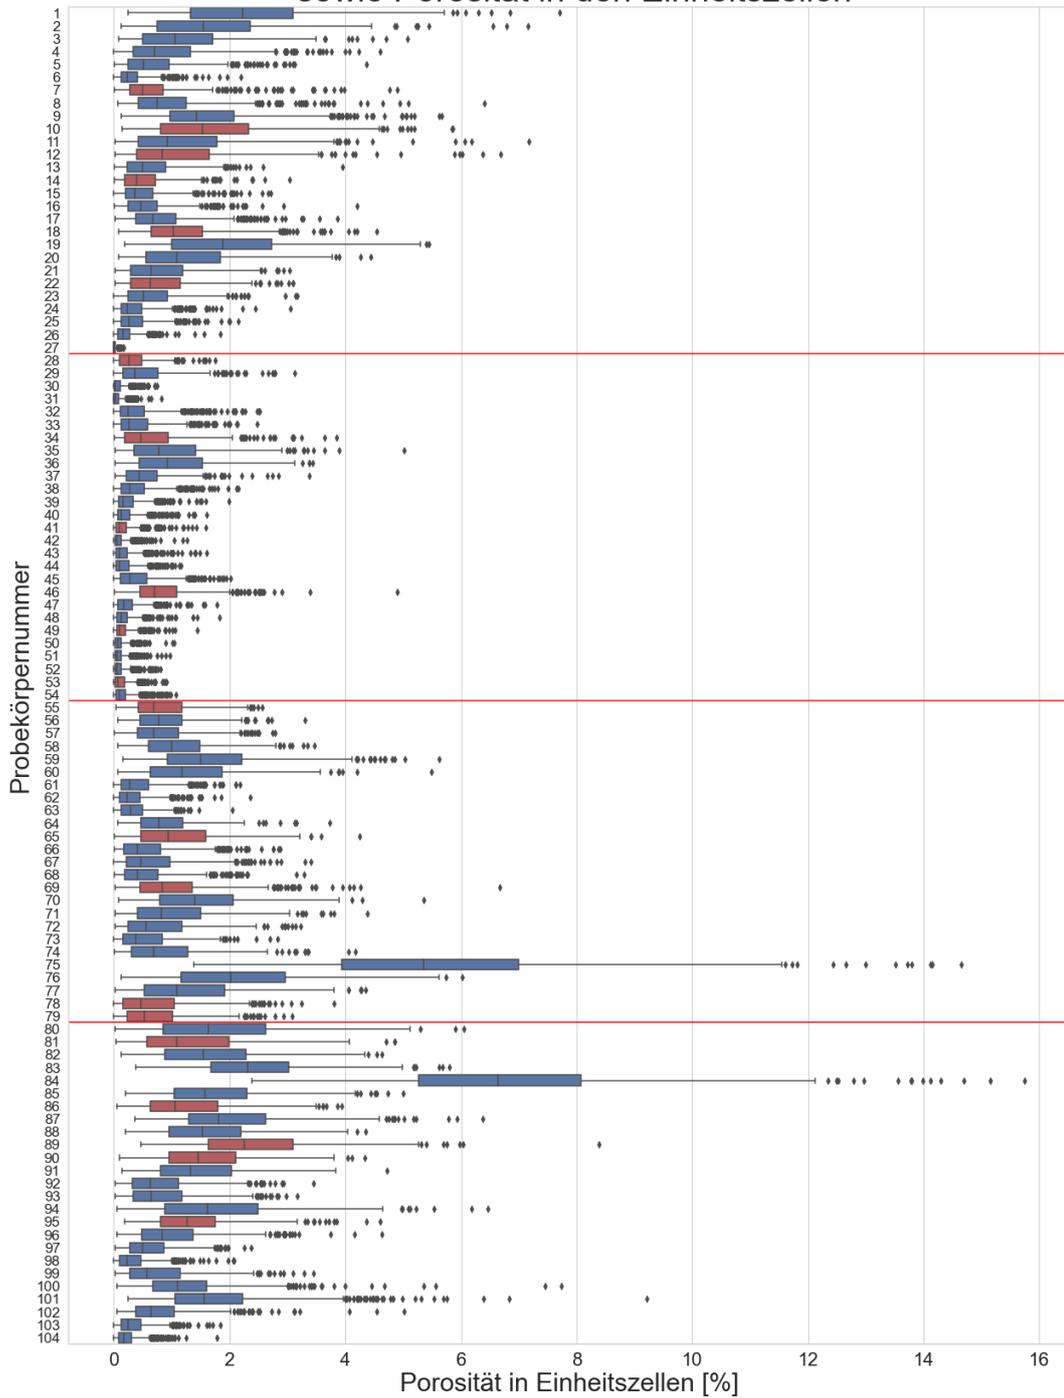


Abbildung 6-5: Boxplots der Porosität der Einheitszellen je Probekörper sowie Aufteilung der Probekörper in Trainingsdaten (blau) und Testdaten (rot)

6.2 Einfluss der Datenkomprimierung

Im Rahmen dieses Kapitels wird untersucht, ob das Vorgehen zur Datenkomprimierung, das in Kapitel 5.5.5.1 vorgestellt wurde, einen Einfluss auf die Modellperformance hat. Mit dieser Untersuchung soll vermieden werden, dass eine zu starke Komprimierung der Daten durchgeführt wird, bei welcher ein zu hoher Informationsverlust auftreten würde.

Dazu werden mit einer festgelegten Modellarchitektur drei Modelle mit unterschiedlichen Kompressionsniveaus trainiert:

1. Auf Basis des unkomprimierten Merkmals *FFT-Segment*
2. Auf Basis des Merkmals *FFT-Segment-Resized*
3. Auf Basis des Merkmals *FFT-Segment-Reduced*

Aufgrund der in Kapitel 5.5.5.1 dargelegten langen Trainingsdauer für den vollen Datensatz wird ein Modell mit weniger Parametern gewählt, sodass weniger Gewichte trainiert werden müssen. Dieses Modell ist nicht auf das Optimieren der Modellperformance ausgelegt, sondern auf den relativen Vergleich zwischen den drei Modellen auf Basis der drei Kompressionsniveaus. Neuronale Netze auf Basis eines MLP trainieren schneller als ein CNN, sodass für diese Betrachtung ein MLP verwendet wird. Als Metriken werden der F1-Score und der MCC betrachtet, da diese die relevanten Metriken bei der Klassifikation im Rahmen dieser Arbeit sind (vgl. Kapitel 5.5.7). In Tabelle 6-1 ist der Vergleich der Modellperformance der drei Modelle dargestellt.

Tabelle 6-1: Vergleich der Modellperformance zur Bewertung der angewandten Datenkomprimierung

Merkmal	F1-Score	MCC
<i>FFT-Segment</i>	0,561	0,355
<i>FFT-Segment-Resized</i>	0,553	0,323
<i>FFT-Segment-Reduced</i>	0,548	0,314

Es zeigt sich, dass die Modelle mit komprimierten Merkmalen keine wesentlich schlechtere Modellperformance aufweisen, als das Modell, welches auf dem nicht-komprimierten Datensatz trainiert wurde. Aus diesem Grund wird für die weitere Arbeit die Annahme getroffen, dass das Nutzen des komprimierten Datensatzes keinen negativen Einfluss auf die erreichbare Modellperformance hat. Das Merkmal *FFT-Segment-Resized* wird in der weiteren Auswertung nicht weiter betrachtet, da bei diesem die Ordinate bei geringen Segmentanzahlen (< 224) gestreckt wird (vgl. Kapitel 5.5.5.2). Bei der

FFT-Segment-Reduced findet keine Verzerrung der Ordinate mit der Anzahl der Segmente statt und die erreichte Modellperformance ist auf demselben Niveau. Aus diesen Gründen erfolgt die weitere Auswertung mit dem Merkmal *FFT-Segment-Reduced*.

Als zusätzliche Untersuchung werden zwei Negativuntersuchungen durchgeführt. Bei diesen wird erwartet, dass das Modell kein sinnvolles Lernverhalten mehr aufweist. Sollte das Modell wider Erwarten ein Lernverhalten aufweisen, so deutet dies auf eine fehlerhafte Auswertung hin.

Die erste Negativuntersuchung ist die deutlich erhöhte Komprimierung bei der Berechnung der *FFT-Segment-Reduced*. Als neuer Kompressionsfaktor wird der Faktor 1000 statt 100 (in der Folge als *FFT-Segment-Reduced-Max* bezeichnet) genutzt. Die Annahme an dieser Stelle ist, dass das Modell kein Lernverhalten mehr aufweist.

Die zweite Negativuntersuchung stellt das Anlernen eines Modells mit randomisiertem Label für die *FFT-Segment-Reduced* dar. In der Betrachtung der ROC-Kurve darf die AUC nur 0,5 betragen und die Kurve muss die Diagonale (vgl. Abbildung 2-17) darstellen. In diesem Fall weist das Modell kein Lernverhalten mehr auf.

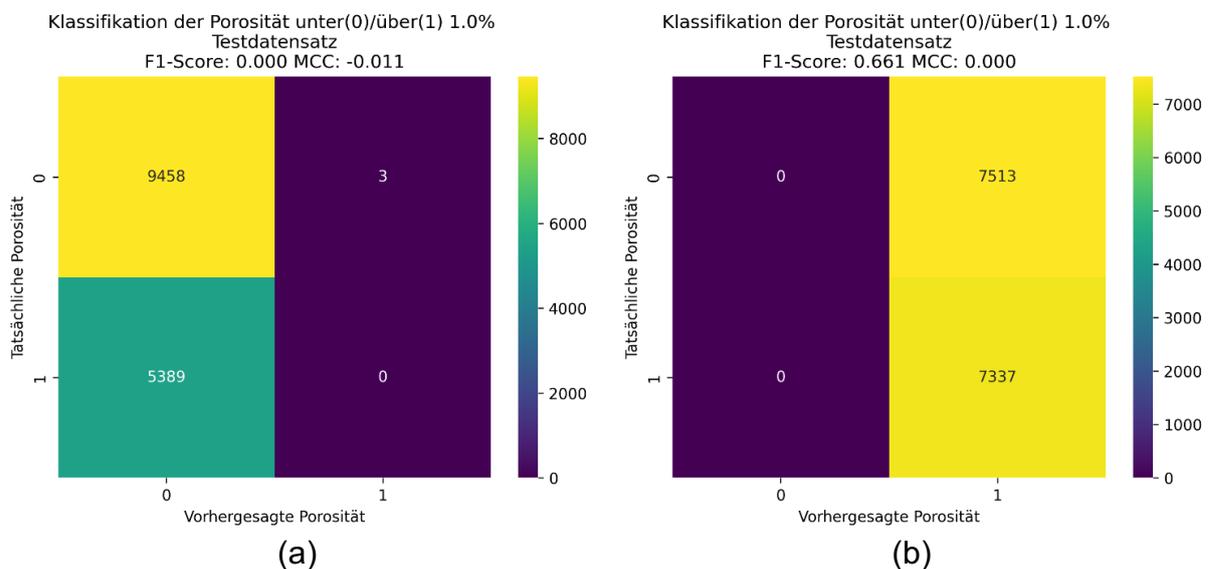


Abbildung 6-6: Konfusionsmatrix für (a) Modell mit maximaler Kompression und (b) mit randomisiertem Label

In Abbildung 6-6 sind die Konfusionsmatrizen für beide Fälle dargestellt. Es zeigt sich, dass das Modell kein Lernverhalten aufweist. Im Fall der maximalen Kompression (a) sagt das Modell fast ausschließlich Klasse 0 vorher. Für den Fall des randomisierten Labels (b) wird ausschließlich Klasse 1 vorhergesagt.

Abbildung 6-7 stellt die ROC-Kurve für das Modell mit randomisiertem Label dar. Wie theoretisch zu erwarten ist, stellt die ROC-Kurve die Diagonale dar und die AUC beträgt 0,5.

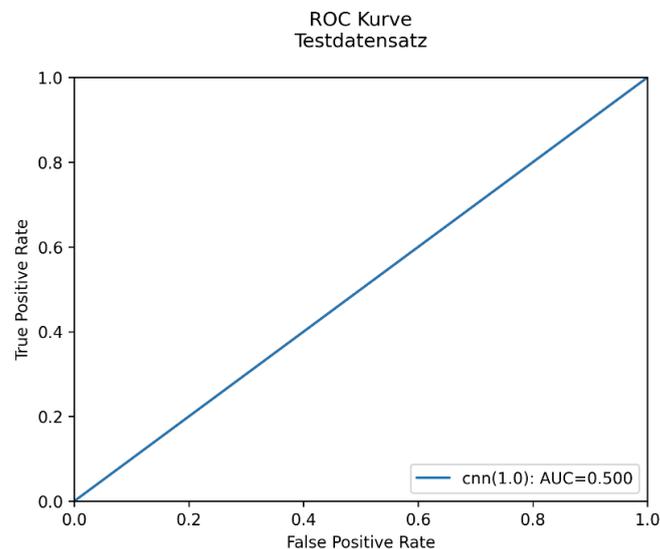


Abbildung 6-7: ROC-Kurve für Modell mit randomisiertem Label

Es zeigt sich, dass die Modelle in beiden Betrachtungen kein Lernverhalten mehr aufweisen. Dies stützt das Vorgehen, für die Datenanalyse im Rahmen der Arbeit das Merkmal *FFT-Segment-Reduced* zu benutzen.

6.3 Klassifikation der Zellporosität auf Gesamtdatensatz

Zunächst werden die Ergebnisse der Vorhersage der Zellporosität in Form einer Klassifikation vorgestellt. Das Kapitel ist zweigeteilt: in Kapitel 6.3.1 werden die Ergebnisse auf Basis der akustischen Körperschallsensorik vorgestellt, in Kapitel 6.3.2 erfolgt die Betrachtung auf Basis der optischen Sensordaten des Fotodiodenarrays.

6.3.1 Akustik: Körperschall

Die Auswertung der akustischen Körperschallsignale erfolgt wie in Kapitel 5.5.6 dargestellt mit künstlichen neuronalen Netzen. Als konkrete KNN-Arten werden zur Vorhersage MLPs und CNNs betrachtet. Die Aufteilung der Daten in Trainings- und Testdaten erfolgt nach der in Kapitel 5.5.5.3 vorgestellten Aufteilung. Die Modelltopologien mit der besten Performance nach Durchführung des in Kapitel 5.5.6 vorgestellten Grid Search sind in Tabelle 6-2 dargestellt.

Tabelle 6-2: Beste Modelltopologien zur Klassifikation der Zellporosität auf dem Gesamtdatensatz auf Basis der akustischen Körperschalldaten

Modellart	Topologie + Parameter	F1-Score	MCC
MLP	Aktivierungsfunktion: ReLU Schichten: [256, 128, 64, 32] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,001 Solver: Adam Scaler: StandardScaler	0,583	0,402
CNN	Aktivierungsfunktion: ReLU Schichten: [256, 128, 64, 32] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,001 Solver: Adam Scaler: StandardScaler	0,690	0,527

Anhand der Metriken zur Bewertung der Modellperformance in Tabelle 6-2 ist erkennbar, dass CNN-basierte Modelle eine bessere Performance gegenüber einfacheren MLP-basierten Modellen erreichen. Sowohl der F1-Score als auch der MCC sind höher. Beim Training zeigt sich, dass die CNN-Modelle länger im Training brauchen: eine Trainingsepoche dauert auf der verwendeten Hardware der DGX-Station etwa 73 Sekunden, während MLP-Modelle eine Epoche in etwa vier Sekunden abgeschlossen haben.

In Abbildung 6-8 sind die Konfusionsmatrizen von MLP und CNN dargestellt. In Summe wurden im Testdatensatz 14.850 Einheitszellen klassifiziert. Davon sind 9.514 mit einer Porosität unter 1 % und 5.336 mit einer Porosität über 1 %. Beide Modelle sind ähnlich gut in der Erkennung von Einheitszellen mit einer Porosität unter 1 %. Von den 9.514 Einheitszellen werden beim MLP 8.188 sowie beim CNN 8.108 Einheitszellen korrekt unter 1 % Porosität klassifiziert. Von 5.336 Einheitszellen über 1 % werden beim MLP 2.739 und beim CNN 3.550 Einheitszellen korrekt klassifiziert. An dieser Stelle weist das CNN eine bessere Performance als das MLP auf. Bei beiden Modellen ist die Anzahl der Einheitszellen mit einer Porosität unter 1 %, welche aber fälschlicherweise vom Modell als über 1 % klassifiziert werden, mit 1.326 (MLP) bzw. 1.353 (CNN) Einheits-

zellen ähnlich groß. Die Unterschiede in der Modellperformance kommen aus Einheitszellen mit einer Porosität über 1 %, welche fälschlicherweise als unter 1 % Porosität klassifiziert werden. Beim MLP tritt dieser Fall 2.597-mal auf, beim CNN 1.839-mal.

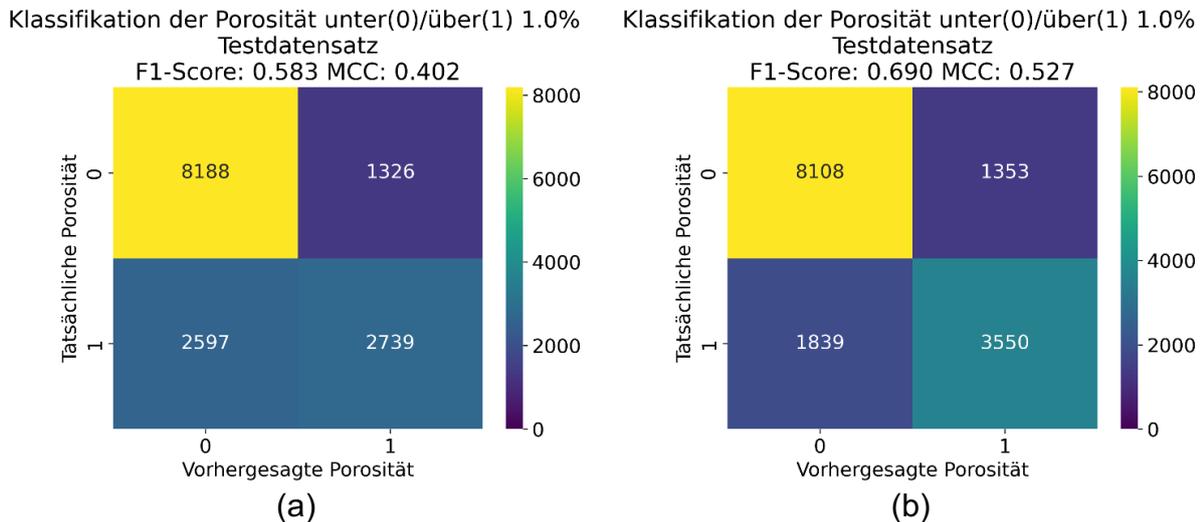


Abbildung 6-8: Konfusionsmatrizen bei der Porositätsklassifikation durch (a) MLP und (b) CNN für die akustischen Körperschalldaten

In Abbildung 6-9 sind die ROC-Kurven für beide Modelle dargestellt. Die Kurve des CNN weist zu Beginn einen deutlich steileren Anstieg als die Kurve des MLP auf, was eine stärkere Trennschärfe des Modells aufzeigt. Die AUC-Werte der beiden Modelle liegen mit 0,795 für das MLP und 0,857 für das CNN signifikant über einem rein zufällig schätzenden Modell.

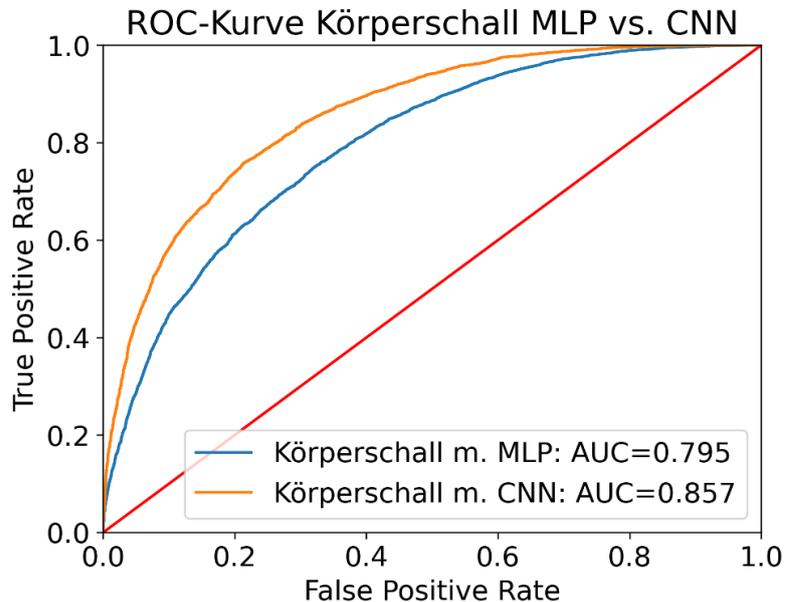


Abbildung 6-9: ROC-Kurven der Modelle zur Klassifikation der Einheitszellenporosität auf Basis der akustischen Körperschalldaten

Neben der Darstellung der Modellergebnisse in Form von Konfusionsmatrizen und ROC-Kurven, welche die Modellperformance quantitativ bewerten, wird nachfolgend eine grafische qualitative Bewertung der Modellergebnisse vorgenommen. Dazu wird die Region-of-Interest der Probekörper, in welcher die Defektanalyse durchgeführt wurde (vgl. Kapitel 5.4.2.3), in einer Schnittansicht für jede Voxelebene dargestellt. In Abbildung 6-10 sind die Schnittansichten von drei exemplarisch ausgewählten Probekörpern dargestellt. Die obere Reihe der Schnittansichten ist die Darstellung auf Basis der tatsächlichen Porositätsklasse, welche durch die CT-Referenzmessung bestimmt wurde. Für jede Schnittansicht ist darunter die Vorhersage des Modells auf Basis der akustischen Körperschalldaten abgebildet. In allen Probekörpern sind fehlerhafte Vorhersagen erkennbar. In Abbildung 6-10 (a) ist Probekörper 10 dargestellt. Der Probekörper weist in den ersten vier Schnittansichten eine hohe Anzahl an Einheitszellen über 1 % Porosität auf, wobei der rechte Rand der Probekörper einen Bereich mit überwiegend unter 1 % Porosität liegenden Einheitszellen darstellt. Die fünfte Schnittansicht stellt einen gemischten Bereich dar. Das Modell ist in der Lage, die grundlegende Charakteristik des Probekörpers vorherzusagen. In der Vorhersage ist sowohl der rechte Rand in den Schnittansichten eins bis vier erkennbar als auch die Charakteristik der fünften Schnittansicht. Abbildung 6-10 (b) zeigt Probekörper 41. Dieser Probekörper weist eine fast durchgängig unter 1 % liegende Porosität in den Einheitszellen auf. Das trainierte Modell ist in der Lage, solche Probekörper mit wenigen Fehlklassifikationen

vorherzusagen. In Abbildung 6-10 (c) ist Probekörper 89 dargestellt. Dieser Probekörper stellt einen Probekörper mit einer fast durchgängig über 1 % liegenden Porosität dar. Das Modell ist wie auch schon im Fall (b) in der Lage, auch solche Probekörper mit wenigen Fehlklassifikationen vorherzusagen.

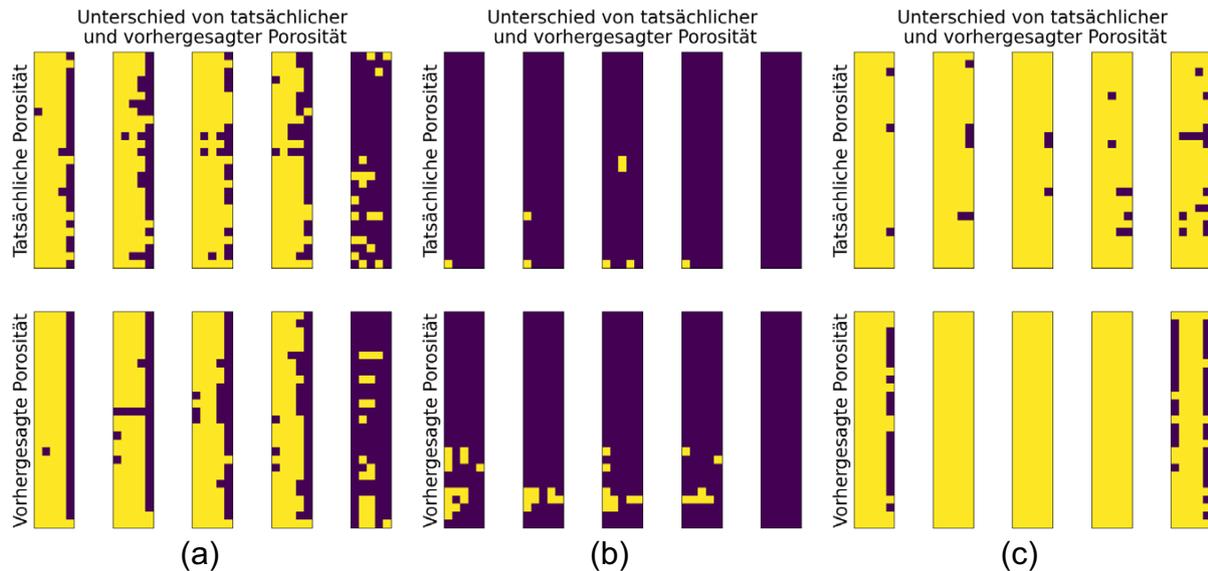


Abbildung 6-10: Schnittdiagramme zum qualitativen Vergleich der Vorhersagequalität der Porositätsklassen mittels CNN - a) Probekörper 10, b) Probekörper 41 und c) Probekörper 89

In Abbildung 6-11 sind weiterhin exemplarisch die Probekörper 7 und 69 als Schnittdiagramme dargestellt. In diesen beiden Fällen sagt das Modell überwiegend Porositätsklassen unter 1 % vorher, während in beiden Bauteilen ein nicht zu vernachlässigender Anteil an Einheitszellen mit einer Porosität über 1 % vorhanden ist. Dies legt nahe, dass die in der Konfusionsmatrix erkennbaren Fehlklassifikationen vor allem probekörper-spezifisch auftreten und nicht randomisiert in allen Bauteilen vorhanden sind.

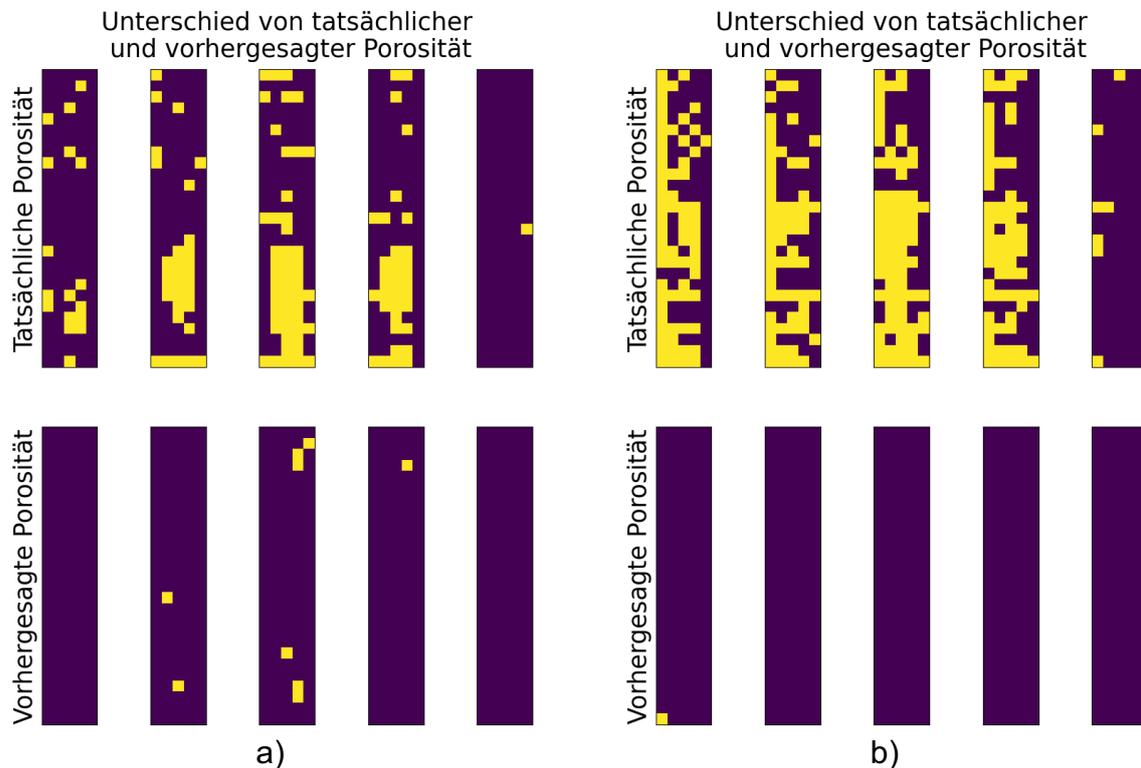


Abbildung 6-11: Schnittdiagramme der Probekörper mit nicht zufriedenstellender Modellperformance – a) Probekörper 7 und b) Probekörper 69

Neben der Klassifikation mit einer Klassengrenze von 1 % Porosität wird als weitere Untersuchung die Klassifikation mit variablen Klassengrenzen im Intervall von $[0,25; 2]$ % Porosität in 0,25 %-Schritten betrachtet. Das Verschieben der Klassengrenze verändert die Unausgeglichenheit des Datensatzes. Bei einer Klassengrenze von etwa 0,75 % Zellporosität sind die Klassen etwa ausgeglichen. Unterhalb davon verschiebt sich die Unausgeglichenheit zu Ungunsten der Klasse 0. Oberhalb von 0,75 % Zellporosität ist die Unausgeglichenheit zu Ungunsten von Klasse 1. In Abbildung 6-12 ist die Verteilung der Klassen bei veränderter Klassengrenze dargestellt.

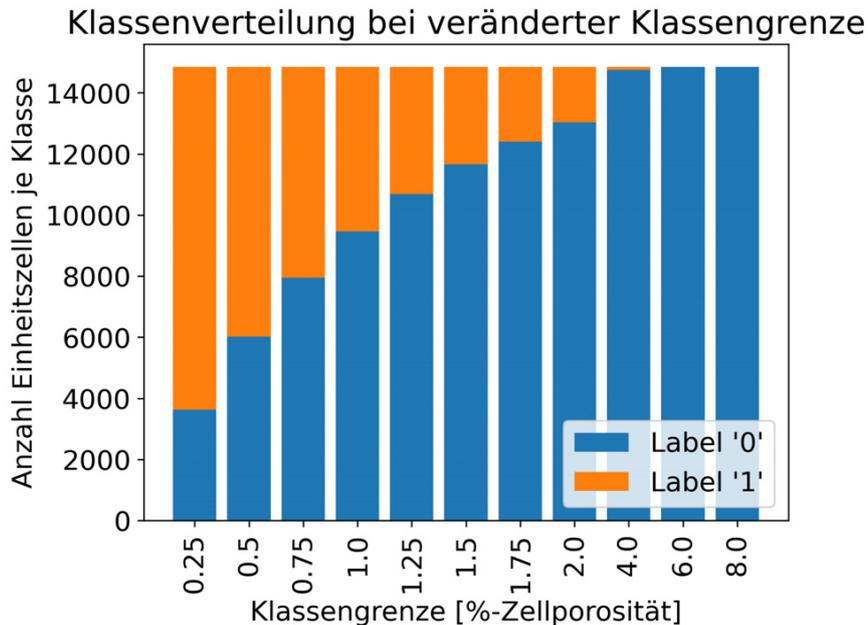


Abbildung 6-12: Veränderung der Klassenverteilung bei veränderter Klassengrenze

Für die angepassten Klassengrenzen werden erneut Modelle trainiert. Da das CNN besser als das MLP in der vorigen Untersuchung abgeschnitten hat, wird in der Folge die Betrachtung des CNN fokussiert. In Tabelle 6-3 ist die Performance des CNN für die verschiedenen Klassengrenzen dargestellt. Es zeigt sich, dass der F1-Score mit zunehmender Klassengrenze kontinuierlich kleiner wird, während der MCC bis etwa 1.25 % im Intervall von 0,51 bis 0,54 bleibt. Ab der Klassengrenze bei 1,5 % fällt auch der MCC kontinuierlich ab. Die Vorhersage von einer hohen Zellporosität ab 4 % funktioniert mit den aktuellen Modellen nicht, was sich an F1-Score und MCC von $\leq 0,1$ zeigt. Allerdings sind bei dieser Klassengrenze die Klassen auch stark unausgeglichen.

Tabelle 6-3: Modellperformance des CNN bei veränderter Klassengrenzen zwischen 0,25 und 8 % Porosität der Einheitszellen

Klassen- grenze	F1-Score	MCC	Bemerkung
0,25 %	0,874	0,543	
0,5 %	0,797	0,547	
0,75 %	0,731	0,526	Etwa ausgeglichene Klassen: 0,535:0,465
1,0 %	0,69	0,527	
1,25 %	0,641	0,511	
1,5 %	0,584	0,477	
1,75 %	0,535	0,458	
2,0 %	0,495	0,426	
4,0 %	0,105	0,105	Keine sinnvolle Vorhersage
6,0 %	0,0	0,0	Keine sinnvolle Vorhersage
8,0 %	0,0	0,0	Keine sinnvolle Vorhersage

In Abbildung 6-13 ist der Verlauf von F1-Score und MCC bei veränderter Klassengrenze grafisch dargestellt. Dabei ist beim F1-Score eine stärkere Abnahme des Wertes in Abhängigkeit der Klassengrenze von 0,25 bis 2 % feststellbar als beim MCC. Dies ist in der veränderten Klassenverteilung in Abhängigkeit der Klassengrenze begründet (vgl. Abbildung 6-12).

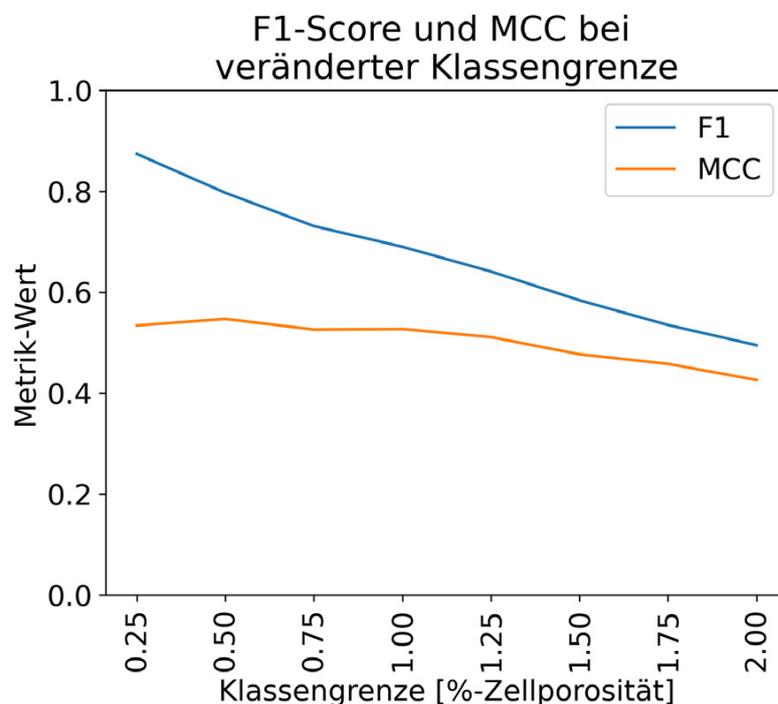


Abbildung 6-13: Verlauf von F1-Score und MCC bei veränderter Klassengrenze

In Abbildung 6-14 sind die ROC-Kurven für die trainierten Modelle mit den jeweiligen Klassengrenzen dargestellt. Für die Modelle mit 6 und 8 % ist die ROC-Kurve nicht mehr sinnvoll darstellbar, da die Klassen zu unausgeglichen sind. Es zeigt sich, dass das Modell mit 0,25 % Porosität als Klassengrenze die beste ROC-Kurve der Modelle aufweist.

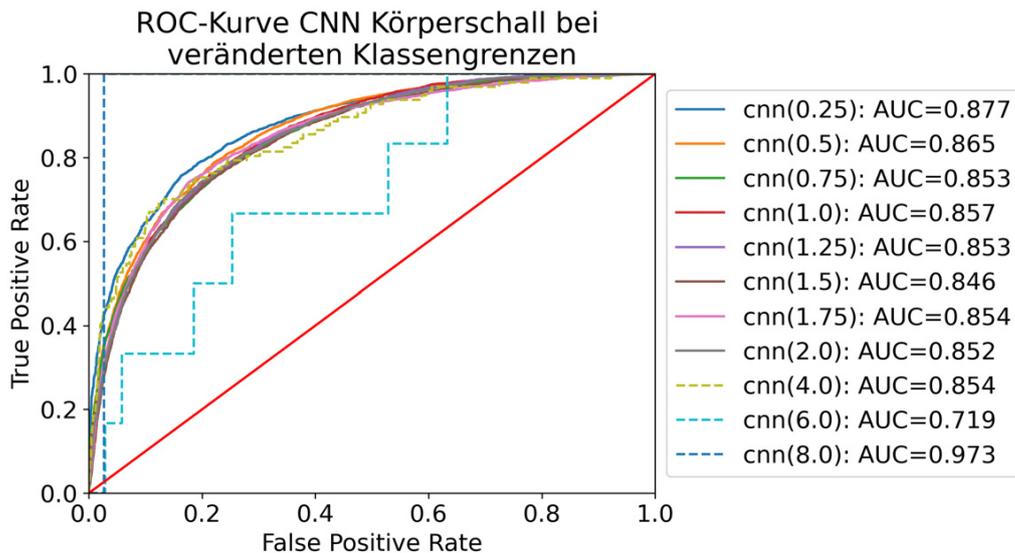


Abbildung 6-14: ROC-Kurve für CNN-Modelle mit veränderten Klassengrenzen

Abschließend wird der Schwellwert zur Klassifikation auf Basis der ROC-Kurve angepasst: dazu wird das CNN-Modell aus Tabelle 6-2 betrachtet. Anhand der ROC-Kurve kann der Schwellwert für die Modellvorhersage in der Ausgabeschicht von 0,5 auf 0,308 verschoben werden. In Abbildung 6-15 sind die beiden Konfusionsmatrizen für das nicht-optimierte und das ROC-optimierte Modell dargestellt. Es zeigt sich, dass der F1-Score leicht ansteigt: von 0,69 auf 0,708 bei nahezu gleichem MCC von 0,527 und 0,525. Betrachtet man die Anzahl der Einheitszellen mit einem Label für die tatsächliche Porosität von 1, welche aber fälschlicherweise als 0 klassifiziert werden (Fehler 2. Art), so ist erkennbar, dass der Wert von 1839 auf 1240 fällt. Beim ROC-optimierten Modell ist jedoch auch eine Zunahme der Klassifikationen von Einheitszellen, welche eine tatsächliche Porosität von 0 haben aber als 1 vorhergesagt werden (Fehler 1. Art), feststellbar: von 1353 auf 2176.

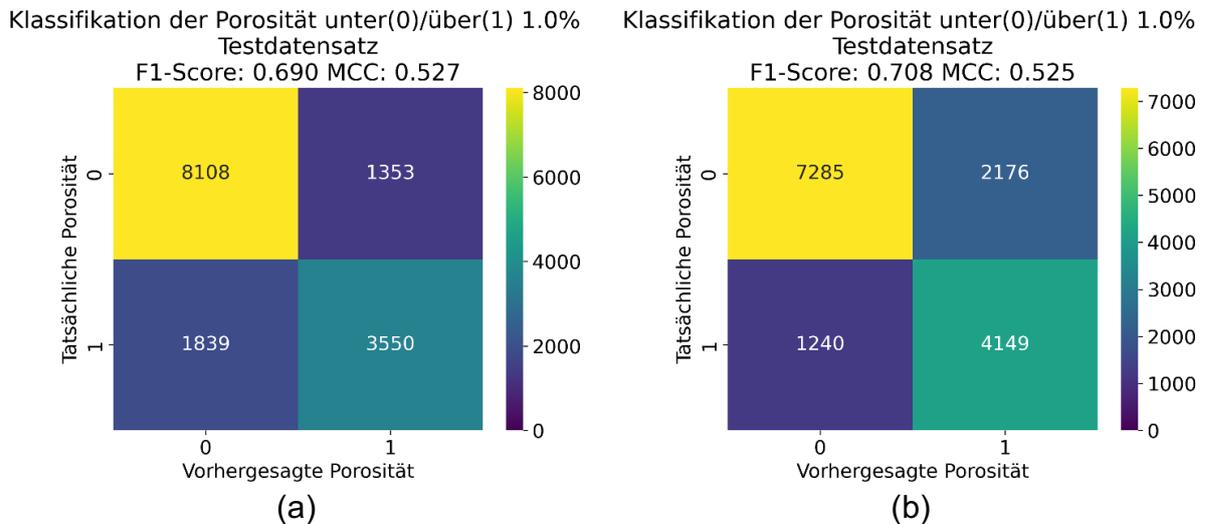


Abbildung 6-15: Vergleich der Konfusionsmatrizen von (a) normalem Modell und (b) ROC-optimiertem Modell

Für den Einsatz ist der Industrie kann eine solche Verschiebung der Erkennungsraten sinnvoll sein, falls das Nichtentdecken von porositätsbehafteten Bereichen mit größeren Kosten verbunden ist als ein möglicherweise erhöhter Ausschuss.

6.3.2 Optik: Fotodiodenarray

Nach Betrachtung der Klassifikationsergebnisse für die akustischen Körperschalldaten erfolgt die analoge Betrachtung der Klassifikationsergebnisse auf Basis der optischen Daten des Fotodiodenarrays. Als Modelle werden dabei ebenfalls MLPs und CNNs betrachtet, um eine Vergleichbarkeit zu den Modellen der akustischen Körperschalldaten aus dem vorherigen Kapitel zu haben.

Zunächst wird betrachtet, ob eine kombinierte oder getrennte Betrachtung der drei Kanäle des Fotodiodenarrays erfolgen soll. Dazu werden jeweils Modelle auf CNN-Basis für jeden einzelnen Kanal sowie für den Gesamtdatensatz erstellt, da CNN-basierte Modelle bei der Betrachtung der akustischen Körperschalldaten die beste Modellperformance aufgewiesen haben. Als Klassengrenze wird wie auch bei der akustischen Körperschallmessung zunächst 1 % Zellporosität genutzt.

In Tabelle 6-4 sind F1-Score und MCC für die jeweiligen Modelle der einzelnen Kanäle sowie für die kombinierte Betrachtung dargestellt. Auf Basis von F1-Score und MCC ist das Modell für den Datenkanal des sichtbaren Spektrums das schlechteste Modell. Die Modelle von Laser und IR haben einen vergleichbaren F1-Score, jedoch ist der MCC für den Kanal der Infrarot-Daten mit 0,395 besser als für die Laser-Daten mit 0,353. Es

zeigt sich, dass die Modelle der einzelnen Kanäle jeweils von F1-Score und MCC schlechter sind als das kombinierte Modell der drei Kanäle. Aus diesem Grund werden nachfolgend alle drei Datenkanäle kombiniert betrachtet.

Tabelle 6-4: F1-Score und MCC für getrennte und kombinierte Betrachtung der drei Kanäle des Fotodiodenarrays mittels CNN

Kanal	F1-Score	MCC
Sichtbar	0,497	0,353
Laser	0,554	0,353
IR	0,564	0,395
Sichtbar + Laser + IR	0,630	0,471

In der finalen Betrachtung wird zur Vergleichbarkeit der Auswertung mit den akustischen Daten auch noch ein MLP herangezogen. In Tabelle 6-5 sind die besten Modelle für jeweils MLP und CNN auf Basis der optischen Daten dargestellt. Wie auch schon bei den akustischen Körperschalldaten sind Modelle auf CNN-Basis den MLP-Modellen von der Modellperformance überlegen. Der F1-Score vom CNN liegt mit 0,63 höher als der F1-Score von 0,594 des MLP. Das gleiche Verhalten ist auch beim MCC mit 0,471 (CNN) zu 0,406 (MLP) zu beobachten.

Tabelle 6-5: Beste Modelltopologien zur Klassifikation der Zellporosität auf dem Gesamtdatensatz auf Basis der optischen Daten des Fotodiodenarrays

Modellart	Topologie + Parameter	F1-Score	MCC
MLP	Aktivierungsfunktion: ReLU Schichten: [256, 128, 64, 32] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,001 Solver: Adam Scaler: StandardScaler	0,594	0,406
CNN	Aktivierungsfunktion: ReLU Schichten: [256, 128, 64, 32] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,001 Solver: Adam Scaler: StandardScaler	0,630	0,471

In Abbildung 6-16 sind die Konfusionsmatrizen der beiden Modellarten dargestellt. Es ist festzustellen, dass die Konfusionsmatrizen beider Modelle ähnlich aussehen. Das MLP weist verstärkt Einheitszellen fälschlicherweise das Label > 1 % Porosität zu, während das CNN hier eine bessere Trennschärfe aufweist.

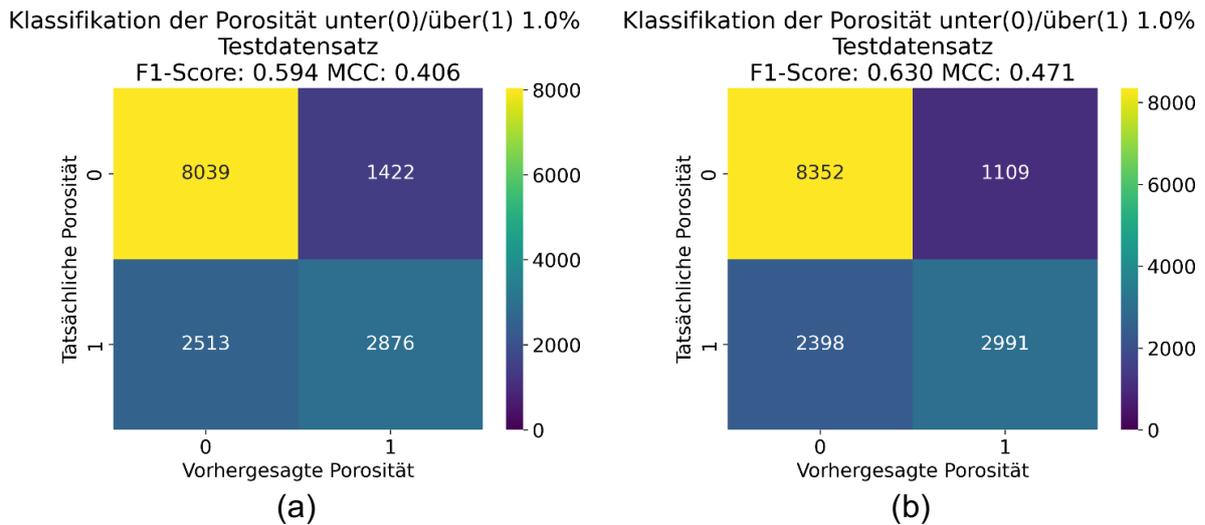


Abbildung 6-16: Konfusionsmatrizen bei der Porositätsklassifikation durch (a) MLP und (b) CNN für die optischen Daten

Bei Betrachtung der ROC-Kurven der beiden Modelle in Abbildung 6-17 zeigt sich ebenfalls, dass das CNN eine bessere Trennschärfe als das MLP aufweist.

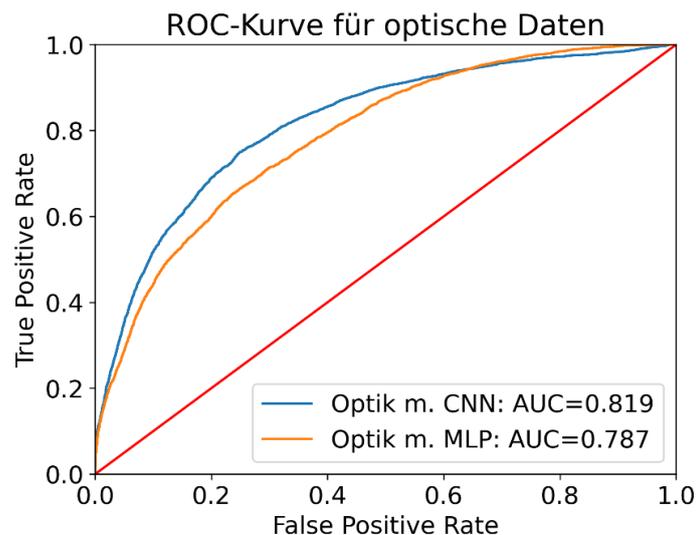


Abbildung 6-17: ROC-Kurven der Modelle zur Klassifikation der Einheitszellenporosität auf Basis der optischen Daten

In Abbildung 6-18 ist in (a) exemplarisch die Schnittansicht von Probekörper 12 dargestellt. Im qualitativen Vergleich von vorhergesagter und tatsächlicher Porosität ist erkennbar, dass die für den Probekörper typische Porositätsverteilung vom Modell erkannt und korrekt vorhergesagt wird. In Abbildung 6-18 (b) ist dahingegen exemplarisch Probekörper 22 dargestellt, bei dem das Modell keine zufriedenstellende Vorhersage vornimmt.

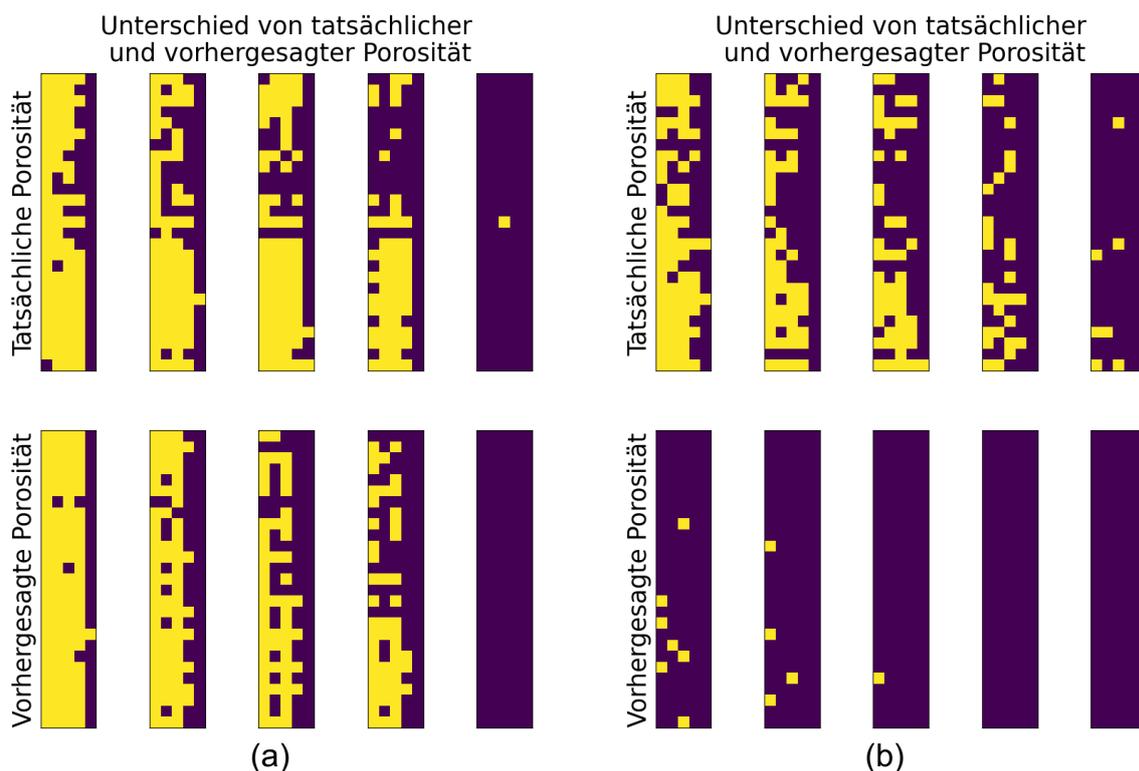


Abbildung 6-18: Schnittansichten zum qualitativen Vergleich der Vorhersagequalität der Porositätsklassen mittels CNN für optische Daten – a) Probekörper 12 und b) Probekörper 22

6.3.3 Vergleich von Körperschall und Fotodiodenarray

Bei der Betrachtung beider Sensoriken im Anwendungsfall der Klassifikation zeigt sich, dass die Modelle auf Basis der akustischen Körperschalldaten besser abschneiden. Das CNN auf Basis der akustischen Daten erreicht einen F1-Score von 0,690 sowie einen MCC von 0,527. Bei den Modellen für die optischen Daten ist die CNN-Topologie ebenfalls die beste Topologie, aber erreicht lediglich einen F1-Score von 0,63 und einen MCC von 0,471. Dies sind niedrigere Werte als beim CNN für die akustischen Daten. Betrachtet man jedoch die Modellperformance des MLP für die akustischen Daten, so

schneidet dies mit einem F1-Score von 0,583 und einem MCC von 0,402 schlechter als das CNN für die optischen Daten ab. Das MLP für die optischen Daten ist mit einem F1-Score von 0,594 und einem MCC von 0,406 nur unwesentlich schlechter. Die Auswertung der akustischen Daten hat im vorliegenden Fall eine bessere Performance als die optischen Daten. Dies zeigt sich auch in den in Abbildung 6-19 dargestellten ROC-Kurven der Modelle. Da die Modelle auf Basis der optischen Daten eine schlechtere Modellperformance als die Modelle auf Basis akustischen Körperschalldaten zeigen, wird in Kapitel 6.3.2 auf die Darstellung der Schnittansichten verzichtet. Die vollständigen Schnittansichten werden im Anhang A2 dargestellt.

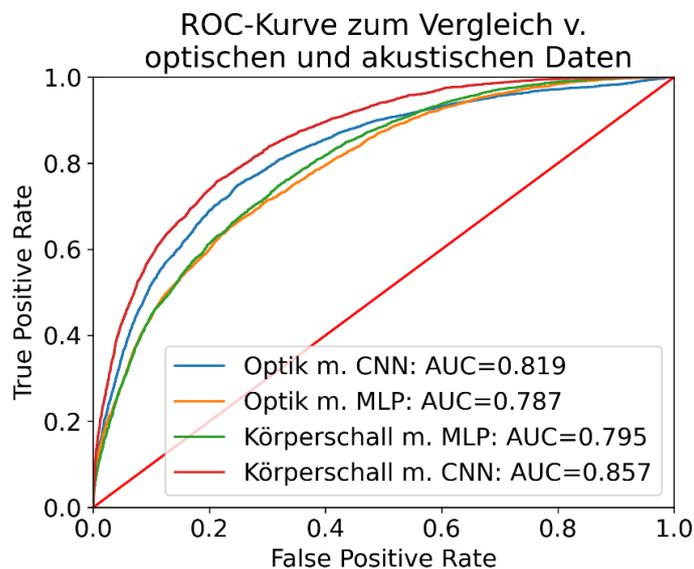


Abbildung 6-19: ROC-Kurven zum Vergleich von MLP und CNN für optische Daten und Körperschalldaten

6.4 Regression der Zellporosität auf Gesamtdatensatz

Nach der Darstellung der Ergebnisse der Klassifikation werden die Ergebnisse für die Regression der Zellporosität vorgestellt. Wie auch schon das vorherige Kapitel, ist dieses Kapitel auf Basis der zugrundeliegenden Sensorik zweigeteilt (Körperschall in Kapitel 6.4.1 und Fotodiodenarray in Kapitel 6.4.2).

6.4.1 Akustik: Körperschall

Als Modellarten werden, wie auch schon bei der Klassifikation, MLPs und CNNs betrachtet. In Tabelle 6-6 sind die Kennzahlen der besten Modellperformance sowie die

optimale Topologie der Modelle nach Durchführung eines Grid Search zur Parameteroptimierung dargestellt. Im direkten Vergleich zur Klassifikation (vgl. Tabelle 6-2) fällt auf, dass für die Aufgabe der Regression komplexere Netze bessere Ergebnisse liefern, da die erste Schicht jeweils aus 512 Neuronen aufgebaut ist und nicht aus 256, wie bei der Klassifikation.

Tabelle 6-6: Beste Modelltopologien zur Regression der Zellporosität auf dem Gesamtdatensatz auf Basis der Körperschalldaten

Modellart	Topologie	R²	RMSE
MLP	Aktivierungsfunktion: ReLU Schichten: [512, 256, 128, 64] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,001 Solver: Adam Scaler: StandardScaler	0,202	0,782
CNN	Aktivierungsfunktion: ReLU Schichten: [512, 256, 128, 64] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,001 Solver: Adam Scaler: StandardScaler	0,392	0,682

In Abbildung 6-20 ist die vorhergesagte Porosität gegen die tatsächliche Porosität der beiden Modelle aufgetragen. Im Falle einer perfekten Regression müssten alle Punkte auf der orangen Winkelhalbierenden liegen. In roter Farbe ist in den Abbildungen jeweils die lineare Ausgleichsgerade aller Datenpunkte eingezeichnet. Liegt diese unterhalb der Winkelhalbierenden, wird in diesem Bereich die Porosität generell unterschätzt. Liegt sie oberhalb der Winkelhalbierenden, wird die Porosität überschätzt. Es ist erkennbar, dass die Modelle bei niedriger Porosität bis ca. 1 % die Porosität überschätzen und vor allem höhere Porosität zunehmend unterschätzen. Bei der Vorhersage mittels CNN fällt weiterhin auf, dass keine Vorhersage unter einem gewissen Schwellwert vom Modell gemacht wird. Ursache hierfür könnte in der gewählten Aktivierungsfunktion des CNN liegen. Durch die Nutzung der ReLU-Aktivierungsfunktion erfolgt unterhalb des Nullwertes keine Aktivierung, sodass das beobachtete Verhalten

darin begründet sein könnte. Dieses Verhalten ist beim MLP nicht zu beobachten, obwohl die gleiche Aktivierungsfunktion verwendet wird. Eine endgültige Bestimmung der Ursache konnte nicht erfolgen. Bei beiden Modellen ist festzustellen, dass insgesamt eine Unterschätzung der Zellporosität stattfindet. Dies zeigt sich an beiden Ausgleichsgeraden, welche eine geringere Steigung als die Winkelhalbierende aufweisen.

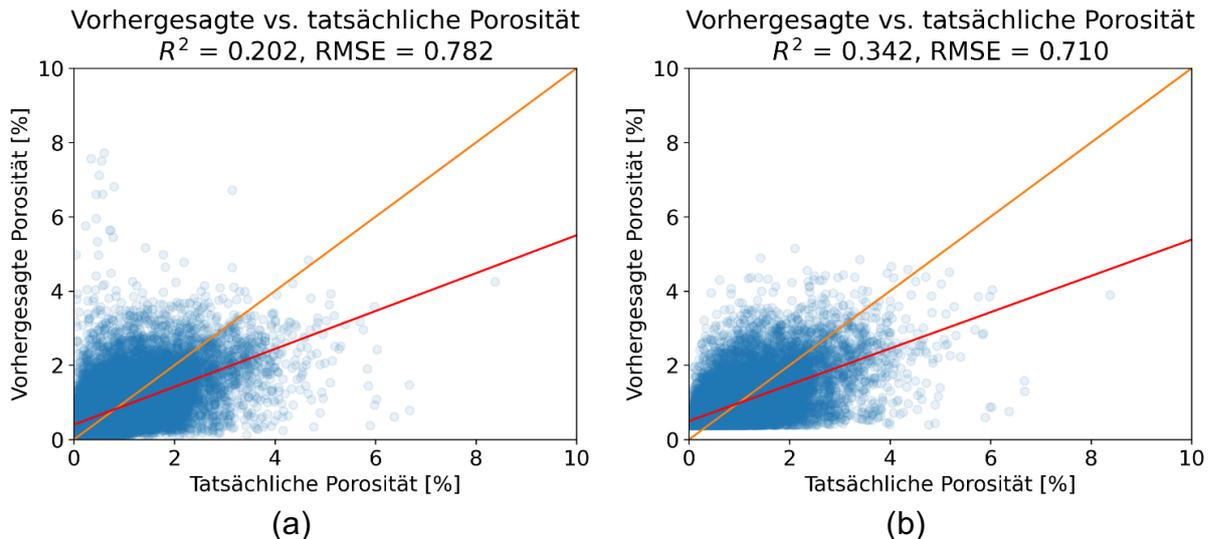


Abbildung 6-20: Vorhergesagte vs. Tatsächliche Porosität bei der Porositätsregression durch (a) MLP und (b) CNN auf Basis der akustischen Körperschalldaten

Wie auch schon bei der Klassifikation werden in Abbildung 6-21 exemplarische Schnittansichten der Probekörper mit der tatsächlichen Porosität sowie vorhergesagten Porosität dargestellt. In Abbildung 6-21 (a) ist Probekörper 86 dargestellt. Probekörper 86 hat vor allem in den ersten drei Schnittansichten erhöhte Porositätswerte. Das Modell ist in der Lage, diesen Trend abzubilden. Abbildung 6-21 (b) zeigt die Schnittansicht von Probekörper 7. Dieser hat in der mittleren Schnittansicht einen prägnanten Bereich mit erhöhter Porosität. Es fällt in der Vorhersage auf, dass dieser Bereich nicht korrekt vom Modell erkannt wird. In Abbildung 6-21 (c) wird Probekörper 18 betrachtet. Probekörper 18 weist in den Schnittansichten eine durchgängigere porösere Struktur auf. Das Modell ist nicht in der Lage, diese Tatsache vorherzusagen. Wie auch schon bei der Klassifikation zeigt sich in Summe, dass es Probekörper gibt, bei denen die Modelle zufriedenstellende Vorhersagen erstellen, jedoch auch Probekörper existieren, bei denen die Vorhersage noch nicht zufriedenstellend funktioniert. Die Ursache für dieses Verhalten der Modelle ist nicht bekannt. Aufgrund der fehlenden Nachvollziehbarkeit der Entscheidungsfindung von künstlichen neuronalen Netzen ist hier die Ursachenforschung erschwert. Die Nutzung anderer Modellarten kann potenziell Abhilfe schaffen.

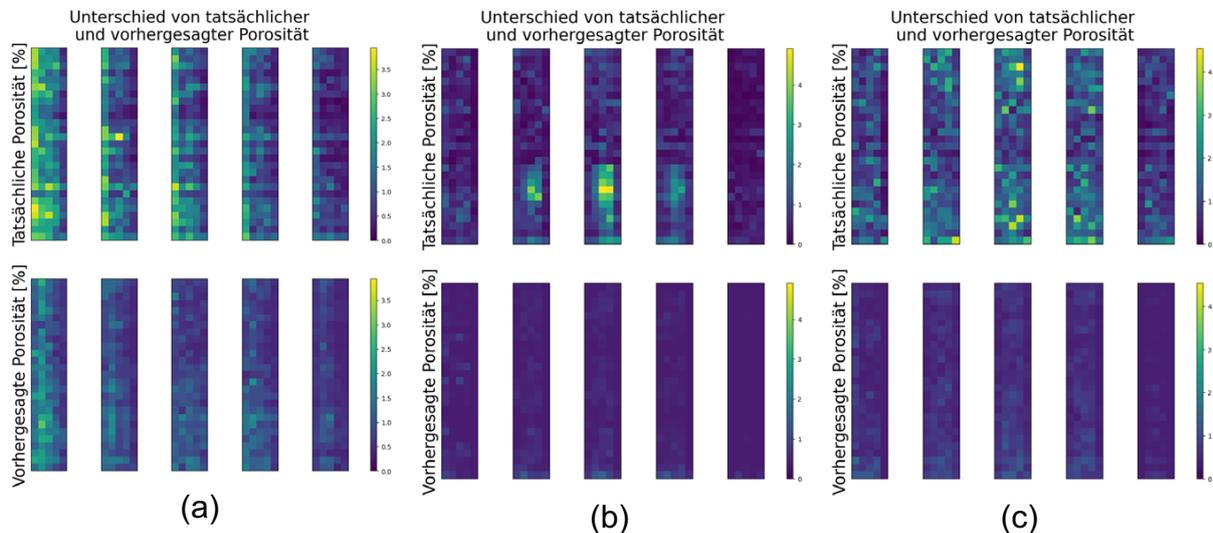


Abbildung 6-21: Schnittdiagramme zum qualitativen Vergleich der Vorhersagequalität der Porositätsregression mittels CNN für akustische Körperschalldaten – a) Probekörper 86, b) Probekörper 7 und c) Probekörper 18

6.4.2 Optik: Fotodiodenarray

Nach Betrachtung der Regressionsergebnisse auf Basis der akustischen Körperschalldaten werden die Regressionsergebnisse auf Basis der optischen Daten des Fotodiodenarrays betrachtet. In Kapitel 6.3.2 wurde bereits gezeigt, dass die kombinierte Auswertung der drei Kanäle des Fotodiodenarrays bessere Ergebnisse liefert als die einzelne Auswertung. Aus diesem Grund wird bei der Regression ebenfalls die kombinierte Auswertung betrachtet.

Wie schon bei der Klassifikation der Porosität in Kapitel 6.3.2 werden für die Regression MLPs und CNNs betrachtet. In Tabelle 6-7 sind die durch Grid Search gefundenen optimalen Topologien für die beiden Modellarten sowie die erreichte Modellperformance dargestellt. Bei Betrachtung der Topologie zeigt sich, analog zur Regression mittels akustischer Körperschalldaten (vgl. Kapitel 6.4.1), dass komplexere Modelltopologien bessere Ergebnisse liefern. Es werden auf Basis des durchgeführten Grid Search zwei weitere Schichten mit je 512 und 1024 Neuronen für die Regression genutzt.

Tabelle 6-7: Beste Modelltopologien zur Regression der Zellporosität auf dem Gesamtdatensatz auf Basis der optischen Daten des Fotodiodenarrays

Modellart	Topologie	R²	RMSE
MLP	Aktivierungsfunktion: ReLU Schichten: [512, 1024, 512, 128, 64, 32] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,0005 Solver: Adam Scaler: StandardScaler	0,296	0,734
CNN	Aktivierungsfunktion: ReLU Schichten: [512, 1024, 512, 128, 64, 32] Lernrate: 0,001 Learning Rate Decay: 0,001 Dropout: 0,3 L2-Faktor: 0,0005 Solver: Adam Scaler: StandardScaler	0,28	0,734

Bei Betrachtung der Modellperformance fällt auf, dass das MLP gegenüber dem CNN eine bessere Performance bei R^2 und RMSE aufweist. Der R^2 -Wert liegt mit 0,296 beim MLP höher als der R^2 -Wert des CNN mit 0,28. Der RMSE ist beim MLP mit 0,734 ebenfalls geringer und damit besser als der RMSE des CNN mit 0,743. Bei Betrachtung der vorhergesagten gegenüber der tatsächlichen Porosität der beiden Modelle in der Abbildung 6-22 fällt auf, dass das CNN, wie auch schon bei den akustischen Körperschalldaten, keine Vorhersage der Zellporosität unterhalb eines gewissen Grenzwertes macht. Dieses Verhalten ist ebenfalls nicht beim MLP zu beobachten. Bei beiden Modellen ist festzustellen, dass insgesamt, analog zu den akustischen Körperschalldaten, auch eine Unterschätzung der Zellporosität stattfindet. Dies zeigt sich erneut an den beiden Ausgleichsgeraden, welche eine geringere Steigung als die Winkelhalbierende aufweisen.

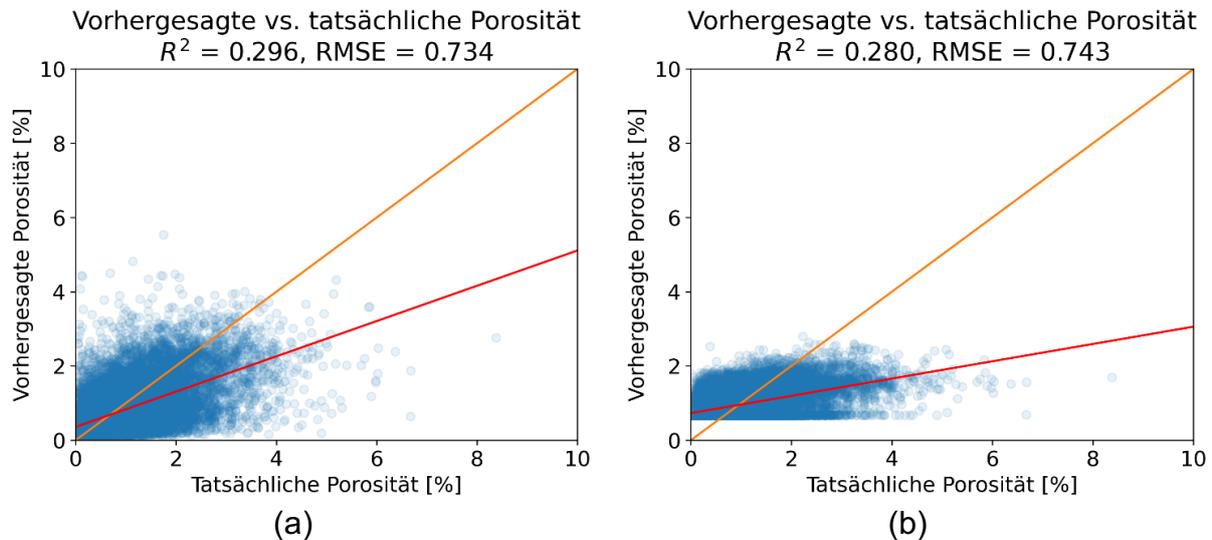


Abbildung 6-22: Vorhergesagte vs. Tatsächliche Porosität bei der Porositätsregression durch (a) MLP und (b) CNN auf Basis der optischen Daten des Fotodiodenarrays

In Abbildung 6-23 sind die Schnittansichten von drei beispielhaften Probekörpern dargestellt. In Abbildung 6-23 (a) ist Probekörper 10 dargestellt. Qualitativ zeigt sich, dass die generelle Tendenz innerhalb des Probekörpers durch das Modell wiedergegeben wird. Bereiche mit lokal besonders erhöhter Porosität (vgl. mittlere Schnittansicht) werden nicht vom Modell vorhergesagt. In Abbildung 6-23 (b) wird Probekörper 69 gezeigt. Dieser weist insgesamt eine geringe Zellporosität auf. In der mittleren Schnittansicht ist ein Bereich erkennbar, in dem erhöhte Porosität zu erkennen ist. Das Modell sagt diesen Bereich wie schon in der Schnittansicht (a) falsch vorher. Abbildung 6-23 (c) zeigt Probekörper 86. In diesem Probekörper ist eine graduelle Abnahme der Porosität in den verschiedenen Schnittansichten feststellbar. Dieses Verhalten findet sich auch in der Vorhersage des Modells wieder. Wie auch schon bei der Betrachtung der Modelle zur Regression auf Basis der Körperschalldaten kann die Ursache der fehlerhaften Vorhersagen nicht ermittelt werden.

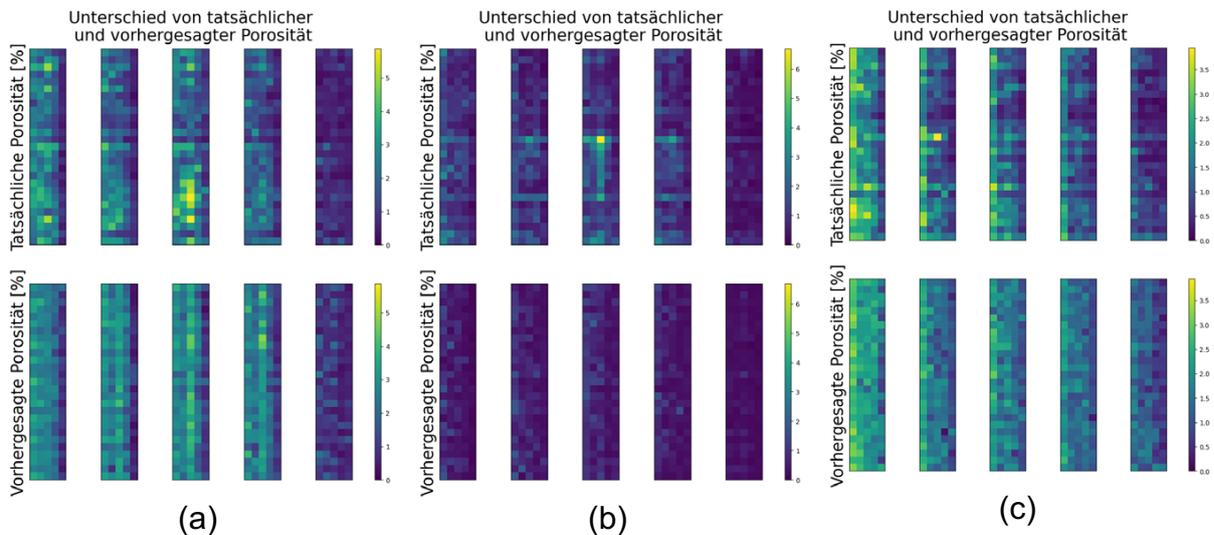


Abbildung 6-23: Schnittdiagramme zum qualitativen Vergleich der Vorhersagequalität der Porositätsregression mittels MLP für optische Daten des Fotodiodenarrays – a) Probekörper 10, b) Probekörper 69 und c) Probekörper 86

6.4.3 Vergleich von Körperschall und Fotodiodenarray

Analog zum Vergleich der Modelle der Klassifikation in Kapitel 6.3.3 erfolgt der Vergleich für die Regression. Das beste Modell stellt erneut die Auswertung der akustischen Daten mittels CNN dar. Das Modell erreicht einen R^2 von 0,392 und einen RMSE von 0,682. Die Performance der Modelle auf den optischen Daten liegt mit einem R^2 von 0,296 und einem RMSE von 0,734 für das MLP sowie einem R^2 von 0,28 und einem RMSE von 0,734 deutlich unter der Performance des CNN für die akustischen Daten. Im Gegensatz zur Klassifikation, schneidet das MLP für die optischen Daten knapp besser als das CNN für diese ab. Das MLP auf Basis der akustischen Daten liegt mit einem R^2 von 0,202 und einem RMSE von 0,782 deutlich unter den anderen Modellen.

6.5 Modellübertragbarkeit auf einzelne Druckjobs

In Kapitel 6.3 und Kapitel 6.4 wurde jeweils der Gesamtdatensatz betrachtet. Dazu wurde aus dem Gesamtdatensatz ein gewisser Anteil an Probekörpern für die Validierung als Testdatensatz genutzt. Im industriellen Anwendungsfall ist von Interesse, wie gut ein vortrainiertes Modell in der Lage ist, die Porosität in einem dem Modell komplett unbekanntem Druckjob vorherzusagen.

Da sich in Kapitel 6.3 und Kapitel 6.4 gezeigt hat, dass die Durchführung einer Klassifikation bessere Ergebnisse als die Regression liefert, soll im Rahmen der Modellübertragbarkeit die Klassifikation betrachtet werden. Im Rahmen der Klassifikation hat sich in Kapitel 6.3.3 gezeigt, dass CNN-basierte Modelle gegenüber MLP-basierten Modellen eine bessere Performance aufweisen. Aus diesem Grund wird die Untersuchung der Modellübertragbarkeit mit CNN-basierten Modellen durchgeführt.

Zur Untersuchung wird jeweils ein Modell auf einem der vier Druckjobs angelernt und dazu genutzt, die Porositätsklassen in den drei anderen Druckjobs vorherzusagen. Es werden die gleichen Trainingsdaten wie in den vorherigen Modellen in einem Druckjob verwendet, um die Modelle vergleichbar zu machen. Die Vorhersage erfolgt bei den anderen Druckjobs auf allen Probekörpern. Aus Zeitgründen wird für alle Modelle eine einheitliche Modelltopologie gewählt.

In Abbildung 6-24 sind der F1-Score (a) und der MCC (b) für die Modelle dargestellt. Das Modell für Druckjob 1 wurde auf den Trainingsdaten von ausschließlich Druckjob 1 trainiert und dann auf jeden Druckjob separat angewandt (siehe dazu Abszisse). Bei Betrachtung des F1-Scores ist zu erkennen, dass der F1-Score für Druckjob 2 bei allen Modellen deutlich niedriger als für die anderen Druckjobs ist. Weiterhin ist zu erkennen, dass das Modell für Druckjob 2 generell deutlich schlechter abschneidet als die anderen Modelle. Dies könnte darin begründet sein, dass Druckjob 2 die Probekörper mit der geringsten Porosität beinhaltet und somit im Training weniger Datentupel für porositätsbehaftete Zellen vorhanden als auf den anderen Druckjobs. In Abbildung 6-25 sind die Klassenverteilungen der einzelnen Datensätze dargestellt. Druckjob 2 hat einen durchweg geringeren Anteil an Einheitszellen, deren Porosität über 1 % liegt. Diese Unterrepräsentierung kann zu einer schlechteren Modellperformance führen.

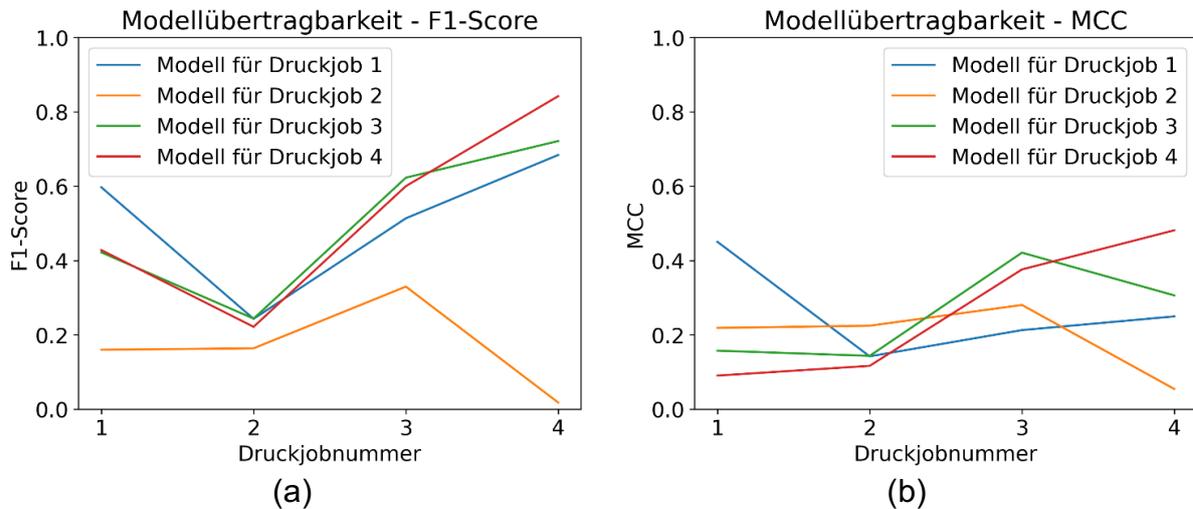


Abbildung 6-24: (a) F1-Score und (b) MCC zur Untersuchung der Modellübertragbarkeit auf andere Druckjobs

Bei Betrachtung des MCC zeigt sich, dass der MCC (mit Ausnahme des Modells für Druckjob 2) auf dem Datensatz am höchsten ist, auf welchem das Modell trainiert wurde. Der MCC für die Druckjobs 1, 3 und 4 liegt niedriger als der zugehörige F1-Score. Auffällig ist, dass das Modell von Druckjob 2, welcher die besten Bauteile und die geringste Porosität in den Probekörpern aufweist, bei der Anwendung auf den Datensatz von Druckjob 4 sowohl einen F1-Score als auch MCC von nahe null aufweist.

Die Betrachtung zeigt, dass eine ausreichende Anzahl an Defekten beim Training des Modells im Datensatz vorhanden sein muss, damit eine Modellübertragbarkeit möglich ist. Der Verlauf der Metriken in Abbildung 6-24 stellt dar, dass eine grundsätzliche Modellübertragbarkeit auf andere Druckjobs mit gleicher Bauteilgeometrie, aber veränderter Position möglich ist. Die Betrachtung der Modellübertragbarkeit auf andere Probekörpergeometrien war im Rahmen der Arbeit aus Gründen der verfügbaren Kapazität des Computertomographen zur Defektanalyse nicht möglich.

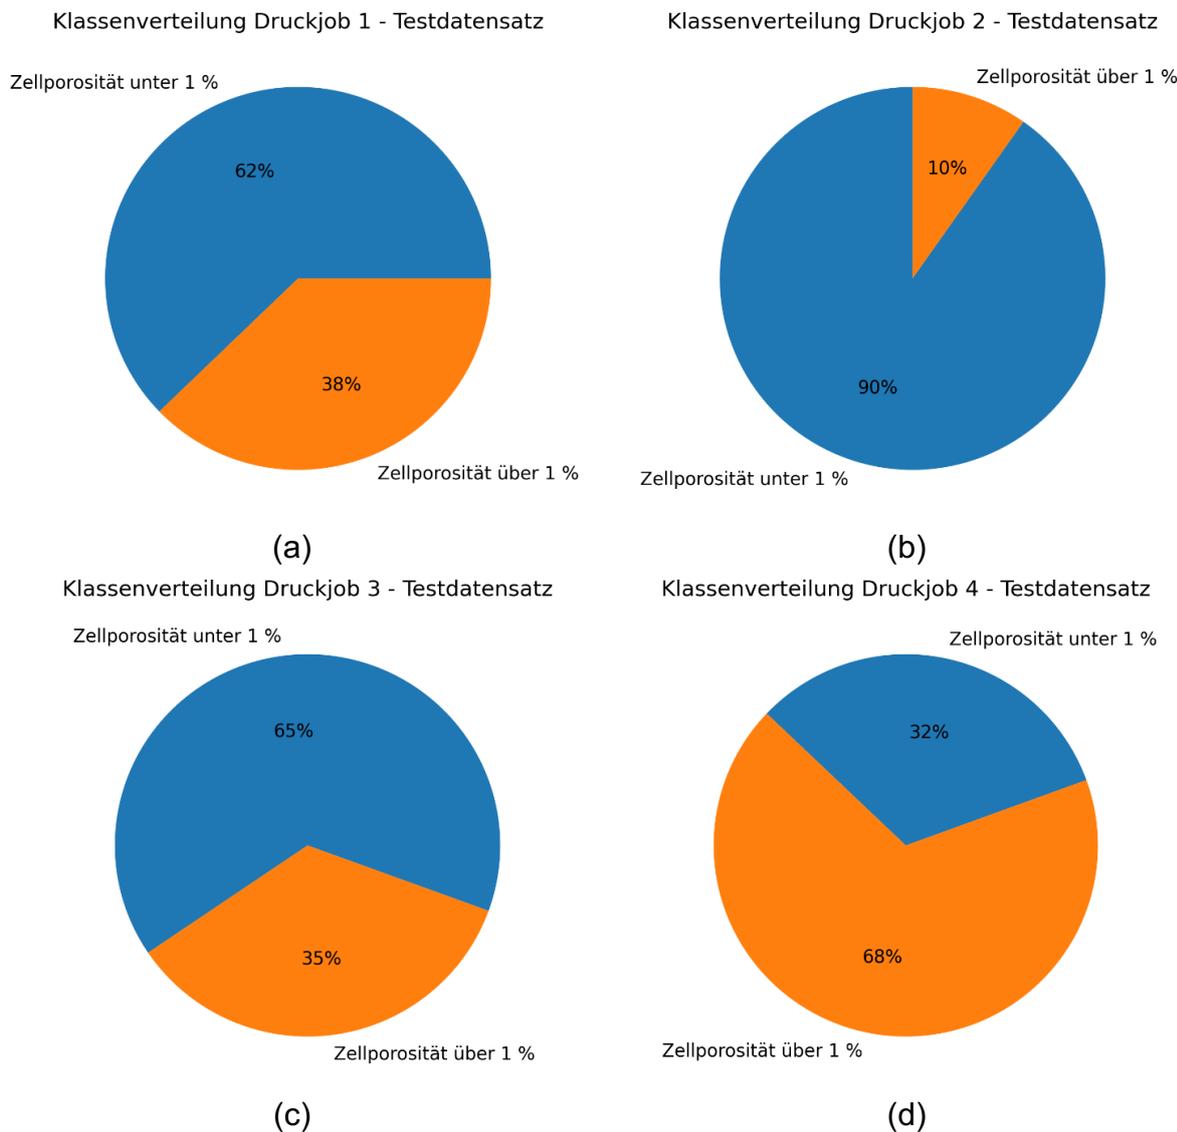


Abbildung 6-25: Klassenverteilung der Testdatensätze von Druckjob 1 (a) bis Druckjob 4 (d)

6.6 Datenfusion von Körperschall und Fotodiodenarray

Nachdem in Kapitel 6.3 und Kapitel 6.4 jeweils eine separate Betrachtung von optischen und akustischen Daten durchgeführt wurde, wird in diesem Kapitel betrachtet, ob eine Datenfusion der beiden Datenquellen eine Verbesserung der Vorhersage erreicht. Die Betrachtung dieser Frage erfolgt zweigeteilt: in Kapitel 6.6.1 erfolgt die Klassifikation der Porosität in den Einheitszellen, während in Kapitel 0 die Regression der Porosität in den Einheitszellen untersucht wird.

6.6.1 Klassifikation

Bei der Datenfusion der akustischen Körperschalldaten mit den optischen Daten des Fotodiodenarrays wird ein neues Modell erstellt: dieses besteht aus zwei separaten Modellen, welche durch eine Verknüpfungsschicht zusammengeführt werden, sowie einem nachgeschalteten Modell. Dieses nachgeschaltete Modell enthält die finale Ausgabeschicht. In Abbildung 6-26 ist die grundlegende Modellstruktur dargestellt.

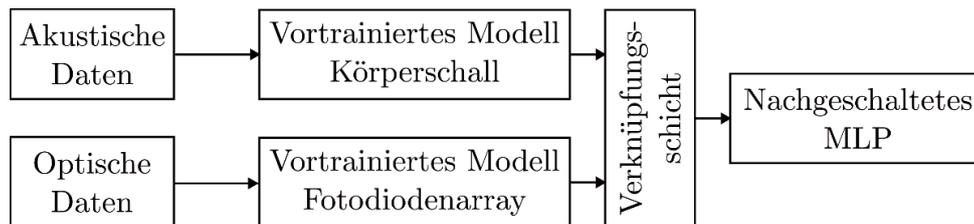


Abbildung 6-26: Modellstruktur zur Datenfusion

Für die akustischen Körperschalldaten und die optischen Daten der Fotodiode werden die vorherigen, bereits vortrainierten Modelle verwendet. Als grundlegende Modellstruktur werden für die akustischen Körperschalldaten die Modelle aus Kapitel 6.3.1 (vgl. auch Tabelle 6-2) verwendet. Für die optischen Daten werden die Modelle aus Kapitel 6.3.2 (vgl. Tabelle 6-5) genutzt. Für die gesamte Betrachtung wird 1 % Zellporosität als Klassengrenze festgelegt, um die Ergebnisse mit den Modellen ohne Datenfusion vergleichen zu können.

In Tabelle 6-8 ist die erreichte Modellperformance für die verschiedenen Kombinationen für die vortrainierten Modelle aus Abbildung 6-26 dargestellt (nach absteigendem F1-Score sortiert). Es werden alle Kombinationsmöglichkeiten betrachtet.

Tabelle 6-8: Klassifikationsperformance der verschiedenen Kombinationen von vortrainierten Modellen für die Datenfusion

Kombination	F1-Score	MCC
CNN (Akustische Daten + Optische Daten)	0,688	0,519
CNN (Akustische Daten) + MLP (Optische Daten)	0,688	0,514
MLP (Akustische Daten + Optische Daten)	0,660	0,467
MLP (Akustische Daten) + CNN (Optische Daten)	0,635	0,450

Die schlechteste Modellperformance erbringt das Modell mit einem MLP für die akustischen Daten und einem CNN für die optischen Daten (F1-Score 0,635 und MCC 0,450). Leicht besser ist das rein auf MLP basierende Modell mit einem F1-Score von 0,660 und einem MCC von 0,467. Zweitbeste Modellperformance weist das Modell mit einem CNN für die akustischen Daten und einem MLP für die optischen Daten auf. Es erreicht einen F1-Score von 0,688 und einen MCC von 0,514. Das beste Gesamtmodell ist das rein auf CNN für die vortrainierten Modelle basierende Modell mit einem F1-Score von 0,688 und einem leicht besseren MCC von 0,519. Zur besseren Vergleichbarkeit sind in Abbildung 6-27 die ROC-Kurven der vier Modelle dargestellt. Die Zuordnung der Modelle zu den optischen und akustischen Daten erfolgt wie in Tabelle 6-8 dargestellt. Es zeigt sich, dass die Modelle mit einem CNN auf den akustischen Daten insgesamt besser abschneiden als die Modelle mit MLP für die akustischen Daten.

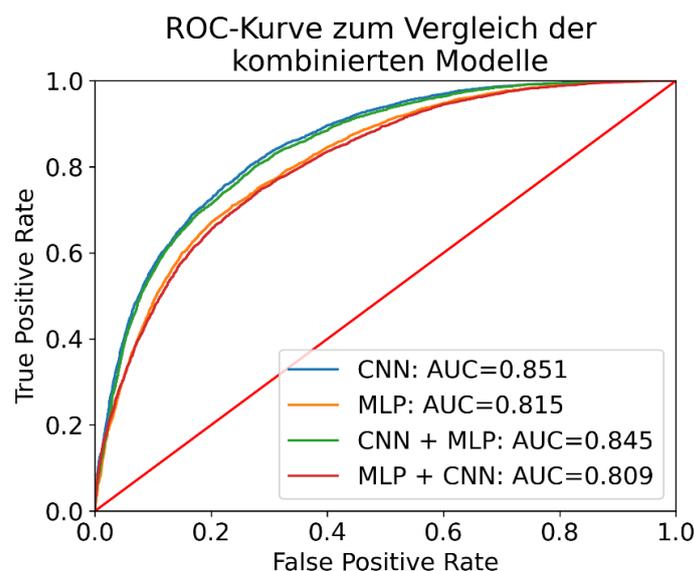


Abbildung 6-27: ROC-Kurven zum Vergleich der kombinierten Modelle für die Datenfusion

Nach der Vorstellung der Modellperformance der einzelnen Modelle wird untersucht, ob die Nutzung eines kombinierten Modells zur Datenfusion einen Vorteil gegenüber einem einzelnen Sensorprinzip hat. Das beste Modell zur Klassifikation der Zellporosität stellt das CNN der akustischen Daten aus Kapitel 6.3.1 dar. Dieses erreicht einen F1-Score von 0,690 und einen MCC von 0,527. Das beste Modell unter Nutzung der Datenfusion von akustischen und optischen Daten stellt das CNN-Modell (vgl. Tabelle 6-8) dar. Dieses erreicht einen F1-Score von 0,688 und einen MCC von 0,519. Die Konfusionsmatrix des Modells ist in Abbildung 6-28 (b) dargestellt. Es zeigt sich somit,

dass das rein akustische Modell einen leicht besseren F1-Score und MCC aufweist. Die Datenfusion von optischer und akustischer Messtechnik erzielt im angewandten Ansatz keine bessere Modellperformance.

Zur genaueren Betrachtung werden die beiden Modelle noch mit jeweils 0,25 % Zellporosität als Klassengrenze betrachtet. Das rein akustische Modell aus Kapitel 6.3.1 erreicht einen F1-Score von 0,874 und einen MCC von 0,543. Das CNN zur Datenfusion erreicht bei einer Klassengrenze von 0,25 % Zellporosität einen F1-Score von 0,864 und einen MCC von 0,502. Die Konfusionsmatrix des Modells ist in Abbildung 6-28 (a) dargestellt. Insgesamt zeigt sich, dass auch bei geringerer Zellporosität als Klassengrenze die Nutzung von mehreren Sensoren keinen Vorteil hat.

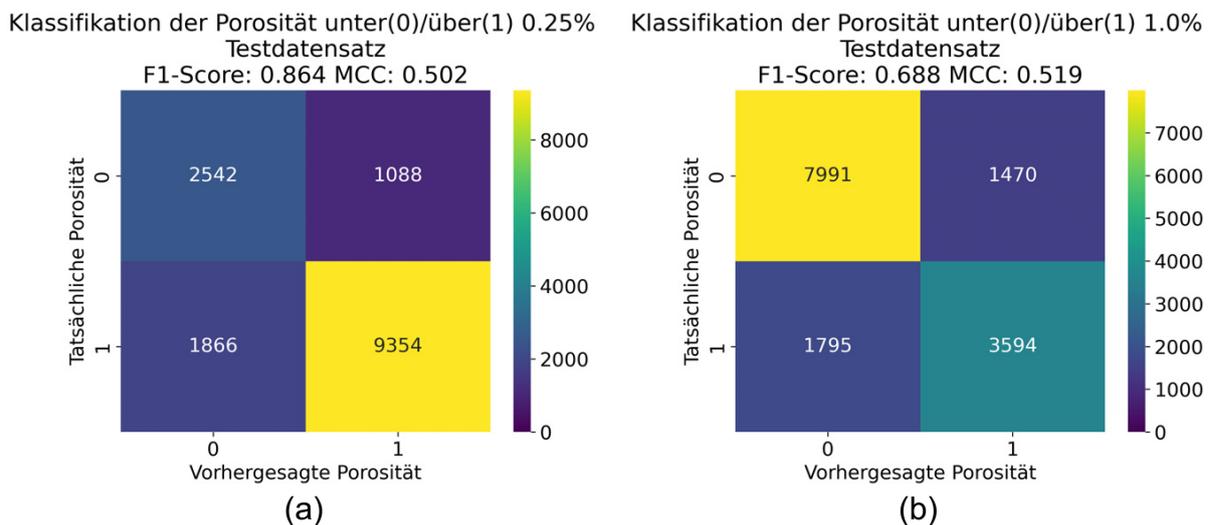


Abbildung 6-28: Konfusionsmatrizen der reinen CNNs zur Datenfusion mit (a) 0,25 % und (b) 1 % Zellporosität als Klassengrenze.

6.6.2 Regression

Analog zur Betrachtung der Datenfusion von Körperschall und Fotodiodenarray im Rahmen einer Klassifikation in Kapitel 6.6.1 wird die Ausgabeschicht im nachgeschalteten MLP (vgl. Abbildung 6-26) für die Regression angepasst. Die Regressionsergebnisse werden in Tabelle 6-9 für die verschiedenen Kombinationen von MLP und CNN dargestellt (nach absteigendem R^2 sortiert).

Tabelle 6-9: Regressionsperformance der verschiedenen Kombinationen von vortrainierten Modellen für die Datenfusion

Kombination	R²	RMSE
CNN (Akustische Daten + Optische Daten)	0,324	0,719
CNN (Akustische Daten) + MLP (Optische Daten)	0,292	0,736
MLP (Akustische Daten + Optische Daten)	0,235	0,766
MLP (Akustische Daten) + CNN (Optische Daten)	0,210	0,778

Die schlechteste Modellperformance weist, wie auch schon im Rahmen der Klassifikation, das Modell mit MLP für die akustischen Daten und CNN für die optischen Daten auf. Es erreicht einen R² von 0,210 und einen RMSE von 0,778. Ebenfalls leicht besser ist das rein auf MLP basierende Modell mit einem R² von 0,235 und einem RMSE von 0,766. Zweitbestes Modell ist das auf einem CNN für die akustischen Daten und einem ML für die optischen Daten basierende Gesamtmodell mit einem R² von 0,292 und einem RMSE 0,736. Wie auch bei der Klassifikation ist das rein auf CNN basierende Gesamtmodell das Modell mit der besten Performance. Es erreicht einen R² von 0,324 und einen RMSE von 0,719.

Das beste Regressionsmodell ohne Datenfusion ist das CNN der akustischen Körperschalldaten aus Kapitel 6.4.1. Es erreicht einen R² von 0,392 sowie einen RMSE von 0,682. Die Modellperformance ist damit besser als das in diesem Kapitel trainierte Gesamtmodell auf Basis von CNN. Es zeigt sich somit, dass entgegen dem Verhalten bei der Klassifikation, sich mit der verwendeten Netzwerktopologie kein Vorteil durch den Einsatz eines kombinierten Modells zur Datenfusion im Anwendungsfall der Regression ergibt. Der Einsatz anderer KNNs oder die Anpassung der Netzwerktopologie sind Möglichkeiten, durch den Einsatz mehrerer Sensoren einen Vorteil aus der Datenfusion zu ziehen.

6.7 Optimales Modell

Auf Basis der bisherigen Erkenntnisse wird in der Folge ein optimiertes Modell vorgestellt. Da die Metriken im Anwendungsfall der Klassifikation bedeutend bessere Ergebnisse gezeigt haben als bei der Regression, soll das optimierte Modell ebenfalls eine Klassifikation durchführen. Auf Basis von Tabelle 6-3 wird die Klassifikationsgrenze auf

0,25 % festgelegt, da bei dieser Klassengrenze die beste Trennschärfe der Modelle erreicht wurde. Das Modell mit der bisher besten Performance ist das rein auf den akustischen Daten basierende CNN. Auf Basis der ROC-Kurve des Modells wird eine Optimierung der Trennschärfe des Modells durchgeführt.

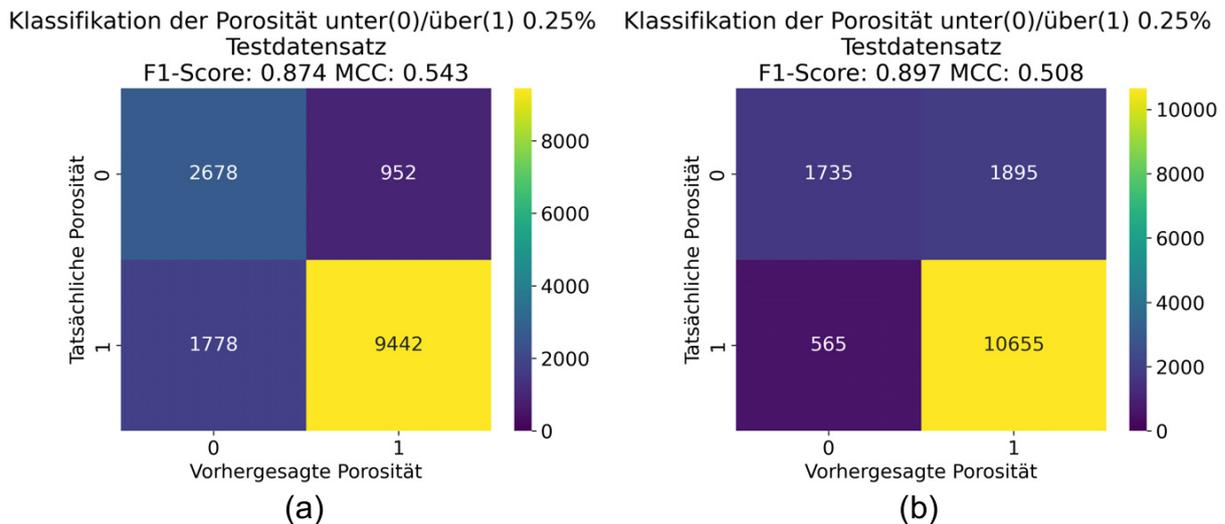


Abbildung 6-29: Konfusionsmatrizen des rein akustischen CNN mit 0,25 % Zellporosität als Klassengrenze (a) vor und (b) nach der ROC-Optimierung.

Das optimierte Modell erreicht einen F1-Score von 0,897 und einen MCC von 0,508. Im Vergleich zum CNN aus Tabelle 6-3 mit 0,25 % fällt auf, dass das optimierte Modell eine bessere Performance hinsichtlich des F1-Scores von 0,874 zu 0,897 aufweist, aber der MCC 0,543 auf 0,508 fällt. Die Anzahl der Einheitszellen die fälschlicherweise als porenfrei vorhergesagt werden, jedoch porenbehaftet sind (false negative), fällt durch die Optimierung von 1778 Einheitszellen auf 565 Einheitszellen. Diese Verbesserung geht jedoch gleichzeitig mit einer Steigerung der false positives, also Zellen die porenfrei sind aber als porenbehaftet vorhergesagt werden, von 952 Einheitszellen auf 1895 Einheitszellen. Das optimale Modell ist somit in der Lage, ein in Einheitszellen segmentiertes Bauteil in Bereiche mit geringer lokaler Porosität ($< 0,25\%$) oder darüber liegender Porosität zu segmentieren. Der daraus resultierende Nutzen für eine industrielle Serienfertigung wird im nachfolgenden Kapitel 7 diskutiert.

7 Kritische Diskussion und Ausblick

Nach der Vorstellung der Ergebnisse der Datenanalyse in Kapitel 6 erfolgt in diesem Kapitel eine kritische Diskussion der Ergebnisse und der Erkenntnisse der Datenanalyse (Kapitel 7.1), gefolgt von der Diskussion der Anforderungserfüllung des eigenen Ansatzes (Kapitel 7.2) sowie ein Ausblick (Kapitel 7.3) auf mögliche, sich anschließende Arbeiten und Möglichkeiten zur thematischen Weiterentwicklung.

7.1 Kritische Diskussion der Ergebnisse

Zunächst werden die Ergebnisse der durchgeführten Druckjobs aus Kapitel 6.1 diskutiert. Das Vorgehen, nicht durch Variation von Prozessparametern (wie der Laserleistung oder Belichtungsgeschwindigkeit), sondern durch die Förderung der Prozessstochastik Porosität in den Probekörpern zu erzeugen, hat zu ausreichend Variation in den Druckjobergebnissen geführt. Die Verteilung der Porosität der Probekörper ist ausreichend groß, um auch Bereiche mit lokal erhöhter Porosität zu erzeugen. Die Verteilung der Porosität innerhalb der vier Druckjob ist jedoch entgegen der Erwartung. Nach Tabelle 5-3 sollte Druckjob 2 die schlechtesten Bauteile hinsichtlich der Bauteilporosität enthalten, da sowohl die gewählte Belichtungsreihenfolge als auch der Füllgrad der Bauplattform das Auftreten von Defekten fördern sollten. In der Betrachtung der Porosität der Probekörper in Abbildung 6-5 zeigt sich, dass Druckjob 2 insgesamt das beste Druckjobergebnis hervorgebracht hat. Druckjob 3 sollte der Theorie nach die geringste Porosität in den Probekörpern haben, liegt aber sowohl von der Streuung der Porosität als auch in der absoluten Höhe der Porosität deutlich über Druckjob 1 und 2. Eine mögliche Ursache für die Zunahme der Porosität und ihrer Streuung in Druckjob 3 und 4 konnte nicht identifiziert werden. Die Anlage wurde nach jedem Druckjob komplett gereinigt und geprüft, sodass die Fehlerursache aller Wahrscheinlichkeit nach nicht auf die mechanische Anlagentechnik zurückzuführen ist.

Die verwendete Sensorik erzeugt viele Rohdaten, was eine sinnvolle Merkmalsextraktion sowie die Komprimierung der Daten erforderlich macht. Die Betrachtung einer zu hohen Komprimierung und das Anlernen eines Modells auf Basis eines randomisierten Labels haben gezeigt, dass dieses Vorgehen jedoch unproblematisch ist. Dies belegt, dass das Modell im Training sinnvolle weitere Datenstrukturen aus den komprimierten Daten extrahieren kann.

Im Bereich der Datenanalyse hat sich gezeigt, dass die Klassifikation gegenüber der Regression deutlich bessere Ergebnisse erzielt. Die Regression funktioniert mit den verwendeten Merkmalen und Modellen noch nicht in einem zufriedenstellenden Maße. Im Bereich der Klassifikation hat sich in dieser Arbeit gezeigt, dass die Modelle auf Basis der akustischen Körperschalldaten bei separater Betrachtung eine bessere Modellperformance als die Modelle der optischen Daten des Fotodiodenarrays aufweisen. Bei Betrachtung der einzelnen Probekörper im Testdatensatz fällt auf, dass es Probekörper gibt, bei denen die Vorhersage sehr gute Ergebnisse liefert, aber auch Probekörper im Datensatz existieren, bei denen die Modelle keine sinnvolle Vorhersage liefern. Die Suche nach der Fehlerursache gestaltet sich bei den verwendeten Modellen schwierig: künstliche neuronale Netze weisen ein starkes Blackbox-Verhalten auf, die Nachvollziehbarkeit der Entscheidungsfindung durch das Modell ist nicht trivial. Dies stellt einen wesentlichen Nachteil der verwendeten Modelle dar.

Die Betrachtung der Modellübertragbarkeit in Kapitel 6.5 zeigt, dass sich die Modelle auch auf komplett unbekannte Druckjobs grundsätzlich übertragen lassen. Die Variation der Position der Probekörper scheint keinen signifikanten Einfluss auf die Modellperformance zu haben. Dennoch ist aktuell noch ein Verlust an Modellperformance beim Übertrag auf unbekannte Druckjobs festzustellen, sodass hier noch weiteres Potential für Optimierung besteht. Die Aussagen zur Übertragbarkeit erfolgen im Rahmen dieser Arbeit unter der Einschränkung der gleichen Geometrie für die Probekörper. Die vorliegende Arbeit hat nur eine Probekörpergeometrie betrachtet. Es ist grundsätzlich zu prüfen, wie sich die Modellperformance bei Bauteilen anderer Geometrie verhält. Bei der Bewertung der Modellübertragbarkeit ist weiterhin festzuhalten, dass die Datengrundlage zum Trainieren eines Modells auf Basis eines einzelnen Druckjobs wiederum klein ist. Für eine ausführlichere Betrachtung und Optimierung ist es deshalb sinnvoll, weitere Druckjobs zum Datensatz hinzuzufügen.

Die Nutzung eines kombinierten Modells aus akustischer Körperschallsensorik und optischer Fotodiodenarray-Sensorik bringt keinen Vorteil gegenüber der separaten Betrachtung der Sensoren im Anwendungsfall der Klassifikation bei Nutzung von vortrainierten künstlichen neuronalen Netzen und dem Nachtrainieren eines nachgeschalteten Netzes. Die Modellperformance liegt unterhalb der Modelle nur auf Basis der akustischen Daten und geht weiterhin mit einer verlängerten Zeit im Training des Modells einher. Geht es rein um die Vorhersage der Existenz von Porosität (Klassengrenze von 0,25 %), so ist das rein akustische Modell das Modell mit der besten Performance und

die Nutzung von einem kombinierten Modell nicht notwendig. Bei der Regression der Zellporosität wird die Modellperformance durch ein kombiniertes Modell ebenfalls nicht verbessert. Die Ursache für dieses Verhalten ist aufgrund des bereits angesprochenen Blackbox-Verhaltens schwierig zu identifizieren.

Der vorliegende Ansatz auf Basis der akustischen und optischen Sensorik in seiner jetzigen Form bringt eine Einschränkung hinsichtlich des Anlagenaufbaus mit sich: eine Prozessüberwachung von Multi-Laser-Systemen ist derzeit nicht möglich. Der Ansatz ist auf die Verwendung von PBF-LB/M Anlagen mit nur einem Laser eingeschränkt, da die Sensordaten nicht eindeutig einer Laserquelle zugeordnet werden können, wenn mehrere gleichartige Laserquellen simultan aktiv sind.

Das optische Fotodiodenarray stellt eine Eigenentwicklung dar, welche mit geringem finanziellem Aufwand umgesetzt wurde und durch die simple Integration in die Baukammer keine Anpassungen am optischen Pfad der Anlage erforderlich macht. Die Modelle auf Basis der optischen Daten sind zwar schlechter als jene auf Basis der akustischen Daten, aber vor allem die CNN-basierten Modelle sind nur unwesentlich schlechter als die Modelle, welche auf den akustischen Daten basieren. Die akustische Körperschallmesstechnik ist mit wesentlich höheren Kosten verbunden.

7.2 Kritische Diskussion der Anforderungserfüllung

In der Folge wird auf die Anforderungen aus Kapitel 3.1 für eine Prozessüberwachung eingegangen und dargelegt, inwieweit der vorgestellte Ansatz diese erfüllt. Durch die verwendete Sensorik und das Aufzeichnen der Sensordaten während des Belichtungsvorgangs stellt der vorgestellte Ansatz eine **in-process Prozessüberwachung** dar. Durch die Kombination der Sensordaten von akustischem Körperschallsensor und optischem Fotodiodenarray mit den Positionsdaten des Galvanometerscanners wird durch den Ansatz eine **ortsaufgelöste Messung** möglich. Durch die entsprechenden Transformationen können die Sensordaten in Anlagenkoordinaten oder Probekörperkoordinaten betrachtet werden.

Nachfolgend wird betrachtet, inwieweit der vorliegende Ansatz für eine **industrielle Anwendbarkeit** geeignet ist. Durch die vollständige Pipeline zur Datenauswertung und die Nutzung von künstlichen neuronalen Netzen ist eine **automatisierte Auswertung** der Daten möglich. Durch die automatisierte Auswertung der Daten ist im vorliegenden Ansatz nur eine geringe Interaktion des Anlagenbedieners mit dem System notwendig,

sodass der Anlagenbediener nur eine **geringe Personalqualifikation** braucht, um mit einer auf dem Ansatz dieser Arbeit basierenden Prozessüberwachung arbeiten zu können. Die verwendete Sensorik kann entweder im Bauraum der Anlage untergebracht werden (optisches Fotodiodenarray) oder durch mechanisches Verschrauben an der Bauplatzform (akustischer Körperschallsensor). Die Sensorik erfordert keine Integration in den Strahlengang der Anlage. Dadurch sind keine angepassten Beschichtungen der optischen Komponenten sowie weitere optische Komponenten wie Strahlteiler notwendig. Aus diesem Grund verursacht der Ansatz dieser Arbeit **geringe Anschaffungskosten**. Da der Ansatz in der Lage ist, Bereiche mit lokal erhöhter Porosität zu identifizieren, können im Rahmen der Druckjobvorbereitung auf Basis von FEM-Simulationen Bereiche identifiziert werden, in denen im angedachten Belastungsfall möglichst keine lokal erhöhte Porosität vorliegen sollte. Fällt eine Einheitszelle mit lokal erhöhter Porosität in einen solchen Bereich, so stellt dies einen **kritischen Defekt** dar. In der Folge könnte die Prozessüberwachung ein Signal an die Steuerung der Anlage übermitteln, um den **Druckjob abubrechen**. Der vorliegende Ansatz erfüllt alle Anforderungen, welche in Kapitel 3.1 unter dem Punkt der industriellen Anwendbarkeit zusammengefasst wurden, sodass dem Ansatz dieser Arbeit die **industrielle Anwendbarkeit** zugesprochen wird. Die in Kapitel 6.5 dargestellte grundsätzliche Übertragbarkeit der Modelle auf weitere Druckjobs mit gleicher Bauteilgeometrie zeigt, dass der vorgestellte Ansatz auch im Kontext einer industriellen Serienfertigung genutzt werden könnte. In solch einem Fall werden viele Bauteile mit gleicher Geometrie gedruckt, sodass für diese bestehende Modelle genutzt werden können. Ein möglicher Übertrag auf neue Bauteilgeometrien ist noch zu untersuchen.

Zur **quantitativen Defektcharakterisierung** lässt sich folgendes festhalten: das Vorhandensein von Porosität kann mittels einer Klassifikation zwischen 0,25 % und 1 % Zellporosität detektiert werden. Die Modelle erreichen dabei einen F1-Score von 0,874 bei 0,25 % Zellporosität und einen F1-Score von 0,69 bei 1 % Zellporosität. Einschränkend muss dabei festgehalten werden, dass es Probekörper gibt, bei denen die Vorhersage gänzlich versagt. Weiterhin werden Konglomerate von defektbehafteten Zellen besser als einzelne, isolierte defektbehaftete Einheitszellen erkannt. Die Ursache für dieses Verhalten der Modelle konnte nicht identifiziert werden. Die Regression der numerischen Zellporosität hat mit dem verwendeten Ansatz nicht zufriedenstellen funktioniert (R^2 : 0,392 und RMSE: 0,682). Eine Betrachtung der Defekte auf Einzelporenebene ist mit dem Ansatz noch nicht möglich. Die Identifikation einzelner Poren und

Bestimmung von Volumen, Lage oder Zerklüftung dieser ist noch nicht möglich – der vorliegende Datensatz erlaubt aber eine mögliche Weiterentwicklung des Ansatzes zur Einzeldefektbetrachtung. Durch die Möglichkeit, den Schwellwert der Klassifikation in einem industriell relevanten Fenster (bis 1 % Porosität in den Einheitszellen) anzupassen, ist eine bedingte quantitative Aussage über vorliegende Defekte möglich. Dem Ansatz wird daher eine **teilweise vorhandene quantitative Defektcharakterisierung** zugesprochen. Zur vollständigen Erfüllung dieser Anforderung bedarf es allerdings weiterer Forschungs- und Entwicklungsarbeit, für welche der Datensatz dieser Arbeit genutzt werden kann.

7.3 Ausblick

Der im Rahmen dieser Arbeit erstellte Datensatz, bestehend aus Sensordaten von akustischer Körperschallmesstechnik, den drei optischen Kanälen des Fotodiodearrays, den zugehörigen zeitsynchronisierten Positionsdaten sowie CT-Scans mit durchgeführter Defektanalyse für über 100 Probekörper, stellt nach aktuellem Kenntnisstand einen der umfangreichsten Datensätze im vorliegenden Forschungsgebiet dar. Der Datensatz wird im Rahmen des Promotionsverfahrens unter der DOI 10.5445/IR/1000156803³⁸ (akustische Daten und Referenzmessung) und unter der DOI 10.5445/IR/1000156806³⁹ (optische Daten und Referenzmessung) veröffentlicht. Auf Basis des Datensatzes können weitere Untersuchungen und sich anschließende Forschungsarbeiten durchgeführt werden. Diese Möglichkeiten werden nachfolgend dargestellt.

Da die Modelle aufgrund des zugrundeliegenden Blackbox-Verhaltens eine geringe Nachvollziehbarkeit haben, kann in weiterführenden Arbeiten untersucht werden, ob mit analytischen Methoden aus dem Bereich der Zeitreihenanalyse eine Analyse möglich ist. Die Nutzung solcher Methoden bringt eine bessere Nachvollziehbarkeit der Modelle mit sich. Ziel ist es, besser zu verstehen, warum auf Basis der Sensordaten Entscheidungen getroffen werden.

Eine weitere sinnvolle Weiterentwicklung liegt in der Erweiterung des Datensatzes zur Datenanalyse. Es können Probekörper mit veränderter Geometrie genutzt werden, um

³⁸ <https://doi.org/10.5445/IR/1000156803>

³⁹ <https://doi.org/10.5445/IR/1000156806>

zu untersuchen, wie sich die Modellperformance bei unbekanntem Geometrien der Probekörper verhält. Weiterhin können Wiederholungsdrucke der bestehenden Druckjobs durchgeführt werden, um zu untersuchen, wie wiederholbar die Ergebnisse der bestehenden Druckjobs sind. Auf Basis dieser Daten kann in der Folge untersucht werden, ob sich bestimmte Muster oder Frequenzbänder in den akustischen Daten finden, die dediziert auf das Entstehen von Porosität im Prozess hinweisen.

Weitere Forschungsarbeit sollte im Bereich der quantitativen Defektcharakterisierung durchgeführt werden. Dazu kann einerseits im Bereich der Modelloptimierung zur Verbesserung der Modellperformance für die Aufgabe einer Regression gearbeitet werden, andererseits sollte die Auswertung auf die Ebene der Einzeldefektauswertung weiterentwickelt werden. Ziel kann es sein, besonders große und scharfkantige Poren in den Sensordaten zu identifizieren. Diese haben einen besonderen Einfluss auf die mechanischen Eigenschaften. Bei besserem Kenntnis über die vorliegenden Einzeldefekte kann untersucht werden, ob sich die mechanischen Eigenschaften, wie beispielsweise die Zugfestigkeit, auf Basis der Sensordaten vorhersagen lassen. Dies ist vor dem Hintergrund einer funktionsorientierten Vorhersage von Interesse.

Die Nutzung von mehreren Sensorprinzipien hat in dieser Arbeit keinen Mehrwert gebracht. Andere Ansätze zur Datenfusion oder andere Modellarten können untersucht werden, ob mit diesen ein Mehrwert aus mehreren Sensoren gezogen werden kann.

Neben der weiteren Betrachtung des Defekts Porosität ist aus Sicht der additiven Fertigung ebenfalls von Interesse, die verwendete Sensorik für die Detektion anderer Defekte zu qualifizieren. Zur Vermeidung von Rissen und Delaminationen können sich weiterführende Forschungsarbeiten beispielsweise auf die in-process Erkennung von Eigenspannungen im PBF-LB/M Fertigungsverfahren konzentrieren.

8 Zusammenfassung

Der PBF-LB/M Prozess hat Vorteile gegenüber der konventionellen Fertigung. Im Rahmen einer Serienfertigung sind jedoch noch Hürden zur Industrialisierung der Technologie vorhanden. Eine davon ist die geringe Reproduzierbarkeit der Prozessergebnisse und das stochastische Auftreten von Defekten. Ein Defekt, der dabei besonders hervorzuheben ist, ist die Porosität. Poren liegen innerhalb des Bauteils und haben je nach Form und Lage einen signifikanten Einfluss auf die mechanischen Eigenschaften des Bauteils. Die zerstörungsfreie Detektion von Poren erfolgt heute oftmals durch die Computertomographie. Dies ist aber vor allem bei hohen Stückzahlen unwirtschaftlich oder bei gewissen Bauteildimensionen nicht durchführbar. Eine mögliche Abhilfe sind dabei Prozessüberwachungen. In der vorliegenden Arbeit werden vier Anforderungen an Prozessüberwachungen zur Porositätsdetektion gestellt: durch eine hauptzeitparallele Messung soll eine sogenannte in-process Prozessüberwachung wirtschaftliche Vorteile bieten, durch eine ortal aufgelöste Messtechnik sowie eine quantitative Defektcharakterisierung soll die Form, Lage und Größe der Porosität erfasst werden. Weiterhin soll die Prozessüberwachung durch eine automatisierte Auswertung der Sensordaten, eine geringe notwendige Qualifikation des Anlagenbedieners zur Bedienung des Prozessüberwachungssystems, geringe Anschaffungskosten der Prozessüberwachung sowie die Möglichkeit, Porosität hinsichtlich der Kritikalität zu bewerten und ggf. Einfluss auf den Druckjob zu nehmen, industrielle Anwendbarkeit haben. Bestehende Forschungsansätze weisen vor allem Defizite im Bereich der industriellen Anwendbarkeit und in der quantitativen Defektcharakterisierung auf. Die existierenden industriellen Lösungen weisen erhebliche Defizite im Bereich der quantitativen Defektcharakterisierung auf, werden aber aufgrund einer unvollständigen Informationslage aus der Bewertung der Ansätze hinsichtlich der Anforderungen ausgeschlossen. Bei der Bewertung der Forschungsansätze zeigt sich, dass eine weiterentwickelte Prozessüberwachung insbesondere Forschungsarbeit hinsichtlich der quantitativen Defektcharakterisierung sowie industrielle Anwendbarkeit bedarf.

Der eigene Ansatz der Arbeit zur Entwicklung einer Prozessüberwachung, welche die oben dargestellten Anforderungen erfüllt, besteht im Wesentlichen aus den folgenden Schritten: (I) zunächst wird eine Auswahl geeigneter Sensorik getroffen. Im Rahmen der Arbeit wird akustische Körperschallsensorik ausgewählt und ein optisches Fotodiodenarray selbst entwickelt. Die Sensorik wird in eine industrielle PBF-LB/M Anlage

vom Typ *Realizer SLM125* des Herstellers *DMG Mori* integriert. Dies geht einher mit Hardware- und Softwareanpassungen an der Anlage. (II) In der Folge werden Probekörper gedruckt, welche an die Zugstabgeometrie der DIN 50125 Typ A angelehnt sind. Durch geeignete Belichtungsreihenfolgen und variablem Abstand der Probekörper auf der Bauplattform wird die existierende Prozessstochastik in der Art gefördert, dass keine Parametervariation von bspw. Laserleistung oder Belichtungsgeschwindigkeit notwendig ist, um eine Varianz der Porosität innerhalb der Probekörper hervorzurufen. In Summe werden in 4 Druckjobs insgesamt 104 Probekörper gedruckt. (III) Als Referenzmessung wird eine Defektanalyse durch die Auswertung mittels Computertomographie für alle Probekörper durchgeführt. Parallel dazu wird untersucht, ob die Auswertekette von Computertomograph und Auswertesoftware für den angedachten Anwendungsfall geeignet ist. Dabei zeigt sich, dass die Auswertekette nach DIN EN ISO 9000 für die Auswertung validiert werden kann. (IV) Bei der Datenanalyse wird der Probekörper in virtuelle Einheitszellen mit einer Kantenlänge von 1 mm segmentiert. Die akustischen Daten werden vor dem Modelltraining vom Zeitbereich in den Frequenzbereich überführt. Die optischen Daten des Fotodiodenarrays werden mittels einer Hauptkomponentenanalyse in ihrer Dimensionalität reduziert. Zur Beschleunigung des Trainings auf der im Rahmen dieser Arbeit zur Verfügung stehenden Hardware wird der Datensatz vor dem Training komprimiert. Die Datenanalyse der vorhandenen Sensordaten erfolgt mittels künstlicher neuronaler Netze. Dabei wird neben einer Regression der Zellporosität auch die Klassifikation einer Grenzporosität in den Einheitszellen betrachtet.

Die Ergebnisse der Datenanalyse zeigen, dass die Klassifikation von Einheitszellen gegenüber der Regression der numerischen Zellporosität besser funktioniert. Dabei lässt sich bereits das Vorhandensein von geringer Zellporosität von über 0,25 % mit einem F1-Score von 0,897 vorhersagen. Bei qualitativer Betrachtung der Vorhersage für die Probekörper zeigt sich aber auch, dass es einzelne Probekörper gibt, bei denen die Vorhersage nicht zufriedenstellend funktioniert. Die Ursache für dieses Verhalten konnte nicht geklärt werden. Die Modelle sind mit geringem Verlust an Modellperformance auch auf andere Druckjobs mit anderer Anordnung der Bauteile übertragbar. An dieser Stelle sollte aber die vorhandene Datenbasis zur Druckjobübertragbarkeit in fortfolgenden Arbeiten noch erweitert werden. Abschließend wird ein Modell trainiert, was sowohl optische als auch akustische Daten nutzt. Dabei werden die vortrainierten Modelle der getrennten Betrachtung der Sensoren genutzt. Es zeigt sich, dass die Nutzung

eines kombinierten Modells zur Datenfusion gegenüber der getrennten Betrachtung der Sensoren keine bessere Modellperformance aufweist. Die Datenfusion geht aber mit erhöhtem Rechenaufwand im Training des Modells einher. Andere Ansätze zur Datenfusion können in Folgearbeiten untersuchen, ob sich ein Mehrwert aus der Nutzung von mehreren Sensoren bieten kann.

Die in dieser Arbeit entwickelte Prozessüberwachung ist in der Lage, in-process das Prozessgeschehen zu überwachen. Weiterhin nutzt sie orts aufgelöste Messtechnik und erfüllt die gestellten Anforderungen für einen industriellen Einsatz des Ansatzes. Lediglich die quantitative Defektcharakterisierung konnte nur bedingt erfüllt werden. Das beste Modell der Arbeit kann das Vorhandensein einer Zellporosität von größer als 0,25 % mit einem F1-Score von 0,897 vorhersagen. An dieser Stelle kann jedoch auf dem erstellten und im Rahmen des Promotionsverfahrens veröffentlichten Datensatz⁴⁰, welcher einer der größten und umfangreichsten Datensätze auf dem Forschungsgebiet ist, weitergeforscht werden, um auch im Bereich der quantitativen Defektcharakterisierung Fortschritte zu machen.

⁴⁰ <https://doi.org/10.5445/IR/1000156803> und <https://doi.org/10.5445/IR/1000156806>

Liste der eigenen Publikationen

Eschner et al. 2018

Eschner, N.; Weiser, L.; Häfner, B. & Lanza, G. (2018), „Development of an Acoustic Process Monitoring System for Selective Laser Melting (SLM)“. Proceedings for the 2018 International Solid Freeform Fabrication Symposium, 13.08.2018 - 15.08.2018, Austin, Texas, USA.

<https://doi.org/10.26153/tsw/17205>.

Eschner et al. 2019

Eschner, N.; Weiser, L.; Häfner, B. & Lanza, G. (2019), „Akustische Prozessüberwachung für das Laserstrahlschmelzen (LBM) mit neuronalen Netzen: Eine Potentialbewertung“, tm - Technisches Messen, 86(11), S. 661–672.

<https://doi.org/10.1515/teme-2019-0070>.

Eschner et al. 2020

Eschner, N.; Weiser, L.; Häfner, B. & Lanza, G. (2020), „Classification of specimen density in Laser Powder Bed Fusion (L-PBF) using in-process structure-borne acoustic process emissions“, Additive Manufacturing, 34, S. 101324.

<https://doi.org/10.1016/J.ADDMA.2020.101324>.

Schild et al. 2023

Schild, L.; Weiser, L.; Höger, K. & Lanza, G. (2023), „Analyzing the error of Computed Tomography-based pore detection by using microscope images of matched cross-sections“, Precision Engineering, 81, S. 192–206.

<https://doi.org/10.1016/j.precisioneng.2023.01.013>.

Weiser et al. 2020

Weiser, L.; Batschkowski, M.; Eschner, N.; Häfner, B.; Neubauer, I.; Gering, M.; Schmidt, M. & Lanza, G. (2020), „AM-Serienproduktion für die Automobilindustrie/AM series production for the automotive industry“, wt Werkstattstechnik online, 110(11-12), S. 752–757. <https://doi.org/10.37544/1436-4980-2020-11-12-16>.

Weiser et al. 2023 (angenommen, aber noch nicht veröffentlicht)

Weiser, L.; Batschkowski, M.; Eschner, N.; Landgräber, T.; Ohlsen, F.; Seiz, S. & Lanza, G. (2023), „Quality Control in L-PBF for Industrial Production by

means of Production Integrated Measurement Technology“ in Springer Handbook of Additive Manufacturing, Hrsg. E. Pei, A. Bernard, D. Gu, C. Klahn, M. Monzon, M. Petersen & T. Sun, Springer International Publishing, Cham.

Literaturverzeichnis

Literaturangaben nach dem Schema (A_<Nachname> <Jahr>) beziehen sich auf studentische Abschlussarbeiten, die vom Verfasser dieser Arbeit inhaltlich und organisatorisch angeleitet wurden.

A_Bauder 2020

Bauder, F. (2020), *Erstellung eines Defektkatalogs für das Laser-Powder Bed Fusion (L-PBF) Verfahren mit experimenteller Untersuchung*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Fink 2021

Fink, C. (2021), *Prozessüberwachung in der additiven Fertigung mittels maschinellen Lernens*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Knipper 2021

Knipper, L. H. J. (2021), *Entwicklung einer Prozessauswertung in der additiven Fertigung mittels maschinellem Lernen*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Liebetrau 2021

Liebetrau, T. (2021), *Qualitätssicherung in der additiven Fertigung mittels maschinellen Lernens*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Meyer Garcia 2020

Meyer Garcia, M. (2020), *Entwicklung eines optischen Messsystems zur direkten in process Überwachung des Laserstrahlschmelzens (L-PBF)*. Masterarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

A_Wilkes 2019

Wilkes, S. (2019), *Integration eines akustischen Sensors in eine Anlage des selektiven Laserstrahlschmelzens*. Bachelorarbeit, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.

Abdi & Williams 2010

Abdi, H. & Williams, L. J. (2010), „Principal component analysis“, *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(4), S. 433–459.
<https://doi.org/10.1002/wics.101>.

Ahn 2019

Ahn, I. H. (2019), „Determination of a process window with consideration of effective layer thickness in SLM process“, *The International Journal of Advanced Manufacturing Technology*, 105(10), S. 4181–4191. <https://doi.org/10.1007/s00170-019-04402-w>.

Albawi et al. 2017

Albawi, S.; Mohammed, T. A. & Al-Zawi, S. (2017), „Understanding of a convolutional neural network“. *2017 International Conference on Engineering and Technology (ICET)*, IEEE, S. 1–6, 21.08.2017 - 23.08.2017, Antalya. ISBN: 9781538619490. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>.

Avrutsky et al. 2006

Avrutsky, I.; Chaganti, K.; Salakhutdinov, I. & Auner, G. (2006), „Concept of a miniature optical spectrometer using integrated optical and micro-optical components“, *Applied optics*, 45(30), S. 7811–7817. <https://doi.org/10.1364/ao.45.007811>, PubMed-ID: 17068514.

Bisht et al. 2018

Bisht, M.; Ray, N.; Verbist, F. & Coeck, S. (2018), „Correlation of selective laser melting-melt pool events with the tensile properties of Ti-6Al-4V ELI processed by laser powder bed fusion“, *Additive Manufacturing*, 22, S. 302–306.
<https://doi.org/10.1016/J.ADDMA.2018.05.004>.

Bremen et al. 2012

Bremen, S.; Meiners, W. & Diatlov, A. (2012), „Selective Laser Melting“, *Laser Technik Journal*, 9(2), S. 33–38. <https://doi.org/10.1002/latj.201290018>.

Bro & Smilde 2014

Bro, R. & Smilde, A. K. (2014), „Principal component analysis“, *Anal. Methods*, 6(9), S. 2812–2831. <https://doi.org/10.1039/C3AY41907J>.

Cain et al. 2015

Cain, V.; Thijs, L.; van Humbeeck, J.; van Hooreweder, B. & Knutsen, R. (2015),

„Crack propagation and fracture toughness of Ti6Al4V alloy produced by selective laser melting“, *Additive Manufacturing*, 5, S. 68–76.

<https://doi.org/10.1016/j.addma.2014.12.006>.

Calta et al. 2018

Calta, N. P.; Wang, J.; Kiss, A. M.; Martin, A. A.; DePond, P. J.; Guss, G. M.; Thampy, V.; Fong, A. Y.; Weker, J. N.; Stone, K. H.; Tassone, C. J.; Kramer, M. J.; Toney, M. F.; van Buuren, A. & Matthews, M. J. (2018), „An instrument for in situ time-resolved X-ray imaging and diffraction of laser powder bed fusion additive manufacturing processes“, *Review of Scientific Instruments*, 89(5), S. 55101.

<https://doi.org/10.1063/1.5017236>, PubMed-ID: 29864819.

Chicco & Jurman 2020

Chicco, D. & Jurman, G. (2020), „The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation“, *BMC genomics*, 21(1), S. 6. <https://doi.org/10.1186/s12864-019-6413-7>, PubMed-ID: 31898477.

Clijsters et al. 2014

Clijsters, S.; Craeghs, T.; Buls, S.; Kempen, K. & Kruth, J.-P. (2014), „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*, 75(5-8), S. 1089–1101. <https://doi.org/10.1007/S00170-014-6214-8>.

Coeck et al. 2019

Coeck, S.; Bisht, M.; Plas, J. & Verbist, F. (2019), „Prediction of lack of fusion porosity in selective laser melting based on melt pool monitoring data“, *Additive Manufacturing*, 25, S. 347–356. <https://doi.org/10.1016/j.addma.2018.11.015>.

Craeghs et al. 2011

Craeghs, T.; Clijsters, S.; Yasa, E. & Kruth, J.-P. (2011), „Online Quality Control of Selective Laser Melting“. *Proceedings for the 2011 International Solid Freeform Fabrication Symposium*, 08.08.2011 - 10.08.2011, Austin, Texas, USA.

<https://doi.org/10.26153/TSW/15289>.

Czichos & Daum 2020

Czichos, H. & Daum, W. (2020), „Grundlagen“ in *Dubbel Taschenbuch für den Maschinenbau 2: Anwendungen*, Hrsg. B. Bender & D. Göhlich, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 683–691.

Demtröder 2015

Demtröder, W. (2015), *Experimentalphysik 1. Mechanik und Wärme*, Springer Berlin Heidelberg, Berlin, Heidelberg. <http://nbn-resolving.org/urn:nbn:de:bsz:31-e-pflicht-1532207>. ISBN: 9783662464151.

DePond et al. 2018

DePond, P. J.; Guss, G.; Ly, S.; Calt, N. P.; Deane, D.; Khairallah, S. & Matthews, M. J. (2018), „In situ measurements of layer roughness during laser powder bed fusion additive manufacturing using low coherence scanning interferometry“, *Materials & Design*, 154, S. 347–359.
<https://doi.org/10.1016/J.MATDES.2018.05.050>.

DIN EN ISO/ASTM 52911-1

DIN EN ISO/ASTM 52911-1 (2020), *Additive Fertigung - Konstruktion - Teil 1: Laserbasierte Pulverbettfusion von Metallen (ISO/ASTM 52911-1:2019); Deutsche Fassung EN ISO/ASTM 52911-1:2019*.

Dowling et al. 2020

Dowling, L.; Kennedy, J.; O'Shaughnessy, S. & Trimble, D. (2020), „A review of critical repeatability and reproducibility issues in powder bed fusion“, *Materials & Design*, 186, S. 108346. <https://doi.org/10.1016/j.matdes.2019.108346>.

Du et al. 2018

Du, W.; Bai, Q.; Wang, Y. & Zhang, B. (2018), „Eddy current detection of subsurface defects for additive/subtractive hybrid manufacturing“, *The International Journal of Advanced Manufacturing Technology*, 95(9-12), S. 3185–3195.
<https://doi.org/10.1007/S00170-017-1354-2>.

Du Plessis et al. 2020

Du Plessis, A.; Yadroitsava, I. & Yadroitsev, I. (2020), „Effects of defects on mechanical properties in metal additive manufacturing: A review focusing on X-ray tomography insights“, *Materials & Design*, 187, S. 108385.
<https://doi.org/10.1016/j.matdes.2019.108385>.

Durak & Arikan 2003

Durak, L. & Arikan, O. (2003), „Short-time fourier transform: two fundamental properties and an optimal implementation“, *IEEE Transactions on Signal Processing*, 51(5), S. 1231–1242. <https://doi.org/10.1109/tsp.2003.810293>.

Eschner et al. 2020

Eschner, N.; Weiser, L.; Häfner, B. & Lanza, G. (2020), „Classification of specimen density in Laser Powder Bed Fusion (L-PBF) using in-process structure-borne acoustic process emissions“, *Additive Manufacturing*, 34, S. 101324. <https://doi.org/10.1016/J.ADDMA.2020.101324>.

Eschner et al. 2019

Eschner, N.; Weiser, L.; Häfner, B. & Lanza, G. (2019), „Akustische Prozessüberwachung für das Laserstrahlschmelzen (LBM) mit neuronalen Netzen: Eine Potentialbewertung“, *tm - Technisches Messen*, 86(11), S. 661–672. <https://doi.org/10.1515/teme-2019-0070>.

Eschner et al. 2018

Eschner, N.; Weiser, L.; Häfner, B. & Lanza, G. (2018), „Development of an Acoustic Process Monitoring System for Selective Laser Melting (SLM)“. *Proceedings for the 2018 International Solid Freeform Fabrication Symposium*, 13.08.2018 - 15.08.2018, Austin, Texas, USA. <https://doi.org/10.26153/tsw/17205>.

Eschner 2021

Eschner, J. N. (2021), *Entwicklung einer akustischen Prozessüberwachung zur Porenbestimmung im Laserstrahlschmelzen*. Dissertation, Karlsruher Institut für Technologie (KIT), Shaker, Düren. ISBN: 9783844079661.

Everton et al. 2016

Everton, S. K.; Hirsch, M.; Stravroulakis, P.; Leach, R. K. & Clare, A. T. (2016), „Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing“, *Materials & Design*, 95, S. 431–445. <https://doi.org/10.1016/j.matdes.2016.01.099>.

Ferrari et al. 2009

Ferrari, G.; Gozzini, F.; Molari, A. & Sampietro, M. (2009), „Transimpedance Amplifier for High Sensitivity Current Measurements on Nanodevices“, *IEEE Journal of Solid-State Circuits*, 44(5), S. 1609–1616. <https://doi.org/10.1109/JSSC.2009.2016998>.

Fossum & Hondongwa 2014

Fossum, E. R. & Hondongwa, D. B. (2014), „A Review of the Pinned Photodiode for CCD and CMOS Image Sensors“, *IEEE Journal of the Electron Devices Society*, 2(3), S. 33–43. <https://doi.org/10.1109/jeds.2014.2306412>.

Foster et al. 2015

Foster, B. K.; Reutzel, E. W.; Nassar, A. R.; Hall, B. T.; Brown, S. W. & Dickman, C. J. (2015), „Optical, Layerwise Monitoring of Powder Bed Fusion“. *Proceedings for the 2015 International Solid Freeform Fabrication Symposium*, 10.08.2015 - 12.08.2015, Austin, Texas, USA. <https://repositories.lib.utexas.edu/handle/2152/89328>.

Gardner & Dorling 1998

Gardner, M. & Dorling, S. (1998), „Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences“, *Atmospheric Environment*, 32(14-15), S. 2627–2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0).

Gu et al. 2018

Gu, J.; Wang, Z.; Kuen, J.; Ma, L.; Shahroudy, A.; Shuai, B.; Liu, T.; Wang, X.; Wang, G.; Cai, J. & Chen, T. (2018), „Recent advances in convolutional neural networks“, 77, S. 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>.
<https://www.sciencedirect.com/science/article/pii/S0031320317304120>.

Hajian-Tilaki 2013

Hajian-Tilaki, K. (2013), „Receiver Operating Characteristic (ROC) Curve Analysis for Medical Diagnostic Test Evaluation“, *Caspian Journal of Internal Medicine*, 4(2), S. 627–635, PubMed-ID: 24009950.

Heering, W. 2004

Heering, W. (2004), *Optoelektronische Schaltungen*. Vorlesungsskript, Universität Karlsruhe, Karlsruhe, Lichttechnisches Institut.

Helland 1987

Helland, I. S. (1987), „On the Interpretation and Use of R² in Regression Analysis“, *Biometrics*, 43(1), S. 61. <https://doi.org/10.2307/2531949>.

Hill & Meltz 1997

Hill, K. O. & Meltz, G. (1997), „Fiber Bragg grating technology fundamentals and overview“, *Journal of Lightwave Technology*, 15(8), S. 1263–1276.
<https://doi.org/10.1109/50.618320>.

Hirsch et al. 2017

Hirsch, M.; Catchpole-Smith, S.; Patel, R.; Marrow, P.; Li, W.; Tuck, C.; Sharples,

S. D. & Clare, A. T. (2017), „Meso-scale defect evaluation of selective laser melting using spatially resolved acoustic spectroscopy“, *Proceedings. Mathematical, physical, and engineering sciences*, 473(2205), S. 20170194.
<https://doi.org/10.1098/RSPA.2017.0194>, PubMed-ID: 28989306.

Hoo et al. 2017

Hoo, Z. H.; Candlish, J. & Teare, D. (2017), „What is an ROC curve?“, *Emergency medicine journal : EMJ*, 34(6), S. 357–359. <https://doi.org/10.1136/emmermed-2017-206735>, PubMed-ID: 28302644.

Hooper 2018

Hooper, P. A. (2018), „Melt pool temperature and cooling rates in laser powder bed fusion“, *Additive Manufacturing*, 22, S. 548–559.
<https://doi.org/10.1016/J.ADDMA.2018.05.032>.

Hu et al. 2017

Hu, Z.; Zhu, H.; Zhang, H. & Zeng, X. (2017), „Experimental investigation on selective laser melting of 17-4PH stainless steel“, *Optics & Laser Technology*, 87, S. 17–25. <https://doi.org/10.1016/j.optlastec.2016.07.012>.

Jacob 2021

Jacob, A. (2021), *Hochiterative Technologieplanung*. Dissertation, Karlsruher Institut für Technologie (KIT), Shaker, Düren. ISBN: 9783844081633.

Jones 1953

Jones, R. C. (1953), „The General Theory of Bolometer Performance“, *Journal of the Optical Society of America*, 43(1), S. 1.
<https://doi.org/10.1364/JOSA.43.000001>.

Karunasingha 2022

Karunasingha, D. S. K. (2022), „Root mean square error or mean absolute error? Use their ratio as well“, *Information Sciences*, 585, S. 609–629.
<https://doi.org/10.1016/j.ins.2021.11.036>.

Kasperovich et al. 2016

Kasperovich, G.; Haubrich, J.; Gussone, J. & Requena, G. (2016), „Correlation between porosity and processing parameters in TiAl6V4 produced by selective laser melting“, *Materials & Design*, 105, S. 160–170.
<https://doi.org/10.1016/j.matdes.2016.05.070>.

Klahn 2015

Klahn, C. (2015), *Laseradditiv Gefertigte, Luftdurchlässige Mesostrukturen. Herstellung und Eigenschaften Für Die Anwendung*, Springer Berlin / Heidelberg, Berlin, Heidelberg. ISBN: 3662477610.

Klassen 2011

Klassen, S. (2011), „The Photoelectric Effect: Reconstructing the Story for the Physics Classroom“, *Science & Education*, 20(7-8), S. 719–731.
<https://doi.org/10.1007/s11191-009-9214-6>.

Kopf 2018

Kopf, R. (2018), *Kostenorientierte Planung von Fertigungsfolgen additiver Technologien*. Dissertation, Karlsruher Institut für Technologie (KIT), Shaker, Düren. ISBN: 9783844059373.

Krauss et al. 2014

Krauss, H.; Zeugner, T. & Zaeh, M. F. (2014), „Layerwise Monitoring of the Selective Laser Melting Process by Thermography“, *Physics Procedia*, 56(C), S. 64–71.
<https://doi.org/10.1016/j.phpro.2014.08.097>. <https://linkinghub.elsevier.com/retrieve/pii/S1875389214002429>.

Krauss et al. 2012

Krauss, H.; Eschey, C. & Zaeh, M. F. (2012), „Thermography for monitoring the selective laser melting process“. *Proceedings for the 2012 International Solid Freeform Fabrication Symposium*, S. 999–1014, 06.08.2012 - 08.08.2012, Austin, Texas, USA. <https://doi.org/10.26153/tsw/15406>.

Krogh 2008

Krogh, A. (2008), „What are artificial neural networks?“, *Nature biotechnology*, 26(2), S. 195–197. <https://doi.org/10.1038/nbt1386>, PubMed-ID: 18259176.

Ladewig et al. 2016

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

Lanza et al. 2019

Lanza, G.; Haefner, B.; Schild, L.; Berger, D.; Eschner, N.; Wagner, R. & Zaiß, M.

(2019), „In-Line Measurement Technology and Quality Control“ in *Metrology*, Hrsg. W. Gao, Springer Singapore, Singapore, S. 399–433.

Leonard et al. 2016

Leonard, F.; Tammam-Williams, S. & Todd, I. (2016), „CT for Additive Manufacturing Process Characterisation: Assessment of melt strategies on defect population“. *6th Conference on Industrial Computed Tomography*, 09.02.2016 - 12.02.2016, Wels, Österreich.

Lerner et al. 1999

Lerner, B.; Guterman, H.; Aladjem, M. & Dinstein, I. (1999), „A comparative study of neural network based feature extraction paradigms“, *Pattern Recognition Letters*, 20(1), S. 7–14. [https://doi.org/10.1016/S0167-8655\(98\)00120-2](https://doi.org/10.1016/S0167-8655(98)00120-2).

Luque et al. 2019

Luque, A.; Carrasco, A.; Martín, A. & las Heras, A. de (2019), „The impact of class imbalance in classification performance metrics based on the binary confusion matrix“, *Pattern Recognition*, 91, S. 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>.

Mandrekar 2010

Mandrekar, J. N. (2010), „Receiver operating characteristic curve in diagnostic test assessment“, *Journal of thoracic oncology : official publication of the International Association for the Study of Lung Cancer*, 5(9), S. 1315–1316. <https://doi.org/10.1097/JTO.0b013e3181ec173d>, PubMed-ID: 20736804.

Martin 1972

Martin, R. M. (1972), „Piezoelectricity“, *Physical Review B*, 5(4), S. 1607–1613. <https://doi.org/10.1103/PhysRevB.5.1607>.

Nevitt & Hancock 2000

Nevitt, J. & Hancock, G. R. (2000), „Improving the Root Mean Square Error of Approximation for Nonnormal Conditions in Structural Equation Modeling“, *The Journal of Experimental Education*, 68(3), S. 251–268. <https://doi.org/10.1080/00220970009600095>.

Nussbaumer 1981

Nussbaumer, H. J. (1981), „The Fast Fourier Transform“ in *Fast Fourier Transform*

and Convolution Algorithms, Springer, Berlin, Heidelberg, S. 80–111.

https://link.springer.com/chapter/10.1007/978-3-662-00551-4_4.

O’Keefe & Deacon 1988

O’Keefe, A. & Deacon, D. A. G. (1988), „Cavity ring-down optical spectrometer for absorption measurements using pulsed laser sources“, *Review of Scientific Instruments*, 59(12), S. 2544–2551. <https://doi.org/10.1063/1.1139895>.

O’Shea & Nash 2015

O’Shea, K. & Nash, R. (2015), *An Introduction to Convolutional Neural Networks*, arXiv. <https://doi.org/10.48550/arXiv.1511.08458>.

Pavlov et al. 2010

Pavlov, M.; Doubenskaia, M. & Smurov, I. (2010), „Pyrometric analysis of thermal processes in SLM technology“, *Physics Procedia*, 5, S. 523–531.

<https://doi.org/10.1016/J.PHPRO.2010.08.080>.

Ramchoun et al. 2016

Ramchoun, H.; Amine, M.; Idrissi, J.; Ghanou, Y. & Ettaouil, M. (2016), „Multilayer Perceptron: Architecture Optimization and Training“, *International Journal of Interactive Multimedia and Artificial Intelligence*, 4(1), S. 26.

<https://doi.org/10.9781/ijimai.2016.415>.

Rashidi et al. 2019

Rashidi, H. H.; Tran, N. K.; Betts, E. V.; Howell, L. P. & Green, R. (2019), „Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods“, *Academic pathology*, 6, 2374289519873088.

<https://doi.org/10.1177/2374289519873088>, PubMed-ID: 31523704.

Razavi 2019

Razavi, B. (2019), „The Transimpedance Amplifier [A Circuit for All Seasons]“, *IEEE Solid-State Circuits Magazine*, 11(1), S. 10–97.

<https://doi.org/10.1109/MSSC.2018.2881860>.

Rehse et al. 2013

Rehse, C.; Schmicker, D.; Maaß, A. & Bähr, R. (2013), „Ein Bewertungskonzept für computertomographisch ermittelte Porositäten in Gussteilen hinsichtlich ihrer Auswirkung auf die lokale Beanspruchbarkeit des Bauteils“, *Giesserei-Rundschau*, 60(5-6).

Rehse et al. 2016

Rehse, C.; Michaelis, C. & Bähr, R. (2016), „Computertomografisch ermittelte Porosität und ihre Wirkung auf die Festigkeitseigenschaften von Al-Gusslegierungen“, *GIESSEREI*, 103(05/2016), S. 16–22.

Rieder et al. 2016

Rieder, H.; Spies, M.; Bamberg, J. & Henkel, B. (2016), „On- and offline ultrasonic characterization of components built by SLM additive manufacturing“, AIP Publishing LLC, S. 130002, 26–31 July 2015, Minneapolis, Minnesota.
<https://doi.org/10.1063/1.4940605>.

Rieder et al. 2015

Rieder, H.; Dillhöfer, A.; Spies, M.; Bamberg, J. & Hess, T. (2015), „Ultrasonic online monitoring of additive manufacturing processes based on selective laser melting“, AIP Publishing LLC, S. 184–191, 20–25 July 2014, Boise, Idaho.
<https://doi.org/10.1063/1.4914609>.

Robinson et al. 2019

Robinson, J. H.; Ashton, I. R. T.; Jones, E.; Fox, P. & Sutcliffe, C. (2019), „The effect of hatch angle rotation on parts manufactured using selective laser melting“, *Rapid Prototyping Journal*, 25(2), S. 289–298. <https://doi.org/10.1108/RPJ-06-2017-0111>.

Schild et al. 2023

Schild, L.; Weiser, L.; Höger, K. & Lanza, G. (2023), „Analyzing the error of Computed Tomography-based pore detection by using microscope images of matched cross-sections“, *Precision Engineering*, 81, S. 192–206.
<https://doi.org/10.1016/j.precisioneng.2023.01.013>.

Schild, L. 2022

Schild, L. (2022), *Erzeugung und Verwendung von Anwendungswissen in der industriellen Computertomographie*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, wbk Institut für Produktionstechnik.
<https://doi.org/10.5445/IR/1000144753>.

Schmidt & Damm 2008

Schmidt, R. & Damm, B. E. (2008), „Prüfen und Messen im Takt : wie sie mit In-line-Messtechnik Ihre Wertschöpfung maximieren“, *Qualität und Zuverlässigkeit: QZ*(53), S. 57–59.

Shi et al. 2020

Shi, X.; Wang, H.; Feng, W.; Zhang, Y.; Ma, S. & Wei, J. (2020), „The crack and pore formation mechanism of Ti–47Al–2Cr–2Nb alloy fabricated by selective laser melting“, *International Journal of Refractory Metals and Hard Materials*, 91, S. 105247. <https://doi.org/10.1016/j.ijrmhm.2020.105247>.

Smith et al. 2016

Smith, R. J.; Hirsch, M.; Patel, R.; Li, W.; Clare, A. T. & Sharples, S. D. (2016), „Spatially resolved acoustic spectroscopy for selective laser melting“, *Journal of Materials Processing Technology*, 236, S. 93–102. <https://doi.org/10.1016/J.JMATPROTEC.2016.05.005>.

Spears & Gold 2016

Spears, T. G. & Gold, S. A. (2016), „In-process sensing in selective laser melting (SLM) additive manufacturing“, *Integrating Materials and Manufacturing Innovation*, 5(1), S. 16–40. <https://doi.org/10.1186/s40192-016-0045-4>.

Spierings & Levy 2009

Spierings, A. B. & Levy, G. (2009), „Comparison of density of stainless steel 316L parts produced with selective laser melting using different powder grades“. *Proceedings for the 2009 International Solid Freeform Fabrication Symposium*, S. 342–353, 03.08.2009 - 05.08.2009, Austin, Texas, USA.

Stroppe 2000

Stroppe, H. (2000), „Einfluss der Porosität auf die mechanischen Eigenschaften von Gusslegierungen“, *Giessereiforschung*, 52(2), S. 58–60.

Tao et al. 2023

Tao, Z.; Thanki, A.; Goossens, L.; Witvrouw, A.; Vrancken, B. & Dewulf, W. (2023), „Porosity Prediction in Selective Laser Melting Combining Photodiode-based In-Process Monitoring and X-CT“, *e-Journal of Nondestructive Testing*, 28(3). <https://doi.org/10.58286/27717>.

Thijs et al. 2010

Thijs, L.; Verhaeghe, F.; Craeghs, T.; van Humbeeck, J. & Kruth, J.-P. (2010), „A study of the microstructural evolution during selective laser melting of Ti–6Al–4V“, *Acta Materialia*, 58(9), S. 3303–3312. <https://doi.org/10.1016/j.actamat.2010.02.004>.

Todorov et al. 2018

Todorov, E. I.; Boulware, P. & Gaah, K. (2018), „Demonstration of array eddy current technology for real-time monitoring of laser powder bed fusion additive manufacturing process“. *Nondestructive Characterization and Monitoring of Advanced Materials, Aerospace, Civil Infrastructure, and Transportation XII*, Hrsg. P. J. Shull, SPIE, S. 40, 03.2018, Denver, United States. ISBN: 9781510616943.
<https://doi.org/10.1117/12.2297511>.

Trächtler & Gausemeier 2018

Trächtler, A. & Gausemeier, J. (2018), *Steigerung der Intelligenz mechatronischer Systeme*, Springer Berlin Heidelberg, Berlin, Heidelberg. ISBN: 9783662563915.

Vendra et al. 2020

Vendra, L.; Dobrowolski, T.; Linares, M. & Avagliano, A. (2020), „Industrialization Of Additive Manufacturing For Oil & Gas Through Process Control“. *Day 3 Wed, May 06, 2020*, OTC, 04.05.2020 - 07.05.2020, Houston, Texas, USA.
<https://doi.org/10.4043/30822-MS>.

Wang et al. 2022

Wang, W.; Ning, J. & Liang, S. Y. (2022), „Analytical prediction of keyhole porosity in laser powder bed fusion“, *The International Journal of Advanced Manufacturing Technology*, 119(11-12), S. 6995–7002. <https://doi.org/10.1007/s00170-021-08276-9>.

Wasmer et al. 2019

Wasmer, K.; Le-Quang, T.; Meylan, B. & Shevchik, S. A. (2019), „In Situ Quality Monitoring in AM Using Acoustic Emission: A Reinforcement Learning Approach“, *Journal of Materials Engineering and Performance*, 28(2), S. 666–672.
<https://doi.org/10.1007/S11665-018-3690-2>.

Wasmer et al. 2018

Wasmer, K.; Kenel, C.; Leinenbach, C. & Shevchik, S. A. (2018), „In Situ and Real-Time Monitoring of Powder-Bed AM by Combining Acoustic Emission and Artificial Intelligence“ in *Industrializing Additive Manufacturing - Proceedings of Additive Manufacturing in Products and Applications - AMPA2017*, Hrsg. M. Meboldt & C. Klahn, Springer International Publishing, Cham, S. 200–209.

Weiser et al. 2020

Weiser, L.; Batschkowski, M.; Eschner, N.; Häfner, B.; Neubauer, I.; Gering, M.;

Schmidt, M. & Lanza, G. (2020), „AM-Serienproduktion für die Automobilindustrie/AM series production for the automotive industry“, *wt Werkstattstechnik online*, 110(11-12), S. 752–757. <https://doi.org/10.37544/1436-4980-2020-11-12-16>.

Weiser et al. 2023

Weiser, L.; Batschkowski, M.; Eschner, N.; Landgräber, T.; Ohlsen, F.; Seiz, S. & Lanza, G. (2023), „Quality Control in L-PBF for Industrial Production by means of Production Integrated Measurement Technology“ in *Springer Handbook of Additive Manufacturing*, Hrsg. E. Pei, A. Bernard, D. Gu, C. Klahn, M. Monzon, M. Petersen & T. Sun, Springer International Publishing, Cham.

Westkämper & Schloske 2020

Westkämper, E. & Schloske, A. (2020), „Fertigungs- und Fabrikbetrieb“ in *Dubbel Taschenbuch für den Maschinenbau 2: Anwendungen*, Hrsg. B. Bender & D. Göhlich, Springer Berlin Heidelberg, Berlin, Heidelberg, S. 997–1045.

Wits et al. 2016

Wits, W. W.; Carmignato, S.; Zanini, F. & Vaneker, T. H. (2016), „Porosity testing methods for the quality assessment of selective laser melted parts“, *CIRP Annals*, 65(1), S. 201–204. <https://doi.org/10.1016/j.cirp.2016.04.054>.

Yadroitsev et al. 2010

Yadroitsev, I.; Gusarov, A.; Yadroitsava, I. & Smurov, I. (2010), „Single track formation in selective laser melting of metal powders“, *Journal of Materials Processing Technology*, 210(12), S. 1624–1631. <https://doi.org/10.1016/j.jmatprotec.2010.05.010>.

Yang et al. 2019

Yang, L.; Zhicong, P.; Ming, L.; Yonggang, W.; Di, W.; Changhui, S. & Shuxin, L. (2019), „Investigation into the dynamic mechanical properties of selective laser melted Ti-6Al-4V alloy at high strain rate tensile loading“, *Materials Science and Engineering: A*, 745, S. 440–449. <https://doi.org/10.1016/j.msea.2019.01.010>.

Ye et al. 2018

Ye, D.; Hong, G. S.; Zhang, Y.; Zhu, K. & Fuh, J. Y. H. (2018), „Defect detection in selective laser melting technology by acoustic signals with deep belief networks“, *The International Journal of Advanced Manufacturing Technology*, 96(5-8), S. 2791–2801. <https://doi.org/10.1007/S00170-018-1728-0>.

Zenzinger et al. 2014

Zenzinger, G.; Bamberg, J.; Henkel, B.; Hess, T. & Ladewig, A. (2014), „Online-Prozesskontrolle bei der additiven Fertigung mittels Laserstrahlschmelzen“, *ZfP-Zeitung 140*, S. 51–54. <https://www.ndt.net/search/docs.php3?id=18213>.

Zhang et al. 2017

Zhang, B.; Li, Y. & Bai, Q. (2017), „Defect Formation Mechanisms in Selective Laser Melting: A Review“, *Chinese Journal of Mechanical Engineering*, 30(3), S. 515–527. <https://doi.org/10.1007/s10033-017-0121-5>.

Abbildungsverzeichnis

Abbildung 2-1: Prinzipieller Prozessablauf des PBF-LB/M Verfahrens – eigene Darstellung nach (Bremen et al. 2012)	6
Abbildung 2-2: Vereinfachter exemplarischer Aufbau einer PBF-LB/M Anlage – eigene Darstellung	7
Abbildung 2-3: Ishikawa-Diagramm für den PBF-LB/M Prozess – eigene Darstellung nach (Spears & Gold 2016)	8
Abbildung 2-4: Prozessdynamik durch unterschiedliches Schmelzbadverhalten bei konstantem Energieeintrag – eigene Darstellung nach (Ahn 2019)	9
Abbildung 2-5: Mögliche Belichtungsstrategien im PBF-LB/M Prozess – eigene Darstellung nach (Klahn 2015)	10
Abbildung 2-6: Anschauliche Darstellung der Zerklüftung s von Poren – eigene Darstellung nach (Rehse et al. 2016)	12
Abbildung 2-7: Zugfestigkeit von 316L in Abhängigkeit der Porosität und Zerklüftung s der Poren – eigene Darstellung	12
Abbildung 2-8: Qualitätssicherungssystem im Qualitätsregelkreis – eigene Darstellung nach (Lanza et al. 2019)	13
Abbildung 2-9: Schematische Darstellung der Integrationsgrade von Messtechnik - eigene Darstellung nach (Lanza et al. 2019)	13
Abbildung 2-10: Kosteneinsparung durch in-process Qualitätssicherung – eigene Darstellung nach (Lanza et al. 2019; Schmidt & Damm 2008)	15
Abbildung 2-11: Schematische Darstellung einer Messkette – eigene Darstellung nach (Czichos & Daum 2020)	16
Abbildung 2-12: Beispielhaftes Signal (a) sowie Realteil der Fourier-Transformation des Signals (b)	20
Abbildung 2-13: Schematischer Aufbau eines künstlichen Neurons mit Gewichten w_i , Bias b und Aktivierungsfunktion f – eigene Darstellung nach (Krogh 2008)	22
Abbildung 2-14: Beispielhafte Faltungsoperation in einer Faltungsschicht bei einem CNN mit einem 3x3 Kernel – eigene Darstellung nach (Albawi et al. 2017)	23

Abbildung 2-15: Beispielhafte Anwendung einer 2x2 Max-Pooling Operation bei einem CNN – eigene Darstellung nach (Albawi et al. 2017)	24
Abbildung 2-16: Konfusionsmatrix mit Fehler erster Ordnung (FP) und Fehler zweiter Ordnung (FN) – eigene Darstellung nach (Luque et al. 2019)	25
Abbildung 2-17: Exemplarische ROC-Kurve mit realem Modell (blau), perfektem Modell (rot) und zufälligem Modell (grün) – eigene Darstellung nach (Mandrekar 2010)	27
Abbildung 3-1: Prinzipieller Aufbau von on-axis Prozessüberwachungen – eigene Darstellung	33
Abbildung 3-2: Prinzipieller Aufbau von off-axis Prozessüberwachungen – eigene Darstellung	36
Abbildung 5-1: Struktureller Ablauf des eigenen Ansatzes	54
Abbildung 5-2: Komponenten im Bauraum der Realizer SLM125 – eigene Darstellung	55
Abbildung 5-3: Komponenten im optischen Pfad der Realizer SLM125 – eigene Darstellung	56
Abbildung 5-4: Vereinfachtes Kommunikationsmodell der Anlage Realizer SLM125 – eigene Darstellung	56
Abbildung 5-5: Körperschallsensor der Firma QASS, welcher unter der Bauplattform verschraubt wird.	59
Abbildung 5-6: Schaltbild eines Transimpedanzverstärkers – eigene Darstellung nach (Ferrari et al. 2009; Razavi 2019)	61
Abbildung 5-7: (a) Fotodiodenarray im Bauraum (grün eingefärbt), (b) Transimpedanzverstärker mit angeschlossener Sensorik, (c) Messgrößenaufnehmer auf Basis eines STM32-Microcontrollers	62
Abbildung 5-8: Technische Zeichnung der Probekörpergeometrie (alle Maße in mm).	69
Abbildung 5-9: CT-Marker für Registrierung mit eingetragenem xyz-Bauteilkoordinatensystem <i>KOSBauteil</i>	70
Abbildung 5-10: Anordnung der Probekörper und Belichtungsreihenfolge in den Druckjobs 1-4	72

Abbildung 5-11: Vorgehen zur Validierung der Referenzmesstechnik	74
Abbildung 5-12: (a) Technische Zeichnung der Schliffbild-Probekörper sowie (b) Bild von zwei gefertigten Probekörpern – Bildquelle: Leonard Schild (wbk)	75
Abbildung 5-13: Gegenüberstellung des (a) realen Schliffbilds und des (b) virtuellen Schliffbilds aus dem Computertomographen	81
Abbildung 5-14: Exemplarische Pore im (a) realen Schliffbild und im (b) virtuellen Schliff gegenübergestellt.	81
Abbildung 5-15: Boxplot der (a) Porenfläche und (b) Zirkularität in realem Schliffbild	82
Abbildung 5-16: Anteile der im virtuellen Schliffbild nicht erkannten Poren	83
Abbildung 5-17: Porenerkennungsrate als Funktion der Voxelgröße	84
Abbildung 5-18: Porenfläche der nicht im virtuellen Schliffbild erkannten Poren	85
Abbildung 5-19: Abweichung der Porenfläche von im virtuellen Schliffbild erkannten Poren zum realem Schliffbild	85
Abbildung 5-20: Zirkularität der nicht im virtuellen Schliffbild erkannten Poren	86
Abbildung 5-21: Abweichung der Zirkularität von im virtuellen Schliffbild erkannten Poren zum realem Schliffbild	87
Abbildung 5-22: Definiertes Bauteilkoordinatensystem <i>KOSBauteil</i> des Probekörpers nach Registrierung im CT	90
Abbildung 5-23: Probekörper mit definierten Einheitszellen (rot) in der ROI dargestellt in VGStudio Max	91
Abbildung 5-24: Vorgehen zur Datenanalyse mit den einzelnen Schritten S1-S793	
Abbildung 5-25: Darstellung der verschiedenen Koordinatensysteme mit schematischer Bauplatzform (gestrichelt dargestellt) und exemplarischem Probekörper	95
Abbildung 5-26: Exemplarischer Sensordatenverlauf des Fotodiodenarrays für ein Bauteil in einer Schicht für den (a) Laser und (b) das sichtbare Spektrum.	97
Abbildung 5-27: Rohsignal des Körperschalls im Zeitbereich	98
Abbildung 5-28: Spektrogramm der Kurzzeit-Fourier-Transformation des Körperschallsignals (a) und resultierender Verlauf der Gesamtintensität (b)	98

Abbildung 5-29: (a) Reihenfolge der Nummerierung von Einheitszellen in einer Schicht und (b) Segmentierung des Scanvektors (vereinfacht dargestellt) einer Schicht in die Einheitszellen	99
Abbildung 5-30: Einteilung der Einheitszellen in Rand-, Eck- und Innenzellen	100
Abbildung 5-31: Exemplarische Darstellung des FFT-Segment-Merkmals für eine Einheitszelle	102
Abbildung 5-32: Exemplarische Darstellung des FFT-Segment-Resized Merkmals für eine Einheitszelle	105
Abbildung 5-33: Exemplarische Darstellung des FFT-Segment-Reduced Merkmals für eine Einheitszelle	106
Abbildung 5-34: relative Häufigkeiten der Zellporosität auf Basis der Referenzmessung mittels Computertomographie	108
Abbildung 6-1: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 1	112
Abbildung 6-2: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 2	112
Abbildung 6-3: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 3	113
Abbildung 6-4: Verteilung der Gesamtporosität der Probekörper auf der Bauplattform in Druckjob 4	113
Abbildung 6-5: Boxplots der Porosität der Einheitszellen je Probekörper sowie Aufteilung der Probekörper in Trainingsdaten (blau) und Testdaten (rot)	114
Abbildung 6-6: Konfusionsmatrix für (a) Modell mit maximaler Kompression und (b) mit randomisiertem Label	116
Abbildung 6-7: ROC-Kurve für Modell mit randomisiertem Label	117
Abbildung 6-8: Konfusionsmatrizen bei der Porositätsklassifikation durch (a) MLP und (b) CNN für die akustischen Körperschalldaten	119
Abbildung 6-9: ROC-Kurven der Modelle zur Klassifikation der Einheitszellenporosität auf Basis der akustischen Körperschalldaten	120

Abbildung 6-10: Schnittansichten zum qualitativen Vergleich der Vorhersagequalität der Porositätsklassen mittels CNN - a) Probekörper 10, b) Probekörper 41 und c) Probekörper 89	121
Abbildung 6-11: Schnittansichten der Probekörper mit nicht zufriedenstellender Modellperformance – a) Probekörper 7 und b) Probekörper 69	122
Abbildung 6-12: Veränderung der Klassenverteilung bei veränderter Klassengrenze	123
Abbildung 6-13: Verlauf von F1-Score und MCC bei veränderter Klassengrenze	124
Abbildung 6-14: ROC-Kurve für CNN-Modelle mit veränderten Klassengrenzen	125
Abbildung 6-15: Vergleich der Konfusionsmatrizen von (a) normalem Modell und (b) ROC-optimiertem Modell	126
Abbildung 6-16: Konfusionsmatrizen bei der Porositätsklassifikation durch (a) MLP und (b) CNN für die optischen Daten	128
Abbildung 6-17: ROC-Kurven der Modelle zur Klassifikation der Einheitszellenporosität auf Basis der optischen Daten	128
Abbildung 6-18: Schnittansichten zum qualitativen Vergleich der Vorhersagequalität der Porositätsklassen mittels CNN für optische Daten – a) Probekörper 12 und b) Probekörper 22	129
Abbildung 6-19: ROC-Kurven zum Vergleich von MLP und CNN für optische Daten und Körperschalldaten	130
Abbildung 6-20: Vorhergesagte vs. Tatsächliche Porosität bei der Porositätsregression durch (a) MLP und (b) CNN auf Basis der akustischen Körperschalldaten	132
Abbildung 6-21: Schnittansichten zum qualitativen Vergleich der Vorhersagequalität der Porositätsregression mittels CNN für akustische Körperschalldaten – a) Probekörper 86, b) Probekörper 7 und c) Probekörper 18	133
Abbildung 6-22: Vorhergesagte vs. Tatsächliche Porosität bei der Porositätsregression durch (a) MLP und (b) CNN auf Basis der optischen Daten des Fotodiodenarrays	135
Abbildung 6-23: Schnittansichten zum qualitativen Vergleich der Vorhersagequalität der Porositätsregression mittels MLP für optische Daten des Fotodiodenarrays – a) Probekörper 10, b) Probekörper 69 und c) Probekörper 86	136

Abbildung 6-24: (a) F1-Score und (b) MCC zur Untersuchung der Modellübertragbarkeit auf andere Druckjobs	138
Abbildung 6-25: Klassenverteilung der Testdatensätze von Druckjob 1 (a) bis Druckjob 4 (d)	139
Abbildung 6-26: Modellstruktur zur Datenfusion	140
Abbildung 6-27: ROC-Kurven zum Vergleich der kombinierten Modelle für die Datenfusion	141
Abbildung 6-28: Konfusionsmatrizen der reinen CNNs zur Datenfusion mit (a) 0,25 % und (b) 1 % Zellporosität als Klassengrenze.	142
Abbildung 6-29: Konfusionsmatrizen des rein akustischen CNN mit 0,25 % Zellporosität als Klassengrenze (a) vor und (b) nach der ROC-Optimierung.	144

Tabellenverzeichnis

Tabelle 3-1: Zusammenfassung der betrachteten Forschungsansätze	52
Tabelle 5-1: Ausgewählte Fotodioden, um die gewünschten Wellenlängenbereiche λ aufzunehmen.	60
Tabelle 5-2: Optische Filter zur genauen Einstellung der aufgezeichneten Wellenlängenbereiche λ .	60
Tabelle 5-3: Parameterstufen zur serienfertigungsnahen Erzeugung von Porosität	67
Tabelle 5-4: Verwendete Prozessparameter zur Probenherstellung	71
Tabelle 5-5: Gewählte Einstellungen für die Erstellung der CT-Scans zur Schliffbildanalyse	77
Tabelle 5-6: Parameter des VGEasyPore-Algorithmus zur Porositätsanalyse	78
Tabelle 5-7: CT-Einstellungen der Referenzmessung mit Zeiss Metrotom 800 225kv HR	89
Tabelle 5-8: Parameter des VGEasyPore-Algorithmus zur Porositätsanalyse	92
Tabelle 5-9: Parameter der Funktion specgram aus Python zur Berechnung der Kurzzeit-Fourier-Transformation	101
Tabelle 5-10: Spezifikationen des verwendeten Rechners DGX-Station von Nvidia	103
Tabelle 5-11: Vorgehen zur Berechnung des Merkmals FFT-Segment-Reduced106	
Tabelle 6-1: Vergleich der Modellperformance zur Bewertung der angewandten Datenkomprimierung	115
Tabelle 6-2: Beste Modelltopologien zur Klassifikation der Zellporosität auf dem Gesamtdatensatz auf Basis der akustischen Körperschalldaten	118
Tabelle 6-3: Modellperformance des CNN bei veränderter Klassengrenzen zwischen 0,25 und 8 % Porosität der Einheitszellen	124
Tabelle 6-4: F1-Score und MCC für getrennte und kombinierte Betrachtung der drei Kanäle des Fotodiodenarrays mittels CNN	127

Tabelle 6-5: Beste Modelltopologien zur Klassifikation der Zellporosität auf dem Gesamtdatensatz auf Basis der optischen Daten des Fotodiodenarrays	127
Tabelle 6-6: Beste Modelltopologien zur Regression der Zellporosität auf dem Gesamtdatensatz auf Basis der Körperschalldaten	131
Tabelle 6-7: Beste Modelltopologien zur Regression der Zellporosität auf dem Gesamtdatensatz auf Basis der optischen Daten des Fotodiodenarrays	134
Tabelle 6-8: Klassifikationsperformance der verschiedenen Kombinationen von vortrainierten Modellen für die Datenfusion	140
Tabelle 6-9: Regressionsperformance der verschiedenen Kombinationen von vortrainierten Modellen für die Datenfusion	143

Anhang

A1 Materialdatenblatt Pulvercharge 316l



METALS FOR PRINTING

Werkzeugnis 3.1
Test Report 3.1
gemäß/per EN 10204

Datum/Date
11.05.2020

m4p material solutions GmbH
Mittelweg 13
39130 Magdeburg
Tel.: 0391/7235789
Fax.: 0391/7214941
email: sales@metals4printing.com

Kunde/Customer

Karlsruher Institut für Technologie - KIT

Ihre Bestell-Nr. vom/Your Order No.Dated

27199653

Liefermenge/Quantity Delivered

100kg

Artikelbezeichnung/ Item description

m4p™ 316l.02/ Artikel 70502

Auftragsnummer./ project no.

101405

Chargen-Nr./Charge-No.

17320106

Chemische Analyse in Gew.%

	C	Mo	Ni	Mn	Cr	Si	Fe
Ist	0,024	2,4	11,2	1,08	16,5	0,78	Basis
Min		2,0	10,5		16,0		Basis
Max	0,03	3,0	14,0	2,0	18,0	1,0	Basis

Siebanalyse

	+63µm	+53µm	-53µm +20µm	-20µm
Ist	0,00%	2,02%	90,79%	7,19%
Min				
Max	0,5%>63µm	4%		8%

Physikalische Daten

Füllichte	Fließzeit (Ø2,54mm)
4,39g/cm³	16,0s/50g

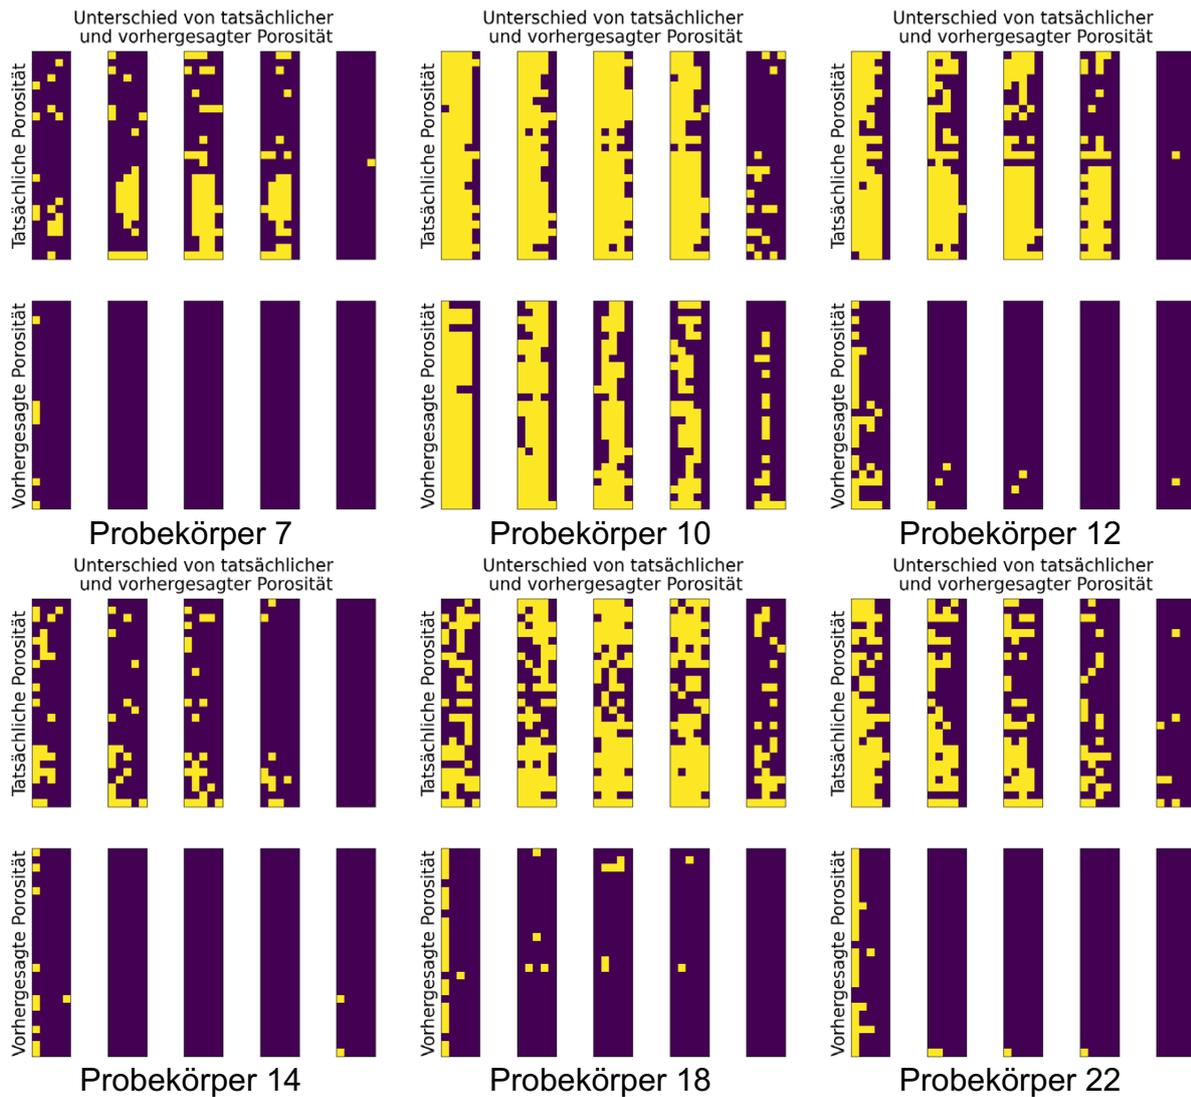
Bemerkungen/Remarks

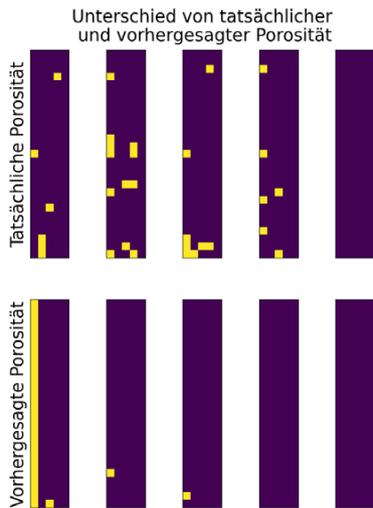


A2 Schnittansichten der Probekörper (Testdatensatz)

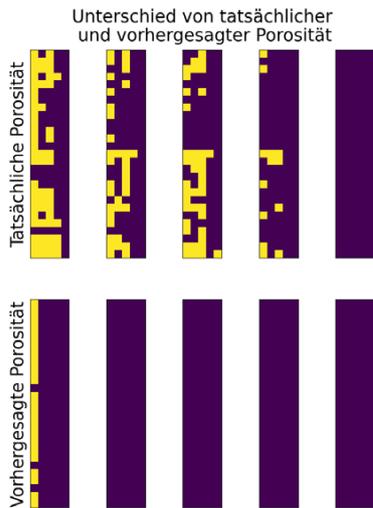
A2.1 Klassifikation Körperschall

Modellart: MLP, Klassengrenze 1 % Zellporosität, Testdatensatz

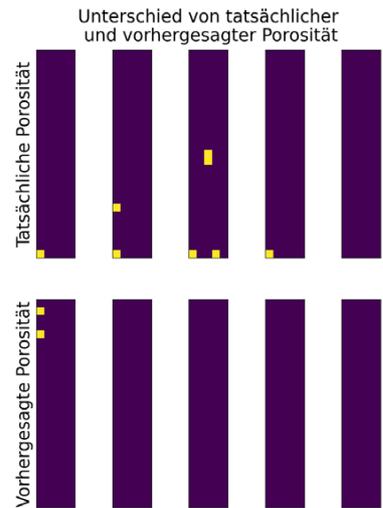




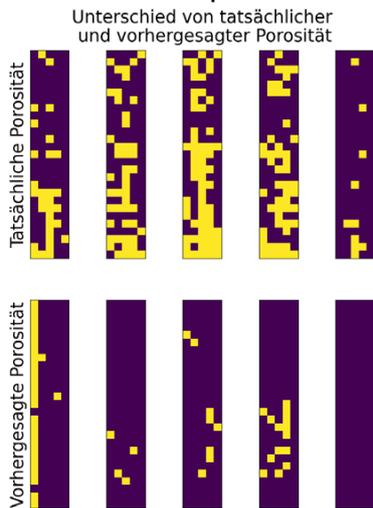
Probekörper 28



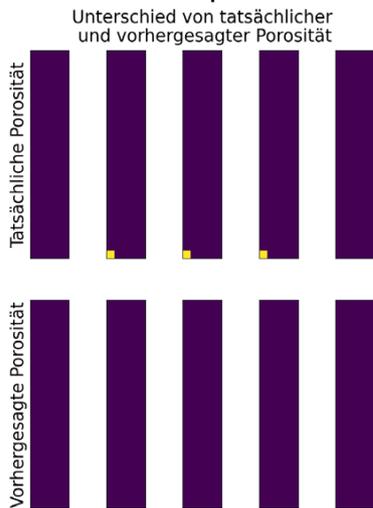
Probekörper 34



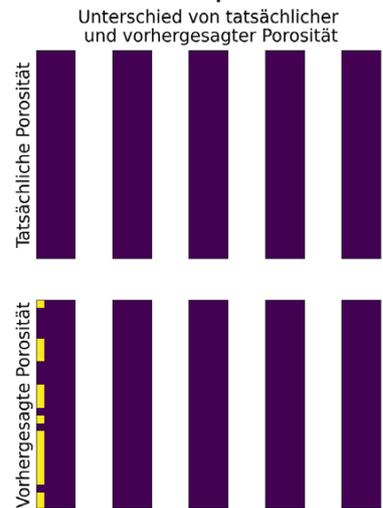
Probekörper 41



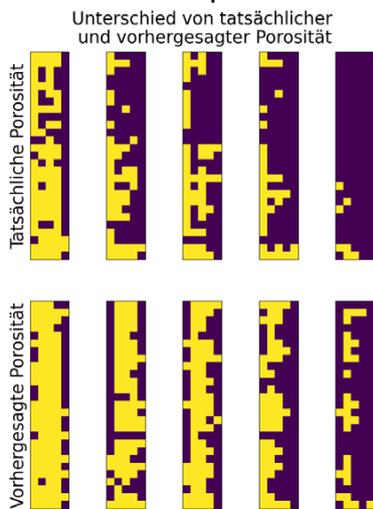
Probekörper 46



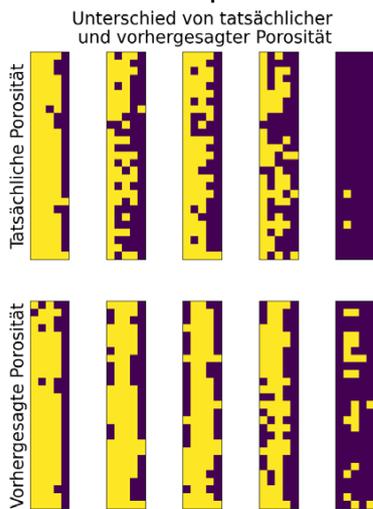
Probekörper 49



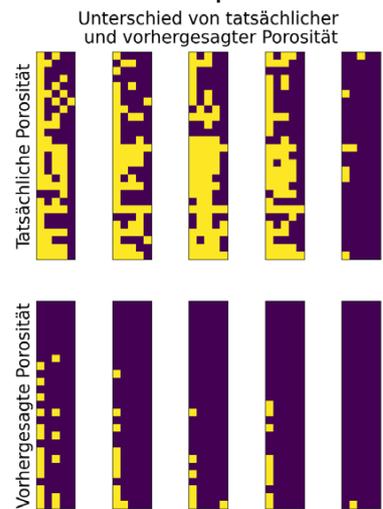
Probekörper 53



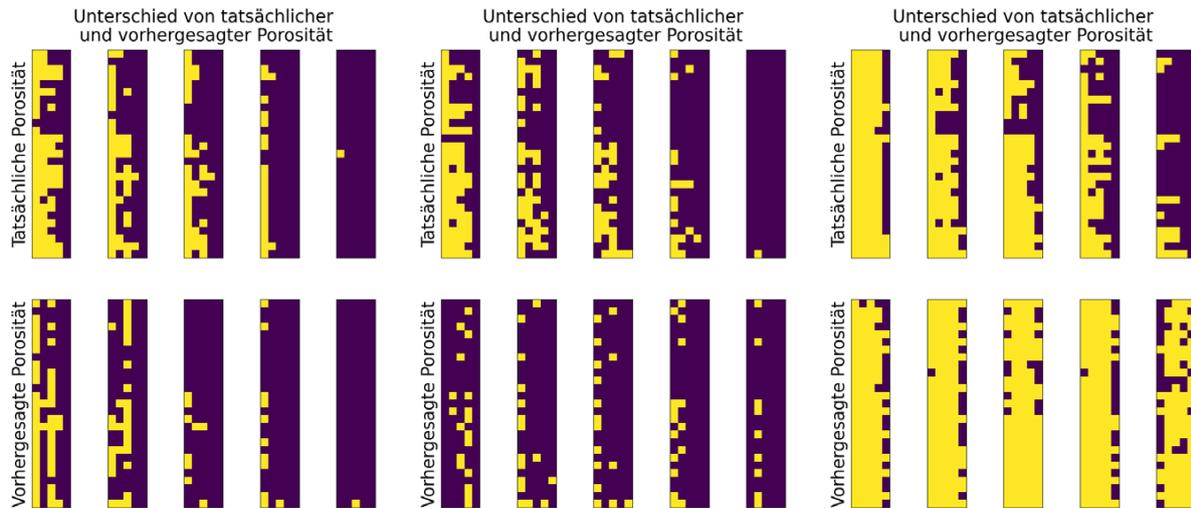
Probekörper 55



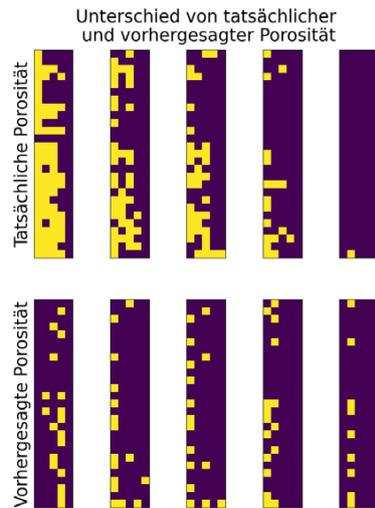
Probekörper 65



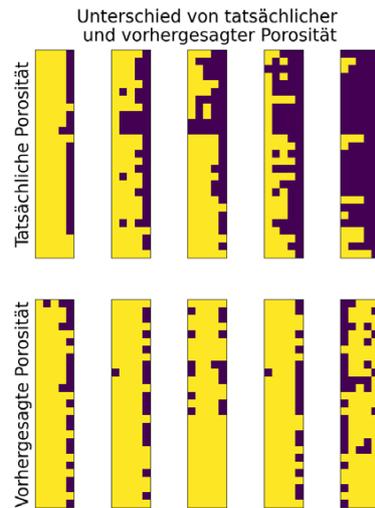
Probekörper 69



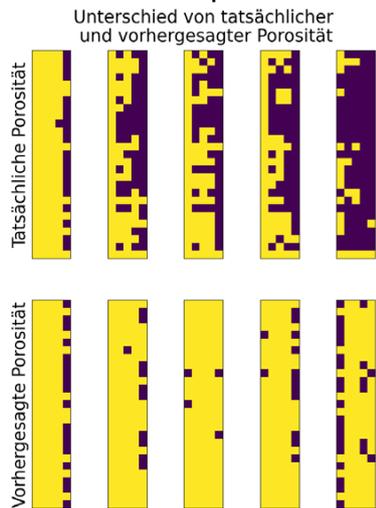
Probekörper 78



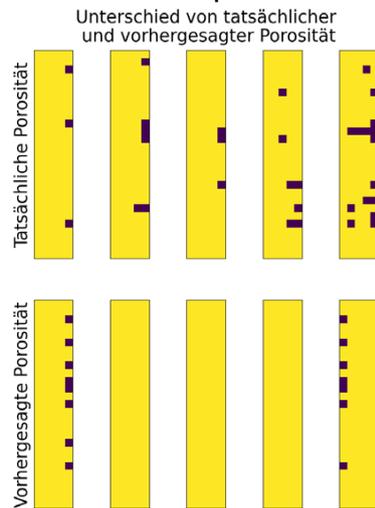
Probekörper 79



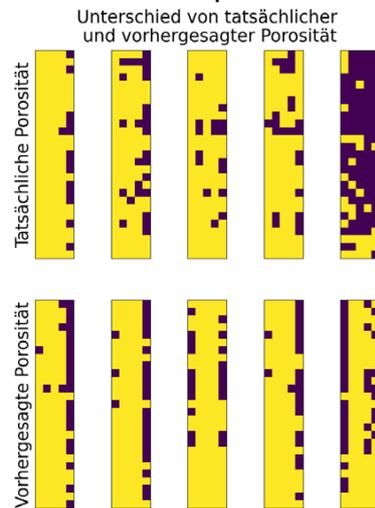
Probekörper 81



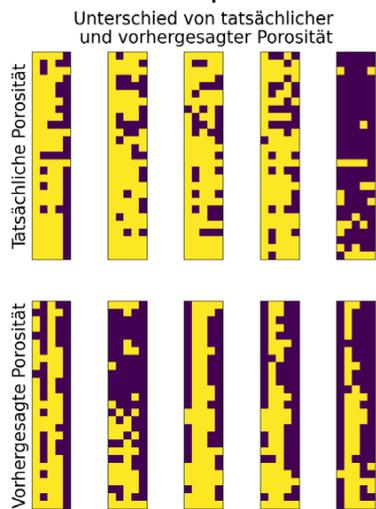
Probekörper 86



Probekörper 89

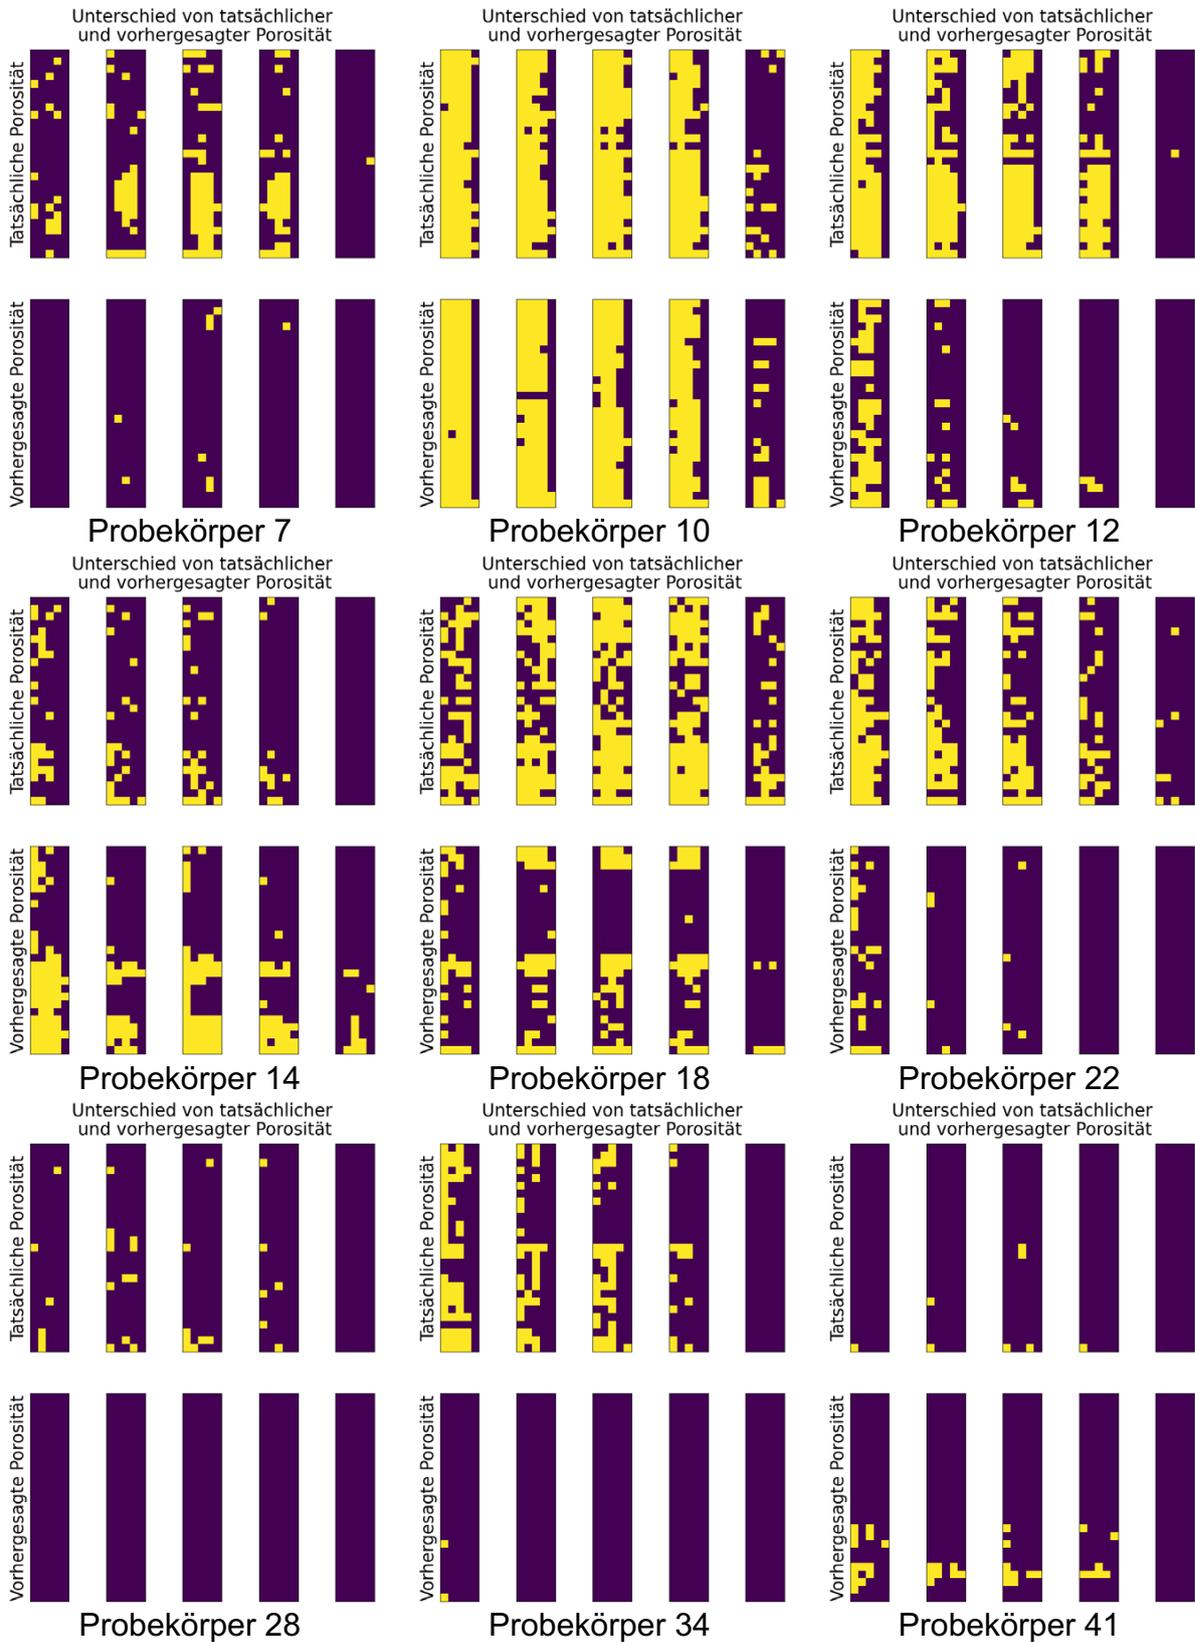


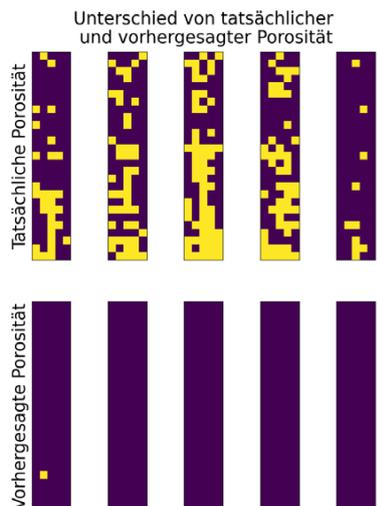
Probekörper 90



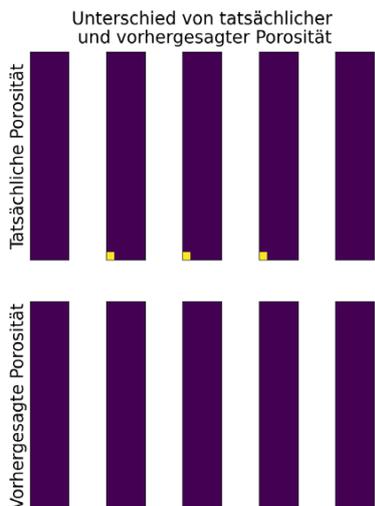
Probekörper 95

Modellart CNN, Klassengrenze 1 % Zellporosität, Testdatensatz

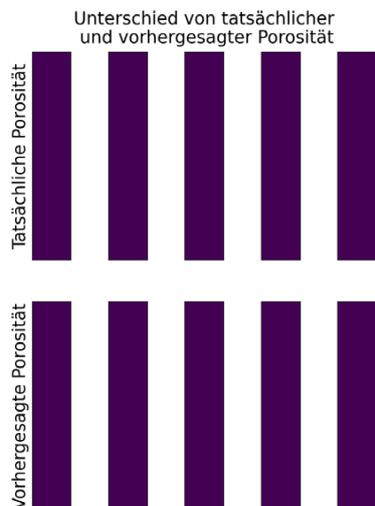




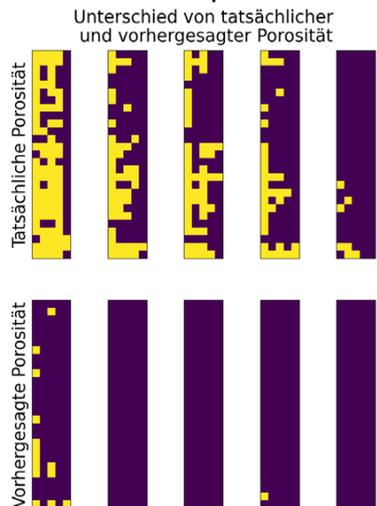
Probekörper 46



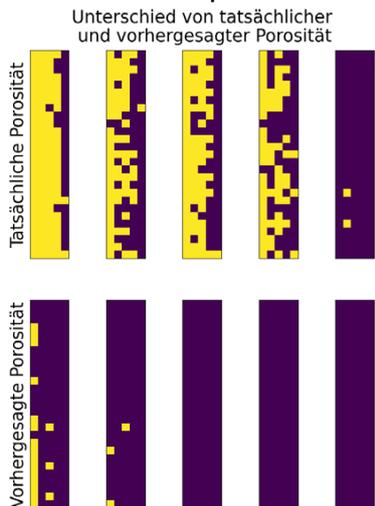
Probekörper 49



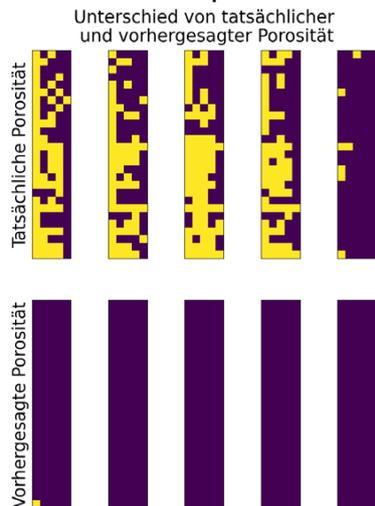
Probekörper 53



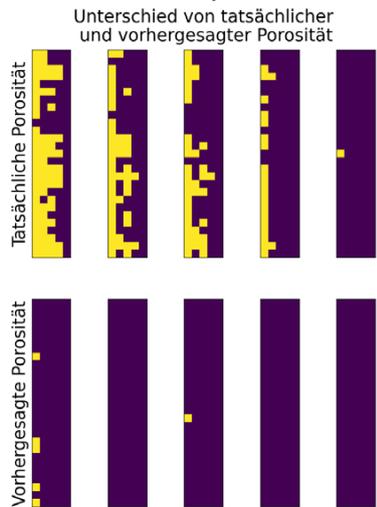
Probekörper 55



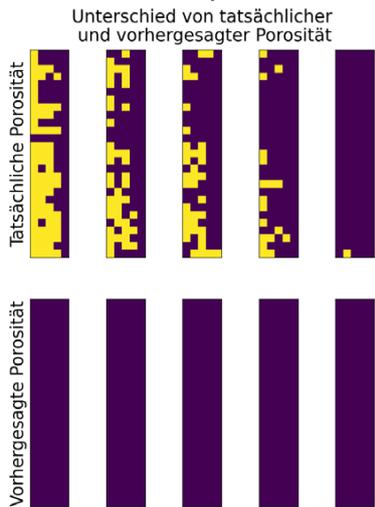
Probekörper 65



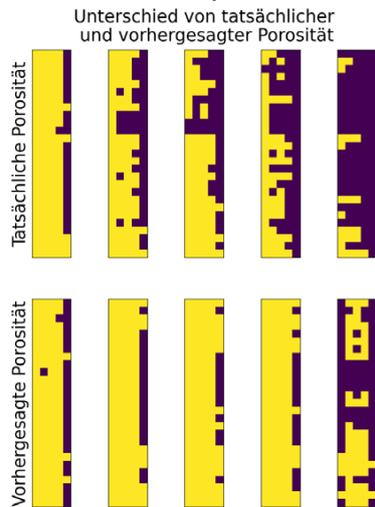
Probekörper 69



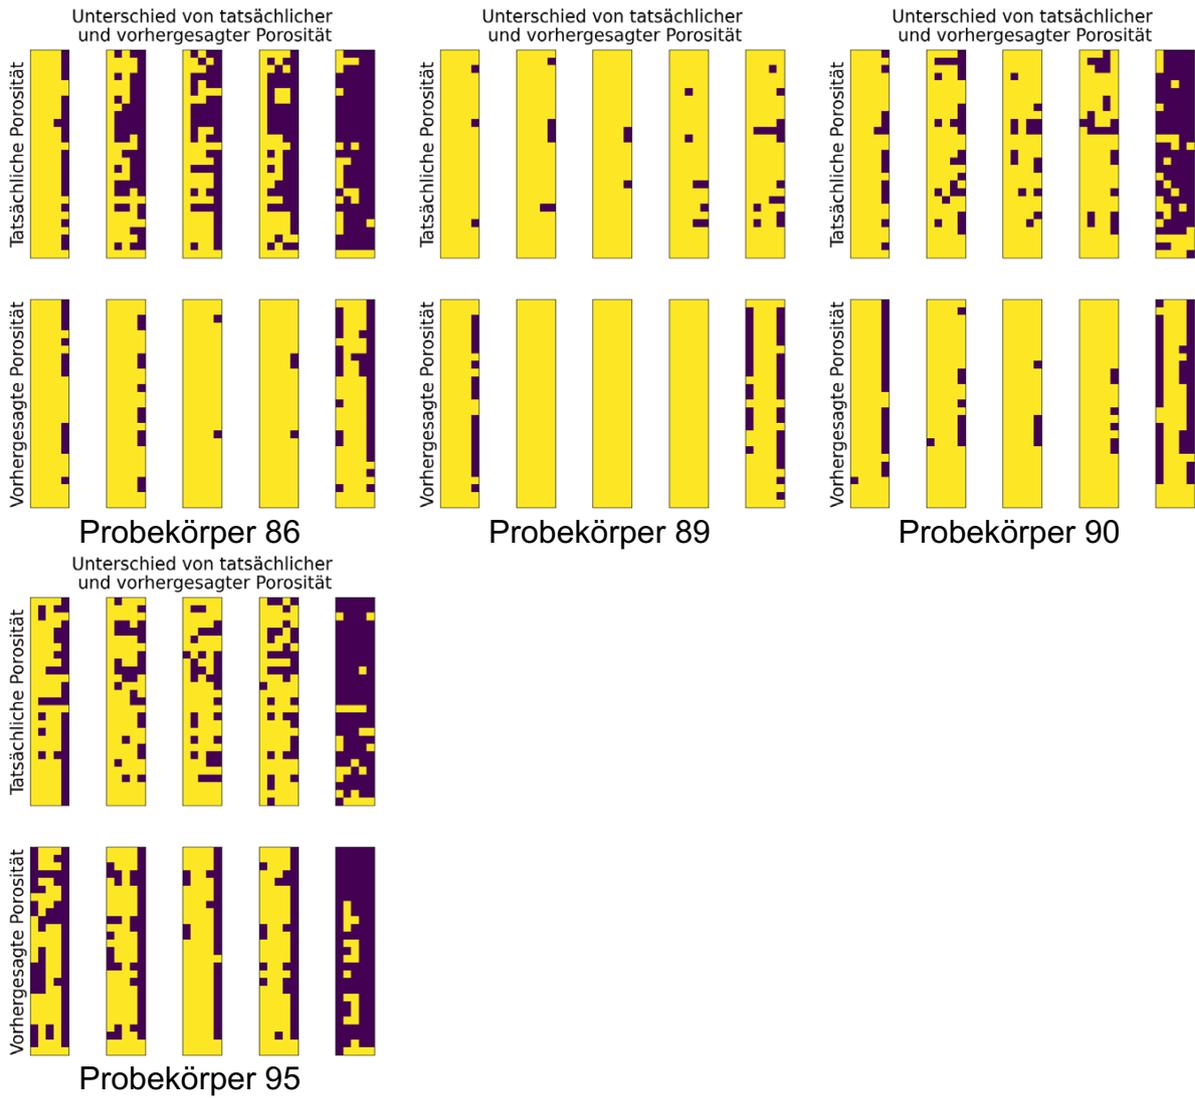
Probekörper 78



Probekörper 79

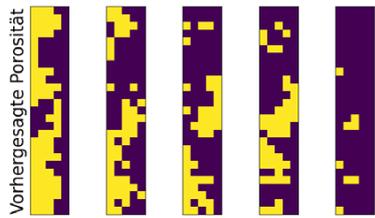
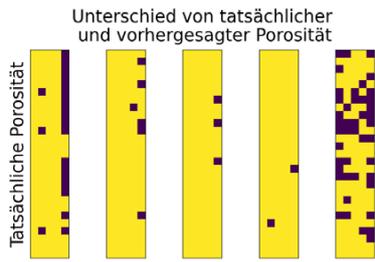


Probekörper 81

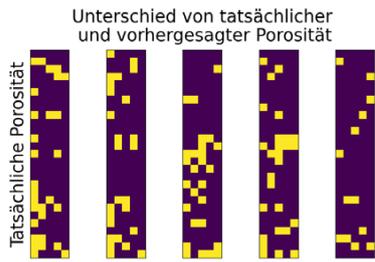


Modellart CNN, Klassengrenze 0,25 % Zellporosität, Testdatensatz

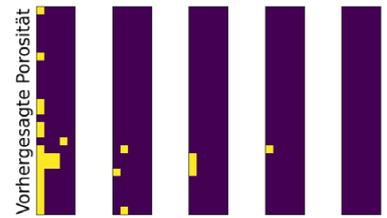
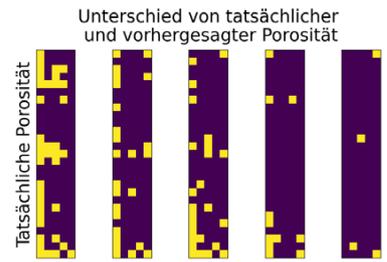




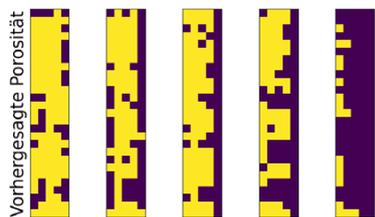
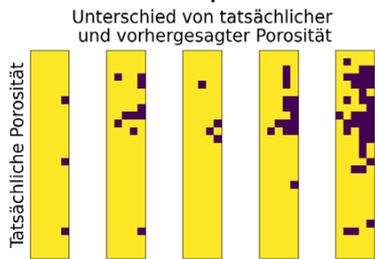
Probekörper 46



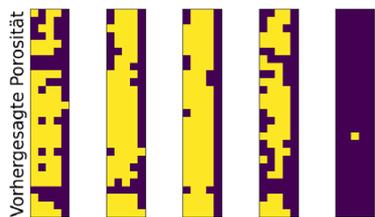
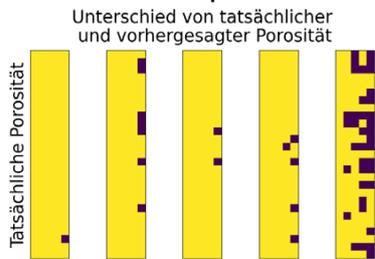
Probekörper 49



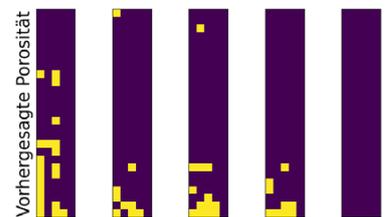
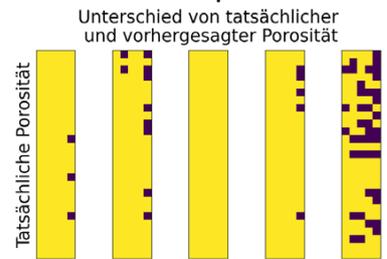
Probekörper 53



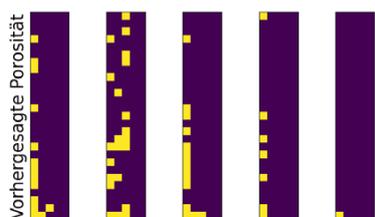
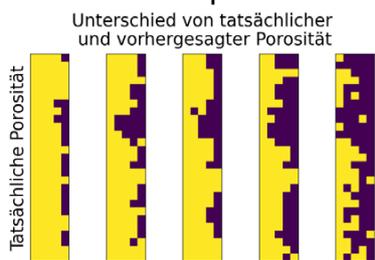
Probekörper 55



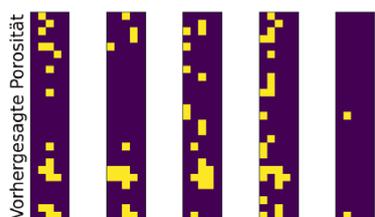
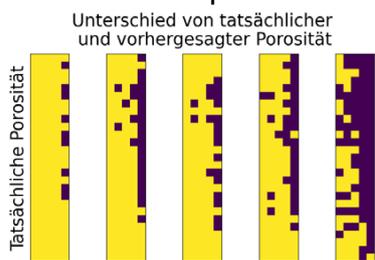
Probekörper 65



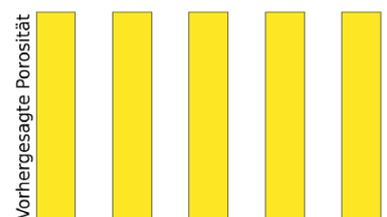
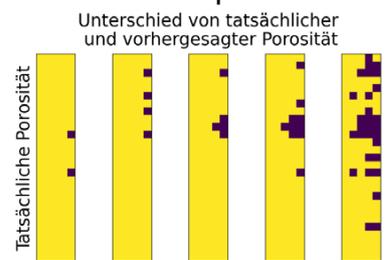
Probekörper 69



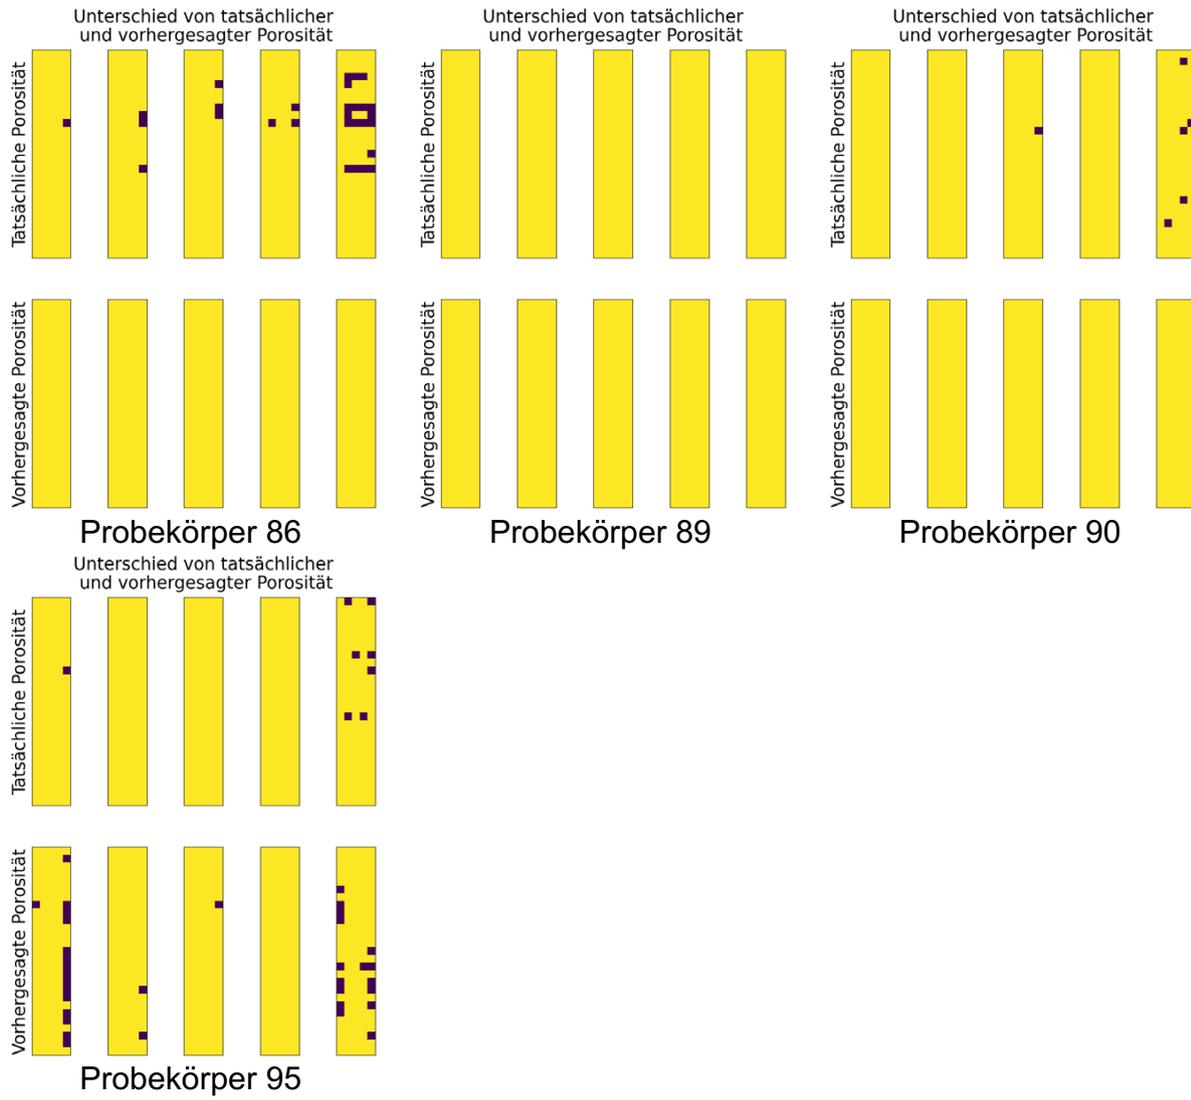
Probekörper 78



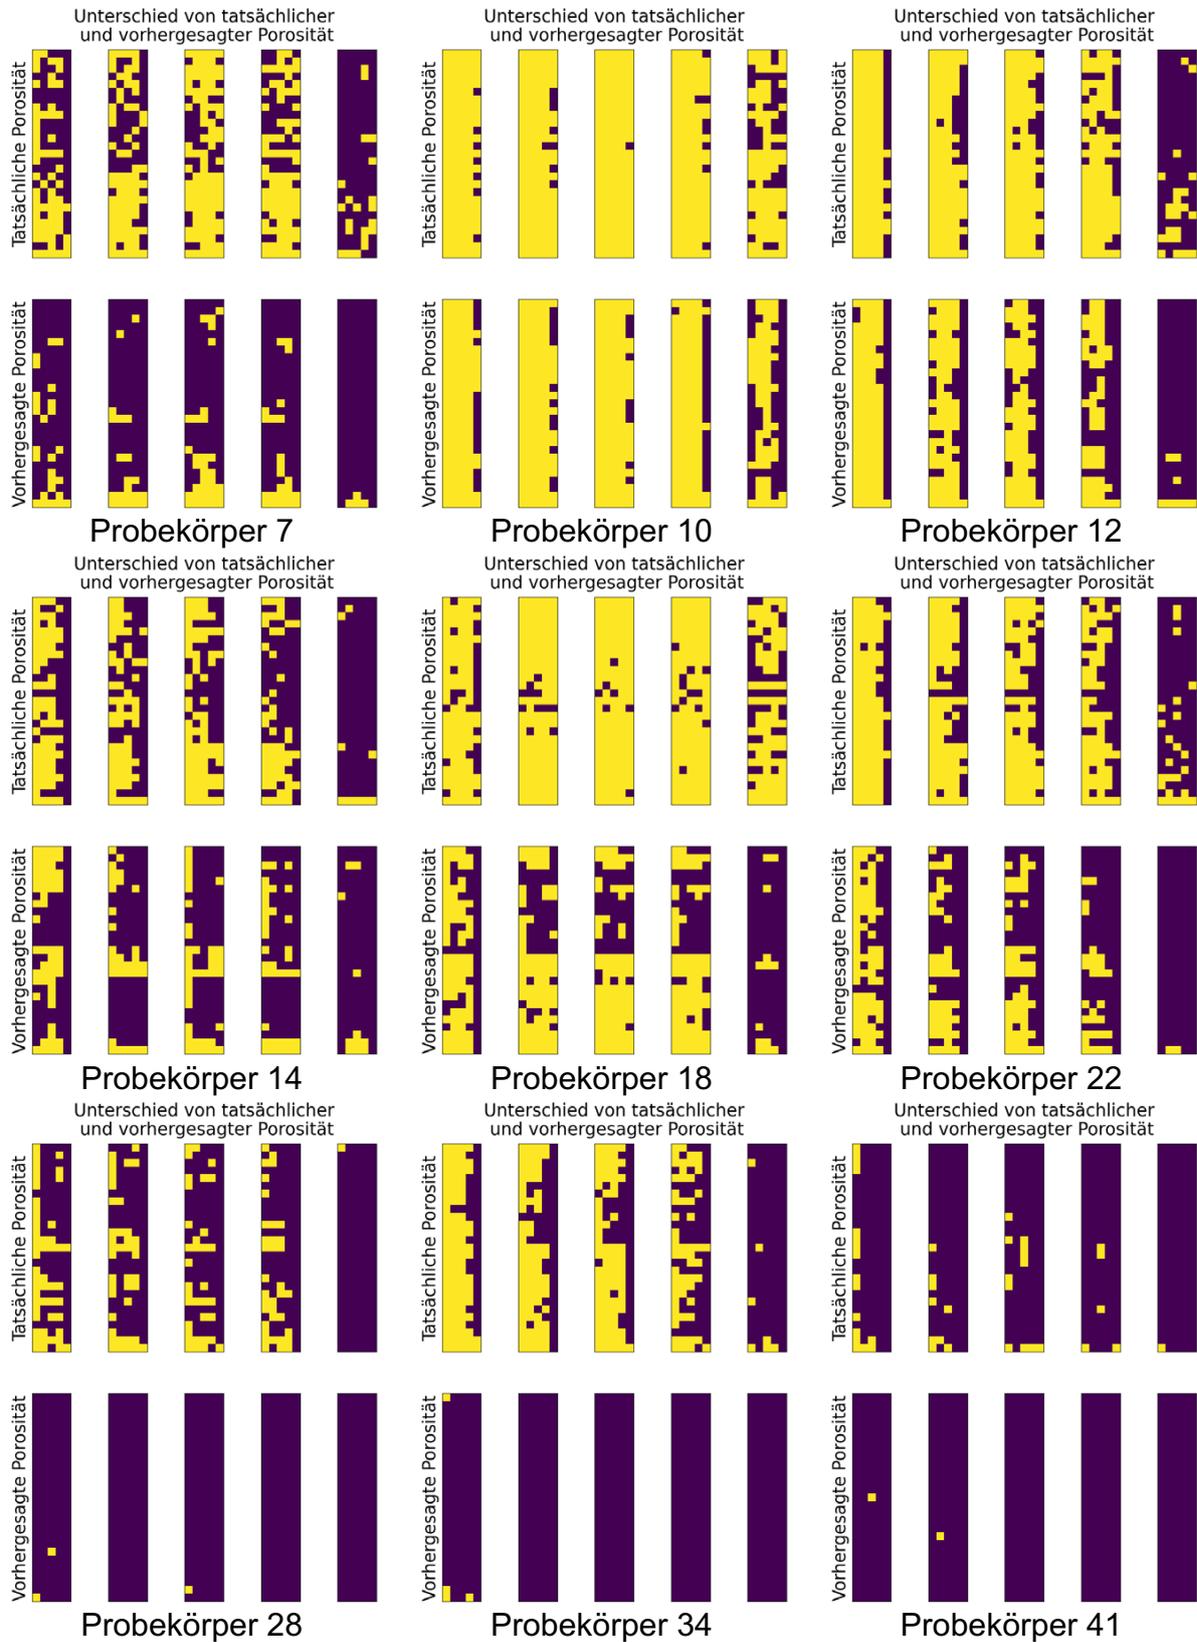
Probekörper 79

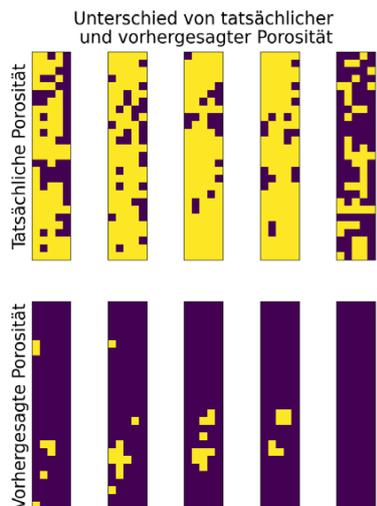


Probekörper 81

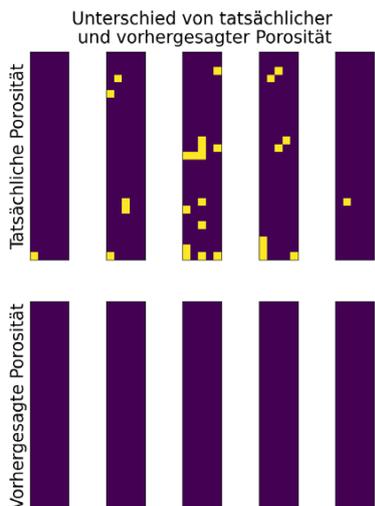


Modellart CNN, Klassengrenze 0,5 % Zellporosität, Testdatensatz

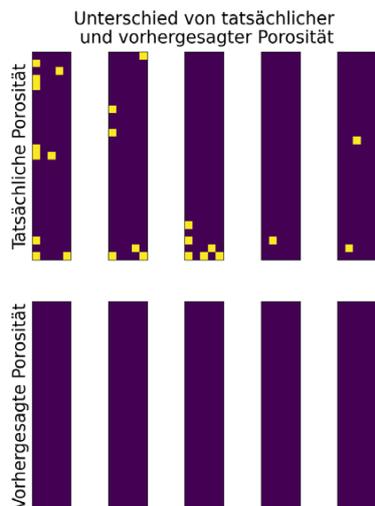




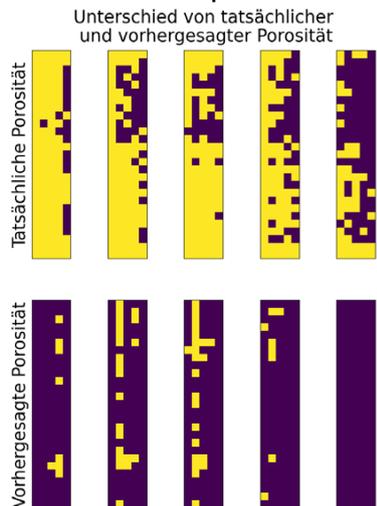
Probekörper 46



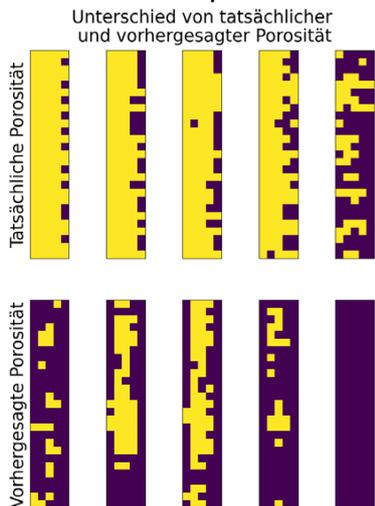
Probekörper 49



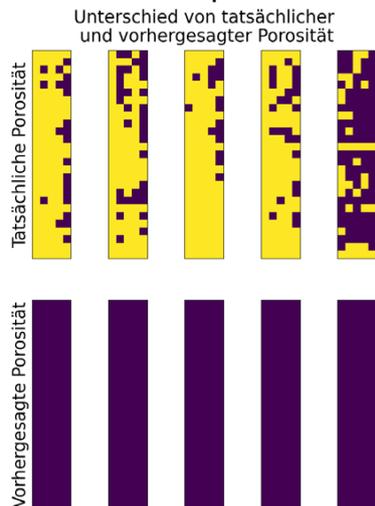
Probekörper 53



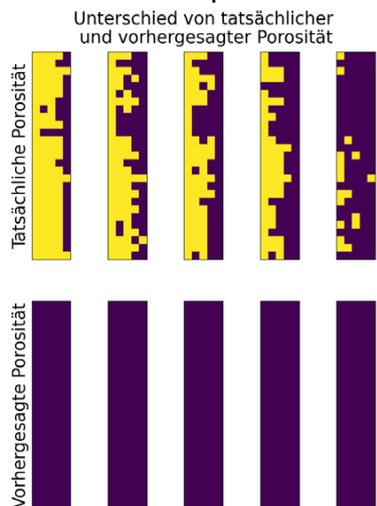
Probekörper 55



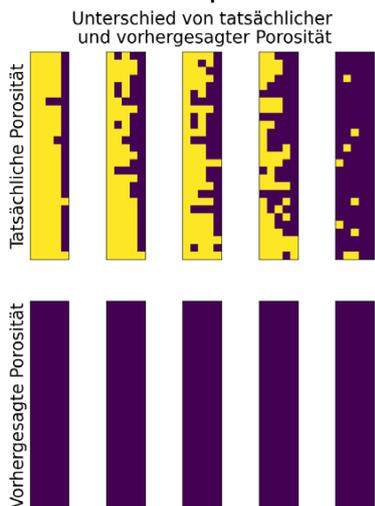
Probekörper 65



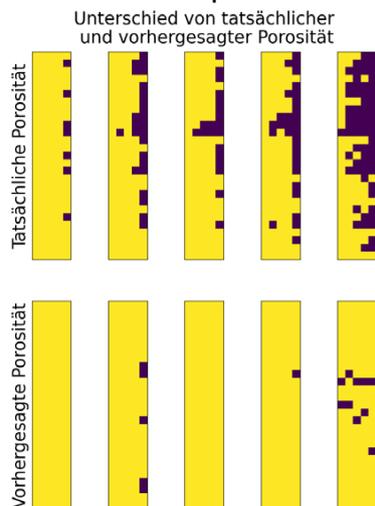
Probekörper 69



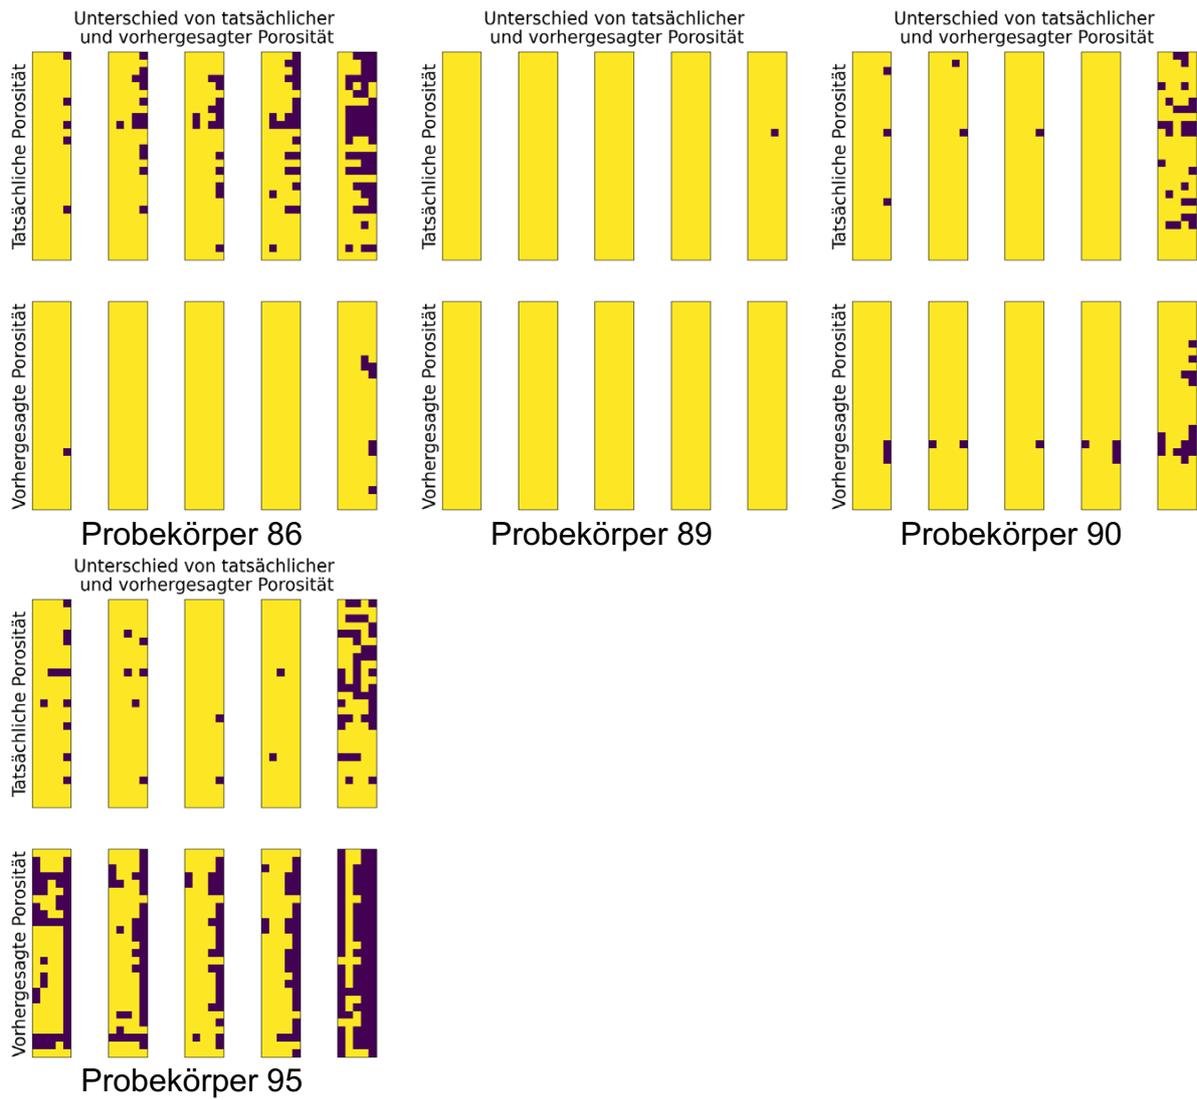
Probekörper 78



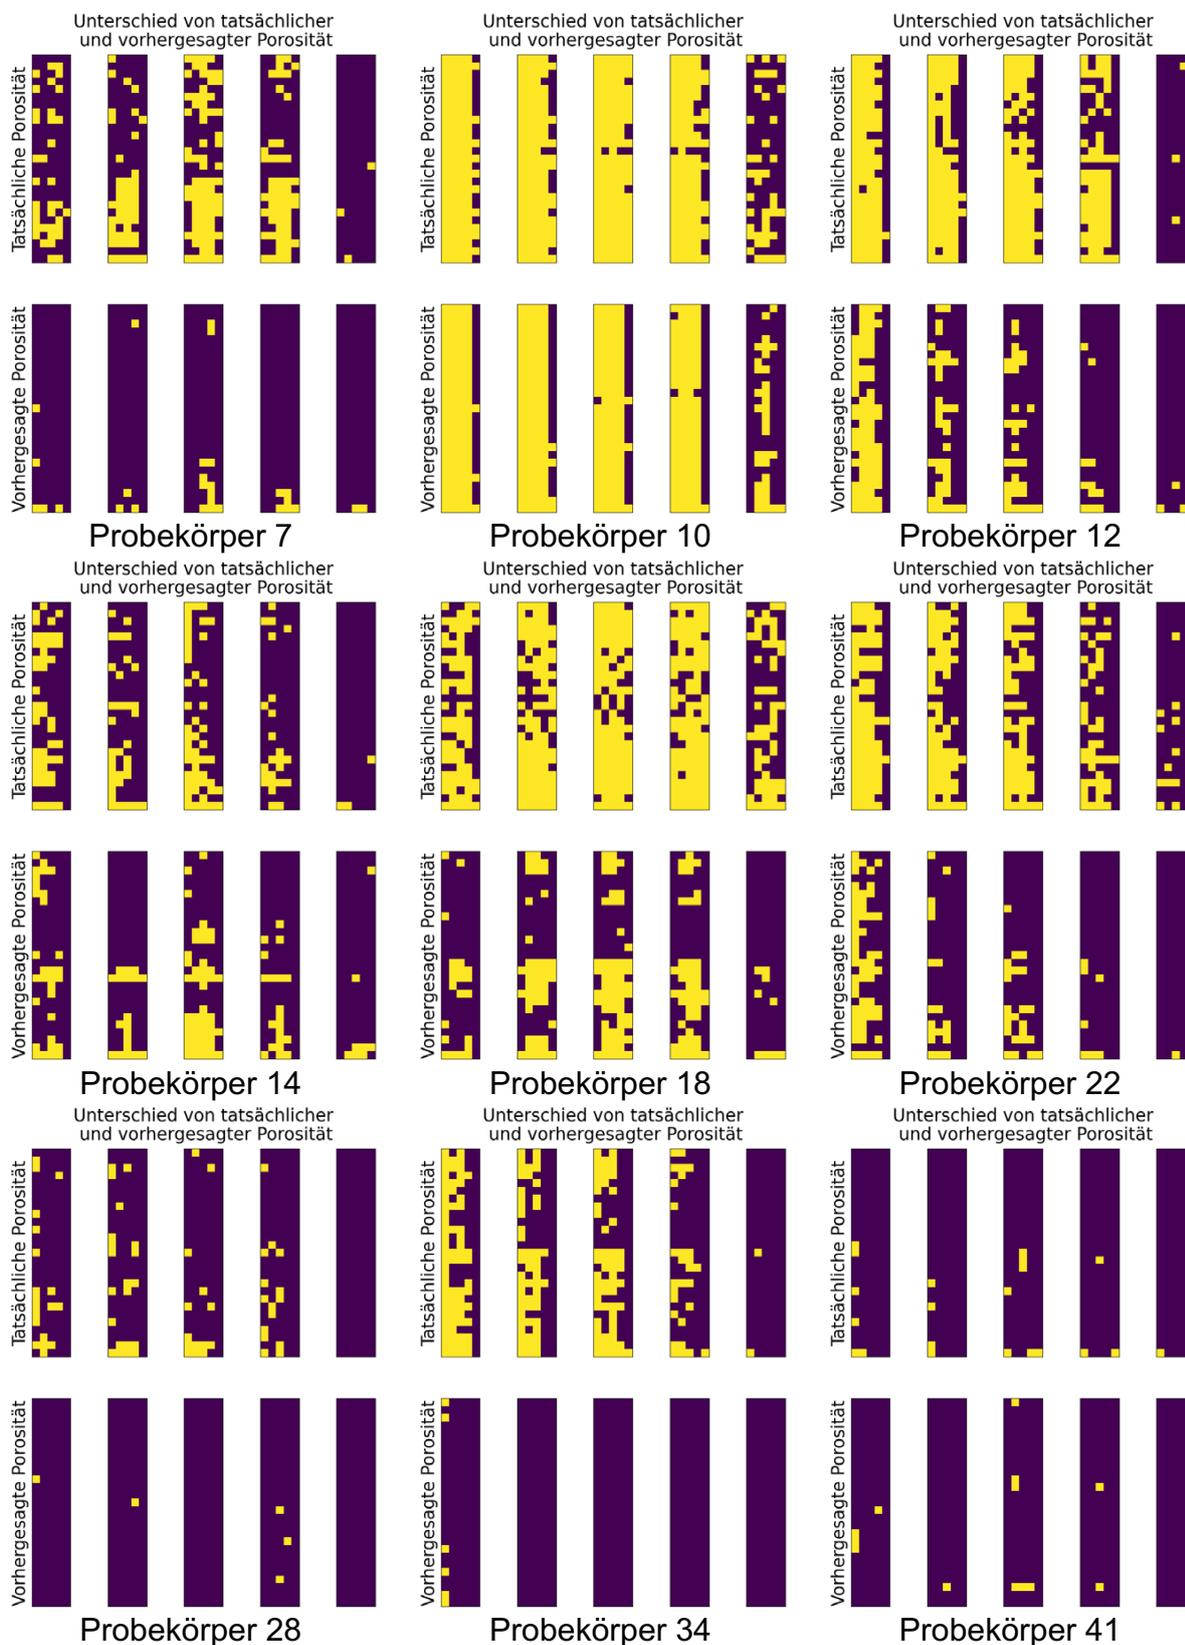
Probekörper 79

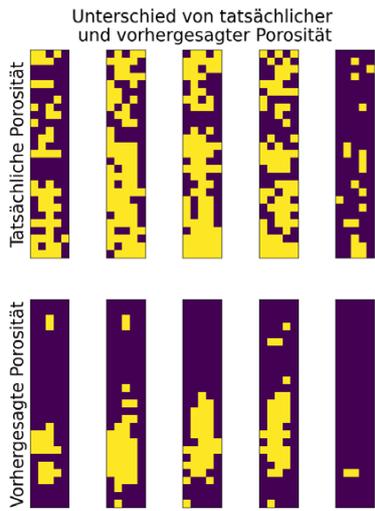


Probekörper 81

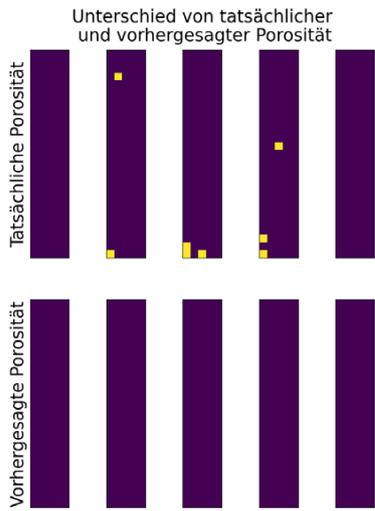


Modellart CNN, Klassengrenze 0,75 % Zellporosität, Testdatensatz

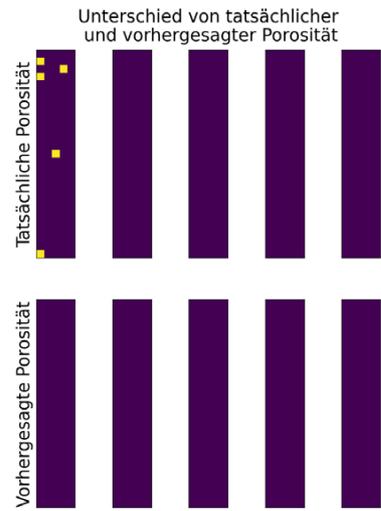




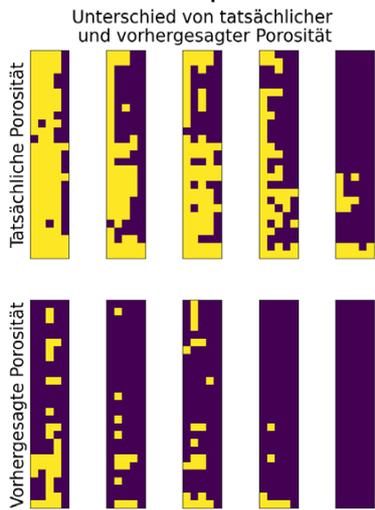
Probekörper 46



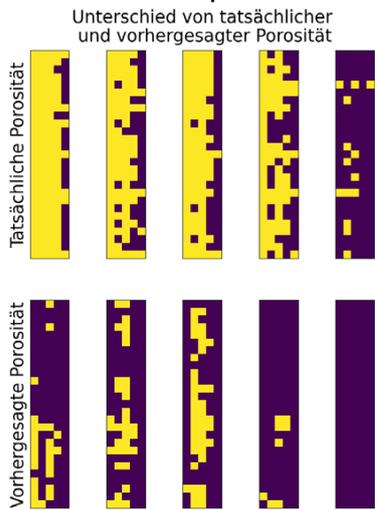
Probekörper 49



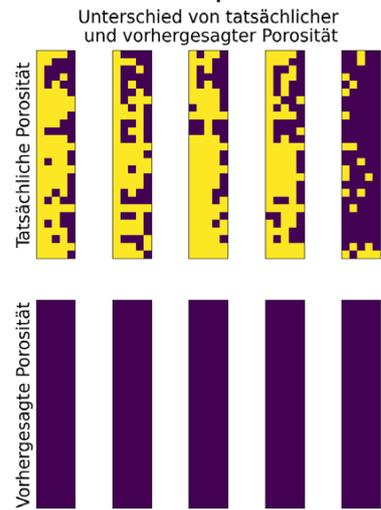
Probekörper 53



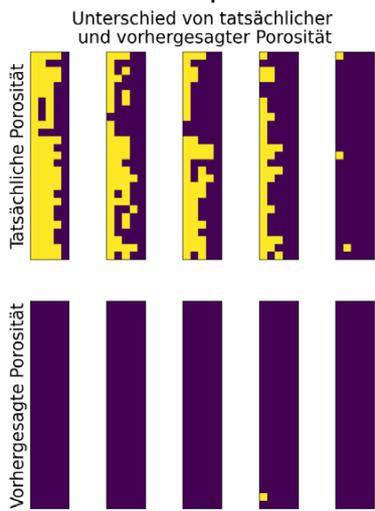
Probekörper 55



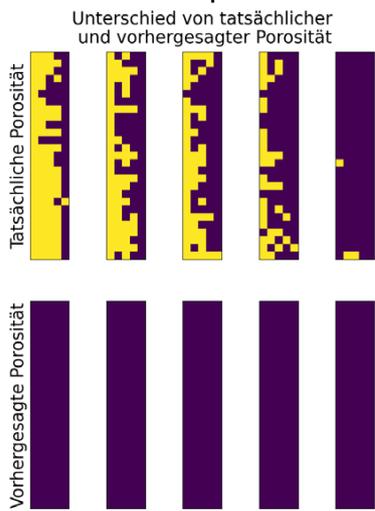
Probekörper 65



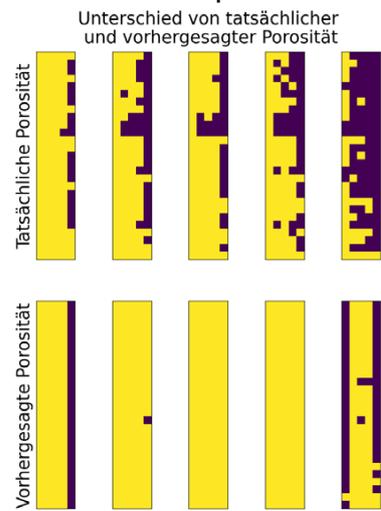
Probekörper 69



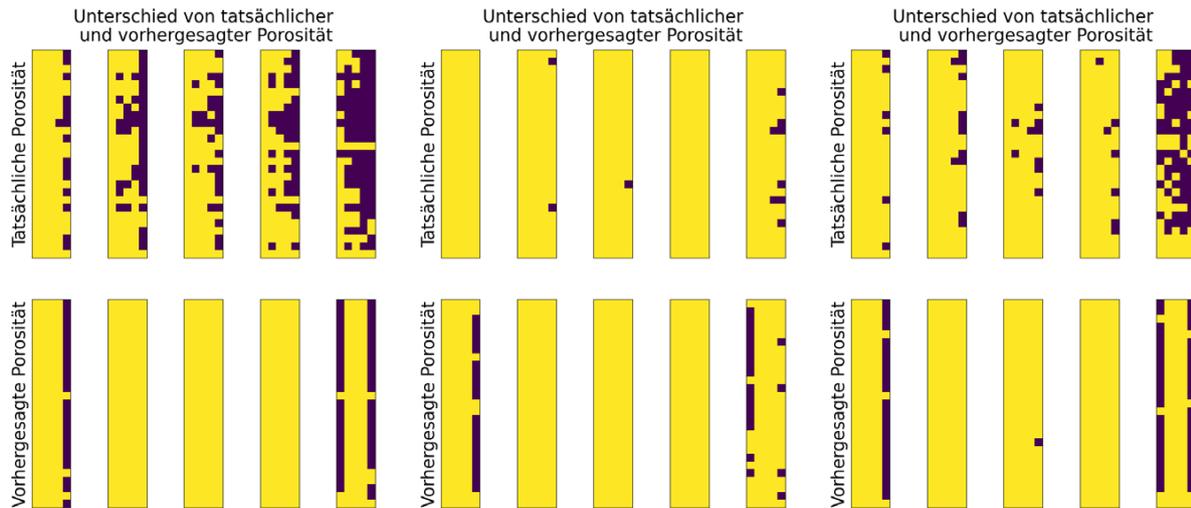
Probekörper 78



Probekörper 79



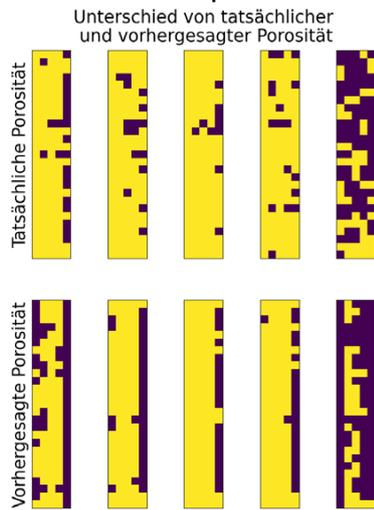
Probekörper 81



Probekörper 86

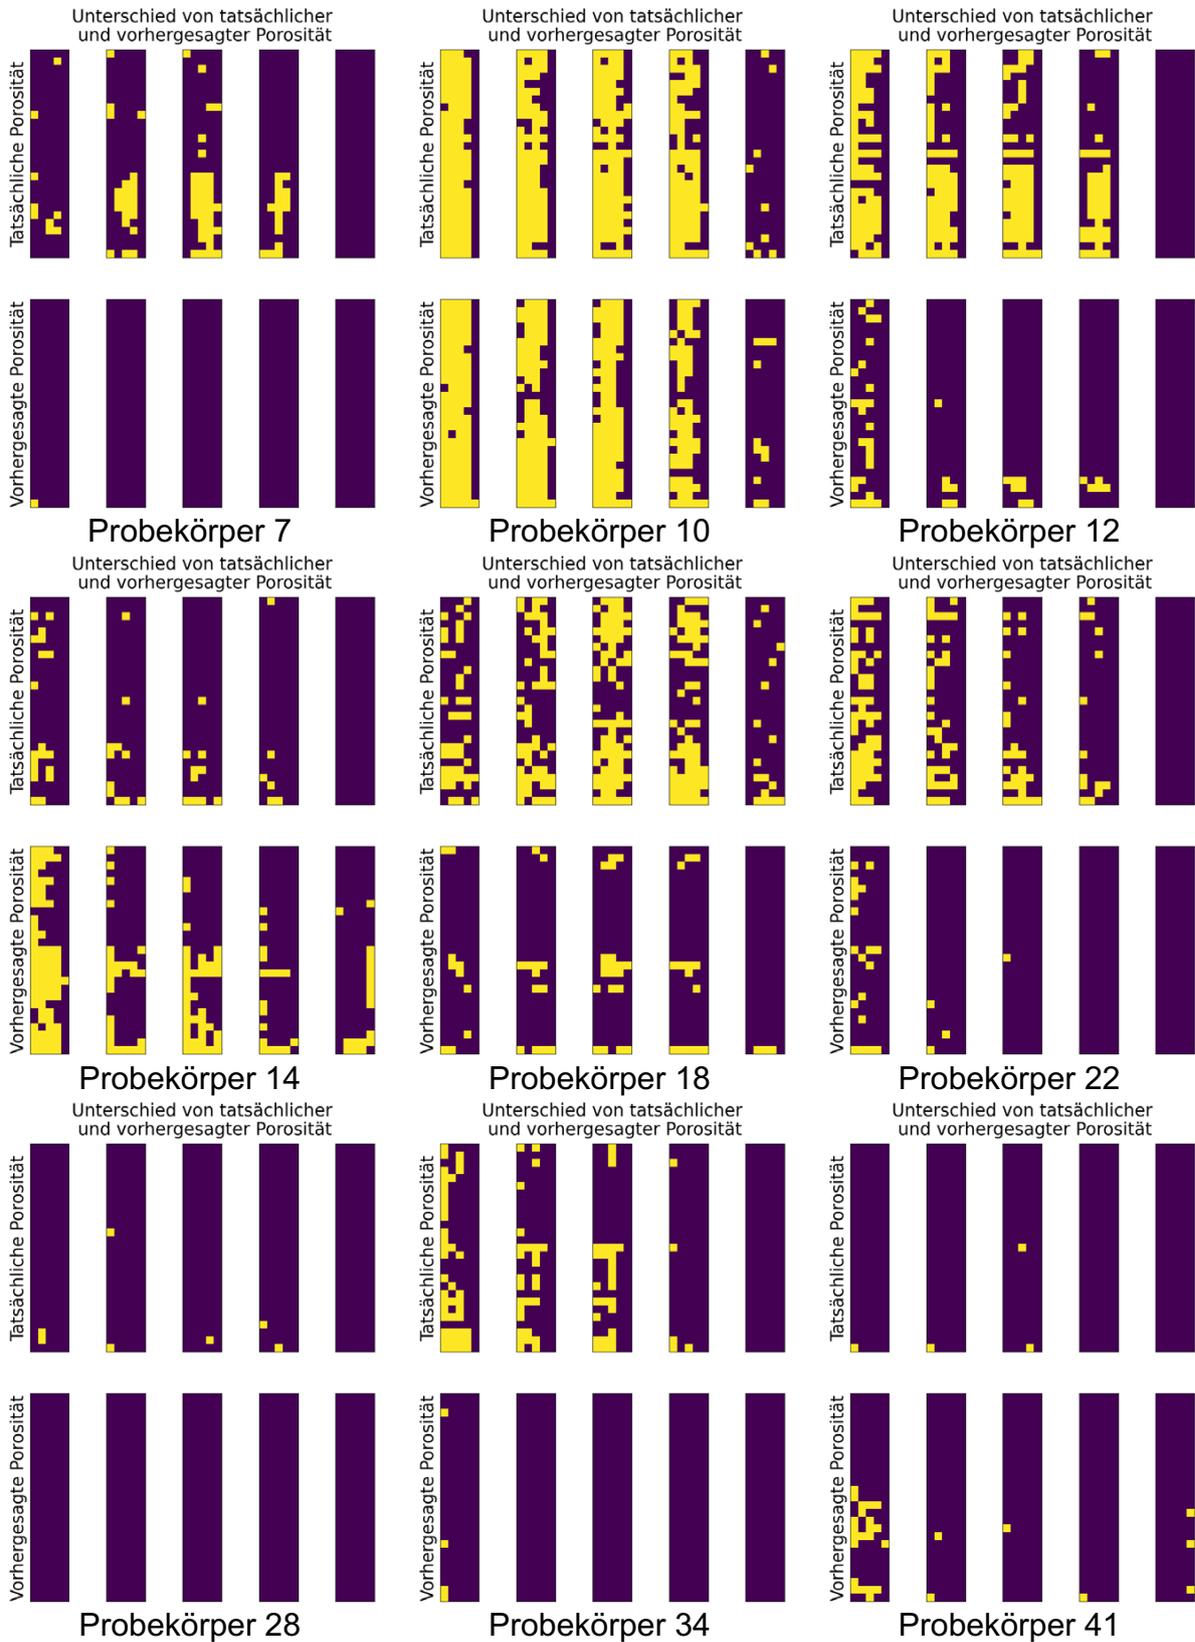
Probekörper 89

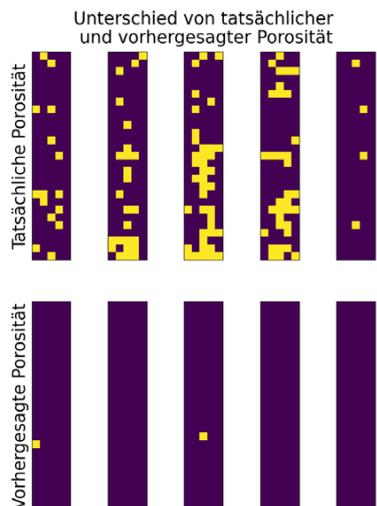
Probekörper 90



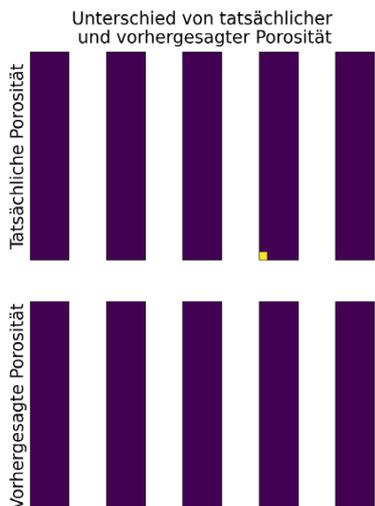
Probekörper 95

Modellart CNN, Klassengrenze 1,25 % Zellporosität, Testdatensatz

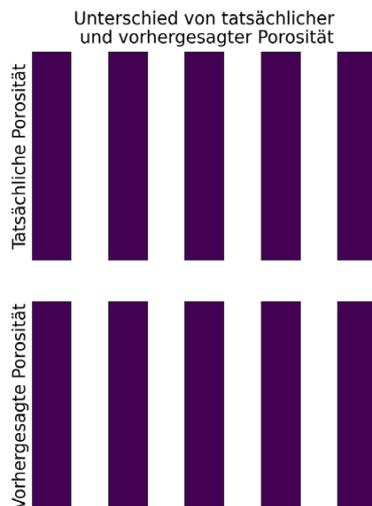




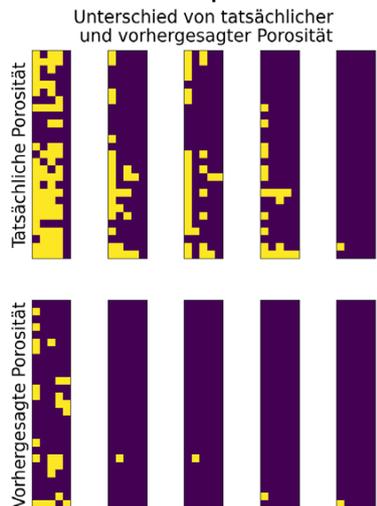
Probekörper 46



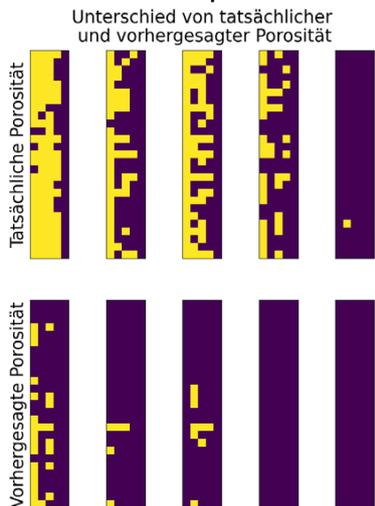
Probekörper 49



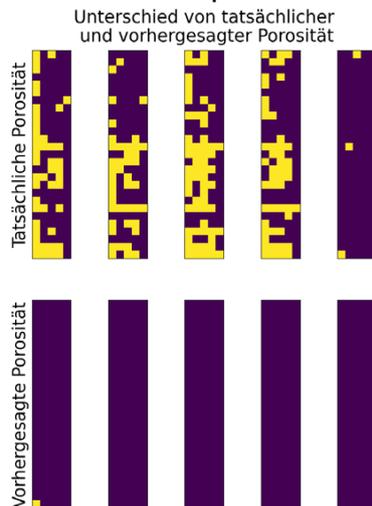
Probekörper 53



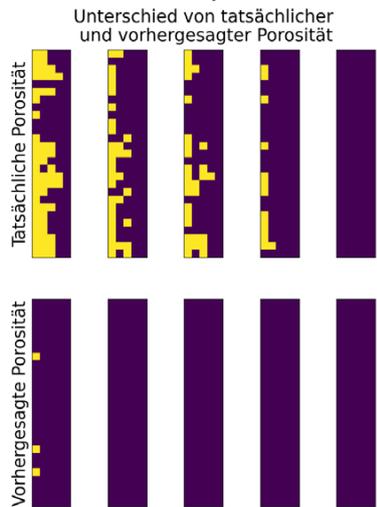
Probekörper 55



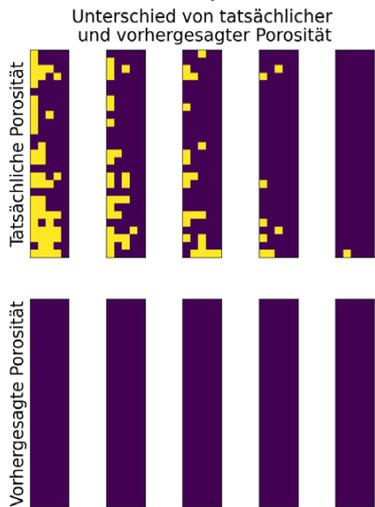
Probekörper 65



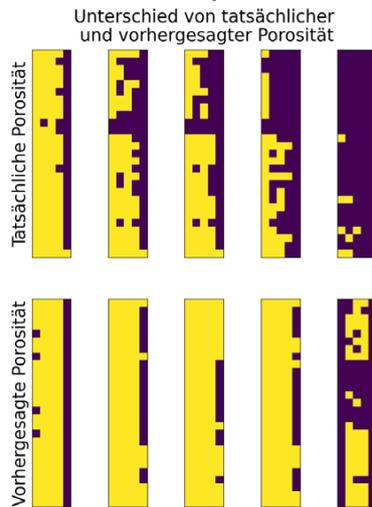
Probekörper 69



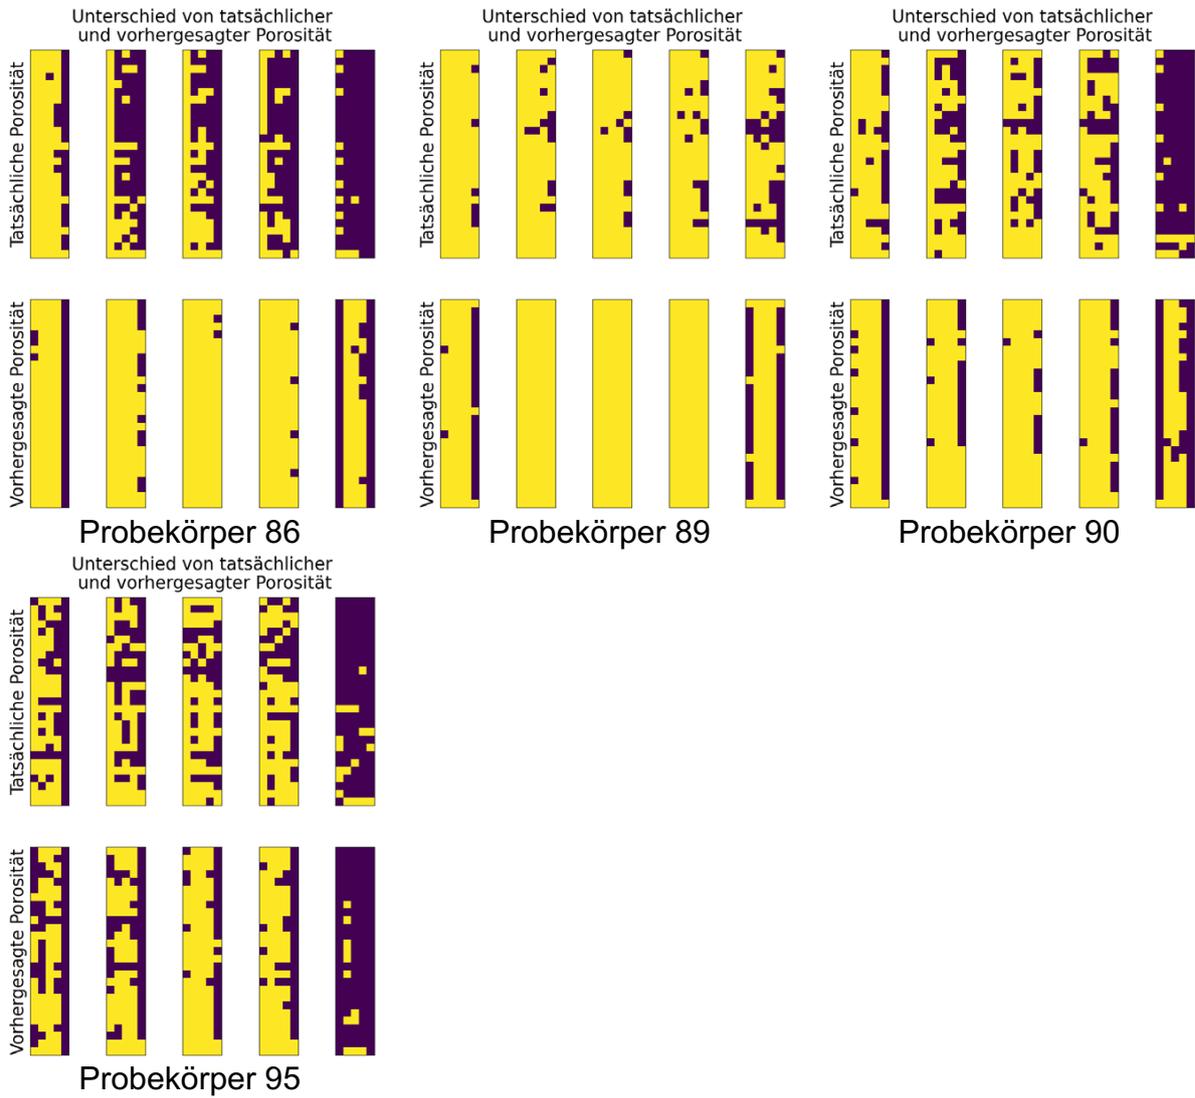
Probekörper 78



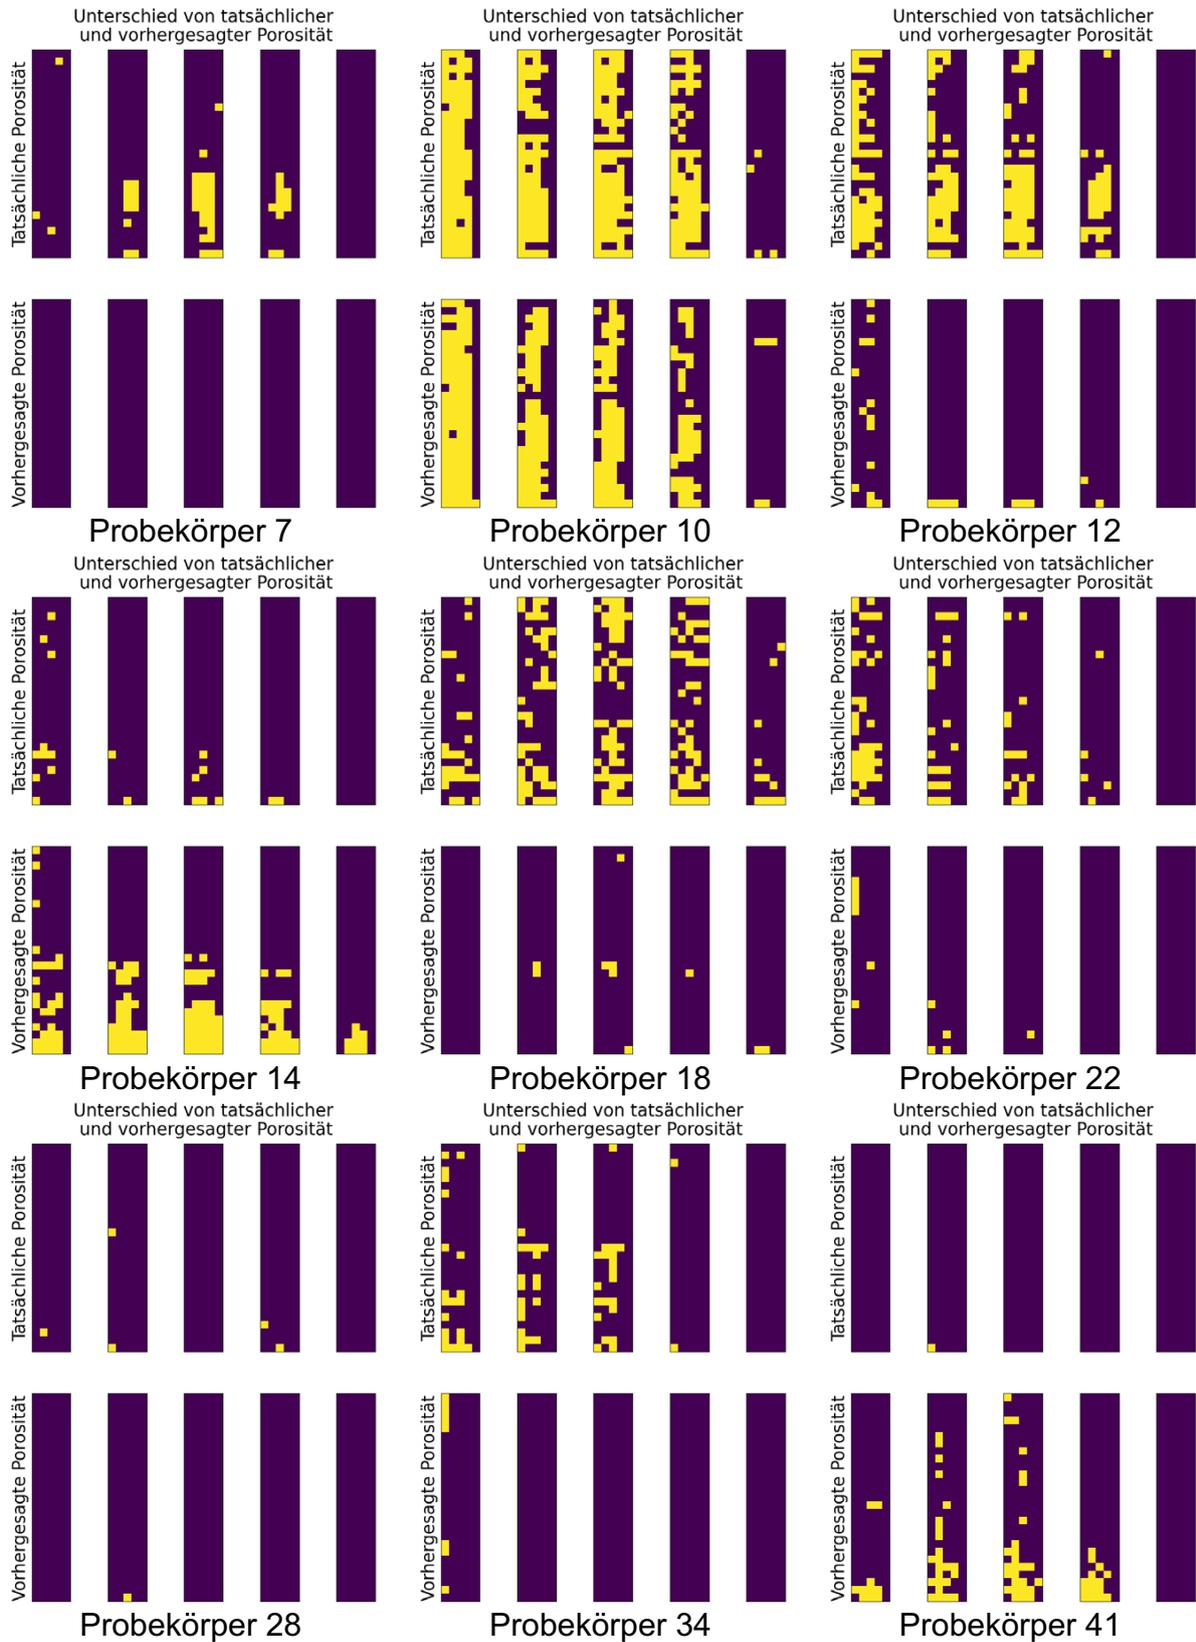
Probekörper 79

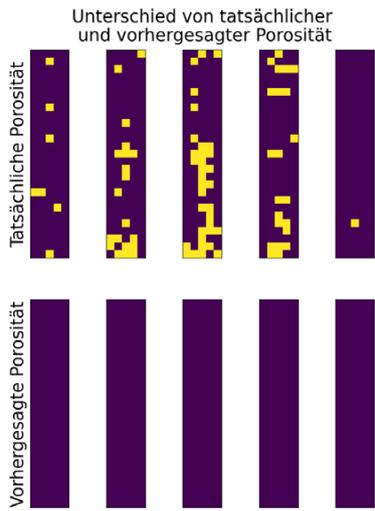


Probekörper 81

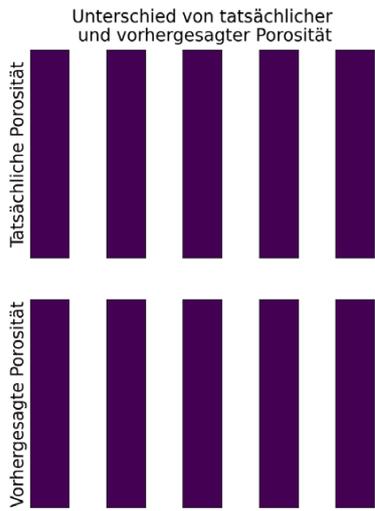


Modellart CNN, Klassengrenze 1,5 % Zellporosität, Testdatensatz

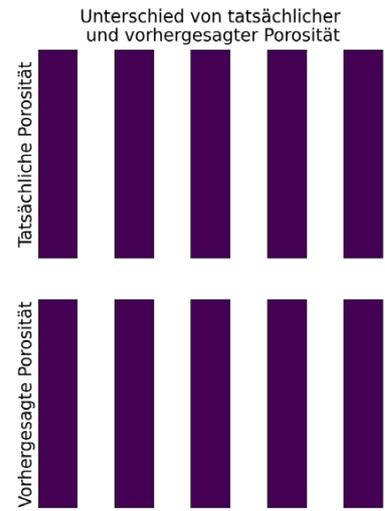




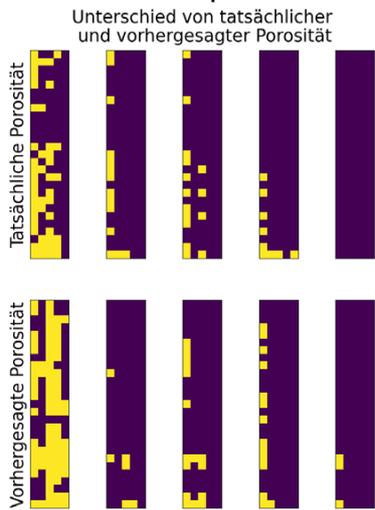
Probekörper 46



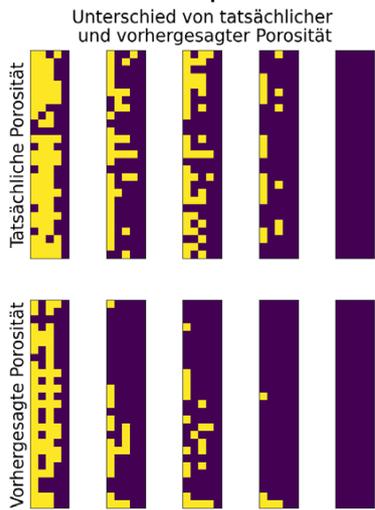
Probekörper 49



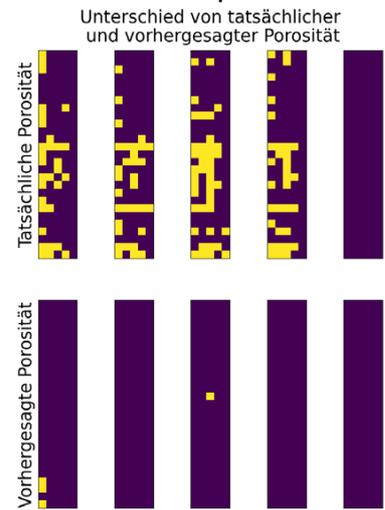
Probekörper 53



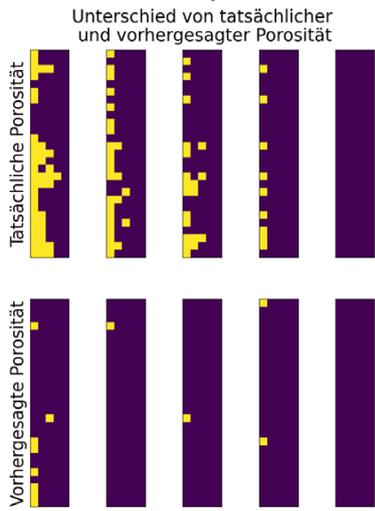
Probekörper 55



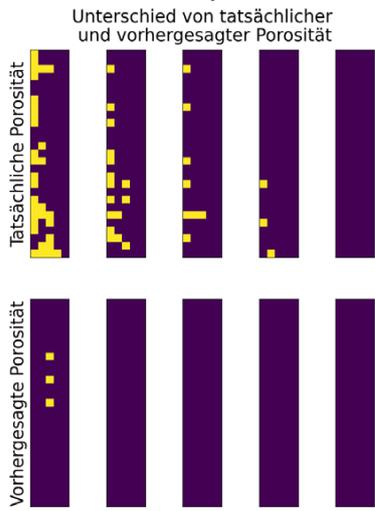
Probekörper 65



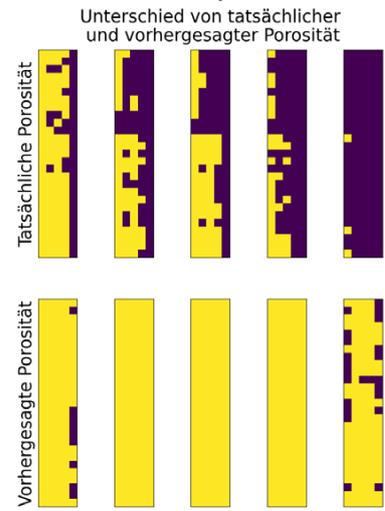
Probekörper 69



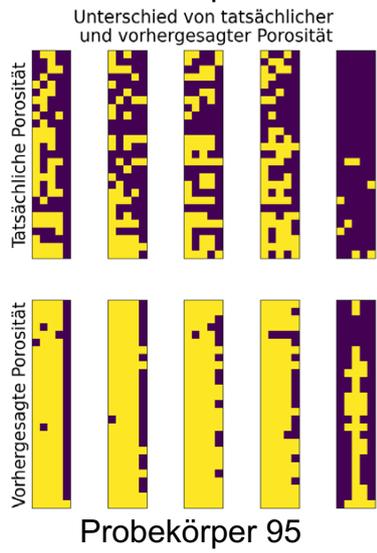
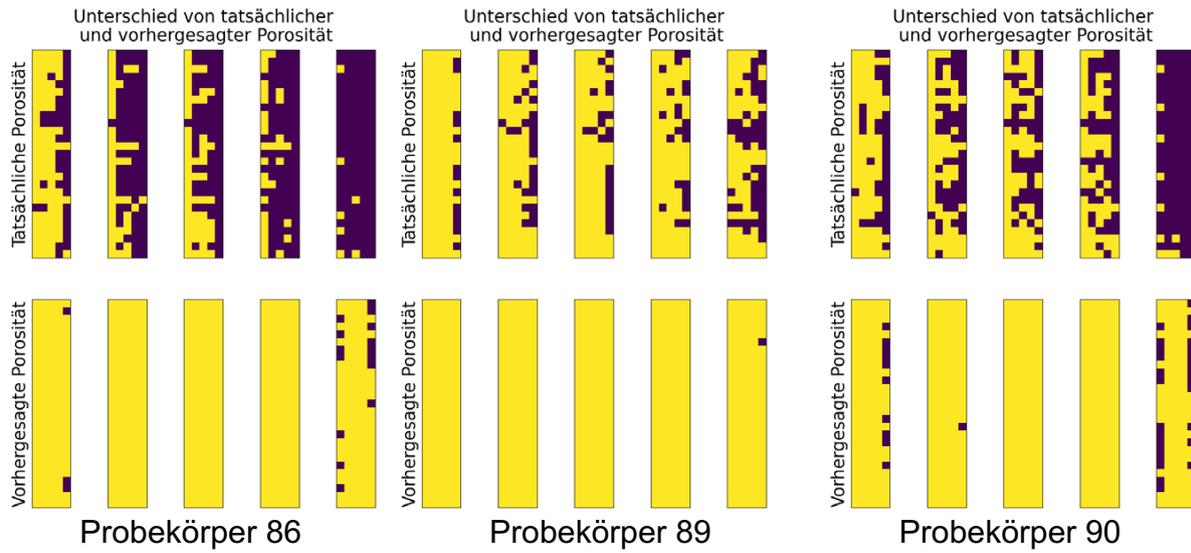
Probekörper 78



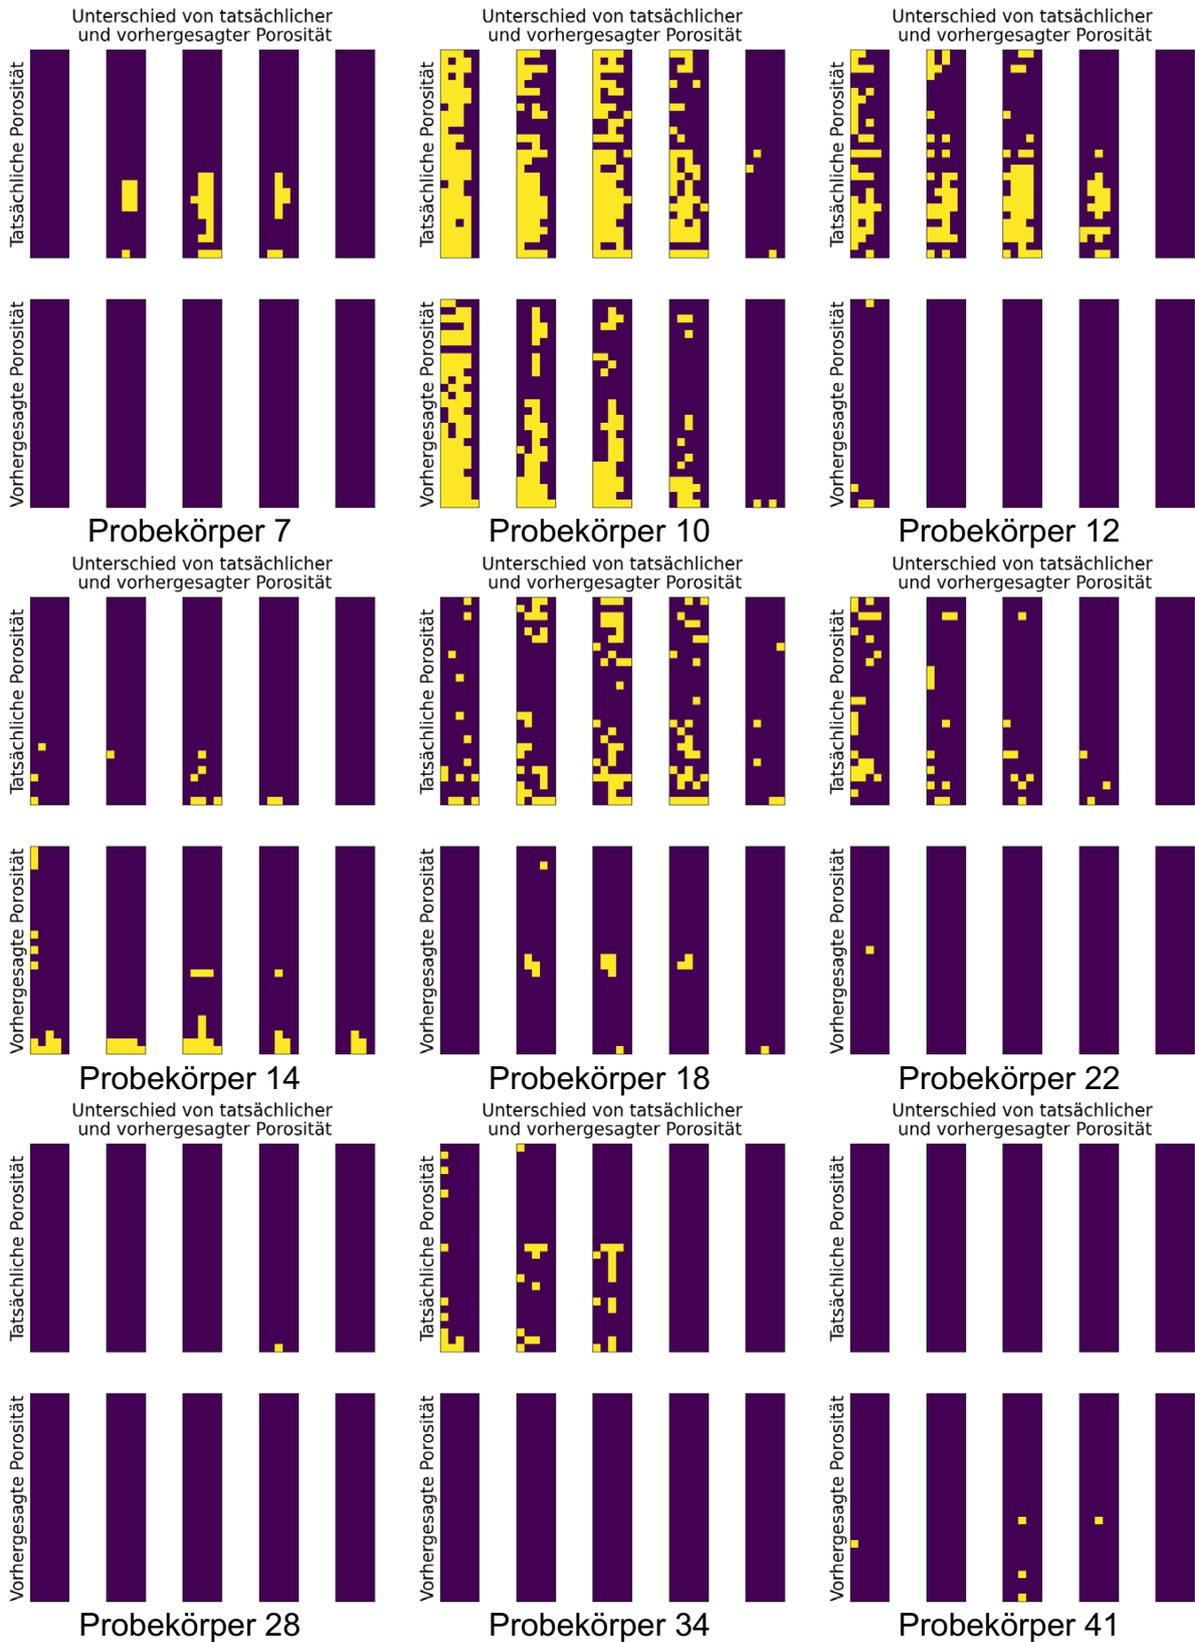
Probekörper 79

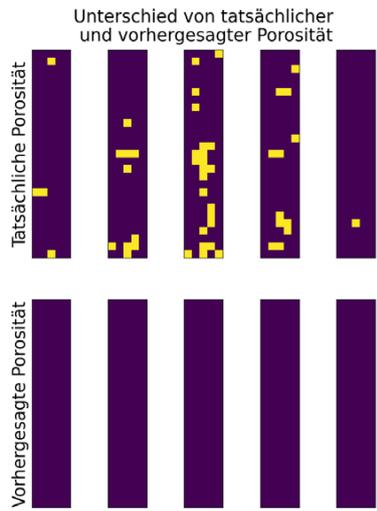


Probekörper 81

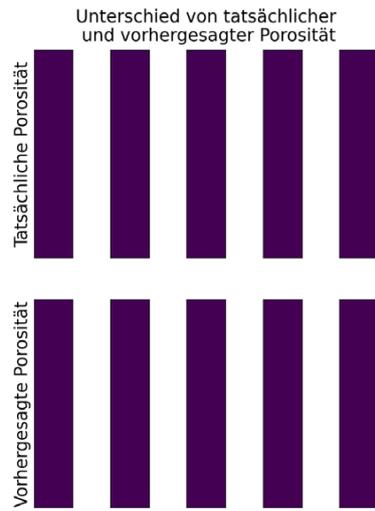


Modellart CNN, Klassengrenze 1,75 % Zellporosität, Testdatensatz

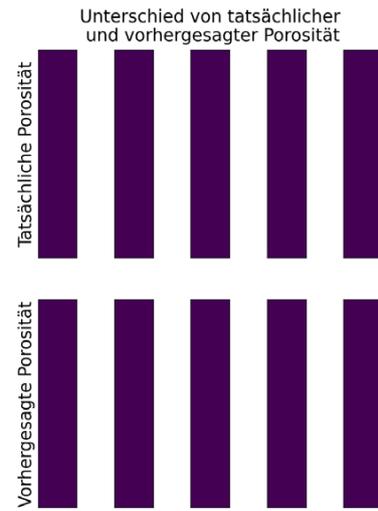




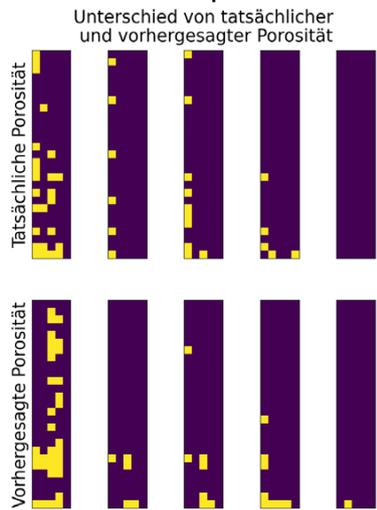
Probekörper 46



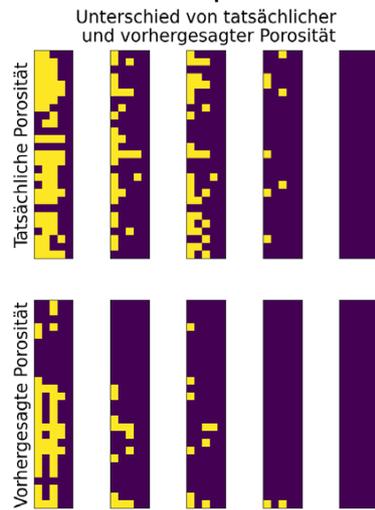
Probekörper 49



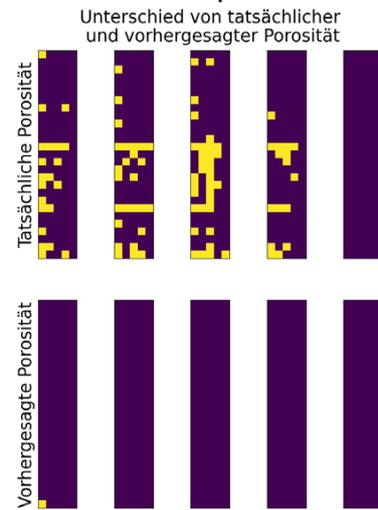
Probekörper 53



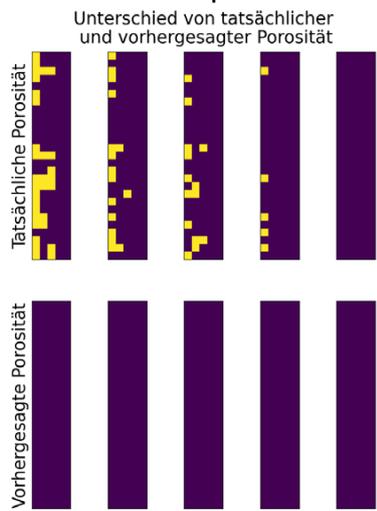
Probekörper 55



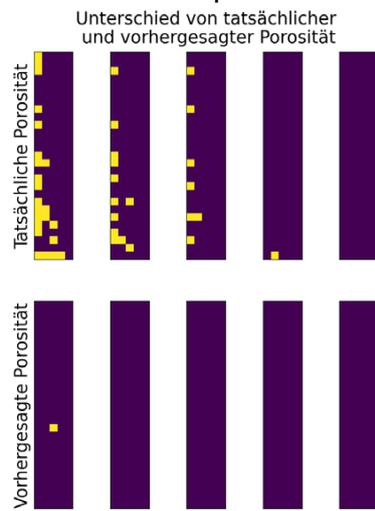
Probekörper 65



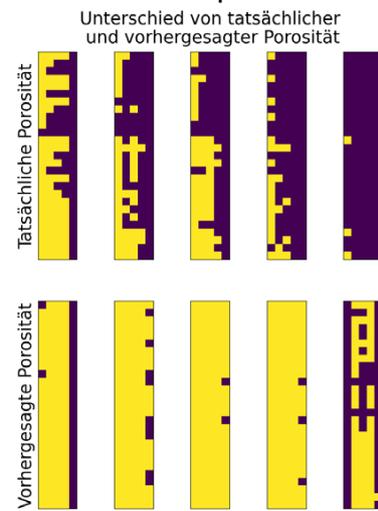
Probekörper 69



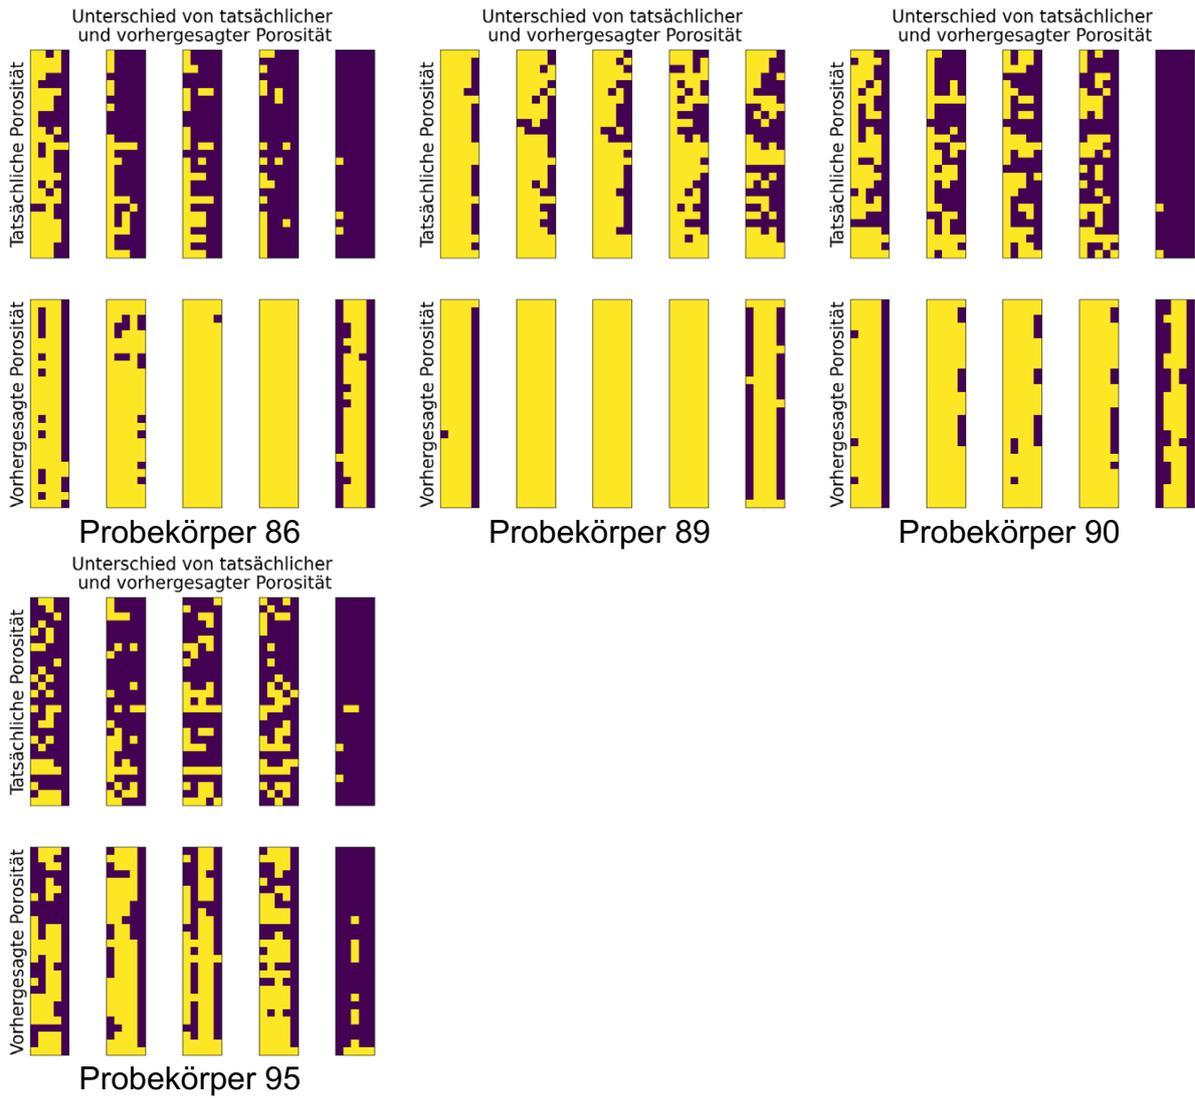
Probekörper 78



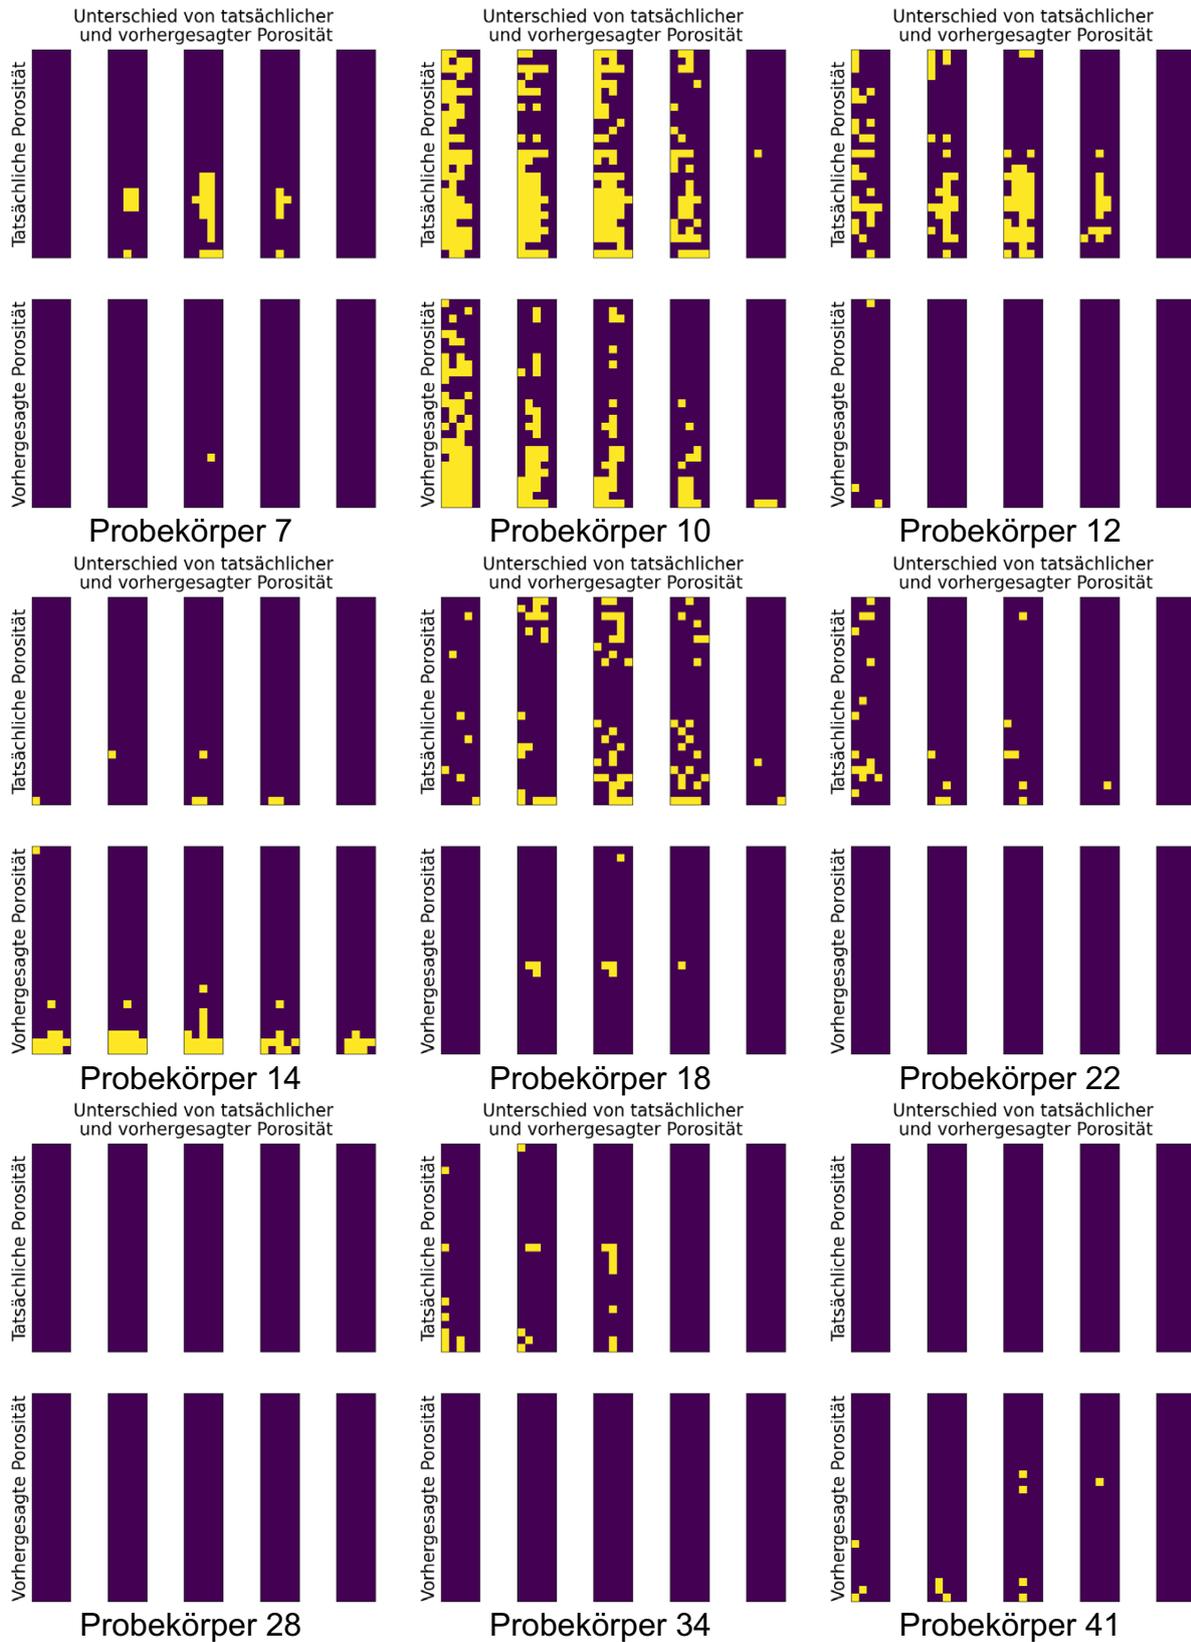
Probekörper 79

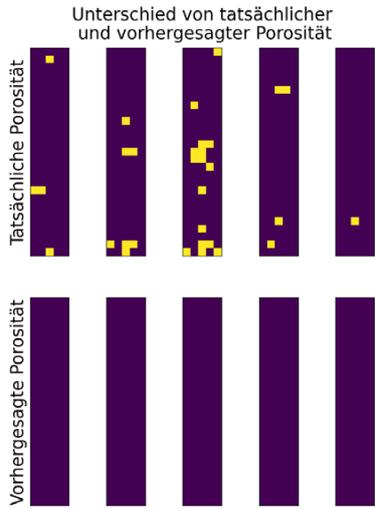


Probekörper 81

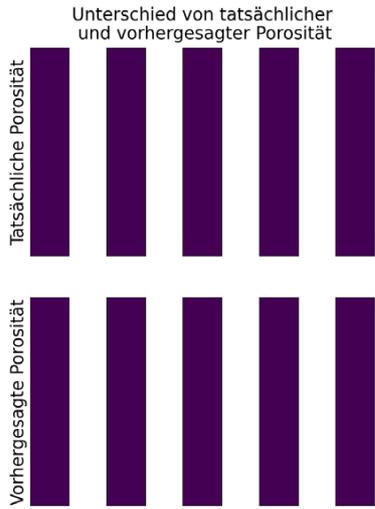


Modellart CNN, Klassengrenze 2 % Zellporosität, Testdatensatz

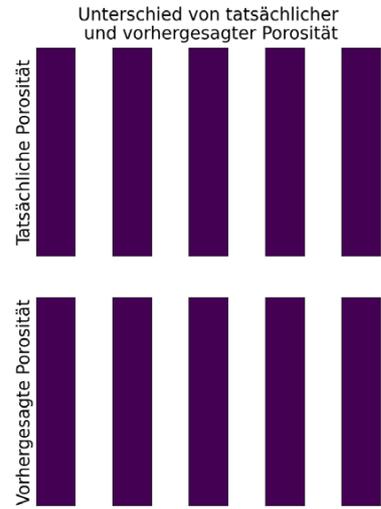




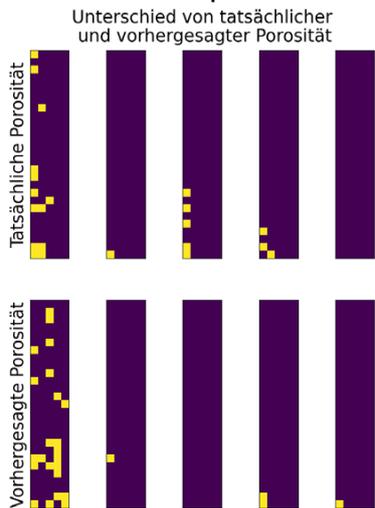
Probekörper 46



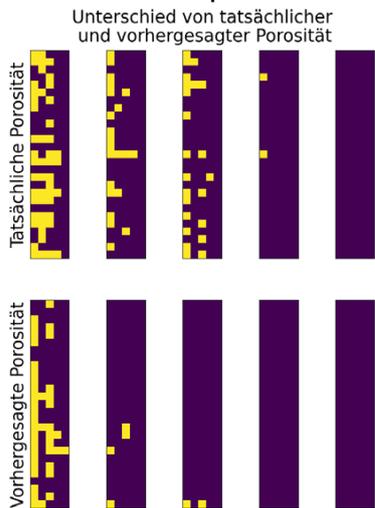
Probekörper 49



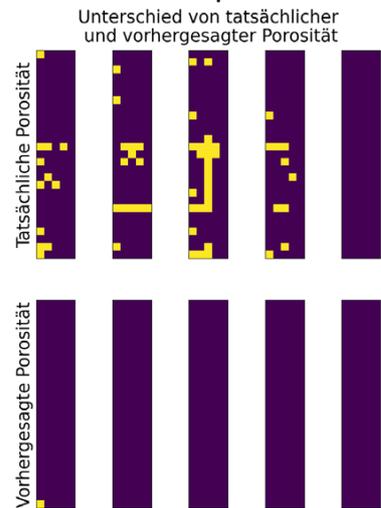
Probekörper 53



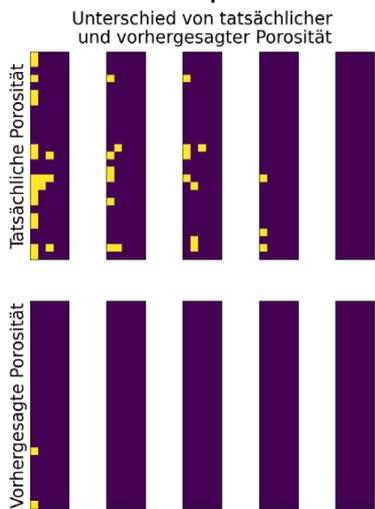
Probekörper 55



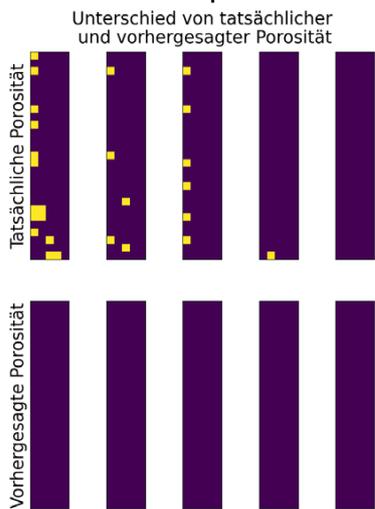
Probekörper 65



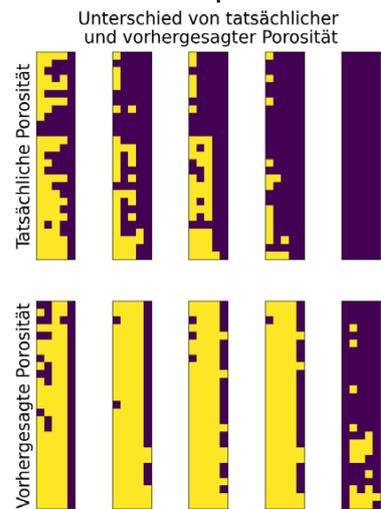
Probekörper 69



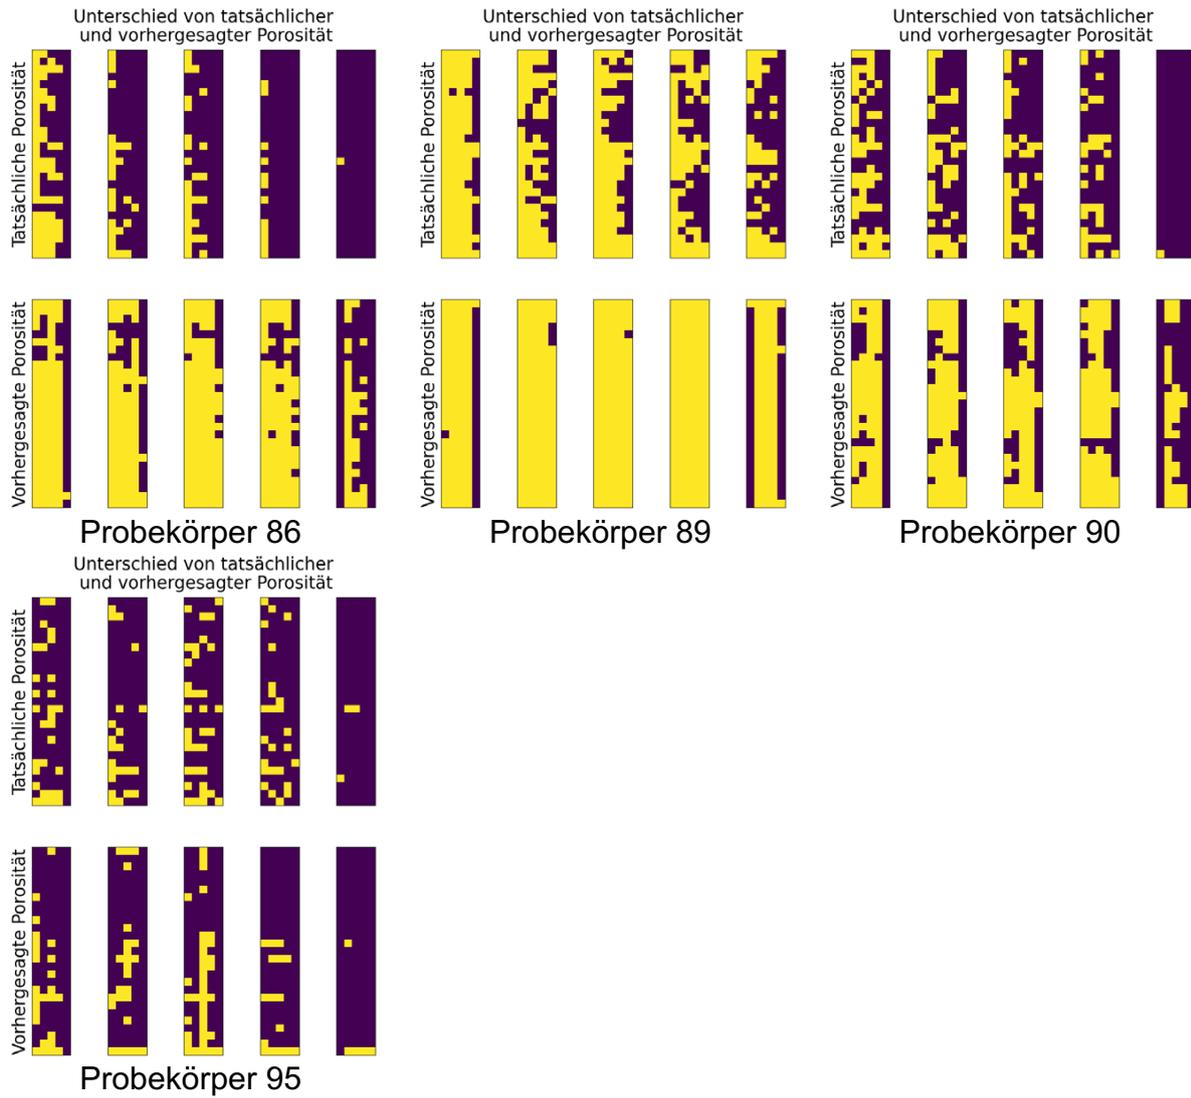
Probekörper 78



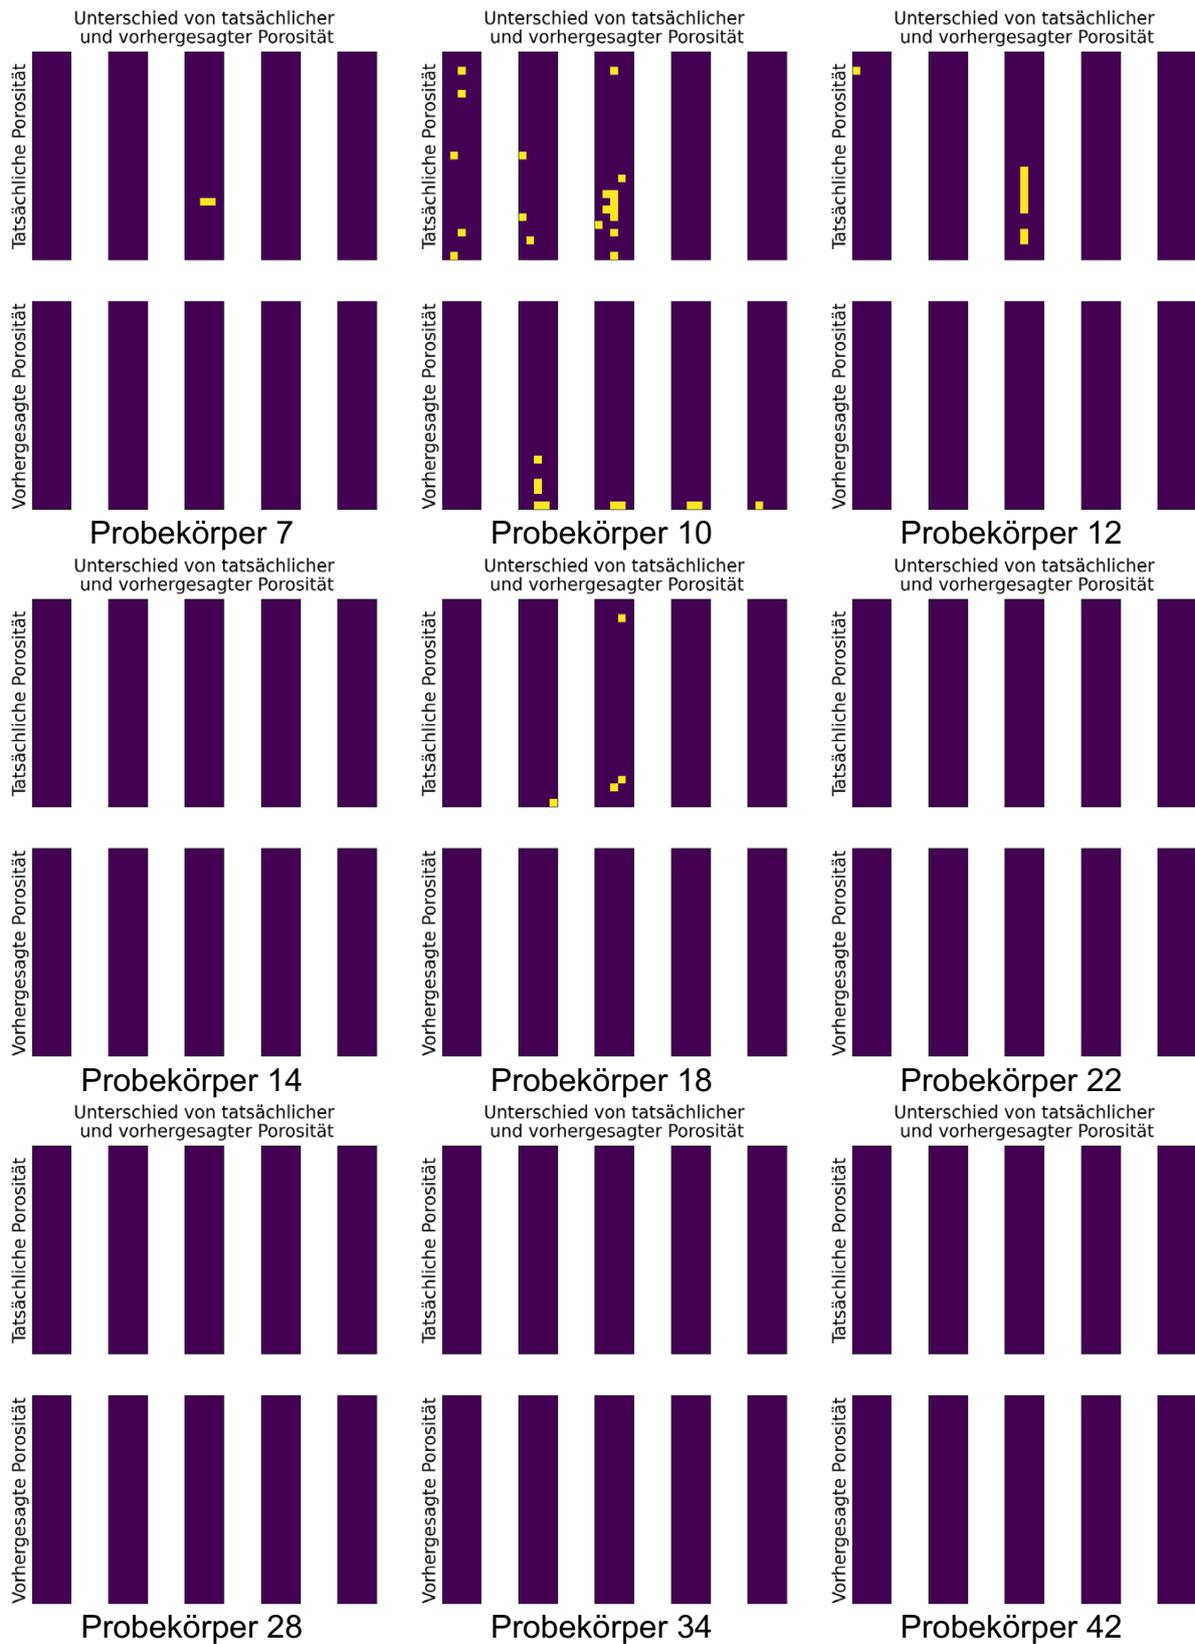
Probekörper 79



Probekörper 81



Modellart CNN, Klassengrenze 4 % Zellporosität, Testdatensatz





Probekörper 46



Probekörper 49



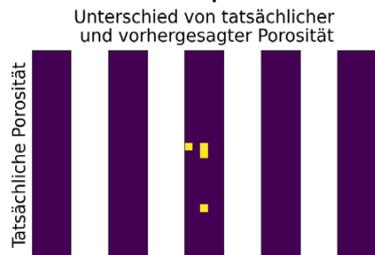
Probekörper 53



Probekörper 55



Probekörper 65



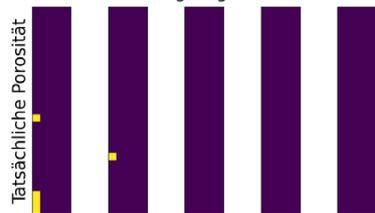
Probekörper 69



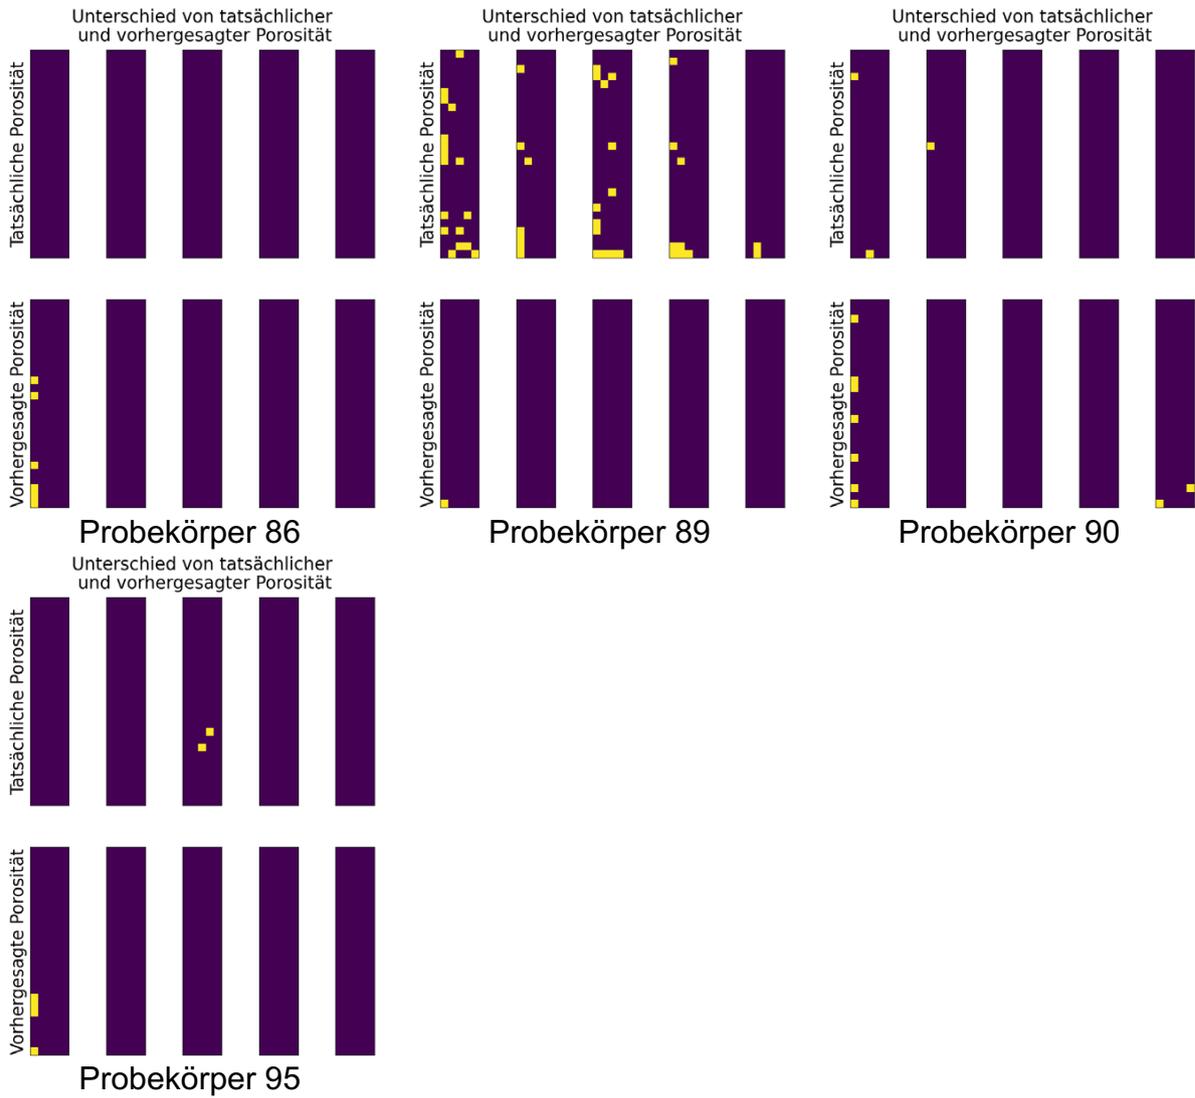
Probekörper 78



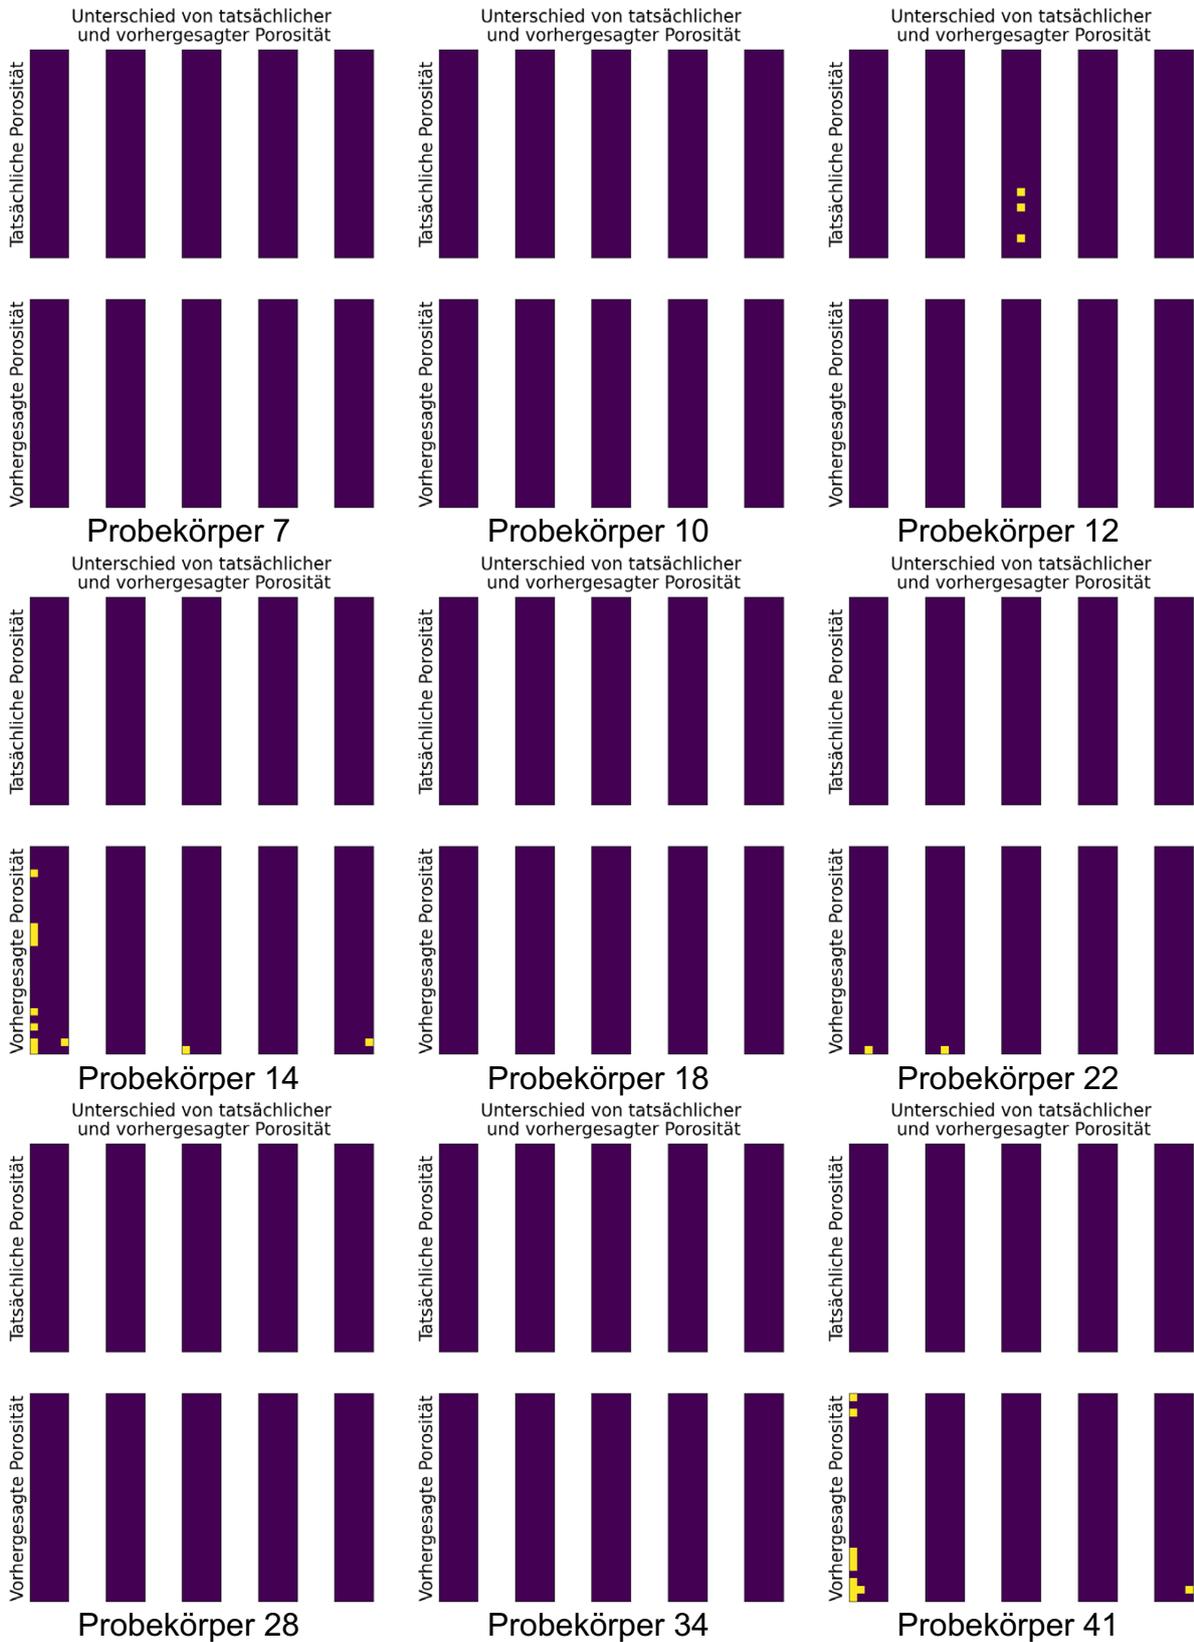
Probekörper 79



Probekörper 81



Modellart CNN, Klassengrenze 6 % Zellporosität, Testdatensatz





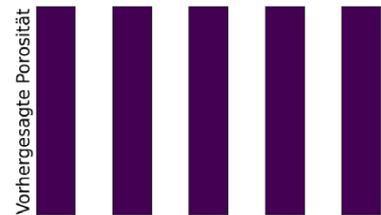
Probekörper 46

Unterschied von tatsächlicher und vorhergesagter Porosität



Probekörper 49

Unterschied von tatsächlicher und vorhergesagter Porosität



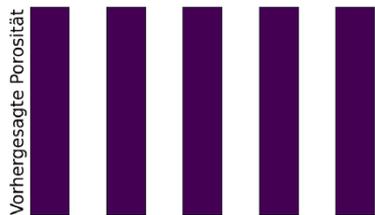
Probekörper 53

Unterschied von tatsächlicher und vorhergesagter Porosität



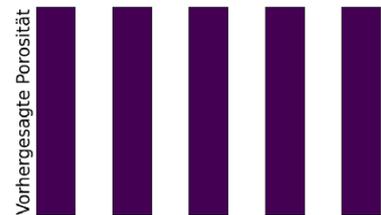
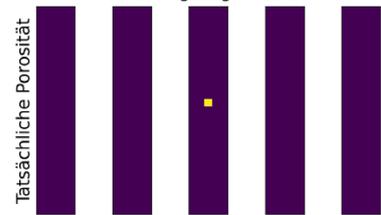
Probekörper 55

Unterschied von tatsächlicher und vorhergesagter Porosität



Probekörper 65

Unterschied von tatsächlicher und vorhergesagter Porosität



Probekörper 69

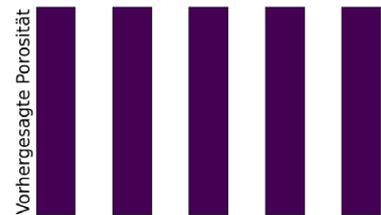
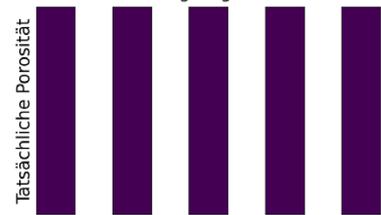
Unterschied von tatsächlicher und vorhergesagter Porosität



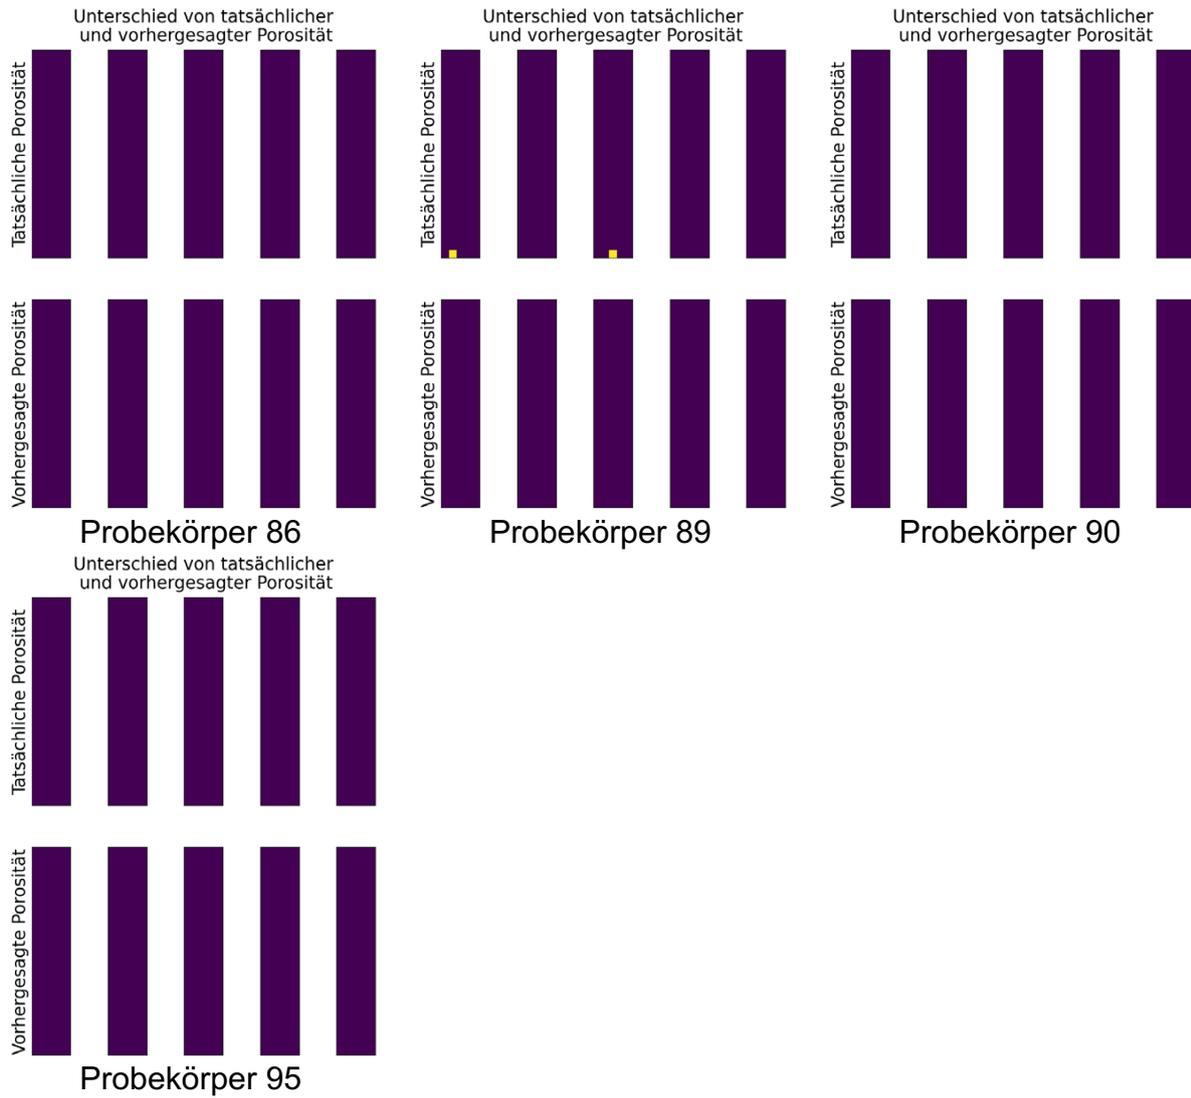
Probekörper 78



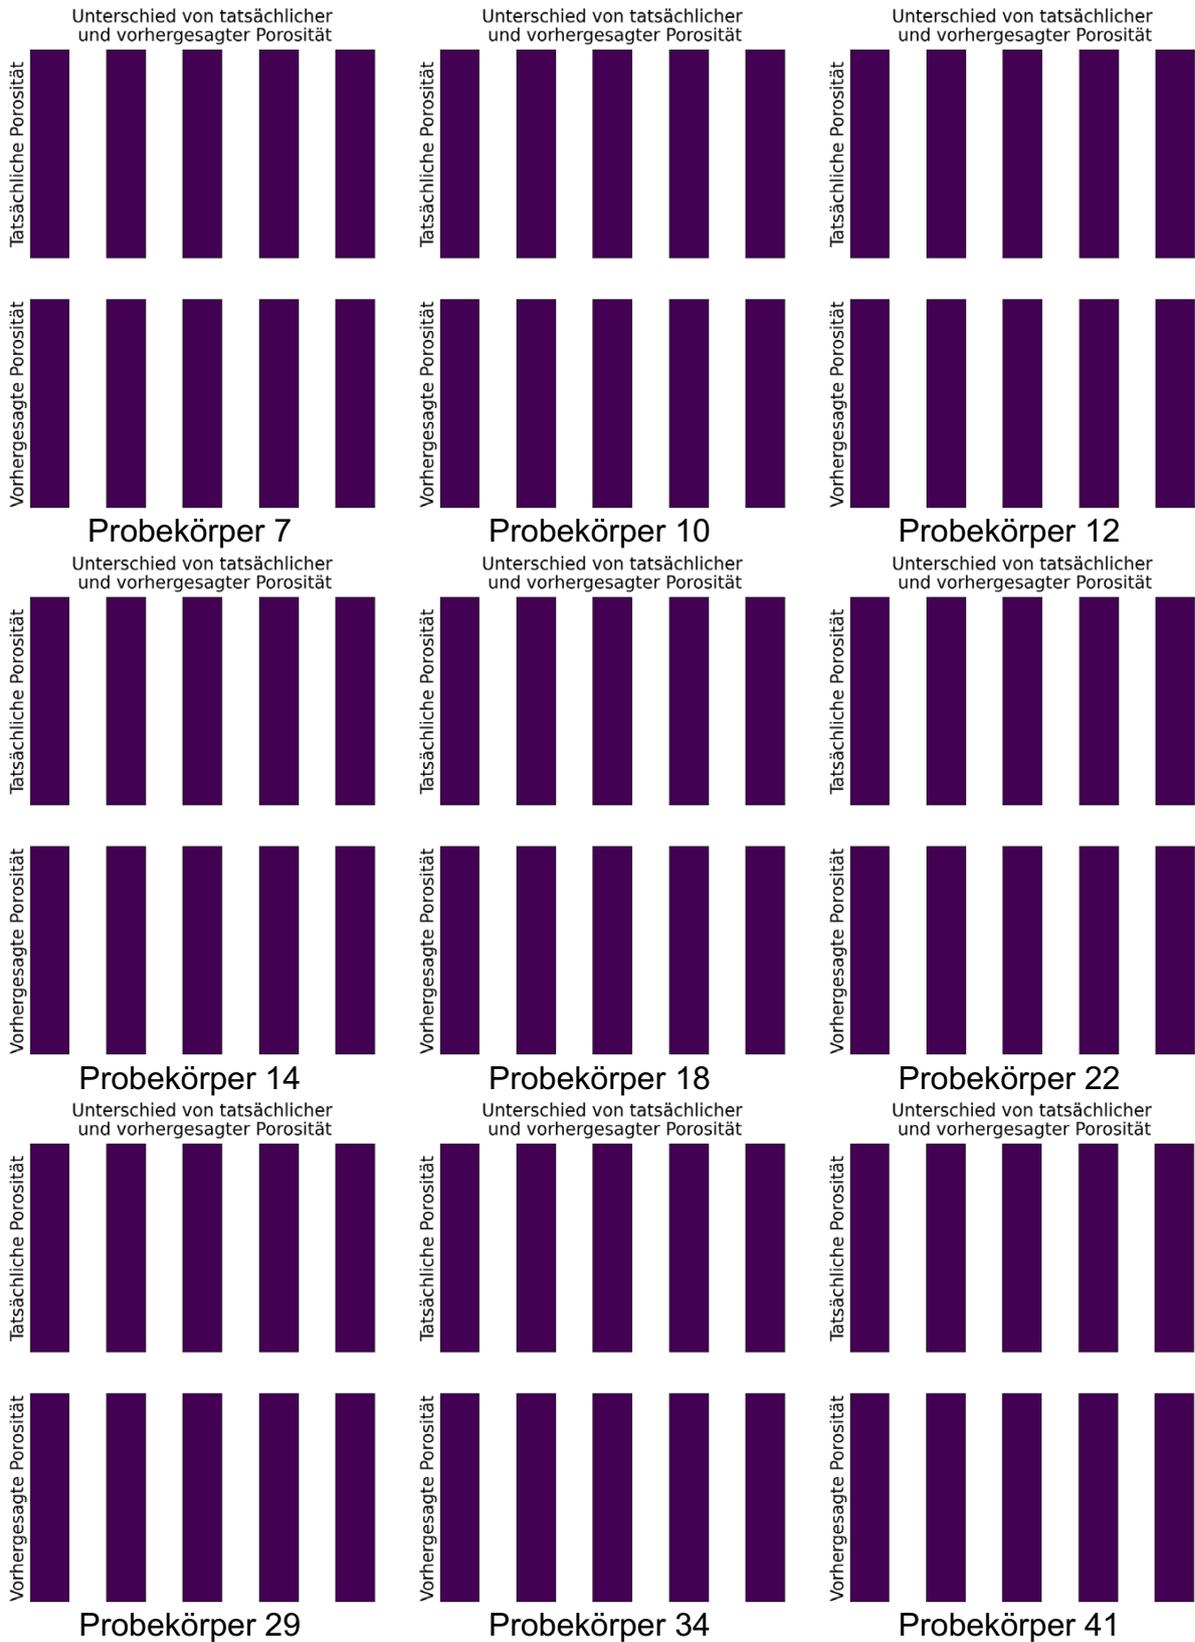
Probekörper 79

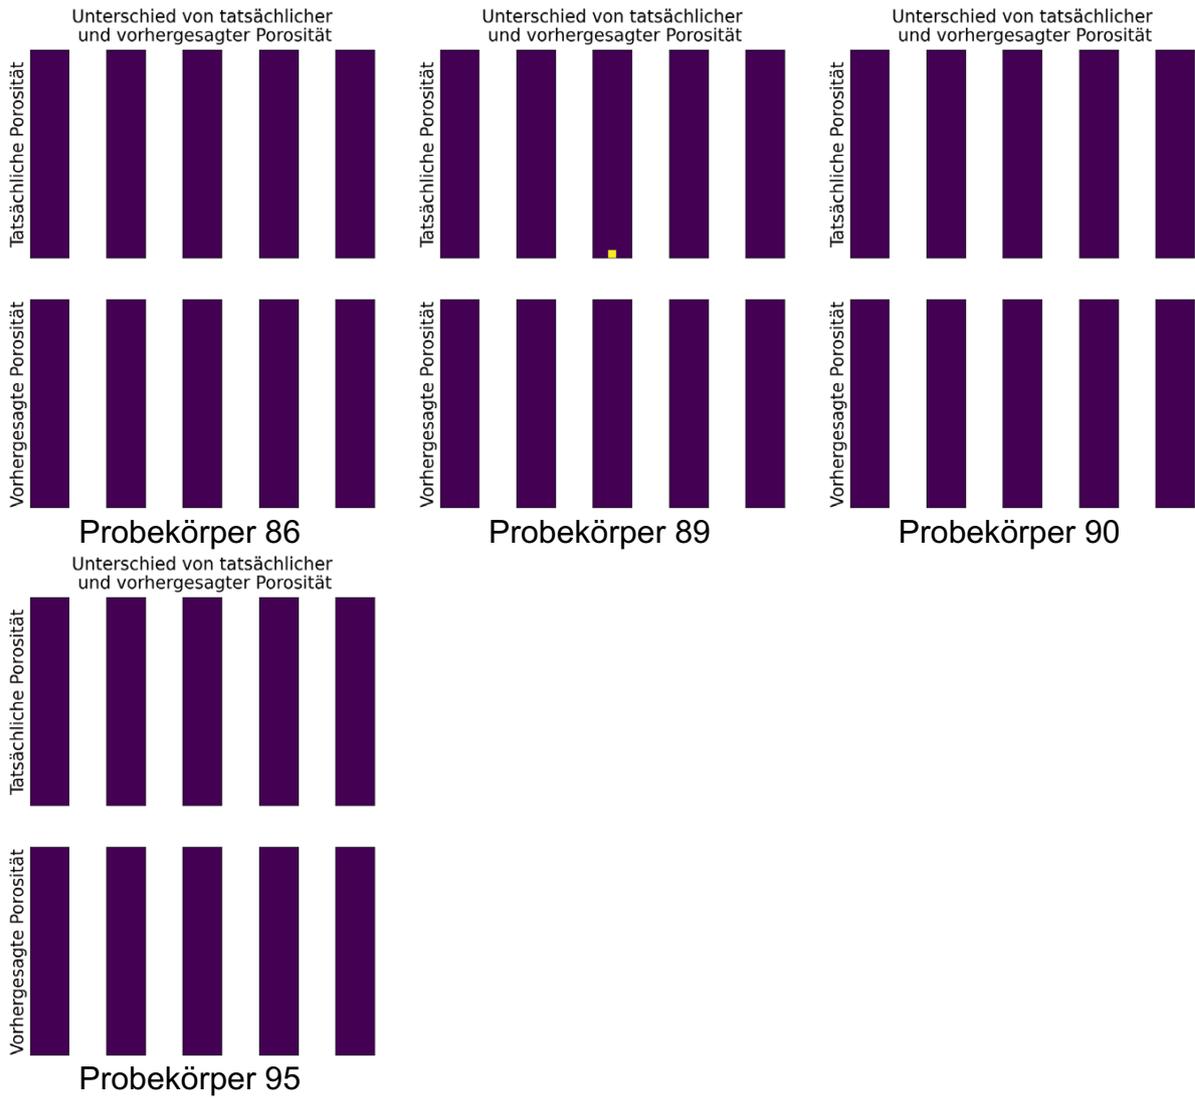


Probekörper 81



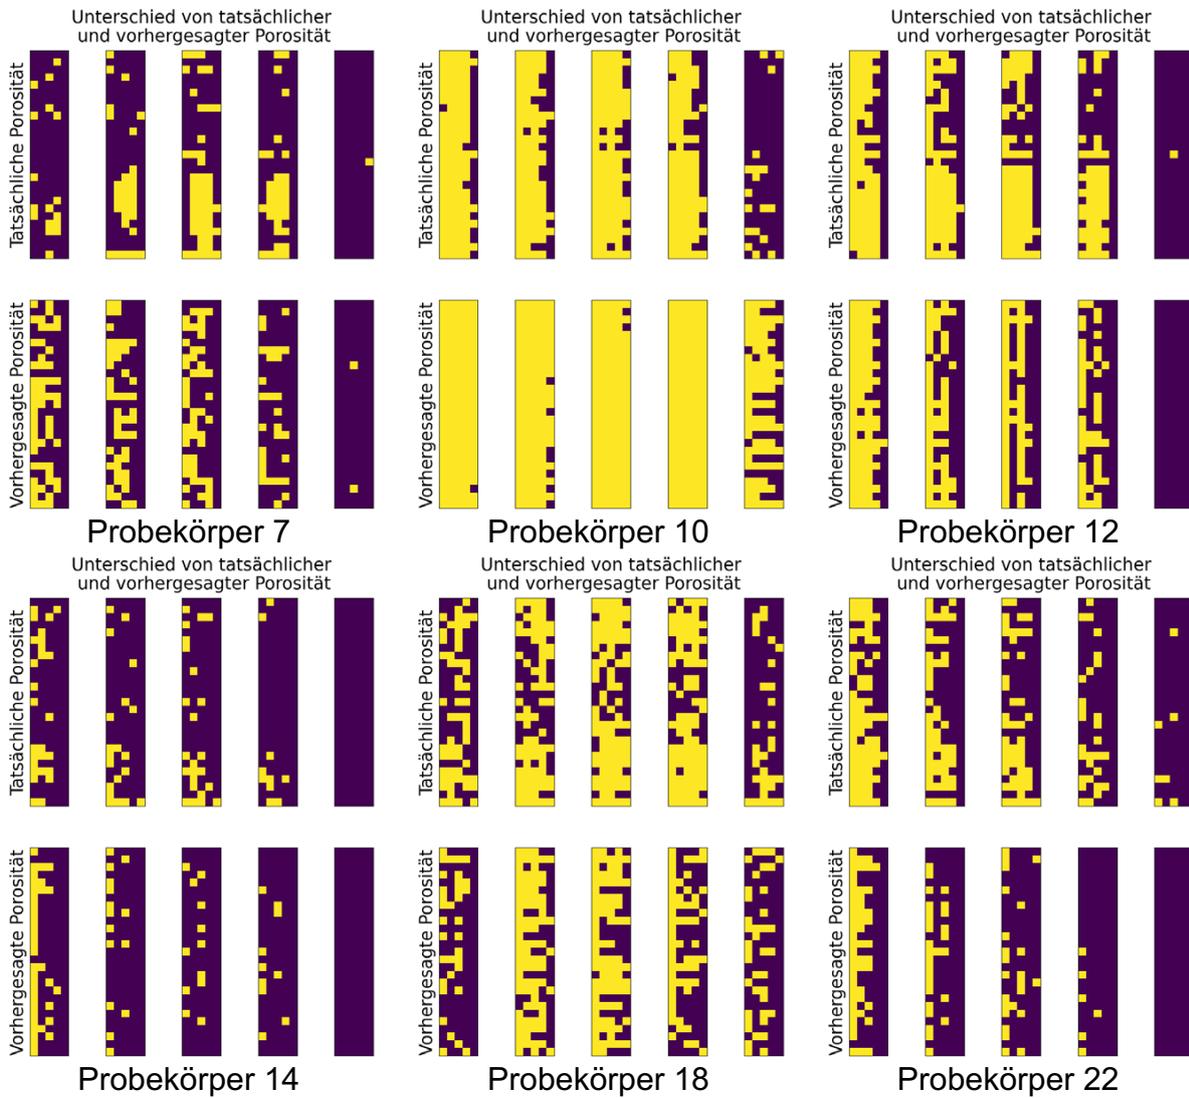
Modellart CNN, Klassengrenze 8 % Zellporosität, Testdatensatz

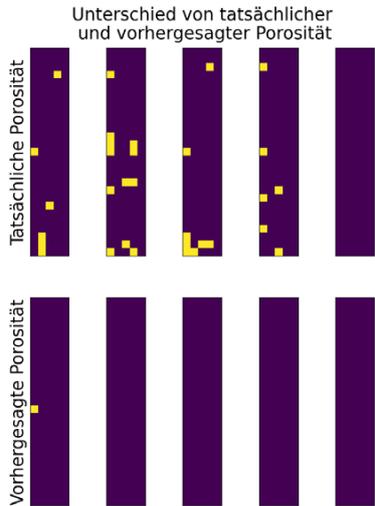




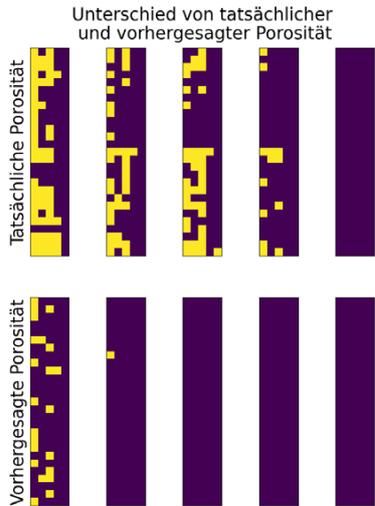
A2.2 Klassifikation Fotodiodenarray

Modellart MLP, Klassengrenze 1 % Zellporosität, Testdatensatz

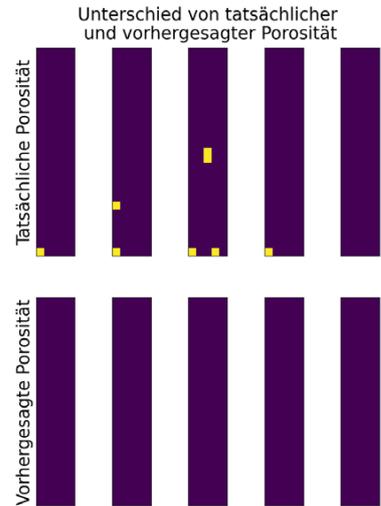




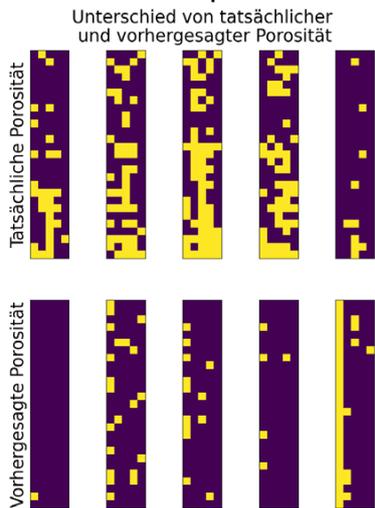
Probekörper 28



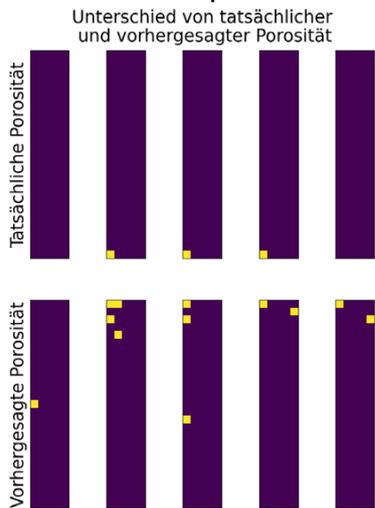
Probekörper 34



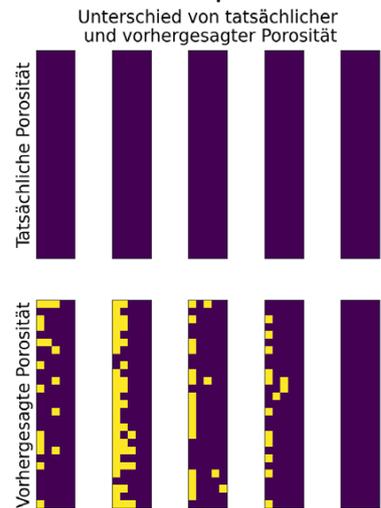
Probekörper 41



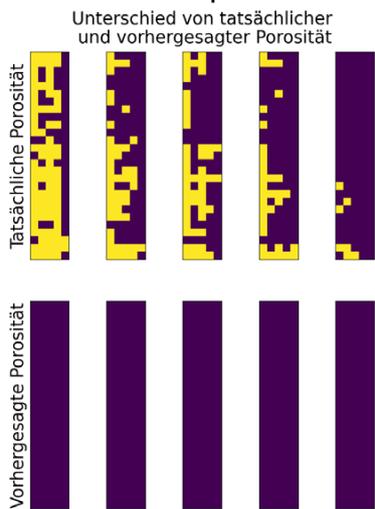
Probekörper 46



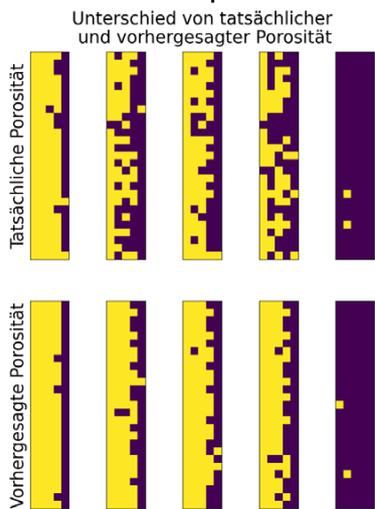
Probekörper 49



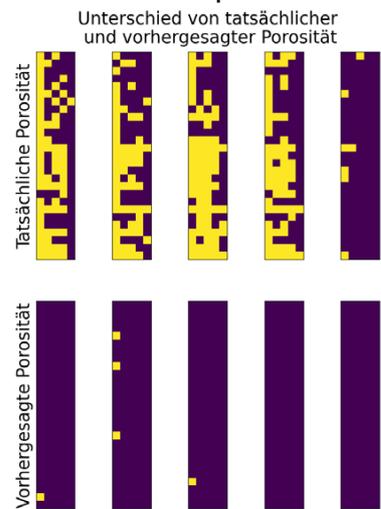
Probekörper 53



Probekörper 55



Probekörper 65



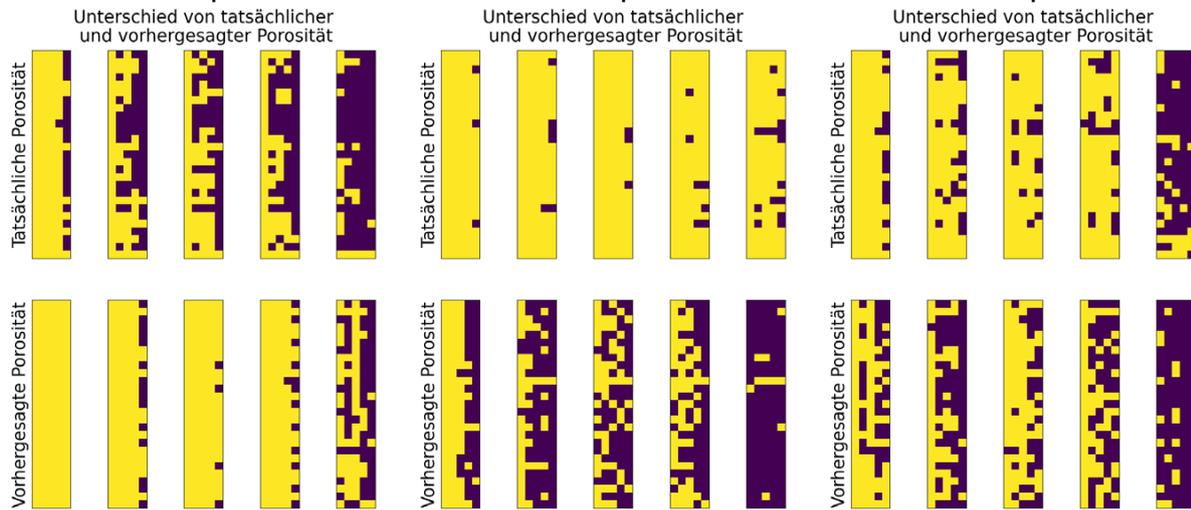
Probekörper 69



Probekörper 78

Probekörper 79

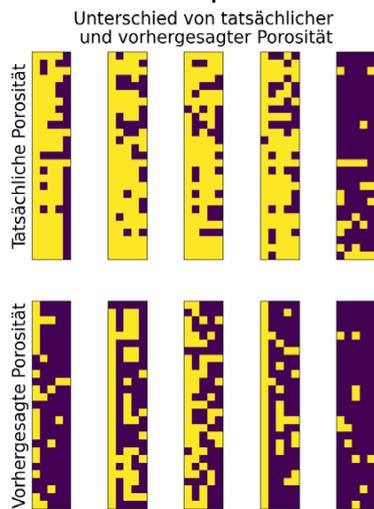
Probekörper 81



Probekörper 86

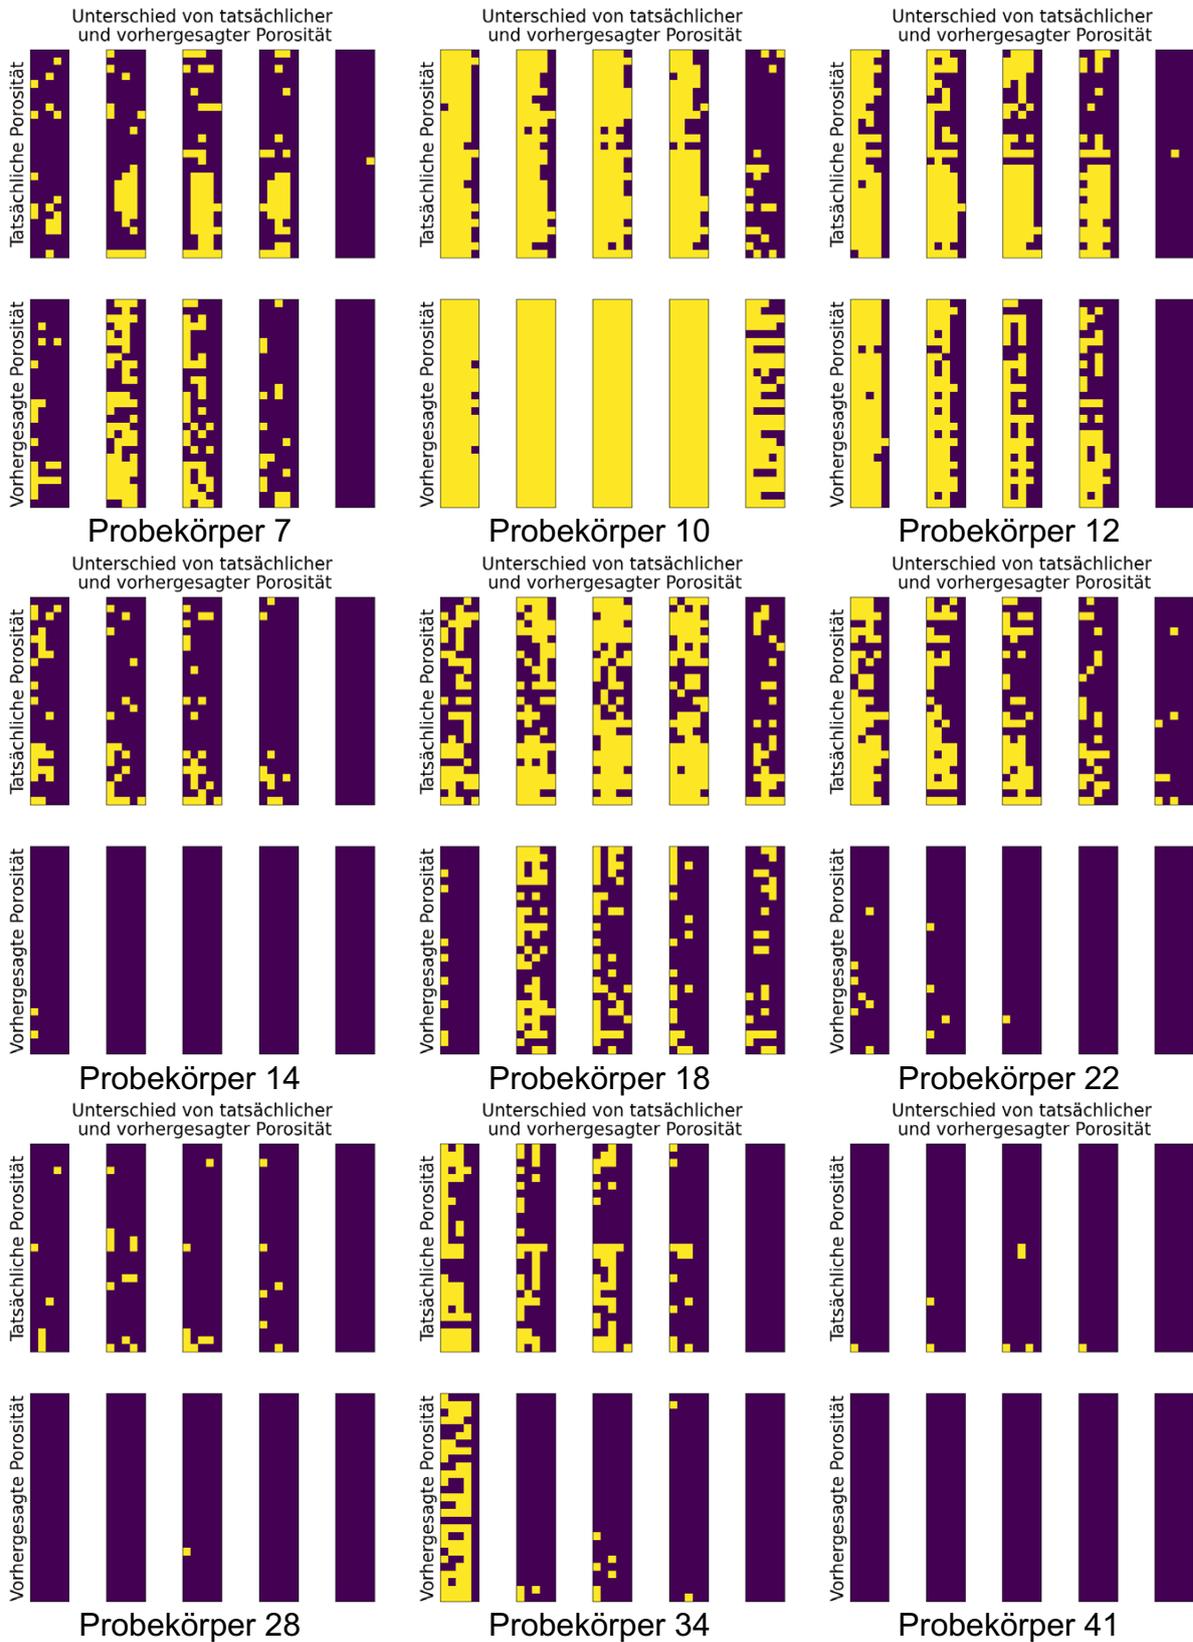
Probekörper 89

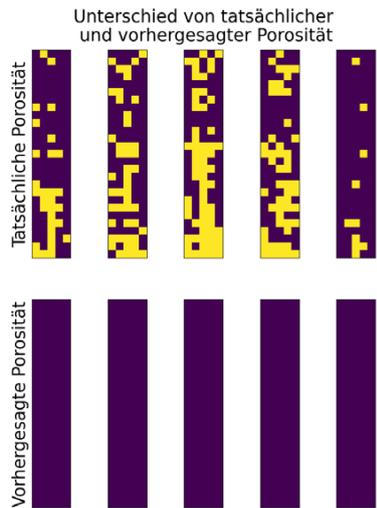
Probekörper 90



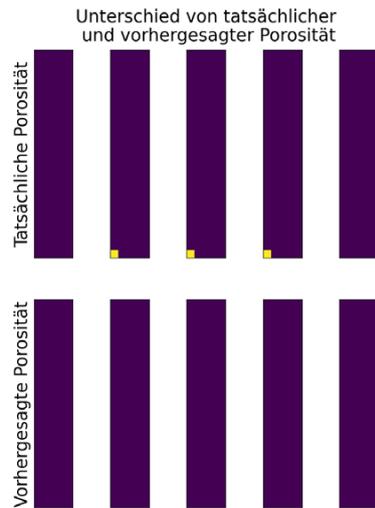
Probekörper 95

Modellart CNN, Klassengrenze 1 % Zellporosität, Testdatensatz

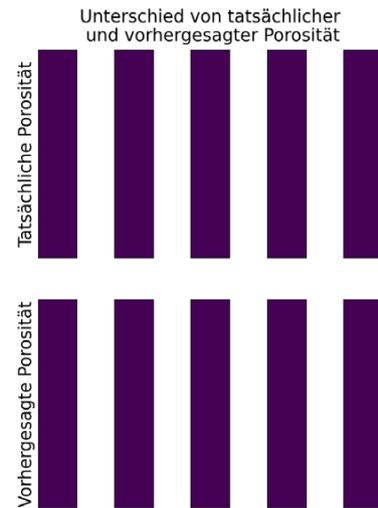




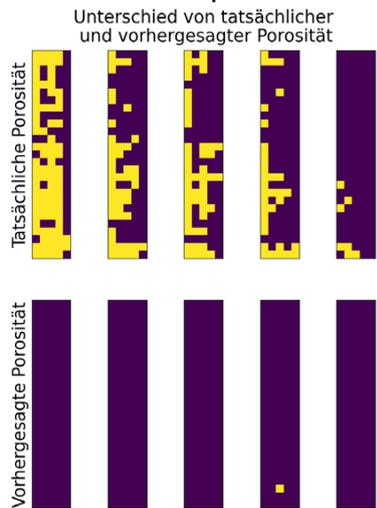
Probekörper 46



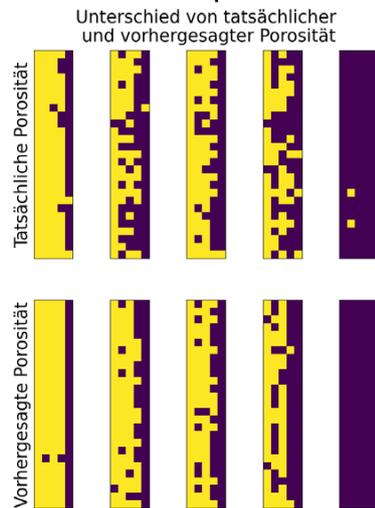
Probekörper 49



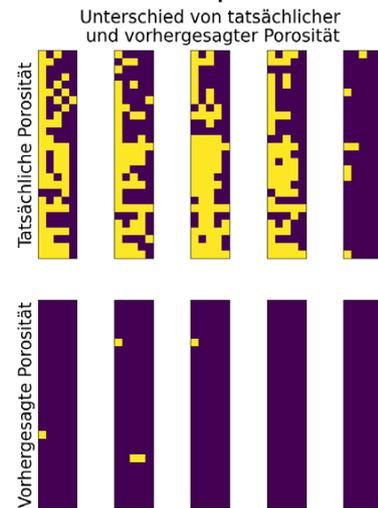
Probekörper 53



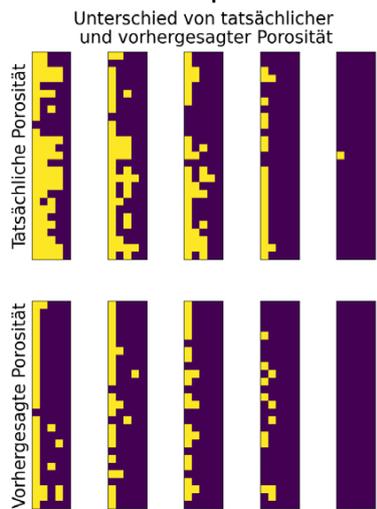
Probekörper 55



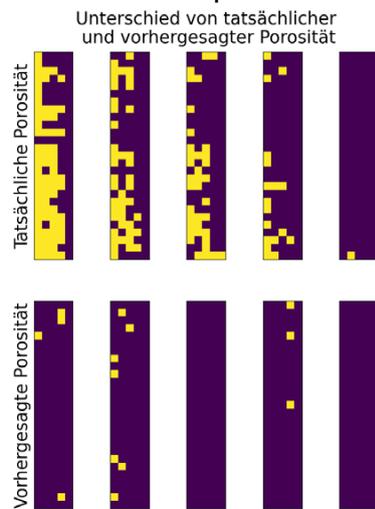
Probekörper 65



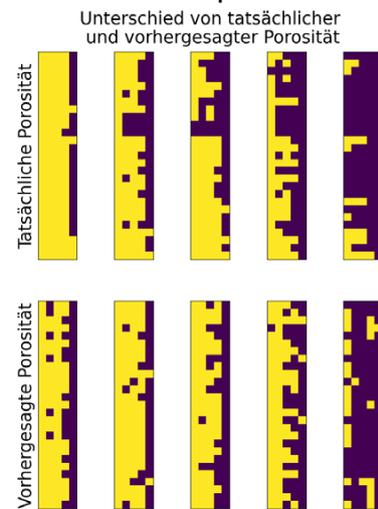
Probekörper 69



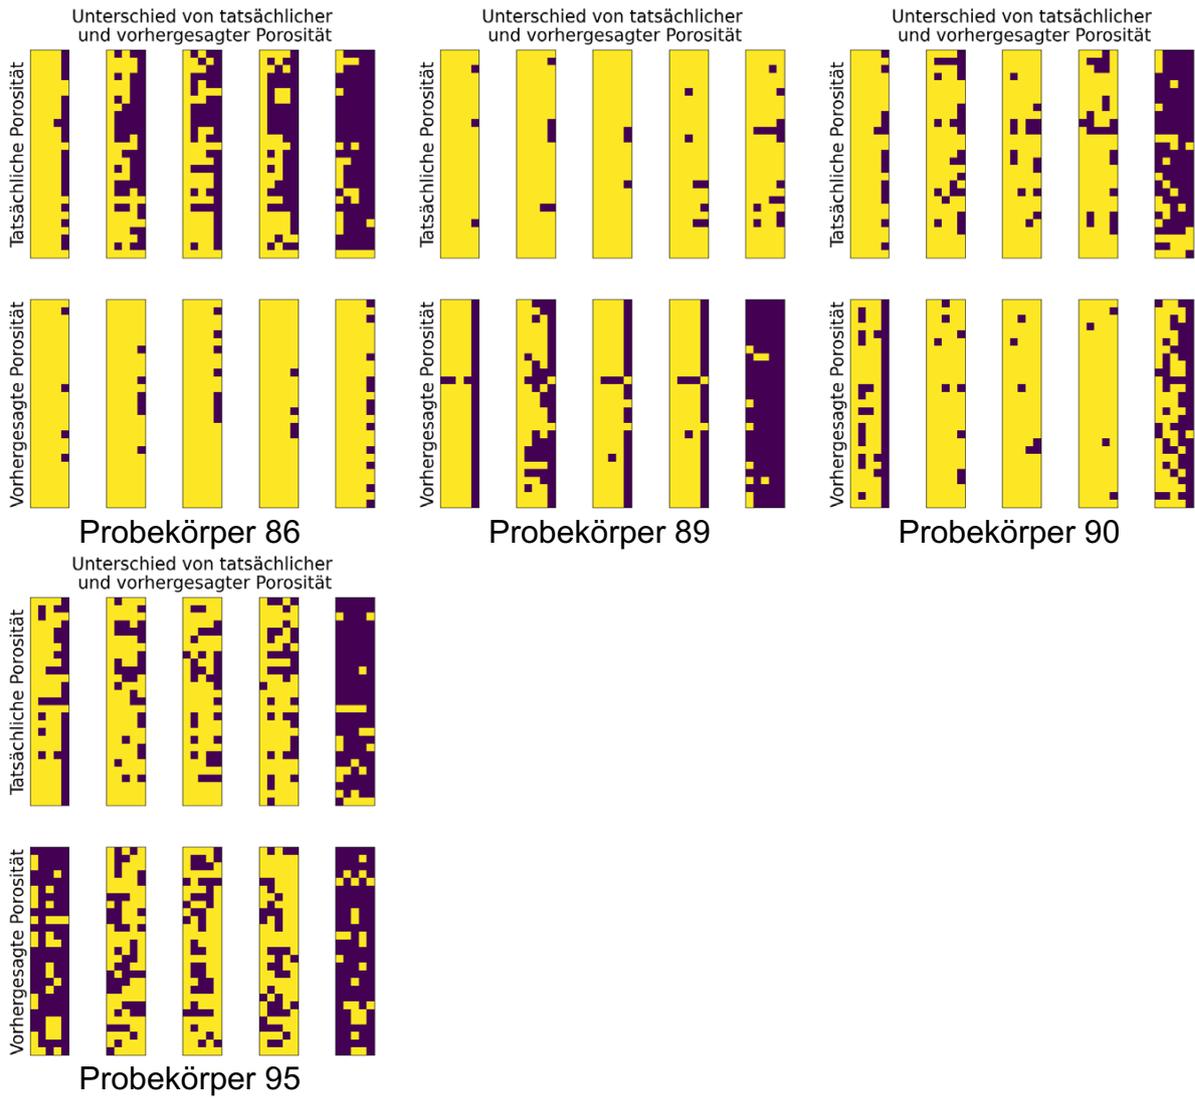
Probekörper 78



Probekörper 79

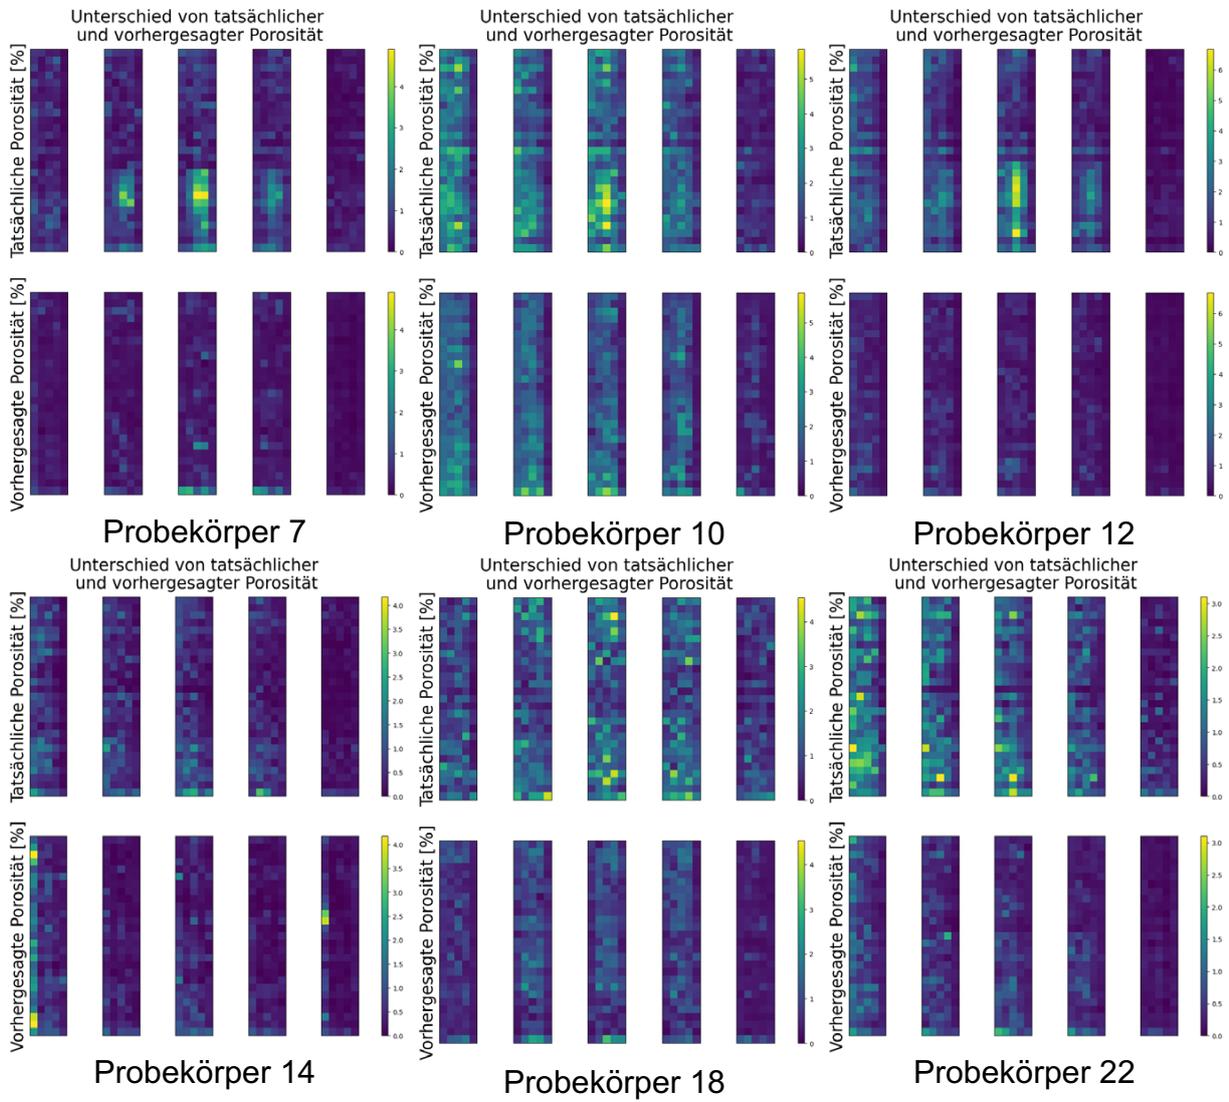


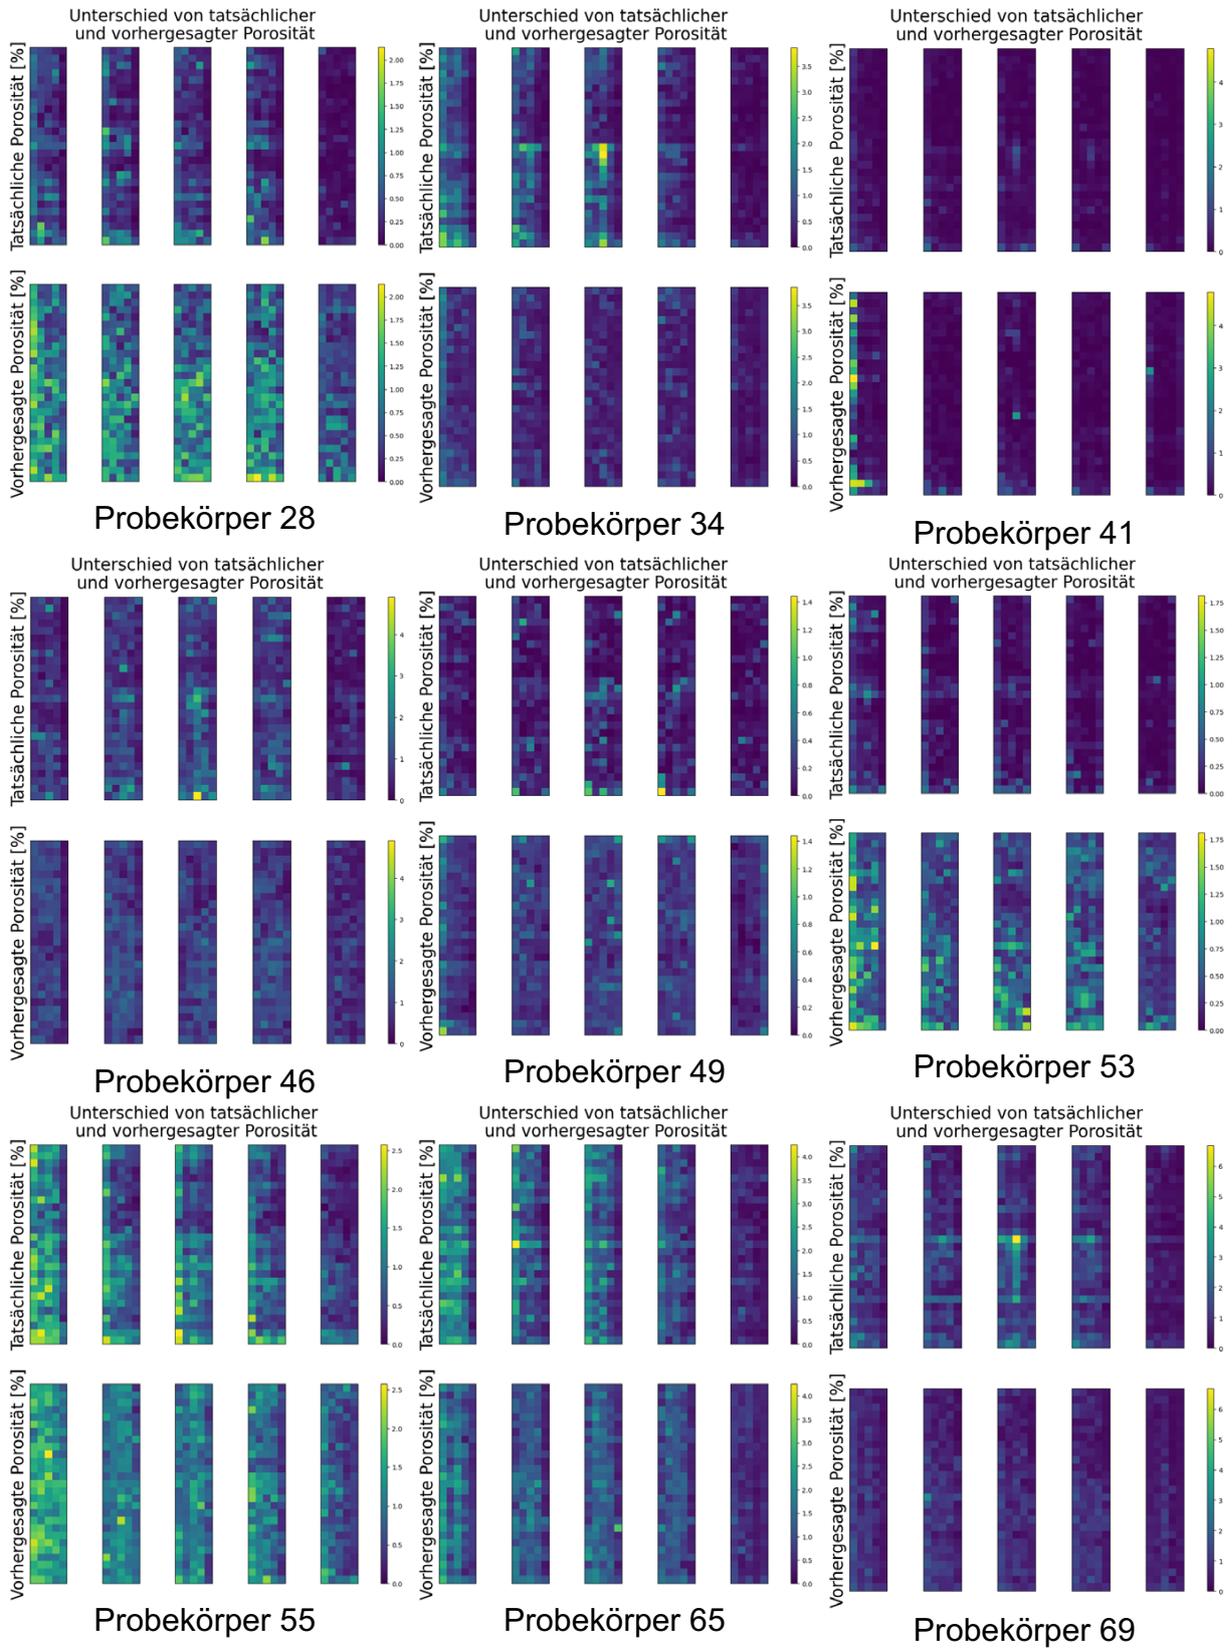
Probekörper 81

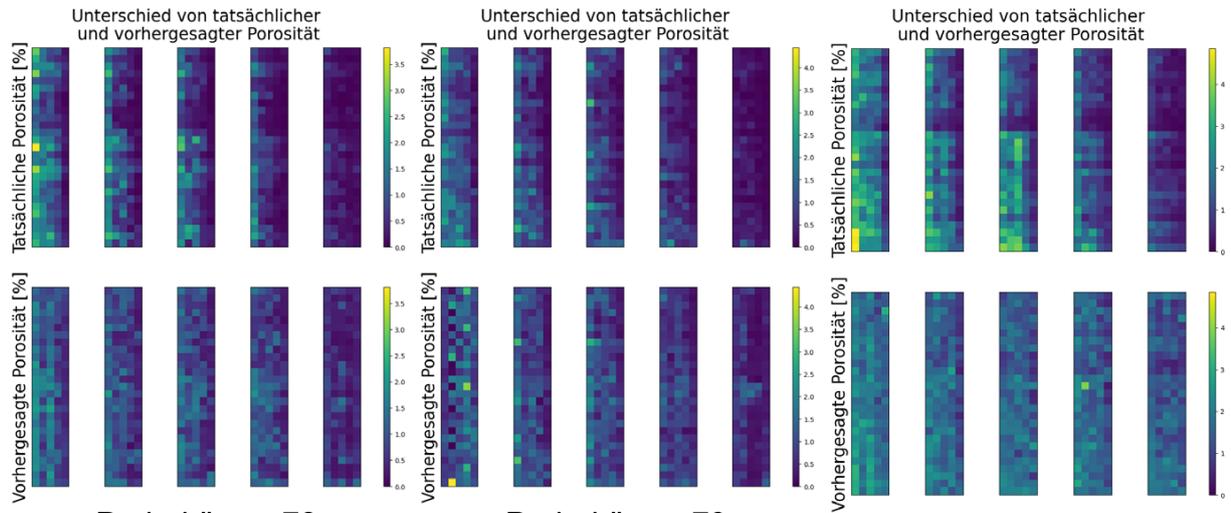


A2.3 Regression Körperschall

Modellart MLP, Testdatensatz



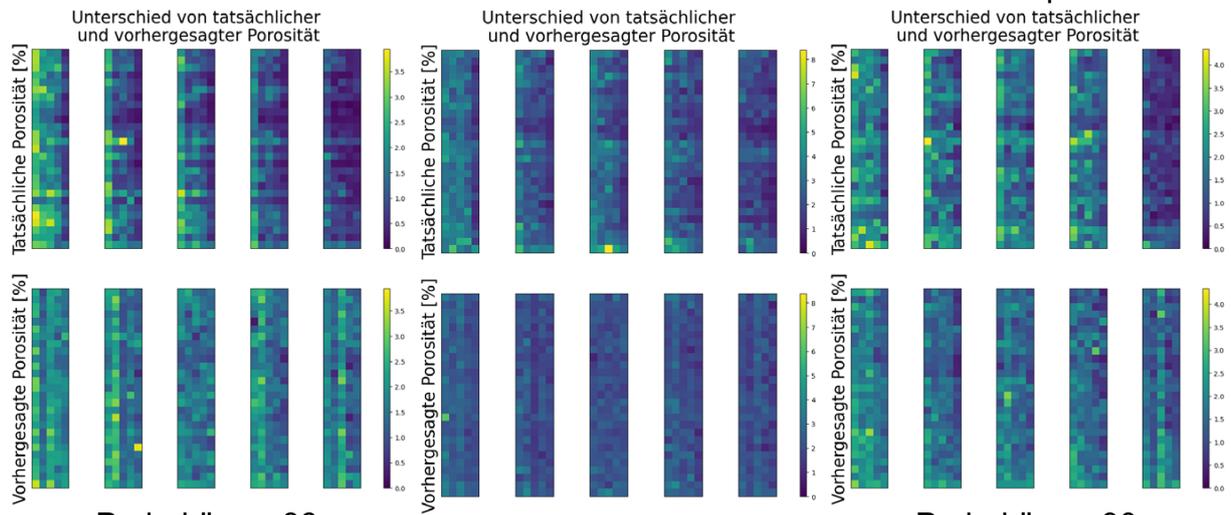




Probekörper 78

Probekörper 79

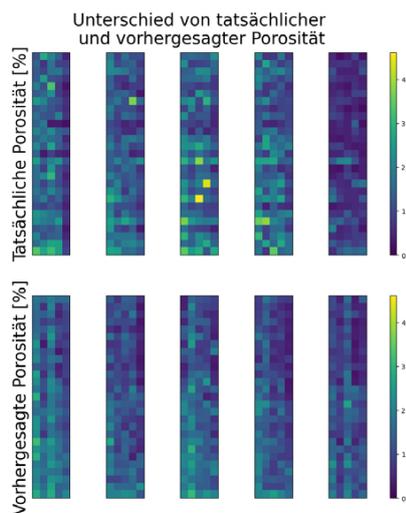
Probekörper 81



Probekörper 86

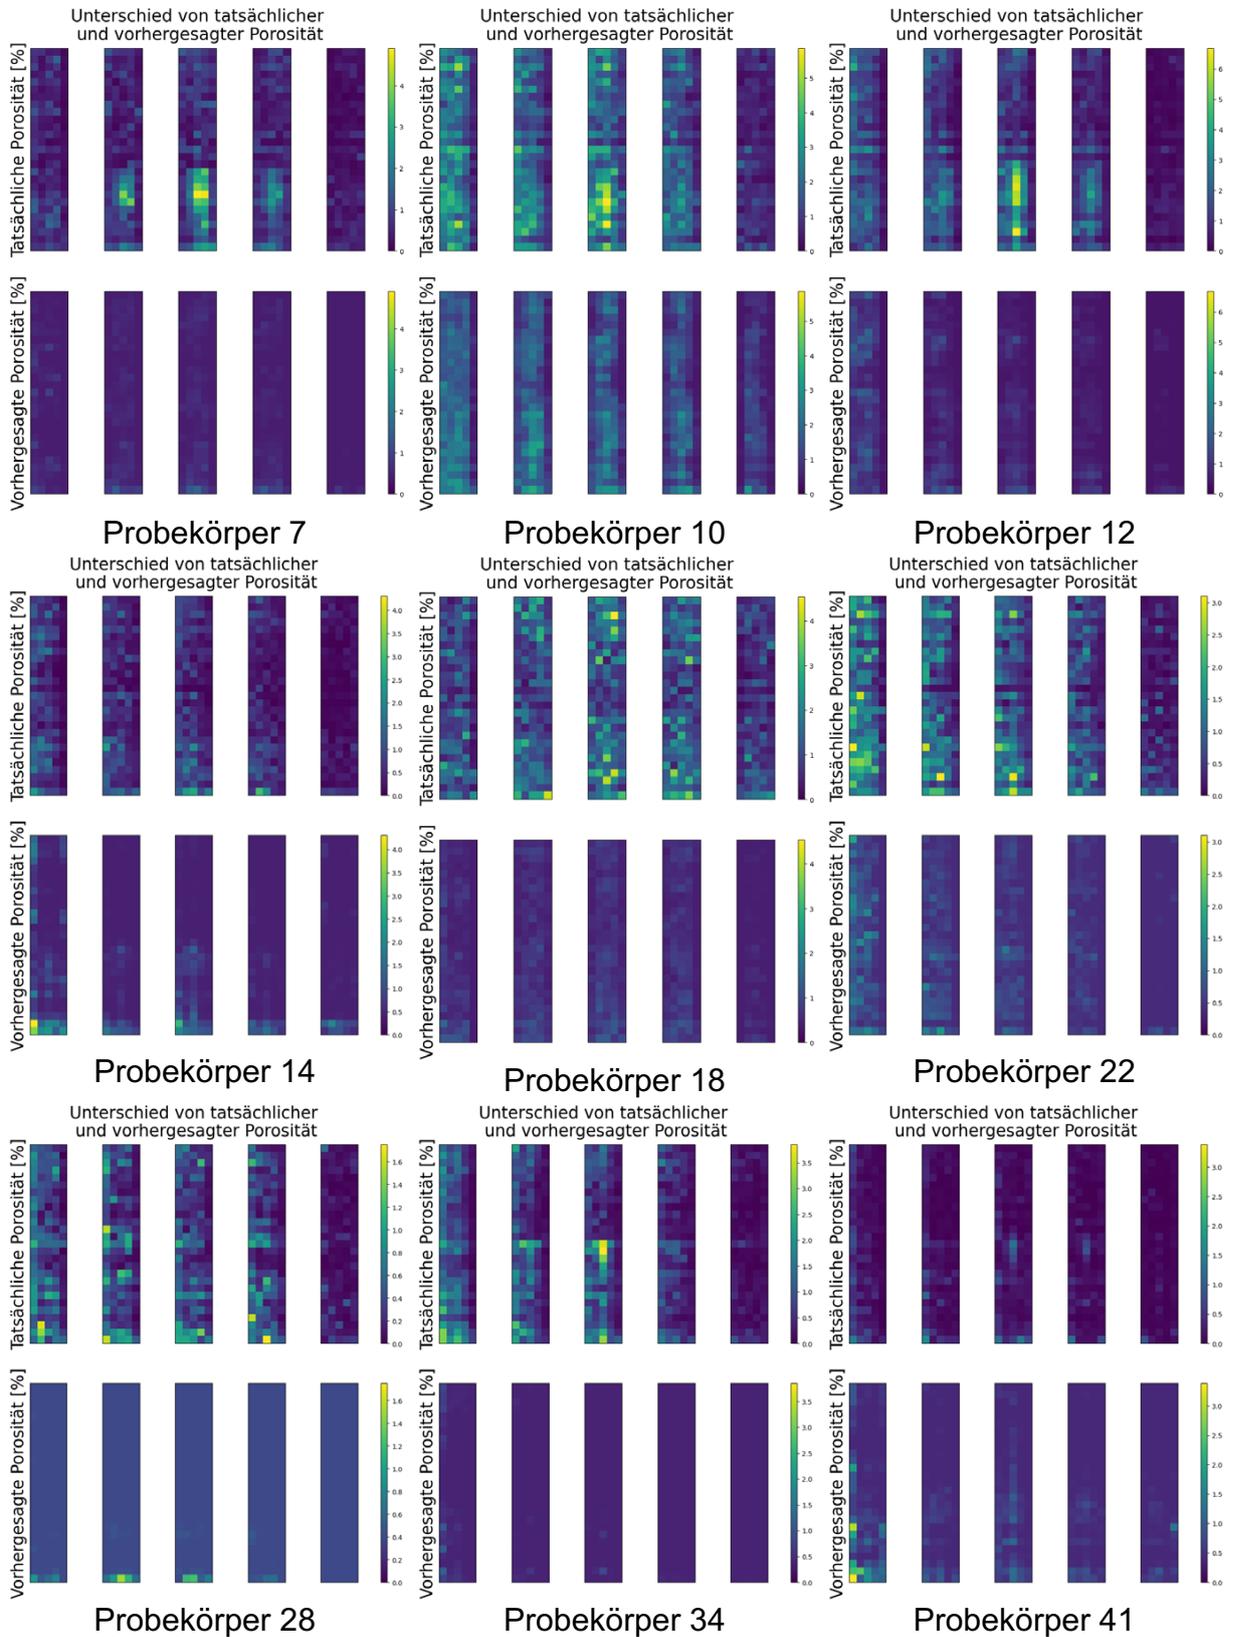
Probekörper 89

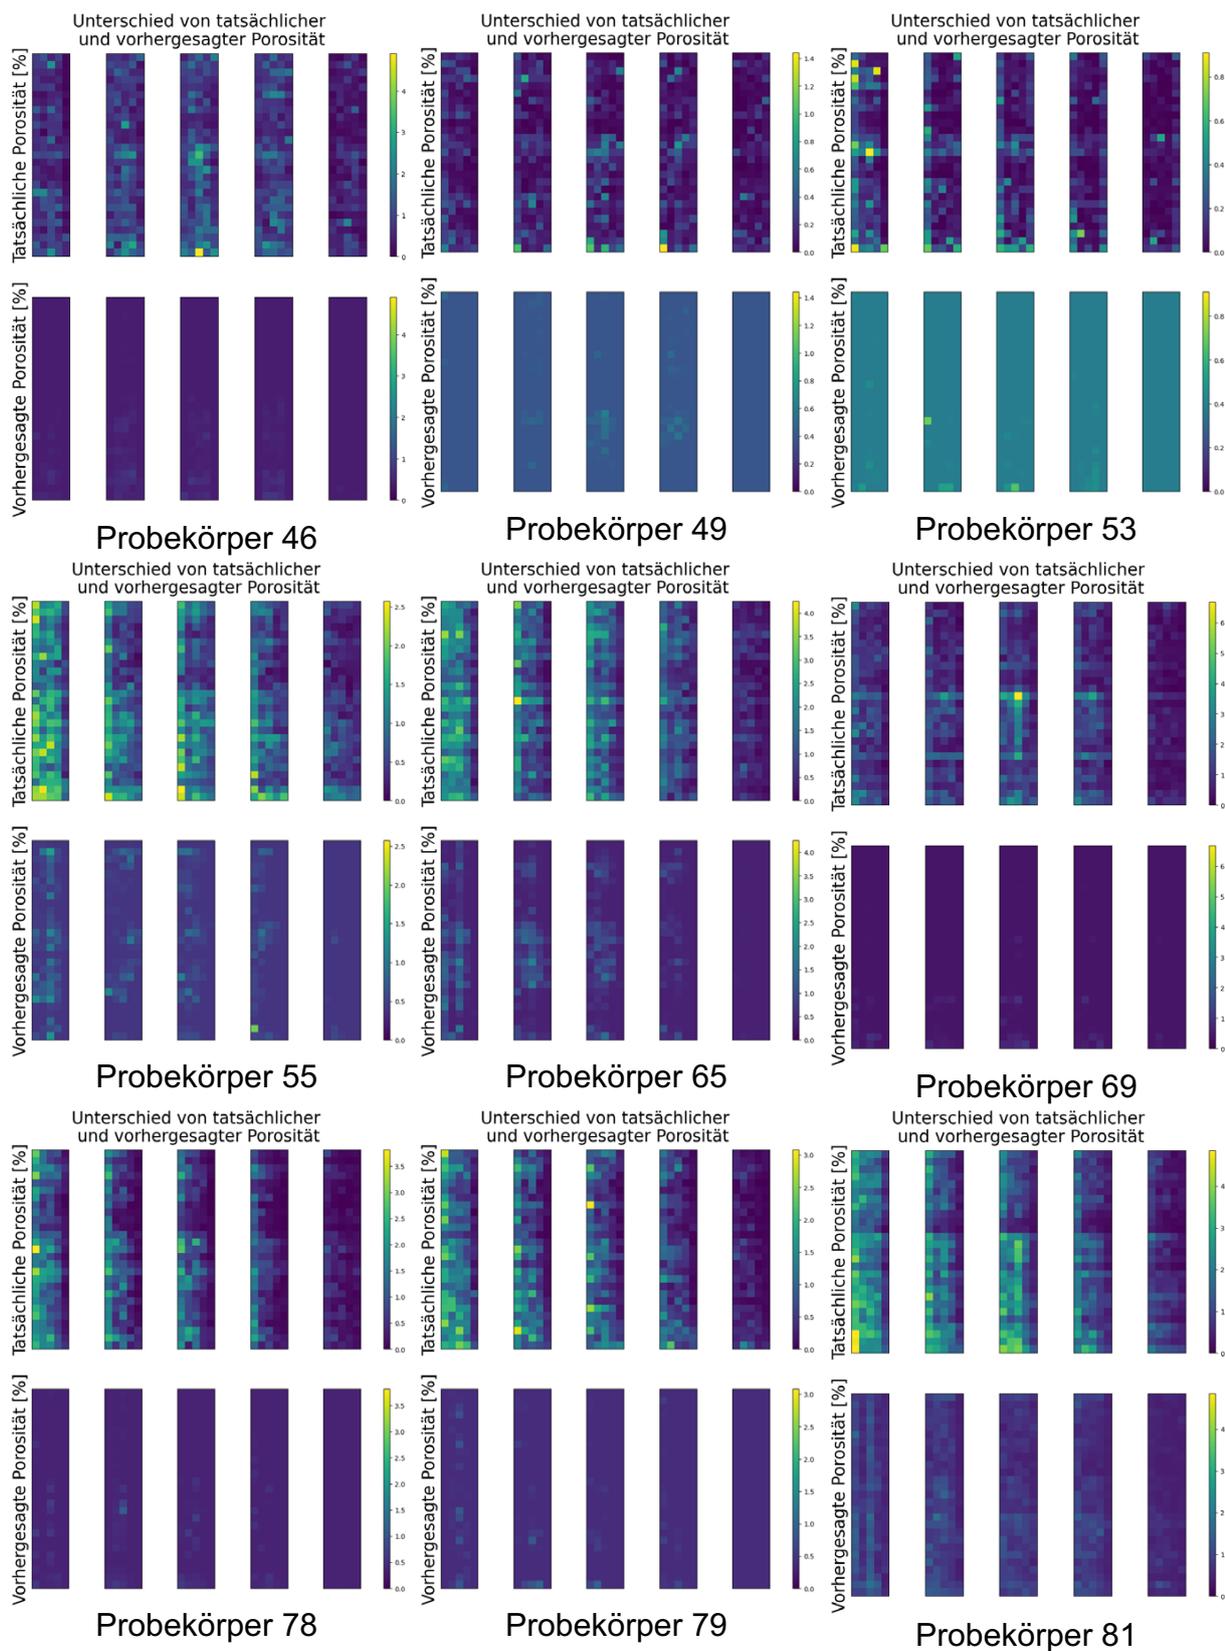
Probekörper 90

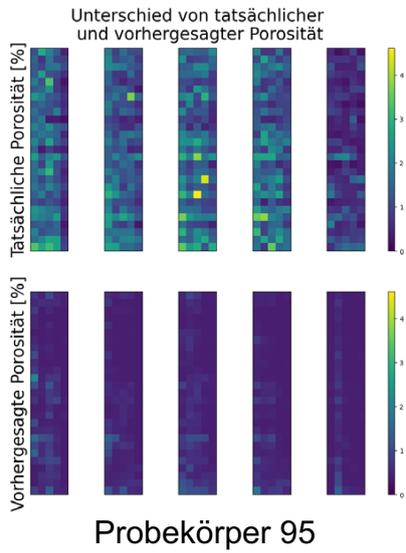
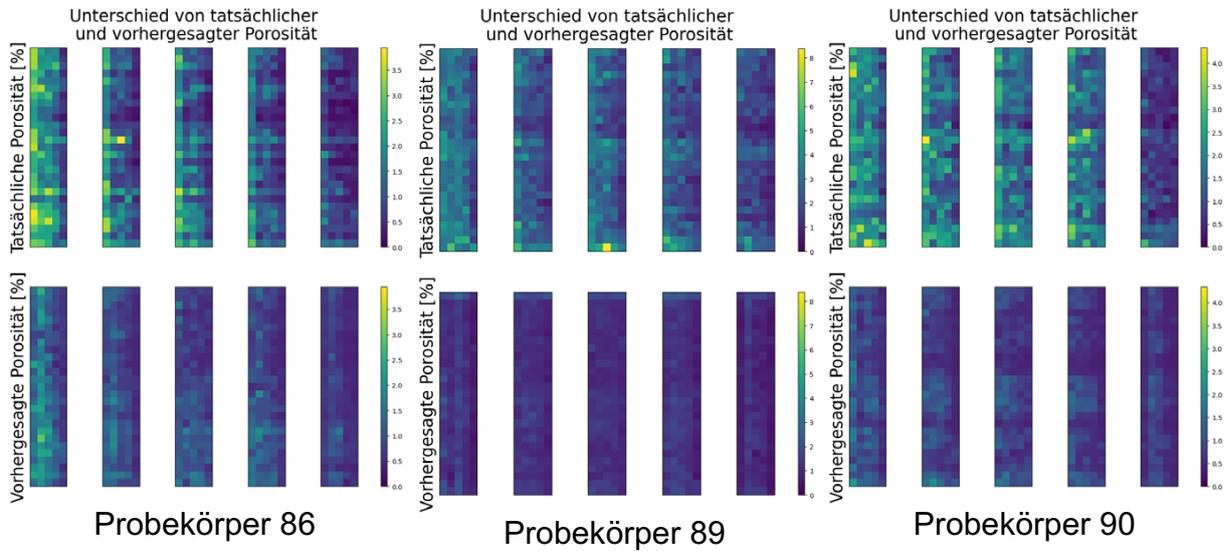


Probekörper 95

Modellart CNN, Testdatensatz

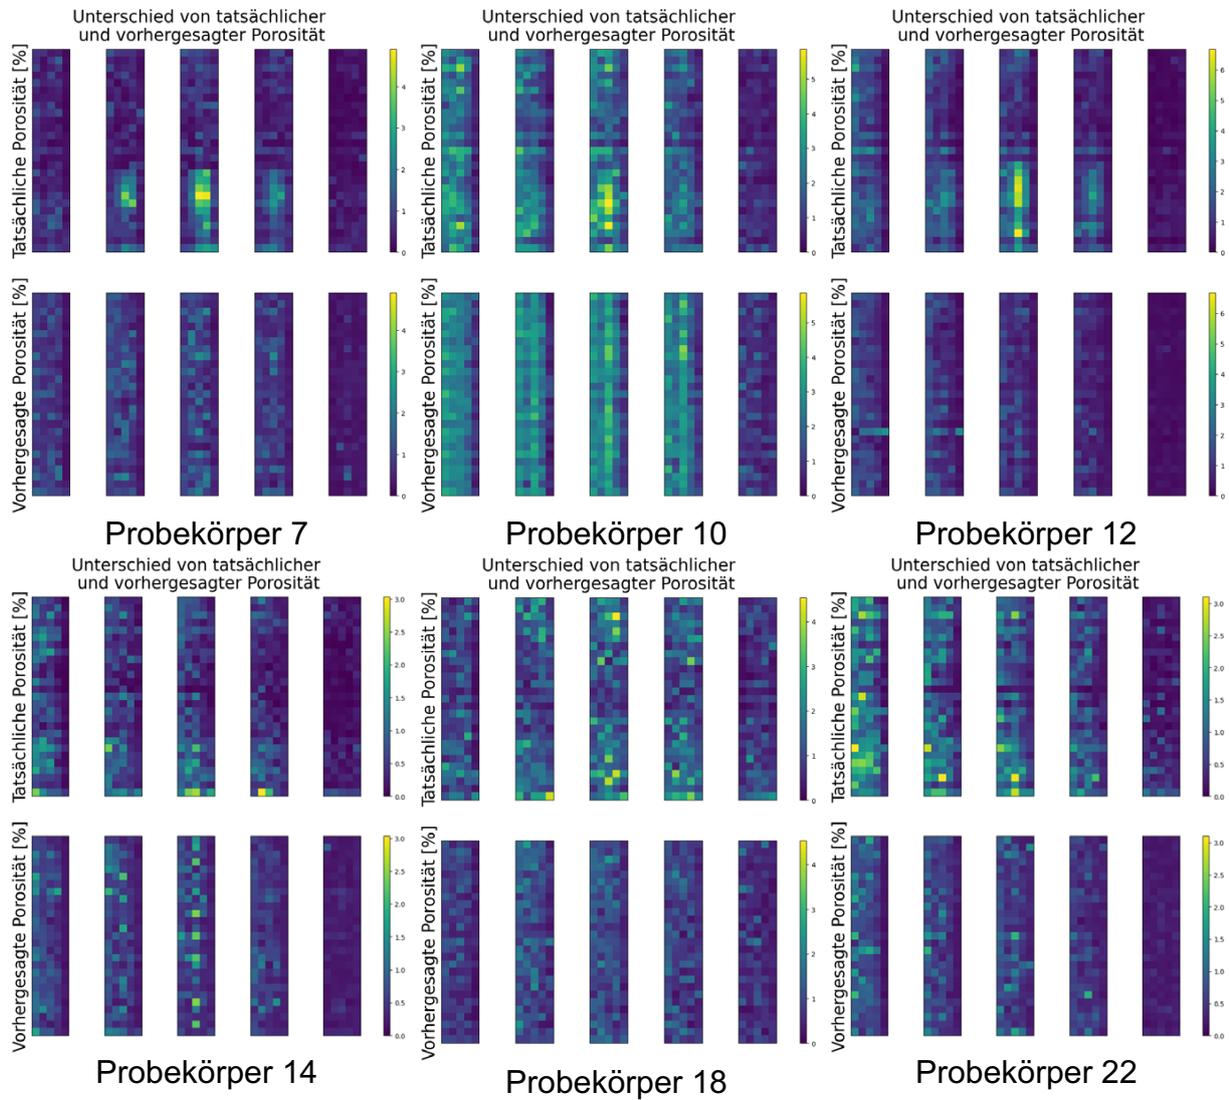


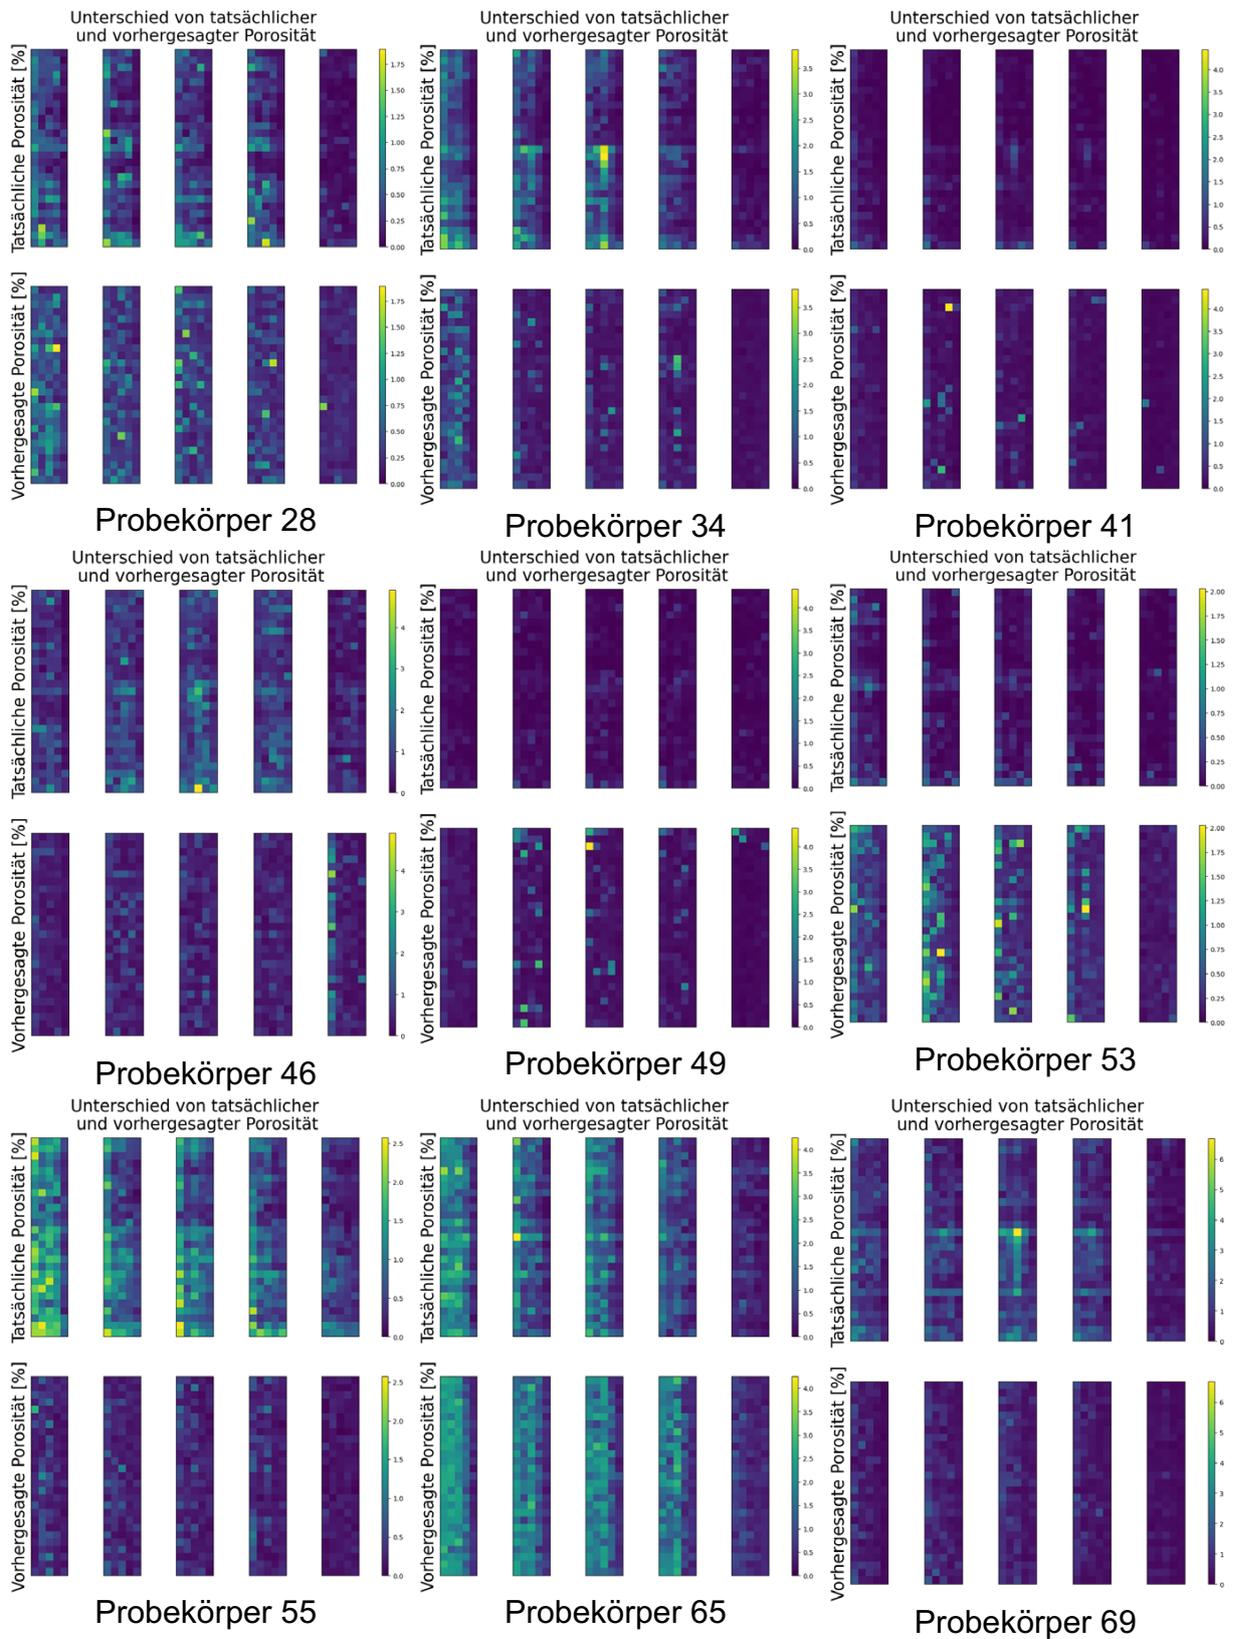


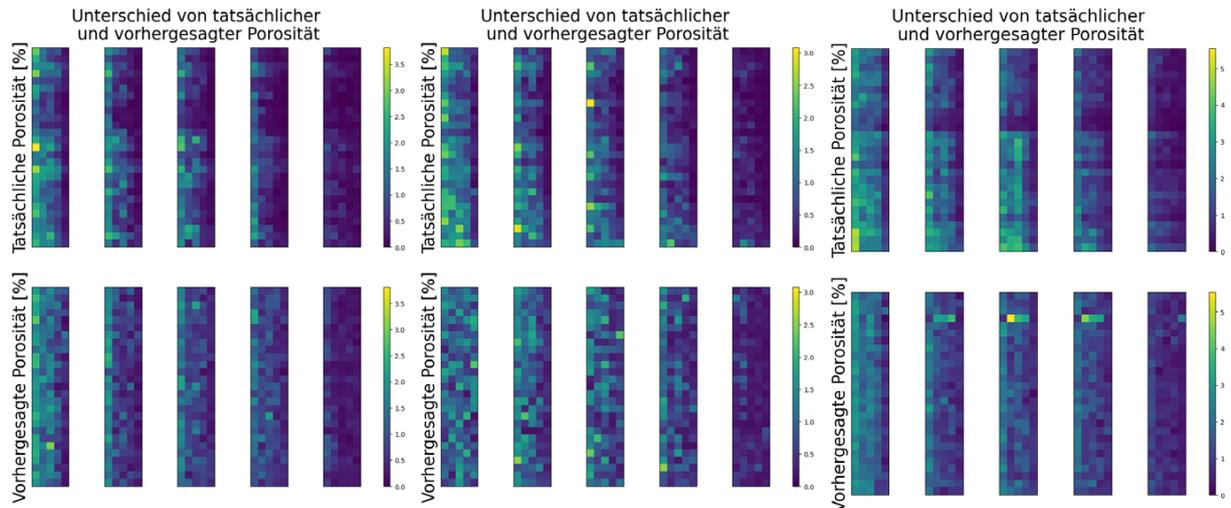


A2.4 Regression Fotodiodenarray

Modellart MLP, Testdatensatz



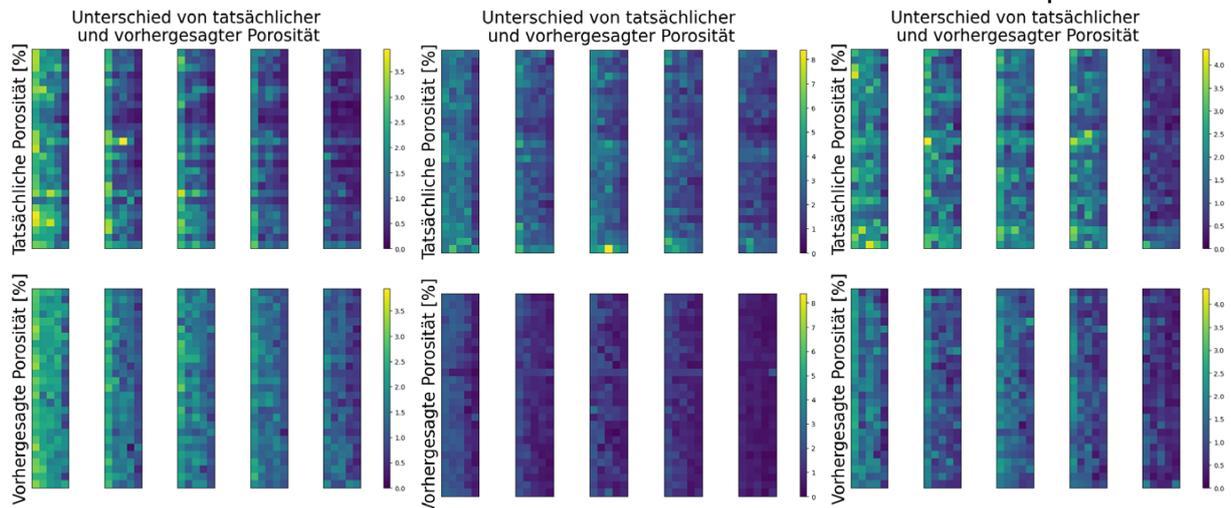




Probekörper 78

Probekörper 79

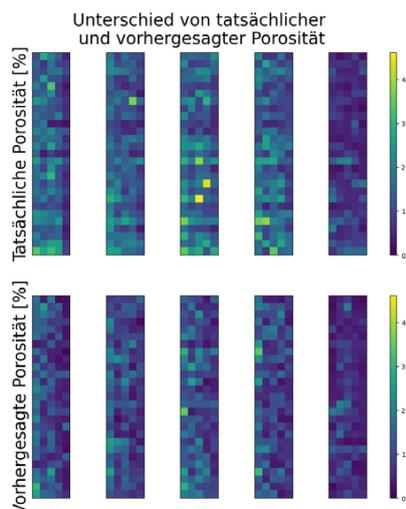
Probekörper 81



Probekörper 86

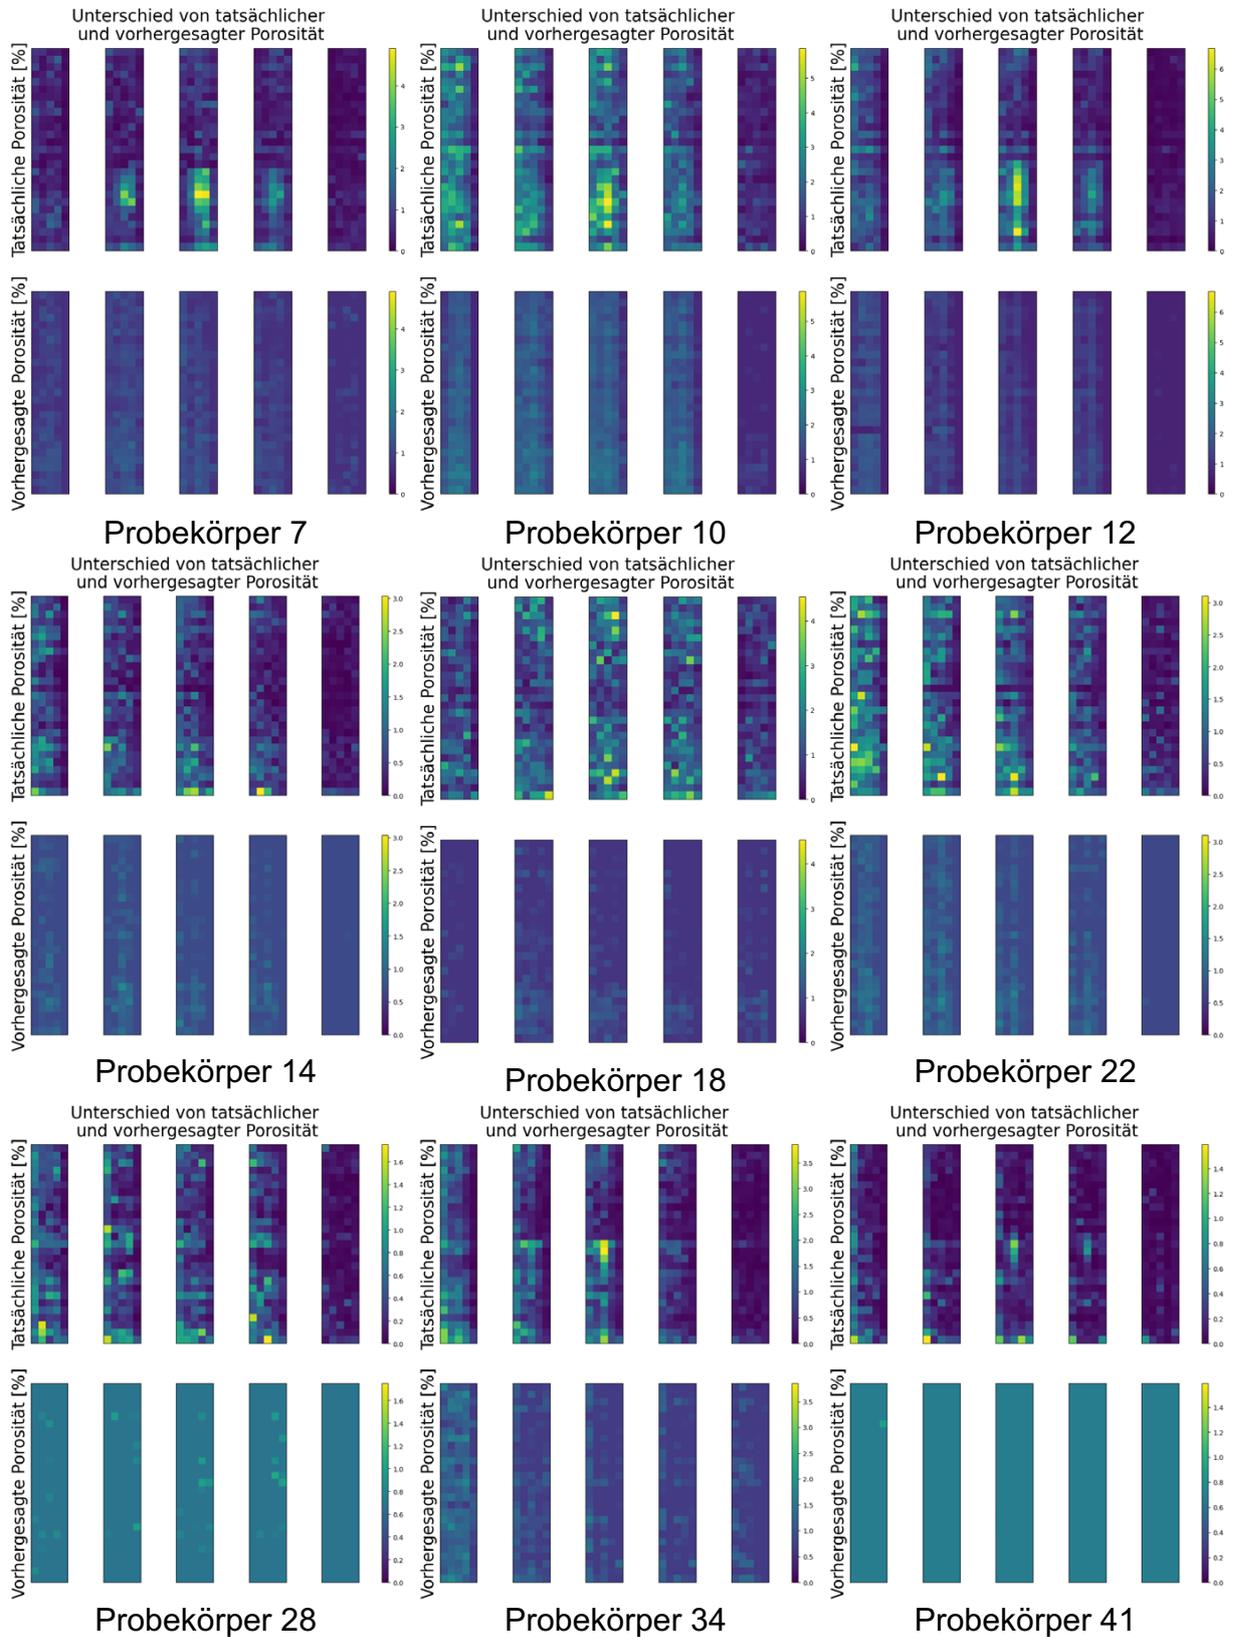
Probekörper 89

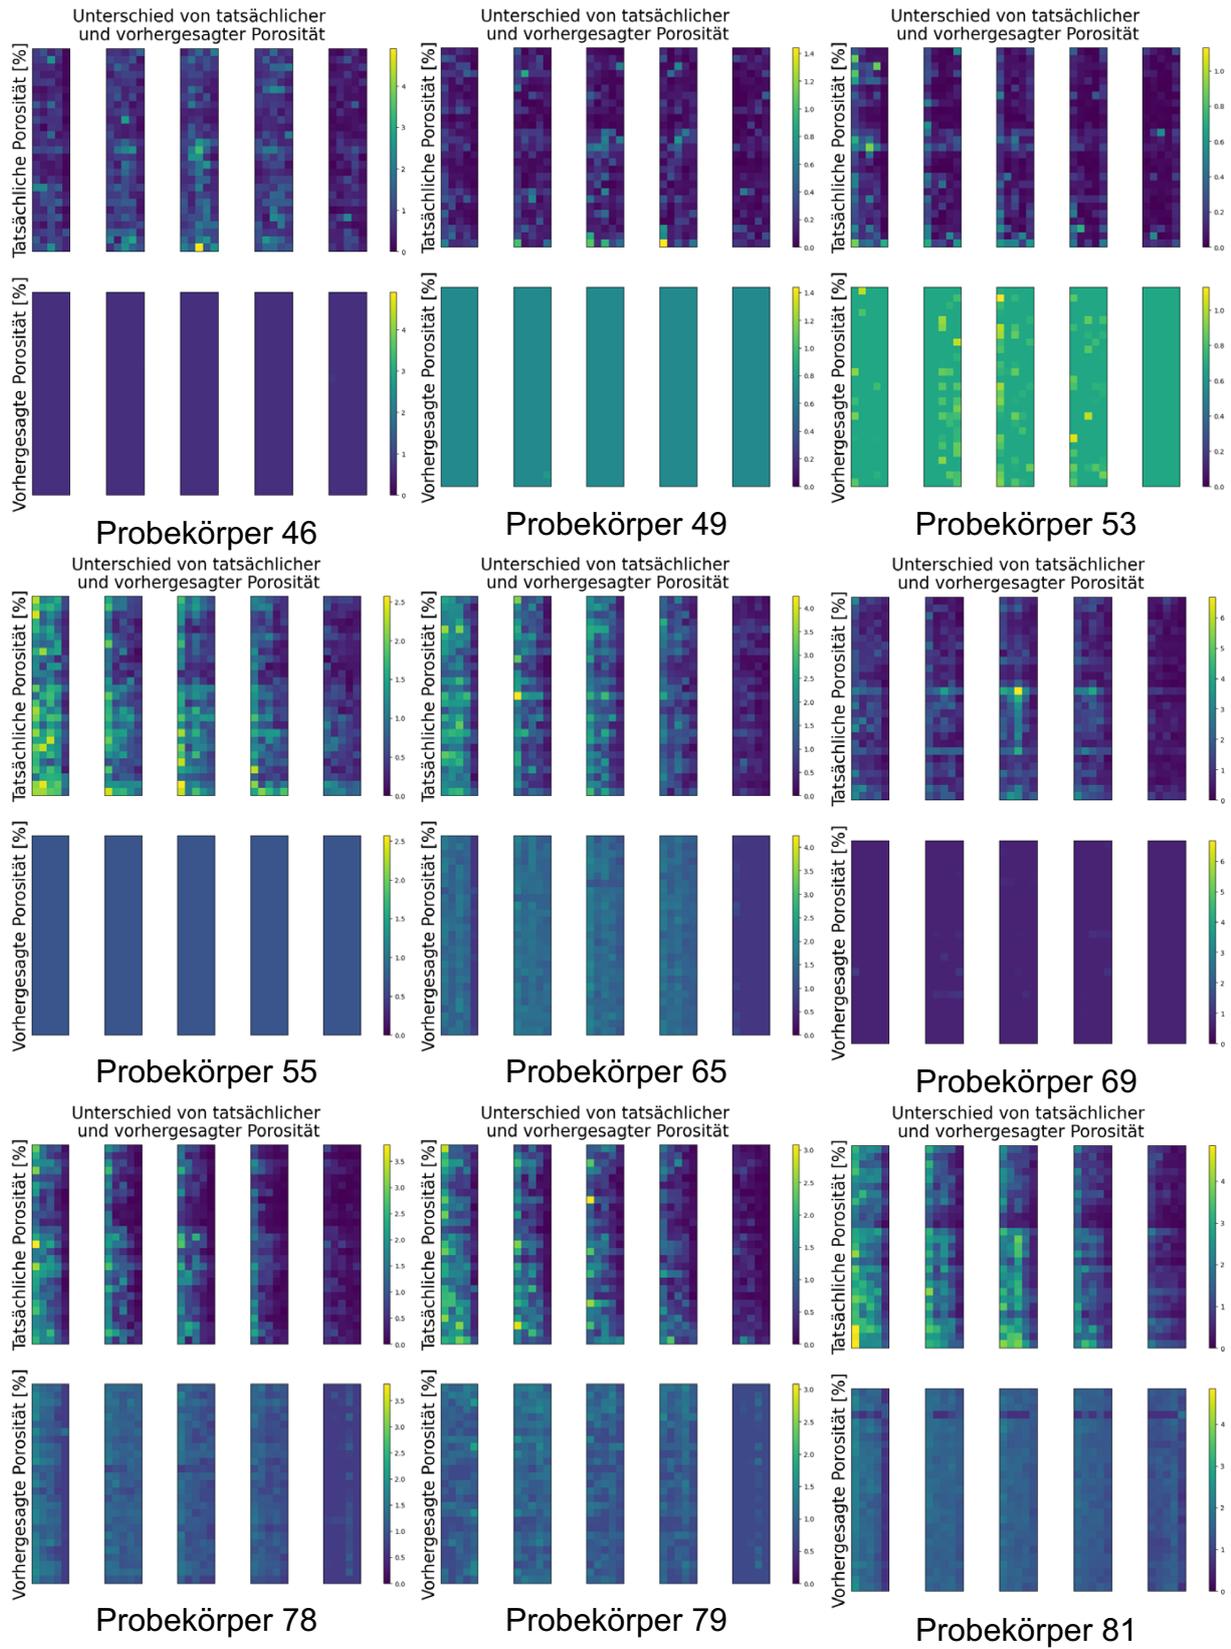
Probekörper 90

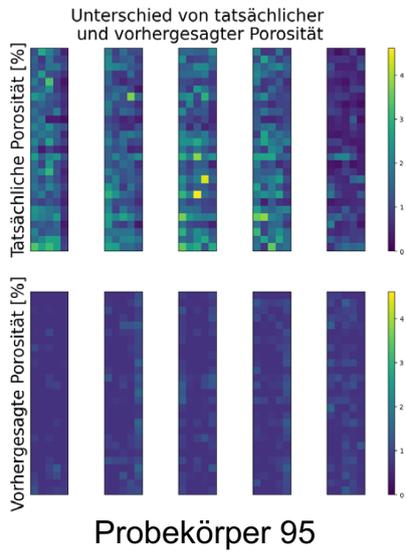
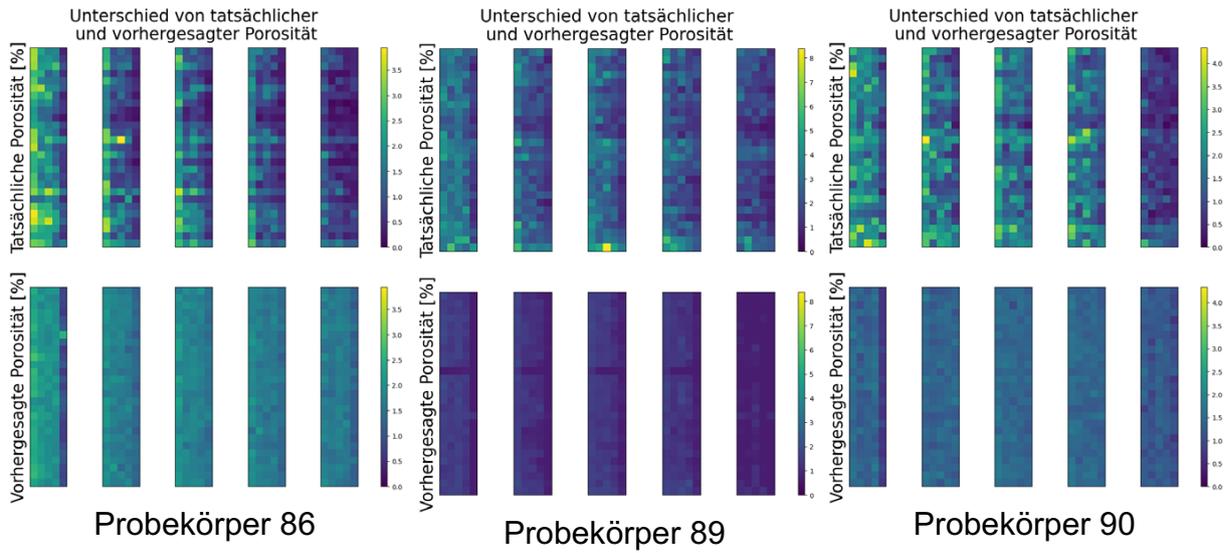


Probekörper 95

Modellart CNN, Testdatensatz

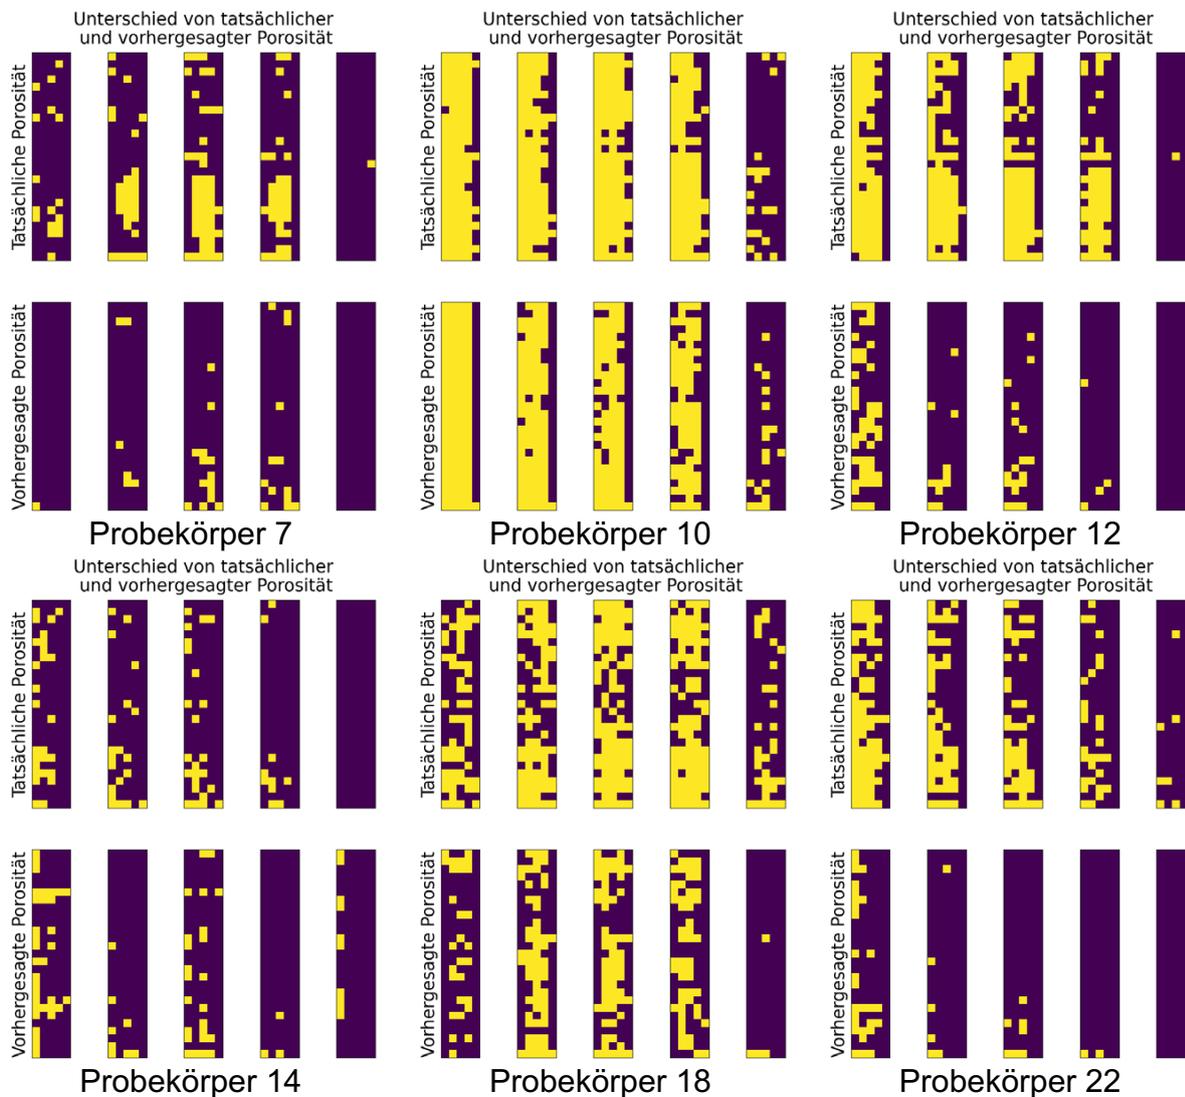


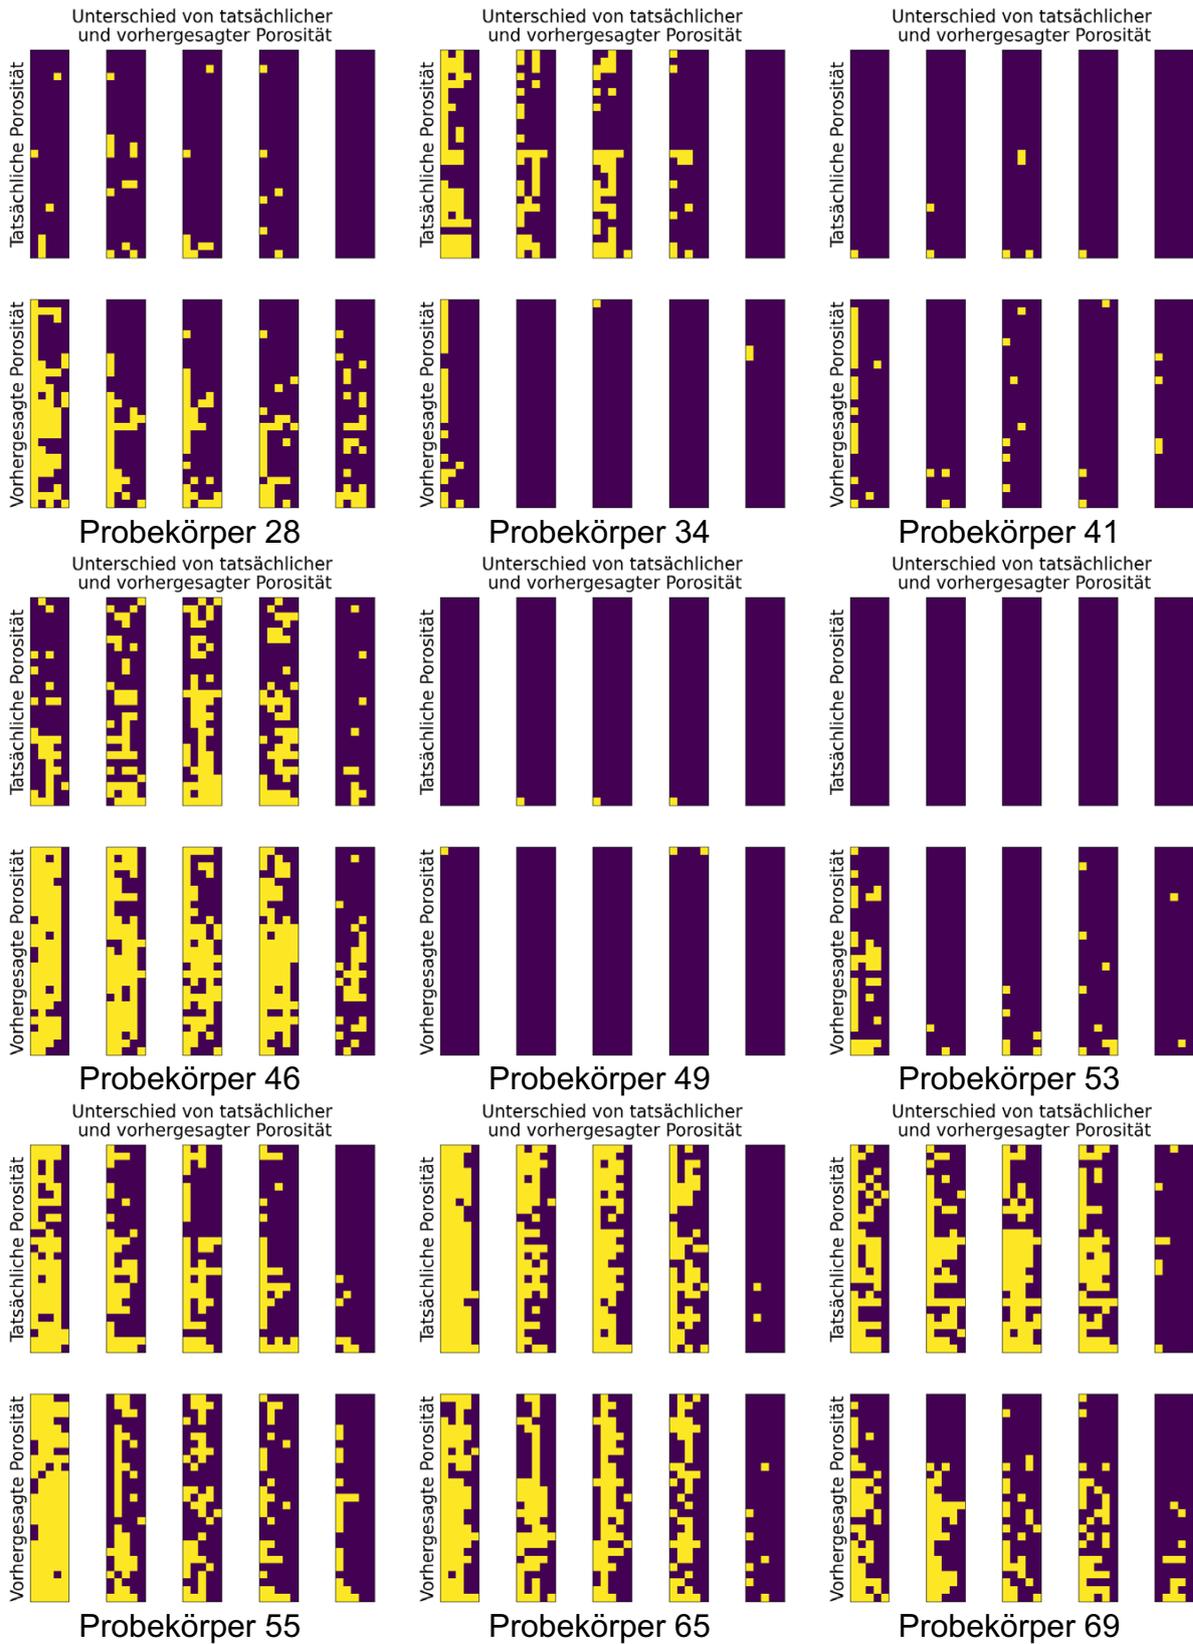




A2.5 Datenfusion Klassifikation

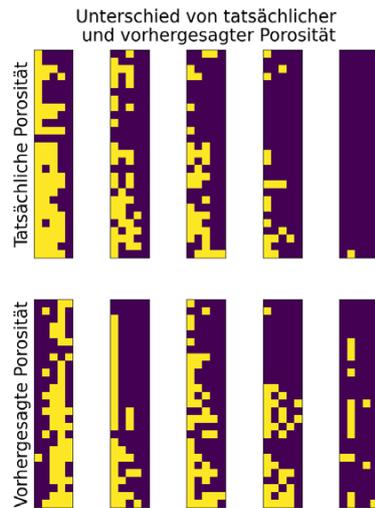
Modellart MLP, Klassengrenze 1 % Zellporosität, Testdatensatz



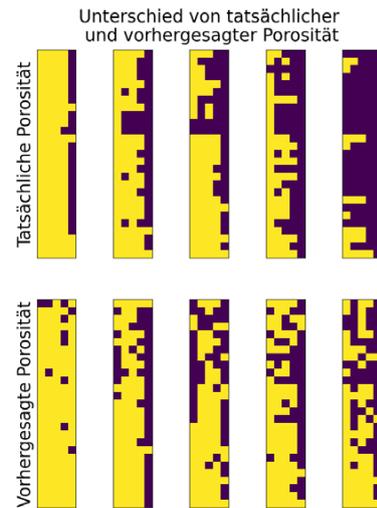




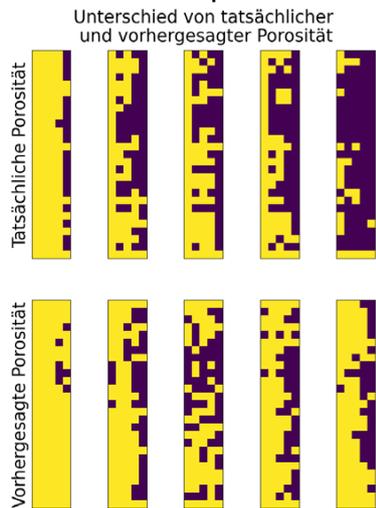
Probekörper 78



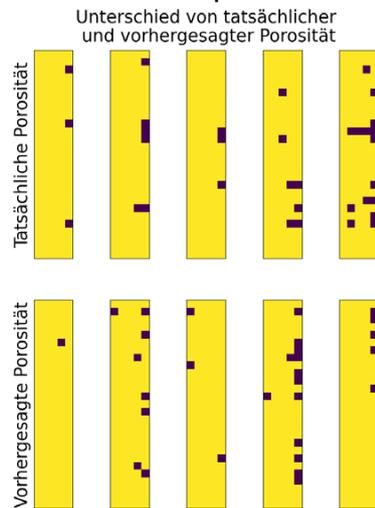
Probekörper 79



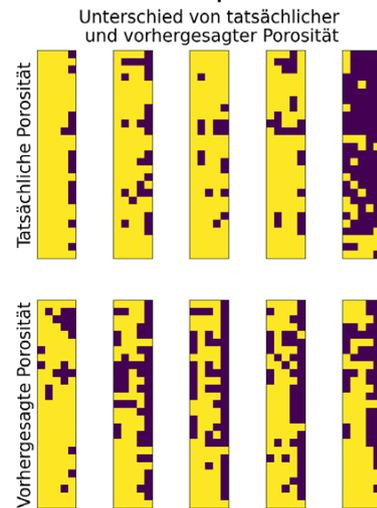
Probekörper 81



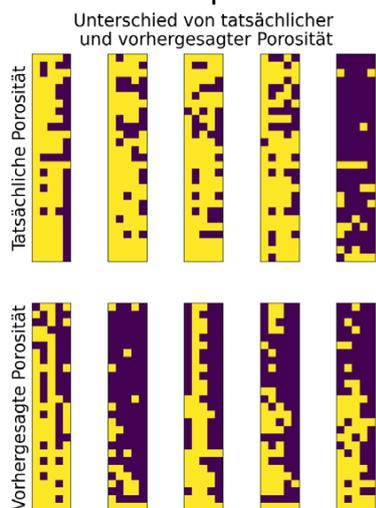
Probekörper 86



Probekörper 89

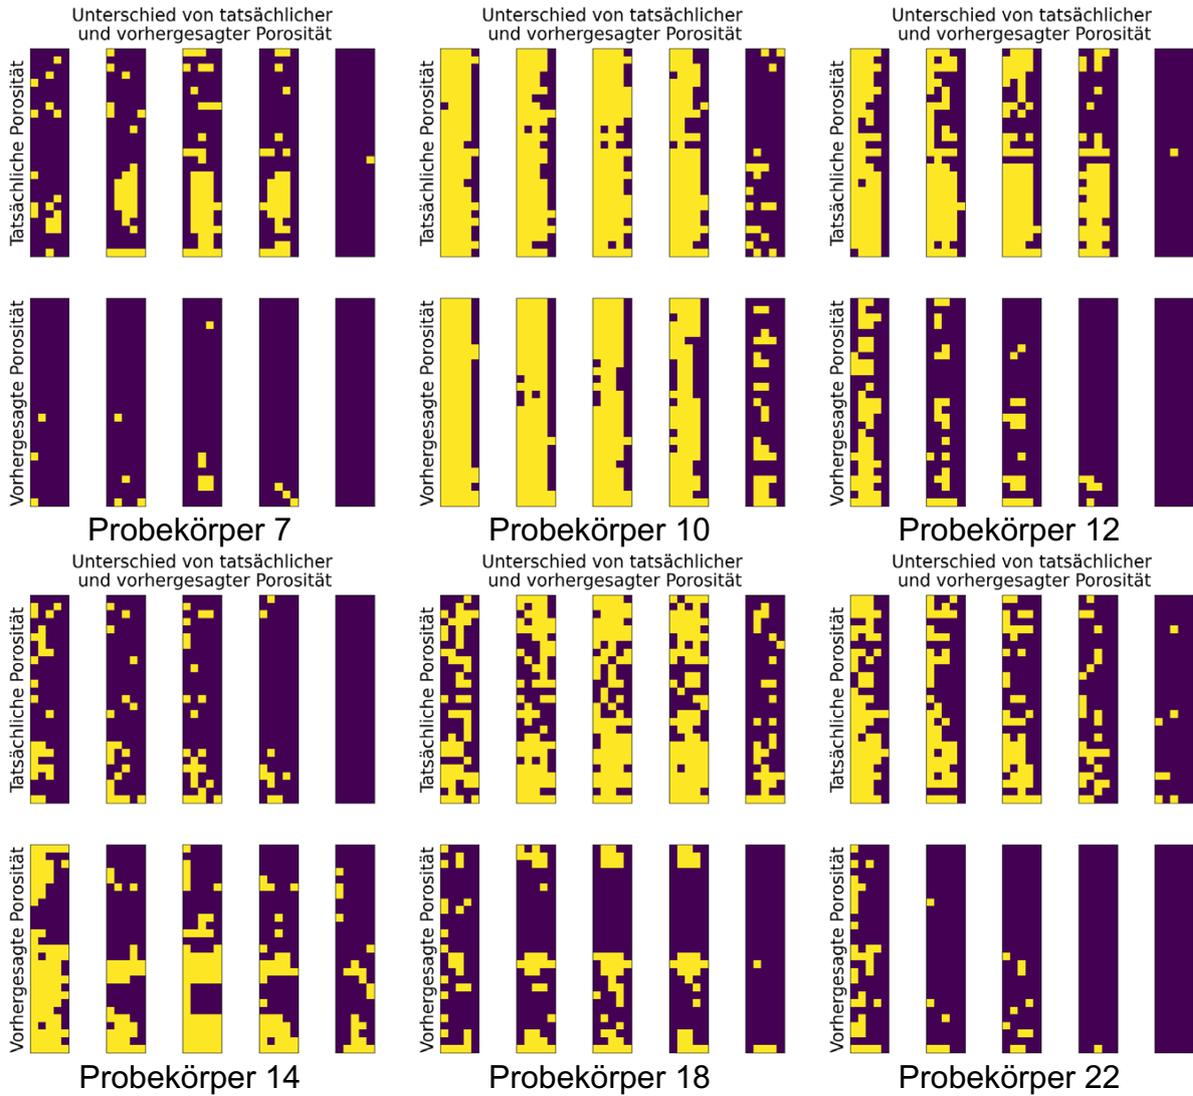


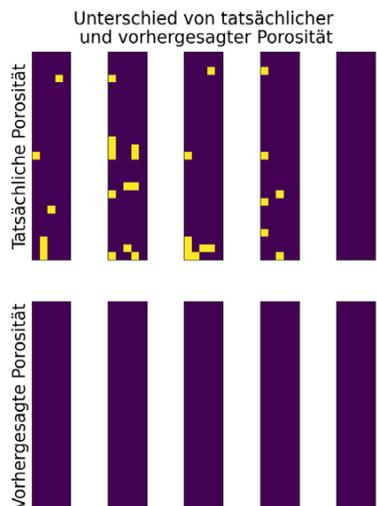
Probekörper 90



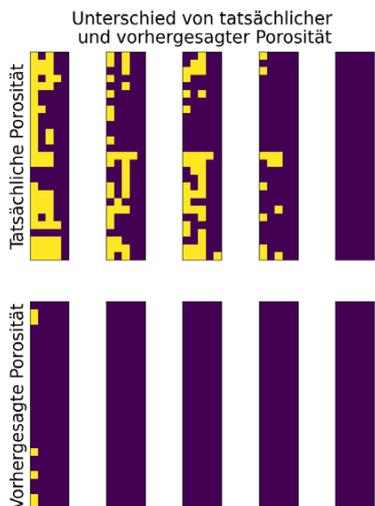
Probekörper 95

Modellart CNN (akustische Daten) + MLP (optische Daten), Klassengrenze 1 % Zellporosität, Testdatensatz

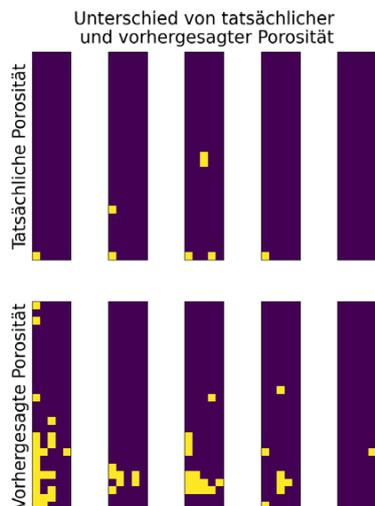




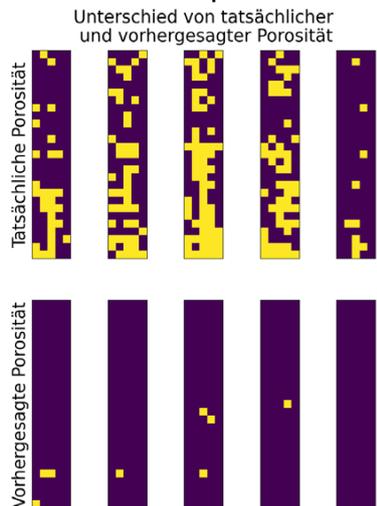
Probekörper 28



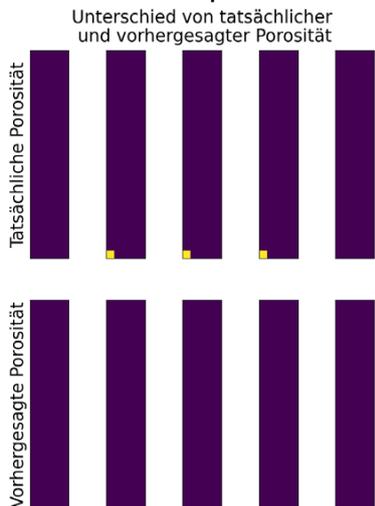
Probekörper 34



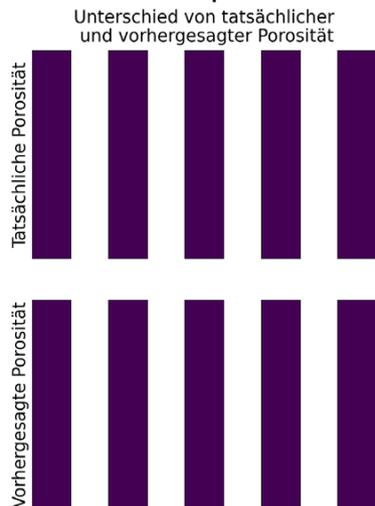
Probekörper 41



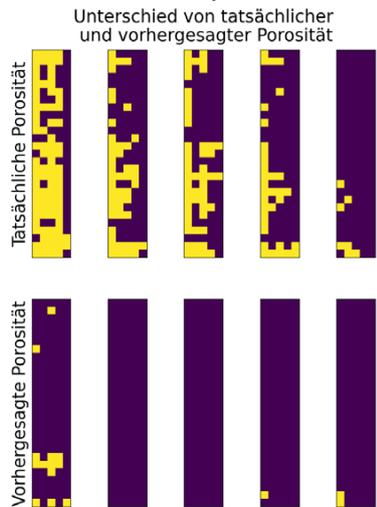
Probekörper 46



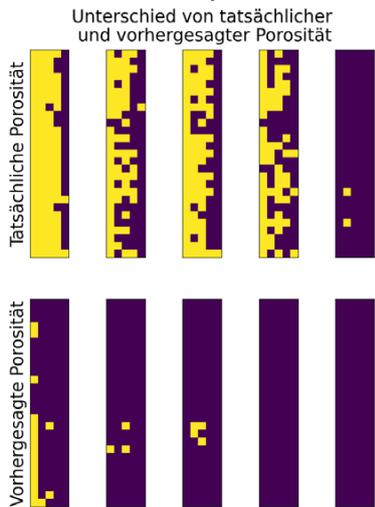
Probekörper 49



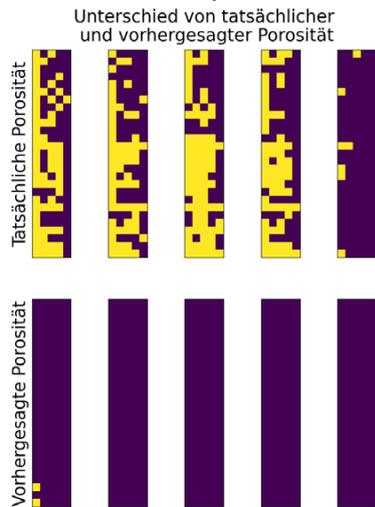
Probekörper 53



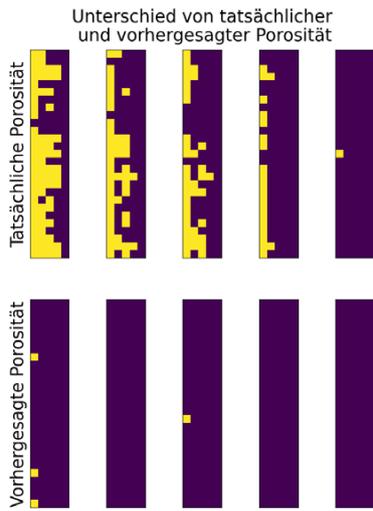
Probekörper 55



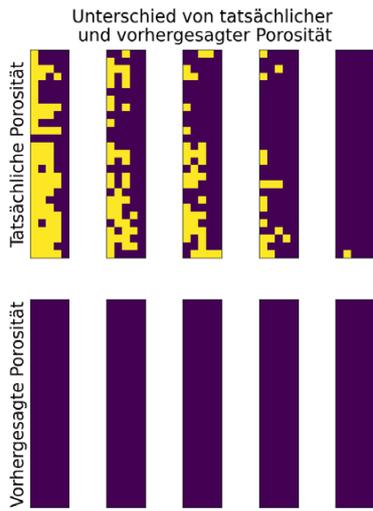
Probekörper 65



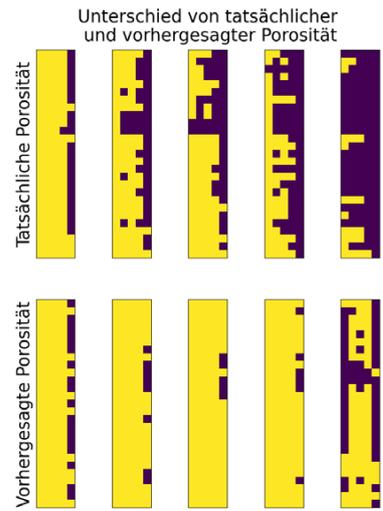
Probekörper 69



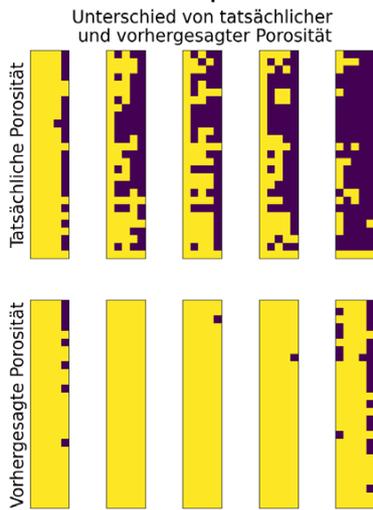
Probekörper 78



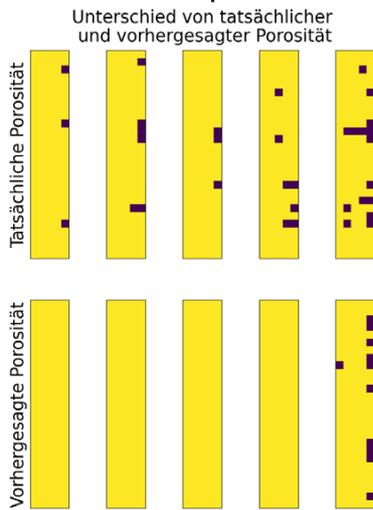
Probekörper 79



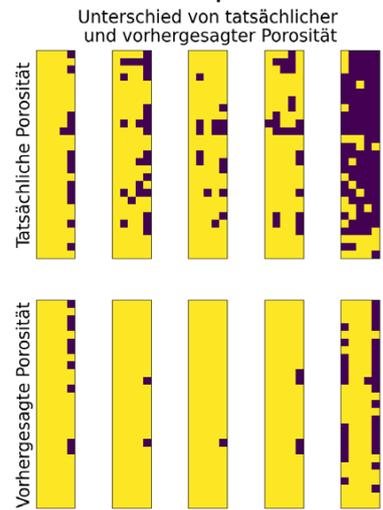
Probekörper 81



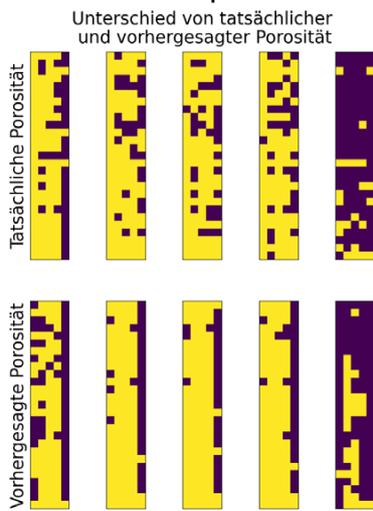
Probekörper 86



Probekörper 89

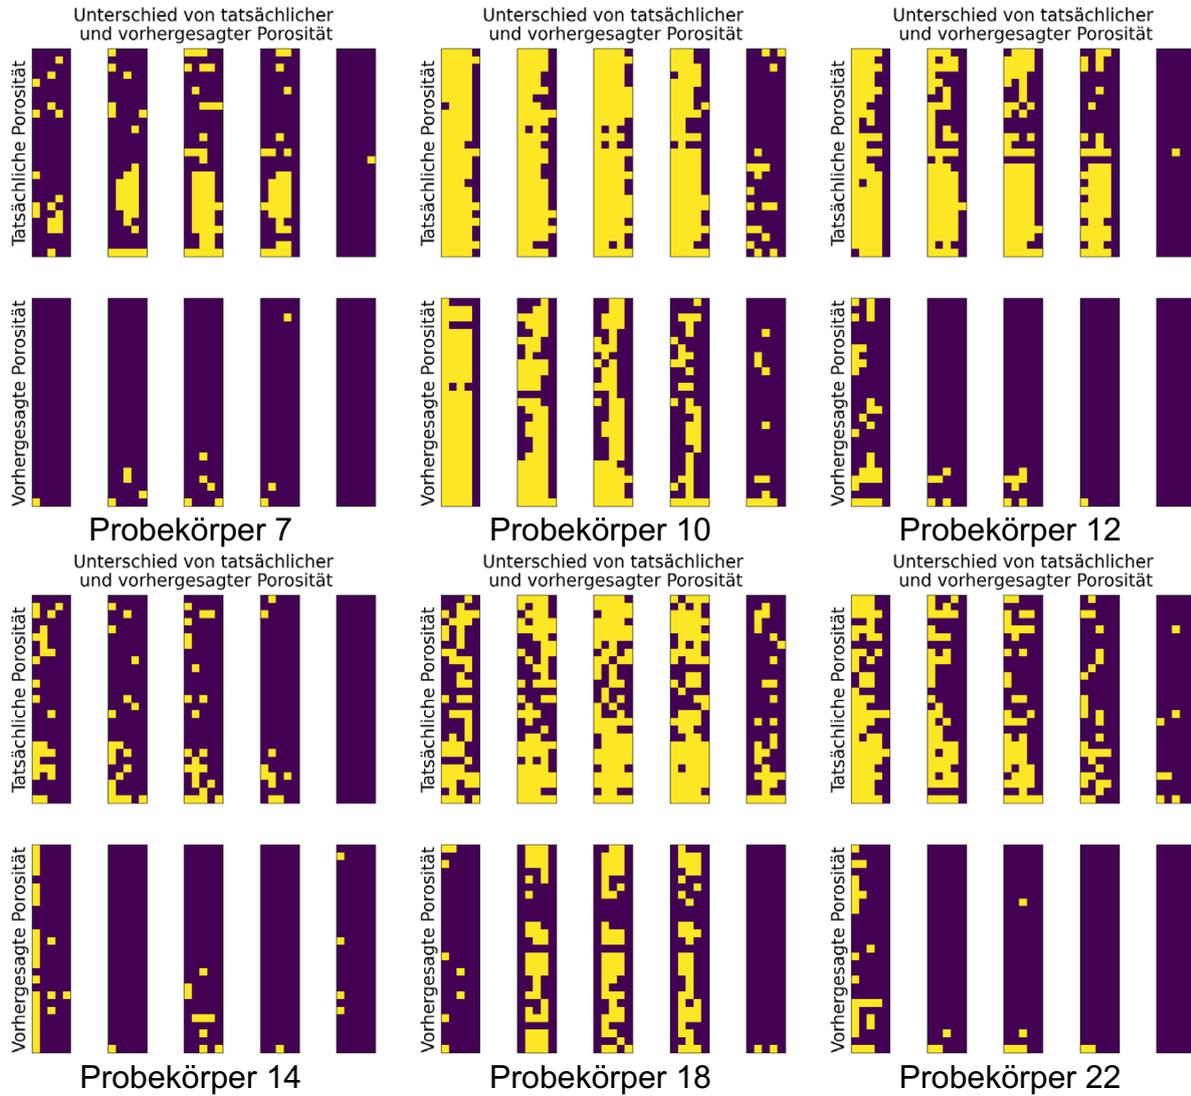


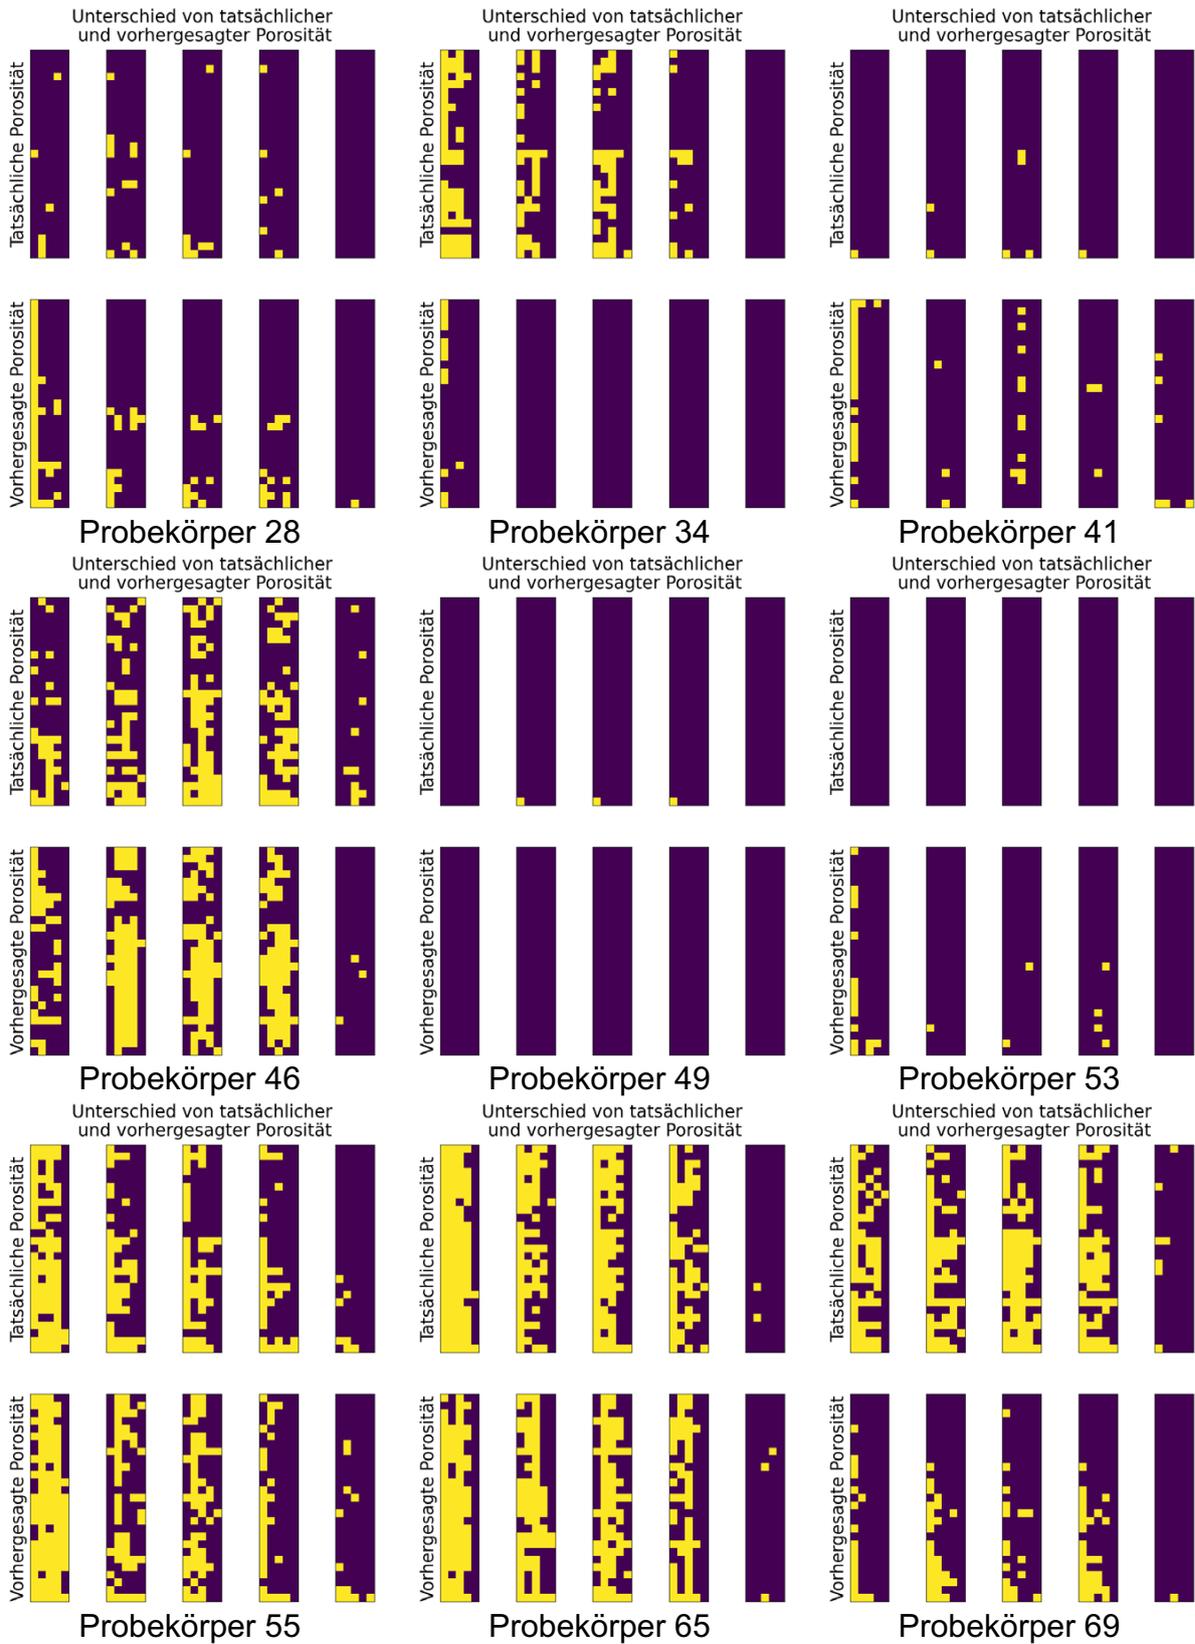
Probekörper 90

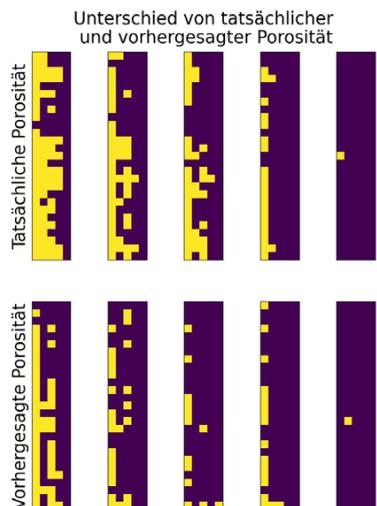


Probekörper 95

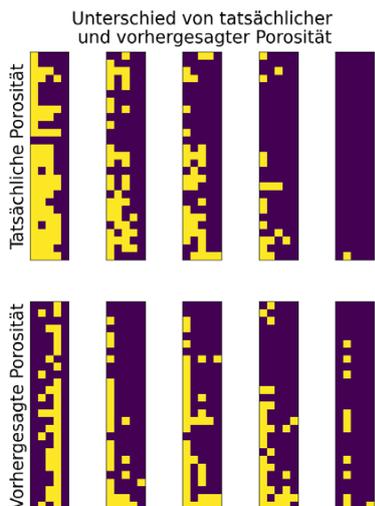
Modellart MLP (akustische Daten) + CNN (optische Daten), Klassengrenze 1 % Zellporosität, Testdatensatz



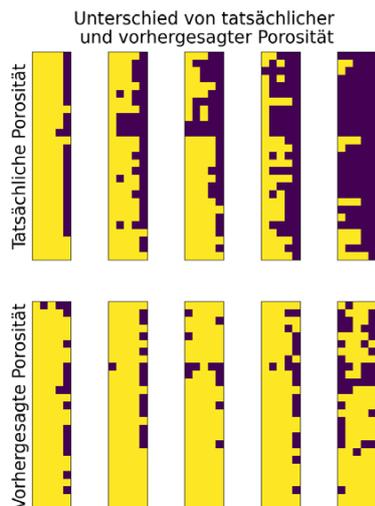




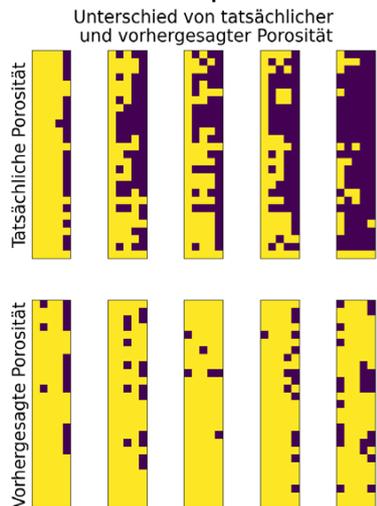
Probekörper 78



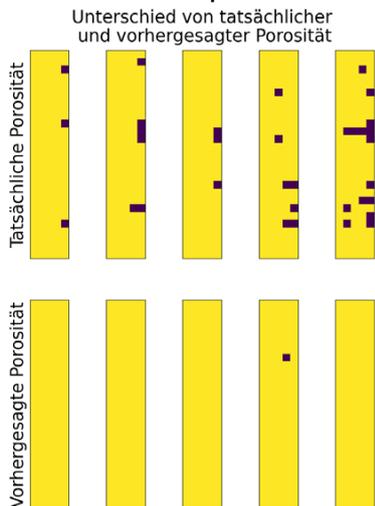
Probekörper 79



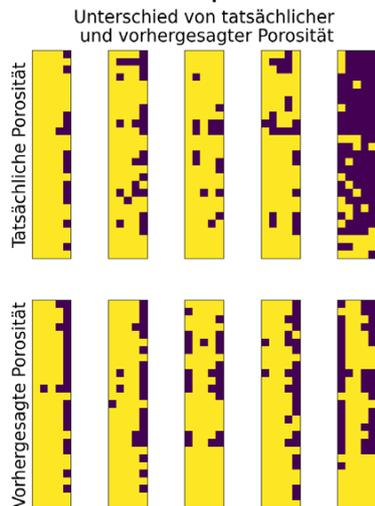
Probekörper 81



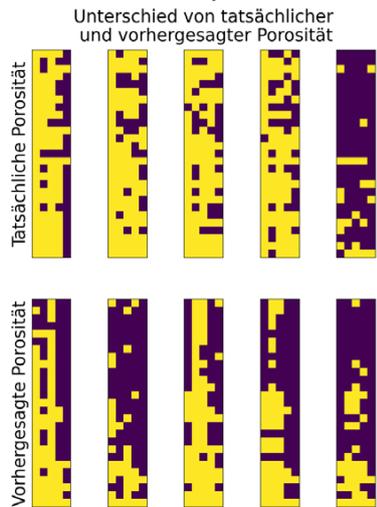
Probekörper 86



Probekörper 89

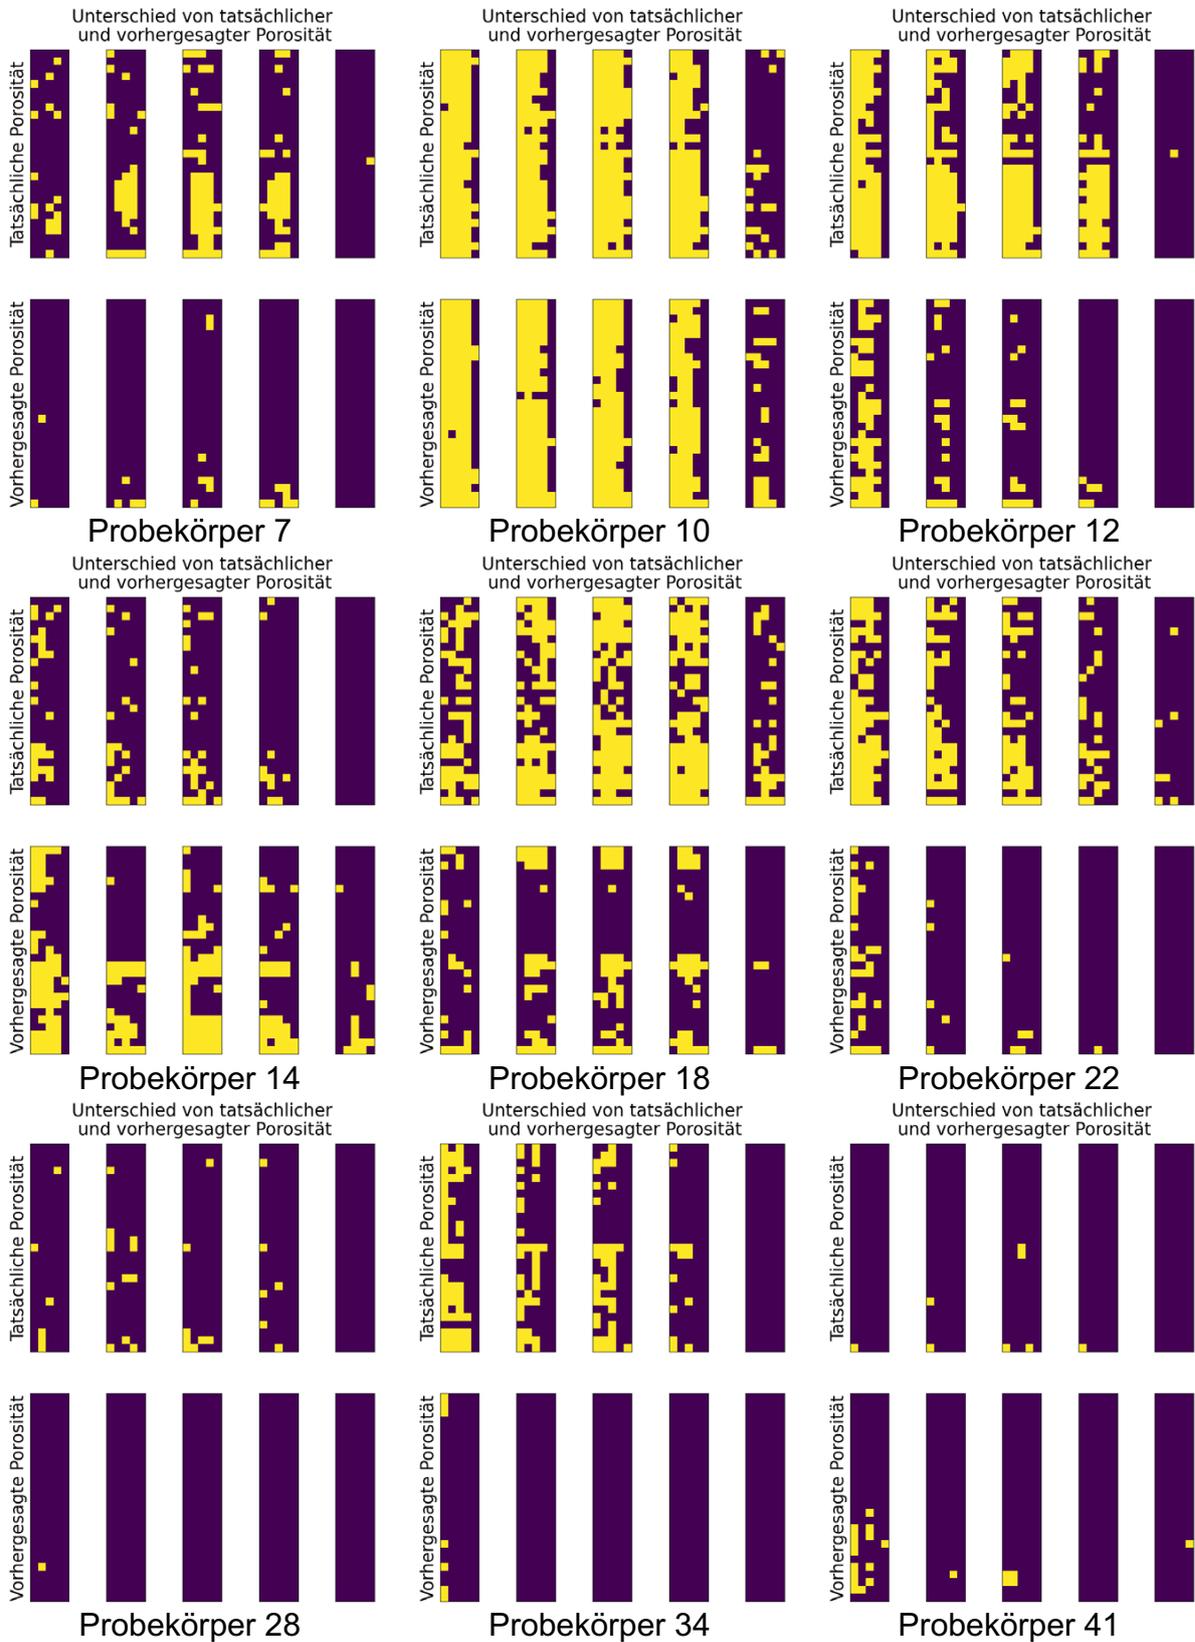


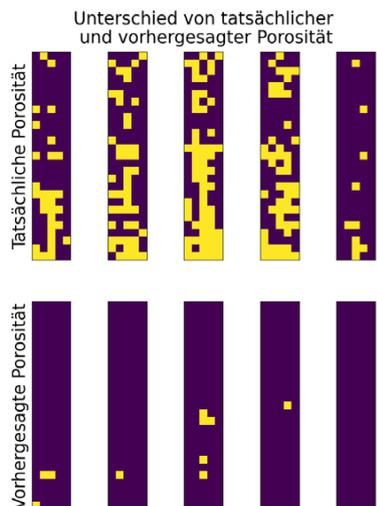
Probekörper 90



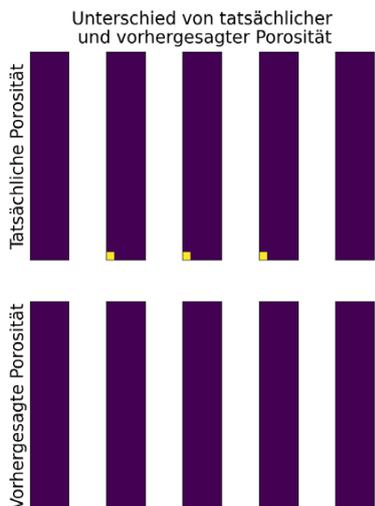
Probekörper 95

Modellart CNN, Klassengrenze 1 % Zellporosität, Testdatensatz

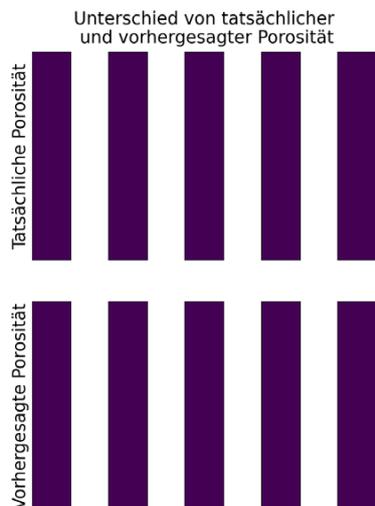




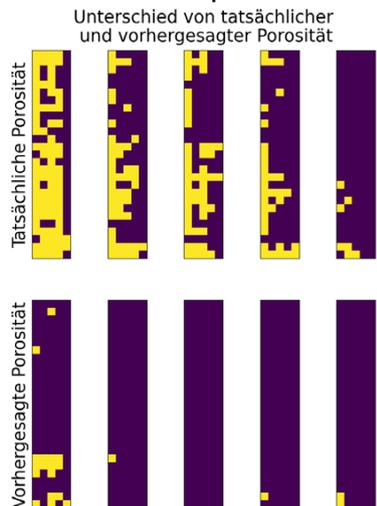
Probekörper 46



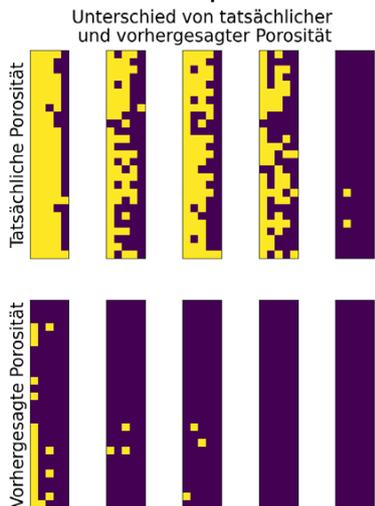
Probekörper 49



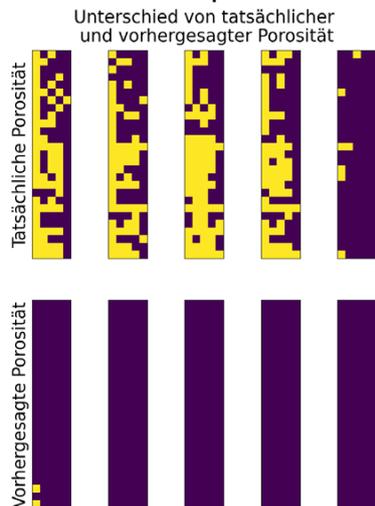
Probekörper 53



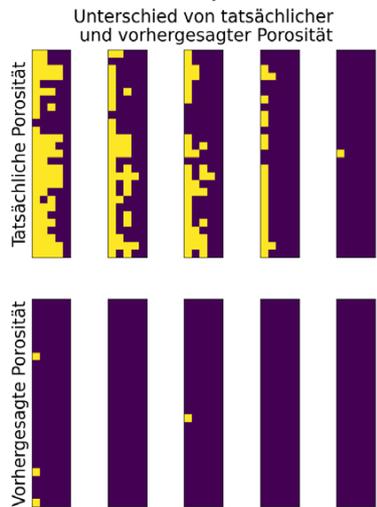
Probekörper 55



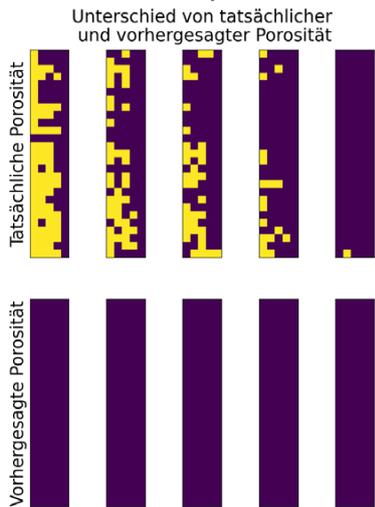
Probekörper 65



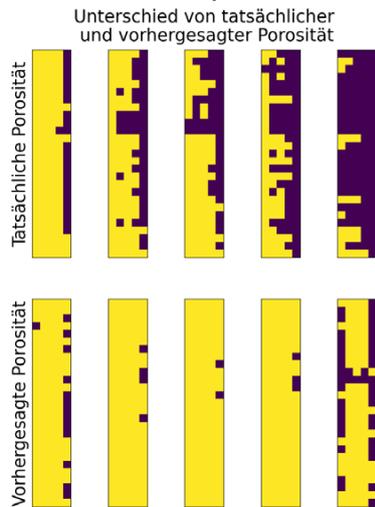
Probekörper 69



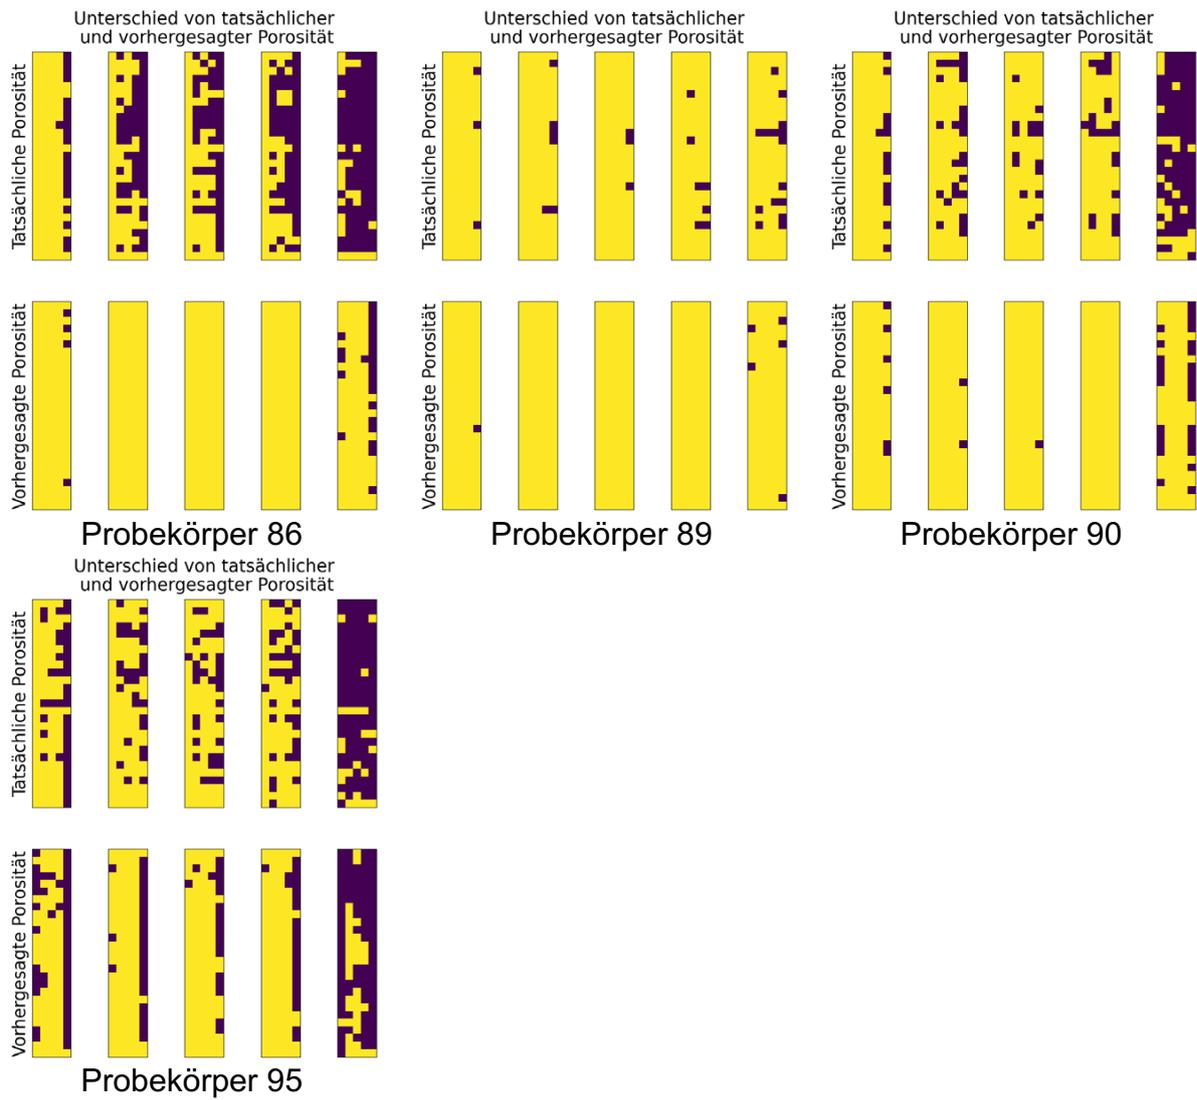
Probekörper 78



Probekörper 79

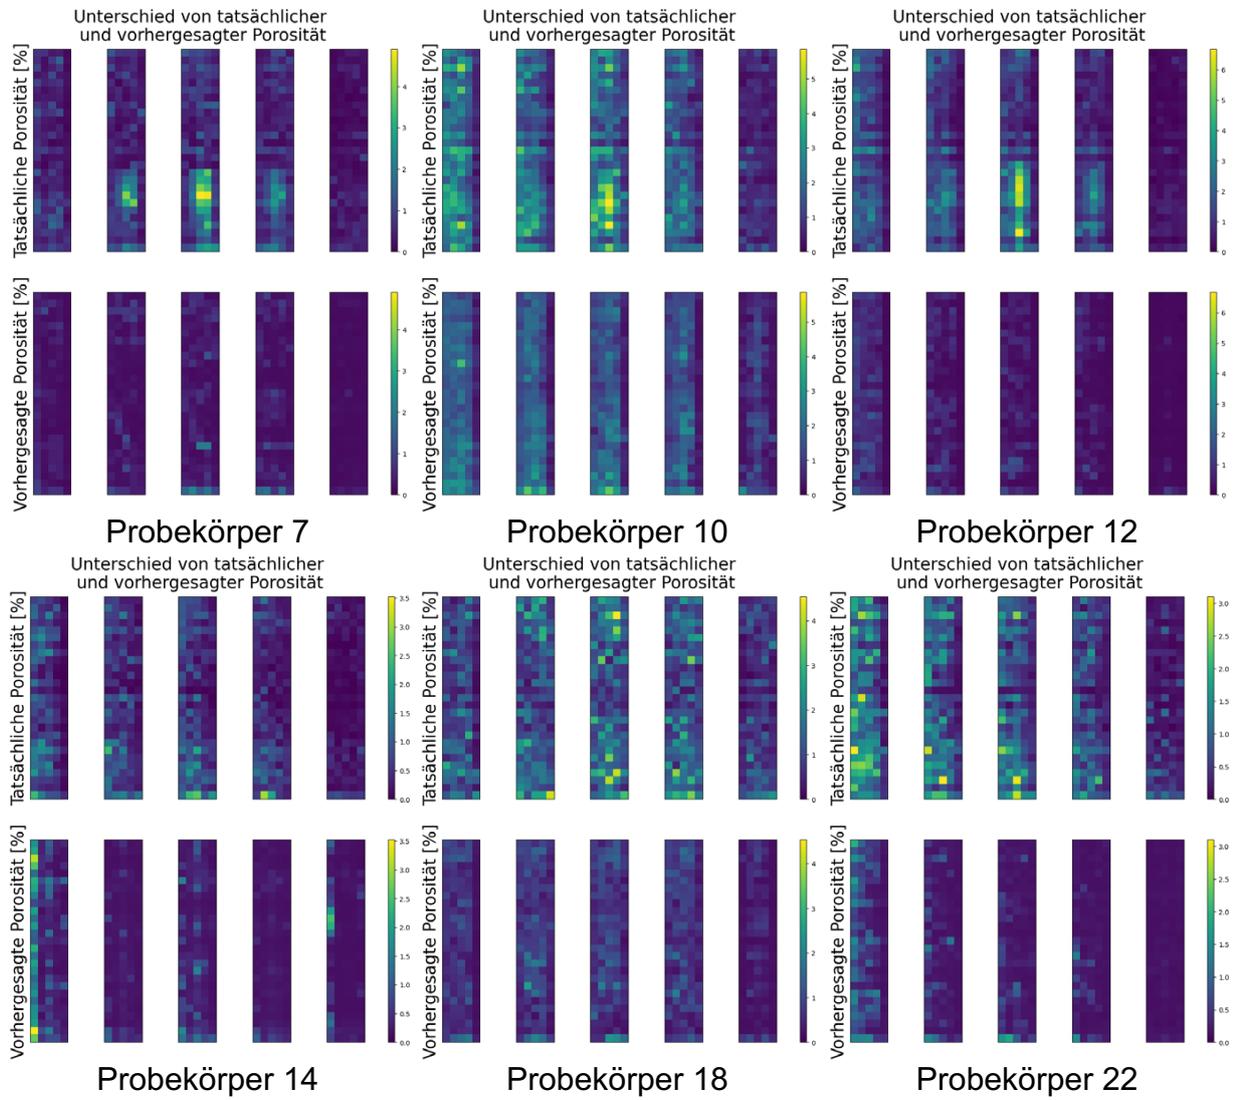


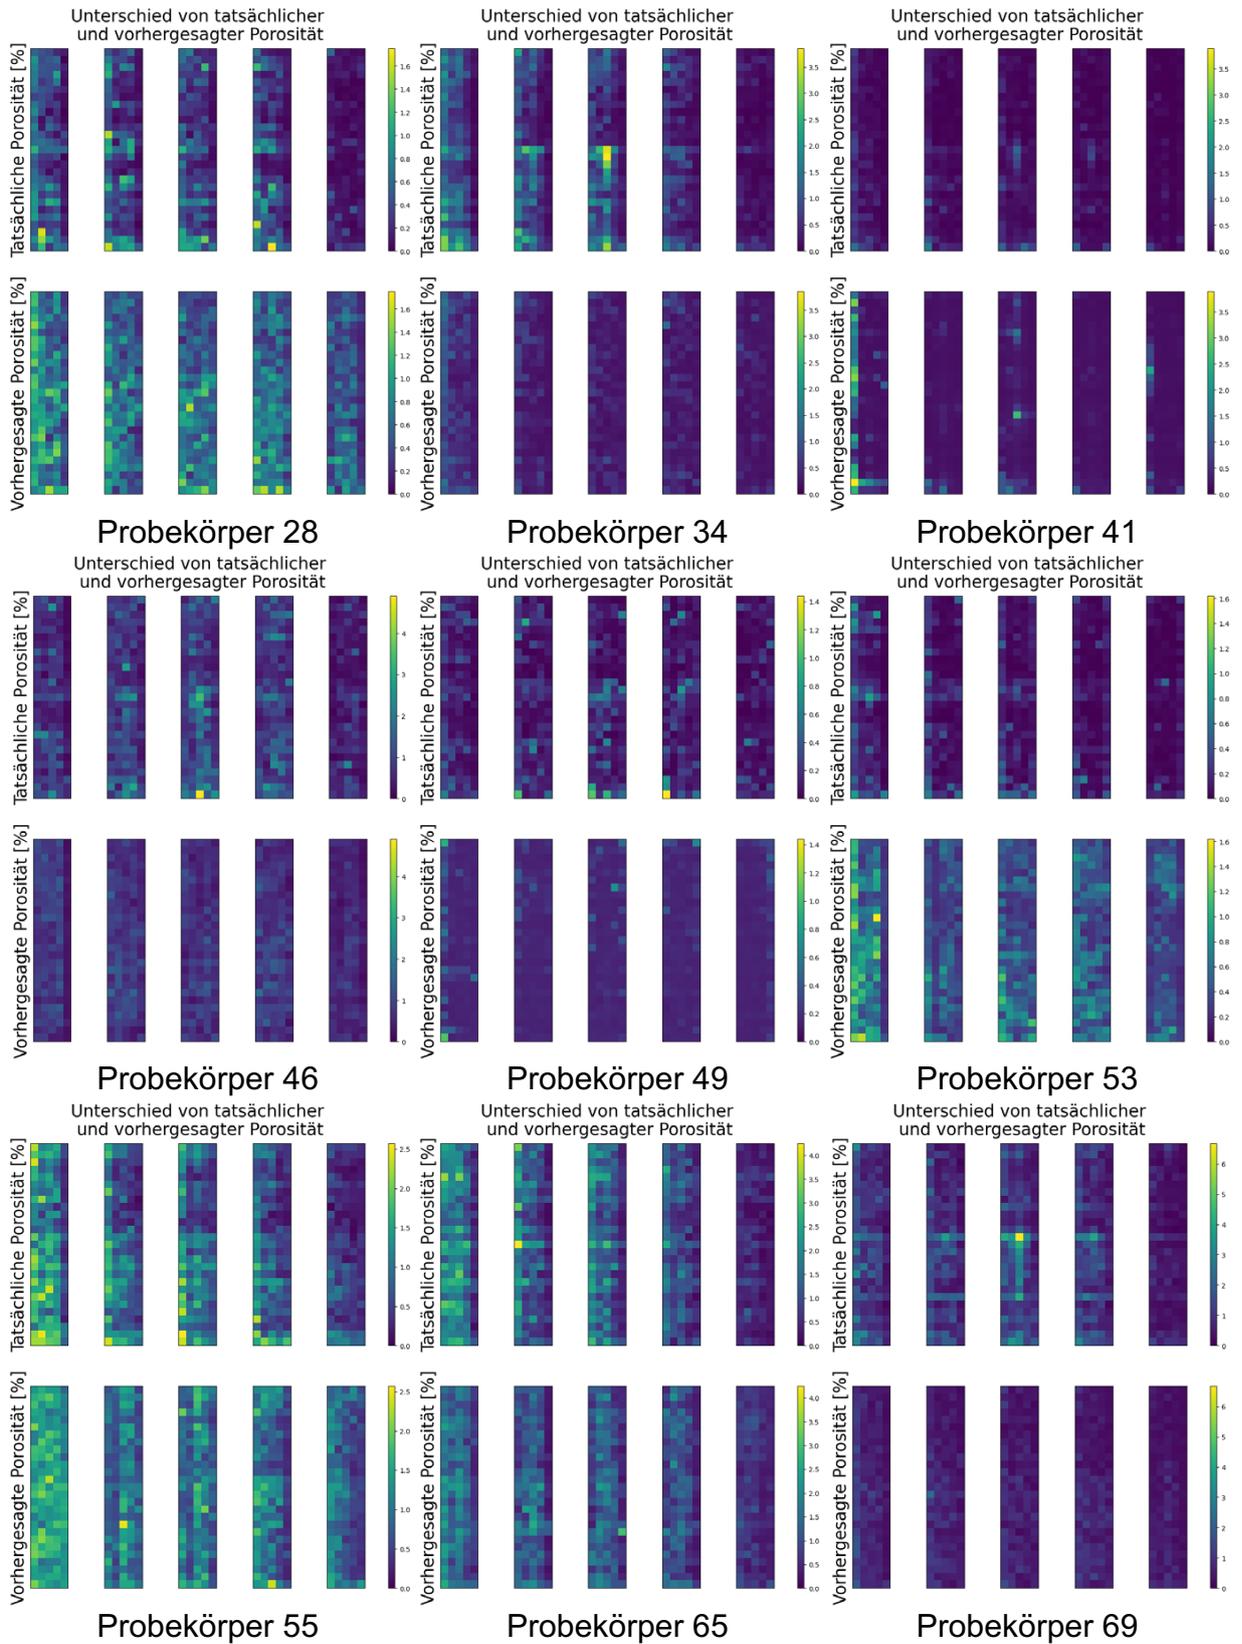
Probekörper 81

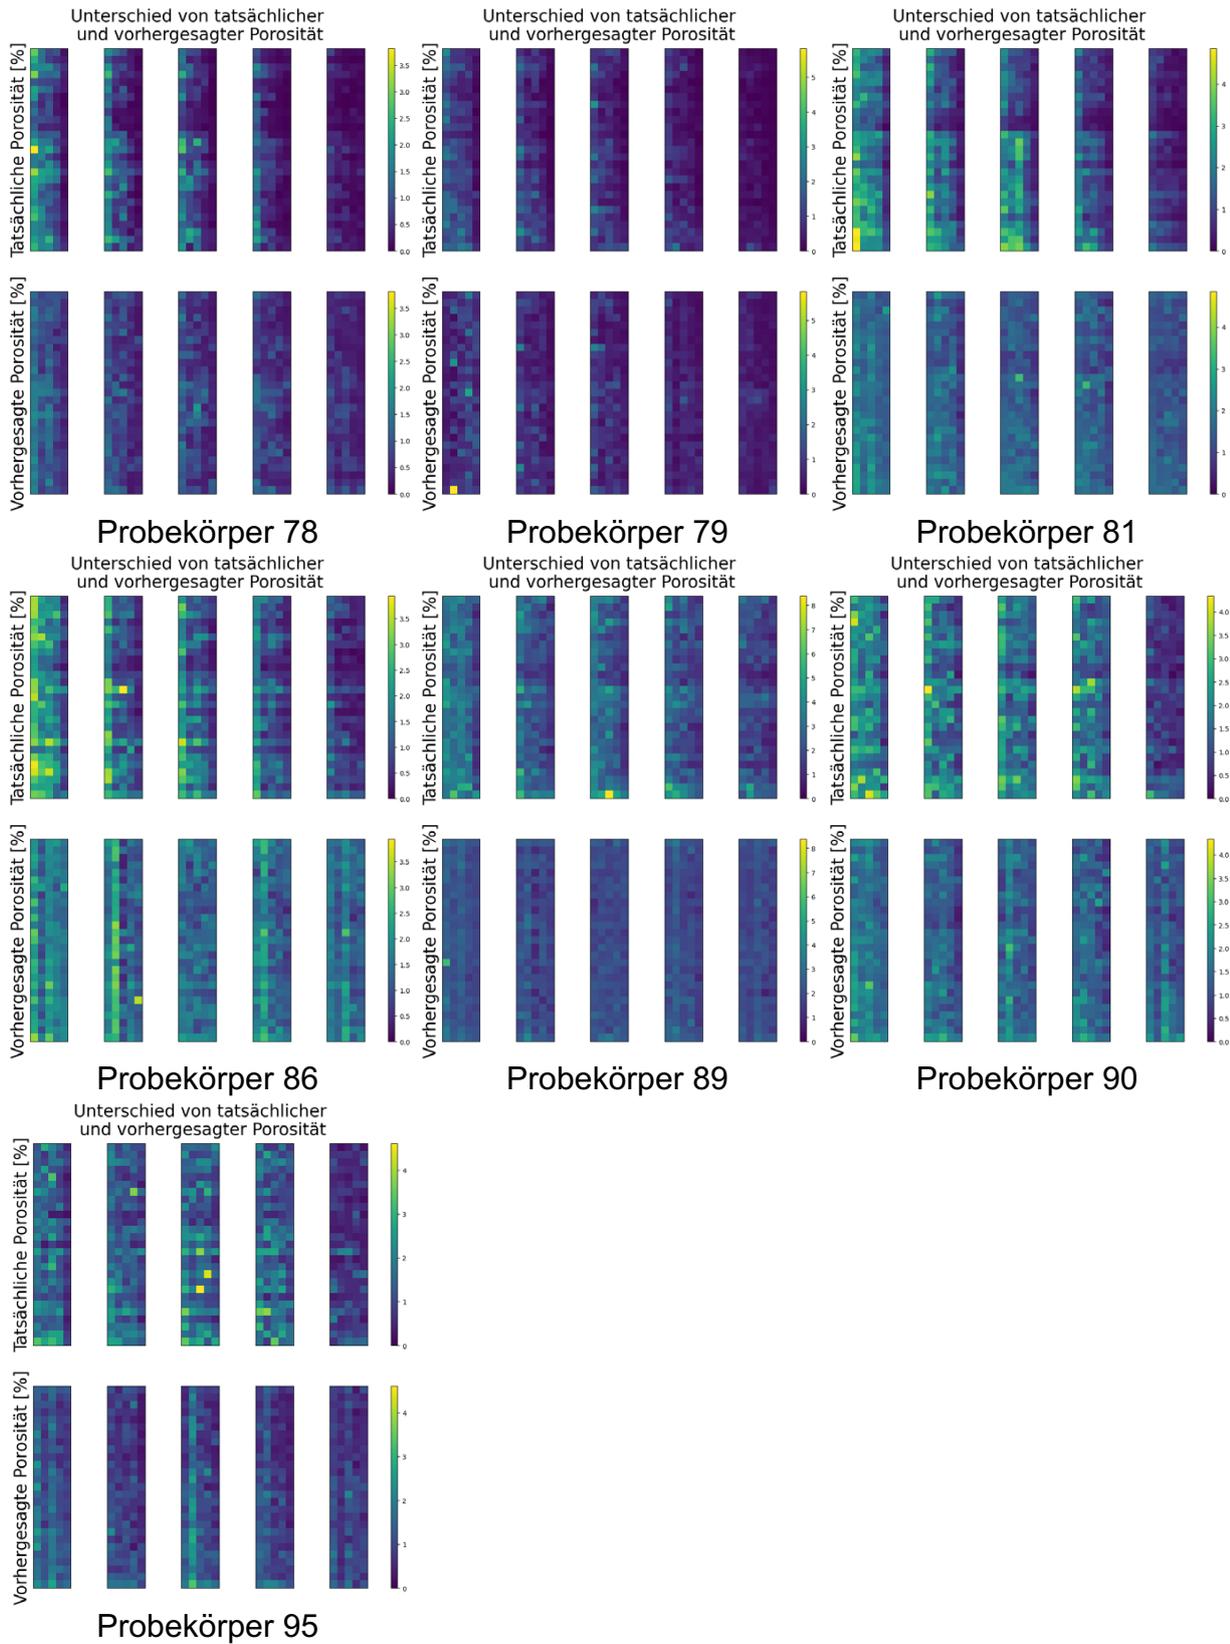


A2.6 Datenfusion Regression

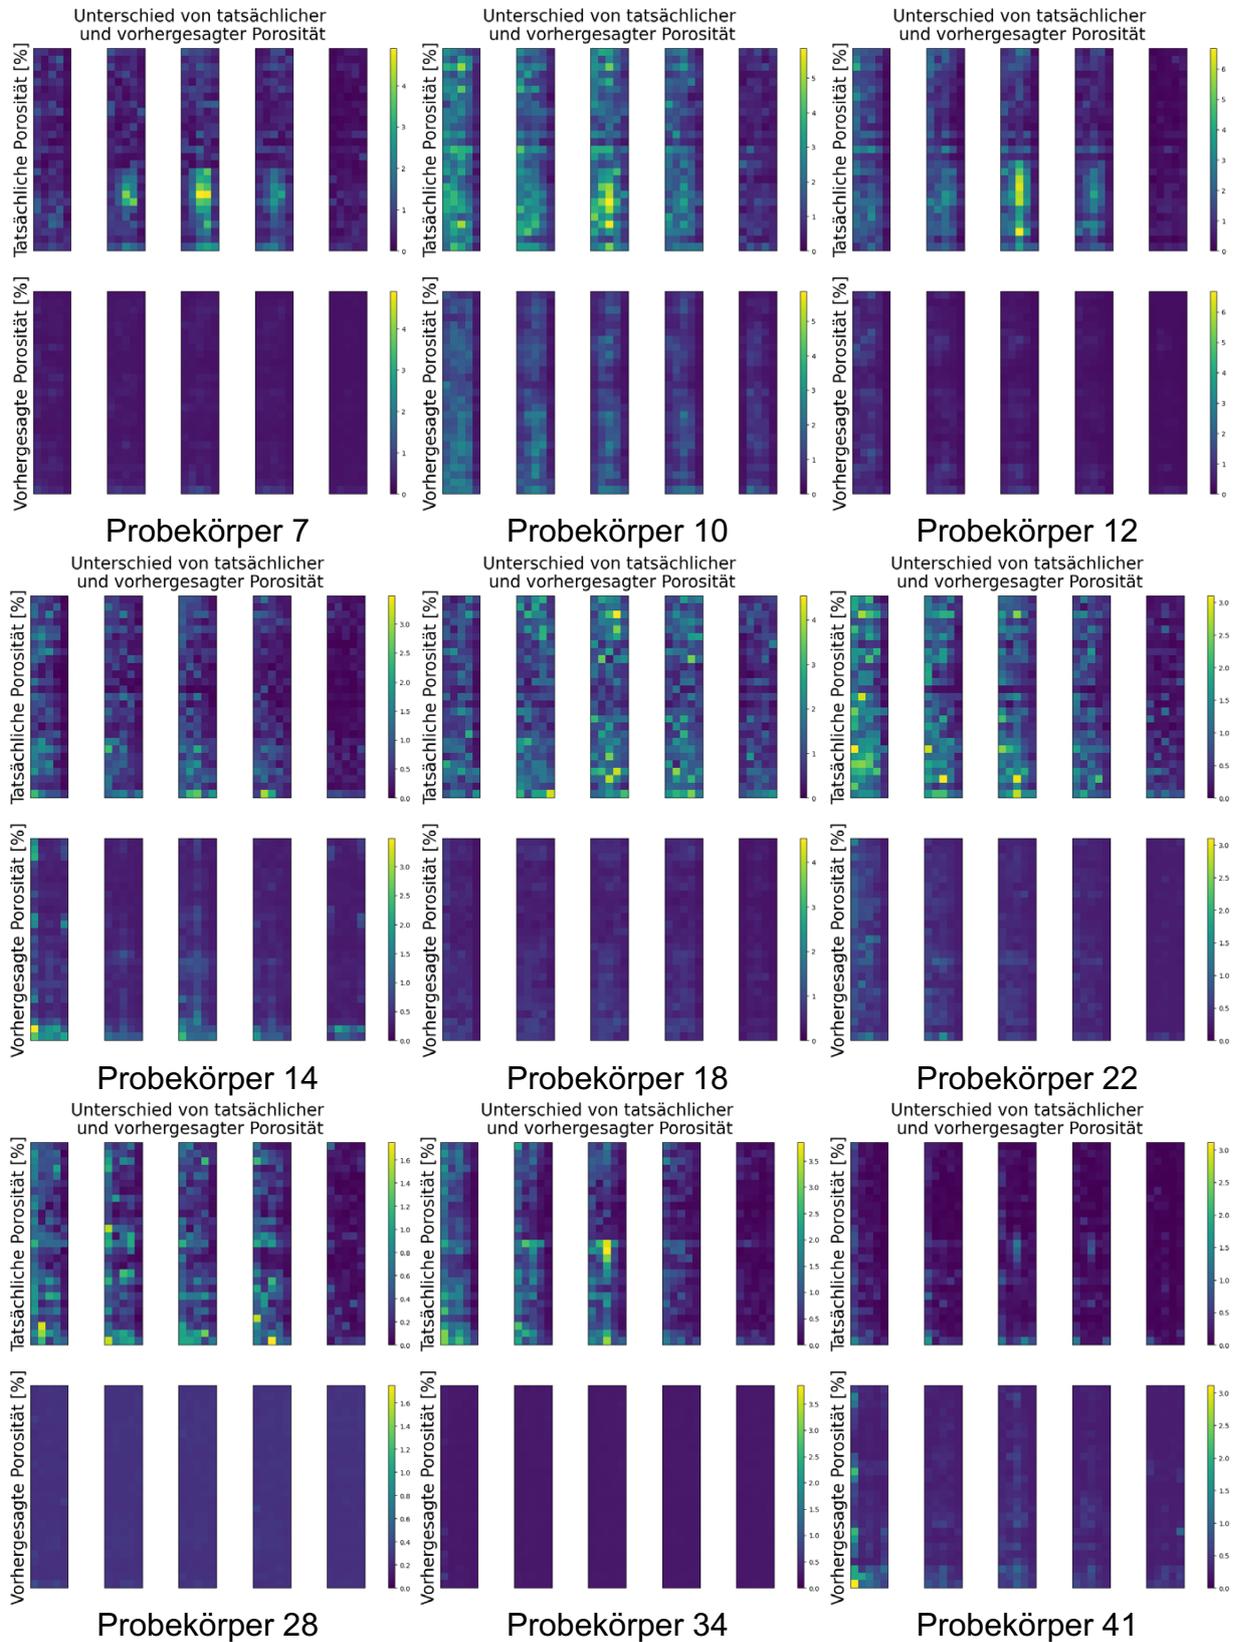
Modellart MLP, Testdatensatz

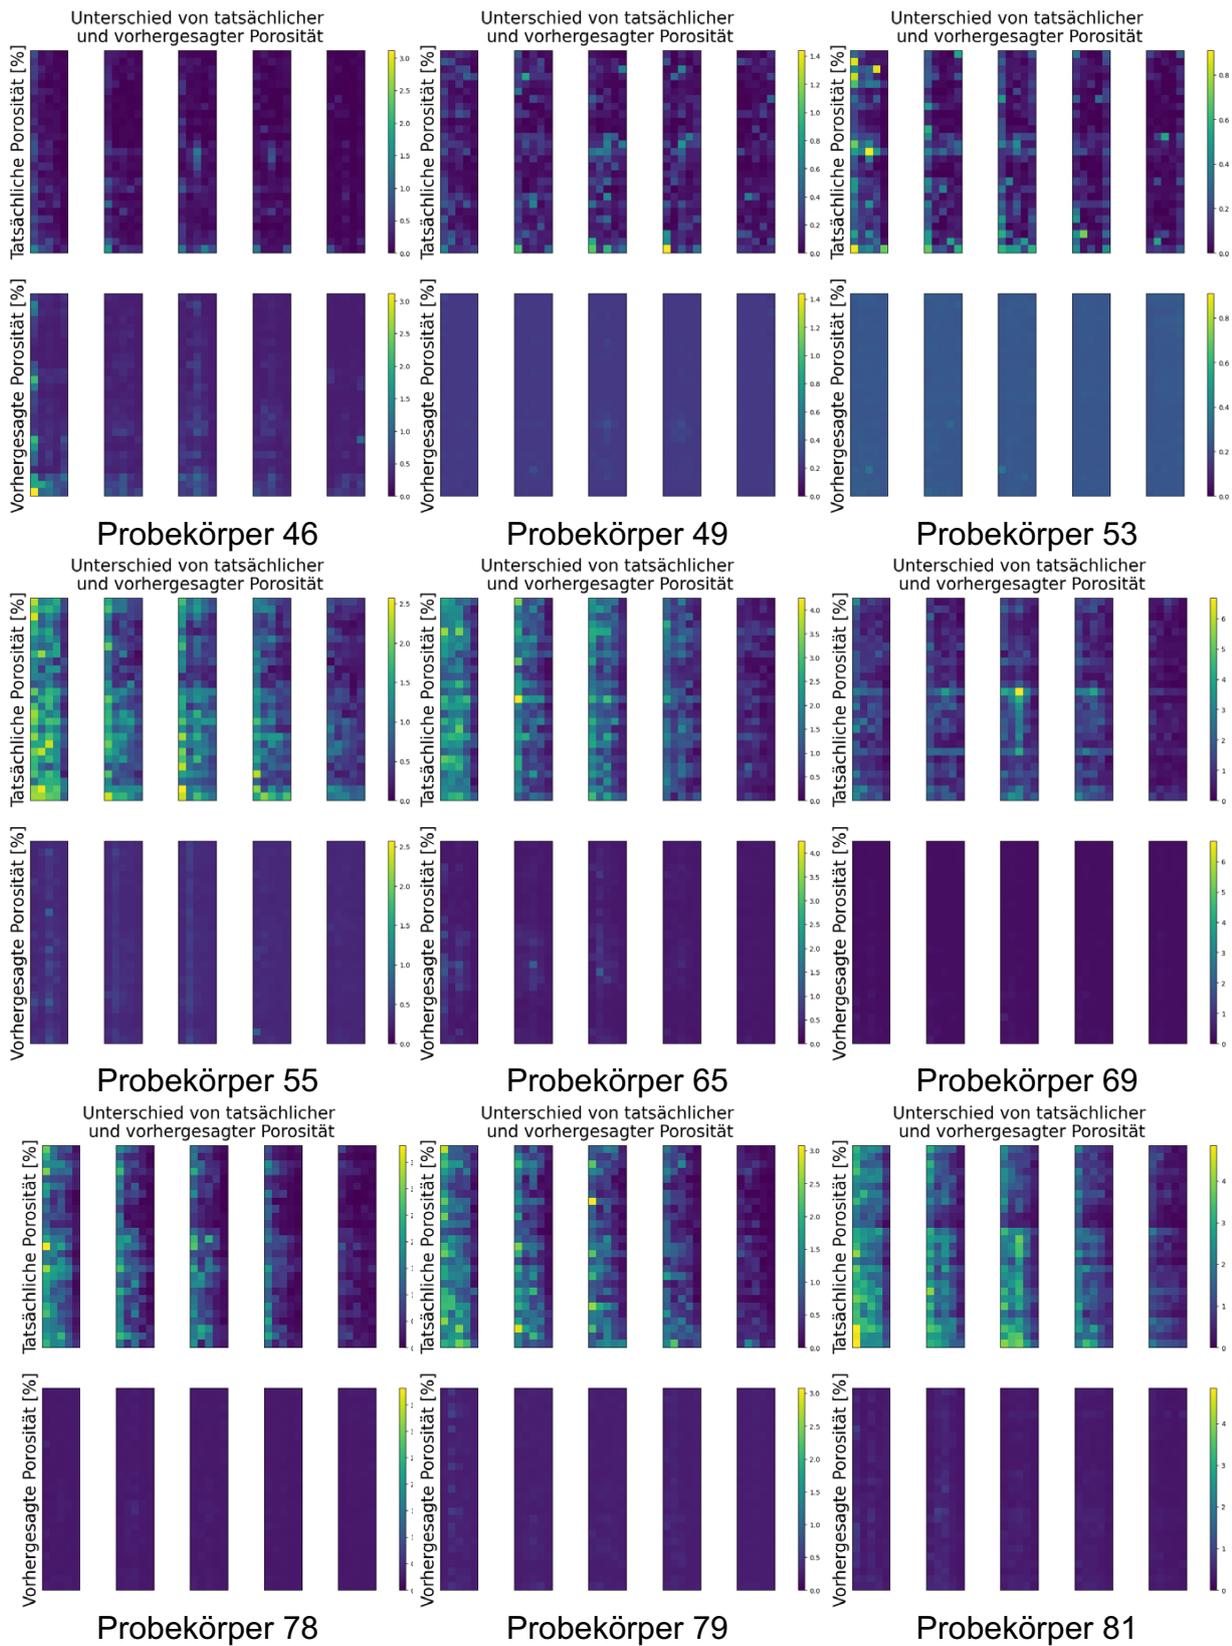


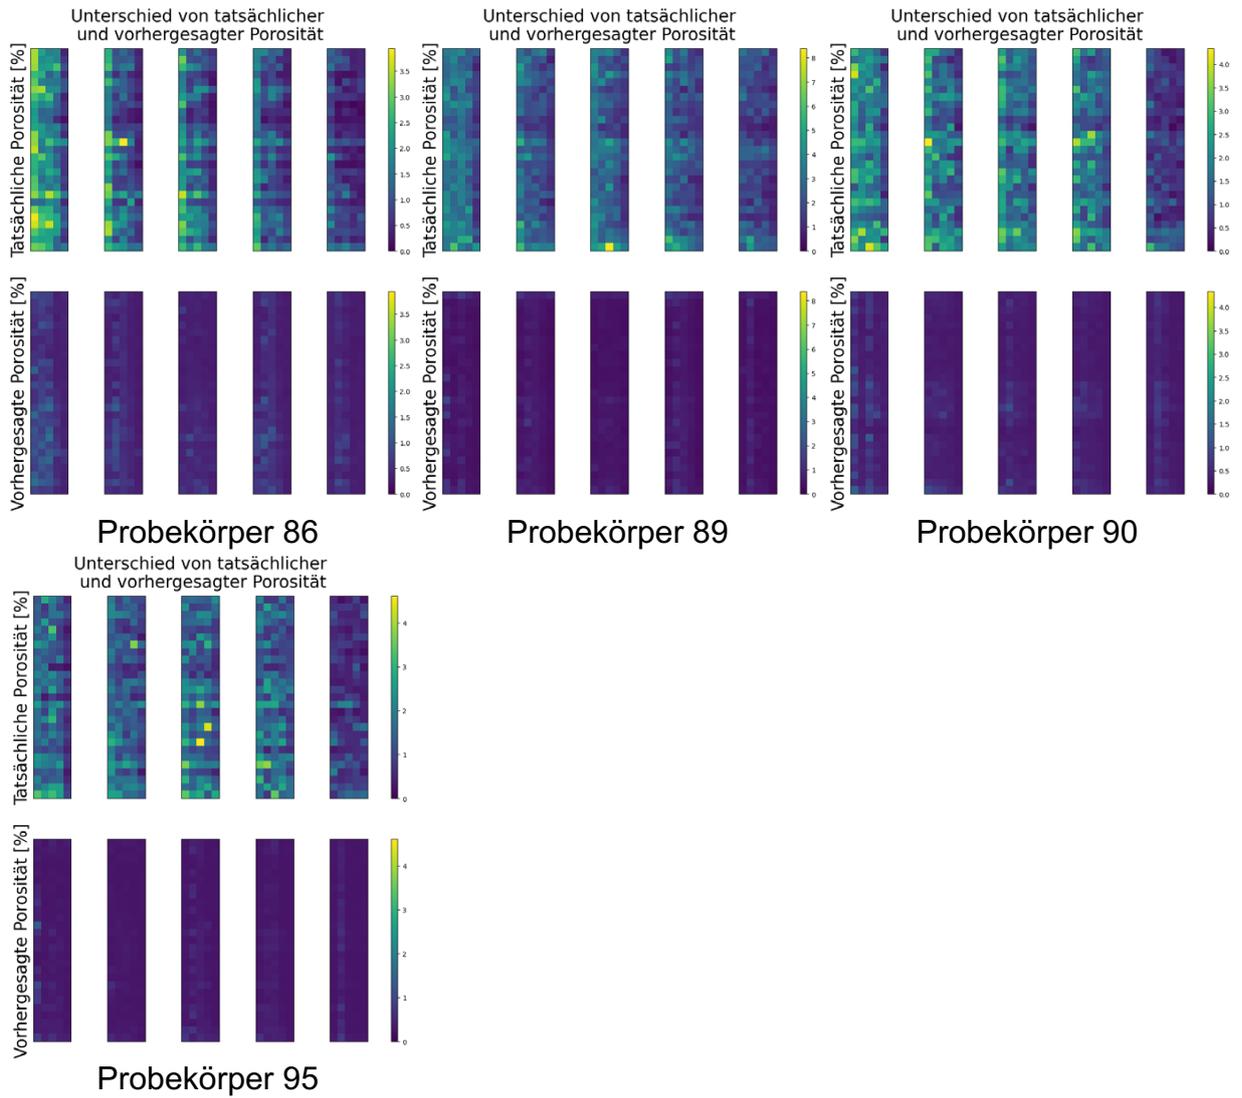




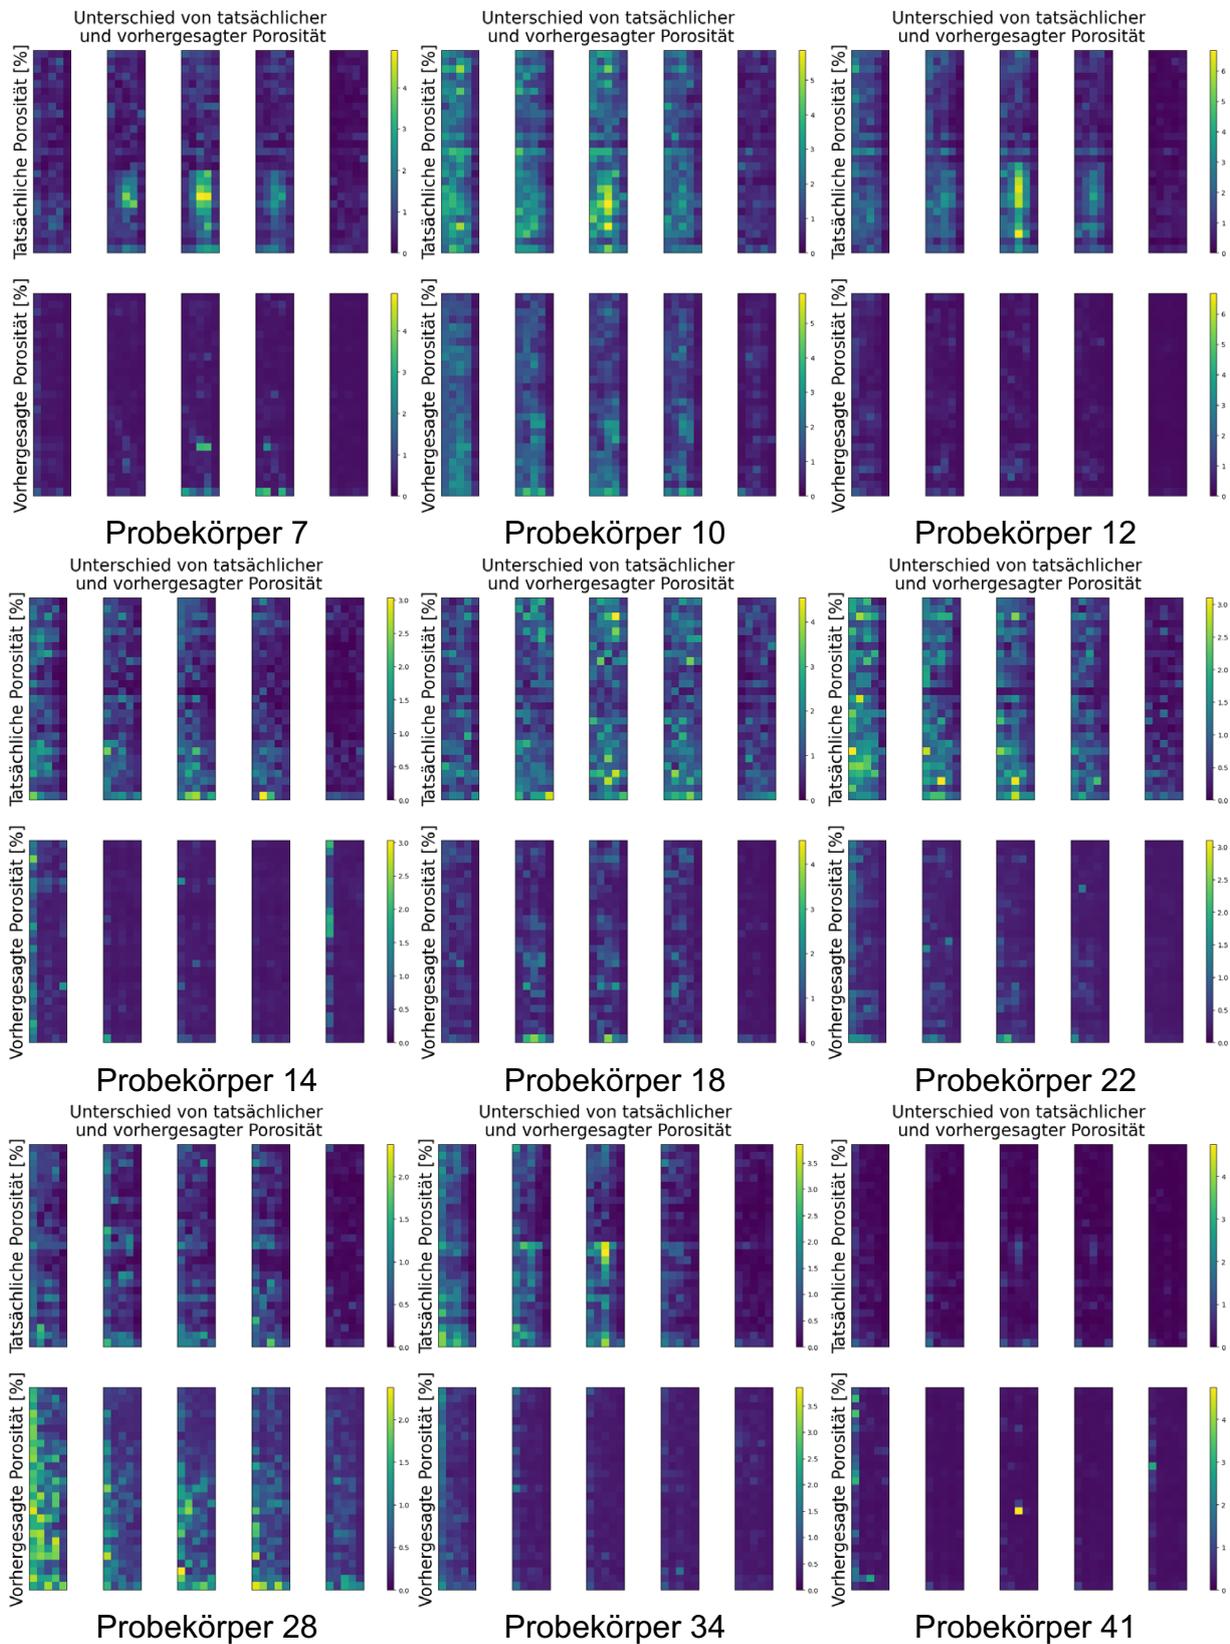
Modellart CNN (akustische Daten) + MLP (optische Daten), Testdatensatz

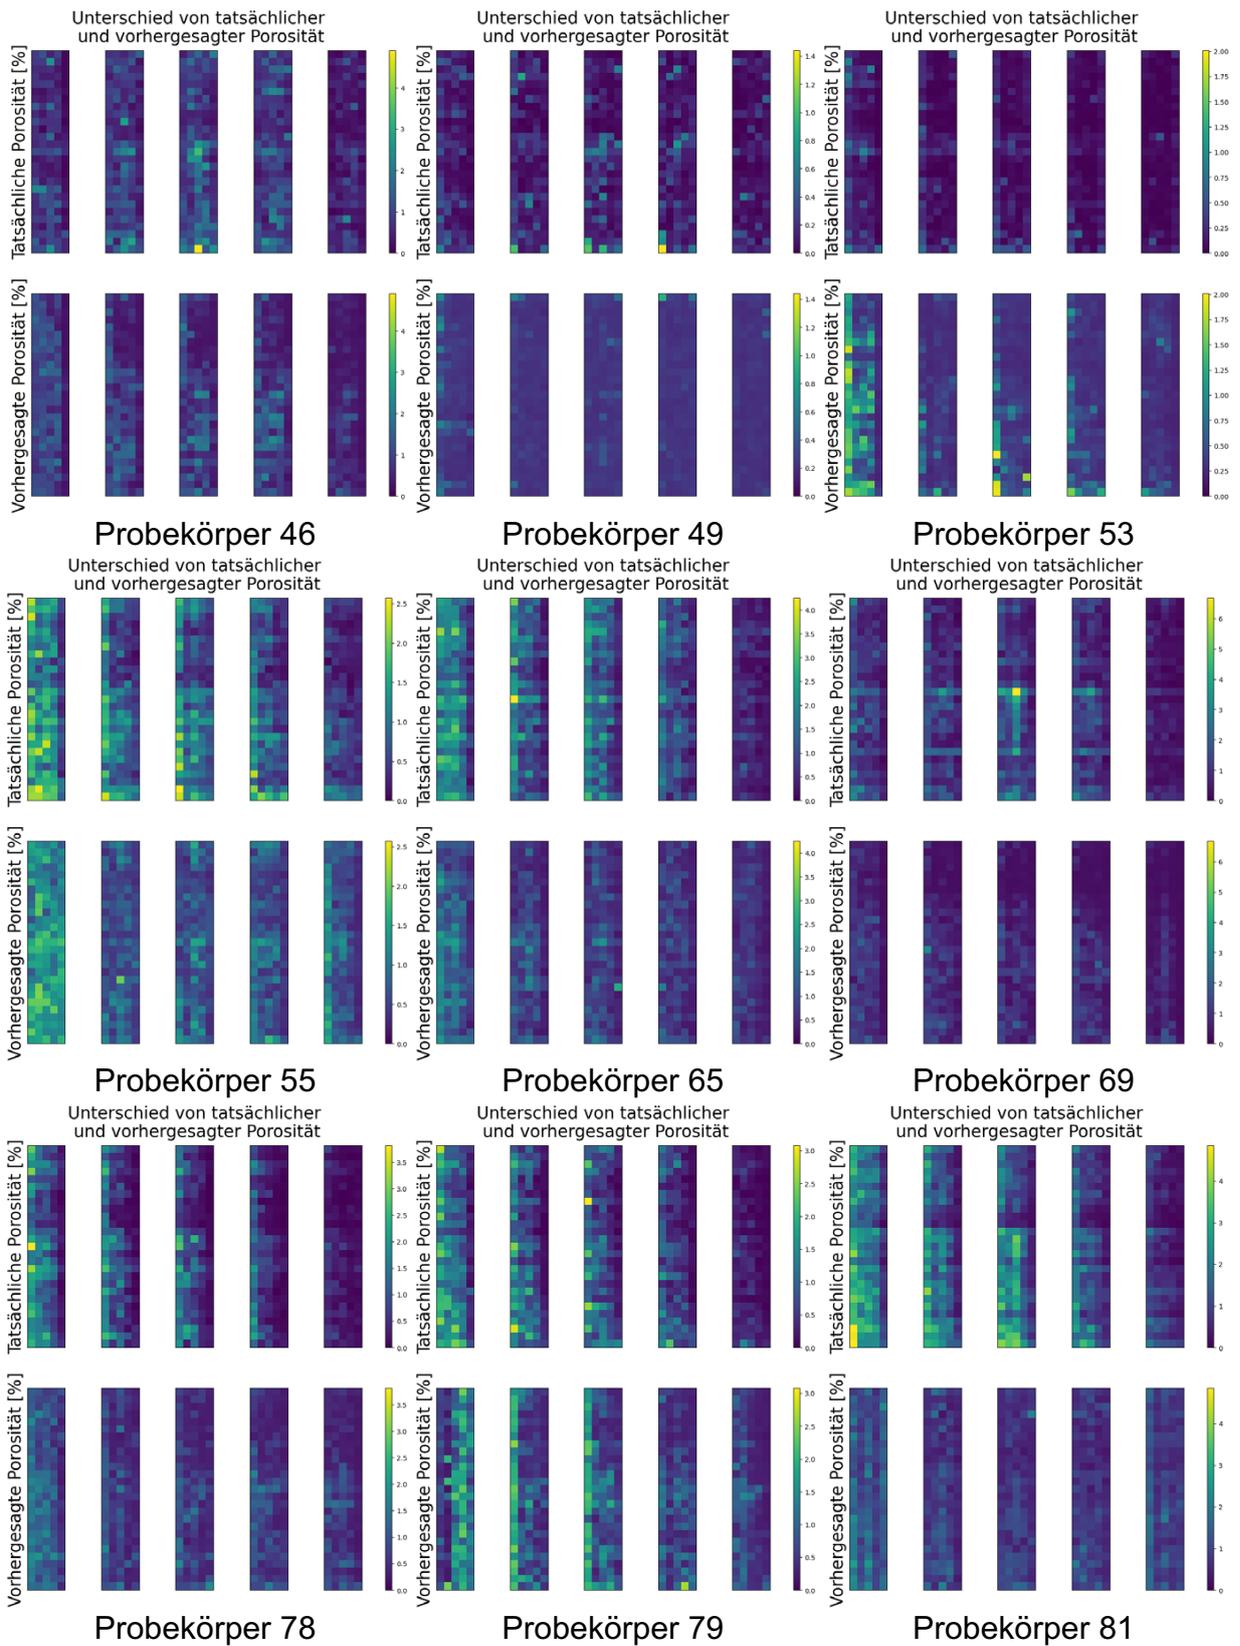


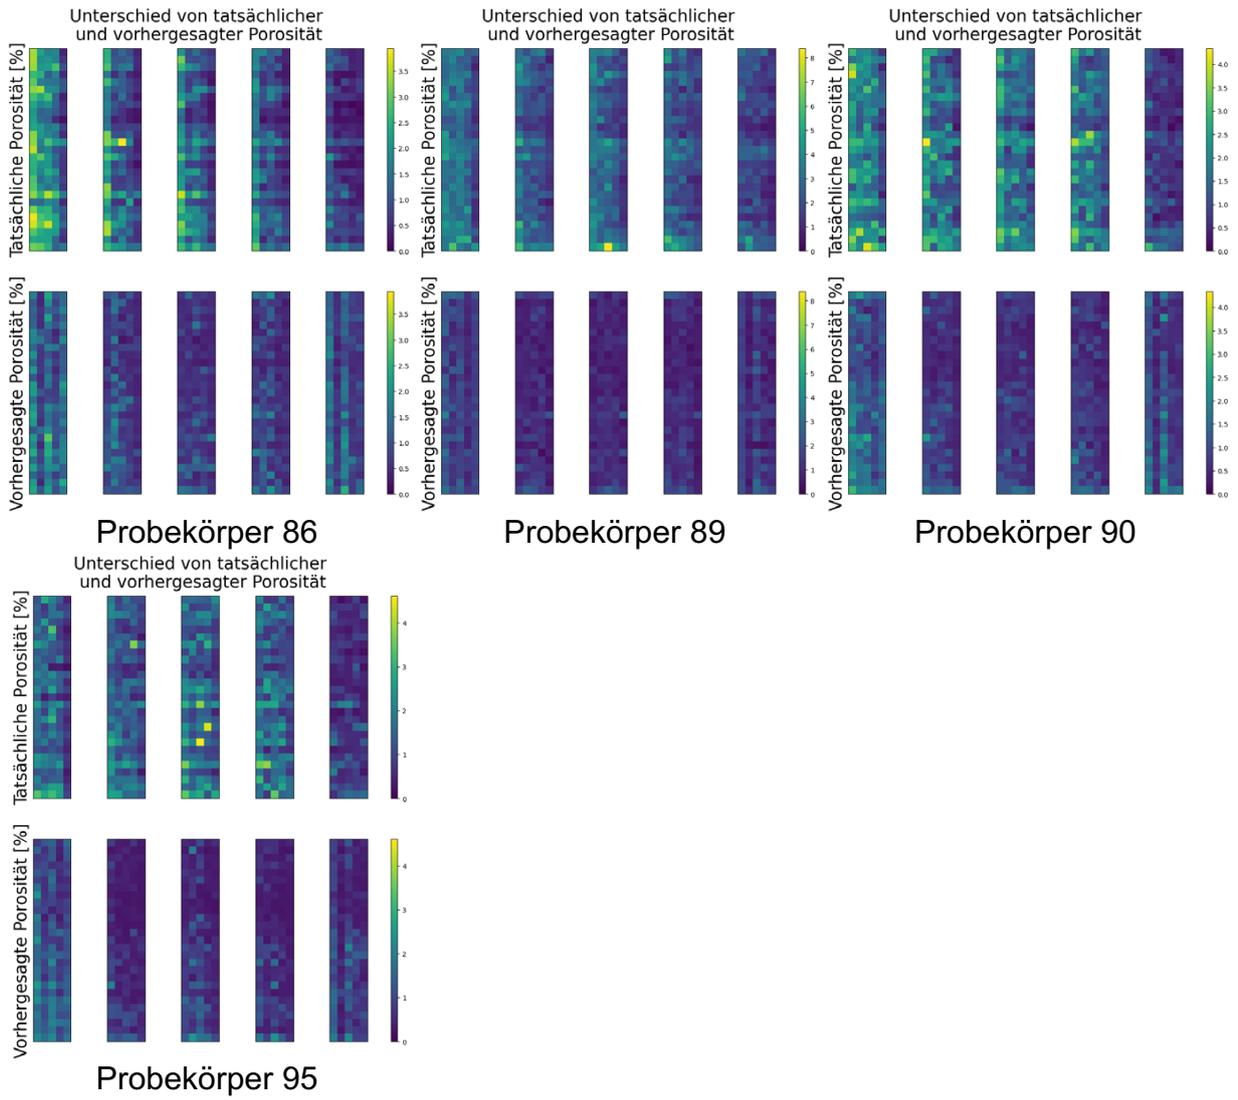




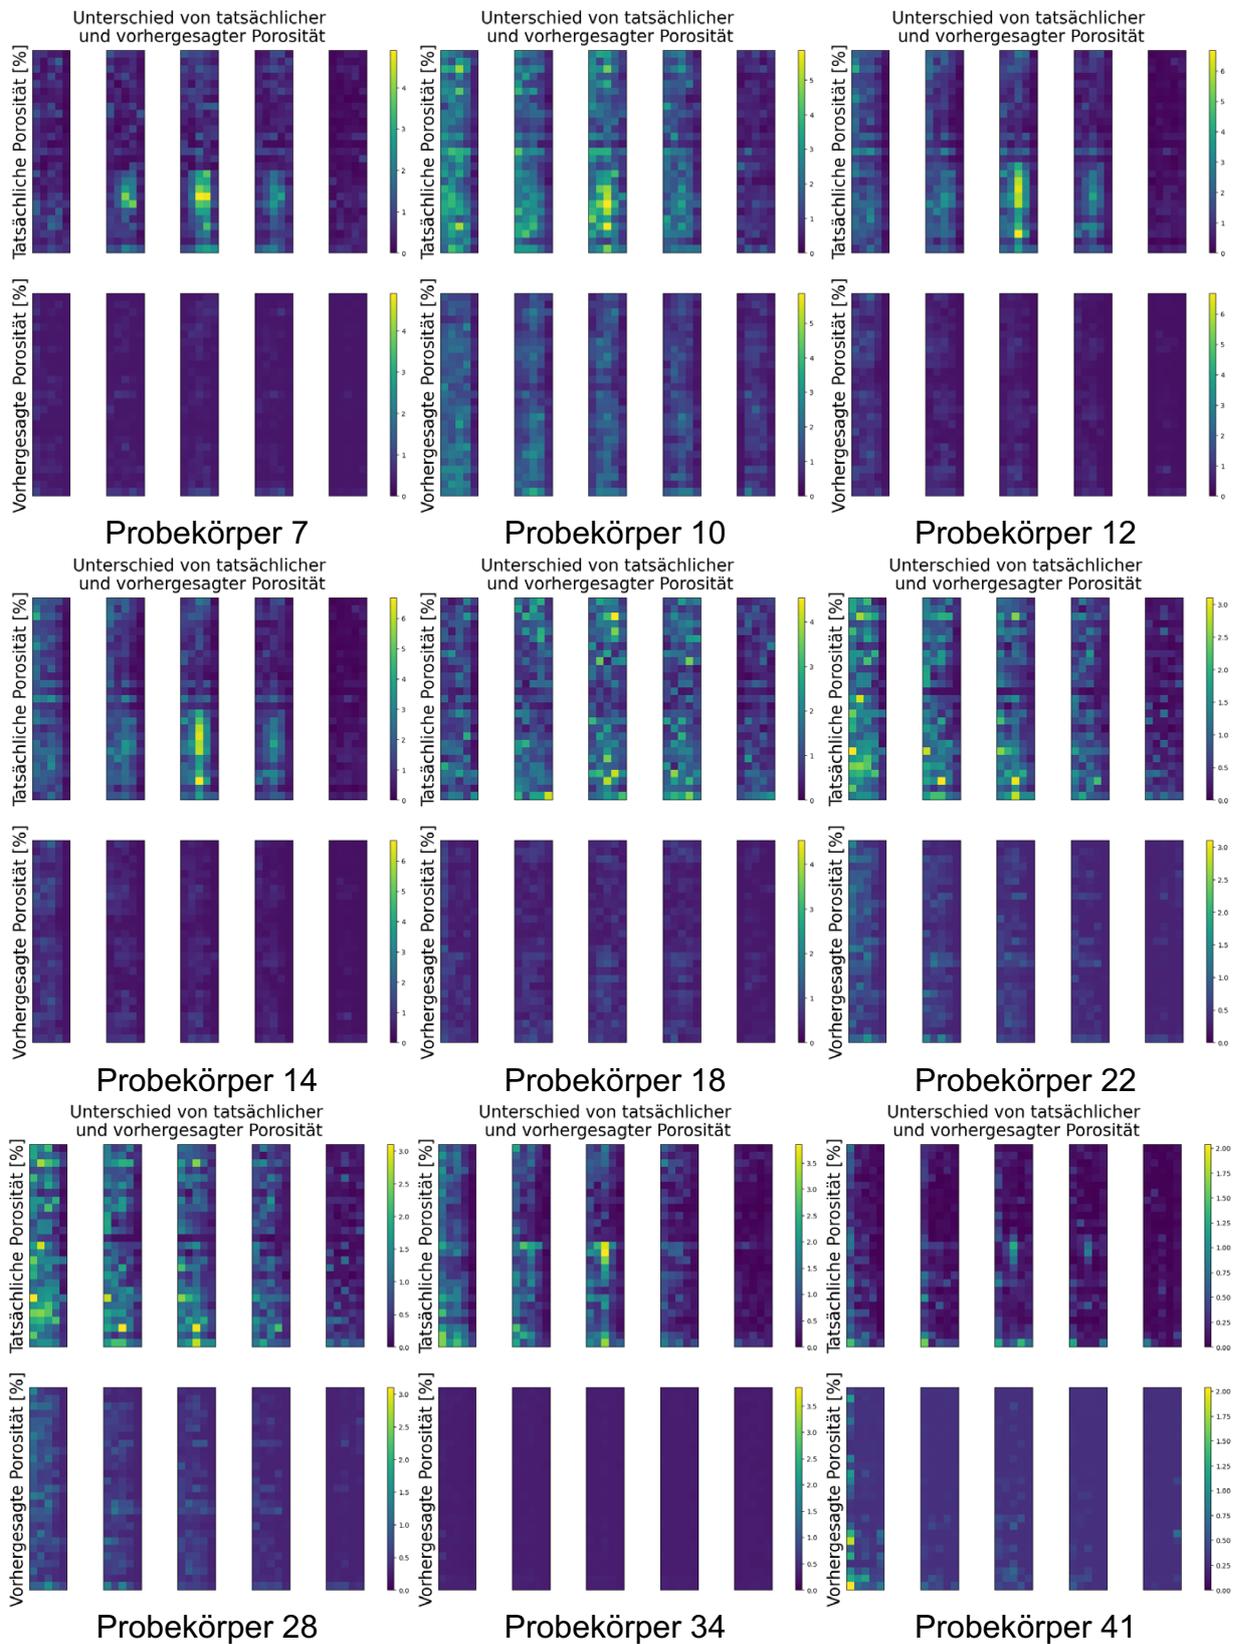
Modellart MLP (akustische Daten) + CNN (optische Daten), Testdatensatz

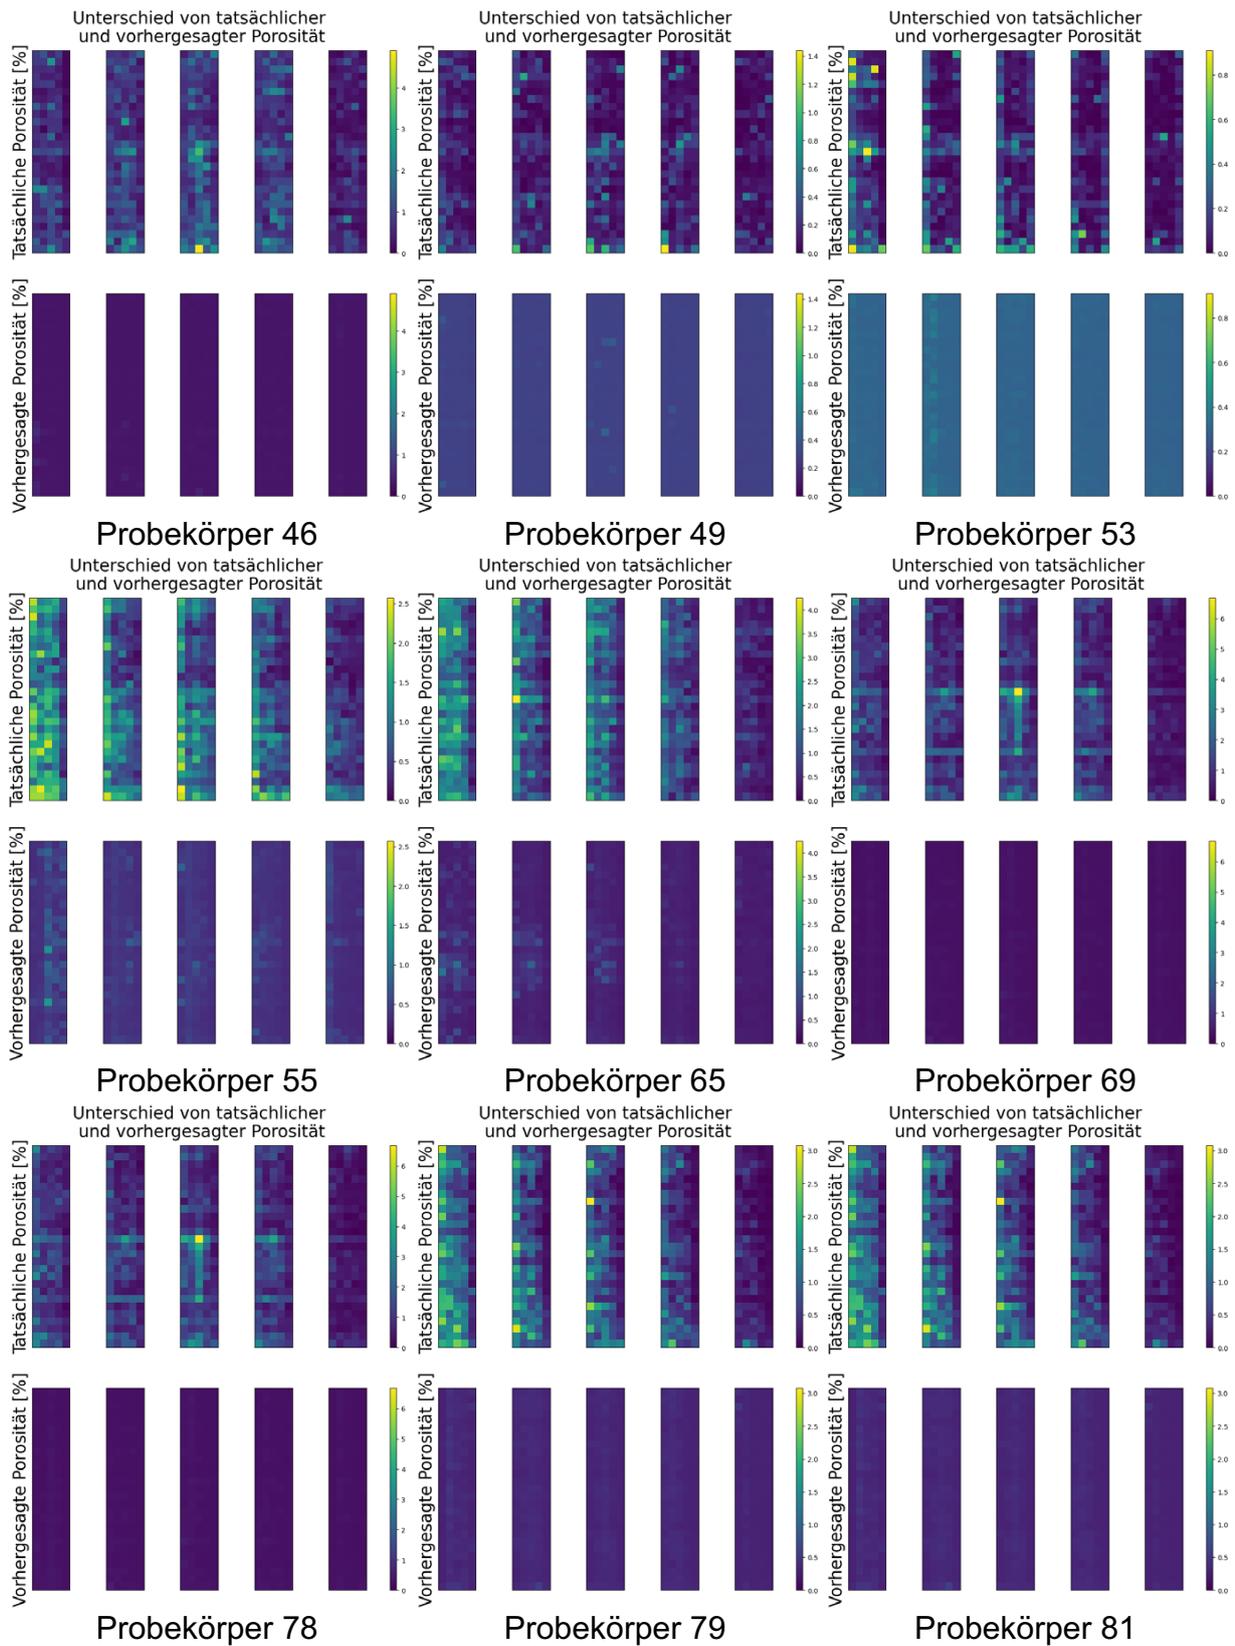


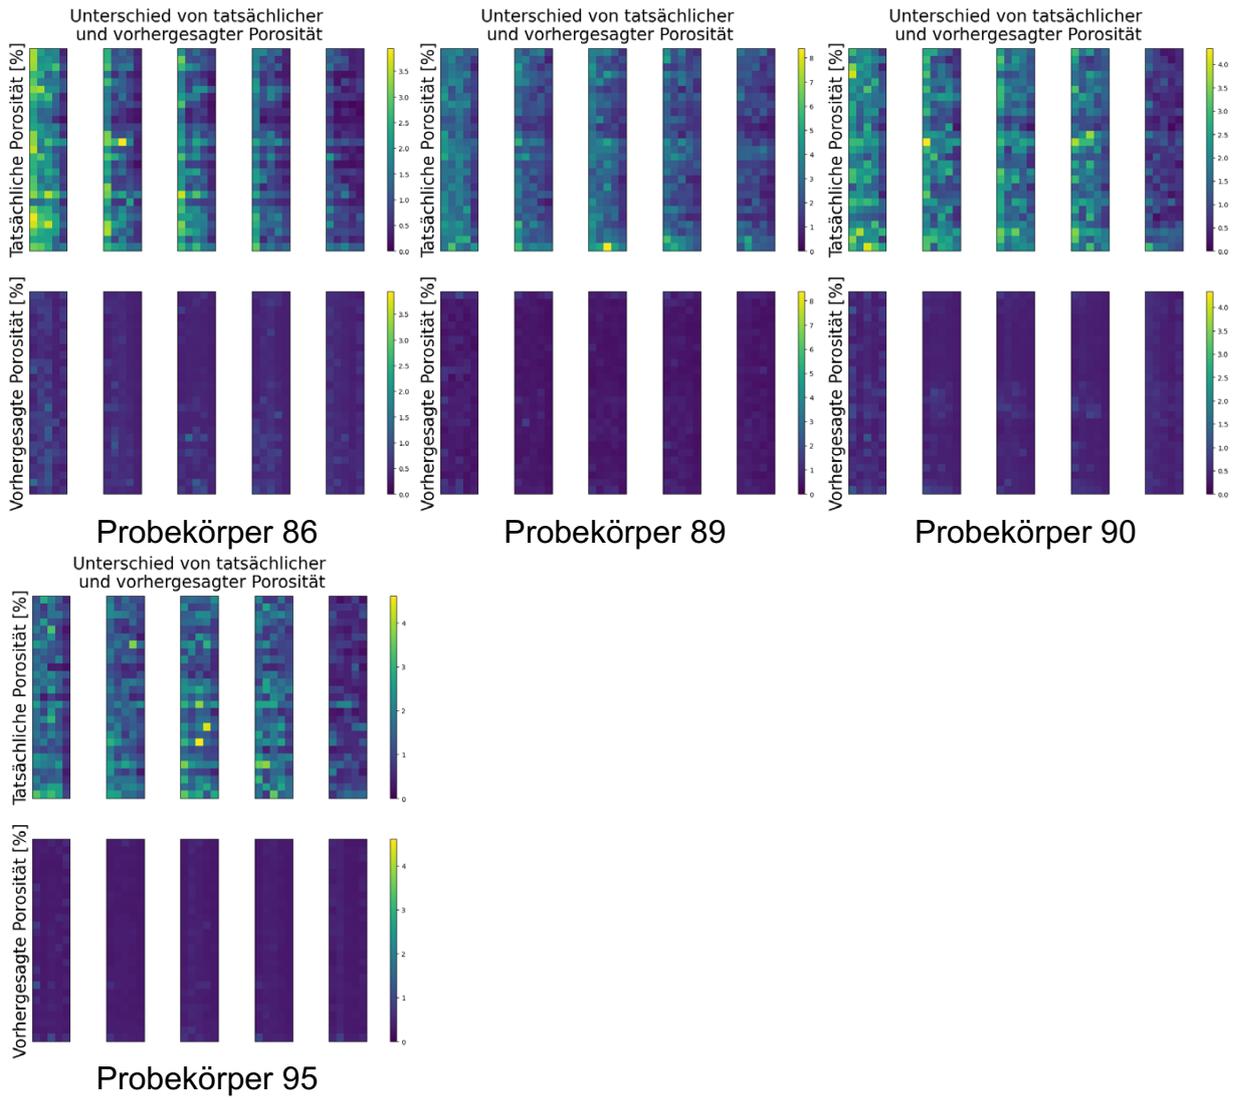




Modellart CNN, Testdatensatz







Forschungsberichte aus dem wbk
Institut für Produktionstechnik
Karlsruher Institut für Technologie (KIT)

Bisher erschienene Bände:

Band 0

Dr.-Ing. Wu Hong-qi

**Adaptive Volumenstromregelung mit Hilfe von drehzahlgeregelten
Elektroantrieben**

Band 1

Dr.-Ing. Heinrich Weiß

**Fräsen mit Schneidkeramik - Verhalten des System
Werkzeugmaschine-Werkzeug-Werkstück und Prozessanalyse**

Band 2

Dr.-Ing. Hans-Jürgen Stierle

**Entwicklung und Untersuchung hydrostatischer Lager für die
Axialkolbenmaschine**

Band 3

Dr.-Ing. Herbert Hörner

Untersuchung des Geräuschverhaltens druckgeregelter Axialkolbenpumpen

Band 4

Dr.-Ing. Rolf-Dieter Brückbauer

**Digitale Drehzahlregelung unter der besonderen Berücksichtigung
von Quantisierungseffekten**

Band 5

Dr.-Ing. Gerhard Staiger

Graphisch interaktive NC-Programmierung von Drehteilen im Werkstattbereich

Band 6

Dr.-Ing. Karl Peters

**Ein Beitrag zur Berechnung und Kompensation von Positionierfehlern an
Industrierobotern**

Band 7

Dr.-Ing. Paul Stauss

Automatisierte Inbetriebnahme und Sicherung der Zuverlässigkeit und Verfügbarkeit numerisch gesteuerter Fertigungseinrichtungen

Band 8

Dr.-Ing. Günter Möckesch

Konzeption und Realisierung eines strategischen, integrierten Gesamtplanungs- und -bearbeitungssystems zur Optimierung der Drehteilorganisation für auftragsbezogene Drehereien

Band 9

Dr.-Ing. Thomas Oestreicher

Rechnergestützte Projektierung von Steuerungen

Band 10

Dr.-Ing. Thomas Selinger

Teilautomatisierte werkstattnahe NC-Programmerstellung im Umfeld einer integrierten Informationsverarbeitung

Band 11

Dr.-Ing. Thomas Buchholz

Prozessmodell Fräsen, Rechnerunterstützte Analyse, Optimierung und Überwachung

Band 12

Dr.-Ing. Bernhard Reichling

Lasergestützte Positions- und Bahnvermessung von Industrierobotern

Band 13

Dr.-Ing. Hans-Jürgen Lesser

Rechnergestützte Methoden zur Auswahl anforderungsgerechter Verbindungselemente

Band 14

Dr.-Ing. Hans-Jürgen Lauffer

Einsatz von Prozessmodellen zur rechnerunterstützten Auslegung von Räumwerkzeugen

Band 15

Dr.-Ing. Michael C. Wilhelm

Rechnergestützte Prüfplanung im Informationsverbund moderner Produktionssysteme

Band 16

Dr.-Ing. Martin Ochs

Entwurf eines Programmsystems zur wissensbasierten Planung und Konfigurierung

Band 17

Dr.-Ing. Heinz-Joachim Schneider

Erhöhung der Verfügbarkeit von hochautomatisierten Produktionseinrichtungen mit Hilfe der Fertigungsleittechnik

Band 18

Dr.-Ing. Hans-Reiner Ludwig

Beanspruchungsanalyse der Werkzeugschneiden beim Stirnplanfräsen

Band 19

Dr.-Ing. Rudolf Wieser

Methoden zur rechnergestützten Konfigurierung von Fertigungsanlagen

Band 20

Dr.-Ing. Edgar Schmitt

Werkstattsteuerung bei wechselnder Auftragsstruktur

Band 21

Dr.-Ing. Wilhelm Enderle

Verfügbarkeitssteigerung automatisierter Montagesysteme durch selbsttätige Behebung prozessbedingter Störungen

Band 22

Dr.-Ing. Dieter Buchberger

Rechnergestützte Strukturplanung von Produktionssystemen

Band 23

Prof. Dr.-Ing. Jürgen Fleischer

Rechnerunterstützte Technologieplanung für die flexibel automatisierte Fertigung von Abkantteilen

Band 24

Dr.-Ing. Lukas Loeffler

Adaptierbare und adaptive Benutzerschnittstellen

Band 25

Dr.-Ing. Thomas Friedmann

Integration von Produktentwicklung und Montageplanung durch neue rechnergestützte Verfahren

Band 26

Dr.-Ing. Robert Zurrin

Variables Formhonen durch rechnergestützte Hornprozesssteuerung

Band 27

Dr.-Ing. Karl-Heinz Bergen

Langhub-Innenrundhonen von Grauguss und Stahl mit einem elektromechanischem Vorschubsystem

Band 28

Dr.-Ing. Andreas Liebisch

Einflüsse des Festwalzens auf die Eigenspannungsverteilung und die Dauerfestigkeit einsatzgehärteter Zahnräder

Band 29

Dr.-Ing. Rolf Ziegler

Auslegung und Optimierung schneller Servopumpen

Band 30

Dr.-Ing. Rainer Bartl

Datenmodellgestützte Wissensverarbeitung zur Diagnose und Informationsunterstützung in technischen Systemen

Band 31

Dr.-Ing. Ulrich Golz

Analyse, Modellbildung und Optimierung des Betriebsverhaltens von Kugelgewindetrieben

Band 32

Dr.-Ing. Stephan Timmermann

Automatisierung der Feinbearbeitung in der Fertigung von Hohlformwerkzeugen

Band 33

Dr.-Ing. Thomas Noe

Rechnergestützter Wissenserwerb zur Erstellung von Überwachungs- und Diagnoseexpertensystemen für hydraulische Anlagen

Band 34

Dr.-Ing. Ralf Lenschow

Rechnerintegrierte Erstellung und Verifikation von Steuerungsprogrammen als Komponente einer durchgängigen Planungsmethodik

Band 35

Dr.-Ing. Matthias Kallabis

Räumen gehärteter Werkstoffe mit kristallinen Hartstoffen

Band 36

Dr.-Ing. Heiner-Michael Honeck

Rückführung von Fertigungsdaten zur Unterstützung einer fertigungsgerechten Konstruktion

Band 37

Dr.-Ing. Manfred Rohr

Automatisierte Technologieplanung am Beispiel der Komplettbearbeitung auf Dreh-/Fräszellen

Band 38

Dr.-Ing. Martin Steuer

Entwicklung von Softwarewerkzeugen zur wissensbasierten Inbetriebnahme von komplexen Serienmaschinen

Band 39

Dr.-Ing. Siegfried Beichter

Rechnergestützte technische Problemlösung bei der Angebotserstellung von flexiblen Drehzellen

Band 40

Dr.-Ing. Thomas Steitz

Methodik zur marktorientierten Entwicklung von Werkzeugmaschinen mit Integration von funktionsbasierter Strukturierung und Kostenschätzung

Band 41

Dr.-Ing. Michael Richter

Wissensbasierte Projektierung elektrohydraulischer Regelungen

Band 42

Dr.-Ing. Roman Kuhn

Technologieplanungssystem Fräsen. Wissensbasierte Auswahl von Werkzeugen, Schneidkörpern und Schnittbedingungen für das Fertigungsverfahren Fräsen

Band 43

Dr.-Ing. Hubert Klein

Rechnerunterstützte Qualitätssicherung bei der Produktion von Bauteilen mit frei geformten Oberflächen

Band 44

Dr.-Ing. Christian Hoffmann

Konzeption und Realisierung eines fertigungsintegrierten Koordinatenmessgerätes

Band 45

Dr.-Ing. Volker Frey

Planung der Leitechnik für flexible Fertigungsanlagen

Band 46

Dr.-Ing. Achim Feller

Kalkulation in der Angebotsphase mit dem selbsttätig abgeleiteten Erfahrungswissen der Arbeitsplanung

Band 47

Dr.-Ing. Markus Klaiber

Produktivitätssteigerung durch rechnerunterstütztes Einfahren von NC-Programmen

Band 48

Dr.-Ing. Roland Minges

Verbesserung der Genauigkeit beim fünffachsignen Fräsen von Freiformflächen

Band 49

Dr.-Ing. Wolfgang Bernhart

Beitrag zur Bewertung von Montagevarianten: Rechnergestützte Hilfsmittel zur kostenorientierten, parallelen Entwicklung von Produkt und Montagesystem

Band 50

Dr.-Ing. Peter Ganghoff

Wissensbasierte Unterstützung der Planung technischer Systeme: Konzeption eines Planungswerkzeuges und exemplarische Anwendung im Bereich der Montagesystemplanung

Band 51

Dr.-Ing. Frank Maier

Rechnergestützte Prozessregelung beim flexiblen Gesenkbiegen durch Rückführung von Qualitätsinformationen

Band 52

Dr.-Ing. Frank Debus

Ansatz eines rechnerunterstützten Planungsmanagements für die Planung in verteilten Strukturen

Band 53

Dr.-Ing. Joachim Weinbrecht

Ein Verfahren zur zielorientierten Reaktion auf Planabweichungen in der Werkstattregelung

Band 54

Dr.-Ing. Gerd Herrmann

Reduzierung des Entwicklungsaufwandes für anwendungsspezifische Zellenrechnersoftware durch Rechnerunterstützung

Band 55

Dr.-Ing. Robert Wassmer

Verschleissentwicklung im tribologischen System Fräsen: Beiträge zur Methodik der Prozessmodellierung auf der Basis tribologischer Untersuchungen beim Fräsen

Band 56

Dr.-Ing. Peter Uebelhoer

Inprocess-Geometriemessung beim Honen

Band 57

Dr.-Ing. Hans-Joachim Schelberg

Objektorientierte Projektierung von SPS-Software

Band 58

Dr.-Ing. Klaus Boes

Integration der Qualitätsentwicklung in featurebasierte CAD/CAM-Prozessketten

Band 59

Dr.-Ing. Martin Schreiber

Wirtschaftliche Investitionsbewertung komplexer Produktionssysteme unter Berücksichtigung von Unsicherheit

Band 60

Dr.-Ing. Ralf Steuernagel

Offenes adaptives Engineering-Werkzeug zur automatisierten Erstellung von entscheidungsunterstützenden Informationssystemen

Band 62

Dr.-Ing. Uwe Schauer

Qualitätsorientierte Feinbearbeitung mit Industrierobotern: Regelungsansatz für die Freiformflächenfertigung des Werkzeug- und Formenbaus

Band 63

Dr.-Ing. Simone Loeper

Kennzahlengestütztes Beratungssystem zur Verbesserung der Logistikleistung in der Werkstattfertigung

Band 64

Dr.-Ing. Achim Raab

Räumen mit hartstoffbeschichteten HSS-Werkzeugen

Band 65,

Dr.-Ing. Jan Erik Burghardt

Unterstützung der NC-Verfahrenskette durch ein bearbeitungs-elementorientiertes, lernfähiges Technologieplanungssystem

Band 66

Dr.-Ing. Christian Tritsch

Flexible Demontage technischer Gebrauchsgüter: Ansatz zur Planung und (teil-)automatisierten Durchführung industrieller Demontageprozesse

Band 67

Dr.-Ing. Oliver Eitrich

Prozessorientiertes Kostenmodell für die entwicklungsbegleitende Vorkalkulation

Band 68

Dr.-Ing. Oliver Wilke

Optimierte Antriebskonzepte für Räummaschinen - Potentiale zur Leistungssteigerung

Band 69

Dr.-Ing. Thilo Sieth

Rechnergestützte Modellierungsmethodik zerspantechnologischer Prozesse

Band 70

Dr.-Ing. Jan Linnenbuerger

Entwicklung neuer Verfahren zur automatisierten Erfassung der geometrischen Abweichungen an Linearachsen und Drehschwenkköpfen

Band 71

Dr.-Ing. Mathias Klimmek

Fraktionierung technischer Produkte mittels eines frei beweglichen Wasserstrahlwerkzeuges

Band 72

Dr.-Ing. Marko Hartel

Kennzahlenbasiertes Bewertungssystem zur Beurteilung der Demontage- und Recyclingeignung von Produkten

Band 73

Dr.-Ing. Jörg Schaupp

Wechselwirkung zwischen der Maschinen- und Hauptspindelantriebsdynamik und dem Zerspanprozess beim Fräsen

Band 74

Dr.-Ing. Bernhard Neisius

Konzeption und Realisierung eines experimentellen Telemanipulators für die Laparoskopie

Band 75

Dr.-Ing. Wolfgang Walter

Erfolgsversprechende Muster für betriebliche Ideenfindungsprozesse. Ein Beitrag zur Steigerung der Innovationsfähigkeit

Band 76

Dr.-Ing. Julian Weber

Ein Ansatz zur Bewertung von Entwicklungsergebnissen in virtuellen Szenarien

Band 77

Dr.-Ing. Dipl. Wirtsch.-Ing. Markus Posur

Unterstützung der Auftragsdurchsetzung in der Fertigung durch Kommunikation über mobile Rechner

Band 78

Dr.-Ing. Frank Fleissner

Prozessorientierte Prüfplanung auf Basis von Bearbeitungsobjekten für die Kleinserienfertigung am Beispiel der Bohr- und Fräsbearbeitung

Band 79

Dr.-Ing. Anton Haberkern

Leistungsfähigere Kugelgewindetriebe durch Beschichtung

Band 80

Dr.-Ing. Dominik Matt

Objektorientierte Prozess- und Strukturinnovation (OPUS)

Band 81

Dr.-Ing. Jürgen Andres

Robotersysteme für den Wohnungsbau: Beitrag zur Automatisierung des Mauerwerkbaus und der Elektroinstallation auf Baustellen

Band 82

Dr.-Ing. Dipl.Wirtschaftsing. Simone Riedmiller

Der Prozesskalender - Eine Methodik zur marktorientierten Entwicklung von Prozessen

Band 83

Dr.-Ing. Dietmar Tilch

Analyse der Geometrieparameter von Präzisionsgewinden auf der Basis einer Least-Squares-Estimation

Band 84

Dr.-Ing. Dipl.-Kfm. Oliver Stiefbold

Konzeption eines reaktionsschnellen Planungssystems für Logistikketten auf Basis von Software-Agenten

Band 85

Dr.-Ing. Ulrich Walter

Einfluss von Kühlschmierstoff auf den Zerspansprozess beim Fräsen: Beitrag zum Prozessverständnis auf Basis von zerspantechnischen Untersuchungen

Band 86

Dr.-Ing. Bernd Werner

Konzeption von teilautonomer Gruppenarbeit unter Berücksichtigung kultureller Einflüsse

Band 87

Dr.-Ing. Ulf Osmers

Projektieren Speicherprogrammierbarer Steuerungen mit Virtual Reality

Band 88

Dr.-Ing. Oliver Doerfel

Optimierung der Zerspantechnik beim Fertigungsverfahren Wälzstossen: Analyse des Potentials zur Trockenbearbeitung

Band 89

Dr.-Ing. Peter Baumgartner

Stufenmethode zur Schnittstellengestaltung in der internationalen Produktion

Band 90

Dr.-Ing. Dirk Vossmann

Wissensmanagement in der Produktentwicklung durch Qualitätsmethodenverbund und Qualitätsmethodenintegration

Band 91

Dr.-Ing. Martin Plass

Beitrag zur Optimierung des Honprozesses durch den Aufbau einer Honprozessregelung

Band 92

Dr.-Ing. Titus Konold

Optimierung der Fünfsachsfräsbearbeitung durch eine kennzahlenunterstützte CAM-Umgebung

Band 93

Dr.-Ing. Jürgen Brath

Unterstützung der Produktionsplanung in der Halbleiterfertigung durch risikoberücksichtigende Betriebskennlinien

Band 94

Dr.-Ing. Dirk Geisinger

Ein Konzept zur marktorientierten Produktentwicklung

Band 95

Dr.-Ing. Marco Lanza

Entwurf der Systemunterstützung des verteilten Engineering mit Axiomatic Design

Band 96

Dr.-Ing. Volker Hüntrup

Untersuchungen zur Mikrostrukturierbarkeit von Stählen durch das Fertigungsverfahren Fräsen

Band 97

Dr.-Ing. Frank Reinboth

Interne Stützung zur Genauigkeitsverbesserung in der Inertialmesstechnik: Beitrag zur Senkung der Anforderungen an Inertialsensoren

Band 98

Dr.-Ing. Lutz Trender

Entwicklungsintegrierte Kalkulation von Produktlebenszykluskosten auf Basis der ressourcenorientierten Prozesskostenrechnung

Band 99

Dr.-Ing. Cornelia Kafka

Konzeption und Umsetzung eines Leitfadens zum industriellen Einsatz von Data-Mining

Band 100

Dr.-Ing. Gebhard Selinger

Rechnerunterstützung der informellen Kommunikation in verteilten Unternehmensstrukturen

Band 101

Dr.-Ing. Thomas Windmüller

Verbesserung bestehender Geschäftsprozesse durch eine mitarbeiterorientierte Informationsversorgung

Band 102

Dr.-Ing. Knud Lembke

Theoretische und experimentelle Untersuchung eines bistabilen elektrohydraulischen Linearantriebs

Band 103

Dr.-Ing. Ulrich Thies

Methode zur Unterstützung der variantengerechten Konstruktion von industriell eingesetzten Kleingeräten

Band 104

Dr.-Ing. Andreas Schmäzle

Bewertungssystem für die Generalüberholung von Montageanlagen –Ein Beitrag zur wirtschaftlichen Gestaltung geschlossener Facility- Management-Systeme im Anlagenbau

Band 105

Dr.-Ing. Thorsten Frank

Vergleichende Untersuchungen schneller elektromechanischer Vorschubachsen mit Kugelgewindetrieb

Band 106

Dr.-Ing. Achim Agostini

Reihenfolgeplanung unter Berücksichtigung von Interaktionen: Beitrag zur ganzheitlichen Strukturierung und Verarbeitung von Interaktionen von Bearbeitungsobjekten

Band 107

Dr.-Ing. Thomas Barrho

Flexible, zeitfenstergesteuerte Auftragseinplanung in segmentierten Fertigungsstrukturen

Band 108

Dr.-Ing. Michael Scharer

Quality Gate-Ansatz mit integriertem Risikomanagement

Band 109

Dr.-Ing. Ulrich Suchy

Entwicklung und Untersuchung eines neuartigen Mischkopfes für das Wasser Abrasivstrahlschneiden

Band 110

Dr.-Ing. Sellal Mussa

Aktive Korrektur von Verlagerungsfehlern in Werkzeugmaschinen

Band 111

Dr.-Ing. Andreas Hühsam

Modellbildung und experimentelle Untersuchung des Wälzschälprozesses

Band 112

Dr.-Ing. Axel Plutowsky

Charakterisierung eines optischen Messsystems und den Bedingungen des Arbeitsraums einer Werkzeugmaschine

Band 113

Dr.-Ing. Robert Landwehr

Konsequent dezentralisierte Steuerung mit Industrial Ethernet und offenen Applikationsprotokollen

Band 114

Dr.-Ing. Christoph Dill

Turbulenzreaktionsprozesse

Band 115

Dr.-Ing. Michael Baumeister

Fabrikplanung im turbulenten Umfeld

Band 116

Dr.-Ing. Christoph Gönninger

Konzept zur Verbesserung der Elektromagnetischen Verträglichkeit (EMV) in Produktionssystemen durch intelligente Sensor/Aktor-Anbindung

Band 117

Dr.-Ing. Lutz Demuß

Ein Reifemodell für die Bewertung und Entwicklung von Dienstleistungsorganisationen: Das Service Management Maturity Modell (SMMM)

Band 118

Dr.-Ing. Jörg Söhner

Beitrag zur Simulation zerspanungstechnologischer Vorgänge mit Hilfe der Finite-Element-Methode

Band 119

Dr.-Ing. Judith Elsner

Informationsmanagement für mehrstufige Mikro-Fertigungsprozesse

Band 120

Dr.-Ing. Lijing Xie

Estimation Of Two-dimension Tool Wear Based On Finite Element Method

Band 121

Dr.-Ing. Ansgar Blessing

Geometrischer Entwurf mikromechatronischer Systeme

Band 122

Dr.-Ing. Rainer Ebner

Steigerung der Effizienz mehrachsiger Fräsprozesse durch neue Planungsmethoden mit hoher Benutzerunterstützung

Band 123

Dr.-Ing. Silja Klinkel

Multikriterielle Feinplanung in teilautonomen Produktionsbereichen – Ein Beitrag zur produkt- und prozessorientierten Planung und Steuerung

Band 124

Dr.-Ing. Wolfgang Neithardt

Methodik zur Simulation und Optimierung von Werkzeugmaschinen in der Konzept- und Entwurfsphase auf Basis der Mehrkörpersimulation

Band 125

Dr.-Ing. Andreas Mehr

Hartfeinbearbeitung von Verzahnungen mit kristallinen diamantbeschichteten Werkzeugen beim Fertigungsverfahren Wälzstoßen

Band 126

Dr.-Ing. Martin Gutmann

Entwicklung einer methodischen Vorgehensweise zur Diagnose von hydraulischen Produktionsmaschinen

Band 127

Dr.-Ing. Gisela Lanza

Simulative Anlaufunterstützung auf Basis der Qualitätsfähigkeiten von Produktionsprozessen

Band 128

Dr.-Ing. Ulf Dambacher

Kugelgewindetrieb mit hohem Druckwinkel

Band 129

Dr.-Ing. Carsten Buchholz

Systematische Konzeption und Aufbau einer automatisierten Produktionszelle für pulverspritzgegossene Mikrobauteile

Band 130

Dr.-Ing. Heiner Lang

Trocken-Räumen mit hohen Schnittgeschwindigkeiten

Band 131

Dr.-Ing. Daniel Nesges

Prognose operationeller Verfügbarkeiten von Werkzeugmaschinen unter Berücksichtigung von Serviceleistungen

Im Shaker Verlag erschienene Bände:

Band 132

Dr.-Ing. Andreas Bechle

Beitrag zur prozesssicheren Bearbeitung beim Hochleistungsfertigungsverfahren Wälzschälern

Band 133

Dr.-Ing. Markus Herm

Konfiguration globaler Wertschöpfungsnetzwerke auf Basis von Business Capabilities

Band 134

Dr.-Ing. Hanno Tritschler

Werkzeug- und Zerspanprozessoptimierung beim Hartfräsen von Mikrostrukturen in Stahl

Band 135

Dr.-Ing. Christian Munzinger

Adaptronische Strebe zur Steifigkeitssteigerung von Werkzeugmaschinen

Band 136

Dr.-Ing. Andreas Stepping

Fabrikplanung im Umfeld von Wertschöpfungsnetzwerken und ganzheitlichen Produktionssystemen

Band 137

Dr.-Ing. Martin Dyck

Beitrag zur Analyse thermische bedingter Werkstückdeformationen in Trockenbearbeitungsprozessen

Band 138

Dr.-Ing. Siegfried Schmalzried

Dreidimensionales optisches Messsystem für eine effizientere geometrische Maschinenbeurteilung

Band 139

Dr.-Ing. Marc Wawerla

Risikomanagement von Garantieleistungen

Band 140

Dr.-Ing. Ivesa Buchholz

Strategien zur Qualitätssicherung mikromechanischer Bauteile mittels multisensorieller Koordinatenmesstechnik

Band 141

Dr.-Ing. Jan Kotschenreuther

Empirische Erweiterung von Modellen der Makrozerspannung auf den Bereich der Mikrobearbeitung

Band 142

Dr.-Ing. Andreas Knödel

Adaptronische hydrostatische Drucktascheneinheit

Band 143

Dr.-Ing. Gregor Stengel

Fliegendes Abtrennen räumlich gekrümmter Strangpressprofile mittels Industrierobotern

Band 144

Dr.-Ing. Udo Weismann

Lebenszyklusorientiertes interorganisationelles Anlagencontrolling

Band 145

Dr.-Ing. Rüdiger Pabst

Mathematische Modellierung der Wärmestromdichte zur Simulation des thermischen Bauteilverhaltens bei der Trockenbearbeitung

Band 146

Dr.-Ing. Jan Wieser

Intelligente Instandhaltung zur Verfügbarkeitssteigerung von Werkzeugmaschinen

Band 147

Dr.-Ing. Sebastian Haupt

Effiziente und kostenoptimale Herstellung von Mikrostrukturen durch eine Verfahrenskombination von Bahnerosion und Laserablation

Band 148

Dr.-Ing. Matthias Schlipf

Statistische Prozessregelung von Fertigungs- und Messprozess zur Erreichung einer variabilitätsarmen Produktion mikromechanischer Bauteile

Band 149

Dr.-Ing. Jan Philipp Schmidt-Ewig

Methodische Erarbeitung und Umsetzung eines neuartigen Maschinenkonzeptes zur produktflexiblen Bearbeitung räumlich gekrümmter Strangpressprofile

Band 150

Dr.-Ing. Thomas Ender

Prognose von Personalbedarfen im Produktionsanlauf unter Berücksichtigung dynamischer Planungsgrößen

Band 151

Dr.-Ing. Kathrin Peter

**Bewertung und Optimierung der Effektivität von Lean Methoden
in der Kleinserienproduktion**

Band 152

Dr.-Ing. Matthias Schopp

Sensorbasierte Zustandsdiagnose und -prognose von Kugelgewindetrieben

Band 153

Dr.-Ing. Martin Kipfmüller

Aufwandsoptimierte Simulation von Werkzeugmaschinen

Band 154

Dr.-Ing. Carsten Schmidt

**Development of a database to consider multi wear mechanisms
within chip forming simulation**

Band 155

Dr.-Ing. Stephan Niggeschmidt

**Ausfallgerechte Ersatzteilbereitstellung im Maschinen- und Anlagenbau
mittels lastabhängiger Lebensdauerprognose**

Band 156

Dr.-Ing. Jochen Conrad Peters

**Bewertung des Einflusses von Formabweichungen in der
Mikro-Koordinatenmesstechnik**

Band 157

Dr.-Ing. Jörg Ude

**Entscheidungsunterstützung für die Konfiguration
globaler Wertschöpfungsnetzwerke**

Band 158

Dr.-Ing. Stefan Weiler

Strategien zur wirtschaftlichen Gestaltung der globalen Beschaffung

Band 159

Dr.-Ing. Jan Rühl

Monetäre Flexibilitäts- und Risikobewertung

Band 160

Dr.-Ing. Daniel Ruch

Positions- und Konturerfassung räumlich gekrümmter Profile auf Basis bauteilimmanenter Markierungen

Band 161

Dr.-Ing. Manuel Tröndle

Flexible Zuführung von Mikrobauteilen mit piezoelektrischen Schwingförderern

Band 162

Dr.-Ing. Benjamin Viering

Mikroverzahnungsnormal

Band 163

Dr.-Ing. Chris Becke

Prozesskraftrichtungsangepasste Frässtrategien zur schädigungsarmen Bohrungsbearbeitung an faserverstärkten Kunststoffen

Band 164

Dr.-Ing. Patrick Werner

Dynamische Optimierung und Unsicherheitsbewertung der lastabhängigen präventiven Instandhaltung von Maschinenkomponenten

Band 165

Dr.-Ing. Martin Weis

Kompensation systematischer Fehler bei Werkzeugmaschinen durch self-sensing Aktoren

Band 166

Dr.-Ing. Markus Schneider

Kompensation von Konturabweichungen bei gerundeten Strangpressprofilen durch robotergestützte Führungswerkzeuge

Band 167

Dr.-Ing. Ester M. R. Ruprecht

Prozesskette zur Herstellung schichtbasierter Systeme mit integrierten Kavitäten

Band 168

Dr.-Ing. Alexander Broos

Simulationsgestützte Ermittlung der Komponentenbelastung für die Lebensdauerprognose an Werkzeugmaschinen

Band 169

Dr.-Ing. Frederik Zanger

Segmentspanbildung, Werkzeugverschleiß, Randschichtzustand und Bauteileigenschaften: Numerische Analysen zur Optimierung des Zerspanungsprozesses am Beispiel von Ti-6Al-4V

Band 170

Dr.-Ing. Benjamin Behmann

Servicefähigkeit

Band 171

Dr.-Ing. Annabel Gabriele Jondral

Simulationsgestützte Optimierung und Wirtschaftlichkeitsbewertung des Lean-Methodeneinsatzes

Band 172

Dr.-Ing. Christoph Ruhs

Automatisierte Prozessabfolge zur qualitätssicheren Herstellung von Kavitäten mittels Mikrobahnerosion

Band 173

Dr.-Ing. Steven Peters

Markoffsche Entscheidungsprozesse zur Kapazitäts- und Investitionsplanung von Produktionssystemen

Band 174

Dr.-Ing. Christoph Kühlewein

Untersuchung und Optimierung des Wälzschälverfahrens mit Hilfe von 3D-FEM-Simulation – 3D-FEM Kinematik- und Spanbildungssimulation

Band 175

Dr.-Ing. Adam-Mwanga Dieckmann

Auslegung und Fertigungsprozessgestaltung sintergefügter Verbindungen für μ MIM-Bauteile

Band 176

Dr.-Ing. Heiko Hennrich

Aufbau eines kombinierten belastungs- und zustandsorientierten Diagnose- und Prognosesystems für Kugelgewindetriebe

Band 177

Dr.-Ing. Stefan Herder

Piezoelektrischer Self-Sensing-Aktor zur Vorspannungsregelung in adaptronischen Kugelgewindetriebe

Band 178

Dr.-Ing. Alexander Ochs

Ultraschall-Strömungsgreifer für die Handhabung textiler Halbzeuge bei der automatisierten Fertigung von RTM-Bauteilen

Band 179

Dr.-Ing. Jürgen Michna

Numerische und experimentelle Untersuchung zerspanungsbedingter Gefügeumwandlungen und Modellierung des thermo-mechanischen Lastkollektivs beim Bohren von 42CrMo4

Band 180

Dr.-Ing. Jörg Elser

Vorrichtungsfreie räumliche Anordnung von Fügepartnern auf Basis von Bauteilmarkierungen

Band 181

Dr.-Ing. Katharina Klimscha

Einfluss des Fügespalts auf die erreichbare Verbindungsqualität beim Sinterfügen

Band 182

Dr.-Ing. Patricia Weber

Steigerung der Prozesswiederholbarkeit mittels Analyse akustischer Emissionen bei der Mikrolaserablation mit UV-Pikosekundenlasern

Band 183

Dr.-Ing. Jochen Schädel

Automatisiertes Fügen von Tragprofilen mittels Faserwickeln

Band 184

Dr.-Ing. Martin Krauß

Aufwandsoptimierte Simulation von Produktionsanlagen durch Vergrößerung der Geltungsbereiche von Teilmodellen

Band 185

Dr.-Ing. Raphael Moser

Strategische Planung globaler Produktionsnetzwerke

Bestimmung von Wandlungsbedarf und Wandlungszeitpunkt mittels multikriterieller Optimierung

Band 186

Dr.-Ing. Martin Otter

Methode zur Kompensation fertigungsbedingter Gestaltabweichungen für die Montage von Aluminium Space-Frame-Strukturen

Band 187

Dr.-Ing. Urs Leberle

Produktive und flexible Gleitförderung kleiner Bauteile auf phasenflexiblen Schwingförderern mit piezoelektrischen 2D-Antriebselementen

Band 188

Dr.-Ing. Johannes Book

Modellierung und Bewertung von Qualitätsmanagementstrategien in globalen Wertschöpfungsnetzwerken

Band 189

Dr.-Ing. Florian Ambrosy

Optimierung von Zerspanungsprozessen zur prozesssicheren Fertigung nanokristalliner Randschichten am Beispiel von 42CrMo4

Band 190

Dr.-Ing. Adrian Kölmel

Integrierte Messtechnik für Prozessketten unreifer Technologien am Beispiel der Batterieproduktion für Elektrofahrzeuge

Band 191

Dr.-Ing. Henning Wagner

Featurebasierte Technologieplanung zum Preforming von textilen Halbzeugen

Band 192

Dr.-Ing. Johannes Gebhardt

**Strukturoptimierung von in FVK eingebetteten metallischen
Lasteinleitungselementen**

Band 193

Dr.-Ing. Jörg Bauer

**Hochintegriertes hydraulisches Vorschubsystem für die Bearbeitung kleiner
Werkstücke mit hohen Fertigungsanforderungen**

Band 194

Dr.-Ing. Nicole Stricker

Robustheit verketteter Produktionssysteme

Robustheitsevaluation und Selektion des Kennzahlensystems der Robustheit

Band 195

Dr.-Ing. Anna Sauer

**Konfiguration von Montagelinien unreifer Produkttechnologien am Beispiel der
Batteriemontage für Elektrofahrzeuge**

Band 196

Dr.-Ing. Florian Sell-Le Blanc

Prozessmodell für das Linearwickeln unrunder Zahnspulen

Ein Beitrag zur orthozyklischen Spulenwickeltechnik

Band 197

Dr.-Ing. Frederic Förster

**Geregeltes Handhabungssystem zum zuverlässigen und energieeffizienten
Handling textiler Kohlenstofffaserzuschnitte**

Band 198

Dr.-Ing. Nikolay Boev

**Numerische Beschreibung von Wechselwirkungen zwischen Zerspanprozess und
Maschine am Beispiel Räumen**

Band 199

Dr.-Ing. Sebastian Greinacher

**Simulationsgestützte Mehrzieloptimierung schlanker und ressourceneffizienter
Produktionssysteme**

Band 200

Dr.-Ing. Benjamin Häfner

Lebensdauerprognose in Abhängigkeit der Fertigungsabweichungen bei Mikroverzahnungen

Band 201

Dr.-Ing. Stefan Klotz

Dynamische Parameteranpassung bei der Bohrungsherstellung in faserverstärkten Kunststoffen unter zusätzlicher Berücksichtigung der Einspannsituation

Band 202

Dr.-Ing. Johannes Stoll

Bewertung konkurrierender Fertigungsfolgen mittels Kostensimulation und stochastischer Mehrzieloptimierung

Anwendung am Beispiel der Blechpaketfertigung für automobiler Elektromotoren

Band 203

Dr.-Ing. Simon-Frederik Koch

Fügen von Metall-Faserverbund-Hybridwellen im Schleuderverfahren ein Beitrag zur fertigungsgerechten intrinsischen Hybridisierung

Band 204

Dr.-Ing. Julius Ficht

Numerische Untersuchung der Eigenspannungsentwicklung für sequenzielle Zerspanungsprozesse

Band 205

Dr.-Ing. Manuel Baumeister

Automatisierte Fertigung von Einzelblattstapeln in der Lithium-Ionen-Zellproduktion

Band 206

Dr.-Ing. Daniel Bertsch

Optimierung der Werkzeug- und Prozessauslegung für das Wälzschälen von Innenverzahnungen

Band 207

Dr.-Ing. Kyle James Kippenbrock

Deconvolution of Industrial Measurement and Manufacturing Processes for Improved Process Capability Assessments

Band 208

Dr.-Ing. Farboud Bejnoud

Experimentelle Prozesskettenbetrachtung für Räumbauteile am Beispiel einer einsatzgehärteten PKW-Schiebemuffe

Band 209

Dr.-Ing. Steffen Dosch

Herstellungsübergreifende Informationsübertragung zur effizienten Produktion von Werkzeugmaschinen am Beispiel von Kugelgewindetrieben

Band 210

Dr.-Ing. Emanuel Moser

Migrationsplanung globaler Produktionsnetzwerke
Bestimmung robuster Migrationspfade und risiko-effizienter Wandlungsbefähiger

Band 211

Dr.-Ing. Jan Hochdörffer

Integrierte Produktallokationsstrategie und Konfigurationssequenz in globalen Produktionsnetzwerken

Band 212

Dr.-Ing. Tobias Arndt

Bewertung und Steigerung der Prozessqualität in globalen Produktionsnetzwerken

Band 213

Dr.-Ing. Manuel Peter

Unwuchtminimale Montage von Permanentmagnetrotoren durch modellbasierte Online-Optimierung

Band 214

Dr.-Ing. Robin Kopf

Kostenorientierte Planung von Fertigungsfolgen additiver Technologien

Band 215

Dr.-Ing. Harald Meier

**Einfluss des Räumens auf den Bauteilzustand in der Prozesskette
Weichbearbeitung – Wärmebehandlung – Hartbearbeitung**

Band 216

Dr.-Ing. Daniel Brabandt

**Qualitätssicherung von textilen Kohlenstofffaser-Preforms mittels
optischer Messtechnik**

Band 217

Dr.-Ing. Alexandra Schabunow

**Einstellung von Aufnahmeparametern mittels projektionsbasierter Qualitäts-
kenngrößen in der industriellen Röntgen-Computertomographie**

Band 218

Dr.-Ing. Jens Bürgin

Robuste Auftragsplanung in Produktionsnetzwerken
Mittelfristige Planung der variantenreichen Serienproduktion unter Unsicherheit
der Kundenauftragskonfigurationen

Band 219

Dr.-Ing. Michael Gerstenmeyer

**Entwicklung und Analyse eines mechanischen Oberflächenbehandlungs-
verfahrens unter Verwendung des Zerspanungswerkzeuges**

Band 220

Dr.-Ing. Jacques Burtscher

**Erhöhung der Bearbeitungsstabilität von Werkzeugmaschinen durch
semi-passive masseneinstellbare Dämpfungssysteme**

Band 221

Dr.-Ing. Dietrich Berger

**Qualitätssicherung von textilen Kohlenstofffaser-Preforms mittels prozess-
integrierter Wirbelstromsensor-Arrays**

Band 222

Dr.-Ing. Fabian Johannes Ballier

Systematic gripper arrangement for a handling device in lightweight production processes

Band 223

Dr.-Ing. Marielouise Schäferling, geb. Zaiß

Development of a Data Fusion-Based Multi-Sensor System for Hybrid Sheet Molding Compound

Band 224

Dr.-Ing. Quirin Spiller

Additive Herstellung von Metallbauteilen mit dem ARBURG Kunststoff-Freiformen

Band 225

Dr.-Ing. Andreas Spohrer

Steigerung der Ressourceneffizienz und Verfügbarkeit von Kugelgewindetrieben durch adaptive Schmierung

Band 226

Dr.-Ing. Johannes Fisel

Veränderungsfähigkeit getakteter Fließmontagesysteme
Planung der Fließbandabstimmung am Beispiel der Automobilmontage

Band 227

Dr.-Ing. Patrick Bollig

Numerische Entwicklung von Strategien zur Kompensation thermisch bedingter Verzüge beim Bohren von 42CrMo4

Band 228

Dr.-Ing. Ramona Pfeiffer, geb. Singer

Untersuchung der prozessbestimmenden Größen für die anforderungsgerechte Gestaltung von Pouchzellen-Verpackungen

Band 229

Dr.-Ing. Florian Baumann

Additive Fertigung von endlosfaserverstärkten Kunststoffen mit dem ARBURG Kunststoff-Freiform Verfahren

Band 230

Dr.-Ing. Tom Stähr

Methodik zur Planung und Konfigurationsauswahl skalierbarer Montagesysteme – Ein Beitrag zur skalierbaren Automatisierung

Band 231

Dr.-Ing. Jan Schwennen

Einbringung und Gestaltung von Lasteinleitungsstrukturen für im RTM-Verfahren hergestellte FVK-Sandwichbauteile

Band 232

Dr.-Ing. Sven Coutandin

Prozessstrategien für das automatisierte Preforming von bebinderten textilen Halbzeugen mit einem segmentierten Werkzeugsystem

Band 233

Dr.-Ing. Christoph Liebrecht

Entscheidungsunterstützung für den Industrie 4.0-Methodeneinsatz
Strukturierung, Bewertung und Ableitung von Implementierungsreihenfolgen

Band 234

Dr.-Ing. Stefan Treber

Transparenzsteigerung in Produktionsnetzwerken
Verbesserung des Störungsmanagements durch verstärkten Informationsaustausch

Band 235

Dr.-Ing. Marius Dackweiler

Modellierung des Fügewickelprozesses zur Herstellung von leichten Fachwerkstrukturen

Band 236

Dr.-Ing. Fabio Echsler Minguillon

Prädiktiv-reaktives Scheduling zur Steigerung der Robustheit in der Matrix-Produktion

Band 237

Dr.-Ing. Sebastian Haag

Entwicklung eines Verfahrensablaufes zur Herstellung von Batteriezellstapeln mit großformatigem, rechteckigem Stapelformat und kontinuierlichen Materialbahnen

Band 238

Dr.-Ing. Raphael Wagner

Strategien zur funktionsorientierten Qualitätsregelung in der Serienproduktion

Band 239

Dr.-Ing. Christopher Ehrmann

Ausfallfrüherkennung von Ritzel-Zahnstangen- Trieben mittels Acoustic Emission

Band 240

Dr.-Ing. Janna Hofmann

Prozessmodellierung des Fünf-Achs-Nadelwickelns zur Implementierung einer trajektoriebasierten Drahtzugkraftregelung

Band 241

Dr.-Ing. Andreas Kuhnle

**Adaptive Order Dispatching based on Reinforcement Learning
Application in a Complex Job Shop in the Semiconductor Industry**

Band 242

Dr.-Ing. Andreas Greiber

**Fertigung optimierter technischer Oberflächen durch eine
Verfahrenskombination aus Fliehkraft-Tauchgleitschleifen und Laserablation
Prozesseinflüsse und Prozessauslegung**

Band 243

Dr.-Ing. Jan Niclas Eschner

**Entwicklung einer akustischen Prozessüberwachung zur
Porenbestimmung im Laserstrahlschmelzen**

Band 244

Dr.-Ing. Sven Roth

**Schädigungsfreie Anbindung von hybriden FVK/Metall-Bauteilen an
metallische Tragstrukturen durch Widerstandspunktschweißen**

Band 245

Dr.-Ing. Sina Kathrin Peukert

**Robustheitssteigerung in Produktionsnetzwerken mithilfe eines integrierten
Störungsmanagements**

Band 246

Dr.-Ing. Alexander Jacob

Hochiterative Technologieplanung

Rekursive Optimierung produkt- und fertigungsbezogener Freiheitsgrade am Beispiel der hybrid-additiven Fertigung

Band 247

Dr.-Ing. Patrick Moll

Ressourceneffiziente Herstellung von Langfaser-Preforms im Faserblasverfahren

Band 248

Dr.-Ing. Eric Thore Segebade

Erhöhung der Verschleißbeständigkeit von Bauteilen aus Ti-6Al-4V mittels simulationsgestützter Zerspanung und mechanischer Mikrotexturierung

Band 249

Dr.-Ing. Shun Yang

Regionalized implementation strategy of smart automation within assembly systems in China

Band 250

Dr.-Ing. Constantin Carl Hofmann

Vorausschauende und reaktive Mehrzieloptimierung für die Produktionssteuerung einer Matrixproduktion

Band 251

Dr.-Ing. Paul Ruhland

Prozesskette zur Herstellung von hybriden Faser-Metall-Preforms

Modellbildung und Optimierung des Binderauftrags und der Drapierung für stabförmige Bauteile

Band 252

Dr.-Ing. Leonard Schild

Erzeugung und Verwendung von Anwendungswissen in der industriellen Computertomographie

Band 253

Dr.-Ing. Benedikt Klee

Analyse von Phaseninformationen in Videodaten zur Identifikation von Schwingungen in Werkzeugmaschinen

Band 254

Dr.-Ing. Bruno Vargas

Wälzschälern mit kleinen Achskreuzwinkeln

Prozessgrenzen und Umsetzbarkeit

Band 255

Dr.-Ing. Lucas Bretz

Function-oriented in-line quality assurance of hybrid sheet molding compound

Band 256

Dr.-Ing. Bastian Rothaupt

Dämpfung von Bauteilschwingungen durch einstellbare Werkstückdirektspannung mit Hydrodehnspanntechnik

Band 257

Dr.-Ing. Daniel Kupzik

Robotic Swing Folding of three-dimensional UD-tape-based Reinforcement Structures

Band 258

Dr.-Ing. Bastian Verhaelen

(De-)Zentralisierung von Entscheidungen in globalen Produktionsnetzwerken
Strategie- und komplexitätsorientierte Gestaltung der Entscheidungsautonomie

Band 259

Dr.-Ing. Hannes Wilhelm Weinmann

Integration des Vereinzelnungs- und Stapelbildungsprozesses in ein flexibel und kontinuierlich arbeitendes Anlagenmodul für die Li-Ionen Batteriezellfertigung

Band 260

Dr.-Ing. Florian Stamer

Dynamische Lieferzeit-Preisgestaltung in variantenreicher Produktion
Ein adaptiver Ansatz mithilfe von Reinforcement Learning

Band 261

Dr.-Ing. Patrick Neuenfeldt

Modellbildung des Tauchgleitschleifens zur Abtrag- und Topografievorhersage an komplexen Geometrien

Band 262

Dr.-Ing. Boris Matuschka

Energieeffizienz in Prozessketten: Analyse und Optimierung von Energieflüssen bei der Herstellung eines PKW-Getriebebauteils aus 16MnCr5

Band 263

Dr.-Ing. Tobias Schlagenhauf

Bildbasierte Quantifizierung und Prognose des Verschleißes an Kugelgewindetriebspindeln

Ein Beitrag zur Zustandsüberwachung von Kugelgewindetrieben mittels Methoden des maschinellen Lernens

Band 264

Dr.-Ing. Benedict Stampfer

Entwicklung eines multimodalen Prozessmodells zur Oberflächenkonditionierung beim Außenlängsdrehen von 42CrMo4

Band 265

Dr.-Ing. Carmen Maria Krahe

KI-gestützte produktionsgerechte Produktentwicklung

Automatisierte Wissensextraktion aus vorhandenen Produktgenerationen

Band 266

Dr.-Ing. Markus Netzer

Intelligente Anomalieerkennung für hochflexible Produktionsmaschinen
Prozessüberwachung in der Brownfield Produktion

Band 267

Dr.-Ing. Simon Raphael Merz

Analyse der Kinematik und Kinetik von Planetenwälzgewindetrieben

Band 268

Dr.-Ing. Rainer Maria Silbernagel

Funktionsorientierte Qualitätsregelung in Produktionsnetzwerken

Qualitätsmanagement in der Produktion hochpräziser Produkte durch netzwerkweite Datenintegration

Band 269

Dr.-Ing. Jonas Nieschlag

Gestaltung und Prozessanalyse für im Schleuderverfahren hergestellte FKV-Metall-Hohlstrukturen

Band 270

Dr.-Ing. Lukas Matthias Weiser

In-Process Porositätserkennung für den PBF-LB/M-Prozess

