

Masterarbeit

Bauingenieurwesen- Architectural Engineering  
Technisches Infrastrukturmanagement

**Entwicklung eines KI-basierten Bildverarbeitungstools zur  
automatisierten Erkennung und Vermessung von Zellen in PUR-  
Hartschaumproben für die Qualitätsprüfung von  
Fernwärmeisoliermaterialien**

Eingereicht an der HafenCity Universität Hamburg  
zur Erlangung des akademischen Grades  
Master of Science

Autor: Nouraldin Idrees  
Matrikelnummer: 6050577  
Mail: [nour.idrees@hcu-hamburg.de](mailto:nour.idrees@hcu-hamburg.de)

Erstgutachter: Prof. Dr.-Ing. Ingo Weidlich  
Zweitgutachter: Pakdad Pourbozorgi Langroudi (M.Sc.)

Eingereicht am: 13.11.2024

## ABSTRAKT

This thesis presents the development of an AI-based image processing tool for the automated detection and measurement of cells in polyurethane rigid foam samples, with the objective of facilitating the quality inspection of district heating insulation materials. Polyurethane rigid foam (PUR) is one of the most utilised insulation materials in district heating systems, primarily due to its exemplary thermal properties. The morphology of the cells in PUR foam, in particular the dimensions of the cells and the thickness of the cell walls, has a considerable effect on the thermal conductivity and ageing of the material. However, the conventional manual inspection of the cell structure in accordance with the DIN EN 253 standard is often time-consuming, labour-intensive and prone to error.

The aim of this study is to develop a Python-based analysis tool that utilises computer vision and AI methods to automatically detect and measure the cell structure in high-resolution X-ray microscopy images of PUR foam samples. The developed algorithm employs established image processing techniques, including thresholding, watershed transformation, and contour detection, for the purpose of cell segmentation. Furthermore, the potential of deep learning approaches, particularly those utilising the Detectron2 framework, for cell analysis is investigated.

The validation of the developed analysis tool is conducted using both synthetic test images and real PUR samples X-ray microscopy images. The results demonstrate that the tool is capable of accurately determining cell diameters and cell wall thicknesses, as well as verifying whether the cell sizes meet the requirements of DIN EN 253. The utilisation of an AI-based image processing tool has the potential to markedly enhance the efficiency and accuracy of quality inspection of PUR insulation materials. The developed code is available in a public GitHub repository (<https://github.com/NouraldinIdrees/PUR-Check>) to ensure reproducibility and further research opportunities.

This work makes a valuable contribution to the digitalisation and automation of material testing in the district heating industry. The developed analysis tool enables a more rapid, consistent and objective evaluation of the cell structure of PUR foams than is possible with manual methods. By integrating AI technologies into quality assurance, district heating systems can be made more efficient and reliable, thereby contributing to sustainable and cost-effective heat supply.

## **DANKSAGUNG**

Mit großer Dankbarkeit blicke ich auf die Zeit der Entstehung dieser Masterarbeit zurück, die ohne die Unterstützung vieler wunderbarer Menschen nicht möglich gewesen wäre.

Mein tiefster Dank gilt Prof. Dr.-Ing. Ingo Weidlich, der mir die Gelegenheit gegeben hat, dieses spannende Projekt zu realisieren. Seine Ermutigung und sein Vertrauen haben mir stets den Rücken gestärkt.

Ein besonderer Dank gebührt Pakdad Pourbozorgi Langroudi (M.Sc.), dessen umfassende Betreuung und wertvolle Ratschläge die Qualität dieser Arbeit entscheidend geprägt haben. Seine konstruktiven Anmerkungen und seine geduldige Unterstützung waren von unschätzbarem Wert.

Von Herzen danke ich meiner Familie und meinen Freunden. Eure unerschütterliche Unterstützung, Geduld und euer Glaube an mich waren die Motivation, die ich brauchte, um diese Herausforderung zu meistern. Ohne eure Liebe und Ermutigung wäre dieser Weg nicht möglich gewesen.

Schließlich möchte ich all jenen meinen Dank aussprechen, die direkt oder indirekt zum erfolgreichen Abschluss dieser Arbeit beigetragen haben.

# INHALTSVERZEICHNIS

<b>Abbildungsverzeichnis.....</b>	<b>VI</b>
<b>1 Einleitung.....</b>	<b>1</b>
1.1 Zielsetzung .....	2
1.2 Forschungsfragen .....	3
1.3 Aufbau der Masterarbeit .....	5
<b>2 Theoretische Grundlagen.....</b>	<b>7</b>
2.1 Fernwärmenetze: Aufbau und Vorteile .....	8
2.2 Rohrsysteme in der Fernwärmeversorgung .....	10
2.3 Morphologie und Wärmeübertragungsmechanismen in Polyurethan-Hartschäumen	15
2.4 Mechanismen der Alterung von Polyurethan.....	21
2.5 Anwendung von Computer Vision in der Materialanalyse .....	27
2.6 Ansätze des maschinellen Lernens und Deep Learning zur automatisierten Bildanalyse .....	35
<b>3 Konzeption des KI-gestützten Analysetools .....</b>	<b>45</b>
3.1 Bildakquisition von Polyurethan-Hartschaumproben .....	45
3.2 Bildverarbeitung zur Analyse der Struktur von Polyurethan-Dämmstoffen .....	47
3.3 Bildanalyse mittels Deep Learning mit Detectron2 .....	62
3.4 Veröffentlichung des entwickelten Codes auf GitHub .....	70
<b>4 Ergebnisse und Diskussion.....</b>	<b>72</b>
4.1 Analyse eines repräsentativen Röntgenmikroskopiebildes der Polyurethan- Hartschaumprobe .....	72
4.2 Ergebnisse der Gesamtprobenanalyse .....	77
4.3 Validierung des Analysetools anhand synthetischer Testbilder.....	79
4.4 Kurze Darstellung der Ergebnisse der Deep-Learning-Methode.....	88

4.5	<i>Diskussion</i> .....	90
5	<b>Fazit und Ausblick</b> .....	97
6	<b>Literatur</b> .....	101

## ABBILDUNGSVERZEICHNIS

Abbildung 1: Fernwärme Systemaufbau (Konstantin & Konstantin, 2022).....	8
Abbildung 2: Prinzipielle Darstellung eine KMR-Rohrbaueinheit als Einzelrohr (links) und als Doppelrohr (rechts) (AGFW, o. D.).....	10
Abbildung 3: Struktur flexibler Rohrsysteme - CASAFLEX UNO (BRUGG Rohrsysteme o. D.) .....	11
Abbildung 4: Polymerisationsreaktion des Polyurethans (Mangs, 2005).....	13
Abbildung 5: Zellwanddicke und Anzahl der Zellwände in Abhängigkeit vom Zelldurchmesser (Choe et al., 2019).....	18
Abbildung 6: Gesamtwärmeleitfähigkeit $\lambda_{PUR}$ in Abhängigkeit vom Zelldurchmesser (Choe et al., 2019). .....	18
Abbildung 7: Alterung der Wärmeleitfähigkeit von Schaumstoffen in Abhängigkeit von Zellgröße und Zellwände (Smits, 1994). .....	27
Abbildung 8: Venn-Diagramm von AI (Künstlicher Intelligenz), Maschinellem Lernen, Deep Learning und Computer Vision (Mohimont et al., 2022). .....	29
Abbildung 9: Der Segmentierungsprozess des Watershed-Algorithmus (Zheng et al., 2021)	32
Abbildung 10: Überblick über Ansätze der maschinellen Intelligenz mit Anwendungsbeispielen (Wuttke, 2023).....	36
Abbildung 11: Convolutional Neural Network am Beispiel der Erkennung einer handschriftlichen Ziffer (Ramiah, 2021). .....	39
Abbildung 12: Übersicht über das R-CNN-System zur Objekterkennung (Girshick et al., 2013). .....	40
Abbildung 13: Röntgenmikroskop SKYSCAN 2214 CMOS (SKYSCAN 2214, o. D.) .....	46
Abbildung 14: Röntgenmikroskopische Aufnahme der PUR-Dämmstoffprobe (Eigene Darstellung).....	47
Abbildung 15: Das Originalbild mit der automatisch erkannten Kontur des Probenbereichs (Eigene Darstellung) .....	49
Abbildung 16: Das extrahierte Probenbild nach Zuschnitt (Eigene Darstellung) .....	49
Abbildung 17: Binäre Maske des PUR-Dämmstoffbildes (Eigene Darstellung) .....	50
Abbildung 18: Maske nach der Wasserscheidentransformation (Eigene Darstellung) .....	52
Abbildung 19: Wasserscheidenmaske mit eingezeichneten Konturen (Eigene Darstellung) ..	53
Abbildung 20: Originalbild mit eingezeichneten Konturen (Eigene Darstellung) .....	54

Abbildung 21: Wasserscheidenmaske mit gefilterten Konturen nach DIN 253 (Eigene Darstellung).....	55
Abbildung 22: Originalbild mit gefilterten Konturen nach DIN 253 (Eigene Darstellung)....	55
Abbildung 23: Beispiel Histogramm der Zellflächen (Eigene Darstellung) .....	57
Abbildung 24: Beispiel Histogramm der Zelldurchmesser (Eigene Darstellung) .....	58
Abbildung 25: Invertierte binäre Maske der Zellwände (Eigene Darstellung).....	59
Abbildung 26: Farbiges Distanztransformationsbild der Zellwände und Farbskala (Eigene Darstellung).....	60
Abbildung 27: Weibull-Diagramm zur statistischen Analyse der Wanddickenverteilung (Eigene Darstellung) .....	61
Abbildung 28: Beispiel für ein Originalbild (links) und die zugehörige Annotationsmaske (rechts) (Eigene Darstellung).....	64
Abbildung 29: Visualisierung eines Bildes aus dem Trainingsdatensatz mit überlagerten Annotationen (Eigene Darstellung) .....	68
Abbildung 30: Röntgenmikroskopiebild der PUR-Hartschaumprobe mit eingezeichneten Zellkonturen (Eigene Darstellung) .....	73
Abbildung 31: Screenshot der Konsole mit den berechneten Kennzahlen zur Zellstruktur....	74
Abbildung 32: Histogramme der Zellflächen und Zelldurchmesser (Eigene Darstellung) .....	74
Abbildung 33: Zellkonturen und Ergebnissen der Zellenvermessung nach DIN 253 entlang einer 10 mm langen Linie (Eigene Darstellung).....	75
Abbildung 34: Farbkodiertes Distanztransformationsbild der Zellwände (Eigene Darstellung) .....	76
Abbildung 35: Weibull-Verteilungsdiagramm der Zellwanddicken (Eigene Darstellung).....	77
Abbildung 36: Histogramm der Zelldurchmesser aller Röntgenmikroskopiebilder (Eigene Darstellung).....	78
Abbildung 37: Weibull-Verteilung der Zellwanddicken für die gesamte Probe (Eigene Darstellung).....	79
Abbildung 38: Synthetisches Testbild mit 100 Zellen (Eigene Darstellung) .....	81
Abbildung 39: Ergebnisse der Bildverarbeitung des ersten Testbildes mit eingezeichneten Konturen (Eigene Darstellung).....	82
Abbildung 40: Synthetisches Testbild mit 12 Zellen unterschiedlicher Durchmesser (Eigene Darstellung).....	83
Abbildung 41: Ergebnisse der Bildverarbeitung des zweiten Testbildes mit eingezeichneten Konturen (Eigene Darstellung).....	84

Abbildung 42: Testbild zur Validierung der Distanztransformation (Eigene Darstellung).....	86
Abbildung 43: Farbkodiertes Distanztransformationsbild zur Visualisierung der Zellwanddicken mit zugehöriger Skala (Eigene Darstellung).....	87
Abbildung 44: Verlauf des Total Loss über die Iterationen während des Trainings des Deep-Learning-Modells mit Detectron2 (Eigene Darstellung).....	88
Abbildung 45: Beispielbild mit Instanzvorhersagen aus der Deep-Learning-Segmentierung (Eigene Darstellung).....	89
Abbildung 46: Ergebnis der Zellsegmentierung mit Detectron2 (Eigene Darstellung) .....	93
Abbildung 47: Ergebnis der Zellsegmentierung mit klassischer Bildverarbeitungsmethode (Eigene Darstellung).....	94

# 1 EINLEITUNG

Die effiziente Nutzung von Fernwärmenetzen stellt einen zentralen Aspekt einer nachhaltigen Stadtentwicklung dar. Im Jahr 2023 wurden in Deutschland 15,1 % der Wohnungen mit Fernwärme beheizt. Dies stellt einen Anstieg von 13,9 % im Jahr 2019 dar, was die wachsende Bedeutung dieser Technologie verdeutlicht (BDEW, 2023). Fernwärme ist ein entscheidender Bestandteil der Wärmewende, da sie maßgeblich zur Reduktion von Treibhausgasemissionen beiträgt und die Integration erneuerbarer Energien erleichtert (Rezaie & Rosen, 2012). Das von der Bundesrepublik Deutschland formulierte Ziel, bis 2030 mindestens 50 Prozent der Fernwärme klimaneutral zu erzeugen und bis 2045 vollständige Klimaneutralität zu erreichen, verdeutlicht die Dringlichkeit, effiziente und nachhaltige Lösungen in diesem Bereich zu entwickeln (AGFW, 2023).

Ein wesentlicher Bestandteil von Fernwärmenetzen sind die Fernwärmeleitungsrohre, welche das heiße Wasser oder den Dampf transportieren und somit die Energieversorgung sicherstellen. Die Isolierung spielt dabei eine entscheidende Rolle bei der Minimierung von Wärmeverlusten. Polyurethan-Hartschaum (PUR) hat sich als weit verbreitetes Isoliermaterial für Fernwärmeleitungsrohre etabliert (Weidlich, 2016). Die Zellmorphologie des PUR-Schaums, insbesondere die Zellgröße und die Zellwanddicke, hat einen entscheidenden Einfluss auf die thermischen Eigenschaften und die Alterung der Wärmeleitfähigkeit des Schaums und damit auf die langfristige Wirksamkeit und Stabilität der Isolierung (Smits, 1994).

Die Qualitätsprüfung von Polyurethan-Hartschaum, einschließlich der Analyse der Zellgrößen, ist in der DIN EN 253 normiert. Die konventionelle manuelle Prüfung der Zellstruktur gemäß dieser Norm erweist sich jedoch in der Praxis oft als zeitintensiv, aufwendig und fehleranfällig. Aufgrund der Komplexität und des Umfangs der Proben wird bei der manuellen Prüfung häufig nur ein Teil der Probe analysiert, was die Repräsentativität der Ergebnisse einschränken kann.

In diesem Kontext bieten die fortschreitende Digitalisierung und die Implementierung von KI-Technologien großes Potenzial, insbesondere zur Verbesserung der Effizienz und Genauigkeit der Qualitätsprüfung in der Fernwärmebranche. Sie bergen das Potenzial, die Effizienz der Netzsteuerung zu optimieren und innovative Lösungen für die Materialprüfung und Zustandsbewertung zu generieren. Die Integration von KI-Technologien, insbesondere im Bereich der Bildverarbeitung (Computer Vision) und des maschinellen Lernens (Deep

Learning), in die Materialprüfung von Fernwärmeisolierungen stellt einen innovativen Ansatz dar, der eine signifikante Steigerung der Effizienz und Nachhaltigkeit von Fernwärmenetzen erwarten lässt.

Die vorliegende Masterarbeit befasst sich mit dem Einsatz moderner KI-Technologien zur automatisierten Materialprüfung und Zellcharakterisierung von PUR-Hartschaum. Ein KI-gestütztes Analysetool verspricht, die Nachteile der manuellen Prüfung zu überwinden, indem es die Zellstruktur automatisch erkennt und analysiert. Dieser Ansatz ermöglicht eine erhebliche Steigerung der Effizienz und Genauigkeit der Qualitätsprüfung, indem größere Datenmengen zuverlässig verarbeitet und eine konsistente sowie schnellere Bewertung der Materialqualität sichergestellt werden kann. Darüber hinaus können durch den Einsatz von KI-Technologien Herausforderungen wie Zeitaufwand, Fehleranfälligkeit und Subjektivität überwunden werden, wodurch kürzere Prüfzeiten und eine höhere Genauigkeit der Analyse erreicht werden. Zukünftige Entwicklungen könnten die Anwendung von KI auf weitere Materialarten und die Integration neuer Datenquellen umfassen, um die Zustandsbewertung noch präziser zu gestalten. Diese Entwicklung steht im Einklang mit dem globalen Trend zur Digitalisierung und Automatisierung industrieller Prozesse und verspricht, einen wesentlichen Beitrag zur Optimierung der Energieinfrastruktur zu leisten.

## **1.1 Zielsetzung**

Ziel dieser Arbeit ist die Entwicklung eines KI-basierten Bildverarbeitungstools zur automatisierten Zellanalyse von PUR-Proben. Dieses Tool soll insbesondere für die Qualitätsprüfung von Fernwärmeisoliermaterialien eingesetzt werden. Durch die Integration moderner Computer-Vision-Methoden, wie der Wasserscheidentransformation und Konturenerkennung, sowie maschineller Lernverfahren, soll die Genauigkeit und Effizienz der Zellcharakterisierung erheblich gesteigert werden.

Im Rahmen dieser Arbeit sollen mehrere spezifische Ziele verfolgt werden. Zunächst werden Zellgrößen und Zellwanddicken von PUR-Hartschaum sowie deren Auswirkungen auf die Materialeigenschaften analysiert. Darauf aufbauend wird ein Algorithmus zur Bildverarbeitung entwickelt, der klassische Verfahren wie die Schwellenwertbildung, die Wasserscheidentransformation und die Konturenerkennung einsetzt. Diese Verfahren werden verwendet, um die Zellstrukturen in hochauflösenden Röntgenmikroskopiebildern der Polyurethan-Hartschaumproben zu segmentieren und zu vermessen.

Zusätzlich wird das Potenzial von Deep-Learning-Ansätzen untersucht, insbesondere unter Verwendung des Detectron2-Frameworks. Dieses wurde aufgrund seiner hohen Genauigkeit und Flexibilität bei der Erkennung komplexer Strukturen gewählt, was besonders zur Effizienzsteigerung bei der Bildverarbeitung beitragen soll. Ziel ist es, zu evaluieren, wie Deep-Learning-Methoden wie Detectron2 sowohl zur Analyse als auch zur Optimierung der Effizienz und Genauigkeit der Bildverarbeitung eingesetzt werden können. Deep Learning ermöglicht die Echtzeitanalyse von Bildern, die effiziente Verarbeitung großer Datenmengen sowie die Erkennung komplexer Strukturen mit hoher Genauigkeit. Ein weiterer Fokus liegt auf der Validierung des entwickelten Analysetools. Das Tool wurde sowohl auf synthetische als auch auf reale Proben angewendet, um die Genauigkeit und Robustheit des Systems zu testen. Um typische Herausforderungen wie geringe Kontrastunterschiede und überlappende Zellstrukturen zu simulieren, wurden gezielt synthetische Testbilder erstellt, die die Robustheit des Tools unter schwierigen Bedingungen bewerten sollten. Die Ergebnisse der Validierung zeigten, dass das Tool präzise Zellendurchmesser und Zellwanddicken bestimmen kann, was seine Eignung für den Einsatz auf reale Proben unterstreicht. Dabei werden die Ergebnisse im Kontext der Materialqualität bewertet, insbesondere im Hinblick auf die Anforderungen der DIN EN 253.

Die Arbeit zielt darauf ab, die Digitalisierung und Automatisierung der Qualitätskontrolle in der Fernwärmeindustrie durch den Einsatz von KI-basierten Bildverarbeitungsalgorithmen und Deep-Learning-Methoden voranzutreiben, um die Effizienz der Prüfverfahren zu erhöhen und die Konsistenz der Ergebnisse zu sichern. Diese Technologien sollen eine schnellere und genauere Analyse der Zellstruktur von Isolationsmaterialien ermöglichen und dadurch die Effizienz und Genauigkeit der Qualitätsprüfung erheblich steigern. Das entwickelte Tool soll nicht nur die Effizienz der Prüfverfahren steigern, sondern auch eine Grundlage für zukünftige Forschungsarbeiten im Bereich der KI-gestützten Materialanalyse bieten, indem es als Plattform für die Weiterentwicklung von Algorithmen und die Anpassung an verschiedene Materialarten dient. Dies könnte Forschern ermöglichen, neue Analysemethoden zu testen und die Einsatzmöglichkeiten von KI-Technologien in der Materialwissenschaft weiter auszubauen.

## **1.2 Forschungsfragen**

Im Rahmen dieser Masterarbeit werden folgende Forschungsfragen untersucht:

**Hauptforschungsfrage:**

- Inwieweit kann ein KI-gestütztes Analysetool auf Basis von Computer Vision die automatische Erkennung und Vermessung von Zellen in PUR-Hartschaumproben für die Qualitätsprüfung von Fernwärmedämmstoffen effektiver und effizienter gestalten?

**Untergeordnete Forschungsfragen:**

- Welche Computer-Vision- und Machine-Learning-Methoden eignen sich am besten zur Erkennung und Bemessung von Zellen in PUR-Hartschaumproben?
- Inwieweit können automatisierte Messverfahren die manuelle Inspektion von PUR-Hartschaumstoffproben ersetzen und welche Herausforderungen sind damit verbunden?
- Welche Einflussfaktoren wirken sich auf die Genauigkeit und Robustheit des KI-Modells aus?
- Wie wirkt sich die Zellstruktur auf die Wärmeleitfähigkeit von PUR-Hartschaum aus?
- Wie beeinflusst die Zellstruktur die Alterungsrate von PUR-Hartschaum?

Die Hauptforschungsfrage zielt darauf ab, das Potenzial eines KI-gestützten Analysetools für die effektive und effiziente Qualitätsprüfung von Fernwärmedämmstoffen zu untersuchen. Durch die Anwendung von Computer-Vision-Techniken soll die automatische Erkennung und Vermessung von Zellen in PUR-Hartschaumproben ermöglicht werden. Diese Fragestellung bildet den Kern der Arbeit und dient als Leitfaden für die weiteren Untersuchungen.

Die untergeordneten Forschungsfragen dienen dazu, spezifische Aspekte des Hauptthemas näher zu beleuchten. Zunächst soll ermittelt werden, welche Computer-Vision- und Machine-Learning-Methoden sich am besten für die Erkennung und Bemessung von Zellen in PUR-Hartschaumproben eignen. Hierbei gilt es, verschiedene Ansätze zu evaluieren und deren Vor- und Nachteile abzuwägen.

Ein weiterer Schwerpunkt liegt auf der Untersuchung, inwieweit automatisierte Messverfahren die manuelle Inspektion von PUR-Hartschaumstoffproben ersetzen können und welche Herausforderungen damit verbunden sind. Diese Fragestellung zielt darauf ab, die Grenzen und Möglichkeiten der Automatisierung in diesem Anwendungsbereich zu erforschen.

Darüber hinaus sollen die Einflussfaktoren identifiziert werden, die sich auf die Genauigkeit und Robustheit des KI-Modells auswirken. Durch ein tieferes Verständnis dieser Faktoren können potenzielle Schwachstellen erkannt und Optimierungsansätze abgeleitet werden. Schließlich sollen die Auswirkungen der Zellstruktur auf die Wärmeleitfähigkeit und die Alterungsrate von PUR-Hartschaum untersucht werden.

### **1.3 Aufbau der Masterarbeit**

Die vorliegende Masterarbeit ist in fünf Kapitel gegliedert, welche den Prozess von den theoretischen Grundlagen bis hin zur praktischen Umsetzung und Evaluierung des KI-gestützten Analysetools abbilden.

Das zweite Kapitel widmet sich den theoretischen Grundlagen und gibt einen Überblick über die für das Verständnis der Arbeit relevanten Themengebiete. Zunächst werden der Aufbau und die Vorteile von Fernwärmenetzen erläutert. Im Anschluss erfolgt eine detaillierte Betrachtung der in der Fernwärmeversorgung eingesetzten Rohrsysteme, wobei ein besonderes Augenmerk auf dem Kunststoffmantelrohr (KMR) und dessen Isolierung aus Polyurethan-Hartschaum (PUR) liegt. Die Eigenschaften und Herstellungsverfahren von PUR werden einer vertieften Betrachtung unterzogen. Darüber hinaus werden die Grundlagen der Computer Vision, des maschinellen Lernens und Deep Learnings eingeführt und ihre Anwendungsmöglichkeiten in der Materialwissenschaft diskutiert.

In Kapitel 3 wird die Konzeption und Entwicklung des KI-gestützten Analysetools beschrieben. Ausgehend von der Bildakquisition mittels 3D-Röntgenmikroskopie werden die einzelnen Schritte der Bildverarbeitung zur Charakterisierung der PUR-Dämmstoffstruktur erläutert. Dies umfasst Techniken wie Hintergrundentfernung, Binarisierung, Wasserscheidentransformation und Konturenerkennung. Im Anschluss erfolgt die Beschreibung der Implementierung des Deep-Learning-Ansatzes mit Detectron2, wobei die Schritte Datenvorverarbeitung, Modellanpassung und -training erläutert werden.

In Kapitel 4 werden die Ergebnisse der Arbeit präsentiert und diskutiert. Zunächst erfolgt eine Auswertung der Leistungsfähigkeit des entwickelten Analysetools anhand von Testdaten. Die erzielten Segmentierungsergebnisse werden sowohl qualitativ als auch quantitativ bewertet und mit den Anforderungen aus Normen und Richtlinien abgeglichen. Im Anschluss werden die Vor- und Nachteile des gewählten Ansatzes erörtert und mögliche Optimierungspotenziale aufgezeigt.

Kapitel 5 dient der Zusammenfassung der wesentlichen Erkenntnisse der Arbeit sowie der Darstellung möglicher zukünftiger Forschungs- und Anwendungsfelder. Es wird erörtert, inwiefern das entwickelte KI-gestützte Analysetool zur Optimierung der Qualitätssicherung von PUR-Dämmstoffen in der Fernwärmeversorgung beitragen kann. Des Weiteren werden Potenziale für die Übertragung des Ansatzes auf andere Materialklassen und Anwendungsgebiete aufgezeigt.

## 2 THEORETISCHE GRUNDLAGEN

Die Entwicklung eines KI-basierten Bildverarbeitungstools zur automatisierten Erkennung und Vermessung von Zellen in PUR-Hartschaumproben für die Qualitätsprüfung von Fernwärmeisoliermaterialien erfordert ein fundiertes Verständnis sowohl der Eigenschaften und Anforderungen an diese Materialien als auch der Möglichkeiten und Methoden der Künstlichen Intelligenz (KI). In diesem Kapitel werden die theoretischen Grundlagen in beiden Bereichen näher beleuchtet.

Zunächst wird ein Überblick über die grundlegenden Prinzipien der Fernwärmetechnik gegeben. Dies umfasst sowohl den Aufbau von Fernwärmesystemen als auch die eingesetzten Materialien und Technologien. Ein besonderer Schwerpunkt liegt dabei auf den Polyurethan-Hartschäumen (PUR), die aufgrund ihrer hervorragenden thermischen Eigenschaften eine wichtige Rolle in der Isolierung von Fernwärmenetzen spielen (Weidlich, 2016).

Ein besonderer Fokus dieses Kapitels liegt auf der Morphologie von Polyurethan-Hartschäumen und ihrem Einfluss auf die Wärmeübertragung. Die Zellstruktur, Zellgröße und Zellwanddicke sind entscheidende Faktoren, die die thermischen Eigenschaften dieser Materialien bestimmen (Choe et al., 2019). Darüber hinaus werden die Herstellungsverfahren von Kunststoffmantelrohren erläutert, um ein umfassendes Verständnis der Produktionsprozesse zu vermitteln.

Ein zentraler Aspekt dieses Kapitels ist die Untersuchung der Alterungsmechanismen von PUR-Hartschäumen, darunter oxidative Degradation, Hydrolyse und Gasdiffusion. Diese Prozesse führen zu einer allmählichen Verschlechterung der mechanischen Festigkeit und thermischen Isolierfähigkeit (Gietzelt et al., 2006). Das Verständnis dieser Alterungsvorgänge ist entscheidend, um Maßnahmen zur Erhöhung der Lebensdauer von PUR-Hartschäumen zu entwickeln und ihre Zuverlässigkeit in Fernwärmesystemen zu gewährleisten.

Abschließend wird die Anwendung von Computer-Vision-Methoden in der Materialanalyse diskutiert. Moderne Technologien der Künstlichen Intelligenz und des maschinellen Lernens eröffnen neue Möglichkeiten zur automatisierten Charakterisierung der Mikrostruktur von Materialien (Cheng et al., 2021). Diese Ansätze tragen dazu bei, die Qualitätssicherung in der Produktion zu optimieren und die Effizienz von Fernwärmesystemen weiter zu steigern.

Die in diesem Kapitel behandelten theoretischen Grundlagen bilden somit die Basis für die weiterführenden Untersuchungen dieser Arbeit. Sie ermöglichen ein umfassendes Verständnis der technischen und wissenschaftlichen Aspekte, die für die Optimierung von Fernwärmenetzen und deren Komponenten von entscheidender Bedeutung sind.

## 2.1 Fernwärmenetze: Aufbau und Vorteile

Ein Fernwärmenetz besteht aus einer Reihe von Hauptkomponenten, die in ihrer Gesamtheit ein effizientes und zuverlässiges System zur Verteilung von Wärmeenergie bilden. Zu den wichtigsten Bestandteilen zählen Heizkraftwerke, Rohrleitungen, Wärmeübergabestationen und Hausanschlussstationen (Konstantin & Konstantin, 2022). Der prinzipielle Aufbau einer Fernwärmeversorgung ist in Abbildung 1 dargestellt.

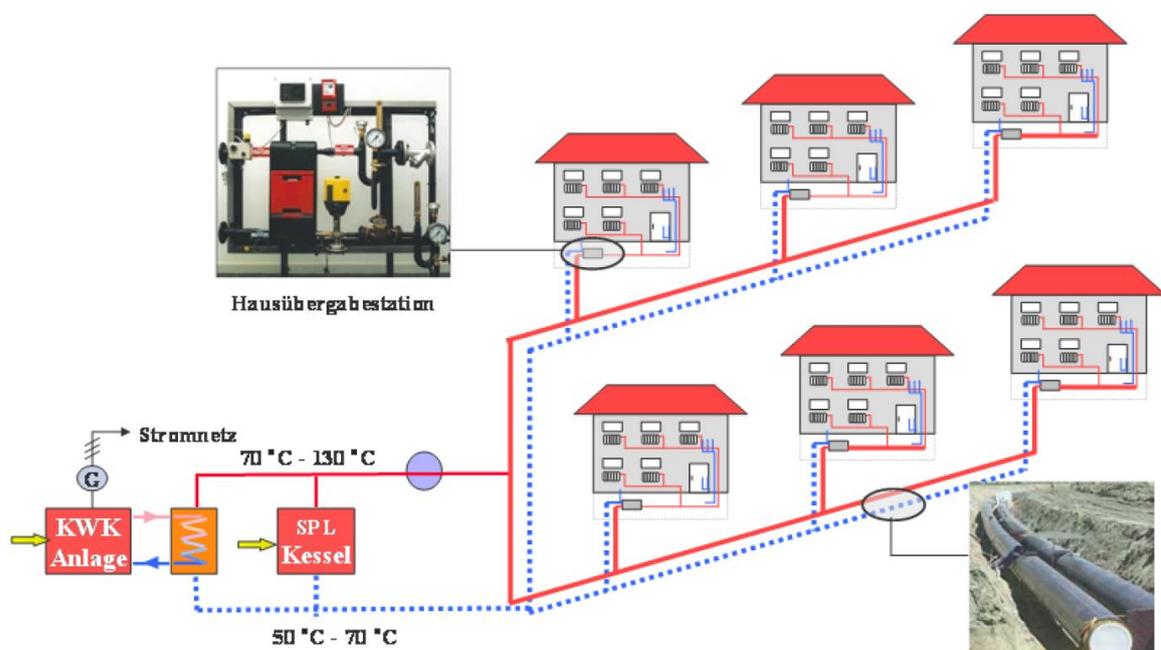


Abbildung 1: Fernwärme Systemaufbau (Konstantin & Konstantin, 2022)

Das Herzstück eines Fernwärmenetzes stellt das Heizkraftwerk dar, in welchem die Wärme erzeugt wird. Die Erzeugung der Wärme kann mittels fossiler Brennstoffe wie Kohle oder Gas oder mittels erneuerbarer Energien wie Holz, Biogas oder Solarenergie erfolgen. Die Kraft-Wärme-Kopplung ermöglicht die Produktion von Wärme und Strom in einem Prozess. Dies führt zu einer Erhöhung des Gesamtwirkungsgrads und einer Einsparung von Primärenergie (Konstantin & Konstantin, 2022).

Die erzeugte Wärme wird über ein Rohrleitungssystem, das Fernwärmenetz, zu den Verbrauchern transportiert. Die Rohrleitungen können ober- oder unterirdisch verlegt

werden und bestehen häufig aus Kunststoffmantelrohren. Als Wärmeträgermedium wird in der Regel Wasser mit Vorlauftemperaturen zwischen 70 °C und 130 °C verwendet. An den Verbrauchsstellen wird die Wärme in Hausanschlussstationen oder Übergabestationen auf die internen Heizungs- und Warmwassersysteme der Gebäude übertragen (Konstantin & Konstantin, 2022).

Fernwärmenetze bieten gegenüber dezentralen Heizsystemen mehrere Vorteile, darunter eine höhere Energieeffizienz, geringere Treibhausgasemissionen, flexible Nutzung von Wärmequellen sowie eine verbesserte lokale Luftqualität. Einer der wichtigsten Vorteile ist der erhöhte Gesamtwirkungsgrad, der durch die Nutzung hocheffizienter Kraft-Wärme-Kopplungsanlagen (KWK) erreicht wird. In diesen Anlagen wird sowohl Strom als auch Wärme erzeugt, was zu einer Verringerung des Primärenergiebedarfs und der Treibhausgasemissionen im Vergleich zu getrennter Strom- und Wärmeerzeugung führt (Rezaie & Rosen, 2012).

Ein weiterer Vorteil von Fernwärmenetzen ist die Flexibilität bei der Wahl der Wärmequellen. Sie können verschiedene Erzeugungsanlagen und Energieträger integrieren, darunter auch erneuerbare Energien wie Biomasse, Geothermie oder Solarthermie (R. S. Lund et al., 2017). Dadurch kann der Anteil fossiler Brennstoffe reduziert und die Versorgungssicherheit erhöht werden.

Fernwärmenetze tragen auch zur Verbesserung der lokalen Luftqualität bei, da die Verbrennung in zentralen Anlagen mit modernen Filtertechnologien erfolgt und somit weniger Schadstoffe emittiert werden als bei individuellen Heizkesseln (Persson & Werner, 2011). Zudem entfällt durch die zentrale Wärmeerzeugung der Bedarf an individuellen Heizkesseln in den versorgten Gebäuden, was Platz spart und den Wartungsaufwand für die Endverbraucher reduziert.

Ein zusätzlicher Vorteil von Fernwärmenetzen ist die Möglichkeit, Abwärme aus industriellen Prozessen oder Abfallverbrennungsanlagen zu nutzen, die sonst ungenutzt bleiben würde (H. Lund et al., 2014). Dadurch wird die Energieeffizienz gesteigert und der Primärenergiebedarf gesenkt.

Insgesamt bieten Fernwärmenetze durch ihre hohe Effizienz, Flexibilität bei der Wahl der Wärmequellen, Verbesserung der lokalen Luftqualität, Platzersparnis und Möglichkeit der Abwärmennutzung bedeutende Vorteile gegenüber dezentralen Heizsystemen und leisten einen wichtigen Beitrag zu einer nachhaltigen Wärmeversorgung.

## 2.2 Rohrsysteme in der Fernwärmeversorgung

In der Fernwärmeversorgung werden unterschiedliche Rohrsysteme verwendet, die sich in Konstruktion, Wärmedämmung und Verlegeart unterscheiden. Die Wahl des Rohrsystems hängt von Anforderungen wie Verlegeart, Betriebsparametern und Umgebungsbedingungen ab.

Kunststoffverbundrohre (KMR) sind das am häufigsten verwendete Rohrsystem in der Fernwärmeversorgung. Sie bestehen aus einem Stahlmediumrohr, einer Polyurethan-Hartschaumdämmung (PUR) und einem Mantelrohr aus hochverdichtetem Polyethylen (HDPE). Die Materialien sind kraftschlüssig verbunden, wodurch die Wärmedehnung auf das gesamte Rohrsystem übertragen wird. KMR können Dauerbetriebstemperaturen bis 140 °C und Drücke bis 25 bar sicher handhaben (Weidlich, 2016).

KMR sind als Einzel- und Doppelrohre erhältlich. Einzelrohre bestehen aus einem Mediumrohr, einer Wärmedämmung und einem Außenmantel, während Doppelrohre Vor- und Rücklauf in einem Rohr vereinen. Doppelrohrsysteme bieten gegenüber Einzelrohrsystemen Vorteile wie geringere Verlegekosten, niedrigere spezifische Wärmeverluste, eine halbierte Anzahl an Muffenverbindungen und Kernbohrungen sowie eine geringere Anzahl an Dehnschenkeln (Weidlich, 2016). Der prinzipielle Aufbau von KMR-Ein- und KMR-Doppelrohren ist in Abbildung 2 dargestellt.

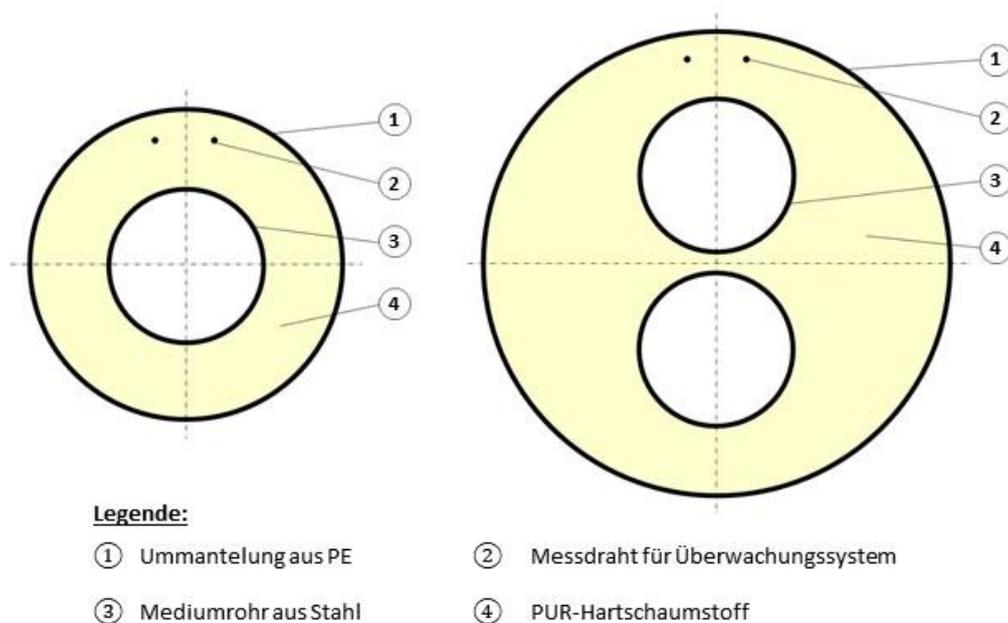


Abbildung 2: Prinzipielle Darstellung eine KMR-Rohrbaueinheit als Einzelrohr (links) und als Doppelrohr (rechts) (AGFW, o. D.).

Neben den starren KMR-Systemen gewinnen flexible Rohrsysteme zunehmend an Bedeutung. Flexible Rohrsysteme ähneln dem konstruktiven Aufbau von KMR, unterscheiden sich jedoch durch ihre höhere Flexibilität und Anpassungsfähigkeit. Sie bestehen aus einem dünnwandigen, gewellten Edelstahlrohr als Mediumrohr, umgeben von einer PUR-Schaumdämmung und einem PE-HD-Außenmantel (siehe Abbildung 3). Die Wellrohrstruktur ermöglicht eine Verlegung der Rohre auch bei sehr geringen Biegeradien, ohne dass es zu Beschädigungen oder Einschränkungen der Wärmedämmung kommt, was die Installation in engen Räumen erheblich erleichtert. Die Verlegung kann mit geringem Aufwand erfolgen, wobei die Abmessungen und die Umgebungstemperaturen zu berücksichtigen sind, um die langfristige Funktionsfähigkeit sicherzustellen. Flexible Rohrsysteme mit glatten Stahlrohren werden als Ein- und Doppelrohre bis zu DN 25 angeboten und dienen der Herstellung eines Anschlusses der zu versorgenden Gebäude mit dem Verteilnetz. Diese Systeme sind besonders nützlich für den Anschluss kleinerer Verbraucher, da sie eine schnelle und einfache Installation ermöglichen. Die zulässigen Betriebstemperaturen entsprechen denen des Verlegesystems KMR, was ihre Vielseitigkeit im Einsatz weiter erhöht (AGFW, o. D.).

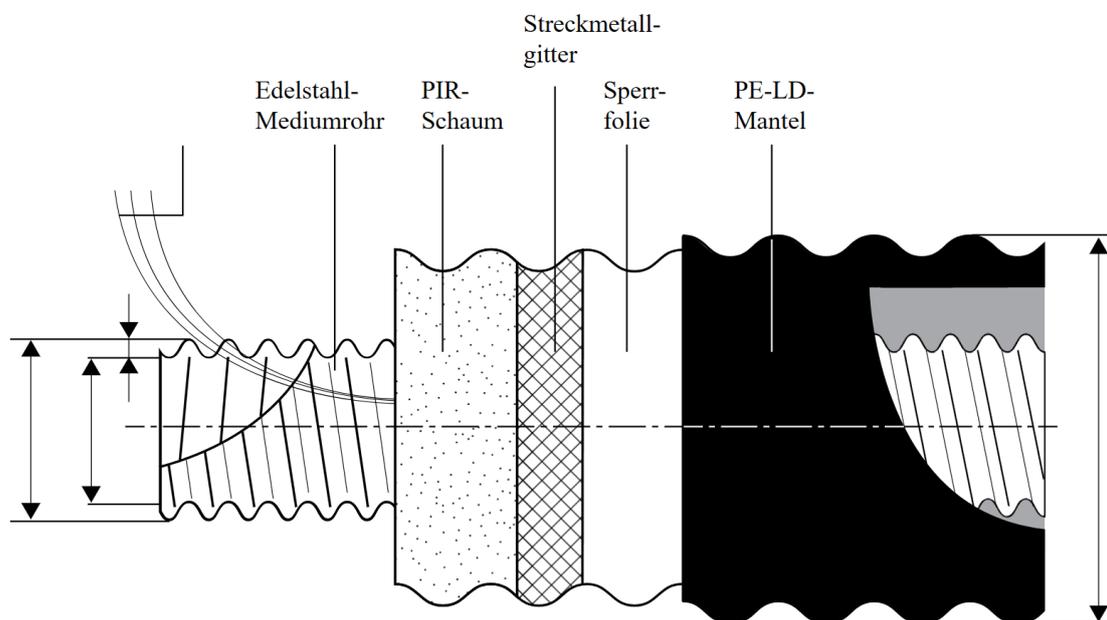


Abbildung 3: Struktur flexibler Rohrsysteme - CASAFLEX UNO (BRUGG Rohrsysteme o. D.)

Weitere Rohrsysteme, die in der Fernwärmeversorgung zum Einsatz kommen, sind unter anderem Kunststoffmediumrohre (PMR), Metallmediumrohre (MMR) und Stahlmantelrohre (SMR). Diese Rohrsysteme finden jedoch im Vergleich zu KMR und

flexiblen Rohrsystemen eine geringere Verbreitung und werden hauptsächlich in speziellen Anwendungsfällen eingesetzt (Weidlich, 2016).

### **2.2.1 Eigenschaften und Herstellung von Polyurethan-Hartschaum**

Die sorgfältige Isolierung von Fernwärmerohren stellt einen entscheidenden Faktor zur Minimierung von Wärmeverlusten und Gewährleistung einer effizienten Energieübertragung dar. Bereits im Jahr 1978 wurden in Deutschland erstmals gesetzliche Vorschriften zur Wärmedämmung von Rohrleitungen bei Heizungsanlagen erlassen, um Energie einzusparen (Zehendner, 2001).

Polyurethan-Hartschaum (PUR) ist eines der am häufigsten verwendeten Isoliermaterialien in Fernwärmesystemen. Die Wärmeleitfähigkeit von PUR-Schäumen liegt typischerweise zwischen  $\lambda_D=0,020 \text{ W/(m}\cdot\text{K)}$  und  $\lambda_D=0,035 \text{ W/(m}\cdot\text{K)}$ , wobei diese Werte je nach Temperatur und Feuchtigkeit variieren können (Weidlich, 2016).

PUR-Schäume sind schwer entflammbar bis nicht brennbar (B1/B2 bis A2 gemäß DIN 4102-1) und können in einem Temperaturbereich von  $-200 \text{ }^\circ\text{C}$  bis etwa  $+110 \text{ }^\circ\text{C}$  bis  $+130 \text{ }^\circ\text{C}$  eingesetzt werden, abhängig vom Hersteller. Die zulässige Flächenpressung beträgt etwa  $0,6$  bis  $0,8 \text{ N/mm}^2$  bei  $10 \%$  Stauchung, und die Dämmstoffmasse liegt bei etwa  $35$  bis  $40 \text{ kg/m}^3$  (Weidlich, 2016).

Die Produktion von Polyurethan-Schaum (PUR-Schaum) basiert auf der Reaktion von drei essenziellen Komponenten: Polyol, Isocyanat und Treibmittel. Das Treibmittel wird üblicherweise zusammen mit Additiven wie Aktivatoren und Schaumstabilisatoren dem Polyol beigemischt. Die chemische Reaktion zwischen dem Polyol und dem Polyisocyanat führt zu einem vernetzten Material mit charakteristischen Urethanstrukturen. Diese Urethanbindungen entstehen durch die Reaktion der funktionellen Gruppen der beiden Komponenten und verleihen dem Material seine Stabilität und Widerstandsfähigkeit (Randall & Lee, 2002). Für die Herstellung von PUR-Schaum werden Polyole mit einer Funktionalität von mehr als drei verwendet, wobei Funktionalität die Anzahl der reaktiven Gruppen bezeichnet, die zur Vernetzung beitragen und eine ausreichende Stabilität gewährleisten. Zusätzlich können weitere Komponenten wie Katalysatoren, physikalische Treibmittel und/oder chemische Treibmittel eingesetzt werden, um die gewünschten Eigenschaften des Endprodukts zu erzielen (Ionescu, 2016). Die grundlegende Urethanreaktion lässt sich in Abbildung 4 veranschaulichen.

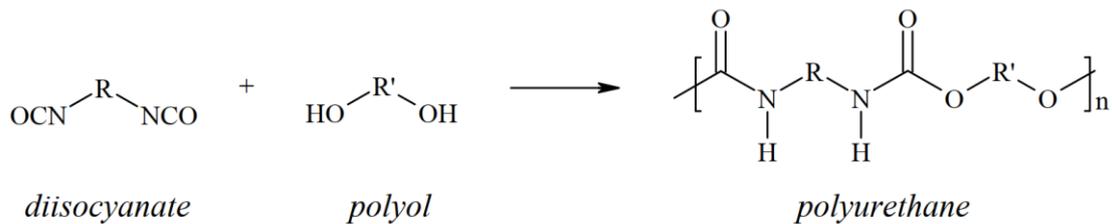


Abbildung 4: Polymerisationsreaktion des Polyurethans (Mangs, 2005)

Polyurethanschäume (PUR) zeichnen sich durch ihre Anpassungsfähigkeit an spezifische Anforderungen aus. Diese Anpassungsfähigkeit wird durch die Integration verschiedener chemischer Gruppen wie Ester, Ether oder aromatische Ringe sowie durch die Reaktion von Isocyanaten mit Polyolen in Gegenwart von Aktivatoren erreicht. Diese Reaktionen sind typischerweise exotherm und erreichen Temperaturen bis zu 160 °C. Dabei verdampfen physikalische Treibmittel und werden in den Schaumzellen eingeschlossen, was zu einer effektiven Isolierung führt (Szycher, 2012). Historisch wurden Fluorchlorkohlenwasserstoffe (FCKW) als Treibmittel verwendet, welche jedoch aufgrund ihrer ozonabbauenden Wirkung verboten wurden. Als Ersatz wurden wassergetriebene Systeme entwickelt, welche Kohlendioxid produzieren und somit als umweltfreundlicher gelten (Singh, 2002).

In der Gegenwart werden zwei Haupttechnologien zur Herstellung von Polyurethanschaum verwendet: wassergeblasene Systeme und Cyclopentan/Wasser-Doppelblasensysteme. Bei wassergeblasenen Systemen erfolgt die Reaktion von Wasser mit Isocyanat, was zu einer höheren Wärmeleitfähigkeit aufgrund der schnellen Diffusion von CO<sub>2</sub> aus der Zellstruktur führt. Im Gegensatz dazu kombinieren Cyclopentan-basierte Systeme eine geringere Wärmeleitfähigkeit mit einer besseren Umweltverträglichkeit, wobei jedoch die Brennbarkeit von Cyclopentan eine sorgfältige Handhabung erfordert (Kellner & Shen, 2000). Der gesamte Prozess zur Herstellung von Polyurethanschaum ist komplex und erfordert eine präzise Kontrolle zahlreicher Variablen, um optimale Zellgrößen und -ausrichtungen zu erreichen, die die gewünschten Schaumeigenschaften bestimmen.

### 2.2.2 Herstellung von Kunststoffmantelrohren

Bei der Produktion von Kunststoffmantelrohren (KMR) für Fernwärmenetze kommen zwei grundlegende Verfahren zum Einsatz: das diskontinuierliche und das kontinuierliche Verfahren. Im diskontinuierlichen Verfahren wird zunächst das Stahlmediumrohr mithilfe von Abstandshaltern im Mantelrohr zentriert. An den Rohrenden erfolgt die Abdichtung des Ringraums zwischen Mediumrohr und Mantelrohr durch Endkappen. Anschließend werden

die Schaumkomponenten in den Ringraum injiziert, wo sie reagieren und den Hohlraum zwischen den beiden Rohren ausfüllen. Es existieren diverse Methoden zur Befüllung des Hohlraums, darunter die Pour-and-Rise-Technik, die Top-Filling-Technik, die Mid-Point-Filling-Technik, die Lance-withdrawal-Technik sowie die Pull-Through-Technik. Die ersten drei Methoden weisen eine hohe Ähnlichkeit auf, wobei primär der Einfüllpunkt des Schaummaterials differiert. Von essentieller Bedeutung ist die Steuerung der Befüllungszeit, um sicherzustellen, dass das Rohr vollständig gefüllt ist, bevor das System die Faserzeit erreicht und folglich die Bildung länglicher Schaumzellen unterbunden wird (Kellner & Shen, 2000).

Die Lance withdrawal-Technik und Pull-Through-Technik kombinieren diskontinuierliche Produktion mit kontinuierlichem Schaumauftrag. Hierbei werden die Schaumkomponenten direkt aufgebracht und reagieren schnell, was zu einer guten Schaumverteilung führt. Traditionell wurden KMR im diskontinuierlichen Verfahren hergestellt, das sich durch geringe Kosten und geringen Arbeitsaufwand für verschiedene Rohrdimensionen auszeichnet. Nachteilig ist jedoch die ungleichmäßige Verteilung des Schaummaterials, die zu Schwankungen in Dichte und mechanischer Festigkeit führt (Kellner & Shen, 2000).

Kontinuierliche Verfahren bestehen aus zwei Hauptstufen: Zunächst wird das Schaummaterial direkt auf das Stahlrohr aufgebracht, anschließend wird ein Mantelrohr um den Schaum extrudiert. Zwei Techniken sind hier zu unterscheiden: Beim kontinuierlichen Formverfahren wird das Schaummaterial in eine Form eingebracht, die das Stahlrohr umgibt, bevor das Mantelrohr geformt wird. Das kontinuierliche Sprühverfahren sprüht das Schaummaterial direkt auf das Stahlrohr, gefolgt von der Extrusion des Mantelrohrs. Diese Methoden ermöglichen eine gleichmäßige Schaumverteilung und effiziente Produktion gleicher Dimensionen, erfordern jedoch höhere Kosten bei Dimensionswechseln (Lefter & Popescu, 2012).

Lefter und Popescu (2012) zeigen, dass die kontinuierliche Produktionsmethode signifikante Vorteile hinsichtlich thermischer Leistungsfähigkeit und Wirtschaftlichkeit bietet. Die Kombination eines kontinuierlichen Schaumverfahrens mit einer Diffusionsbarriere gewährleistet eine konstante thermische Leitfähigkeit von  $0,023 \text{ W/m}\cdot\text{K}$ , was im Vergleich zu traditionellen Kunststoffmantelrohren (bis zu  $0,038 \text{ W/m}\cdot\text{K}$ ) eine erhebliche Verbesserung darstellt. Dies führt zu einer Reduktion der Wärmeverluste um bis zu 20,9% und einer Amortisationszeit von weniger als 10 Jahren. Zudem verbessert die gleichmäßigere Verteilung und Dichte des Schaums die mechanische Stärke und Adhäsion

zwischen Stahlrohr und HDPE-Ummantelung. Die Diffusionsbarriere verhindert effektiv den Alterungsprozess des Schaums, was die Lebensdauer der Isolierung verlängert und langfristig Betriebskosten senkt. Diese Vorteile unterstreichen die Überlegenheit der "Conti"-Rohre gegenüber traditionellen Methoden für moderne Fernwärmenetze.

### **2.3 Morphologie und Wärmeübertragungsmechanismen in Polyurethan-Hartschäumen**

Die thermischen Eigenschaften von Polyurethan-Hartschäumen (PUR) sind von grundlegender Bedeutung für ihre Verwendung als effiziente Dämmstoffe in verschiedenen Industriesektoren. Das Verständnis der Morphologie von PUR sowie der Einfluss derselben auf die Wärmeübertragungsmechanismen bildet die Grundlage für die Optimierung dieser Materialien hinsichtlich ihrer Wärmedämmeigenschaften. Die Zellstruktur, die Zellgröße sowie die Zellwanddicke sind von entscheidender Bedeutung für die Bestimmung der Wärmeleitfähigkeit und des Gesamtwärmetransports durch den Schaum (Choe et al., 2019). Im vorliegenden Kapitel erfolgt eine Untersuchung der verschiedenen Aspekte der PUR-Morphologie sowie eine Analyse ihres Zusammenhangs mit den Mechanismen der Wärmeübertragung. Des Weiteren werden die normativen Anforderungen an den Anteil geschlossener Zellen sowie die Methoden zu deren Bestimmung gemäß EN 253 und ASTM D3576 dargelegt.

#### **2.3.1 Anteil geschlossener Zellen in Polyurethan-Hartschaumstoffen**

Polyurethan-Hartschaumstoffe bestehen aus einer Vielzahl von Zellen, die entweder offen oder geschlossen sein können. Geschlossene Zellen sind vollständig von Polymerwänden umgeben und nicht mit benachbarten Zellen verbunden. Diese Struktur minimiert den Luftaustausch zwischen den Zellen und der Umgebung, was zu einer geringeren Wärmeleitfähigkeit führt (Berardi & Madzarevic, 2020).

Die DIN EN 253 fordert, dass das Verhältnis der offenen zu den geschlossenen Zellen nach EN ISO 4590 (Verfahren 1) zu bestimmen ist. Dieses Verfahren basiert auf dem Prinzip der Gasexpansion und ermöglicht die Bestimmung des geschlossenzelligen Volumenanteils in Schaumstoffen. Bei Verfahren 1 der EN ISO 4590 wird eine Schaumstoffprobe in eine Prüfkammer eingebracht und einem definierten Unterdruck ausgesetzt. Durch das Anlegen des Unterdrucks expandiert das in den geschlossenen Zellen enthaltene Gas, während die offenen Zellen keine Volumenänderung erfahren. Aus der gemessenen Volumenänderung der Probe kann dann der Anteil der geschlossenen Zellen berechnet werden.

DIN EN 253 legt fest, dass die Probekörper für die Bestimmung des Anteils geschlossener Zellen Würfel mit einer Kantenlänge von 25 mm sein müssen. Ist dies nicht möglich, können auch Probekörper mit den Maßen  $25 \text{ mm} \times 25 \text{ mm} \times t$  verwendet werden, wobei  $t$  der größtmöglichen Dicke in Radialrichtung entspricht. Das Prüfergebnis muss als Durchschnittswert aus Messungen an drei Probekörpern bestimmt werden.

Gemäß DIN EN 253: 2020-03 muss der Anteil der geschlossenen Zellen in Polyurethan-Hartschaumstoffen für Fernwärmerohre mindestens 88% betragen. Diese Anforderung gewährleistet, dass die Wärmeleitfähigkeit und die mechanische Integrität des Materials über die vorgesehene Lebensdauer der Rohrleitungssysteme erhalten bleiben. In der Praxis wird dieser Anteil durch die Auswahl der Rohstoffe, die Rezeptur und die Verarbeitungsbedingungen während der Schaumherstellung gesteuert (Gama et al., 2018). Die Einhaltung dieser Spezifikation muss durch regelmäßige Qualitätskontrollen seitens der Hersteller gewährleistet werden.

### **2.3.2 Wärmeübertragungsmechanismen in Polyurethan-Hartschäumen**

Polyurethan-Hartschäume zeichnen sich durch ihre hervorragenden Wärmedämmeigenschaften aus, die auf der komplexen Interaktion verschiedener Wärmeübertragungsmechanismen beruhen. Die Effizienz dieser Materialien als Wärmedämmung hängt von ihrer Fähigkeit ab, den Wärmetransport durch das Material zu minimieren. In Polyurethan-Hartschäumen erfolgt die Wärmeübertragung hauptsächlich durch drei Mechanismen: Wärmeleitung, Konvektion und Strahlung (Gama et al., 2018).

Die Wärmeleitung ist der dominierende Wärmeübertragungsmechanismus in Polyurethan-Hartschäumen. Sie beschreibt den Energietransport durch Molekülschwingungen und -stöße innerhalb des Materials, ohne dass ein makroskopischer Stofftransport stattfindet (Berardi & Madzarevic, 2019). In Polyurethan-Hartschäumen erfolgt die Wärmeleitung sowohl durch das Feststoffgerüst des Schaums als auch durch das in den Zellen eingeschlossene Gas. Die Wärmeleitfähigkeit des Feststoffs hängt von der chemischen Zusammensetzung und der Dichte des Schaums ab, während die Wärmeleitfähigkeit des Gases von der Art des Gases, dessen Dichte und der Zellgröße beeinflusst wird (Cunningham et al., 1988).

Konvektion spielt in Polyurethan-Hartschäumen aufgrund der geschlossenen Zellstruktur und der geringen Zellgröße eine untergeordnete Rolle. Konvektion beschreibt den Wärmetransport durch die Bewegung von Fluiden oder Gasen, angetrieben durch Dichteunterschiede infolge von Temperaturgradienten. In den kleinen, geschlossenen Zellen

von Polyurethan-Hartschäumen ist die konvektive Wärmeübertragung stark eingeschränkt, da die Zellgröße die Ausbildung von Konvektionsströmen verhindert (Gama et al., 2018).

Die Wärmestrahlung trägt ebenfalls zur Wärmeübertragung in Polyurethan-Hartschäumen bei. Wärmestrahlung ist die Emission von elektromagnetischen Wellen durch Materie aufgrund ihrer Temperatur. In Polyurethan-Hartschäumen wird die Wärmestrahlung durch Absorption, Reflexion und Streuung an den Zellwänden und -stegen beeinflusst. Die Strahlungseigenschaften des Schaums hängen von der Zellgröße, der Dichte und der Oberflächenbeschaffenheit der Zellen ab (Choe et al., 2019).

Um die Wärmedämmeigenschaften von Polyurethan-Hartschäumen zu optimieren, ist es entscheidend, die Beiträge der einzelnen Wärmeübertragungsmechanismen zu minimieren. Dies kann durch die Anpassung der Schaumstruktur, wie z. B. die Verringerung der Zellgröße, die Erhöhung der Dichte und die Verwendung von Additiven mit niedrigerer Wärmeleitfähigkeit, erreicht werden (Gietzelt et al., 2006; Smits, 1994).

### **2.3.3 Einfluss der Zellmorphologie auf die Wärmeübertragung**

Die Zellmorphologie von Polyurethan-Hartschäumen ist von entscheidender Bedeutung für deren thermische Eigenschaften und Wärmeübertragungsverhalten. Die zelluläre Struktur, Zellgröße und Zellwanddicke wirken sich maßgeblich auf die Wärmeleitfähigkeit und den Wärmetransport durch den Schaum aus (Choe et al., 2019; Smits, 1994).

Die Forschung belegt, dass die Wärmeübertragung in PUR-Schäumen hauptsächlich durch die Gase in den Zellen sowie das feste Medium erfolgt. Dabei ist der Wärmetransport durch Strahlung, der durch die Zellwände und -stegen stattfindet, von besonderer Signifikanz (Choe et al., 2019). Der Wärmetransport durch Strahlung ist eng mit dem Transport von Photonen durch die Zellwände verbunden, wobei die Morphologie der Zellen eine maßgebliche Rolle spielt.

Abbildung 5 aus der Studie von Choe et al. (2019) veranschaulicht, dass Schaumproben mit größeren Zelldurchmessern dünnere Zellwände aufweisen. Dies führt zu einer erhöhten Wärmeleitfähigkeit durch Strahlung, da dünnere Zellwände weniger effektiv bei der Absorption und Streuung von Wärmestrahlung sind. Dadurch nimmt der Gesamtwärmetransport durch den Schaum zu, was die thermische Effizienz verringert. Dies resultiert in einer geringeren Absorption und Streuung von Photonen, was eine erhöhte Wärmeleitfähigkeit durch Strahlung bei größeren Zelldurchmessern zur Folge hat. Demgegenüber weisen Proben mit kleineren Zelldurchmessern eine höhere Anzahl an

absorbierten und gestreuten Photonen auf, was zu einer geringeren Wärmeleitfähigkeit durch Strahlung führt.

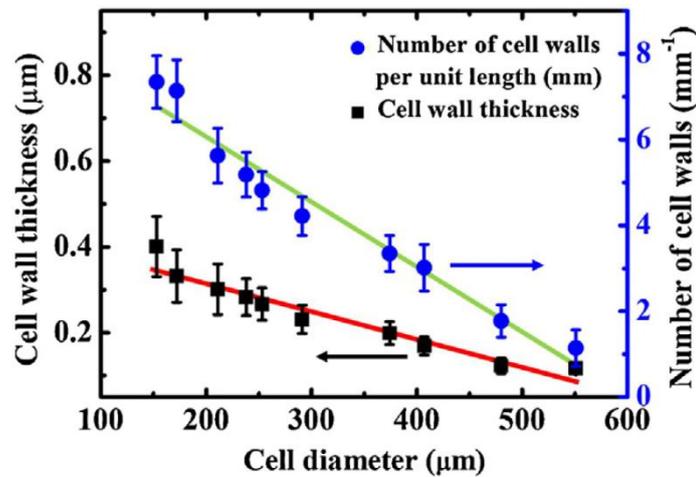


Abbildung 5: Zellwanddicke und Anzahl der Zellwände in Abhängigkeit vom Zelldurchmesser (Choe et al., 2019).

Abbildung 6 demonstriert, dass die gesamte Wärmeleitfähigkeit der Schaumproben in Abhängigkeit vom Zelldurchmesser einen klaren Schwellenwert bei etwa 230 Mikrometern aufweist. Unterhalb dieses kritischen Zelldurchmessers ist die Abhängigkeit der gesamten Wärmeleitfähigkeit vom Zelldurchmesser nahezu vernachlässigbar. Dies lässt sich durch den verstärkten relativen Effekt der Wärmeleitfähigkeit der festen Teile erklären, da die Dicke der festen Wände mit abnehmender Zellgröße unter gleichbleibendem Gasgehalt zunimmt. Oberhalb des kritischen Zelldurchmessers ist der Beitrag des radiativen Wärmetransfers zur gesamten Wärmeleitfähigkeit signifikant (Choe et al., 2019).

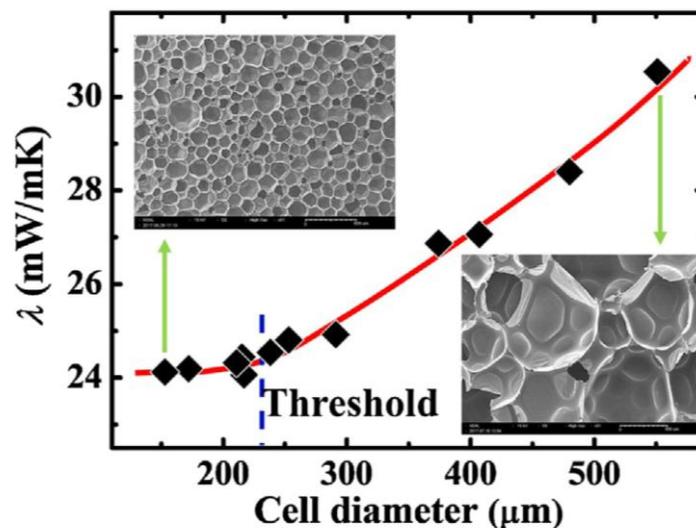


Abbildung 6: Gesamtwärmeleitfähigkeit  $\lambda_{PUR}$  in Abhängigkeit vom Zelldurchmesser (Choe et al., 2019).

Die Dicke der Zellwände beeinflusst ebenfalls die Wärmeleitfähigkeit des Schaums. Dünnere Zellwände reduzieren den Wärmetransport durch das Feststoffgerüst, erhöhen jedoch den Beitrag der Strahlungswärmeübertragung zur Gesamtwärmeleitfähigkeit. Je größer die Zelldurchmesser sind, desto höher ist die Strahlungswärmeleitfähigkeit des Schaums (Choe et al., 2019). Um die Wärmeübertragung durch Strahlung zu minimieren, ist es wichtig, den Zelldurchmesser unter einem kritischen Wert zu halten.

Die Morphologie von Polyurethan-Hartschäumen weist einen vielseitigen Einfluss auf die Wärmeübertragung auf. Eine optimierte Zellstruktur mit kleinen, gleichmäßigen Zellen und dünnen Zellwänden ist von entscheidender Bedeutung, um eine geringe Wärmeleitfähigkeit und gute Isoliereigenschaften zu erzielen. Ein vertieftes Verständnis dieser Zusammenhänge ist eine grundlegende Voraussetzung für die Entwicklung hocheffizienter Dämmstoffe (Choe et al., 2019).

#### **2.3.4 Normbasierte Zellgrößenbestimmung in Polyurethan-Hartschäumen**

Die Bestimmung der Zellgröße in Polyurethan-Hartschaumstoffen ist ein wesentlicher Aspekt zur Sicherstellung der Qualität und Leistungsfähigkeit von Materialien, die in Fernwärmerohren eingesetzt werden. Zwei wichtige Normen, die Methoden zur Messung der Zellgröße beschreiben, sind die ASTM D3576 und die DIN EN 253. Beide Normen bieten spezifische Verfahren, um die Zellgrößen präzise zu bestimmen, unterscheiden sich jedoch in ihrer Methodik und den spezifischen Anforderungen.

Gemäß EN 253:2020-03 muss die mittlere Zellgröße in radialer Richtung weniger als 0,5 mm betragen. Um die Zellgröße zu bestimmen, müssen zunächst Probekörper aus dem Verbund-Rohrsystem entnommen werden. Die Probekörper dürfen der Ummantelung erst entnommen werden, nachdem diese mindestens 16 Stunden bei einer Temperatur von  $(23 \pm 2) \text{ }^\circ\text{C}$  gelagert wurden. Alternativ können die Probekörper von der PUR-Schaumstoffwärmedämmung und vom Verbund-Rohrsystem entnommen werden, wenn diese mindestens 72 Stunden bei einer Temperatur von  $(23 \pm 2) \text{ }^\circ\text{C}$  gelagert wurden.

Die Probekörper zur Bestimmung der Schaumstoffeigenschaften müssen an einer Stelle an jedem Ende des Verbund-Rohrsystems entnommen werden. Von den Stellen, die zur Entnahme von Probekörpern vorgesehen sind, müssen gleichmäßig über den Umfang verteilt drei Probekörper entnommen werden. Bei der Entnahme der Probekörper darf der Schaumstoff, der nahe der Mediumrohr- sowie der Ummantelungsoberfläche liegt, nicht berücksichtigt werden. Es ist ein Abstand von mindestens 5 mm bzw. 3 mm einzuhalten. Die

Zellgröße wird über eine in radialer Richtung gemessene Länge von 10 mm bestimmt, wobei der Mittelpunkt der angewendeten Dämmung genau in der Mitte der Messlänge von 10 mm liegt. Die Zellgröße ergibt sich aus dem Quotienten der Prüflänge und der Anzahl der Zellen, die entlang der radialen Linie über die ausgewählte Prüflänge gezählt werden. Das Prüfergebnis muss an jeder Stelle als Durchschnittswert aus Messungen an drei Probekörpern bestimmt werden. Die Norm sieht zudem eine regelmäßige Überwachung und Prüfung der Zellgröße vor. Bei der Typprüfung des Herstellers muss die Zellgröße einmal je Polyol-/Isocyanat-Typ und Maschine bestimmt werden. Im Rahmen der Qualitätskontrolle des Herstellers muss die Zellgröße mindestens zweimal jährlich pro Maschine geprüft werden. Bei der außerbetrieblichen Prüfung erfolgt die Bestimmung der Zellgröße einmal je Inspektionsbesuch, wobei die Aufzeichnungen des Herstellers kontrolliert werden (Überwachungs- und Prüfrichtlinien).

Die ASTM D3576-Norm bietet zwei Verfahren zur Bestimmung der scheinbaren Zellengröße von starren zellularen Kunststoffen. Im Verfahren A wird ein dünner Schnitt des Materials hergestellt, dessen Dicke nicht mehr als die Hälfte des durchschnittlichen Zelldurchmessers betragen darf. Dieser Schnitt wird projiziert, und die Zellen werden anhand der Schnittpunkte ihrer Wände auf einer definierten Messstrecke gezählt. Dieses Verfahren erfordert eine sorgfältige Probenvorbereitung und ist besonders für Materialien geeignet, bei denen eine detaillierte Analyse der Zellstruktur erforderlich ist.

Verfahren B der ASTM D3576-Norm kommt bei Materialien zur Anwendung, deren brüchige Natur die Herstellung eines dünnen Schnittes erschwert. Hierbei wird die Oberfläche des Materials geglättet, um eine bessere Sichtbarkeit der Zellwände zu gewährleisten. Diese Methode ermöglicht eine leichtere Zählung der Zellen und bietet Flexibilität bei der Analyse von Materialien mit unterschiedlichen Zellgrößen.

Ein wesentlicher Aspekt bei der normbasierten Zellgrößenbestimmung in Polyurethan-Hartschäumen ist die Tatsache, dass die derzeit etablierten Methoden auf manuellen und zeitintensiven Prozessen basieren. Sowohl die ASTM D3576 als auch die EN 253 erfordern eine sorgfältige Probenvorbereitung, eine visuelle Inspektion sowie eine manuelle Zählung der Zellen entlang definierter Messlinien oder -bereiche. Diese Vorgehensweise ist nicht nur arbeitsintensiv, sondern auch anfällig für menschliche Fehler und subjektive Einflüsse. Des Weiteren ist zu berücksichtigen, dass die manuelle Analyse die Anzahl der pro Zeiteinheit untersuchbaren Proben begrenzt, was die statistische Aussagekraft der Ergebnisse potenziell einschränkt.

Trotz der zunehmenden Digitalisierung und Automatisierung in vielen Bereichen der Materialcharakterisierung gibt es derzeit keine standardisierte digitale Lösung, die eine vollautomatische Bestimmung der Zellgröße in Polyurethan-Hartschäumen ermöglicht. Forschungsarbeiten haben zwar das Potenzial von Bildverarbeitungstechniken und maschinellem Lernen zur Automatisierung der Zellgrößenanalyse aufgezeigt, jedoch haben sich diese Ansätze noch nicht in der industriellen Praxis etabliert. Die Entwicklung und Validierung einer robusten, zuverlässigen und normenkonformen digitalen Methode zur Zellgrößenbestimmung stellt somit eine wichtige Herausforderung und Chance für zukünftige Entwicklungsaktivitäten dar.

## **2.4 Mechanismen der Alterung von Polyurethan**

Polyurethan-Hartschäume sind aufgrund ihrer hervorragenden mechanischen und thermischen Eigenschaften in zahlreichen industriellen Anwendungen weit verbreitet, insbesondere in der Wärmedämmung von Fernwärmesystemen, im Bauwesen, in Kühlgeräten und bei der Isolierung von Rohrleitungen (Gietzelt et al., 2006). Die Alterung dieser Materialien stellt jedoch eine große Herausforderung dar, da verschiedene chemische und physikalische Prozesse die strukturelle Integrität und Leistungsfähigkeit der Schäume im Laufe der Zeit beeinträchtigen können (Maxwell et al., 2005). In diesem Kapitel werden die verschiedenen Alterungsmechanismen von Polyurethan-Hartschäumen analysiert und deren Einfluss auf die Lebensdauer und Funktionsfähigkeit der Materialien bewertet.

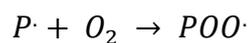
Die wichtigsten Alterungsmechanismen sind die oxidative Degradation, die Hydrolyse und die Diffusion von Gasen. Diese Prozesse führen zu einer allmählichen Verschlechterung der mechanischen Festigkeit, der thermischen Isolierfähigkeit und der gesamten Materialstruktur. Sie werden sowohl durch äußere Einflüsse wie Temperatur und Feuchtigkeit als auch durch interne Materialeigenschaften wie die Zellmorphologie und den chemischen Aufbau des Schaums beeinflusst (Szycher, 2012; Maxwell et al., 2005).

Ein tiefgehendes Verständnis dieser Alterungsmechanismen ist von entscheidender Bedeutung, um gezielte Maßnahmen zur Erhöhung der Lebensdauer von Polyurethan-Hartschäumen zu entwickeln und die Zuverlässigkeit ihrer Verwendung in Fernwärmesystemen zu gewährleisten. In den folgenden Unterkapiteln werden die verschiedenen Mechanismen im Detail untersucht, um die Faktoren und Prozesse zu identifizieren, die maßgeblich zur Alterung von Polyurethan-Hartschäumen beitragen.

### 2.4.1 Oxidative Alterung von Polyurethan-Hartschäumen

Die oxidative Alterung von Polyurethan-Hartschäumen (PUR) ist ein wesentlicher Degradationsmechanismus, der die Langzeitstabilität und Leistungsfähigkeit dieser Materialien erheblich beeinträchtigt. Die Polyurethan-Matrix besteht aus organischen Polymeren, die über längere Zeiträume hinweg anfällig für oxidative Abbauprozesse sind, wenn sie Sauerstoff und anderen oxidativen Einflüssen ausgesetzt werden. Diese chemischen Veränderungen in der Polymerstruktur führen zu einer Verschlechterung sowohl der mechanischen als auch der thermischen Eigenschaften des Schaums, was die Lebensdauer und Wirksamkeit des Materials in Anwendungen wie der Bau- und Isolationsindustrie stark einschränken kann (Szycher, 2012).

Der oxidative Abbau beginnt mit der Reaktion freier Radikale im PUR-Schaum mit Sauerstoff, wodurch Peroxid-Radikale entstehen. Diese Reaktion lässt sich folgendermaßen beschreiben:



In nachfolgenden, langsameren Reaktionen führen die Peroxid-Radikale zum Abbau der Polymerketten. Der gesamte Prozess umfasst eine ausgedehnte Induktionsperiode, in der lediglich geringe Degradationserscheinungen festzustellen sind. Gegen Ende dieser Periode erfolgt ein rapider Anstieg der Zersetzung, was zu einer signifikanten Verschlechterung der mechanischen Eigenschaften des Schaums führt. Die Länge dieser Induktionsperiode ist stark von der Temperatur abhängig. Mit steigender Temperatur erfolgt eine deutliche Verkürzung der Induktionsphase, was zu einer beschleunigten Initiierung des oxidativen Abbaus führt. (Maxwell et al., 2005).

Zusätzlich zur Bildung freier Radikale tragen auch Umweltbedingungen wie Luftfeuchtigkeit zur Degradation bei. Wassermoleküle können durch die Zellwände des Schaums diffundieren und chemische Reaktionen mit den Bestandteilen des Materials eingehen, was den oxidativen Abbau beschleunigt. Diese Effekte sind besonders in Anwendungen mit hohen Temperaturen oder mechanischer Belastung von Bedeutung, da unter solchen Bedingungen die Isolationswirkung des Schaums schneller abnimmt (Maxwell et al., 2005).

Um die Auswirkungen der oxidativen Alterung zu minimieren, können Additive wie Antioxidantien und UV-Stabilisatoren in die Polyurethan-Matrix eingebracht werden. Diese Additive hemmen die Bildung freier Radikale und reduzieren die Reaktivität von

Sauerstoffmolekülen, wodurch die Degradationsrate verlangsamt wird. Zusätzlich können Beschichtungen auf der Oberfläche des Schaums angewendet werden, um das Eindringen von Sauerstoff und Feuchtigkeit zu verringern (Szycher, 2012)

#### **2.4.2 Hydrolyse von Polyurethan-Hartschäumen**

Die Hydrolyse ist ein wesentlicher Degradationsmechanismus, der die strukturelle Integrität und Leistungsfähigkeit von Polyurethan-Hartschäumen (PUR) erheblich beeinträchtigen kann. Bei der Hydrolyse reagieren die Urethan- und Harnstoffbindungen des Polyurethans mit Wasser, was zu einer Zersetzung der Polymerketten führt. Diese chemische Reaktion schwächt die mechanischen Eigenschaften des Schaums und verringert seine thermische Effizienz, insbesondere in feuchten und hochtemperierten Umgebungen. Die Hydrolyse von PUR-Schäumen erfolgt durch einen nukleophilen Angriff von Wassermolekülen auf die Carbonylgruppe der Urethangruppen. In dieser Reaktion werden die Polymerketten gespalten, was zur Bildung von Carbamidsäure führt, die anschließend in primäre Amine und Kohlendioxid zerfällt (Maxwell et al., 2005).

Die fortschreitende Zersetzung der Polymerketten führt zu einer Abnahme des Molekulargewichts, was die mechanische Festigkeit des Schaums beeinträchtigt. Dieser Abbauprozess wird insbesondere in feuchten und wärmeren Umgebungen beschleunigt (Szycher, 2012).

Feuchtigkeit und Temperatur spielen eine zentrale Rolle bei der Hydrolyse. Wasser kann durch die Zellstruktur des Schaums diffundieren und die chemischen Reaktionen mit den Urethangruppen fördern. Erhöhte Temperaturen verstärken diesen Effekt, da sie die Reaktionsgeschwindigkeit und die Diffusion von Wassermolekülen in die Zellstruktur erhöhen (Gietzelt et al., 2006).

Durch die Hydrolyse verringert sich die mechanische Festigkeit von Polyurethan-Hartschäumen erheblich. Die Zersetzung der Polymerketten führt zu einer spröderen Struktur, was die Druck- und Zugfestigkeit des Materials mindert. Dies kann in Anwendungen wie der Rohrisolierung oder der Bauindustrie zu einem vorzeitigen Versagen des Materials führen. Zusätzlich erhöht sich durch die Wasserdiffusion in den Schaum die Wärmeleitfähigkeit, was die thermische Isolierleistung verringert (Doyle & Weidlich, 2022).

Um die negativen Auswirkungen der Hydrolyse zu minimieren, können Feuchtigkeitssperren und Additive eingesetzt werden, die die Hydrolyseresistenz des Schaums erhöhen. Solche Maßnahmen sind besonders in Anwendungen mit hohen

Feuchtigkeits- und Temperaturbelastungen, wie in der Rohrisolierung, wichtig, um die Lebensdauer des Materials zu verlängern (Szycher, 2012).

### **2.4.3 Diffusion in Polyurethan-Hartschäumen**

Die Diffusion von Gasen, insbesondere von Luft und Wasserdampf, ist ein entscheidender Faktor für die Langzeitstabilität und Leistungsfähigkeit von Polyurethan-Hartschäumen. Diffusionsprozesse beeinflussen nicht nur die Wärmeleitfähigkeit, sondern auch die Alterungsbeständigkeit der Schäume. Da die Polyurethan-Matrix nicht vollständig diffusionsdicht ist, kommt es zu einem ständigen Austausch zwischen den in den Zellen eingeschlossenen Treibgasen und der Umgebungsluft. Dieser Austausch führt zu einer allmählichen Verschlechterung der isolierenden Eigenschaften des Materials (Glicksman, 1994).

In geschlossenen Zellstrukturen verläuft die Diffusion langsamer, da die Zellwände als Barrieren wirken. Polyurethan-Schäume mit hohem Anteil an geschlossenen Zellen zeigen daher eine bessere Langzeitstabilität. Treibmittel wie Kohlenstoffdioxid bleiben zunächst in den geschlossenen Zellen eingeschlossen, diffundieren jedoch über die Zeit nach außen. Parallel dazu dringen Luftbestandteile wie Sauerstoff und Stickstoff in die Zellstrukturen ein, was die thermischen und mechanischen Eigenschaften des Schaums verändert (Glicksman, 1994).

Bei der gewöhnlichen Verwendung von PU-Schäumen in Rohrleitungen lassen sich zwei Mechanismen des Massentransports beobachten (Gietzelt et al., 2006):

- i. Fick'sche Diffusion: Der Massenstrom wird durch einen Konzentrations- oder Partialdruckunterschied angetrieben. Höhere Unterschiede in der Konzentration oder im Partialdruck führen zu einer Zunahme des Diffusionsstroms.
- ii. Soret'sche Diffusion (Thermodiffusion): Dieser Diffusionsmechanismus wird durch Temperaturunterschiede angetrieben. Bei einem steigenden Temperaturgradienten nimmt die Thermodiffusion zu, allerdings sinkt der Gesamtdiffusionsstrom bei höheren Temperaturen.

Beide Diffusionsprozesse sind instationär und sowohl zeitlich als auch räumlich variabel. Zudem erschweren Phasengrenzflächen die Berechnung des Diffusionsstroms innerhalb des Schaums erheblich. Der Transport von Wasser innerhalb der Zellen des Schaums wird stark durch die Zellgröße und die Anzahl der geschlossenen Zellen beeinflusst, wobei kleinere Zellen zu einer langsameren Diffusion führen (Gietzelt et al., 2006)

Die Temperatur beeinflusst die Diffusion in Polyurethan-Hartschäumen erheblich, indem sie sowohl die Diffusionskoeffizienten als auch den Diffusionsfluss beeinflusst. Bei höheren Temperaturen wird die Fick'sche Diffusion von Zellgasen wie CO<sub>2</sub> beschleunigt, was zu einem verstärkten Austritt der Treibmittel und einer Verringerung des Gasaustauschs mit Luft und Wasser führt. Umgekehrt fördern niedrigere Temperaturen den Lufteintritt in den Schaum und verringern den Austritt der Treibmittel. Zusätzlich verursacht der Temperaturgradient eine Thermodiffusion, die schwere Treibmittelmoleküle von der Rohrinneenseite nach außen transportiert, während leichtere Luftmoleküle in die entgegengesetzte Richtung diffundieren. Diese Prozesse wirken sich langfristig auf die Lebensdauer und die mechanischen Eigenschaften des Schaums aus, da Temperaturänderungen zu Spannungen und Volumenänderungen führen, die durch unterschiedliche Ausdehnungskoeffizienten in den Materialien verursacht werden (Gietzelt et al., 2006).

Die Diffusion in Polyurethan-Hartschäumen stellt einen komplexen Prozess dar, der von verschiedenen Faktoren wie der Zellstruktur, der Temperatur und der Feuchtigkeit beeinflusst wird. Diese Prozesse haben signifikante Auswirkungen auf die thermischen und mechanischen Eigenschaften des Materials und sind daher ein wichtiger Faktor für die Langzeitstabilität von Dämmstoffen in der Fernwärmeversorgung (Gietzelt et al., 2006; Ostrogorsky et al., 1986).

#### **2.4.4 Beziehung der Morphologie und Alterung von Polyurethan-Hartschäumen**

Die Morphologie von Polyurethan-Hartschäumen spielt eine entscheidende Rolle für die Alterungsprozesse, insbesondere durch die Diffusion von Gasen in den Schaumzellen, die zu einer Veränderung der thermischen Leitfähigkeit führt. Die thermische Leitfähigkeit frisch hergestellter Schäume ist niedrig, nimmt jedoch mit der Zeit zu, da Luft in die Zellen eindringt und das ursprüngliche Treibmittel ersetzt. Dieser Prozess wird als Schaumalterung bezeichnet und stellt einen wesentlichen Faktor bei der langfristigen Bewertung der Leistungsfähigkeit von Dämmstoffen dar (Navickas & Madsen, 1977).

Untersuchungen haben gezeigt, dass größere Zellen tendenziell schneller altern, da sie eine größere Oberfläche für den Gasaustausch bieten, was die Diffusion von Luft in den Schaum erleichtert und zu einer beschleunigten Verschlechterung der thermischen Eigenschaften führt (Ostrogorsky et al., 1986). Darüber hinaus zeigt sich, dass Schäume mit größeren Zellen eine geringere strukturelle Stabilität aufweisen, da die geringere Materialverteilung zu einer höheren Anfälligkeit für mechanische Belastungen führt (Smits, 1994). Dies

bedeutet, dass im Laufe der Zeit nicht nur die Wärmeleitfähigkeit zunimmt, sondern auch die Festigkeit und die mechanische Integrität des Schaums abnimmt. Dieser Effekt wird durch äußere Einflüsse wie Temperatur- und Feuchtigkeitsschwankungen noch verstärkt, was letztlich die langfristige Leistungsfähigkeit des Materials erheblich beeinträchtigt (Ostrogorsky et al., 1986).

Smits (1994) untersuchte die Auswirkungen einer Zellgrößenreduktion auf die physikalischen Eigenschaften von PUR-Schäumen. Er stellte fest, dass eine Verringerung der durchschnittlichen Zellgröße zu einer Umverteilung des Materials hin zu den Zellwänden führt, wobei die Dicke der Zellwände größtenteils konstant bleibt. Dies hat zur Folge, dass ab einer bestimmten Dichte und Zellgröße nicht mehr genügend Material vorhanden ist, um die Stabilität der Zellwände zu gewährleisten.

Da die Zellwände die Hauptbarriere für Diffusionsprozesse darstellen, wird die Alterungsrate durch diese Verschiebung der Materialverteilung drastisch reduziert, solange die Zellen noch geschlossen sind. Abbildung 7 veranschaulicht die Abnahme der Alterungsrate der Wärmeleitfähigkeit, die eine lineare Funktion der Zellgröße ist. Eine Verringerung der Zellgröße führt in der Regel zu einer Abnahme der anfänglichen Wärmeleitfähigkeit, hauptsächlich aufgrund der Reduktion des Anteils der durch Strahlung übertragenen Wärme. Kleinere Zellen streuen und absorbieren die Wärmestrahlung effektiver, wodurch der Gesamtwärmetransport verringert wird. Es existiert jedoch ein Bereich, in dem sich dieser Effekt umkehrt und weitere Zellgrößenreduktionen eher zu einem Anstieg als zu einer Abnahme der Wärmeleitfähigkeit führen (Smits, 1994).

Mit der Zeit können sich die strukturellen Eigenschaften von PUR-Hartschäumen durch physikalische Einflüsse wie Temperatur und Feuchtigkeit verändern. Studien haben gezeigt, dass die regelmäßige Struktur der Schaumzellen durch Alterungsprozesse beeinträchtigt werden kann, was zu einer Abnahme der mechanischen Stabilität und einer Erhöhung der Wärmeleitfähigkeit führt. Diese Veränderungen sind oft mit einem Verlust an Zellintegrität verbunden, wodurch die Barriereigenschaften des Schaums gegen Gasdiffusion reduziert werden (Barszczewska-Rybarek et al., 2021).

Die vorliegenden Erkenntnisse legen insgesamt den Schluss nahe, dass die Morphologie von Polyurethan-Hartschäumen nicht nur die Wärmedämmeigenschaften beeinflusst, sondern auch das Alterungsverhalten und die Langzeitstabilität dieser Materialien maßgeblich bestimmt. Ein vertieftes Verständnis dieser Zusammenhänge erlaubt die Entwicklung von Schäumen mit optimierter Langlebigkeit und Leistungsfähigkeit.

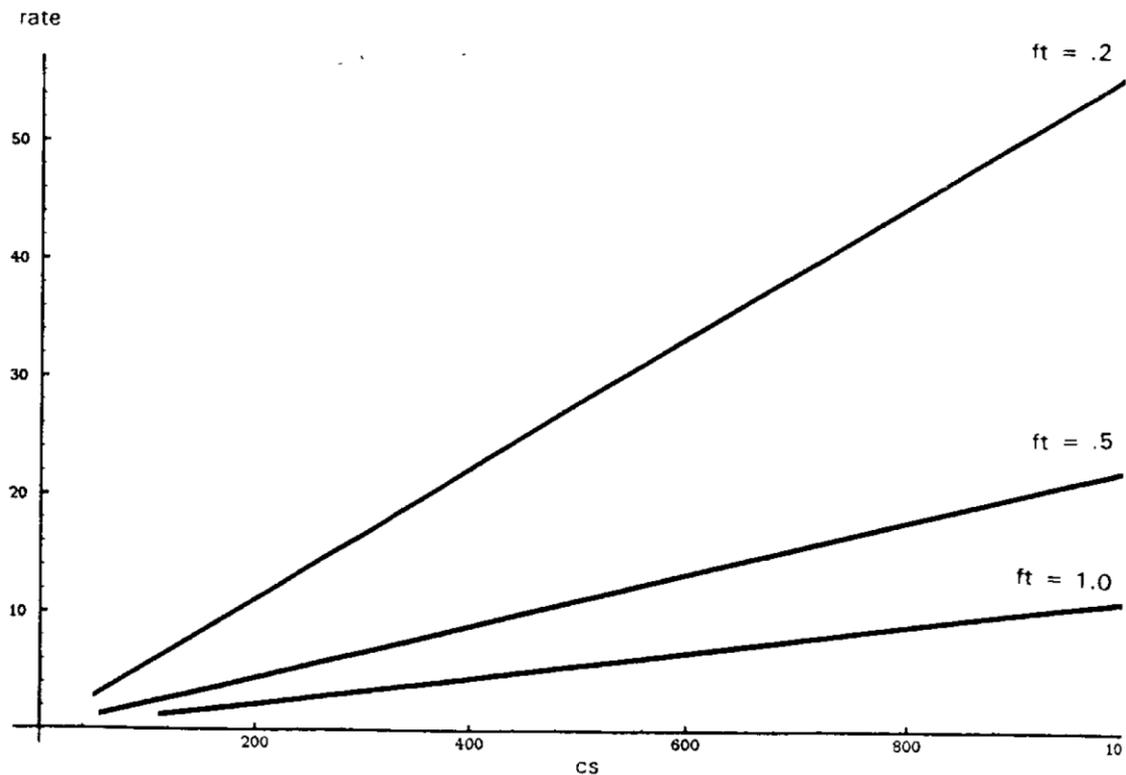


Abbildung 7: Alterung der Wärmeleitfähigkeit von Schaumstoffen in Abhängigkeit von Zellgröße und Zellwände (Smits, 1994).

## 2.5 Anwendung von Computer Vision in der Materialanalyse

Computer Vision, ein Teilgebiet der künstlichen Intelligenz, befasst sich mit der Entwicklung von Methoden und Technologien, die es Computern ermöglichen, visuelle Informationen aus digitalen Bildern oder Videos zu extrahieren, zu analysieren und zu verstehen. Das übergeordnete Ziel von Computer Vision besteht in der Verleihung der Fähigkeit an Computer, die Welt durch visuelle Wahrnehmung ähnlich wie Menschen zu interpretieren und darauf zu reagieren (Szeliski, 2022).

Die Anwendungsbereiche von Computer Vision sind vielfältig und erstrecken sich von der industriellen Automatisierung, beispielsweise zur Fehlererkennung in Produktionslinien, über die medizinische Bildgebung, wie die Identifizierung von Tumoren, bis hin zu autonomen Fahrzeugen und Robotik. In den vergangenen Jahren hat die rapide Entwicklung von Deep Learning und künstlichen neuronalen Netzen zu einem signifikanten Fortschritt hinsichtlich der Leistungsfähigkeit und Anwendbarkeit von Computer-Vision-Algorithmen geführt, insbesondere durch die automatische Merkmalsextraktion und die Fähigkeit, komplexe Muster in Bilddaten zu erkennen.

### **2.5.1 Einführung in Computer Vision**

Die grundlegenden Aufgaben der Computer Vision umfassen die Bilderfassung, Vorverarbeitung, Merkmalsextraktion, Segmentierung, Klassifikation und Interpretation. Der erste Schritt im Rahmen der Bilderfassung besteht in der Digitalisierung von Bildern, welche durch Kameras oder andere Sensoren erzeugt werden. Im Anschluss erfolgt die Umformung der erfassten Bilder in eine für die weitere Verarbeitung geeignete Form. Im Anschluss werden Vorverarbeitungstechniken wie Rauschunterdrückung, Kontrastverbesserung und geometrische Transformationen angewendet, um die Bildqualität zu optimieren und störende Einflüsse zu minimieren (Szeliski, 2022).

Ein wesentlicher Aspekt der Computer Vision ist die Extraktion aussagekräftiger Merkmale aus Bildern, welche eine kompakte und diskriminative Beschreibung des visuellen Inhalts ermöglichen. Traditionelle Ansätze basieren auf handgefertigten Merkmalen wie Kanten, Ecken, Texturen oder lokalen Deskriptoren (z. B. SIFT oder HOG), während moderne Deep-Learning-Methoden gelernte hierarchische Merkmalsrepräsentationen verwenden (Szeliski, 2022).

Auf der Grundlage extrahierter Merkmale können Computer-Vision-Algorithmen Bilder in semantisch bedeutungsvolle Regionen segmentieren, Objekte lokalisieren und klassifizieren sowie höherwertige Informationen wie räumliche Beziehungen, Aktivitäten oder Emotionen ableiten (Azimi et al., 2018). Deep-Learning-Architekturen wie Convolutional Neural Networks (CNNs) haben sich als besonders leistungsfähig für die Bewältigung dieser Aufgaben erwiesen und erreichen in vielen Benchmarks eine mit Menschen vergleichbare oder sogar überlegene Genauigkeit (Goodfellow et al., 2016).

Die Interpretation der extrahierten Informationen und die Ableitung von Wissen aus Bildern erfordern in vielen Fällen die Integration von Vorwissen, Kontextinformationen und Reasoning-Fähigkeiten. In diesem Kontext sind zudem Ansätze wie Probabilistische Graphische Modelle, Semantische Netze und Wissensbasierte Systeme zu nennen, welche die Modellierung der höheren Ebenen der visuellen Wahrnehmung zum Ziel haben (Lake et al., 2016).

Insgesamt bilden die Grundlagen der Computer Vision das Fundament für die Entwicklung intelligenter Systeme, die in der Lage sind, visuelle Informationen ähnlich wie Menschen zu verarbeiten und zu interpretieren. Der rasante Fortschritt in diesem Bereich eröffnet faszinierende Möglichkeiten für innovative Anwendungen, die unser Leben in vielfältiger Weise bereichern und erleichtern können.

### 2.5.2 Beziehungen zwischen KI, Computer Vision und maschinellem Lernen

Die Bereiche der künstlichen Intelligenz (KI), der Computer Vision (CV) und des maschinellen Lernens (ML) sind eng miteinander verknüpft und beeinflussen sich gegenseitig. Zudem ergänzen sie sich gegenseitig.

KI ist ein übergeordnetes Feld, das sich mit der Entwicklung intelligenter Systeme befasst, die in der Lage sind, Aufgaben auszuführen, die normalerweise menschliche Intelligenz erfordern. Computer Vision ist ein Teilgebiet der KI, das sich speziell mit der Fähigkeit von Computern beschäftigt, visuelle Informationen aus digitalen Bildern oder Videos zu gewinnen und zu verstehen (Goodfellow et al., 2016).

Maschinelles Lernen spielt sowohl in der KI als auch in der Computer Vision eine zentrale Rolle. Es bezeichnet die Fähigkeit von Computersystemen, aus Daten zu lernen und ihre Leistung bei einer bestimmten Aufgabe zu verbessern, ohne dafür explizit programmiert zu werden. In der Computer Vision werden ML-Algorithmen häufig eingesetzt, um visuelle Muster zu erkennen, Objekte zu klassifizieren und semantische Informationen aus Bildern zu extrahieren (Voulodimos et al., 2018). Die folgende Abbildung 8 zeigt die Einordnung zwischen künstlicher Intelligenz, maschinellem Lernen und Deep Learning sowie Computer Vision.

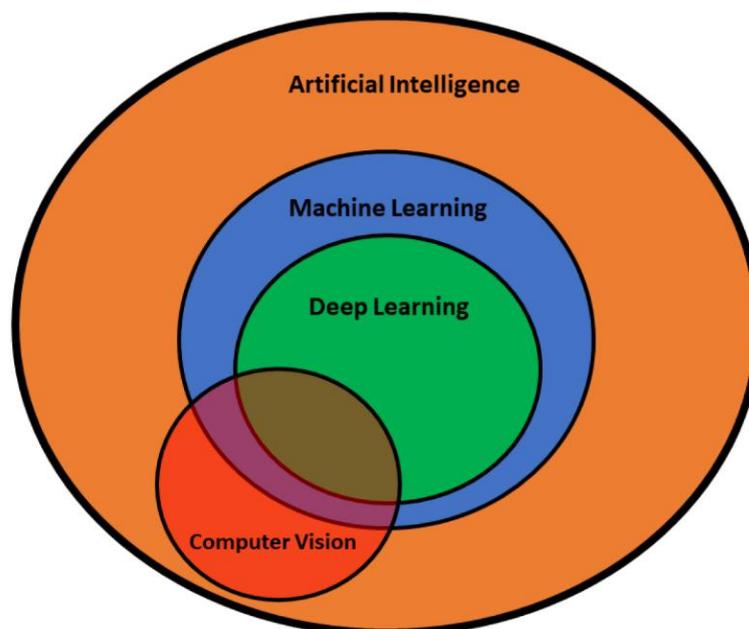


Abbildung 8: Venn-Diagramm von AI (Künstlicher Intelligenz), Maschinellern, Deep Learning und Computer Vision (Mohimont et al., 2022).

Die Fortschritte im Bereich des maschinellen Lernens, insbesondere des Deep Learning, haben die Entwicklung der Computer Vision in den letzten Jahren erheblich vorangetrieben. Die Mehrzahl der gegenwärtig in der Computer Vision eingesetzten State-of-the-Art-Ansätze basiert auf tiefen neuronalen Netzen, welche in der Lage sind, komplexe visuelle Muster direkt aus Bilddaten zu erlernen (Voulodimos et al., 2018).

### **2.5.3 Bildakquisition und -verarbeitung in der Computer Vision**

Die Bildakquisition und -verarbeitung sind wesentliche Bestandteile der Computer Vision, die es Maschinen ermöglichen, visuelle Informationen zu erfassen, zu analysieren und zu interpretieren. Diese Prozesse sind entscheidend für die Entwicklung intelligenter Systeme, die in der Lage sind, Aufgaben auszuführen, die traditionell menschliche Wahrnehmung erfordern (Szeliski, 2022).

Der erste Schritt in der Bildverarbeitung ist die Erfassung von Bildern, die durch Kameras oder andere Sensoren aufgenommen werden. Diese Bilder müssen in eine digitale Form umgewandelt werden, um von Computern verarbeitet werden zu können. Die Qualität der Bildakquisition beeinflusst maßgeblich die nachfolgenden Verarbeitungs- und Analyseprozesse. Hochauflösende Kameras und spezialisierte Sensoren werden häufig eingesetzt, um detaillierte Bilder zu erfassen, die für präzise Analysen erforderlich sind (Gonzalez & Woods, 2018).

Nach der Erfassung müssen die Bilder oft vorverarbeitet werden, um Rauschen zu reduzieren, den Kontrast zu verbessern und störende Artefakte zu entfernen. Zu den gängigen Vorverarbeitungstechniken gehören Rauschunterdrückung, Histogrammausgleich und geometrische Transformationen. Diese Schritte dienen dazu, die Bildqualität zu optimieren und die nachfolgenden Analyseschritte zu erleichtern (Gonzalez & Woods, 2018).

Die Binärbildumwandlung stellt einen wesentlichen Schritt innerhalb der Bildvorverarbeitung dar, wobei ein Graustufenbild in ein Binärbild transformiert wird. Im Rahmen dieses Prozesses erfolgt eine Klassifikation der Pixel anhand eines Schwellenwerts, wobei die Pixel dem Vordergrund (weiß) oder dem Hintergrund (schwarz) zugeordnet werden. Die Verarbeitung von Binärbildern ermöglicht eine Vielzahl von nachfolgenden Verarbeitungsschritten, darunter Segmentierung und morphologische Operationen (Burger & Burge, 2016).

Die Prozesse der Bildakquisition und -verarbeitung stellen ein Fundament für eine Vielzahl von Anwendungen im Bereich der Computer Vision dar. Die genannten Prozesse ermöglichen es Systemen, visuelle Daten effektiv zu nutzen, wodurch eine Grundlage für fortschrittliche Anwendungen in Bereichen wie autonomes Fahren, medizinische Bildgebung und industrielle Automatisierung geschaffen wird.

#### **2.5.4 Methoden der Bildsegmentierung**

Die Bildsegmentierung stellt einen entscheidenden Prozess in der Computer Vision dar, bei dem ein Bild in mehrere Segmente unterteilt wird, die jeweils homogene Eigenschaften aufweisen. Dazu zählen beispielsweise Farbe, Intensität oder Textur. Die resultierenden Segmente können Objekte, Kanten oder Regionen im Bild repräsentieren, die für weitere Analysen wie Objekterkennung oder Klassifikation von Bedeutung sind (Szeliski, 2022).

Ein grundlegender Ansatz der Segmentierung ist die Schwellwertbildung (engl. Thresholding), bei der Pixel basierend auf ihrer Intensität in Vorder- und Hintergrund klassifiziert werden. Diese Methode erweist sich insbesondere bei Bildern mit einem hohen Kontrast zwischen den Objekten und dem Hintergrund als effektiv (Sankur & Sezgin, 2004).

Ein weiterer Ansatz, der in der Praxis häufig Anwendung findet, ist die Verwendung von Clustering-Methoden wie dem k-Means-Algorithmus. Dieser teilt die Pixel anhand ihrer Eigenschaften in ähnliche Gruppen (Cluster) ein. Diese Methode zeichnet sich durch ihre Flexibilität aus und kann auf eine Vielzahl von Bildtypen angewendet werden (Raschka & Mirjalili, 2017).

Für komplexe Szenarien, in denen Objekte unterschiedliche Formen und Größen aufweisen oder sich überlappen, wird die Wasserscheidentransformation (engl. watershed transformation) als fortgeschrittene Technik zur Bildsegmentierung eingesetzt. Diese Methode eignet sich besonders zur Trennung von sich berührenden Objekten in einem Bild. Die Wasserscheidentransformation basiert auf der Analogie zur topografischen Analyse, bei der ein Bild als dreidimensionale Landschaft betrachtet wird, wobei die Pixelintensitäten die Höhen repräsentieren (Roerdink & Meijster, 2000).

Der grundlegende Ansatz basiert auf der Interpretation des Bildes als Reliefkarte, auf der Wasser aus den tiefsten Punkten, den lokalen Minima, zu fließen beginnt (siehe Abbildung 9). Diese Minima fungieren als "Marker", von denen aus die Flutung startet. Während des Flutungsprozesses bilden sich an den Berührungspunkten der Regionen sogenannte

Wasserscheidenlinien, die als Grenzen zwischen den Objekten dienen und somit die Segmentierungsgrenzen definieren (Roerdink & Meijster, 2000).

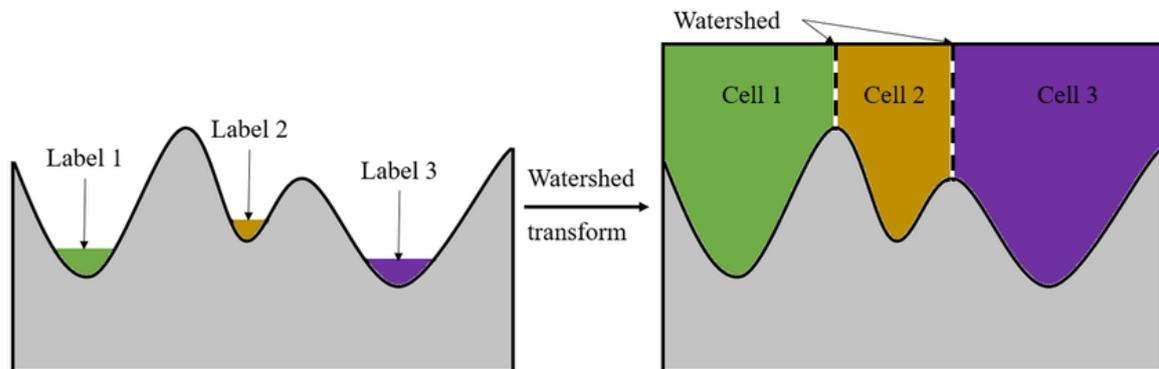


Abbildung 9: Der Segmentierungsprozess des Watershed-Algorithmus (Zheng et al., 2021)

Ein wesentlicher Vorteil der Wasserscheidentransformation ist ihre Fähigkeit, komplexe und dicht gepackte Strukturen effektiv zu segmentieren. Dies macht sie besonders geeignet für Anwendungen in der Materialwissenschaft, Biologie und Medizin, wo präzise Segmentierungen erforderlich sind (Roerdink & Meijster, 2000).

Die Wasserscheidentransformation ist in vielen Bildverarbeitungsbibliotheken implementiert und bietet eine flexible Lösung für die Segmentierung anspruchsvoller Bilddaten. Ihre Anwendung erfordert jedoch eine sorgfältige Parametrisierung und Vorverarbeitung der Bilder, um optimale Ergebnisse zu erzielen. In Kombination mit anderen Bildverarbeitungstechniken kann sie eine robuste Grundlage für die Analyse komplexer Strukturen bieten und somit wertvolle Einblicke in die zugrunde liegenden Daten ermöglichen (Gonzalez & Woods, 2017).

Zusammenfassend lässt sich festhalten, dass die Methoden der Bildsegmentierung eine entscheidende Rolle in der Computer Vision einnehmen, indem sie die Grundlage für die Objekterkennung und weitere Bildanalysen bilden. Die Wahl der adäquaten Segmentierungstechnik ist maßgeblich von der spezifischen Anwendung sowie den Eigenschaften der zu analysierenden Bilder abhängig.

### 2.5.5 Distanztransformation

Die Distanztransformation ist eine fundamentale Technik in der Bildverarbeitung, die eine Vielzahl von Anwendungen in der Analyse und Verarbeitung von Bildern findet. Sie ordnet jedem Pixel eines Binärbildes den Abstand zum nächstgelegenen Hintergrundpixel zu und erzeugt somit eine Distanzkarte. Die resultierenden Distanzwerte können als Grundlage für

verschiedene Bildverarbeitungsoperationen dienen, wie beispielsweise die Skelettierung, die Segmentierung oder die Analyse von Objektformen (Fabbri et al., 2008).

Der Hauptzweck der Distanztransformation besteht darin, strukturelle Informationen über die Objekte im Bild zu extrahieren. Durch die Berechnung der Distanzen können wichtige Merkmale wie die Dicke von Strukturen oder die Breite von Objekten quantifiziert werden. Diese Informationen sind besonders wertvoll für Anwendungen in der Materialwissenschaft, Medizin und Computer Vision, wo eine präzise Analyse der Objektmorphologie erforderlich ist.

Das Grundprinzip der Distanztransformation besteht darin, für jedes Vordergrundpixel im Bild den kürzesten Abstand zum nächstgelegenen Hintergrundpixel zu berechnen. Dabei können verschiedene Distanzmetriken verwendet werden, wie die euklidische Distanz, die Manhattan-Distanz oder die Schachbrett-Distanz (Fabbri et al., 2008). Die Wahl der Distanzmetrik hängt von der spezifischen Anwendung und den Anforderungen an die Genauigkeit und Effizienz ab.

Eine häufig verwendete Methode zur Berechnung der Distanztransformation ist der Algorithmus von Rosenfeld und Pfaltz (1966). Dieser Algorithmus basiert auf einer zweistufigen Berechnung, bei der zunächst eine vorläufige Distanzkarte erstellt wird, indem die Distanzen in horizontaler und vertikaler Richtung berechnet werden. Anschließend wird die endgültige Distanzkarte durch eine Verfeinerung der vorläufigen Werte unter Berücksichtigung der diagonalen Distanzen erstellt. Dieser Ansatz ermöglicht eine effiziente Berechnung der Distanztransformation mit linearer Zeitkomplexität.

Die Distanztransformation wird häufig als Vorverarbeitungsschritt für komplexere Bildverarbeitungsaufgaben eingesetzt. Sie kann z.B. dazu verwendet werden, Marker für die Wasserscheidentransformation zu generieren oder als Grundlage für die Skelettierung von Objekten zu dienen (Saha et al., 2015). In der Segmentierung hilft sie bei der genauen Trennung von Objekten und der Definition ihrer Grenzen.

Die Distanztransformation stellt insgesamt eine leistungsfähige Technik in der Bildverarbeitung dar, die sich durch eine Vielzahl anwendungsspezifischer Möglichkeiten auszeichnet. Die Berechnung von Distanzwerten erlaubt die Gewinnung wichtiger Informationen bezüglich der Geometrie und Morphologie von Objekten. Die Distanztransformation zeichnet sich durch ihre Effizienz, Robustheit und Flexibilität aus und stellt somit ein wertvolles Werkzeug für die Analyse und Charakterisierung von Bilddaten

in verschiedenen Bereichen dar, darunter die Materialwissenschaft und die mikroskopische Bildanalyse.

### **2.5.6 Anwendungen von Computer Vision in der Materialwissenschaft**

Computer Vision hat in den letzten Jahren zunehmend Einzug in die Materialwissenschaft gehalten und eröffnet neue Möglichkeiten für die Charakterisierung, Analyse und Qualitätskontrolle von Materialien. Die automatisierte Bildverarbeitung und -analyse ermöglicht es, komplexe Materialstrukturen und -eigenschaften effizient und objektiv zu erfassen und zu quantifizieren (Cheng et al., 2021).

Eine wichtige Anwendung von Computer Vision in der Materialwissenschaft ist die Charakterisierung der Mikrostruktur von Werkstoffen. Mithilfe von mikroskopischen Aufnahmen und Bildverarbeitungsalgorithmen können Korngrößen, Phasenverteilungen und Defekte automatisch detektiert und vermessen werden (DeCost et al., 2017). Dies ermöglicht eine schnelle und reproduzierbare Analyse im Vergleich zu manuellen Methoden und erlaubt die Verarbeitung großer Datenmengen.

Auch bei der zerstörungsfreien Prüfung von Materialien kommt Computer Vision zum Einsatz. Bildgebende Verfahren wie die Röntgen-Computertomographie (CT) oder die Ultraschallprüfung liefern detaillierte Informationen über das Innere von Bauteilen. Durch den Einsatz von Bildverarbeitungs- und Segmentierungsalgorithmen können Defekte wie Risse, Poren oder Einschlüsse automatisch erkannt und charakterisiert werden (Yoon et al., 2022). Dies ermöglicht eine effiziente Qualitätskontrolle und Schadensanalyse.

Ein weiteres Anwendungsfeld ist die Überwachung von Herstellungsprozessen mithilfe von Computer Vision. Durch die Analyse von Kamerabildern können Prozessparameter wie Temperaturverteilungen oder Materialflüsse in Echtzeit überwacht und gesteuert werden (Stavropoulos et al., 2020). Anomalien oder Abweichungen vom Sollzustand können so frühzeitig erkannt und korrigiert werden, was zu einer verbesserten Prozessstabilität und Produktqualität führt.

Darüber hinaus eröffnet die Kombination von Computer Vision mit maschinellem Lernen neue Möglichkeiten für die datengetriebene Materialentwicklung. Durch die Analyse großer Mengen an Bilddaten und deren Verknüpfung mit Materialeigenschaften können Vorhersagemodelle trainiert werden, die eine gezielte Optimierung von Materialzusammensetzungen und -strukturen ermöglichen (DeCost et al., 2019). Dies beschleunigt die Entwicklung neuer Materialien mit maßgeschneiderten Eigenschaften.

Insgesamt zeigt sich, dass Computer Vision zu einem unverzichtbaren Werkzeug in der modernen Materialwissenschaft geworden ist. Die automatisierte Bildanalyse ermöglicht eine effiziente Charakterisierung, Prüfung und Überwachung von Materialien und trägt so maßgeblich zum Fortschritt in diesem Forschungsgebiet bei.

## **2.6 Ansätze des maschinellen Lernens und Deep Learning zur automatisierten Bildanalyse**

Maschinelles Lernen (ML) ist ein Teilgebiet der künstlichen Intelligenz, das sich mit der Entwicklung von Algorithmen und statistischen Modellen befasst, die es Computersystemen ermöglichen, Aufgaben zu erledigen, ohne dafür explizit programmiert zu werden. Stattdessen lernen sie aus Erfahrung und verbessern ihre Leistung mit zunehmender Datenmenge. ML-Techniken haben in den letzten Jahren enorme Fortschritte gemacht und werden in einer Vielzahl von Bereichen eingesetzt, darunter Bildverarbeitung, Spracherkennung, Empfehlungssysteme und autonomes Fahren.

### **2.6.1 Einführung in maschinelles Lernen**

Die Grundidee des maschinellen Lernens besteht darin, dass ein System anhand von Beispieldaten lernt, anstatt explizit programmiert zu werden. Das System erkennt Muster und Gesetzmäßigkeiten in den Daten und verallgemeinert diese, um Vorhersagen oder Entscheidungen für neue, noch nicht gesehene Daten zu treffen (Goodfellow et al., 2016). Je nach Art der Lernaufgabe und der verfügbaren Daten können verschiedene Ansätze des maschinellen Lernens unterschieden werden:

- i. Überwachtes Lernen (Supervised Learning): Beim überwachten Lernen werden dem System Eingabedaten zusammen mit den gewünschten Ausgaben (Labels) präsentiert. Ziel ist es, eine Funktion zu erlernen, die die Eingaben auf die richtigen Ausgaben abbildet. Beispiele für überwachtes Lernen sind Klassifikations- und Regressionsaufgaben (Goodfellow et al., 2016).
- ii. Unüberwachtes Lernen (Unsupervised Learning): Beim unüberwachten Lernen erhält das System nur Eingabedaten ohne zugehörige Labels. Ziel ist es, verborgene Strukturen oder Zusammenhänge in den Daten zu entdecken, z.B. durch Clustering oder Dimensionsreduktion (Goodfellow et al., 2016).
- iii. Bestärkendes Lernen (Reinforcement Learning): Beim Reinforcement Learning interagiert ein Agent mit einer Umgebung und erhält für seine Aktionen

Belohnungen oder Bestrafungen. Ziel ist es, eine Strategie zu erlernen, die die kumulative Belohnung über die Zeit maximiert (Sutton & Barto, 2014).

Abbildung 10 gibt einen Überblick über Ansätze der maschinellen Intelligenz mit Anwendungsbeispielen.

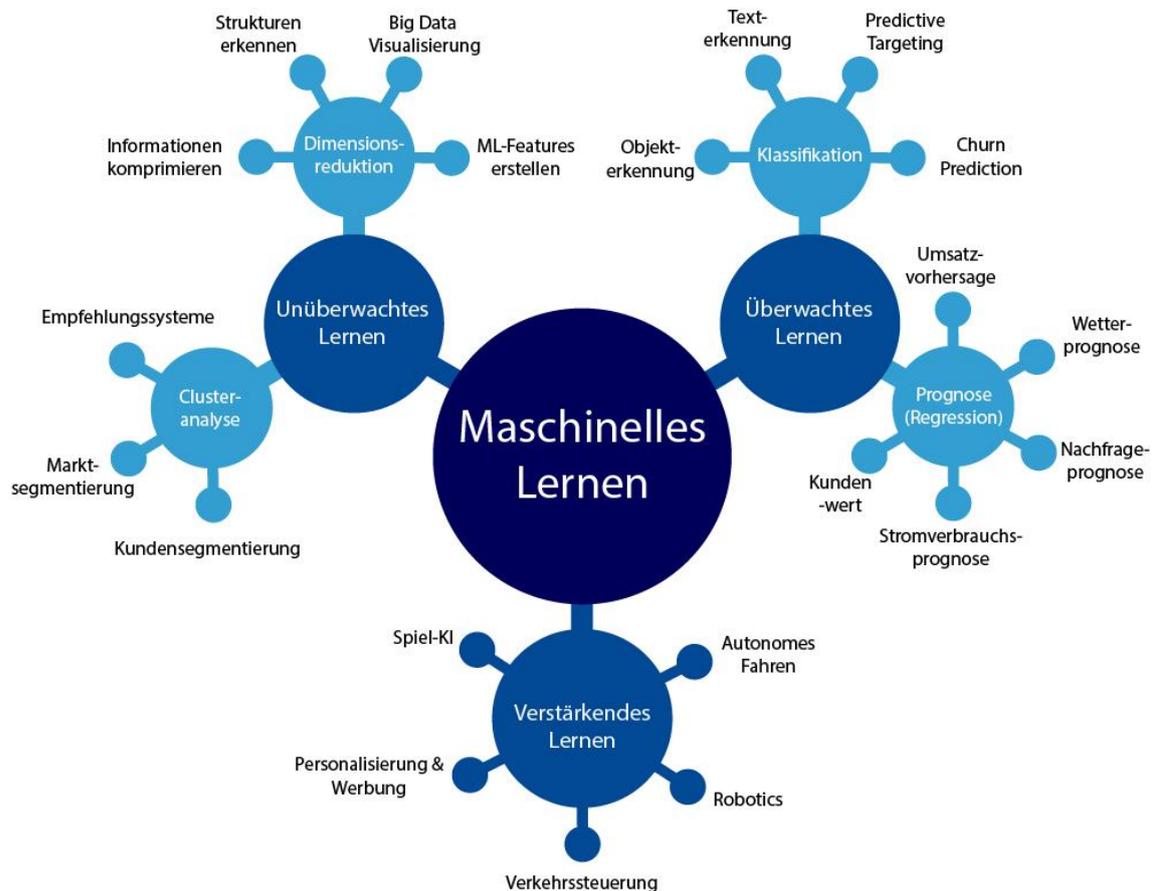


Abbildung 10: Überblick über Ansätze der maschinellen Intelligenz mit Anwendungsbeispielen (Wutke, 2023).

Die Wahl des geeigneten ML-Ansatzes hängt von der spezifischen Aufgabenstellung und der Verfügbarkeit von annotierten Trainingsdaten ab. In vielen praktischen Anwendungen der Bildverarbeitung hat sich das überwachte Lernen als besonders effektiv erwiesen, insbesondere durch den Einsatz tiefer neuronaler Netze (Goodfellow et al., 2016).

Ein wesentlicher Aspekt des maschinellen Lernens ist die Fähigkeit zur Generalisierung, also die Kompetenz, aus den Trainingsdaten zu lernen und dieses Wissen auf neue, bisher nicht beobachtete Daten anzuwenden. Um eine angemessene Generalisierung zu erreichen, müssen ML-Modelle ausreichend komplex sein und mit repräsentativen Daten trainiert werden. Modelle, die zu komplex sind, neigen dazu, die Trainingsdaten auswendig zu lernen,

was als Overfitting bezeichnet wird. Hingegen können zu einfache Modelle die zugrunde liegenden Muster nicht vollständig erfassen, was als Underfitting bekannt ist (Goodfellow et al., 2016).

### **2.6.2 Einführung in Deep Learning**

Deep Learning (DL) ist ein Teilgebiet des maschinellen Lernens, das in den letzten Jahren enorme Fortschritte gemacht hat und zu einem der wichtigsten Werkzeuge in der Bildverarbeitung und Mustererkennung geworden ist. DL-Algorithmen basieren auf künstlichen neuronalen Netzen mit vielen Schichten (Deep Networks), die in der Lage sind, komplexe Muster und Hierarchien in Daten zu erkennen und zu lernen (Szeliski, 2022).

Im Gegensatz zu traditionellen Ansätzen des maschinellen Lernens, bei denen Merkmale oft manuell entwickelt werden müssen, können DL-Modelle hierarchische Darstellungen automatisch aus Rohdaten lernen. Diese Fähigkeit macht DL besonders geeignet für die Verarbeitung hochdimensionaler und komplexer Daten wie Bilder, Audio und Video (LeCun et al., 2015).

Die Grundbausteine von DL-Modellen sind künstliche Neuronen, die in Schichten organisiert sind. Jedes Neuron berechnet eine gewichtete Summe seiner Eingaben und wendet dann eine nichtlineare Aktivierungsfunktion an, um seine Ausgabe zu berechnen. Durch Anpassung der Gewichte während des Trainings können die Neuronen lernen, relevante Merkmale zu extrahieren und zu kombinieren (Goodfellow et al., 2016).

Ein Schlüsselfaktor für den Erfolg von DL ist die Verfügbarkeit großer annotierter Datensätze und leistungsfähiger Hardware, insbesondere von Grafikprozessoren (GPUs). GPUs ermöglichen die parallele Verarbeitung von Millionen von Parametern und beschleunigen damit das Training von DL-Modellen erheblich (Goodfellow et al., 2016).

Trotz ihrer beeindruckenden Leistungsfähigkeit bringen DL-Modelle auch einige Herausforderungen mit sich. Dazu gehören die Interpretierbarkeit der gelernten Merkmale, die Robustheit gegenüber Angriffen und die Generalisierbarkeit auf Daten außerhalb der Trainingsverteilung (Szegedy et al., 2013). Aktuelle Forschungsarbeiten zielen darauf ab, diese Herausforderungen durch Techniken wie Transferlernen, Datenanreicherung und Regularisierung zu überwinden.

### **2.6.3 Convolutional Neural Networks (CNNs)**

Convolutional Neural Networks (CNNs) sind eine besondere Art von tiefen neuronalen Netzen, die speziell für die Verarbeitung von Bilddaten entwickelt wurden. Sie haben sich als äußerst effektiv für Aufgaben wie Bildklassifikation, Objekterkennung und Segmentierung erwiesen. CNNs nutzen die räumliche Struktur von Bildern durch die Anwendung von Faltungsoperationen (Convolutions), die lokalen Merkmale extrahieren und invariant gegenüber Translationen sind (Gu et al., 2017).

Die Abbildung 11 veranschaulicht die Funktionsweise eines Convolutional Neural Network am Beispiel der Erkennung handschriftlicher Ziffern. Die Architektur eines typischen CNN besteht aus mehreren Schichten (Gu et al., 2017):

- 1) Convolutional Layers (Faltungsschichten): Diese Schichten führen die Faltungsoperationen durch, indem sie einen Satz von Filtern (auch Kernel genannt) über das Eingabebild legen. Jeder Filter extrahiert bestimmte lokale Merkmale wie Kanten, Ecken oder Texturen. Die Ausgabe einer Faltungsschicht ist eine Merkmalskarte, die die Antworten der Filter an jeder Position im Bild darstellt.
- 2) Activation Functions (Aktivierungsfunktionen): Nach jeder Faltungsschicht wird eine nichtlineare Aktivierungsfunktion wie die Rectified Linear Unit (ReLU) angewendet, um Nichtlinearitäten in das Netzwerk einzuführen und die Aussagekraft des Modells zu erhöhen.
- 3) Pooling Layers: Pooling Layers reduzieren die räumliche Größe der Merkmalskarten, indem benachbarte Pixel zusammengefasst werden. Dies hilft, die Berechnungskomplexität zu reduzieren und eine gewisse Invarianz gegenüber kleinen Translationen und Verzerrungen zu erreichen. Die am häufigsten verwendete Pooling-Operation ist das Max-Pooling, bei dem das Maximum innerhalb eines lokalen Fensters ausgewählt wird.
- 4) Fully Connected Layers (Vollständig verbundene Schichten): Nach mehreren Faltungs- und Pooling-Schichten werden die resultierenden Merkmalskarten abgeflacht und an vollständig verbundene Schichten weitergeleitet. Diese Schichten führen die eigentliche Klassifikation oder Regression auf Basis der extrahierten Merkmale durch.

Ein wesentliches Merkmal von CNNs ist ihre Fähigkeit, hierarchische Merkmalsdarstellungen zu lernen. Frühe Schichten erfassen einfache, lokale Muster wie Kanten und Farben, während spätere Schichten komplexere und abstraktere Merkmale wie Objektteile oder ganze Objekte lernen. Diese hierarchische Struktur ermöglicht es CNNs,

robuste und diskriminierende Merkmale direkt aus den Rohdaten zu lernen, ohne dass eine manuelle Merkmalsextraktion notwendig ist (LeCun et al., 2015).

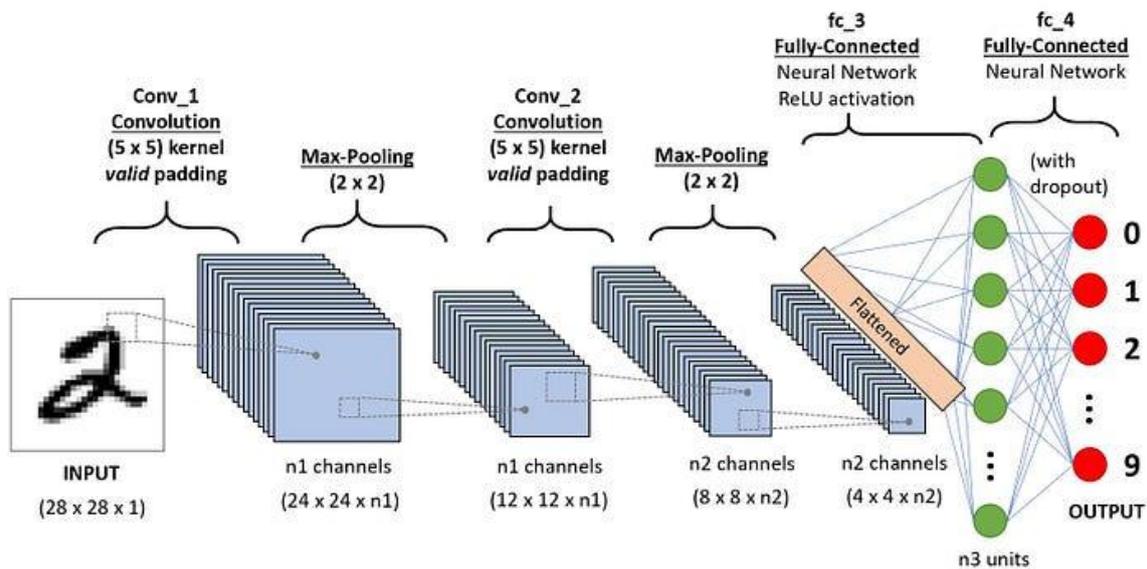


Abbildung 11: Convolutional Neural Network am Beispiel der Erkennung einer handschriftlichen Ziffer (Ramiah, 2021).

CNNs haben in vielen Bereichen der Bildverarbeitung, von der medizinischen Bildgebung bis hin zur autonomen Fahrzeugnavigation, beeindruckende Ergebnisse erzielt. Mit der kontinuierlichen Weiterentwicklung von CNN-Architekturen und Trainingsmethoden ist zu erwarten, dass sie auch in Zukunft eine zentrale Rolle in der Bildanalyse spielen werden (LeCun et al., 2015).

#### 2.6.4 Region-basierte Convolutional Neural Networks (R-CNN)

Region-basierte Convolutional Neural Networks (R-CNN) stellen einen bedeutenden Fortschritt in der Objekterkennung dar, indem sie die Stärken von Region Proposal Methoden und Convolutional Neural Networks (CNNs) kombinieren. Das von Girshick et al. (2013) entwickelte R-CNN-Verfahren zielt darauf ab, Objekte in Bildern präzise zu lokalisieren und zu klassifizieren.

Der R-CNN-Algorithmus durchläuft mehrere Schritte (siehe Abbildung 12): Zunächst werden potenzielle Objektregionen im Bild durch eine Region-Proposal-Methode wie Selective Search identifiziert. Diese Region-Proposals werden dann an ein vortrainiertes CNN weitergeleitet, das als Feature Extractor fungiert. Im Anschluss extrahiert das CNN Merkmale aus jeder Region, welche zur Klassifizierung der Objekte herangezogen werden.

Schließlich wird eine Bounding-Box-Regression durchgeführt, um die Genauigkeit der vorhergesagten Objektgrenzen zu verbessern (Girshick et al., 2013).

Ein wesentlicher Vorteil von R-CNN ist die Nutzung von Transfer Learning. Anstatt das CNN von Grund auf neu zu trainieren, wird ein auf großen Datensätzen wie ImageNet vortrainiertes Netzwerk verwendet. Das Fine-Tuning des vortrainierten CNNs auf den spezifischen Objekterkennungsdatensatz ermöglicht eine effektive Übertragung der gelernten Merkmale auf die neue Aufgabe, wodurch der Bedarf an annotierten Trainingsdaten reduziert und der Trainingsprozess beschleunigt wird (Girshick et al., 2013).

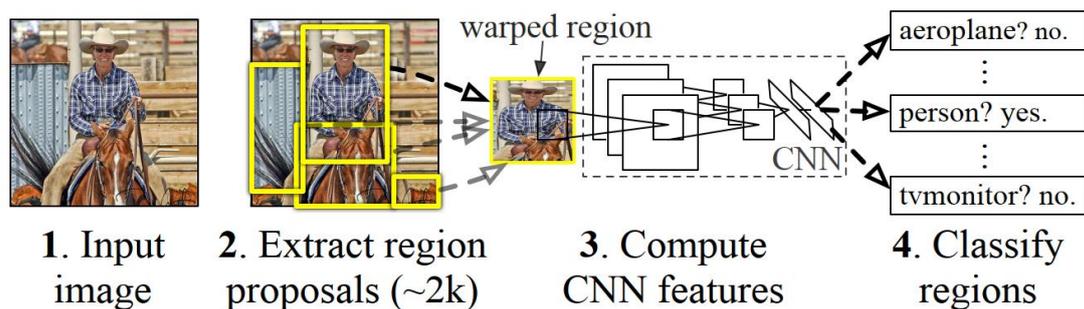


Abbildung 12: Übersicht über das R-CNN-System zur Objekterkennung (Girshick et al., 2013).

Obgleich R-CNN eine beachtliche Leistung erbringt, sind dennoch gewisse Einschränkungen zu vermerken. Die Generierung der Region Proposals und die Feature Extraction für jede Region sind mit einem hohen Rechenaufwand und einer entsprechend langen Inferenzzeit verbunden (Girshick et al., 2013). Diese Einschränkungen machen R-CNN für Echtzeitanwendungen weniger geeignet. Des Weiteren erfolgt die Feature Extraction für jede Region separat, was zu redundanten Berechnungen führt.

Die Limitierungen von R-CNN haben zur Entwicklung effizienterer Modelle geführt, welche die zuvor genannten Nachteile überwinden. Fast R-CNN und Faster R-CNN bauen auf den Konzepten von R-CNN auf und bieten verbesserte Architekturen, die zu einer Erhöhung der Geschwindigkeit und Genauigkeit der Objekterkennung führen (Girshick, 2015; Ren et al., 2015). Im Rahmen der Weiterentwicklung von R-CNN wurden die Schritte der Region Proposal und Feature Extraction integriert, während Faster R-CNN ein Region Proposal Network (RPN) einführte, welches die Region Proposals direkt im CNN generiert (Ren et al., 2015).

## 2.6.5 Training und Validierung von Modellen

Die Trainings- und Validierungsprozesse von Modellen stellen wesentliche Schritte in der Entwicklung leistungsfähiger maschineller Lernsysteme dar. Diese Prozesse gewährleisten,

dass ein Modell nicht nur die Trainingsdaten korrekt erfasst, sondern auch auf unbekannte Daten verallgemeinern kann. Im Kontext der Bildverarbeitung sind diese Schritte von entscheidender Bedeutung, um verlässliche und reproduzierbare Resultate zu erzielen.

Der Trainingsprozess beginnt mit der Vorbereitung der Daten. Die verfügbaren Daten werden typischerweise in Trainings-, Validierungs- und Testdatensätze aufgeteilt. Der Trainingsdatensatz dient dazu, das Modell zu trainieren und die Modellparameter anzupassen. Der Validierungsdatensatz wird verwendet, um die Leistung des Modells während des Trainings zu überwachen und eine Überanpassung (Overfitting) zu vermeiden. Der Testdatensatz wird schließlich verwendet, um die Leistung des trainierten Modells auf ungesehenen Daten zu bewerten (Raschka & Mirjalili, 2017).

Während des Trainings werden die Modellparameter iterativ angepasst, um die Verlustfunktion (Loss Function) zu minimieren. Die Verlustfunktion quantifiziert den Unterschied zwischen den vorhergesagten und den tatsächlichen Werten. Gängige Verlustfunktionen sind beispielsweise der mittlere quadratische Fehler (Mean Squared Error, MSE) für Regressionsprobleme oder die Kreuzentropie (Cross-Entropy) für Klassifikationsaufgaben (Goodfellow et al., 2016). Durch die Minimierung der Verlustfunktion lernt das Modell, die Zusammenhänge in den Daten zu erfassen und bessere Vorhersagen zu treffen.

Ein wichtiger Aspekt beim Training von Modellen ist die Wahl der Hyperparameter. Hyperparameter sind Einstellungen, die vor dem Training festgelegt werden und die Architektur und das Verhalten des Modells bestimmen. Beispiele für Hyperparameter sind die Anzahl der Schichten in einem neuronalen Netz, die Anzahl der Neuronen pro Schicht, die Lernrate und die Batch-Größe. Die Optimierung der Hyperparameter erfolgt oft durch eine systematische Suche oder durch Techniken wie die Kreuzvalidierung (Cross-Validation), bei der der Trainingsdatensatz in mehrere Teilmengen unterteilt wird, um verschiedene Hyperparameterkonfigurationen zu bewerten (Goodfellow et al., 2016).

Die Validierung erfolgt parallel zum Training und dient dazu, die Leistung des Modells auf einem separaten Datensatz zu bewerten, der nicht im Training verwendet wurde. Dieser Validierungsdatensatz hilft dabei, die Verallgemeinerungsfähigkeit des Modells zu überprüfen und sicherzustellen, dass es nicht nur die Trainingsdaten auswendig gelernt hat.

Während des Validierungsprozesses werden verschiedene Metriken wie Genauigkeit, Präzision und F-Score berechnet. Diese Metriken bieten Einblicke in die Stärken und

Schwächen des Modells (Sokolova & Lapalme, 2009). Eine häufig verwendete Technik zur Verbesserung der Modellleistung ist das Cross-Validation-Verfahren, bei dem der gesamte Datensatz in mehrere Teilmengen aufgeteilt wird. Das Modell wird dann mehrmals trainiert und validiert, wobei jedes Mal eine andere Teilmenge als Validierungsdatsatz verwendet wird (Goodfellow et al., 2016).

Eine der größten Herausforderungen beim Training und bei der Validierung von Modellen ist das Risiko der Überanpassung. Dies tritt auf, wenn ein Modell zu stark an den Trainingsdaten angepasst wird und seine Leistung auf neuen Daten abnimmt. Um dies zu vermeiden, können Techniken wie Regularisierung, Dropout oder Dataaugmentation eingesetzt werden (Srivastava et al., 2014).

Nach Abschluss des Trainings wird das Modell auf dem Testdatensatz evaluiert, um seine Leistung auf ungesehenen Daten zu bewerten. Gängige Evaluierungsmetriken sind beispielsweise die Genauigkeit (Accuracy), die Präzision (Precision), der Recall und die F-Score für Klassifikationsaufgaben sowie der mittlere absolute Fehler (Mean Absolute Error, MAE) und der mittlere quadratische Fehler (Mean Squared Error, MSE) für Regressionsaufgaben (Raschka & Mirjalili, 2017). Die Evaluierung auf dem Testdatensatz gibt Aufschluss darüber, wie gut das Modell in der Lage ist, auf neuen, ungesehenen Daten zu generalisieren.

Ein weiterer wichtiger Aspekt ist die Qualität und Quantität der Daten. Ein gut kuratierter Datensatz mit ausreichender Vielfalt ist entscheidend für das erfolgreiche Training eines Modells. Zudem sollte sichergestellt werden, dass die Daten korrekt annotiert sind, um eine präzise Überwachung des Lernprozesses zu ermöglichen (Goodfellow et al., 2016).

Die Prozesse der Modellierung und deren Verifizierung sind in ihrer Gesamtheit als komplex zu bezeichnen, was eine präzise Planung sowie eine sorgfältige Umsetzung erforderlich macht. Der Einsatz bewährter Methoden ermöglicht die Entwicklung robuster Modelle, welche in der Lage sind, komplexe Aufgaben in verschiedenen Anwendungsbereichen mit hoher Zuverlässigkeit zu lösen.

### **2.6.6 Detectron2 Framework**

Detectron2 ist ein leistungsfähiges, flexibles und benutzerfreundliches Framework für die Objekterkennung und -segmentierung, das von Facebook AI Research (FAIR) entwickelt wurde. Es baut auf den Erfahrungen und Erkenntnissen des ursprünglichen Detectron-Frameworks auf und bietet eine Reihe von Verbesserungen und Erweiterungen

(Facebookresearch, o. D.). Detectron2 ist in PyTorch implementiert und unterstützt eine Vielzahl von state-of-the-art Modellen für die Objekterkennung, Instanzsegmentierung und semantische Segmentierung.

Ein wesentlicher Vorteil von Detectron2 ist die Bereitstellung einer umfangreichen Modellbibliothek, die es Entwicklern ermöglicht, schnell und einfach verschiedene Architekturen zu testen und zu vergleichen. Die Bibliothek umfasst bekannte Modelle wie Faster R-CNN Mask R-CNN und RetinaNet, die für unterschiedliche Anwendungsfälle optimiert sind. Darüber hinaus bietet Detectron2 die Möglichkeit, benutzerdefinierte Modelle zu implementieren und nahtlos in das Framework zu integrieren (Detectron2, o. D.).

Detectron2 nutzt die Vorteile von Transfer Learning, indem es vortrainierte Modelle bereitstellt, die auf großen Datensätzen wie COCO oder ImageNet trainiert wurden. Diese vortrainierten Modelle können als Ausgangspunkt für spezifische Anwendungen verwendet werden, was die Trainingszeit verkürzt und die Notwendigkeit großer Mengen an annotierten Daten reduziert (He et al., 2017). Durch Feinabstimmung dieser Modelle auf spezifische Datensätze können Entwickler schnell leistungsfähige Lösungen entwickeln.

Ein weiterer Vorteil von Detectron2 ist seine Fähigkeit zur Echtzeitverarbeitung von Bildern. Durch den Einsatz effizienter Algorithmen und Datenstrukturen kann das Framework Bilder in hoher Geschwindigkeit verarbeiten, was es ideal für Anwendungen macht, bei denen schnelle Reaktionszeiten erforderlich sind (Boesch, 2024). Dies ist besonders relevant in Bereichen wie der autonomen Fahrzeugtechnik oder der industriellen Automatisierung.

Ein wesentlicher Vorteil von Detectron2 besteht in der nahtlosen Integration mit anderen PyTorch-basierten Tools und Bibliotheken. Dies ermöglicht den Nutzern, von den umfangreichen Ressourcen und der aktiven Community rund um PyTorch zu profitieren. Detectron2 ist eng mit der PyTorch-Bibliothek verwoben und nutzt deren Funktionen und Datenstrukturen, um eine effiziente Verarbeitung und Optimierung zu ermöglichen (Pham, 2023).

Die Konfiguration von Modellen und Trainingsparametern erfolgt in Detectron2 über konfigurierbare Einstellungen, die in YAML-Dateien definiert werden (Detectron2 Documentation, o. D.). Benutzer können verschiedene Aspekte wie Backbone-Architekturen, Hyperparameter, Augmentierungstechniken und Verlustfunktionen über die Konfigurationsdateien steuern (Boesch, 2024).

Ein Nachteil von Detectron2 ist die Komplexität des Frameworks, insbesondere für Einsteiger. Aufgrund der Vielzahl von Funktionen und Konfigurationsmöglichkeiten kann die Einarbeitung in Detectron2 eine Herausforderung darstellen. Es erfordert ein gutes Verständnis von Deep Learning, Computer Vision und PyTorch, um das Framework effektiv zu nutzen und anzupassen.

Insgesamt stellt Detectron2 ein leistungsfähiges und flexibles Framework für die Objekterkennung und -segmentierung dar, welches eine breite Palette von Modellen und Funktionen bereitstellt. Es ermöglicht Forschern und Praktikern, zeitnah und effektiv aktuelle Modelle zu trainieren, anzupassen und einzusetzen. Aufgrund seiner modularen Architektur, seiner Möglichkeiten zur Erweiterung sowie seiner Integration mit PyTorch stellt Detectron2 ein wertvolles Werkzeug für die Entwicklung fortschrittlicher Computer-Vision-Anwendungen dar.

### **3 KONZEPTION DES KI-GESTÜTZTEN ANALYSETOOLS**

Im vorliegenden Kapitel erfolgt eine detaillierte Beschreibung der Entwicklung eines KI-gestützten Analysetools zur automatischen Erkennung, Vermessung von Zellen und Bestimmung der Zellwanddicken in Polyurethan-Hartschaumproben. Das Ziel dieses Kapitels besteht in der Erläuterung der methodischen Ansätze und technologischen Implementierungen, welche zur Optimierung der Qualitätsprüfung von Fernwärmedämmstoffen beitragen.

Zunächst wird die Bildakquisition mittels 3D-Röntgenmikroskopie erläutert, welche die Grundlage für die Entwicklung des Tools bildet. Die hochauflösenden Aufnahmen der PUR-Hartschaumproben ermöglichen eine detaillierte Erfassung der inneren Struktur und dienen als Ausgangspunkt für die nachfolgenden Bildverarbeitungsschritte.

Im Anschluss werden die klassischen Bildverarbeitungstechniken zur Charakterisierung der PUR-Dämmstoffstruktur beschrieben. Dieser Abschnitt umfasst die Vorverarbeitung der Bilder, die Segmentierung der Zellen mittels Schwellenwertverfahren und Wasserscheidentransformation sowie die Analyse der Zellmorphologie durch Konturenerkennung und morphologische Operationen. Die Implementierung dieser Methoden in Python unter Verwendung der OpenCV Bibliothek wird detailliert erläutert.

Neben den klassischen Bildverarbeitungsmethoden wird auch der Einsatz von Deep Learning zur Analyse der PUR-Hartschaumproben untersucht. Mithilfe des Detectron2-Frameworks werden Verfahren des maschinellen Lernens auf die Bilddaten angewendet, um eine automatisierte Segmentierung und Klassifizierung der Zellen zu erreichen. Die Vorgehensweise bei der Datenaufbereitung, der Auswahl geeigneter Modellarchitekturen und der Durchführung des Trainings wird ausführlich beschrieben.

#### **3.1 Bildakquisition von Polyurethan-Hartschaumproben**

Die Grundlage für die Entwicklung des KI-gestützten Analysetools bildet die Akquisition hochauflösender Bilder der PUR-Hartschaumproben. Für die zerstörungsfreie Erfassung der inneren Struktur der Proben wurde die 3D-Röntgenmikroskopie (XRM) eingesetzt. Konkret kam das Gerät SKYSCAN 2214 CMOS Edition der Firma Bruker zum Einsatz (siehe Abbildung 13). Das hochmoderne XRM-System ermöglicht die Erstellung detaillierter dreidimensionaler Aufnahmen mit einer Auflösung im Submikrometerbereich (SKYSCAN 2214, o. D.).

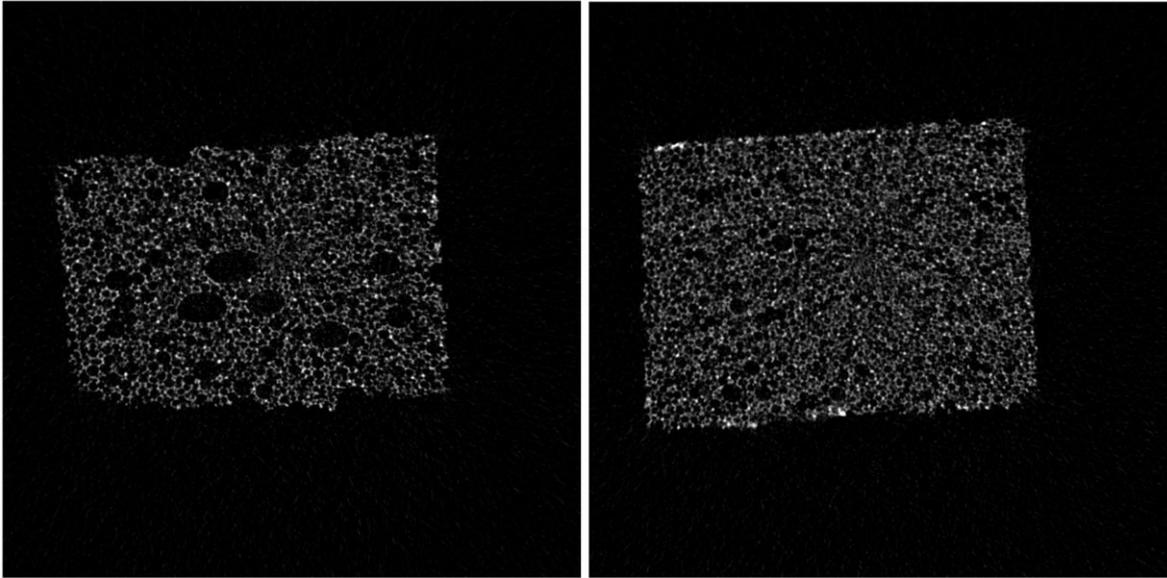


*Abbildung 13: Röntgenmikroskop SKYSCAN 2214 CMOS (SKYSCAN 2214, o. D.)*

Die untersuchte Probe aus Polyurethan-Dämmung von Fernwärmeleitungen wiesen eine Größe von ca. 15 mm x 10 mm x 60 mm auf. Zur vollständigen Erfassung der inneren Struktur wurde die Probe schichtweise gescannt, wobei jedes Bild eine einzelne Schicht repräsentiert.

Der Scanvorgang umfasste die schichtweise Durchleuchtung der PUR-Probe, wodurch insgesamt 1.242 Einzelbilder generiert wurden. Jedes dieser Bilder repräsentiert eine Schnittebene der Probe mit einer Dicke von wenigen Mikrometern, was eine äußerst detaillierte Darstellung der inneren Struktur ermöglicht. Die Aneinanderreihung der Schnittbilder ermöglicht eine virtuelle dreidimensionale Rekonstruktion, die eine umfassende Analyse der räumlichen Struktur der Probe erlaubt. Abbildung 14 präsentiert eine exemplarische Schnittaufnahme aus dem akquirierten Bilddatensatz, die zeigt, wie fein die Zellstruktur und Porenverteilung sichtbar gemacht werden können.

Im Vergleich zu herkömmlichen optischen Methoden bietet die Röntgenmikroskopie den Vorteil, dass die dreidimensionale Mikrostruktur der Probe zerstörungsfrei analysiert werden kann. Die Erfassung einer Vielzahl von Schichtbildern erlaubt die Untersuchung der räumlichen Verteilung von Poren, Zellen und anderen Strukturmerkmalen im gesamten Probenvolumen.



*Abbildung 14: Röntgenmikroskopische Aufnahme der PUR-Dämmstoffprobe (Eigene Darstellung)*

Die 3D-Röntgenmikroskopie erweist sich insgesamt als eine leistungsfähige Methode zur Charakterisierung der komplexen Mikrostruktur von PUR-Hartschäumen. Die gewonnenen Schichtbilder stellen die Grundlage für die nachfolgenden Schritte der Bildverarbeitung und -analyse im Rahmen der Entwicklung des KI-gestützten Analysetools dar.

### **3.2 Bildverarbeitung zur Analyse der Struktur von Polyurethan-Dämmstoffen**

Im Folgenden wird die Anwendung klassischer Bildverarbeitungstechniken zur Charakterisierung der Struktur von Polyurethan-Hartschaumdämmstoffen erörtert. Die Bildverarbeitung bildet die Grundlage für die automatisierte Quantifizierung relevanter Strukturparameter, zu denen unter anderem die Zellgröße und die Zellwanddicke zählen.

Der Prozess startet mit der Bildvorbereitung, bei der der Hintergrund entfernt wird, um den relevanten Bereich für die Analyse zu isolieren. Die Segmentierung der Zellstrukturen erfolgt durch eine Kombination aus Schwellenwertverfahren und fortschrittlichen Algorithmen wie der Wasserscheidentransformation. Die genannten Methoden erlauben eine effektive Trennung und Identifizierung einzelner Zellen, selbst in komplexen Proben mit überlappenden Strukturen. Im Anschluss werden die gewonnenen Daten genutzt, um die geometrischen Eigenschaften der Zellen zu analysieren und zu visualisieren. Die folgenden Unterkapitel erläutern die spezifischen Schritte des Bildverarbeitungsprozesses, von der Vorbereitung und Binarisierung bis hin zur Segmentierung und Quantifizierung der Zellstrukturen.

### 3.2.1 Bildvorbereitung - Hintergrund entfernen

Der erste Schritt in der Bildverarbeitungspipeline besteht in der Eliminierung des Hintergrunds aus den Aufnahmen der PUR-Probe, um ausschließlich den relevanten Bildbereich für die weitere Analyse zu erhalten. Da die Probe eine rechteckige Form aufweist, kann dies durch die Identifikation der äußeren Konturen erreicht werden.

In einem ersten Schritt wird das Bild im RGB-Farbraum eingelesen und in ein Graustufenbild konvertiert. Im Anschluss erfolgt eine Binarisierung des Bildes mittels eines Schwellenwertverfahrens, um die Kanten der Probe klar vom Hintergrund zu trennen. Im Anschluss werden die Konturen auf dem binarisierten Bild mit der OpenCV-Funktion `cv2.findContours()` detektiert.

Die größte Kontur wird ausgewählt und basierend auf der Bounding Box dieser Kontur wird ein zentrierter Ausschnitt definiert, der die Probe enthält, jedoch einen schmalen Rand des Hintergrunds ausschließt. Die Größe des Ausschnitts wird dynamisch angepasst, um Variationen in der Probengröße zu berücksichtigen.

Der definierte Bildausschnitt wird extrahiert, wodurch ein neues Bild entsteht, das ausschließlich des relevanten Bereichs der PUR-Probe zeigt. Dieses Bild dient als Grundlage für die weiteren Verarbeitungsschritte zur Charakterisierung der Schaumstruktur.

Um eine maßstabsgetreue Analyse zu ermöglichen, werden die Pixelkoordinaten des Ausschnitts in Millimeter umgerechnet. Dazu wird ein Umrechnungsfaktor von 0,025 mm/Pixel verwendet. Die Umrechnung von Pixeln in Millimeter erfolgte basierend auf der Auflösung der verwendeten Bilder von 1016 DPI (Dots per Inch). Ein Inch entspricht 25,4 Millimetern. Durch Division der Millimeter pro Inch durch die Pixel pro Inch erhält man die Größe eines Pixels in Millimetern. In diesem Fall ergibt sich:

$$1 \text{ Inch} = 25,4 \text{ mm}$$

$$1016 \text{ px} = 1 \text{ Inch}$$

$$1 \text{ px} = 25,4 \text{ mm} / 1016 = 0,025 \text{ mm}$$

Die Achsenbeschriftungen der Visualisierungen werden entsprechend angepasst, um die physikalischen Dimensionen korrekt darzustellen. Abbildung 15 veranschaulicht das Originalbild mit der automatisch erkannten Kontur des Probenbereichs, welche durch eine blaue Linie gekennzeichnet ist. Abbildung 16 zeigt das extrahierte Probenbild nach Zuschchnitt.

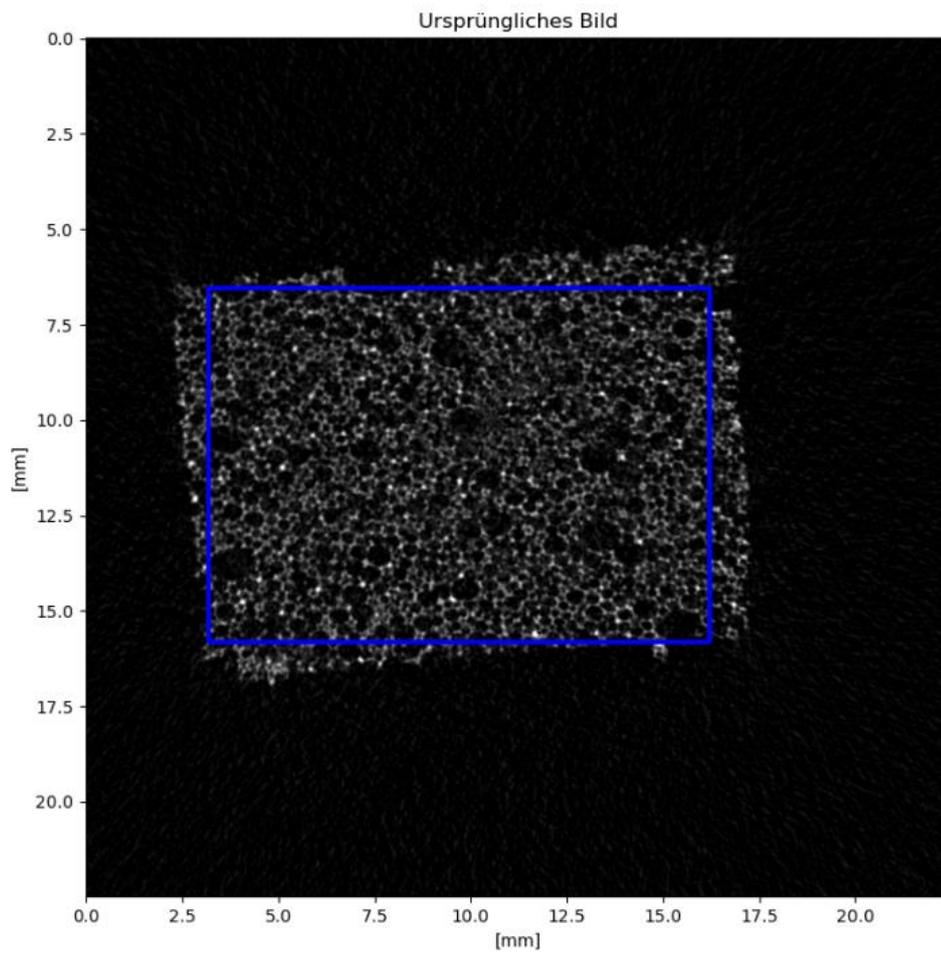


Abbildung 15: Das Originalbild mit der automatisch erkannten Kontur des Probenbereichs (Eigene Darstellung)

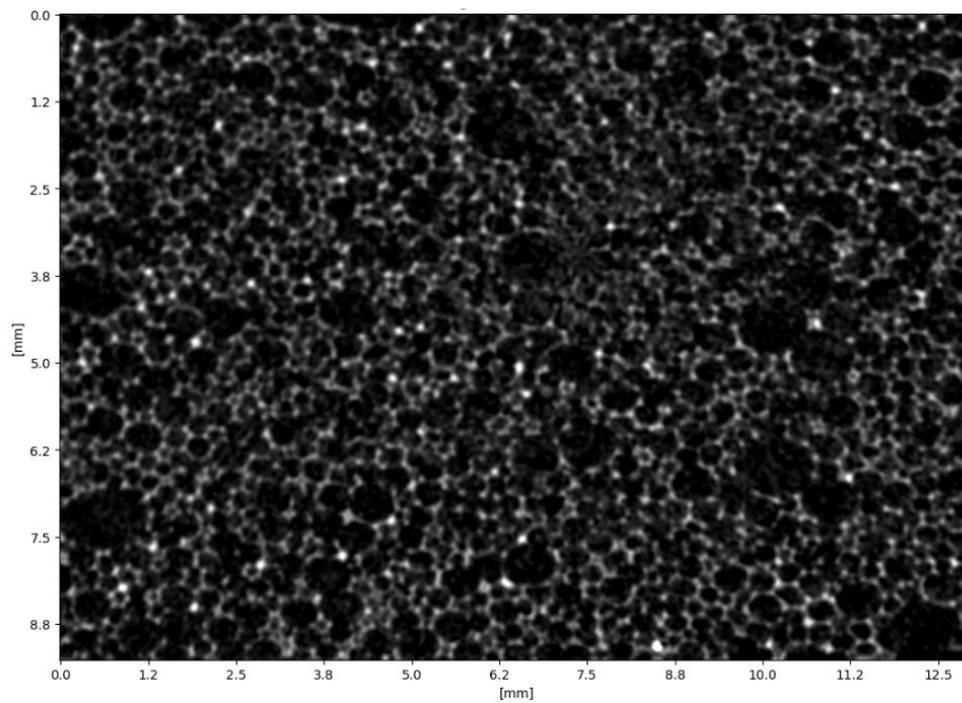


Abbildung 16: Das extrahierte Probenbild nach Zuschritt (Eigene Darstellung)

### 3.2.2 Binarisierung und Maskenerstellung

Im Anschluss an die erfolgreiche Extraktion des relevanten Bildausschnitts erfolgt die Umwandlung des Bildes in eine binäre Maske. Der folgende Schritt dient der Vorbereitung für die nachfolgende Segmentierung und Analyse der Zellstrukturen im PUR-Hartschaum.

Zunächst wird das ausgeschnittene RGB-Bild mittels der OpenCV-Funktion `cv2.cvtColor()` in ein Graustufenbild konvertiert. In diesem Schritt wird die Dimensionalität der Bilddaten von drei Farbkanälen auf einen Intensitätskanal reduziert, was die weitere Verarbeitung vereinfacht und beschleunigt.

Im Anschluss erfolgt die Binarisierung des Graustufenbildes durch Anwendung des Otsu-Schwellenwertverfahrens. Das adaptive Verfahren bestimmt automatisch einen optimalen Schwellenwert, der das Bild in Vordergrund (Zellen) und Hintergrund (Zellwände) unterteilt. Pixel mit Intensitätswerten oberhalb des Schwellenwerts werden dem Vordergrund zugeordnet und auf den Wert 255 (weiß) gesetzt, während Pixel unterhalb des Schwellenwerts dem Hintergrund zugeordnet und auf den Wert 0 (schwarz) gesetzt werden. Das Resultat ist ein Binärbild, welches die Zellen als weiße Objekte auf schwarzem Hintergrund darstellt.

Um die Zellen für die nachfolgenden Analyseschritte hervorzuheben, wird die binäre Maske invertiert. Die bitweise Negation mittels `cv2.bitwise_not()` bewirkt eine Änderung der Pixelwerte von 0 auf 255 bzw. von 255 auf 0. In der Konsequenz erscheinen die Zellen nun als weiße Objekte auf schwarzem Hintergrund. In Abbildung 17 wird eine binäre Maske präsentiert, die aus dem PUR-Dämmstoffbild in Abbildung 16 erstellt wurde.

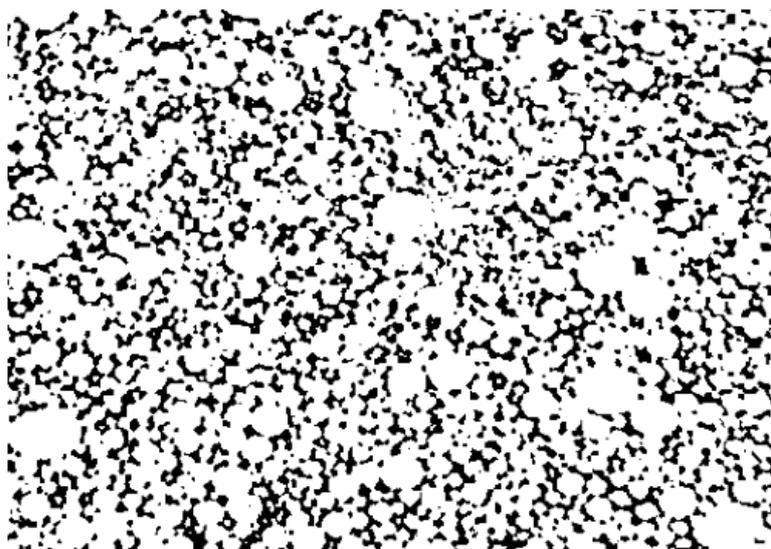


Abbildung 17: Binäre Maske des PUR-Dämmstoffbildes (Eigene Darstellung)

Die resultierende invertierte Binärmaske dient als Grundlage für die Segmentierung und Charakterisierung der einzelnen Zellen im PUR-Hartschaum. Die Reduktion der Bildinformationen auf eine binäre Darstellung ermöglicht die Anwendung effizienter Algorithmen zur Objekterkennung und -vermessung, wie in den folgenden Abschnitten beschrieben wird.

Die Visualisierung der erzeugten Binärmaske erfolgt unter Verwendung der Matplotlib-Bibliothek. Durch Setzen des `cmap`-Parameters auf „gray“ wird sichergestellt, dass das Bild in Graustufen dargestellt wird. Dabei entspricht der Wert 0 schwarz und der Wert 255 weiß. Die Unterdrückung der Achsenbeschriftungen mittels `plt.axis('off')` gewährleistet eine übersichtliche Darstellung der Binärmaske, wodurch ablenkende Elemente eliminiert werden.

### **3.2.3 Wasserscheidentransformation zur Zellsegmentierung**

Nach der erfolgreichen Binarisierung und Maskenerstellung wird die Binärmaske in ein ImageJ-Objekt konvertiert. ImageJ ist eine leistungsstarke Open-Source-Plattform für die Bildverarbeitung und -analyse, die eine Vielzahl von Plugins und Erweiterungen bietet. Die Integration von ImageJ in den Python-Workflow ermöglicht die nahtlose Einbindung fortgeschrittener Bildverarbeitungsalgorithmen in die Analysepipeline.

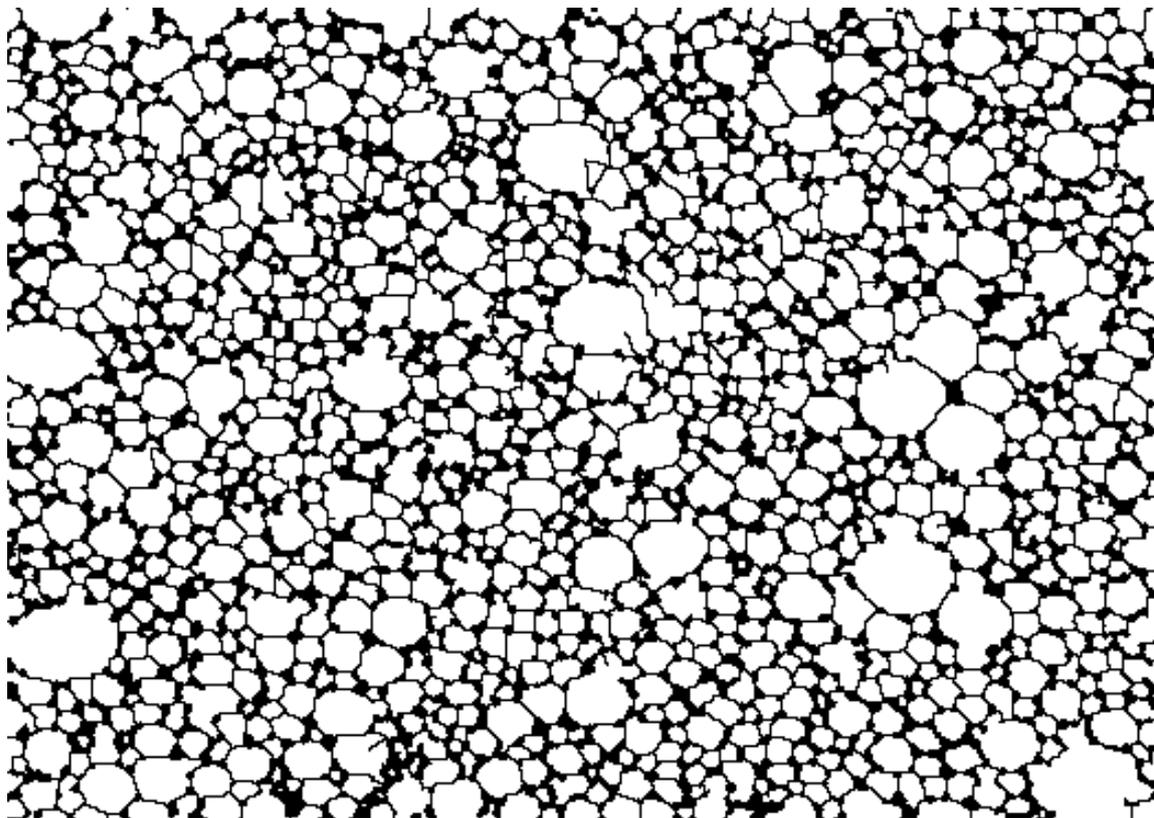
Ein zentraler Schritt in der Segmentierung der Zellen im PUR-Hartschaum ist die Anwendung der Wasserscheidentransformation (Watershed). Dieses morphologische Verfahren ermöglicht die Trennung sich berührender oder überlappender Objekte in einem Binärbild. Die Grundidee besteht darin, das Bild als topografische Oberfläche zu betrachten, bei der die Intensitätswerte die Höhe darstellen. Ausgehend von lokalen Minima (Markern) erfolgt eine schrittweise Flutung der Oberfläche, wobei an den Berührungspunkten der Regionen Wasserscheiden entstehen, welche die Objektgrenzen definieren.

Die Durchführung der Wasserscheidentransformation in ImageJ erfordert zunächst den Abruf des Prozessors des Binärbildes. Anschließend erfolgt die Implantation des Plugins „EDM“ (Euclidean Distance Map), welches die Berechnung der euklidischen Distanztransformation ermöglicht. Diese Transformation weist jedem Vordergrundpixel die Distanz zum nächstgelegenen Hintergrundpixel zu und generiert somit eine Grauwertdarstellung, welche als Eingabe für die Wasserscheidentransformation dient.

Vor der Anwendung der Transformation wird eine Prüfung durchgeführt, um sicherzustellen, dass das Eingabebild den Anforderungen entspricht. Dazu muss es sich um

ein 8-Bit-Binärbild mit Werten zwischen 0 und 255 handeln. Ist dies der Fall, wird die Wasserscheidentransformation mit den entsprechenden Parametern initialisiert und auf das Bild angewendet. Die Abbildung 18 zeigt die Maske nach Anwendung der Wasserscheidentransformation. Das resultierende segmentierte Bild wird temporär gespeichert und anschließend mit OpenCV erneut geladen.

Die Wasserscheidentransformation hat sich als robuste und effiziente Methode zur Segmentierung sich berührender Objekte in Binärbildern erwiesen. Durch die Integration dieses Verfahrens in den Analyseablauf können die einzelnen Zellen im PUR-Hartschaum zuverlässig voneinander getrennt und für die nachfolgende Quantifizierung zugänglich gemacht werden. Die Kombination von Python, OpenCV und ImageJ erlaubt eine flexible und leistungsstarke Umsetzung dieser Segmentierungsaufgabe im Rahmen der Entwicklung des KI-gestützten Analysetools.



*Abbildung 18: Maske nach der Wasserscheidentransformation (Eigene Darstellung)*

### **3.2.4 Konturenerkennung und Visualisierung**

Im Anschluss an die Anwendung der Wasserscheidentransformation erfolgt die Konturenerkennung, um die Zellstrukturen im PUR-Hartschaum präzise zu identifizieren und zu visualisieren. Dieser Schritt ist von entscheidender Bedeutung, um die geometrischen Eigenschaften der Zellen zu analysieren und die Qualität der Isolierung zu bewerten.

Zunächst wird das durch die Wasserscheidentransformation erzeugte Bild erneut mit OpenCV geladen. Die Funktion `cv2.imread()` wird verwendet, um das Bild im unveränderten Modus (`cv2.IMREAD_UNCHANGED`) zu laden. Dadurch wird sichergestellt, dass die binäre Struktur des Bildes erhalten bleibt. Im nächsten Schritt werden die Konturen im binären Bild mittels der Funktion `cv2.findContours()` detektiert. Die Funktion extrahiert die Konturen, indem sie die Grenzen zwischen den schwarzen und weißen Pixeln im Bild identifiziert. Hierbei wird der Modus `cv2.RETR_EXTERNAL` verwendet, um nur die äußersten Konturen zu erfassen, und die Methode `cv2.CHAIN_APPROX_SIMPLE`, um die Konturpunkte zu komprimieren und redundante Punkte zu entfernen.

Im Anschluss werden die erkannten Konturen auf zwei verschiedenen Bildern visualisiert. Zunächst wird eine Kopie des Originalbildes erstellt, auf der die Konturen mit der Funktion `cv2.drawContours()` eingezeichnet werden. Die Konturen werden in einer auffälligen roten Farbe dargestellt, um sie deutlich sichtbar zu machen. Ein weiteres Bild wird erstellt, indem die Konturen auf das durch die Wasserscheidentransformation erzeugte Bild gezeichnet werden. Dies ermöglicht einen direkten Vergleich der Segmentierungsergebnisse.

Die Abbildung 19 und Abbildung 20 veranschaulichen die generierten Bilder. Abbildung 19 präsentiert die Wasserscheidenmaske mit den Konturen, während Abbildung 20 das Originalbild mit den eingezeichneten Konturen zeigt.

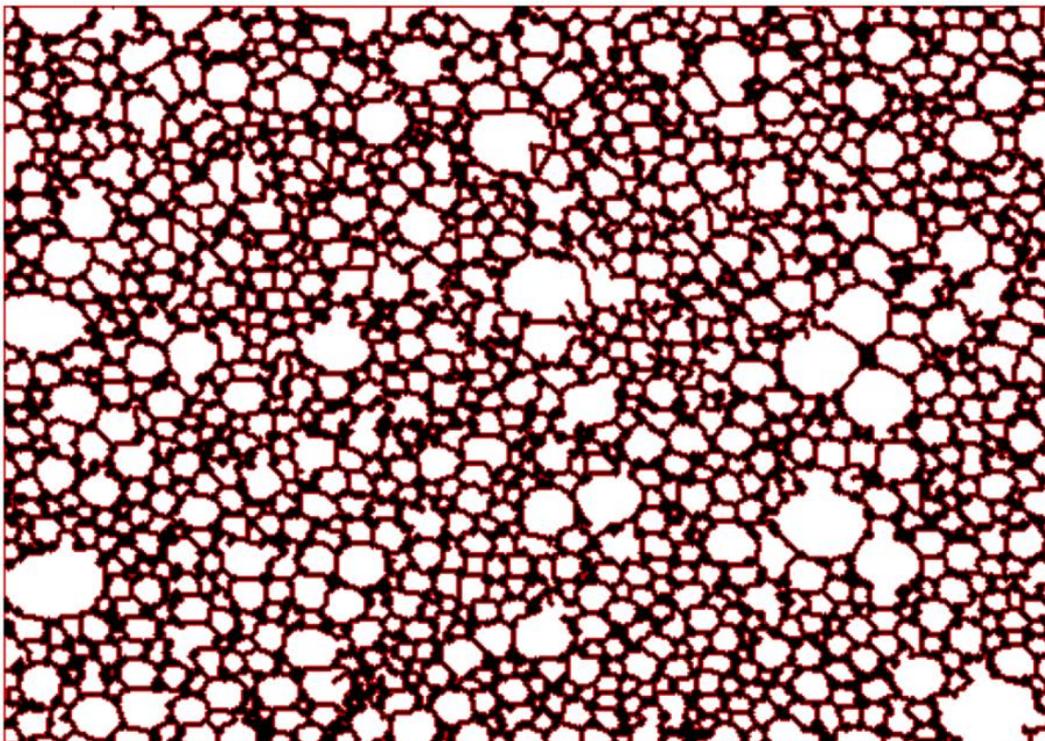
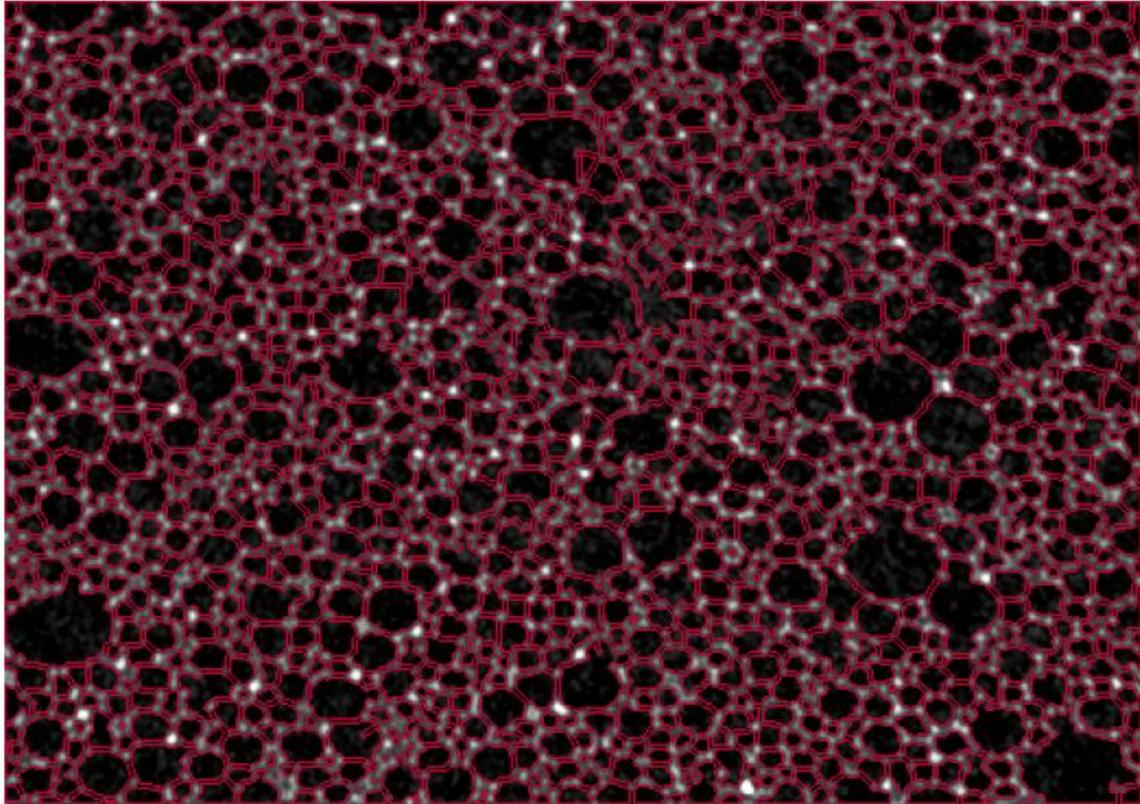


Abbildung 19: Wasserscheidenmaske mit eingezeichneten Konturen (Eigene Darstellung)



*Abbildung 20: Originalbild mit eingezeichneten Konturen (Eigene Darstellung)*

Zusätzlich zur Visualisierung aller erkannten Konturen wird eine Filterung der Konturen entlang einer Linie durchgeführt, die der Prüfmethode nach DIN EN 253. Bei dieser Methode werden die Zellen entlang einer 10 mm langen Linie gemessen, die sich ungefähr in der Mitte des Röntgenmikroskopiebildes befindet. Dazu wird zunächst die Länge der Linie in Pixel umgerechnet und der Startpunkt der Linie in der Mitte des Bildes festgelegt. Anschließend werden die Konturen gefiltert, indem nur diejenigen Konturen berücksichtigt werden, die mindestens einen Punkt entlang der definierten Linie aufweisen.

Die gefilterten Konturen werden sowohl auf dem Originalbild als auch auf der Wasserscheidenmaske visualisiert. Abbildung 21 zeigt die Wasserscheidenmaske mit den gefilterten Konturen, während Abbildung 22 das Originalbild mit den gefilterten Konturen darstellt. Durch die Filterung entlang der Linie werden nur die für die Prüfmethode nach DIN EN 253 relevanten Zellen berücksichtigt.

Basierend auf den gefilterten Konturen werden verschiedene Kenngrößen berechnet, darunter die Anzahl der gefilterten Zellen, der Mittelwert und die größte Fläche der gefilterten Zellen sowie der Mittelwert und der maximale Durchmesser der gefilterten

Zellen. Zudem wird überprüft, ob der Durchmesser der mittleren gefilterten Zelle die Anforderungen der DIN EN 253 erfüllt.

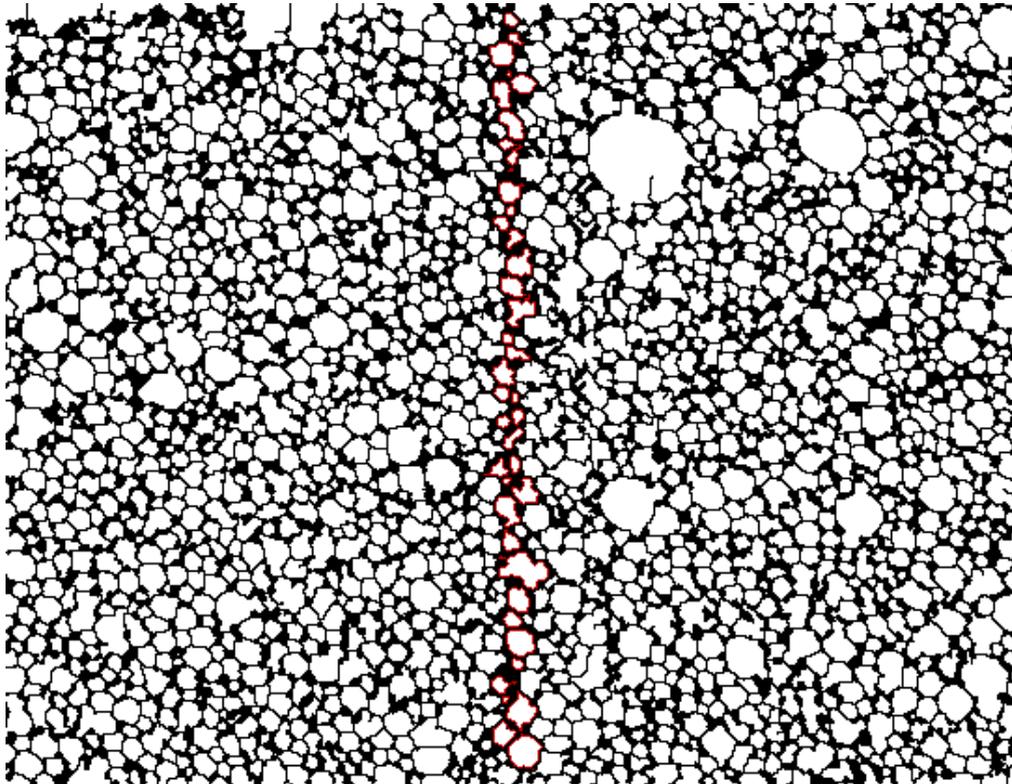


Abbildung 21: Wasserscheidenmaske mit gefilterten Konturen nach DIN 253 (Eigene Darstellung)

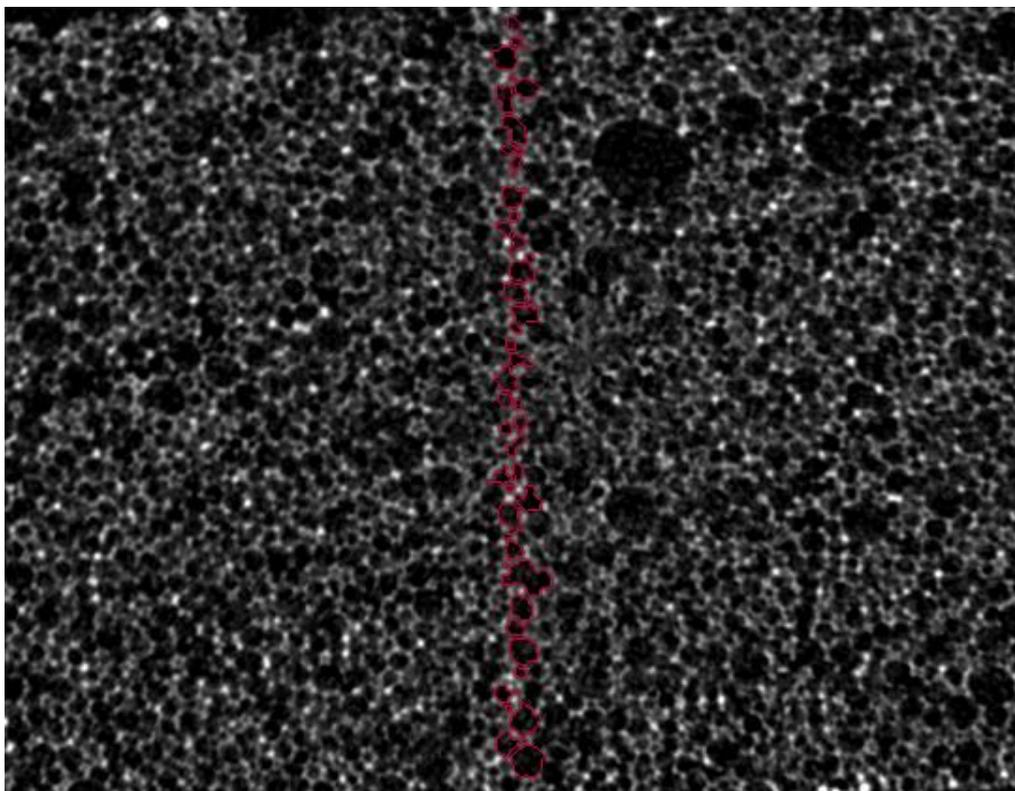


Abbildung 22: Originalbild mit gefilterten Konturen nach DIN 253 (Eigene Darstellung)

Die Konturenerkennung und Visualisierung erlaubt eine detaillierte Analyse der Zellstrukturen im PUR-Hartschaum. Die Kombination von Wasserscheidentransformation, Konturenerkennung und Filterung gemäß DIN 253 ermöglicht eine präzise Segmentierung sowie eine Quantifizierung der geometrischen Eigenschaften der Zellen. Die erzeugten Bilder und Messungen dienen als Basis für eine umfassende Evaluierung der Isolierqualität und erlauben Rückschlüsse auf die Leistungsfähigkeit des Materials.

### **3.2.5 Quantitative Analyse der Materialmorphologie und Überprüfung der Anforderungen nach EN 253**

Nachdem die Zellen im PUR-Hartschaum segmentiert wurden, erfolgt die quantitative Analyse ihrer Morphologie. Ziel ist es, die Materialmorphologie zu bewerten und die Einhaltung der Anforderungen der EN 253 zu überprüfen. Dazu wird zunächst die Fläche jeder einzelnen Zelle bestimmt. Dazu wird die Funktion `cv2.contourArea()` auf jede Kontur angewandt. Die resultierenden Flächenwerte in Pixeln werden anschließend unter Verwendung des zuvor ermittelten Umrechnungsfaktors von 0,025 mm/Pixel in Quadratmillimeter umgerechnet. Basierend auf den Zellflächen werden die Gesamtfläche aller Zellen, die durchschnittliche Zellfläche sowie die größte Zellfläche bestimmt.

Ein weiterer wesentlicher morphologischer Parameter ist der Zelldurchmesser. Unter der Annahme, dass die Zellen näherungsweise kreisförmig sind, kann der Durchmesser aus der Fläche berechnet werden. Dazu wird die Formel für den Durchmesser eines Kreises mit gegebener Fläche verwendet:

$$d = \sqrt{\frac{4A}{\pi}}$$

wobei  $d$  der Durchmesser und  $A$  die Fläche ist. Die Durchmesser aller Zellen werden berechnet und der Mittelwert sowie der maximale Wert bestimmt. Gemäß EN 253 muss der mittlere Zelldurchmesser in Polyurethan-Hartschäumen für Fernwärmerohre kleiner als 0,5 mm betragen. Die Erfüllung dieser Anforderung wird durch einen Vergleich des berechneten mittleren Zelldurchmessers mit den Grenzwerten überprüft. Das Ergebnis dieser Überprüfung wird ausgegeben, um eine Aussage darüber zu treffen, ob das Material den Anforderungen entspricht.

Neben den zellspezifischen Parametern werden zudem Kenngrößen für das Gesamtbild berechnet. Die Gesamtfläche des Bildes lässt sich durch Multiplikation der Bildabmessungen in Pixeln mit dem Quadrat des Umrechnungsfaktors ermitteln. Die Fläche

ohne Zellen wird durch Subtraktion der Gesamtfläche der Zellen von der Gesamtfläche des Bildes ermittelt. Das Verhältnis der Zellenfläche zur Gesamtfläche gibt Aufschluss über den Anteil des Bildes, der von Zellen eingenommen wird. In einem letzten Schritt wird die Anzahl der Zellen im Bild bestimmt, indem die Länge der Liste der Konturen ermittelt wird. Die ermittelten Ergebnisse werden in übersichtlicher Form ausgegeben, um einen schnellen Überblick über die wichtigsten morphologischen Parameter zu ermöglichen. Die berechneten Ergebnisse umfassen die Gesamtfläche des Bildes, die Fläche aller Zellen, die Fläche ohne Zellen, die durchschnittliche und größte Zellfläche, die Anzahl der Zellen, das Verhältnis der Zellenfläche zur Gesamtfläche sowie den mittleren und maximalen Zelldurchmesser.

Zur Veranschaulichung der Verteilung der Zellflächen und -durchmesser werden Histogramme erstellt, die eine detaillierte Übersicht über die Morphologie der Zellen ermöglichen. Abbildung 23 zeigt ein Beispiel für ein Histogramm der Zellflächen, während Abbildung 24 ein Beispiel für ein Histogramm der Zelldurchmesser darstellt. Die Histogramme zeigen die Häufigkeitsverteilung der Werte, wobei die X-Achse die Fläche der Zellen bzw. den Durchmesser in Millimetern und die Y-Achse die Anzahl der Zellen angibt. Diese Verteilung gibt Aufschluss über die Homogenität des Materials und erlaubt eine genauere Bewertung der Qualität des PUR-Hartschaums.

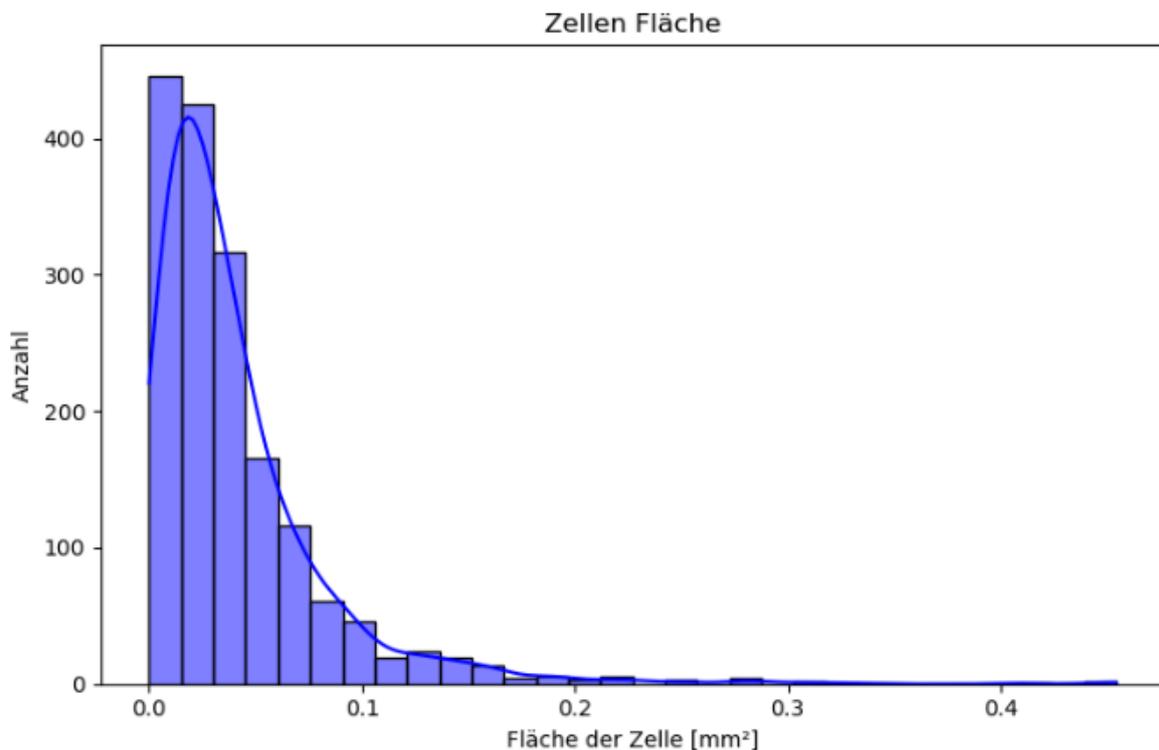


Abbildung 23: Beispiel Histogramm der Zellflächen (Eigene Darstellung)

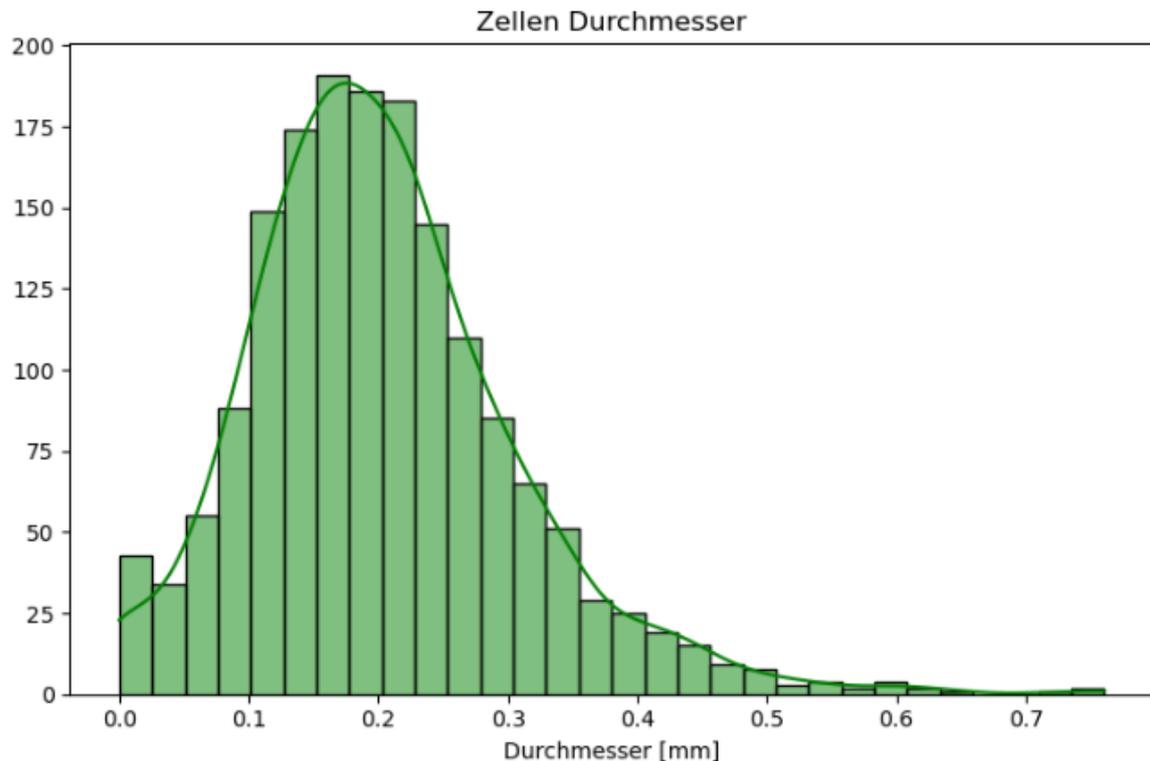


Abbildung 24: Beispiel Histogramm der Zelldurchmesser (Eigene Darstellung)

### 3.2.6 Analyse der Zellwanddicken mittels Distanztransformation

Die Analyse der Zellwanddicken stellt einen wichtigen Schritt zur Charakterisierung der Schaumstruktur dar, nachdem die Zellen im PUR-Hartschaum erfolgreich segmentiert wurden. In diesem Abschnitt wird die Anwendung der Distanztransformation zur Quantifizierung der Zellwanddicken erläutert.

Im Rahmen der Zellwandanalyse wird die Distanztransformation auf das invertierte Binärbild der segmentierten Zellen angewendet. Die Pixel der Zellwände erhalten dadurch Werte, die ihrer Dicke entsprechen, und die Pixel im Inneren der Zellen werden mit dem Wert Null zugewiesen.

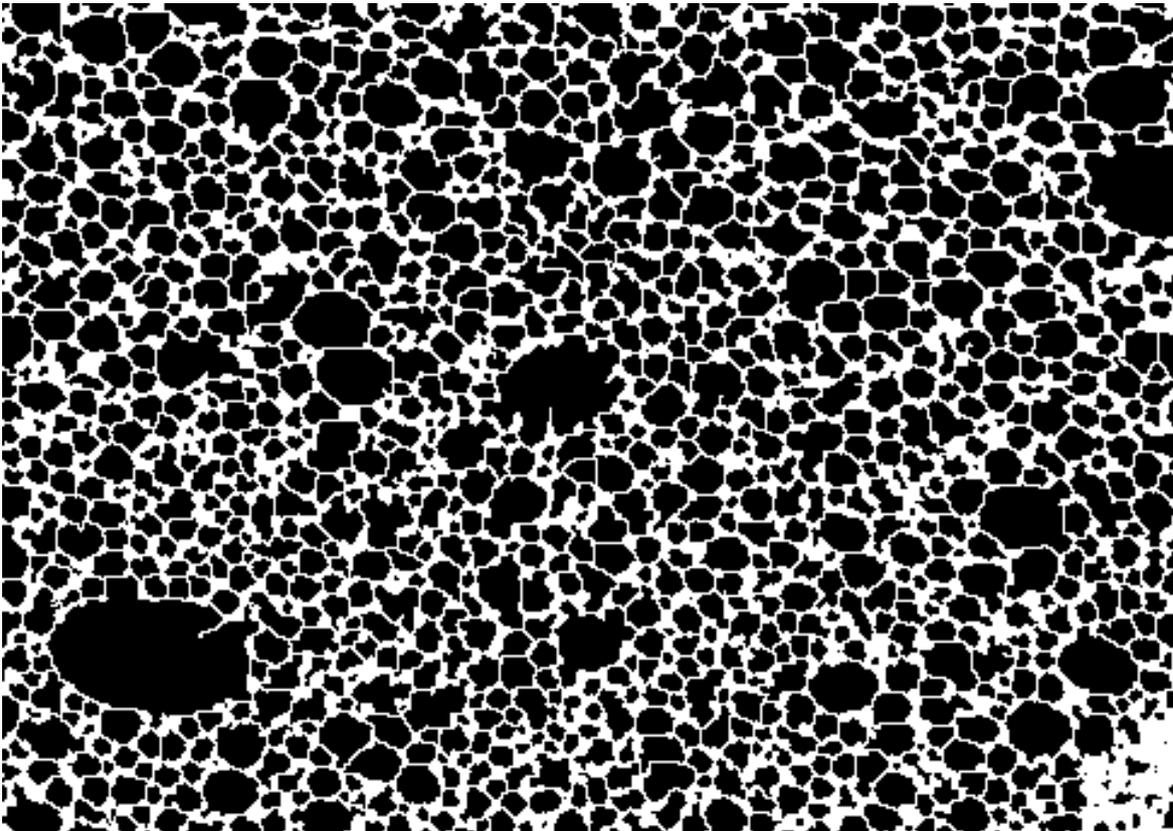
Die OpenCV-Funktion `cv2.distanceTransform()` implementiert die Distanztransformation mit hoher Effizienz. Die Eingabe bildet die invertierte Binärmaske der Zellen (`mask`), welche durch bitweise Negation des Wasserscheiden-Segmentierungsergebnisses (`img_Watershed_binary`) erzeugt wird. Der Parameter `cv2.DIST_L2` spezifiziert die Verwendung der euklidischen Distanz als Metrik.

Zur Visualisierung der Ergebnisse der Distanztransformation werden eine Normalisierung und Farbkodierung durchgeführt. Die Funktion `cv2.normalize()` skaliert die Distanzwerte auf den Bereich von 0 bis 255, gefolgt von einer Konvertierung in den Datentyp `uint8`. Im

Anschluss erfolgt die Anwendung der Funktion `cv2.applyColorMap()`, welche den normalisierten Distanzwerten eine Farbskala (hier: `cv2.COLORMAP_TURBO`) zuordnet. Um die Zellen selbst hervorzuheben, werden die entsprechenden Pixel in der farbkodierten Darstellung auf den Wert `[255, 255, 255]` (weiß) gesetzt.

Basierend auf den Ergebnissen der Distanztransformation können quantitative Kenngrößen der Zellwanddicken berechnet werden. Dazu werden die Distanzwerte der Pixel extrahiert, die den Zellwänden entsprechen (`wall_thicknesses`). Durch Multiplikation mit dem Umrechnungsfaktor von `0,025 mm/Pixel` werden die Dicken in physikalische Einheiten (Millimeter) umgerechnet. Mittlere und maximale Zellwanddicke werden berechnet und ausgegeben.

Die Ergebnisse der Distanztransformation und der Wanddickenberechnung werden in mehreren Visualisierungen dargestellt. Abbildung 25 zeigt die invertierte binäre Maske der Zellwände und Abbildung 26 das farbige Distanztransformationssbild der Zellwände. Diese Darstellungen bieten eine anschauliche Übersicht über die Struktur der Zellwände und die Verteilung der Wanddicken.



*Abbildung 25: Invertierte binäre Maske der Zellwände (Eigene Darstellung)*

Des Weiteren wird eine Farbskala erstellt, welche den Zusammenhang zwischen den Farben im Distanztransformationsbild und den entsprechenden Wanddicken in Millimetern verdeutlicht. Die Farbskala dient der erleichterten Interpretation der Ergebnisse sowie einer zeitökonomischen, visuellen Bewertung der Wanddickenverteilung.

Um die statistische Verteilung der Wanddicken weiter zu analysieren, generierte der Code ein Weibull-Diagramm. Abbildung 27 zeigt ein Beispiel für das durch den Code generierte Weibull-Diagramm. Durch Anpassung der Weibull-Parameter (Formparameter  $k$  und Skalenparameter  $\lambda$ ) an die gemessenen Wanddicken kann das Diagramm erstellt werden. Die Wahrscheinlichkeitsdichtefunktion der Weibull-Verteilung wird zusammen mit den Wanddickendaten geplottet, um die Übereinstimmung zwischen Modell und Daten zu visualisieren.

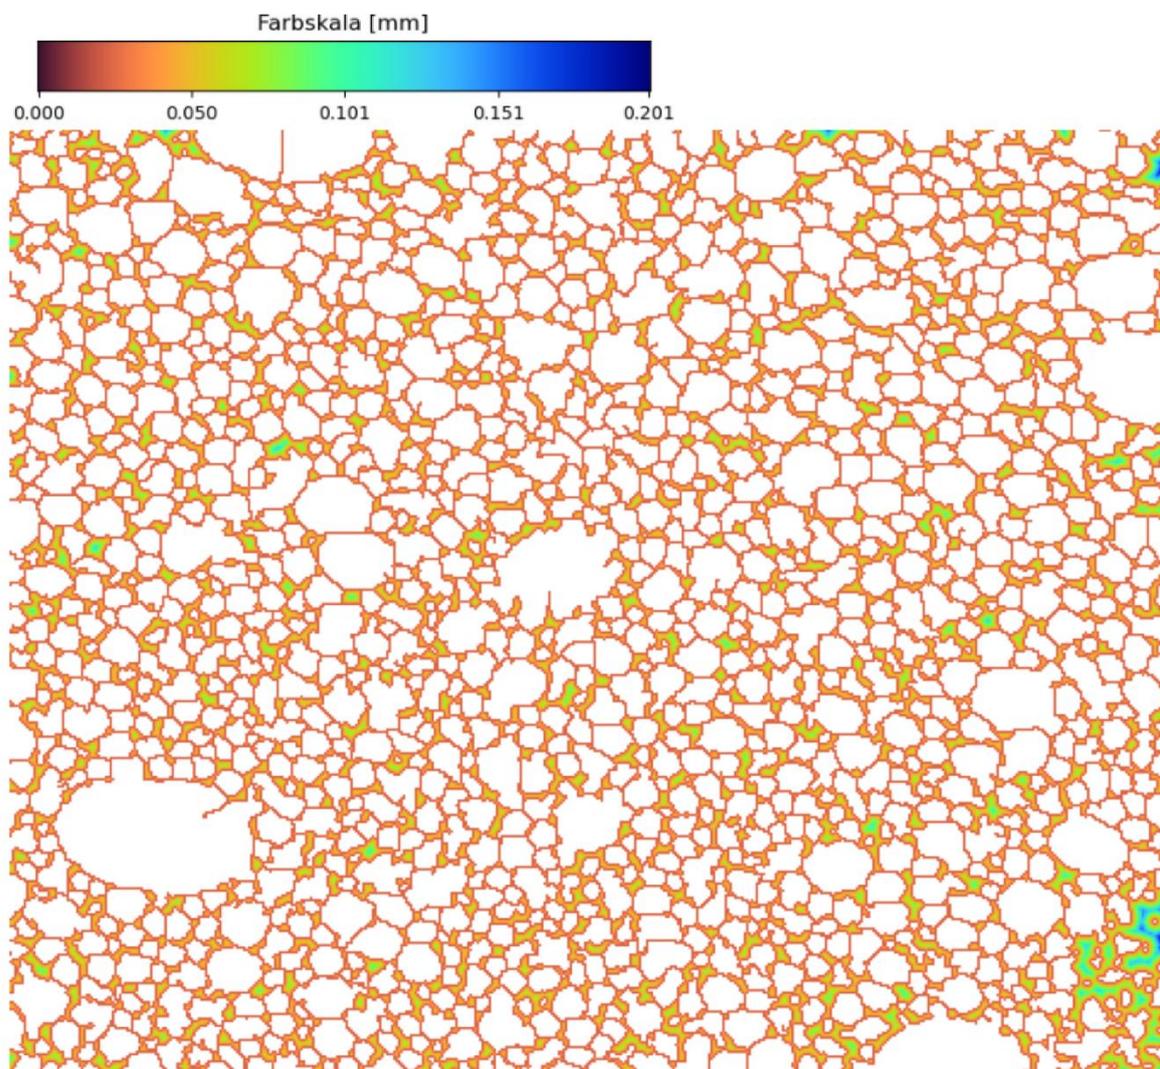


Abbildung 26: Farbiges Distanztransformationsbild der Zellwände und Farbskala (Eigene Darstellung)

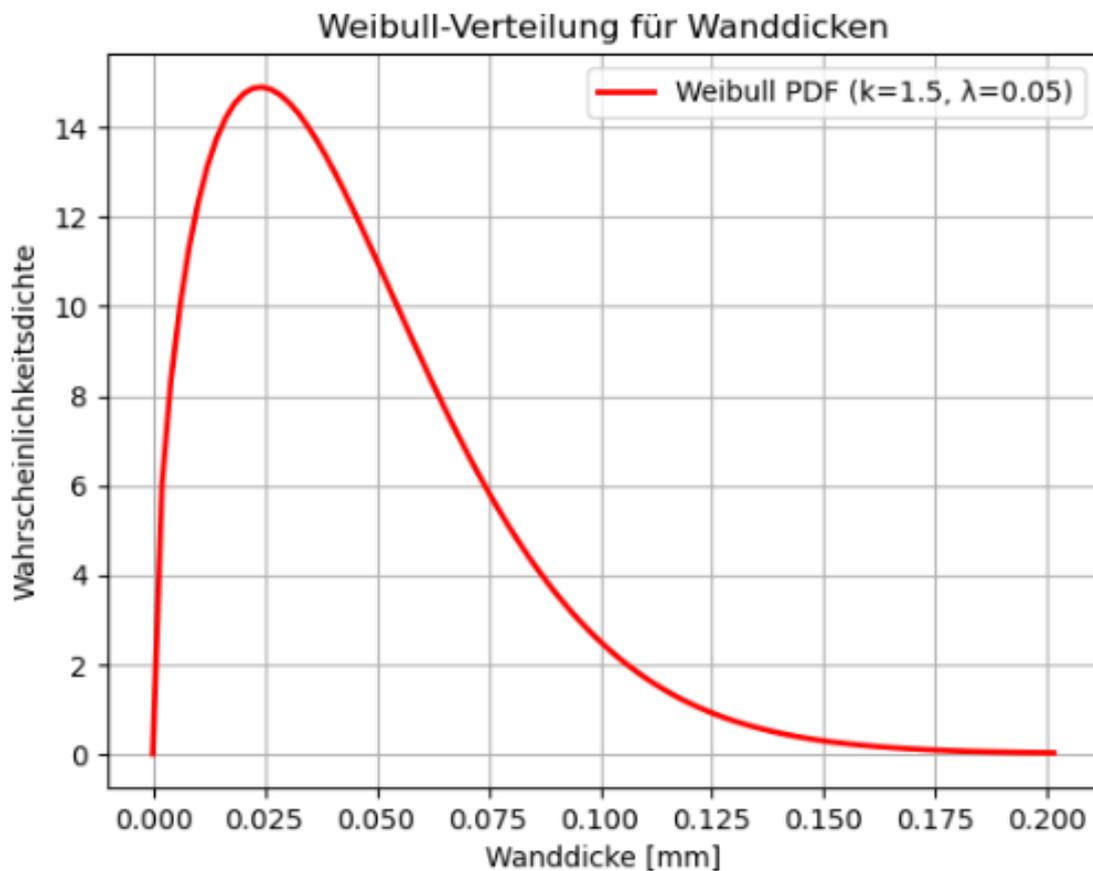


Abbildung 27: Weibull-Diagramm zur statistischen Analyse der Wanddickenverteilung (Eigene Darstellung)

### 3.2.7 Automatisierte Analyse der gesamten Probe

In diesem Unterkapitel wird die automatisierte Analyse der gesamten Polyurethan-Hartschaumprobe beschrieben. Hierbei werden alle Bilder des Datensatzes verarbeitet, um eine umfassende Bewertung der Zellstrukturen zu ermöglichen. Der entwickelte Python-Code implementiert die in den vorherigen Unterkapiteln beschriebenen Schritte (3.2.2 – 3.2.6) für alle Bilder im Datensatz und aggregiert die Ergebnisse, um eine Gesamtaussage über die Probe treffen zu können.

Der Code initialisiert ImageJ und definiert die Pfade zu den Eingabe- und Ausgabeverzeichnissen. Im Anschluss erfolgt das nacheinander erfolgende Laden der Bilder, deren Vorverarbeitung sowie die Analyse. Die Ergebnisse werden für jedes Bild berechnet und in Listen gespeichert, um eine Gesamtbewertung der Probe zu ermöglichen.

Im ersten Schritt erfolgt die Konvertierung der Bilder in Graustufenbilder sowie die Erstellung binärer Masken. Im Anschluss werden die Masken invertiert und in ImageJ-Objekte konvertiert, um die Wasserscheidentransformation durchzuführen. Die

resultierenden Bilder werden gespeichert und erneut geladen, um die Konturen der Zellen zu finden und deren Flächen und Durchmesser zu berechnen.

Nach der Verarbeitung aller Bilder werden die Gesamtergebnisse berechnet und ausgegeben. Die Ergebnisse umfassen den Mittelwert und die größte Zellfläche, den Mittelwert und den maximalen Zelldurchmesser, Verhältnis der Zellenfläche zur Gesamtfläche sowie die mittlere und maximale Wanddicke. Des Weiteren wird evaluiert, ob der mittlere Zelldurchmesser die Anforderungen der Norm EN 253 erfüllt.

Der Code visualisiert zudem die Ergebnisse, indem er zufällig ausgewählte Bilder mit den erkannten Konturen anzeigt und Histogramme der Zelldurchmesser und Wanddicken erstellt. Die genannten Visualisierungen erlauben eine qualitative Bewertung der Zellstrukturen sowie eine Aussage über die Verteilung der Zelleigenschaften in der gesamten Probe.

Die automatisierte Analyse der gesamten Probe erlaubt die Erstellung umfassender Aussagen über die Struktur und Qualität des Polyurethan-Hartschaums. Die aggregierten Ergebnisse bieten eine solide Grundlage für die Bewertung der Materialeigenschaften sowie die Einhaltung der relevanten Normen. Die Automatisierung des Analyseprozesses ermöglicht eine effiziente und reproduzierbare Charakterisierung der Probe, was insbesondere für die Qualitätskontrolle und Optimierung des Herstellungsprozesses von großer Bedeutung ist.

### **3.3 Bildanalyse mittels Deep Learning mit Detectron2**

Die Bildanalyse mittels Deep Learning hat in den letzten Jahren große Fortschritte gemacht und bietet zahlreiche Vorteile gegenüber herkömmlichen Bildverarbeitungsmethoden. Insbesondere die Fähigkeit von Deep-Learning-Algorithmen, komplexe Muster und Strukturen in Bilddaten automatisch zu erkennen und zu erlernen, hat zu einer breiten Anwendung in verschiedenen wissenschaftlichen und industriellen Bereichen geführt. In diesem Kapitel wird die Anwendung von Detectron2, einem leistungsfähigen Framework zur Objekterkennung und -segmentierung, für die Analyse von Polyurethan-Hartschaumproben beschrieben.

In diesem Projekt wurde Detectron2 zur Segmentierung und Analyse von Zellstrukturen in PUR-Hartschaumproben eingesetzt. Die Methode umfasst mehrere Schritte, beginnend mit der Vorbereitung der Bilder und der Erstellung von Masken für die Zellen, gefolgt von der

Konvertierung der Masken in das COCO-JSON-Format und der Aufteilung der Bilder in Trainings-, Validierungs- und Testdatensätze. Anschließend wurde das Modell in Google Colab trainiert und evaluiert.

Es muss konstatiert werden, dass das Modell in diesem Projekt keine zufriedenstellenden Ergebnisse geliefert hat. Die Gründe dafür sowie potenzielle Verbesserungen werden in Kapitel 4 erörtert. Trotz der Herausforderungen und der suboptimalen Ergebnisse liefern die Anwendung von Deep Learning und Detectron2 wertvolle Erkenntnisse, die den Grundstein für zukünftige Arbeiten in diesem Bereich legen.

### **3.3.1 Datenvorverarbeitung und Annotation**

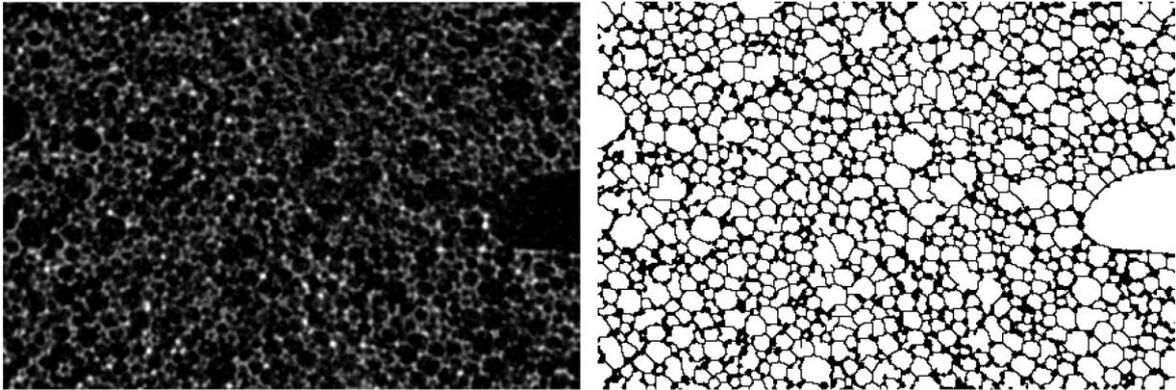
Die Entwicklung des Deep-Learning-Modells zur Segmentierung der Zellen in den PUR-Hartschaumproben erforderte eine sorgfältige Vorbereitung und Annotation der Bilddaten. Der Prozess umfasste mehrere Schritte, um qualitativ hochwertige Trainingsdaten zu generieren.

Zunächst wurden die 1242 Bilder des Datensatzes zugeschnitten, um den Hintergrund zu entfernen und den Fokus auf die relevanten Bildbereiche zu legen. Der Zweck dieses Schritts bestand in der Minimierung störender Einflüsse sowie der Verbesserung der Effizienz des Trainings. Die Entfernung des Hintergrunds erfolgte mittels der in Kapitel 3.2 vorgestellten klassischen Bildverarbeitungsmethoden, welche eine zuverlässige Extraktion der Proben ermöglichten.

Im Anschluss an das Zuschneiden der Bilder wurden für jedes Bild Annotationen in Form von Masken erstellt. Die erstellten Masken fungierten als Grundlage für das überwachte Lernen des Deep-Learning-Modells. Die Markierung der Positionen und Formen der einzelnen Zellen im Bild diente dazu, dem Modell die Zusammenhänge zwischen den Bilddaten und den gewünschten Segmentierungen zu vermitteln.

Die Erstellung der Annotationsmasken erfolgte ebenfalls unter Verwendung der in Kapitel 3.2 beschriebenen Bildverarbeitungstechniken. Durch die Anwendung von Schwellenwertverfahren, morphologischen Operationen und Konturenerkennung konnten die Zellgrenzen präzise identifiziert und in binäre Masken überführt werden. Der halbautomatische Ansatz ermöglichte eine effiziente Annotation der Bilddaten, wobei jedoch eine manuelle Nachbearbeitung erforderlich war, um die Genauigkeit der Masken zu gewährleisten.

Abbildung 28 präsentiert ein exemplarisches Originalbild aus dem Datensatz sowie die zugehörige Annotationsmaske. Die weiß dargestellten Bereiche in der Maske repräsentieren die Zellen, während der schwarze die Zellwände (Hintergrund) und -grenzen kennzeichnet. Die Kombination von Bild und Maske stellt die Grundlage für das überwachte Training des Deep-Learning-Modells dar.



*Abbildung 28: Beispiel für ein Originalbild (links) und die zugehörige Annotationsmaske (rechts) (Eigene Darstellung)*

Die sorgfältige Annotation der Bilddaten stellte einen zeitaufwändigen, jedoch entscheidenden Schritt dar, um qualitativ hochwertige Trainingsdaten für das Deep-Learning-Modell zu generieren. Die Kombination von klassischen Bildverarbeitungsmethoden und manueller Nachbearbeitung ermöglichte die Erstellung präziser Masken, welche die Grundlage für ein robustes und zuverlässiges Segmentierungsmodell bildeten.

### **3.3.2 Konvertierung der Masken in das COCO JSON-Format**

Nach der erfolgreichen Erstellung der Annotationsmasken für die Bilddaten ist der nächste Schritt die Konvertierung dieser Masken in das COCO JSON-Format. Dieses Format ist ein weit verbreiteter Standard für die Annotation von Objekten in Bildern und wird von vielen Deep-Learning-Frameworks und -Tools unterstützt (COCO - Common Objects in Context, o. D.). Die Konvertierung in das COCO JSON-Format ist erforderlich, um die Daten für das Training des Detectron2-Modells vorzubereiten. Das COCO JSON-Format besteht aus einem einzelnen JSON-Objekt, das alle Informationen über die Bilder, Annotationen und Kategorien enthält. Jedes Bild wird durch einen Eintrag im „images“-Array repräsentiert, der Informationen wie die Bild-ID, den Dateinamen, die Höhe und Breite enthält. Die Annotationen werden im „annotations“-Array gespeichert, wobei jede Annotation durch eine Polygon-Segmentierung, eine Bounding Box, eine Fläche und eine Kategorie-ID

gekennzeichnet ist. Die Kategorien selbst werden im „categories“-Array definiert (Lin et al., 2014).

Zur Konvertierung der Masken in das COCO JSON-Format wurde ein Python-Skript entwickelt, welches die folgenden Schritte ausführt:

- 1) Einlesen der Bild- und Maskenpfade: Die Funktion `get_image_mask_pairs()` durchsucht die angegebenen Verzeichnisse nach Bild- und Maskendateien und gibt die Pfade der zusammengehörigen Paare zurück.
- 2) Konvertierung der Masken in Polygone: Die Funktion `mask_to_polygons()` verwendet die OpenCV-Funktion `cv2.findContours()`, um die Konturen in der Maske zu finden. Diese Konturen werden dann in Polygone umgewandelt, die als Liste von Punkten dargestellt werden.
- 3) Verarbeitung der Bild- und Maskendaten: Die Funktion `process_data()` iteriert über die Bild-Masken-Paare und erstellt für jedes Bild einen Eintrag im "images"-Array. Für jede eindeutige Objektinstanz in der Maske wird eine Annotation im "annotations"-Array erstellt, die die Polygon-Segmentierung, die Bounding Box, die Fläche und die Kategorie-ID enthält.
- 4) Speicherung der COCO JSON-Datei: Das resultierende COCO JSON-Objekt, das die Bilder, Annotationen und Kategorien enthält, wird in einer Datei namens `coco_annotations.json` im Ausgabeverzeichnis gespeichert.

Des Weiteren erfolgt eine Aufteilung der Bilddaten in Trainings- und Validierungsdatensätze, wobei das COCO JSON-Format als Zielformat dient. Die Aufteilung der Daten in Trainings- und Validierungsdatensätze erfolgt mittels der Funktion `train_test_split()` aus der Bibliothek `scikit-learn`. Diese Funktion führt eine zufällige Aufteilung der Daten in der angegebenen Größe (hier 80 % für Training und 20 % für Validierung) durch. Im Anschluss werden die aufgeteilten Daten in separaten Verzeichnissen für Training und Validierung gespeichert.

Die Konvertierung der Annotationsmasken in das COCO-JSON-Format sowie die Aufteilung der Daten in Trainings- und Validierungsdatensätze stellen die erforderlichen Voraussetzungen für das Training des Detectron2-Modells dar. Das COCO-Format gewährleistet eine standardisierte Darstellung der Annotationen, die von einer Vielzahl von Deep-Learning-Tools unterstützt wird. Dadurch wird die Interoperabilität und Wiederverwendbarkeit der Daten verbessert.

### 3.3.3 Einrichtung der Entwicklungsumgebung in Google Colab

Für die Entwicklung und das Training des Deep-Learning-Modells zur Segmentierung der Zellen in den PUR-Hartschaumproben wurde Google Colab als Plattform gewählt. Google Colab ist ein kostenloser Cloud-Service, der eine Jupyter-Notebook-Umgebung zur Verfügung stellt und die Ausführung von Python-Code auf leistungsfähigen GPUs ermöglicht. Die Nutzung von Google Colab bietet mehrere Vorteile, darunter die einfache Einrichtung, die Skalierbarkeit der Rechenressourcen und die Möglichkeit der Zusammenarbeit.

Der erste Schritt bei der Einrichtung der Entwicklungsumgebung in Google Colab besteht in der Einbindung von Google Drive. Durch die Verknüpfung des Colab-Notebooks mit Google Drive können die benötigten Datensätze, Modelle und Konfigurationsdateien effizient verwaltet und zwischen verschiedenen Notebooks ausgetauscht werden.

Ein entscheidender Aspekt bei der Verwendung von Google Colab für Deep-Learning-Anwendungen ist die Verfügbarkeit von GPUs. Durch die Ausführung der rechenintensiven Operationen auf GPUs kann die Trainingszeit deutlich reduziert werden. Zur Überprüfung der Verfügbarkeit einer GPU wird das Modul „torch“ verwendet und der Befehl „torch.cuda.is\_available()“ ausgeführt (PyTorch, 2023). Anschließend wird der Laufzeittyp des Notebooks auf „GPU“ gesetzt, um die Nutzung der GPU zu aktivieren.

Die Installation von Detectron2 in Google Colab erfordert zunächst die Installation der Abhängigkeiten, zu denen unter anderem PyTorch und torchvision gehören. Die entsprechenden Versionen der Bibliotheken werden über die Paketmanager pip installiert.

Anschließend wird das Detectron2-Repository von GitHub geklont und die Setup-Datei ausgeführt, um die Liste der Abhängigkeiten zu erhalten. Diese Abhängigkeiten werden dann ebenfalls über pip installiert. Nach der erfolgreichen Installation wird das Detectron2-Verzeichnis zum Systempfad hinzugefügt, um den Import der Bibliothek in Python zu ermöglichen.

Zur Überprüfung der korrekten Installation und Konfiguration werden die Versionen der NVIDIA CUDA Compiler (nvcc), PyTorch und Detectron2 ausgegeben. Des Weiteren werden einige grundlegende Einstellungen vorgenommen, darunter das Einrichten des Detectron2-Loggers sowie der Import häufig verwendeter Bibliotheken und Funktionen.

### 3.3.4 Datenaufbereitung und -visualisierung

Nach der erfolgreichen Einrichtung der Entwicklungsumgebung in Google Colab und der Installation der erforderlichen Bibliotheken erfolgt die Aufbereitung und Visualisierung der Bilddaten.

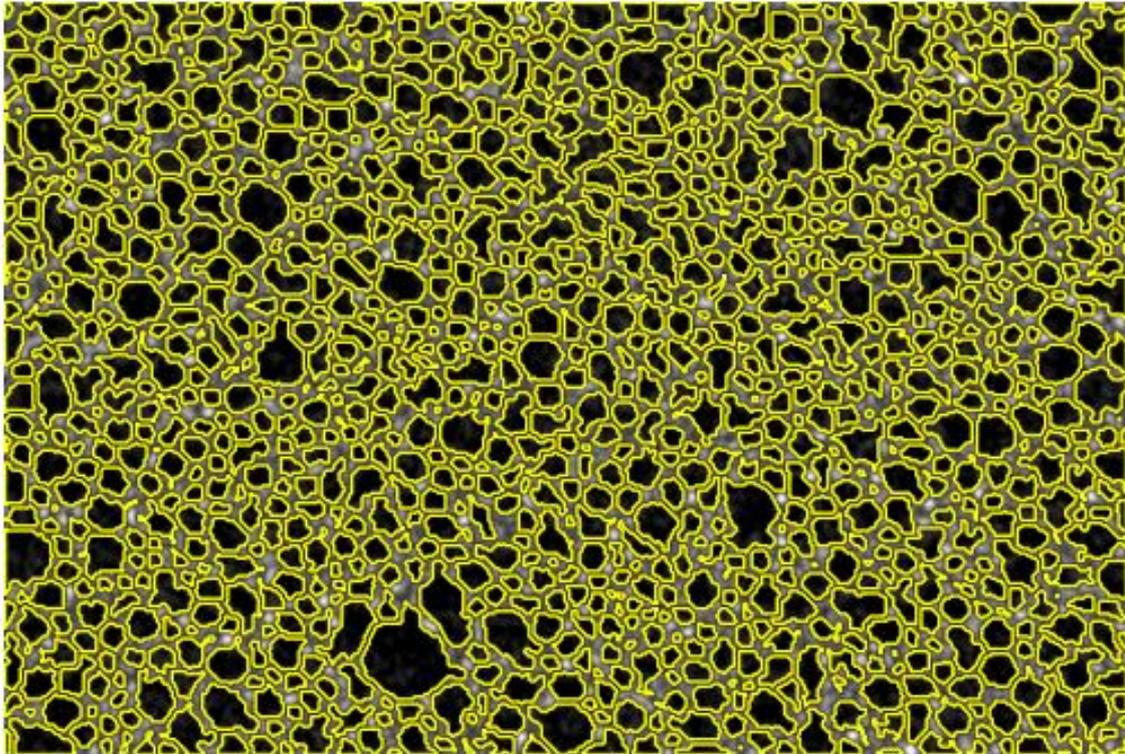
Zunächst werden die Trainings- und Validierungsdatensätze im COCO-Format registriert. Dazu wird die Funktion `register_coco_instances()` aus dem Modul `detectron2.data.datasets` verwendet. Diese Funktion erwartet den Pfad zur COCO-JSON-Datei sowie den Pfad zum Verzeichnis mit den zugehörigen Bildern. Durch die Registrierung werden die Datensätze in das von Detectron2 verwendete Format konvertiert und können effizient geladen und verarbeitet werden.

Nach der Registrierung der Datensätze werden die Metadaten und Datensatz-Dictionaries für den Trainings- und Validierungsdatensatz abgerufen. Die Metadaten umfassen Informationen zu den Kategorien, Klassennamen und Farben, während die Datensatz-Dictionaries die eigentlichen Bilddaten und Annotationen enthalten. Die entsprechenden Informationen werden mithilfe der Funktionen `„MetadataCatalog.get()“` und `„DatasetCatalog.get()“` aus dem Modul `„detectron2.data“` geladen.

Um einen visuellen Eindruck von den Bilddaten zu gewinnen, werden einige zufällig ausgewählte Bilder zusammen mit ihren Annotationen visualisiert. Zur Realisierung dieser Funktionalität wird die Klasse `Visualizer` aus dem Modul `detectron2.utils.visualizer` verwendet. Die Klasse ermöglicht die Darstellung von Bildern, die mit Annotationen wie Bounding Boxes, Segmentierungsmasken und Klassenlabels überlagert sind.

Abbildung 29 präsentiert ein Beispiel für ein visualisiertes Bild aus dem Trainingsdatensatz. Das Originalbild wird zusammen mit den Annotationen dargestellt, wobei die Zellen durch farbige Polygone hervorgehoben sind. Die dargestellte Visualisierung erlaubt eine schnelle Überprüfung der Annotationsqualität und verschafft einen Überblick über die Verteilung und Variabilität der Zellen im Bild.

Die Aufbereitung und Visualisierung der Bilddaten in Google Colab stellt die Grundlage für das Training des Deep-Learning-Modells dar. Die registrierten Datensätze können effizient geladen und verarbeitet werden, während die Visualisierung der Annotationen eine Überprüfung der Datenqualität ermöglicht. Dieser Schritt dient der frühzeitigen Erkennung und Behebung potenzieller Probleme oder Inkonsistenzen in den Daten, um optimale Ergebnisse beim Training des Modells zu erzielen.



*Abbildung 29: Visualisierung eines Bildes aus dem Trainingsdatensatz mit überlagerten Annotationen (Eigene Darstellung)*

### **3.3.5 Konfiguration und Training des Detectron2-Modells**

Nach der erfolgreichen Aufbereitung der Bilddaten und der Konvertierung in das COCO-Format erfolgt die Konfiguration und das Training des Detectron2-Modells. Dieser Schritt umfasst die Auswahl einer geeigneten Modellarchitektur, die Festlegung der Hyperparameter und die Durchführung des Trainingsprozesses.

Für die Segmentierung der Zellen in den PUR-Hartschaumproben wurde das Mask R-CNN-Modell ausgewählt, welches auf der Faster R-CNN-Architektur basiert und zusätzlich eine Instanzsegmentierung ermöglicht (He et al., 2017). Die Konfiguration des Modells erfolgte durch die Anpassung der Standardeinstellungen aus dem Detectron2 Model Zoo (Wu et al., 2019). Zu den weiteren Einstellungen gehören die Auswahl des Backbone-Netzwerks (ResNet-50 mit FPN), die Anzahl der Klassen (1 für die Zellen) sowie die Batch-Größe (2 Bilder pro Batch).

Ein wesentlicher Aspekt bei der Konfiguration ist die Festlegung der Lernrate sowie der Anzahl der Iterationen. Die Lernrate bestimmt die Schrittweite, mit der die Gewichte des neuronalen Netzes während des Trainings angepasst werden. Eine zu hohe Lernrate kann zu

Instabilität führen, während eine zu niedrige Lernrate das Training verlangsamt. Für das Training des Mask R-CNN-Modells wurde eine Lernrate von 0,00025 gewählt, die sich in Experimenten als geeignet erwiesen hat. Die Anzahl der Iterationen legt fest, wie oft das Modell die Trainingsdaten durchläuft. Eine höhere Anzahl an Iterationen ermöglicht eine bessere Anpassung des Modells an die Daten, birgt jedoch die Gefahr einer Überanpassung (Overfitting).

Das Training des Mask R-CNN-Modells erfolgte unter Verwendung der von Detectron2 bereitgestellten Trainingsroutinen. Dazu wurde eine Instanz der Klasse „DefaultTrainer“ erstellt, welche den Trainingsprozess steuert. Die Überprüfung, ob ein vortrainiertes Modell geladen werden soll, um das Training fortzusetzen, erfolgte durch den Aufruf der Methode „resume\_or\_load()“. In diesem Fall wurde jedoch ein vollständiges Training von Grund auf gestartet.

Im Rahmen des Trainings erfolgt eine iterative Anpassung der Gewichte des Modells, um die Verlustfunktion zu minimieren. Die Verlustfunktion setzt sich aus mehreren Komponenten zusammen, darunter der Klassifikationsverlust für die Erkennung der Zellen und der Segmentierungsverlust für die pixelgenaue Abgrenzung der Zellen. Die Gewichte des Modells werden im Rahmen der Optimierung derart angepasst, dass das Modell in der Lage ist, die relevanten Merkmale aus den Bilddaten zu extrahieren und die Zellen präzise zu segmentieren.

Das Training des Masken-R-CNN-Modells auf dem PUR-Hartschaumdatensatz nahm mehrere Stunden auf einer leistungsfähigen Grafikkarte in Anspruch. Während des Trainings wurden regelmäßig Checkpoints gespeichert, um den Fortschritt zu überwachen und die Möglichkeit zu haben, das Training zu einem späteren Zeitpunkt fortzusetzen.

### **3.3.6 Inferenz und Evaluierung auf Testdaten**

Nach dem erfolgreichen Training des Detectron2-Modells ist der nächste Schritt die Evaluierung der Leistung auf ungesehenen Testdaten. Der Prozess erlaubt die Beurteilung der Generalisierungsfähigkeit des Modells sowie die Sicherstellung, dass es nicht lediglich die Trainingsdaten auswendig gelernt hat, sondern auch auf neuen Daten gute Ergebnisse liefert.

Im nächsten Schritt erfolgt die Inferenz auf Testdaten. Dazu wird zunächst der Testdatensatz im COCO-Format registriert. Die Registrierung erfolgt analog zur Registrierung des Trainings- und Validierungsdatensatzes unter Verwendung der Funktion

„register\_coco\_instances()“ aus dem Modul „detectron2.data.datasets“ (Detectron2, 2023). Dabei werden der Pfad zur COCO-JSON-Datei sowie der Pfad zum Verzeichnis mit den Testbildern angegeben.

Im Anschluss wird eine Instanz der Klasse „DefaultPredictor“ erstellt, welche die Inferenz mit dem trainierten Modell ermöglicht. In einem nächsten Schritt wird die Konfiguration des Modells geladen und die trainierten Gewichte aus der Datei „model\_final.pth“ im Ausgabeverzeichnis des Trainings verwendet. Des Weiteren besteht die Möglichkeit, einen benutzerdefinierten Schwellenwert für die Objekterkennung festzulegen, um die Empfindlichkeit des Modells anzupassen.

Die Inferenz auf den Testdaten erfolgt durch Aufruf des DefaultPredictor auf den einzelnen Bildern. Die erkannten Objekte werden mit ihren Bounding Boxes, Segmentierungsmasken und Konfidenzwerten zurückgegeben. Die Ergebnisse können zudem visualisiert werden, um eine qualitative Bewertung der Leistung des Modells vorzunehmen.

Die quantitative Evaluierung der Modellleistung auf den Testdaten erfolgt mittels des COCOEvaluators aus dem Modul detectron2.evaluation. Der Evaluator berechnet verschiedene Metriken, darunter die mittlere durchschnittliche Präzision (mAP) für die Objekterkennung und die Intersection over Union (IoU) für die Segmentierung (Detectron2, 2023). In einem nächsten Schritt wird ein Datenloader für den Testdatensatz erstellt und die Inferenz auf den Testdaten durchgeführt. Der Evaluator vergleicht die durch das Modell generierten Vorhersagen mit den Ground-Truth-Annotationen und berechnet die entsprechenden Metriken.

Die Evaluierungsergebnisse geben Aufschluss darüber, in welchem Maße das trainierte Modell in der Lage ist, Zellen in den PUR-Hartschaumproben zu erkennen und zu segmentieren. Eine hohe mAP und IoU lassen auf eine gute Generalisierungsfähigkeit des Modells schließen, während niedrige Werte auf potenzielle Probleme wie Überanpassung oder unzureichende Trainingsdaten hindeuten können.

### **3.4 Veröffentlichung des entwickelten Codes auf GitHub**

Um die Transparenz, Reproduzierbarkeit und Zugänglichkeit des entwickelten KI-gestützten Bildverarbeitungstools zu gewährleisten, wurde der Quellcode auf der Plattform GitHub unter dem Repository "PUR-Check" veröffentlicht. Das Repository kann unter der URL <https://github.com/NouraldinIdrees/PUR-Check> aufgerufen werden. GitHub ermöglicht als

webbasiertes Versionskontrollsystem die effiziente Zusammenarbeit und Versionierung von Softwareprojekten (Informationen zu Git - GitHub-Dokumentation, o. D.)

Das Repository enthält den vollständigen Quellcode des entwickelten Tools sowie eine detaillierte Dokumentation zur Installation und Verwendung. Die Kernfunktionalität des Tools, basierend auf klassischen Bildverarbeitungsmethoden, ist in den Jupyter Notebooks "01a\_pur-cell-analysis.ipynb" und "01b\_pur-cell-analysis-(multi-image).ipynb" implementiert. Diese Notebooks ermöglichen eine schrittweise Nachvollziehbarkeit des Verarbeitungsprozesses.

Darüber hinaus enthält das Repository den Code für das Deep-Learning-Modell auf Basis des Detectron2-Frameworks in der Datei "02\_Detectron2\_COCO\_ImageSegmentation\_Pipeline.ipynb". Obwohl dieses Modell noch nicht die Genauigkeit der klassischen Bildverarbeitungsmethoden erreicht, bietet es eine Grundlage für zukünftige Weiterentwicklungen. Die Bereitstellung des Codes auf GitHub fördert nicht nur die Transparenz und Reproduzierbarkeit der Forschungsergebnisse, sondern ermöglicht auch die Einbindung der wissenschaftlichen Gemeinschaft in den Entwicklungsprozess. Durch die Möglichkeit, Fehler zu melden, Verbesserungsvorschläge einzureichen und eigene Beiträge beizusteuern, kann das Tool kontinuierlich verbessert und an neue Herausforderungen angepasst werden.

Um die Nutzung des Tools zu erleichtern, wurde eine ausführliche README-Datei erstellt, die Informationen zur Installation, den Abhängigkeiten und der Verwendung des Tools enthält. Zusätzlich wurde eine LICENSE-Datei hinzugefügt, die die Nutzungsbedingungen und Lizenzierung des Codes klar definiert.

Durch die Veröffentlichung auf GitHub wird zudem eine Möglichkeit geschaffen, zukünftige Anpassungen und Entwicklungen über die GitHub-eigene Versionskontrolle transparent nachzuverfolgen und die Community in die Weiterentwicklung des Projekts einzubinden. Darüber hinaus können Fehlerberichte eingereicht und Verbesserungsvorschläge gemacht werden, was die kontinuierliche Optimierung des Tools unterstützt.

## 4 ERGEBNISSE UND DISKUSSION

In diesem Kapitel werden die Ergebnisse der entwickelten Methoden zur Analyse von Polyurethan-Hartschaumproben vorgestellt und diskutiert. Der Schwerpunkt liegt dabei auf der klassischen Bildverarbeitungsmethode, die sich bei der Analyse als besonders effektiv erwiesen hat. Diese Methode wurde anhand von synthetischen Testbildern validiert, die speziell erstellt wurden, um die Leistungsfähigkeit des Analysetools zu überprüfen.

Die klassische Bildverarbeitungsmethode, die in Kapitel 3.2 detailliert beschrieben wurde, basiert auf etablierten Algorithmen wie Schwellwertverfahren, morphologischen Operationen und der Wasserscheidentransformation. Diese Methode hat sich als robust und effektiv für die Analyse der vorliegenden Röntgenmikroskopie-Aufnahmen erwiesen. Im Gegensatz dazu steht der Deep-Learning-Ansatz mit Detectron2, der in Kapitel 3.3 erläutert wurde und auf der Nutzung künstlicher neuronaler Netze zur Bildsegmentierung beruht.

In den folgenden Abschnitten werden zunächst die Ergebnisse der klassischen Bildverarbeitungsmethode anhand eines exemplarischen Röntgenmikroskopiebild einer PUR-Hartschaumprobe präsentiert. Anschließend wird die Leistungsfähigkeit des entwickelten Algorithmus anhand speziell erstellter Testbilder evaluiert. Diese Testbilder wurden mit bekannten geometrischen Eigenschaften generiert, um eine präzise Bewertung der Genauigkeit und Zuverlässigkeit des Verfahrens zu ermöglichen.

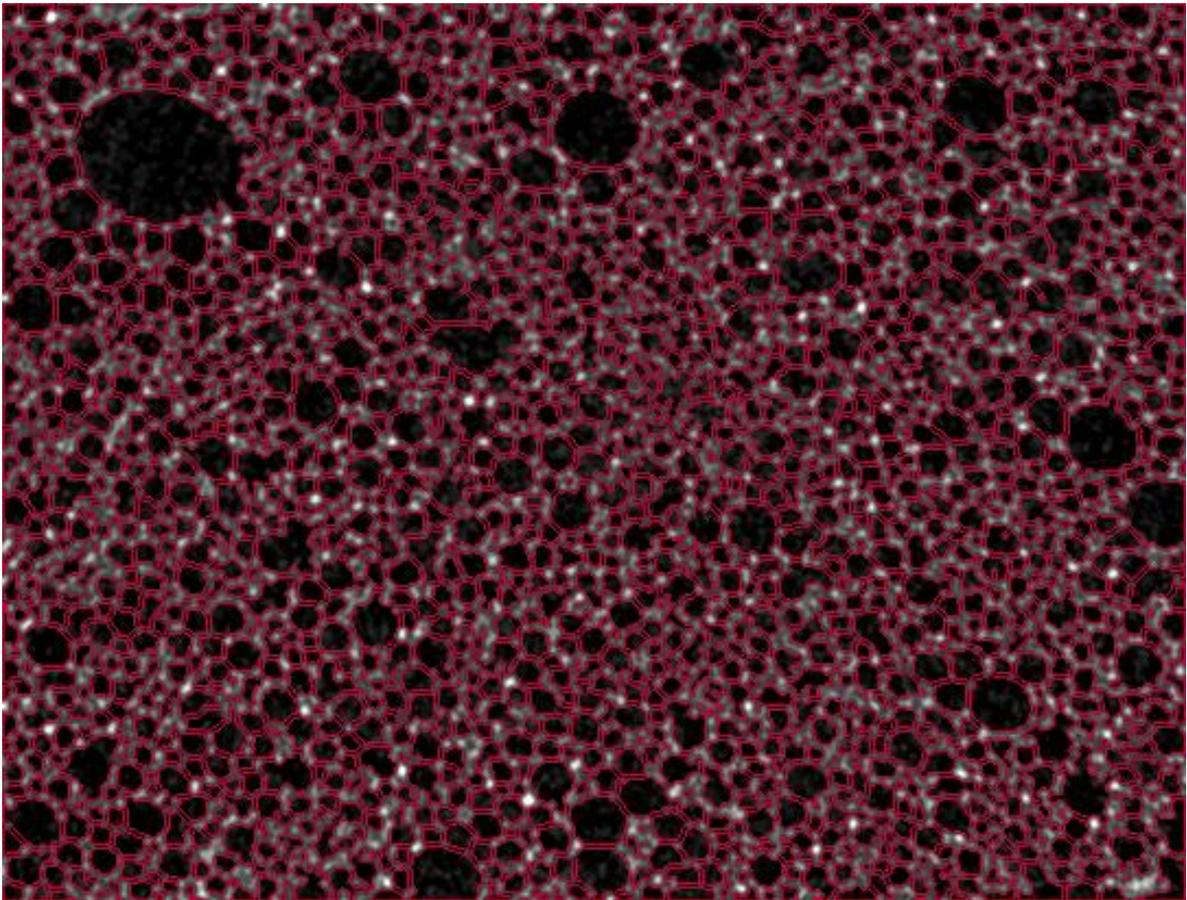
Die Ergebnisse des Deep-Learning-Ansatzes werden ebenfalls vorgestellt, wobei hier aufgrund der nicht zufriedenstellenden Leistung eine kritische Betrachtung der Limitationen und möglichen Ursachen für die suboptimalen Resultate erfolgt. Diese Analyse soll Einblicke in die Herausforderungen bei der Anwendung von Deep-Learning-Methoden auf die spezifische Problemstellung der PUR-Hartschaumanalyse geben und potenzielle Verbesserungsansätze aufzeigen.

### 4.1 Analyse eines repräsentativen Röntgenmikroskopiebildes der Polyurethan-Hartschaumprobe

Im Folgenden wird die Anwendung des entwickelten Bildverarbeitungsalgorithmus auf ein repräsentatives Röntgenmikroskopiebild der PUR-Hartschaumprobe demonstriert.

Der Code identifiziert die Konturen der Zellen im Bild mit hoher Zuverlässigkeit und zeichnet diese präzise ein. Abbildung 30 zeigt das Originalbild mit den eingezeichneten Konturen, welche die Zellgrenzen deutlich sichtbar machen. Die visuelle Darstellung

bestätigt die hohe Genauigkeit der Konturenerkennung, welche für die nachfolgende Analyse von entscheidender Bedeutung ist.



*Abbildung 30: Röntgenmikroskopiebild der PUR-Hartschaumprobe mit eingezeichneten Zellkonturen (Eigene Darstellung)*

Ein besonderes Augenmerk liegt auf der Effektivität der Wasserscheidentransformation. Diese Methode ermöglicht eine zuverlässige Trennung sich berührender Zellen, was für die genaue Quantifizierung der Materialmorphologie von entscheidender Bedeutung ist. Die Ergebnisse der Wasserscheidentransformation sind ebenfalls in Abbildung 30 dargestellt, wo die Zellen sauber voneinander getrennt sind.

Die quantitative Analyse liefert wesentliche Kennzahlen zur Charakterisierung der Schaumstruktur. Der Algorithmus berechnet unter anderem die durchschnittliche Zellfläche, den mittleren Zelldurchmesser und das Verhältnis der Zellenfläche zur Gesamtfläche. Diese Werte sind in Abbildung 31 dargestellt, welche einen Screenshot der Ergebnisse aus der Konsole zeigt. Abbildung 32 präsentiert die Histogramme für die Fläche und den Durchmesser der Zellen. Die dargestellten Ergebnisse resultieren aus der Analyse aller Zellen im gesamten Bild.

geladenes Bild: D:\Studium\Master\Masterarbeit\dataset\21251\_T1\_rec00000860.tif  
 Gesamtbildfläche: 125.82 mm<sup>2</sup>  
 Gesamtzellenfläche: 72.14 mm<sup>2</sup>  
 Fläche ohne Zellen: 53.68 mm<sup>2</sup>  
 Mittlere Zellenfläche: 0.0530 mm<sup>2</sup>  
 Größte Zellenfläche: 2.9563 mm<sup>2</sup>  
 Anzahl der Zellen: 1362  
 Verhältnis der Zellenfläche zur Gesamtbildfläche: 57.34%  
 Mittlerer Zelldurchmesser: 0.226 mm  
 Durchmesser der größten Zelle: 1.940 mm  
 Der mittlere Zelldurchmesser erfüllt die Anforderungen nach EN 253.

Abbildung 31: Screenshot der Konsole mit den berechneten Kennzahlen zur Zellstruktur

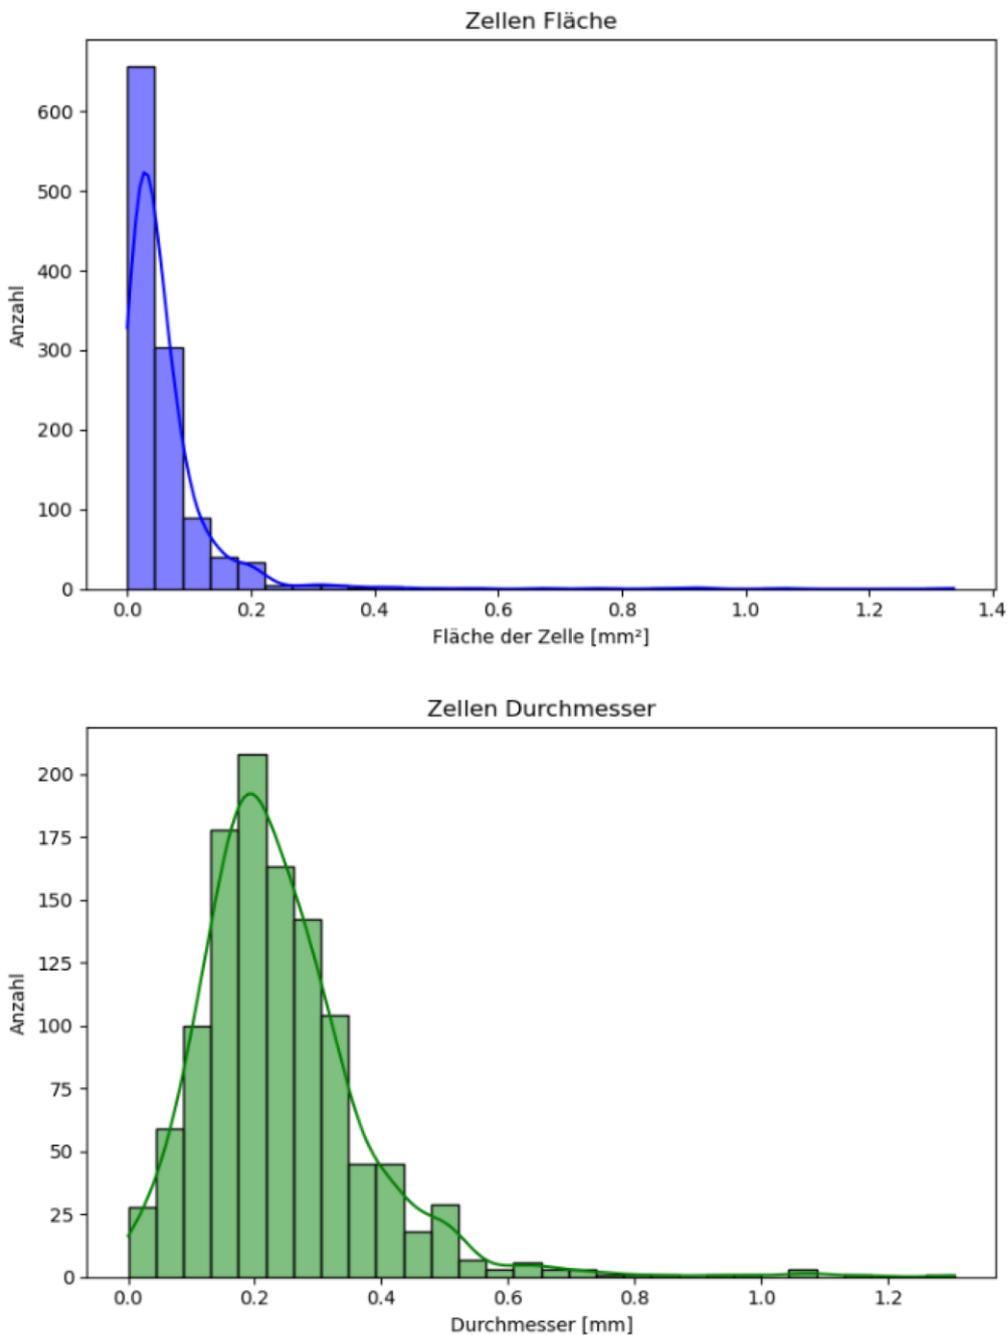
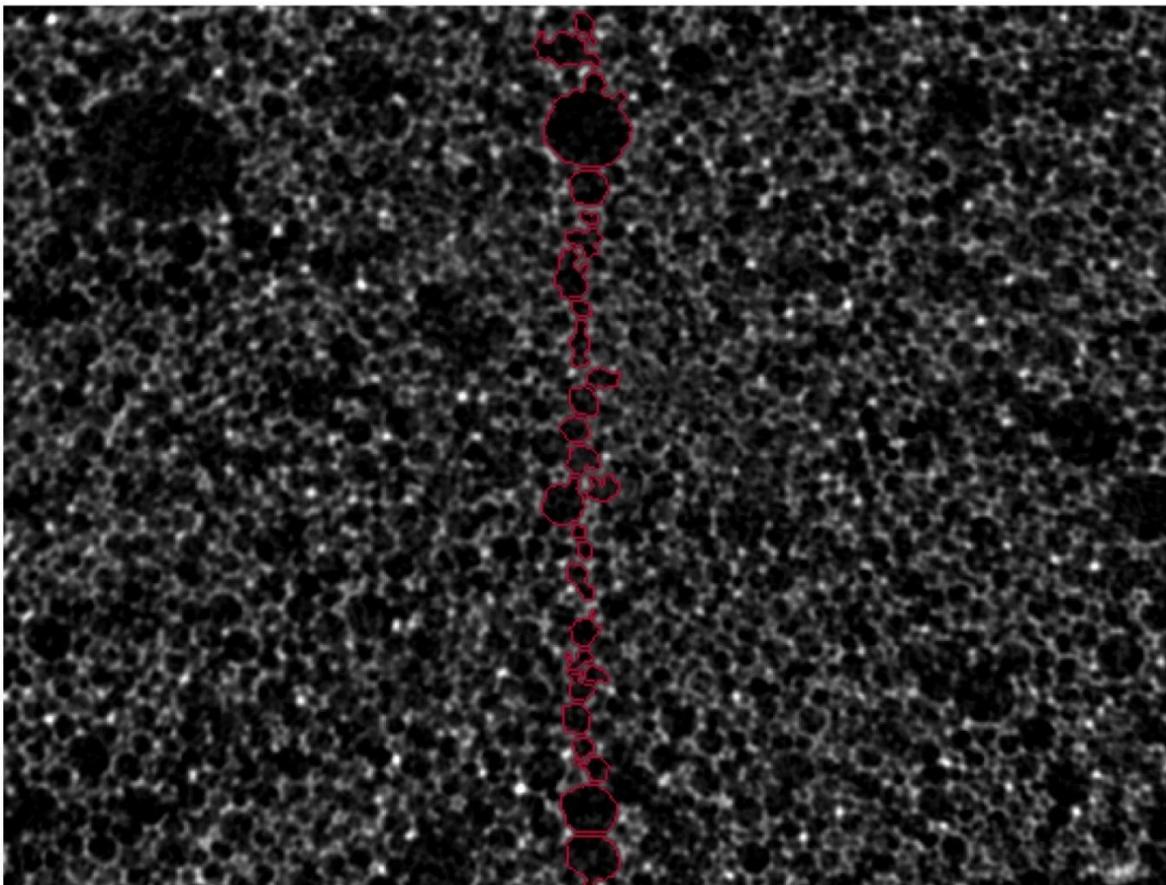


Abbildung 32: Histogramme der Zellflächen und Zelldurchmesser (Eigene Darstellung)

Abbildung 33 zeigt das Originalbild mit den eingezeichneten Konturen, jedoch unter Anwendung der Prüfmethode nach DIN 253. Bei dieser Methode werden die Zellen entlang einer 10 mm langen Linie gemessen, die sich ungefähr in der Mitte des Röntgenmikroskopiebildes befindet. Dies impliziert, dass nicht alle Zellen, sondern lediglich diejenigen, die diese Linie schneiden, Berücksichtigung finden. Die Abbildung präsentiert zudem die Resultate der Zellenvermessung, inklusive der Anzahl der Zellen, des Mittelwerts aller gefilterten Zellflächen, der größten gefilterten Zellfläche, des Mittelwerts aller gefilterten Zelldurchmesser, des Durchmessers der größten gefilterten Zelle sowie einer Bestätigung, dass der Durchmesser der mittleren gefilterten Zelle die Anforderungen der EN 253 erfüllt. Auch hier wird durch die visuelle Darstellung die hohe Genauigkeit der Konturenerkennung bestätigt.



Anzahl der gefilterte Zellen: 27  
Durchschnittliche Fläche der gefilterten Zellen:  $0.1169 \text{ mm}^2$   
Größte gefilterte Zellenfläche:  $0.7531 \text{ mm}^2$   
Durchschnittlicher Durchmesser der gefilterten Zellen:  $0.35 \text{ mm}$   
Durchmesser der größten gefilterten Zelle:  $0.98 \text{ mm}$   
Der Durchmesser der mittleren gefilterten Zelle erfüllt die Anforderungen nach EN 253.

*Abbildung 33: Zellkonturen und Ergebnissen der Zellenvermessung nach DIN 253 entlang einer 10 mm langen Linie (Eigene Darstellung)*

Die Distanztransformation wurde angewendet, um die Zellwanddicken zu berechnen. Die Ergebnisse dieser Analyse sind in Abbildung 34 visualisiert, die das farbkodierte Distanztransformationsbild der Zellwände zeigt. Bei der Distanztransformation handelt es sich um eine Bildverarbeitungstechnik, bei der jedem Pixel eines Binärbildes der Abstand zum nächstgelegenen Hintergrundpixel zugewiesen wird. In diesem Kontext bedeutet die Messung der Zellwanddicke die Ermittlung der Entfernung vom am weitesten entfernten Punkt des Materials zur Zelle, was nicht unbedingt der tatsächlichen Dicke entspricht.

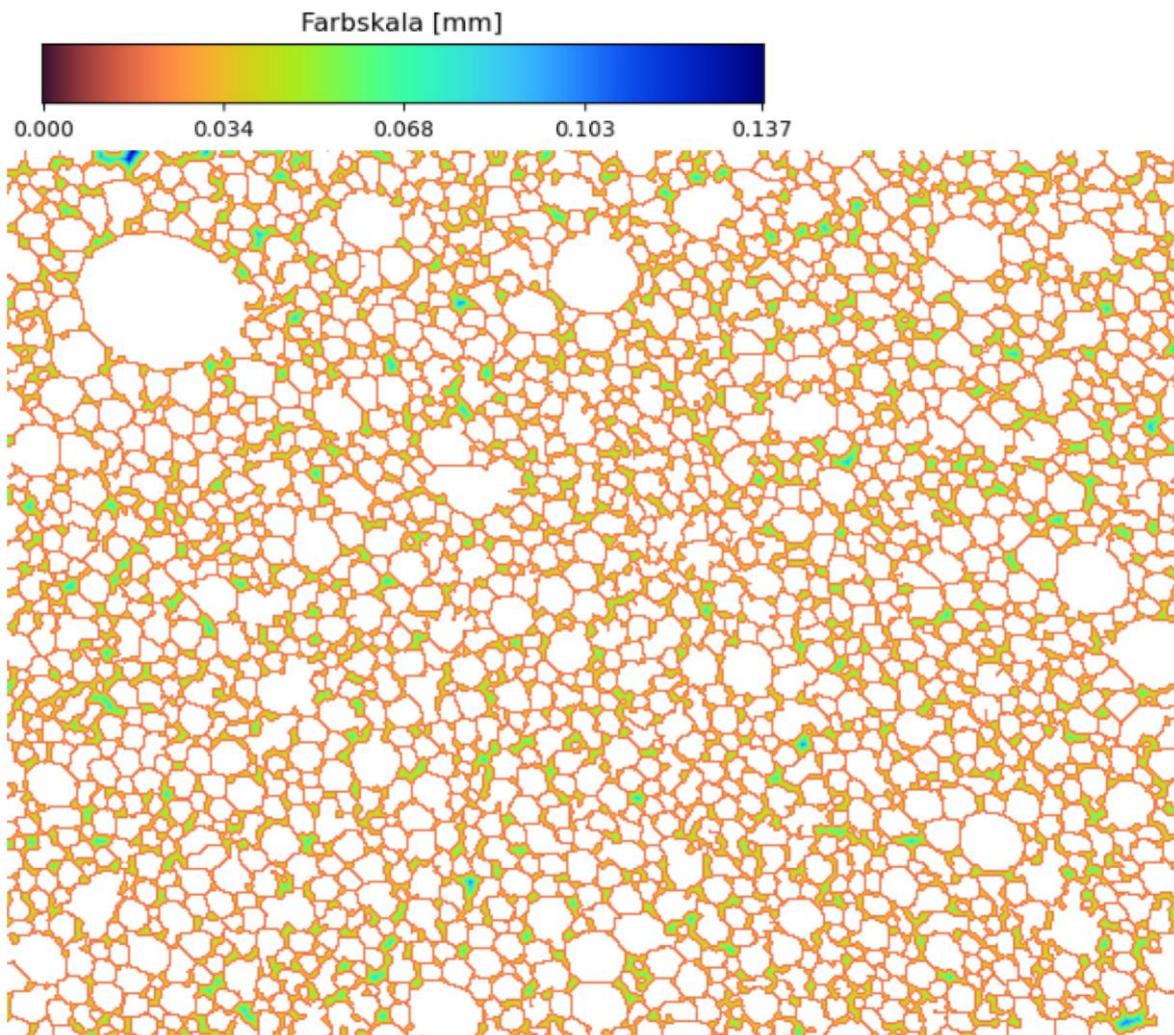


Abbildung 34: Farbkodiertes Distanztransformationsbild der Zellwände (Eigene Darstellung)

Der Code liefert für dieses Bild eine mittlere Wanddicke von 0,0332 mm sowie eine maximale Wanddicke von 0,1671 mm. Das Weibull-Verteilungsdiagramm für die Wanddicken ist in Abbildung 35 dargestellt. Dabei wurden ein Formparameter  $k$  von 1,5 und ein Skalenparameter  $\lambda$  von 0,05 verwendet.

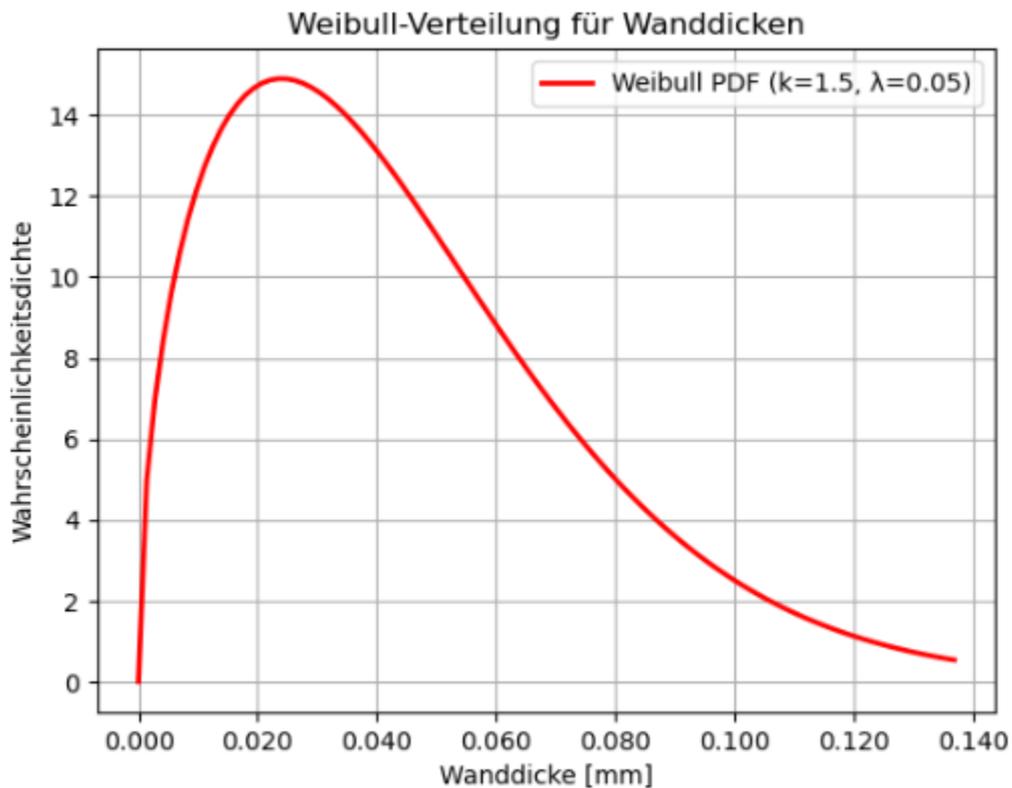


Abbildung 35: Weibull-Verteilungsdiagramm der Zellwanddicken (Eigene Darstellung)

Die Berechnungen der Wanddicken wurden durch eine manuelle Messung überprüft, um die Plausibilität zu kontrollieren. Die Ergebnisse stimmen hervorragend überein, was die Zuverlässigkeit des Analysetools unterstreicht.

## 4.2 Ergebnisse der Gesamtprobenanalyse

In diesem Abschnitt werden die Ergebnisse der Analyse der Polyurethan-Hartschaumprobe präsentiert. Der entwickelte Bildverarbeitungsalgorithmus wurde auf insgesamt 1242 Röntgenmikroskopiebilder angewendet, um eine detaillierte Charakterisierung der Zellstrukturen zu ermöglichen.

Die Analyse ergab, dass das Verhältnis der Zellenfläche zur Gesamtfläche für die bearbeiteten Bilder 54,43% beträgt. Dies deutet darauf hin, dass nahezu die Hälfte der Gesamtfläche von Zellstrukturen eingenommen wird, was für die Bewertung der Materialdichte und -homogenität von Bedeutung ist. Die mittlere Zellenfläche wurde mit 0,0454 mm<sup>2</sup> berechnet, während die größte Zellenfläche 5,3250 mm<sup>2</sup> beträgt. Diese Werte geben Aufschluss über die Variabilität der Zellgrößen innerhalb der Probe. Der Durchmesser der mittleren Zelle liegt bei 0,21 mm und erfüllt damit die Anforderungen nach EN 253, die eine spezifische Bandbreite für die Zellgrößen vorschreiben. Der Durchmesser der größten

Zelle beträgt 2,60 mm, was auf das Vorhandensein einiger größerer Zellstrukturen hinweist. Die Analyse der Zellwanddicken ergab eine mittlere Wanddicke von 0,0322 mm und eine maximale Wanddicke von 0,3248 mm. Diese Metriken sind entscheidend für die Bewertung der mechanischen Eigenschaften und der Wärmeleitfähigkeit des Materials.

Die Bearbeitung aller 1242 Bilder dauerte insgesamt 1 Minute und 52,95 Sekunden, was die Effizienz des entwickelten Analysetools unterstreicht. Diese schnelle Verarbeitung ermöglicht eine zeitnahe Qualitätsprüfung großer Datenmengen, was insbesondere in industriellen Anwendungen von Vorteil ist. Die Automatisierung des Analyseprozesses reduziert zudem den manuellen Aufwand. Sie minimiert potenzielle Fehlerquellen, die bei einer visuellen Inspektion auftreten könnten.

Zusätzlich wurde ein Histogramm für die Zelldurchmesser aller Röntgenmikroskopiebilder erstellt, das in Abbildung 36 dargestellt ist, sowie ein Diagramm, das einer Weibull-Verteilung entspricht, in Abbildung 37 dargestellt ist für die Wanddicken der gesamten Probe. Diese Darstellungen bieten eine klare Visualisierung der Datenverteilung und ermöglichen eine einfache Identifizierung von Ausreißern oder Anomalien in der Zellstruktur. Die Identifizierung solcher Ausreißer ist essenziell, um Schwachstellen im Material zu erkennen und gezielte Optimierungen vornehmen zu können.

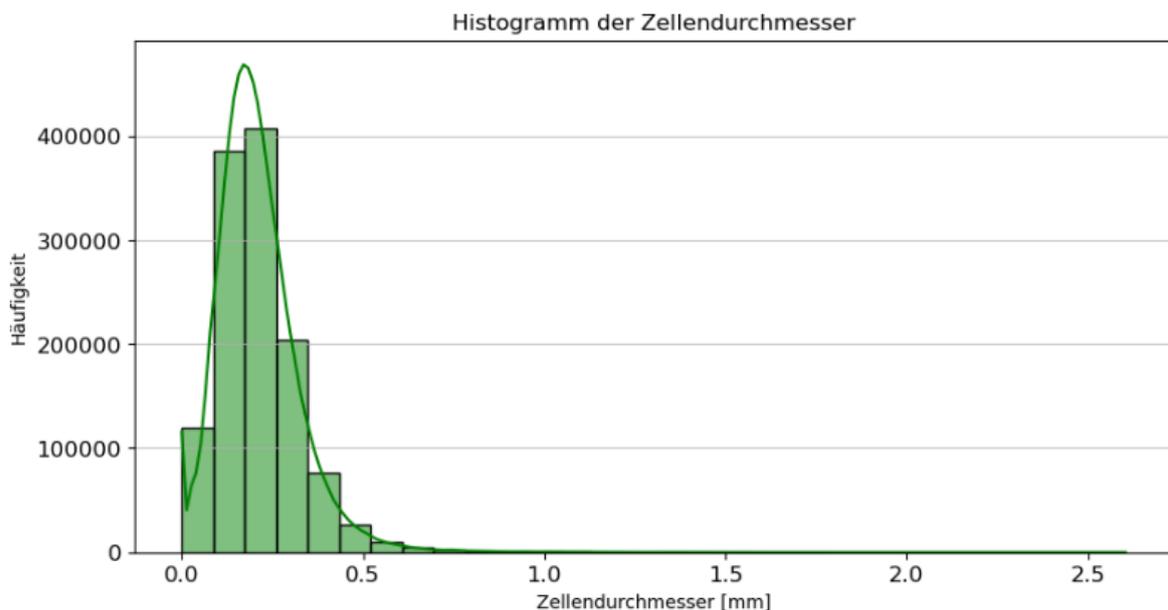


Abbildung 36: Histogramm der Zelldurchmesser aller Röntgenmikroskopiebilder (Eigene Darstellung)

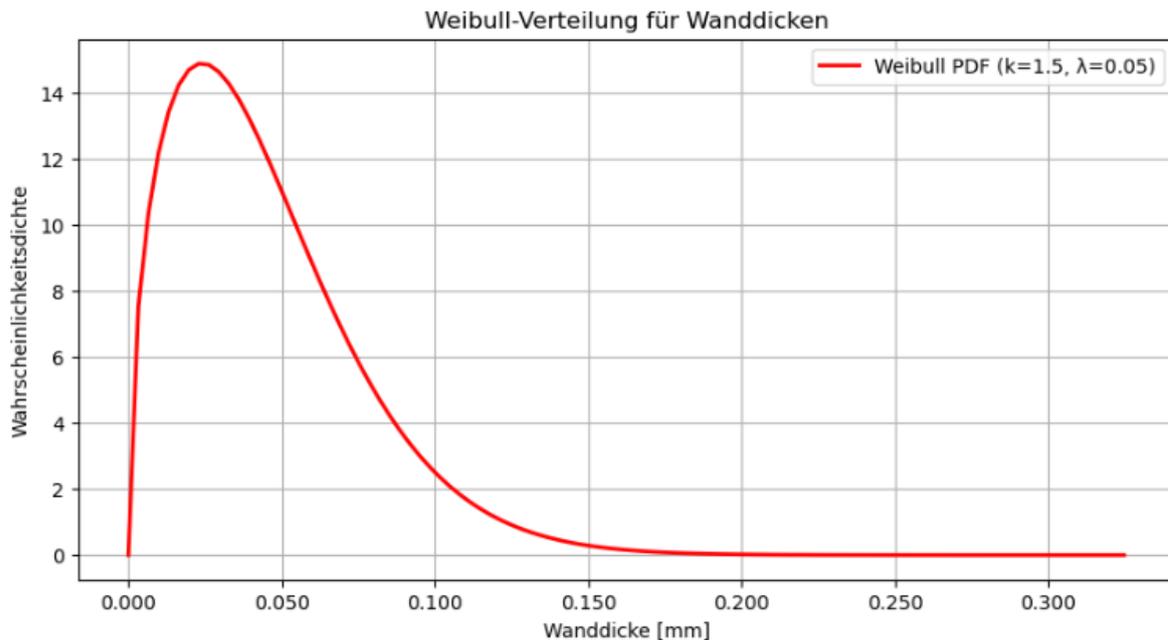


Abbildung 37: Weibull-Verteilung der Zellwanddicken für die gesamte Probe (Eigene Darstellung)

Insgesamt zeigt die Gesamtprobenanalyse, dass der entwickelte Bildverarbeitungsalgorithmus effektiv und effizient Zellstrukturen in PUR-Hartschaumproben charakterisieren kann. Die Ergebnisse liefern wertvolle Einblicke in die Materialeigenschaften und unterstützen die Qualitätssicherung und Optimierung von Fernwärmeisoliermaterialien. Diese Erkenntnisse sind insbesondere für die Weiterentwicklung nachhaltiger und leistungsfähiger Isolationsmaterialien von großer Bedeutung.

### 4.3 Validierung des Analysetools anhand synthetischer Testbilder

Die Validierung des entwickelten Analysetools erfolgte durch den Einsatz synthetischer Testbilder, die speziell zum Testen der Leistungsfähigkeit des Bildverarbeitungsalgorithmus erstellt wurden. Diese Testbilder dienen dazu, die Genauigkeit und Robustheit des Tools unter kontrollierten Bedingungen zu bewerten. Die synthetischen Bilder wurden so konzipiert, dass sie die Herausforderungen realer Röntgenmikroskopiebilder simulieren, insbesondere in Bezug auf geringe Kontrastunterschiede und überlappende Zellstrukturen.

#### 4.3.1 Methodik zur Erstellung der Testbilder

Die Testbilder wurden mit einem Grafikprogramm erstellt, um präzise kontrollierte Bedingungen zu gewährleisten. Jedes Bild enthält eine Anzahl von Kreisen, die die Zellen simulieren, mit definierten Durchmessern und Abständen. Die Farben der Kreise und des

Hintergrunds wurden bewusst so gewählt, dass der Kontrast gering ist, um die Fähigkeit des Analysetools zu testen, Zellen unter schwierigen Bedingungen zu erkennen. Diese Farbwahl spiegelt die typischen Herausforderungen bei der Analyse von Röntgenmikroskopiebildern wider, bei denen die Kontrastunterschiede zwischen den Zellstrukturen und dem umgebenden Material oft minimal sind.

Um die Wasserscheidentransformation zu testen, wurden einige Kreise so platziert, dass sie sich leicht überlappen. Diese Überlappung stellt sicher, dass der Algorithmus in der Lage ist, die Zellen korrekt zu trennen und die Zellgrenzen präzise zu bestimmen. Die Testbilder wurden in verschiedenen Varianten erstellt, um sowohl die Zelldurchmesser als auch die Wanddicken zu prüfen. Zwei Bilder wurden speziell zur Validierung der Zelldurchmesser erstellt, während ein weiteres Bild zur Bewertung der Distanztransformation und der Berechnung der Zellwanddicken diente.

Die synthetischen Testbilder bieten eine ideale Plattform zur Validierung des Analysetools, da sie es ermöglichen, die Ergebnisse mit den bekannten Parametern der Bilder zu vergleichen.

#### **4.3.2 Analyse der Testbilder für Zelldurchmesser**

Zur Validierung des Analysetools wurden zwei synthetische Testbilder erstellt, die speziell zur Überprüfung der Genauigkeit bei der Bestimmung der Zelldurchmesser konzipiert sind. Diese Testbilder unterscheiden sich in ihren Eigenschaften von den Röntgenmikroskopiebildern, insbesondere hinsichtlich der Auflösung. Die Testbilder wurden mit einer Auflösung von 300 DPI erstellt, was eine Anpassung des Umrechnungsfaktors im Code erforderte. Der angepasste Umrechnungsfaktor beträgt 0,085 mm pro Pixel. Diese synthetischen Testbilder ermöglichen eine präzisere Kontrolle der einzelnen Parameter und erlauben eine gezielte Analyse der Leistungsfähigkeit des entwickelten Algorithmus in spezifischen Szenarien.

Das erste Testbild, dargestellt in Abbildung 38, besteht aus 100 Zellen, die als Kreise mit einem einheitlichen Durchmesser von 50 mm angeordnet sind. Die Anordnung umfasst 10 Reihen und 10 Spalten, wobei die Zellen bewusst so platziert wurden, dass sie an allen vier Seiten überlappen. Diese Überlappung stellt eine Herausforderung für die Segmentierung dar und ermöglicht die Überprüfung der Effektivität der Wasserscheidentransformation. Durch die gezielte Überlappung werden insbesondere die Grenzen der

Segmentierungsverfahren ausgelotet, da eine korrekte Zelltrennung unter diesen Bedingungen eine höhere algorithmische Präzision erfordert.

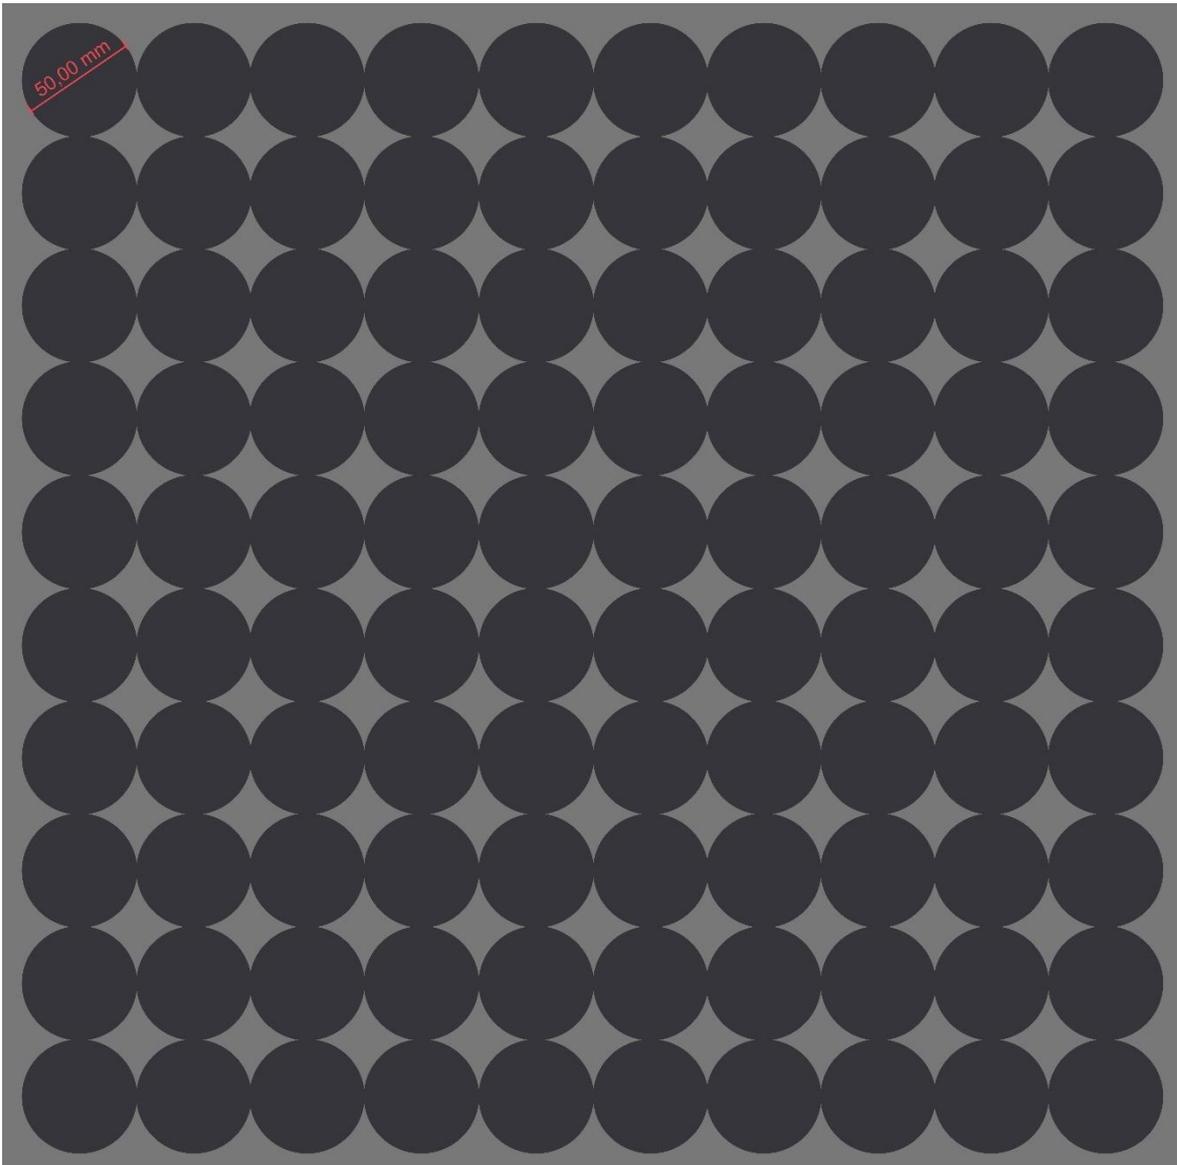
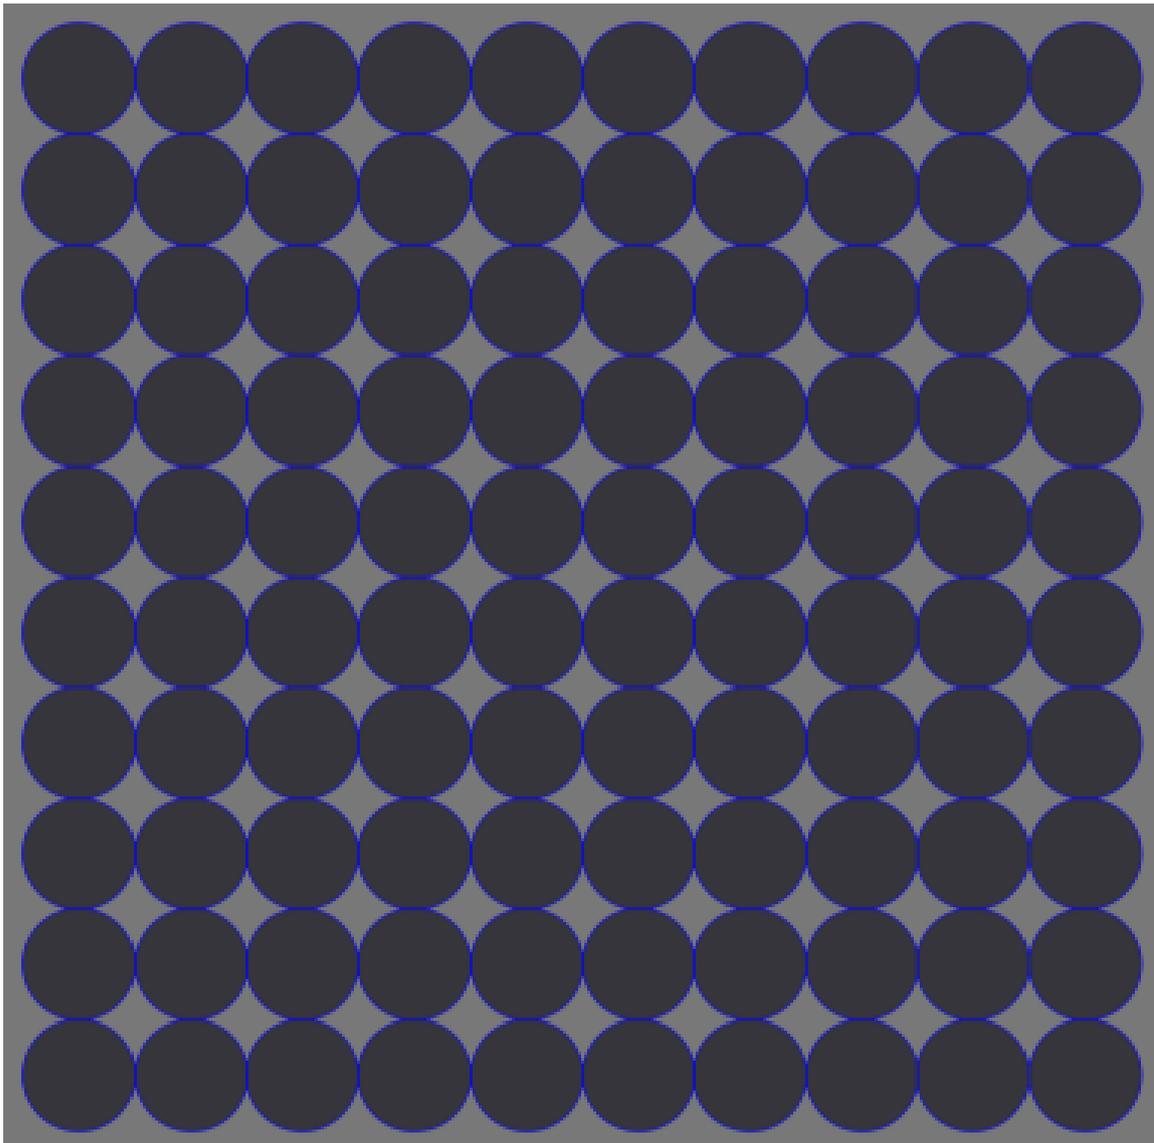


Abbildung 38: Synthetisches Testbild mit 100 Zellen (Eigene Darstellung)

Die Ergebnisse der Bildverarbeitung sind in Abbildung 39 dargestellt. Dabei werden die Wasserscheidenmaske mit den eingezeichneten Konturen sowie das Originalbild mit den erkannten Konturen gezeigt. Visuell lässt sich erkennen, dass die Wasserscheidentransformation die Zellen erfolgreich getrennt hat und die Konturen präzise um die Zellen gezeichnet wurden. Der Code liefert folgende Ergebnisse:

- Gesamtfläche des Bildes: 260.153,12 mm<sup>2</sup>
- Fläche aller Zellen: 195.522,13 mm<sup>2</sup>
- Fläche ohne Zellen: 64.630,99 mm<sup>2</sup>

- Mittelwert aller Zellenfläche: 1.955,2213 mm<sup>2</sup>
- Größte Zellenfläche: 1.960,5590 mm<sup>2</sup>
- Anzahl der Zellen: 100
- Verhältnis der Zellenfläche (Löcher) zur Gesamtfläche: 75,16%
- Mittelwert aller Zellen Durchmesser: 49,89 mm
- Durchmesser der größten Zelle: 49,96 mm



*Abbildung 39: Ergebnisse der Bildverarbeitung des ersten Testbildes mit eingezeichneten Konturen (Eigene Darstellung)*

Die mittels des Codes berechneten Ergebnisse belegen, dass die Zellen korrekt erkannt und die Überlappungen erfolgreich getrennt wurden. Andernfalls hätte der Algorithmus die Zellen als eine einzige Fläche identifiziert, was jedoch nicht der Fall war. Die ermittelten

Werte sind äußerst präzise, wobei die geringen Abweichungen auf die Überlappung der Zellen sowie die Rundung der Werte zurückzuführen sind.

Das zweite Testbild, dargestellt in Abbildung 40, besteht aus 12 Zellen, die als Kreise mit unterschiedlichen Durchmessern angeordnet sind. Die Durchmesser variieren zwischen 9 mm und 150 mm, was eine breite Palette von Zellgrößen abdeckt. Auch in diesem Bild überlappen sich die Zellen, um die Fähigkeit des Analysetools zur Trennung und Erkennung der Zellstrukturen zu testen.

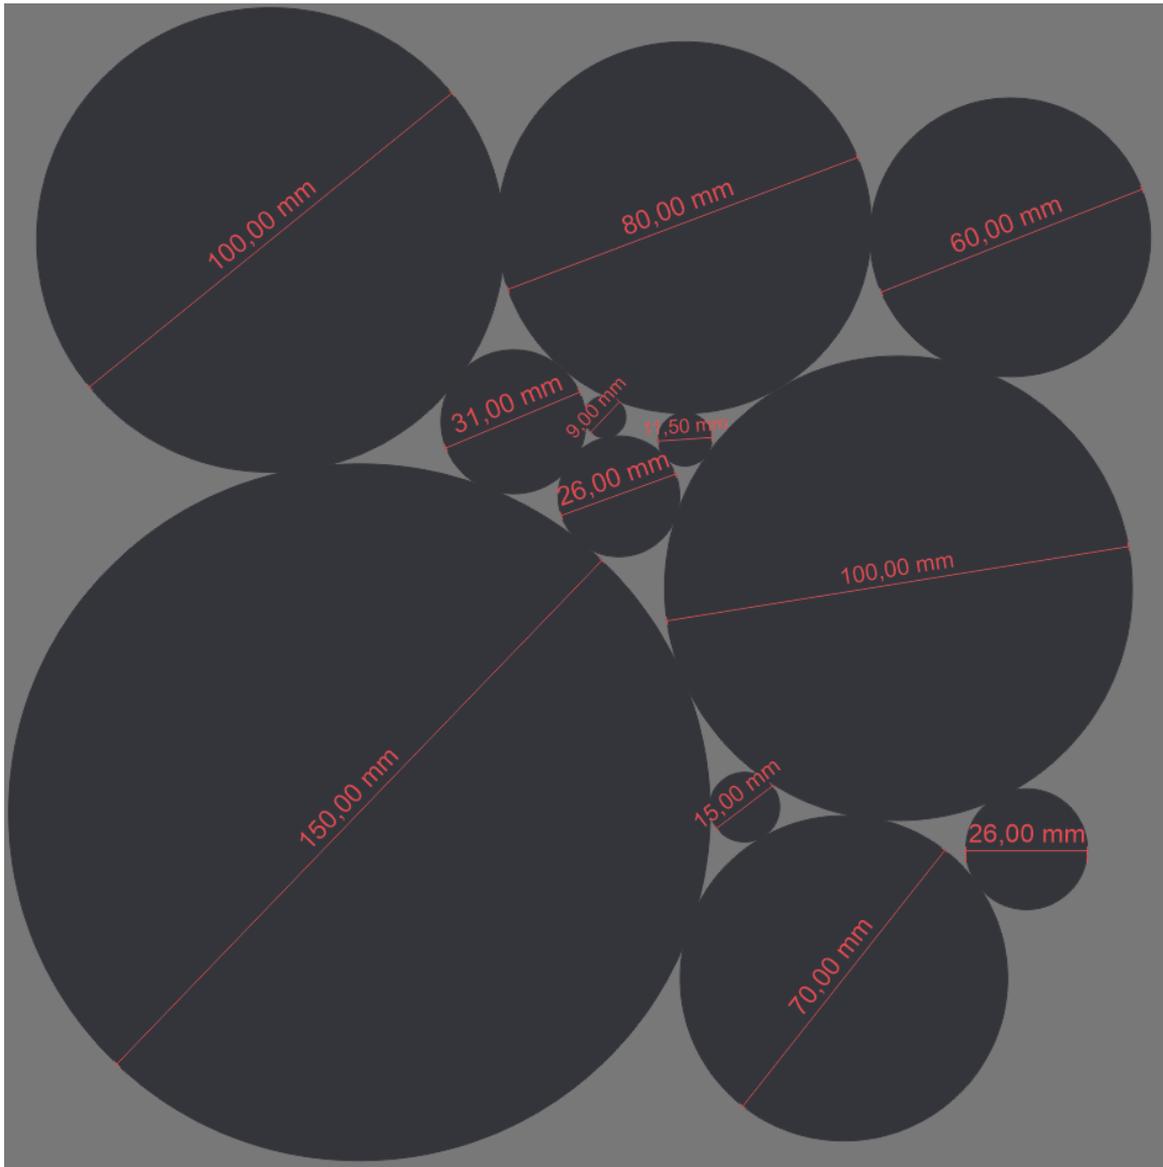
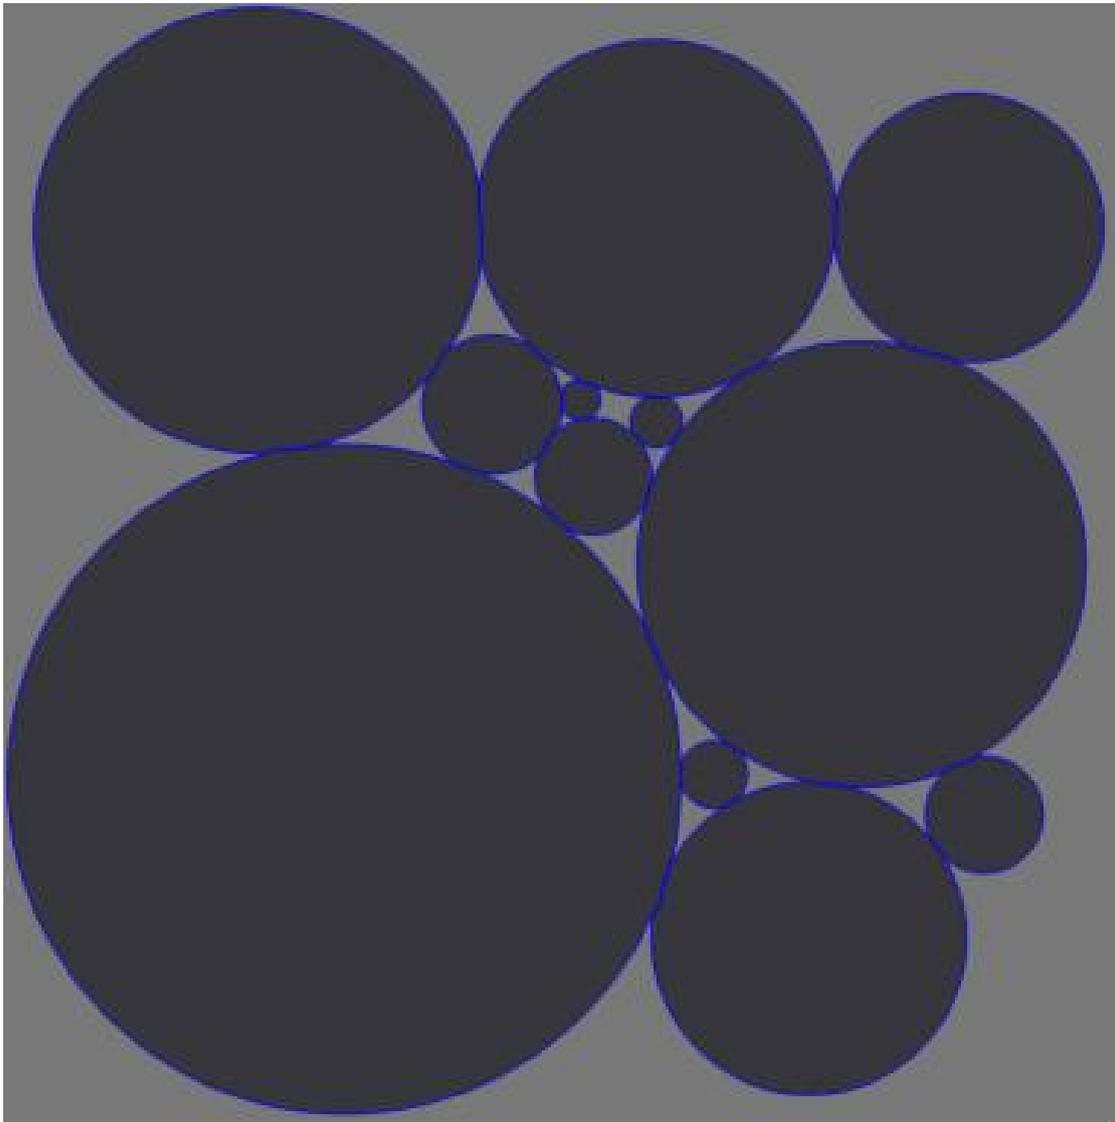


Abbildung 40: Synthetisches Testbild mit 12 Zellen unterschiedlicher Durchmesser (Eigene Darstellung)

Abbildung 41 zeigt die Ergebnisse der Bildverarbeitung, einschließlich der Wasserscheidenmaske und der eingezeichneten Konturen. Die visuelle Darstellung bestätigt, dass der Code die Zellen erfolgreich getrennt und die Konturen präzise gezeichnet hat. Dies

unterstreicht die Effektivität der Wasserscheidentransformation und der Konturenerkennung im Analysetool.



*Abbildung 41: Ergebnisse der Bildverarbeitung des zweiten Testbildes mit eingezeichneten Konturen (Eigene Darstellung)*

Die Ergebnisse der Zellvermessung aus dem Code sind nach aufsteigender Größe der Durchmesser in Millimetern gelistet:

Zelle	Berechneter Zelldurchmesser	Gezeichneter Zelldurchmesser
1	8,8 mm	9 mm
2	11,5 mm	11,5 mm
3	15,1 mm	15 mm
4	26,0 mm	26 mm
5	26,1 mm	26 mm

6	31,0 mm	31 mm
7	60,1 mm	60 mm
8	70,1 mm	70 mm
9	80,1 mm	80 mm
10	100,1 mm	100 mm
11	100,1 mm	100 mm
12	150,2 mm	150 mm

Die Ergebnisse zeigen eine hohe Präzision bei der Bestimmung der Zellendurchmesser. Die geringen Abweichungen sind auf die Überlappung der Zellen und die unvermeidliche Rundung der Werte bei der Umrechnung von Pixeln in Millimeter zurückzuführen. Diese Unterschiede sind jedoch sehr klein und vernachlässigbar, was die Zuverlässigkeit und Genauigkeit des Analysetools bei der Erkennung und Vermessung von Zellen in synthetischen Testbildern bestätigt.

Insgesamt demonstriert die Analyse der Testbilder, dass das Analysetool in der Lage ist, Zellen mit unterschiedlichen Größen und Überlappungen präzise zu erkennen und zu vermessen, was seine Eignung für die Anwendung auf reale Proben unterstreicht.

### **4.3.3 Analyse des Testbildes für Zellwanddicken**

Zur Validierung der Distanztransformation, die zur Bestimmung der Zellwanddicken verwendet wird, wurde ein spezielles Testbild erstellt. Diese Methode ermöglicht die präzise Messung der Wanddicken, indem sie die maximale Entfernung von der Mitte eines Kreises zur Zellwand berechnet. Um die Effektivität dieser Methode zu testen, wurde ein Bild mit invertierten Farben im Vergleich zu den zuvor erstellten Testbildern für die Zellendurchmesser verwendet. In diesem Fall repräsentieren die Kreise das Material, während der Hintergrund die Zellen (Löcher) darstellt.

Das Testbild besteht aus 10 Kreisen, die verschiedene Halbdurchmesser von 0,5 mm bis 5 mm aufweisen, wie in Abbildung 42 dargestellt. Diese Anordnung ermöglicht es, die Distanztransformation unter verschiedenen Bedingungen zu testen und die Genauigkeit der Wanddickenmessung zu evaluieren. Die Variation der Halbdurchmesser sorgt dafür, dass der Algorithmus auf unterschiedliche Zellgrößen angewendet werden kann, was die Robustheit der Methode weiter erhöht.

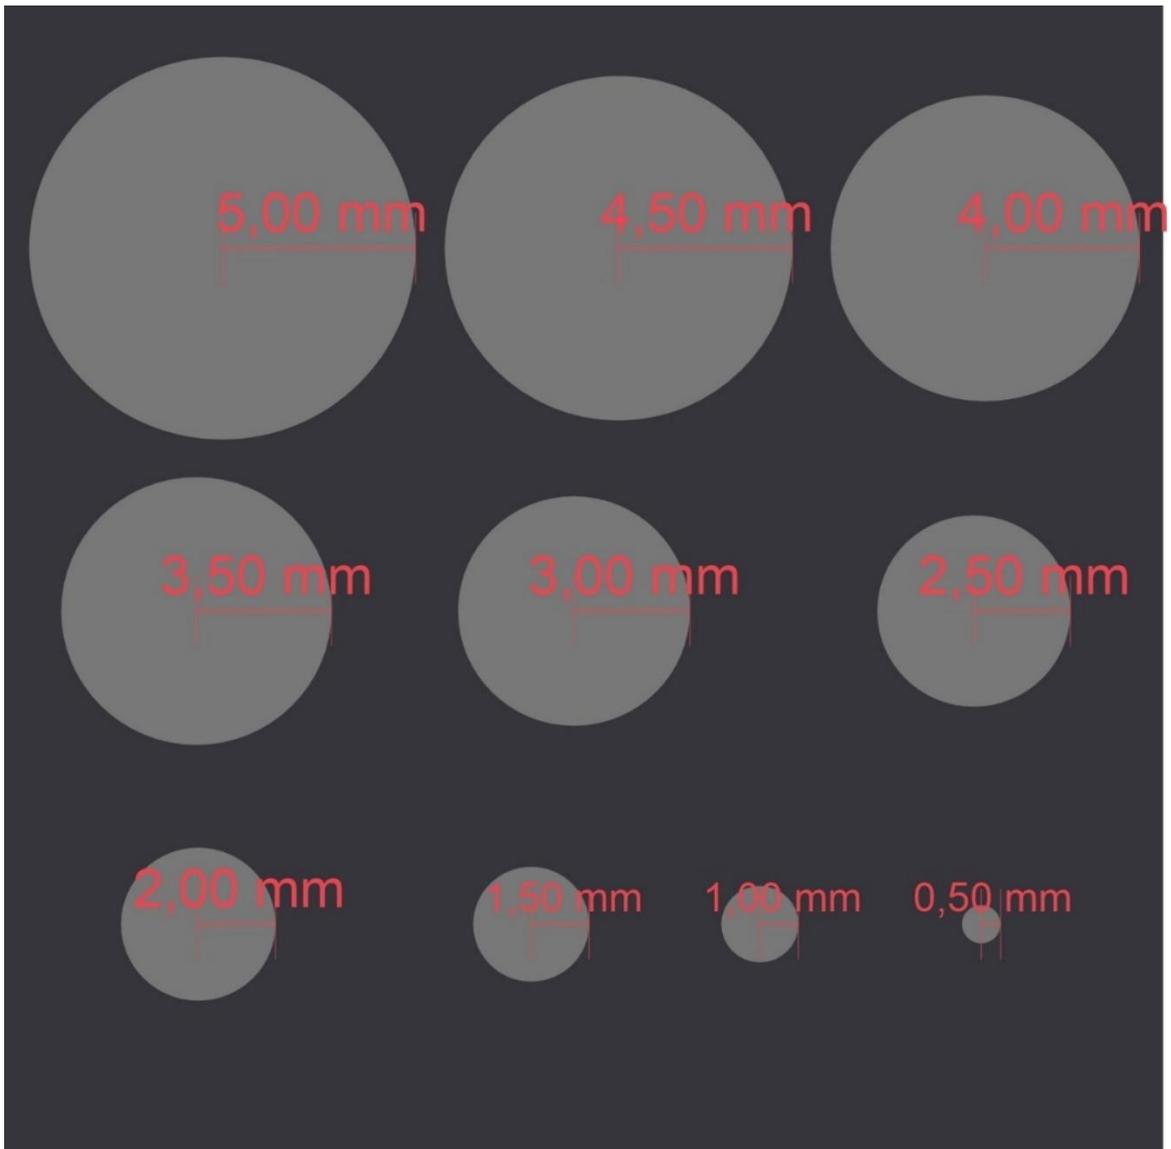


Abbildung 42: Testbild zur Validierung der Distanztransformation (Eigene Darstellung)

Abbildung 43 zeigt das Ergebnis der Bildverarbeitung mit dem farbcodierten Distanztransformationsbild und der zugehörigen Skala. Die Farbcodierung visualisiert die Wanddicken, wobei unterschiedliche Farben verschiedene Abstände repräsentieren.

Die folgenden Analyseergebnisse zeigen die berechneten Halbdurchmesser der Kreise in Millimetern:

Kreis	Berechneter Halbdurchmesser	Gezeichneter Halbdurchmesser
1	0,49 mm	0,5 mm
2	0,93 mm	1 mm
3	1,40 mm	1,5 mm
4	1,94 mm	2 mm

5	2,44 mm	2,5 mm
6	2,88 mm	3 mm
7	3,41 mm	3,5 mm
8	3,89 mm	4 mm
9	4,38 mm	4,5 mm
10	4,87 mm	5 mm

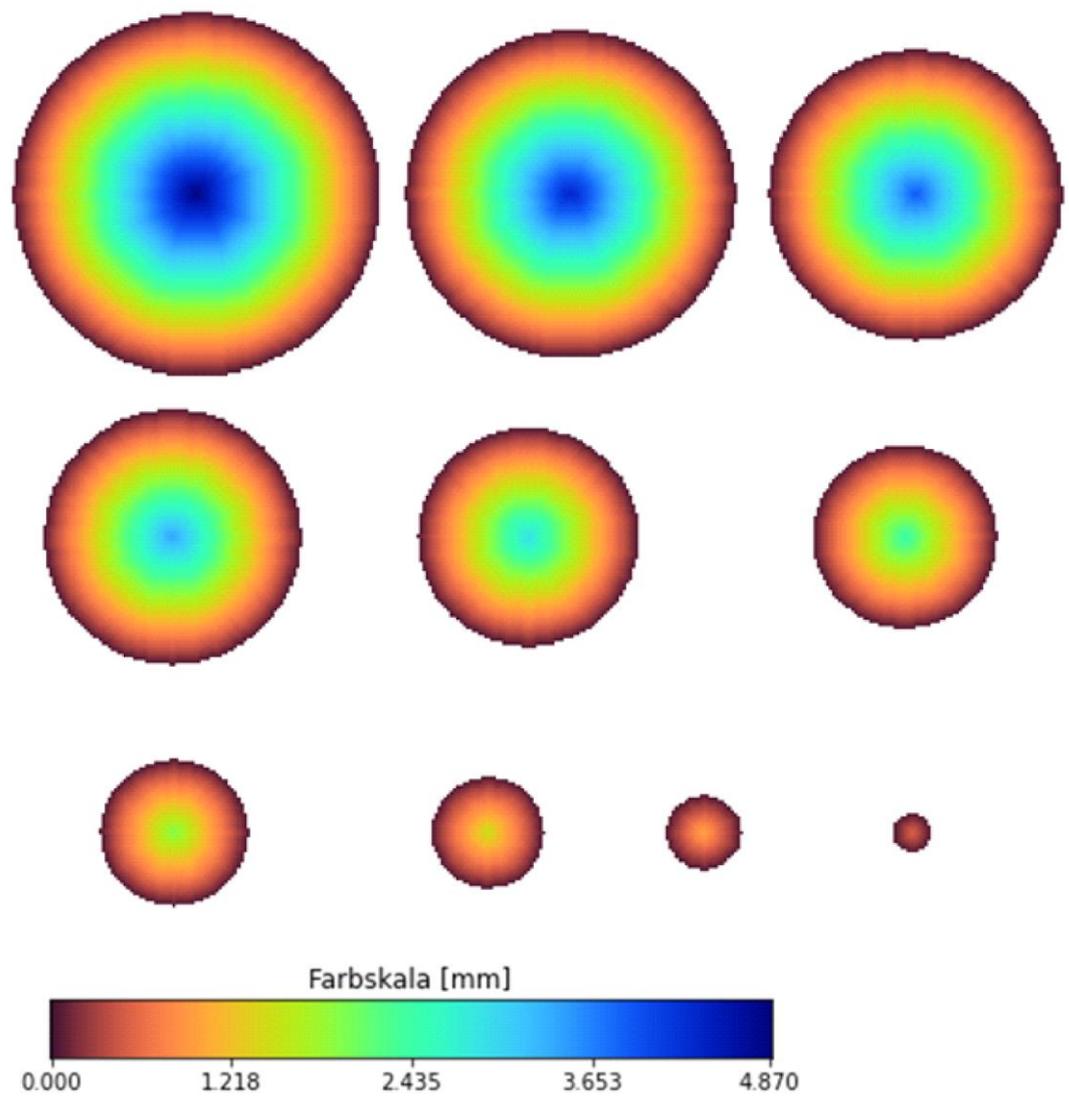


Abbildung 43: Farbkodiertes Distanztransformationsbild zur Visualisierung der Zellwanddicken mit zugehöriger Skala (Eigene Darstellung)

Die Ergebnisse sind bemerkenswert präzise und bestätigen die Fähigkeit des Analysetools, die Zellwanddicken genau zu bestimmen. Die geringen Abweichungen zwischen den berechneten und den tatsächlichen Werten sind vernachlässigbar und unterstreichen die

Zuverlässigkeit der Distanztransformation als Methode zur Messung der Zellwanddicken in synthetischen Testbildern. Es ist zu beachten, dass die Abweichung mit zunehmender Größe der Kreise leicht zunimmt, jedoch im Bereich von 0,1 mm bleibt. Dies ist unproblematisch, da die Zellwanddicken in realen Proben deutlich kleiner sind als die Abmessungen der Testbilder. Diese Validierung zeigt, dass das Analysetool effektiv für die Analyse von Zellwanddicken in realen Proben eingesetzt werden kann.

#### 4.4 Kurze Darstellung der Ergebnisse der Deep-Learning-Methode

In diesem Abschnitt werden die Ergebnisse der Anwendung der Deep-Learning-Methode mit Detectron2 zur Segmentierung von Zellen in Polyurethan-Hartschaumproben kurz dargestellt und bewertet. Trotz der vielversprechenden Ansätze im Bereich des maschinellen Lernens zeigte diese Methode in der aktuellen Implementierung keine zufriedenstellenden Ergebnisse.

Der Total Loss ist eine wichtige Metrik, die den Gesamtverlust des Modells während des Trainings darstellt. Nach 13.000 Iterationen betrug der Total Loss 1,75. Dieser Wert blieb nahezu konstant und verringerte sich nicht signifikant mit weiteren Iterationen. Abbildung 44 zeigt den Verlauf des Total Loss über die Iterationen, was die Konstanz des Verlusts verdeutlicht. Diese Konstanz deutet darauf hin, dass das Modell möglicherweise in einem lokalen Minimum steckengeblieben ist oder dass die Lernrate nicht optimal gewählt wurde.

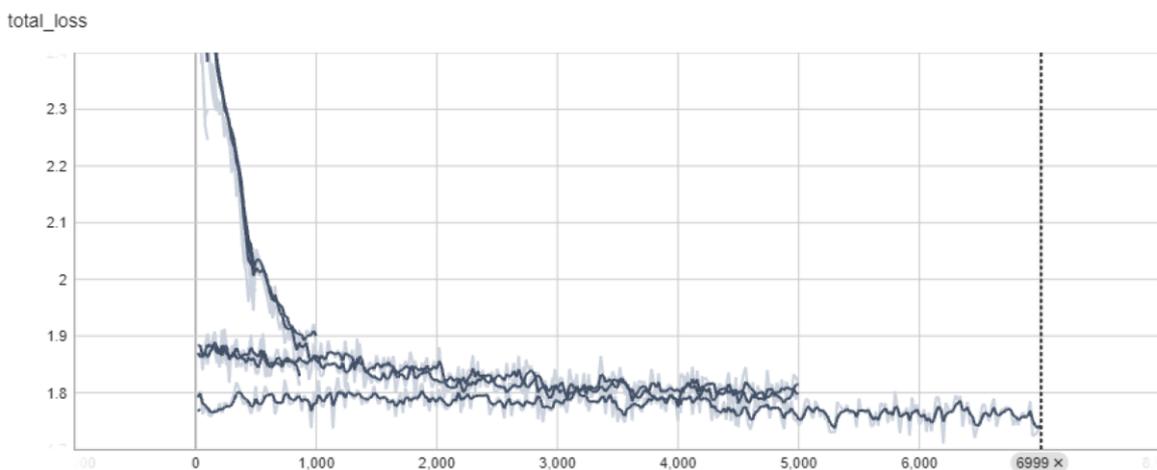


Abbildung 44: Verlauf des Total Loss über die Iterationen während des Trainings des Deep-Learning-Modells mit Detectron2 (Eigene Darstellung)

Die Überprüfung der Segmentierung auf zufälligen Testbildern ergab ebenfalls keine zufriedenstellenden Ergebnisse. Abbildung 45 zeigt ein Beispielbild mit den vom Code erkannten Instanzvorhersagen. Der Code identifiziert nur sehr wenige Zellen, die klar und

rund sind, und diese Zellen sind von Material umgeben, das im Bild sehr hell erscheint (hoher Kontrastunterschied). Dies deutet darauf hin, dass das Modell Schwierigkeiten hat, Zellen zu erkennen, wenn der Kontrast gering ist oder die Zellformen komplexer sind.

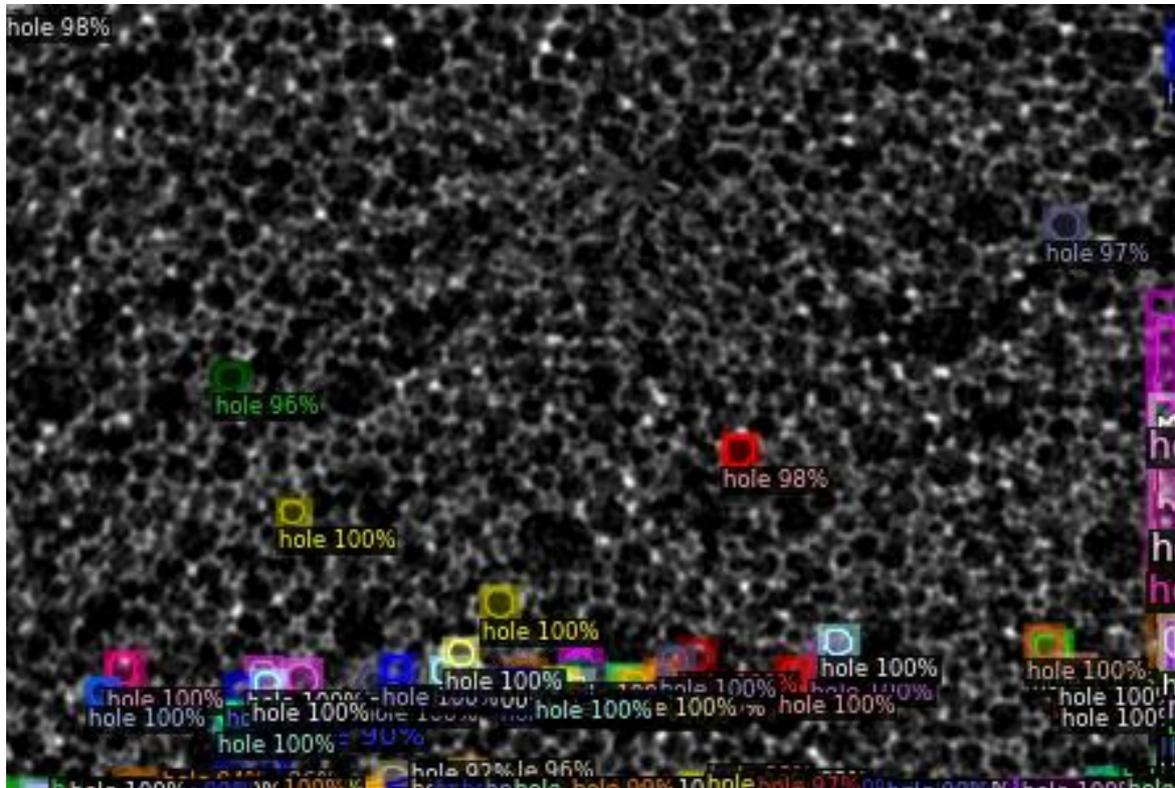


Abbildung 45: Beispielbild mit Instanzvorhersagen aus der Deep-Learning-Segmentierung (Eigene Darstellung)

Die Segmentierungsmetriken, einschließlich der Average Precision (AP) und des Recalls, bieten weitere Einblicke in die Modellleistung:

AP	AP50	AP75	APs	APm	APl
0.970	2.318	0.616	1.125	5.584	nan

Die Werte für Average Precision (AP) und die spezifischen AP-Werte für verschiedene IoU-Schwellenwerte (AP50, AP75) sind ungewöhnlich hoch, was auf eine mögliche Überanpassung oder Fehlklassifikation hinweist. Der Wert von APs (Small Objects) und APm (Medium Objects) ist ebenfalls ungewöhnlich, während der Wert für APl (Large Objects) nicht verfügbar ist. Diese Ergebnisse deuten darauf hin, dass das Modell möglicherweise Schwierigkeiten hatte, die Zellen konsistent und präzise zu erkennen, was zu einer ungenauen Bewertung der Segmentierungsmetriken führte.

Insgesamt zeigt die Analyse der Ergebnisse der Deep-Learning-Methode, dass diese Ansätze in diesem spezifischen Projekt nicht die erwarteten Ergebnisse lieferten. Die Konstanz des

Total Loss und die ungenauen Segmentierungsergebnisse deuten auf mögliche Probleme bei der Modellarchitektur, den Hyperparametern oder der Datenqualität hin. Diese Ergebnisse unterstreichen die Bedeutung einer sorgfältigen Evaluierung und Anpassung von Deep-Learning-Modellen an die spezifischen Anforderungen des Projekts.

## **4.5 Diskussion**

In diesem Kapitel werden die Ergebnisse der durchgeführten Analysen im Kontext der Zielsetzung und der theoretischen Grundlagen dieser Masterarbeit diskutiert. Die Diskussion zielt darauf ab, die Bedeutung der Ergebnisse zu interpretieren, ihre Implikationen für die Praxis zu erörtern und mögliche Limitationen sowie Ansätze für zukünftige Forschungen aufzuzeigen.

### **4.5.1 Zusammenfassung der Ergebnisse**

Die in dieser Arbeit entwickelten Methoden zur Analyse von Polyurethan-Hartschaumproben haben sich als effektiv erwiesen, insbesondere die klassische Bildverarbeitungsmethode. Diese Methode zeigte eine hohe Präzision bei der Erkennung und Vermessung der Zellstrukturen in den Röntgenmikroskopiebildern. Die Anwendung der Wasserscheidentransformation ermöglichte eine zuverlässige Trennung überlappender Zellen, was für die genaue Quantifizierung der Materialmorphologie entscheidend war.

Die Validierung des Analysetools mit synthetischen Testbildern bestätigte die Genauigkeit der Zellendurchmesser- und Zellwanddickenmessungen. Die berechneten Werte stimmten eng mit den bekannten Parametern der Testbilder überein, was die Zuverlässigkeit des Tools unterstrich. Diese hohe Übereinstimmung zeigt, dass das Analysetool in der Lage ist, auch komplexe Strukturen präzise zu messen, was für den Einsatz in der Materialforschung und Qualitätskontrolle von entscheidender Bedeutung ist.

Im Gegensatz dazu lieferte die Deep-Learning-Methode mit Detectron2 keine zufriedenstellenden Ergebnisse. Der Total Loss blieb trotz zahlreicher Iterationen konstant hoch, und die Segmentierungsmetriken zeigten eine unzureichende Präzision bei der Erkennung von Zellen. Diese Diskrepanz weist auf potenzielle Herausforderungen hin, wie unzureichende Datenqualität oder suboptimale Hyperparameter.

Die Ergebnisse dieser Arbeit tragen zur digitalen Transformation in der Materialprüfung bei, indem sie ein automatisiertes Analysetool bereitstellen, das eine effiziente und zuverlässige Bewertung von PUR-Hartschaumproben ermöglicht.

#### **4.5.2 Vorteile und Potenziale des entwickelten Analysetools**

Die Entwicklung des Analysetools zur automatischen Erkennung und Bemessung von Zellgrößen in Fernwärmeisoliermaterialien stellt einen bedeutenden Fortschritt gegenüber den bisher in der Praxis angewandten manuellen Methoden dar. Das Tool ermöglicht eine schnelle und effiziente Überprüfung der Konformität von Proben mit den Anforderungen der DIN 253, was zu erheblichen Zeit- und Arbeitersparnissen führt. Darüber hinaus bietet die automatisierte Analyse eine höhere Genauigkeit im Vergleich zu manuellen Messungen, die anfällig für menschliche Fehler sein können.

Ein wesentlicher Vorteil des entwickelten Tools besteht darin, dass es alle Zellen im Bild erfasst und somit auf die gesamte Probe angewendet werden kann. Dies ermöglicht eine umfassendere Analyse im Vergleich zur vereinfachten Methode nach DIN 253, bei der nur die Zellen entlang einer 10 mm langen Linie in der Probe berücksichtigt werden. Durch die Einbeziehung aller Zellen können aussagekräftigere Ergebnisse erzielt und potenzielle lokale Abweichungen in der Zellstruktur identifiziert werden.

Ein weiterer bedeutender Aspekt des Analysetools ist die Fähigkeit, die Zellwanddicken zu berechnen und zu visualisieren. Die manuelle Messung der Zellwanddicken ist äußerst schwierig, wenn nicht sogar unmöglich, insbesondere bei komplexen Zellstrukturen. Obwohl die Zellwanddicke in der DIN 253 nicht explizit behandelt wird, ist sie ein wichtiger Parameter zur Bewertung der Materialeigenschaften. Durch die automatisierte Analyse der Zellwanddicken können wertvolle Erkenntnisse über die Qualität und Leistungsfähigkeit des Isoliermaterials gewonnen werden.

Die vom Analysetool generierten Histogramme und visuellen Darstellungen bieten zusätzliche Einblicke in die Verteilung der Zellgrößen und -wanddicken. Diese Informationen können für verschiedene Anwendungen und Bewertungen nützlich sein, wie z. B. für die Optimierung des Herstellungsprozesses, die Qualitätskontrolle oder die Entwicklung neuer Isoliermaterialien. Durch die visuelle Aufbereitung der Ergebnisse wird die Interpretation und Kommunikation der Daten erleichtert, was die Entscheidungsfindung und Zusammenarbeit zwischen Forschung und Industrie unterstützt.

Insgesamt demonstrieren die Ergebnisse das Potenzial des entwickelten Analysetools, die Charakterisierung von Fernwärmeisoliermaterialien zu verbessern und zu automatisieren. Die Effizienzsteigerung, die erhöhte Genauigkeit und die Erfassung zusätzlicher Parameter wie der Zellwanddicke eröffnen neue Möglichkeiten für die Qualitätskontrolle und die Entwicklung leistungsfähigerer Isoliermaterialien. Dennoch sind weitere Untersuchungen

erforderlich, um die Robustheit und Übertragbarkeit des Tools auf verschiedene Materialtypen und Herstellungsverfahren zu validieren. Zukünftige Entwicklungen könnten die Integration von Machine-Learning-Algorithmen zur automatischen Klassifizierung von Zellstrukturen oder die Erweiterung des Tools auf andere Anwendungsbereiche wie die Bauindustrie umfassen.

### **4.5.3 Vergleich der Methoden**

Im Rahmen dieser Arbeit wurden zwei Ansätze zur Analyse von Fernwärmeisoliermaterialien untersucht: die klassische Bildverarbeitungsmethode und die Deep-Learning-Methode. Beide Methoden weisen unterschiedliche Stärken und Herausforderungen auf, welche im Folgenden erörtert werden.

Die klassische Bildverarbeitungsmethode erwies sich als äußerst effektiv bei der Erkennung und Vermessung der Zellstrukturen in den Röntgenmikroskopiebildern. Durch die Anwendung von Techniken wie Binarisierung, Wasserscheidentransformation und Konturerkennung konnten präzise Ergebnisse erzielt werden. Die Methode zeigte eine hohe Genauigkeit bei der Bestimmung von Zellgrößen und -wanddicken und ermöglichte eine zuverlässige Bewertung der Materialeigenschaften. Im Gegensatz dazu lieferte die Deep-Learning-Methode unter Verwendung von Detectron2 keine zufriedenstellenden Ergebnisse. Die Anwendung von Deep Learning auf die Analyse von Fernwärmeisoliermaterialien bringt mehrere Herausforderungen mit sich. Zunächst erforderten die Entwicklung und Optimierung eines Deep-Learning-Modells umfangreiches Fachwissen und Erfahrung. Die Auswahl geeigneter Architekturen, Hyperparameter und Trainingsstrategien ist komplex und zeitaufwendig. Darüber hinaus erfordert das Training eines Deep-Learning-Modells große Rechenressourcen, die auf normalen Computern oft nicht verfügbar sind. In dieser Arbeit wurde daher Google Colab verwendet, was jedoch auch Einschränkungen hinsichtlich der Rechenleistung und Trainingsdauer mit sich brachte. Diese Limitationen erschwerten die Feinabstimmung des Modells und die Untersuchung des Einflusses verschiedener Parameter auf die Ergebnisse. Es gibt mehrere mögliche Gründe für die unzureichende Leistung der Deep-Learning-Methode in dieser Arbeit. Ein Hauptfaktor könnte die begrenzte Größe des verfügbaren Datensatzes sein. Deep-Learning-Modelle erfordern typischerweise große Mengen an annotierten Trainingsdaten, um robuste Ergebnisse zu erzielen. Eine Erweiterung des Datensatzes durch zusätzliche Aufnahmen und Annotationen könnte die Leistung des Modells verbessern. Darüber hinaus könnten längere Trainingszeiten und die systematische Untersuchung verschiedener Hyperparameter und

Architekturen dazu beitragen, die Genauigkeit des Modells zu steigern. Trotz der Herausforderungen birgt die Deep-Learning-Methode ein erhebliches Potenzial für die Analyse von Fernwärmeisoliermaterialien. Ein gut trainiertes Deep-Learning-Modell könnte in der Lage sein, komplexe Zellstrukturen zu erkennen und zu segmentieren, die mit klassischen Bildverarbeitungstechniken schwer zu erfassen sind. Darüber hinaus könnte ein Deep-Learning-Ansatz die Automatisierung des Analyseprozesses weiter vorantreiben und die Übertragbarkeit auf verschiedene Materialtypen und Bildmodalitäten verbessern.

Ein direkter Vergleich der Ergebnisse der klassischen Bildverarbeitungsmethode und der Deep-Learning-Methode mit Detectron2 anhand desselben Bildes "212S1\_T1\_rec00001216" verdeutlicht die Unterschiede in der Leistungsfähigkeit beider Ansätze. Abbildung 46 zeigt das Ergebnis der Zellsegmentierung mit Detectron2, während Abbildung 47 das Resultat der Bildverarbeitungsmethode präsentiert.

Es ist offensichtlich, dass die Bildverarbeitungsmethode in diesem Fall deutlich bessere Ergebnisse liefert. Die Konturen der Zellen wurden präzise erkannt und gezeichnet, was eine zuverlässige Quantifizierung der Zellgrößen und -wanddicken ermöglicht. Im Gegensatz dazu weist das Ergebnis von Detectron2 erhebliche Mängel auf. Nur sehr wenige Zellen wurden korrekt identifiziert, und die Segmentierung ist insgesamt unzureichend.

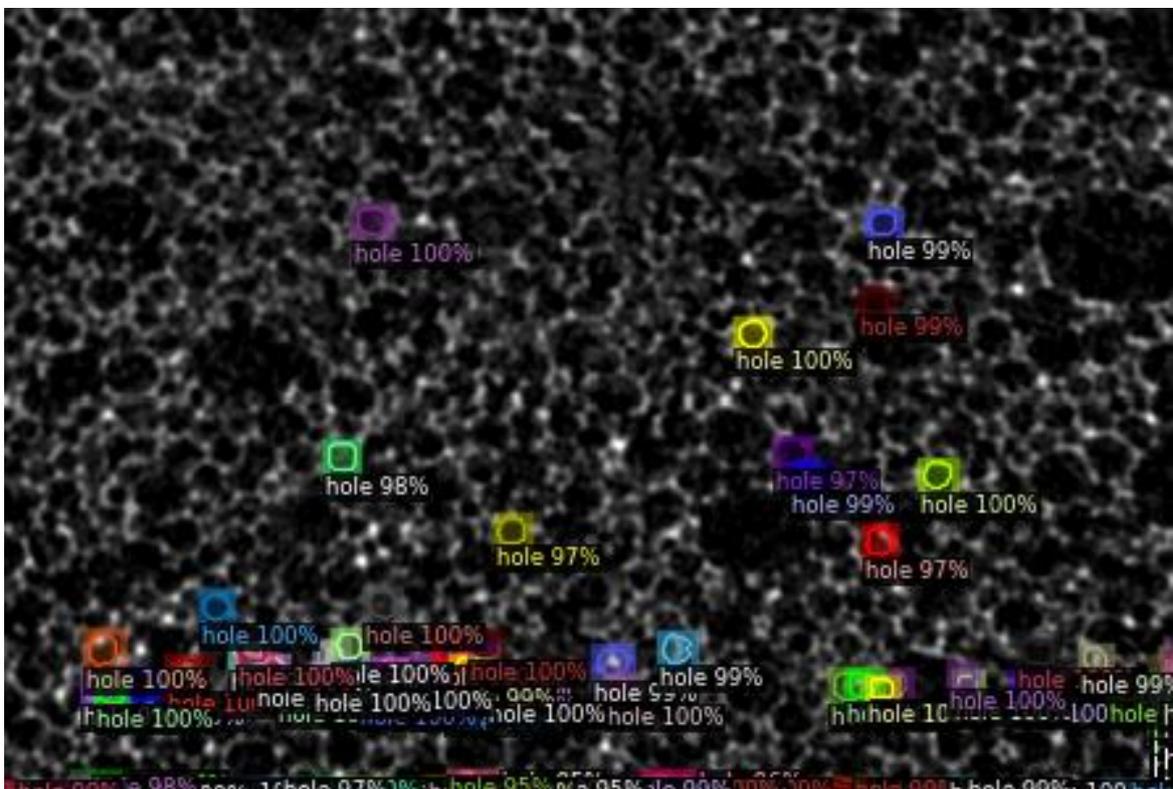
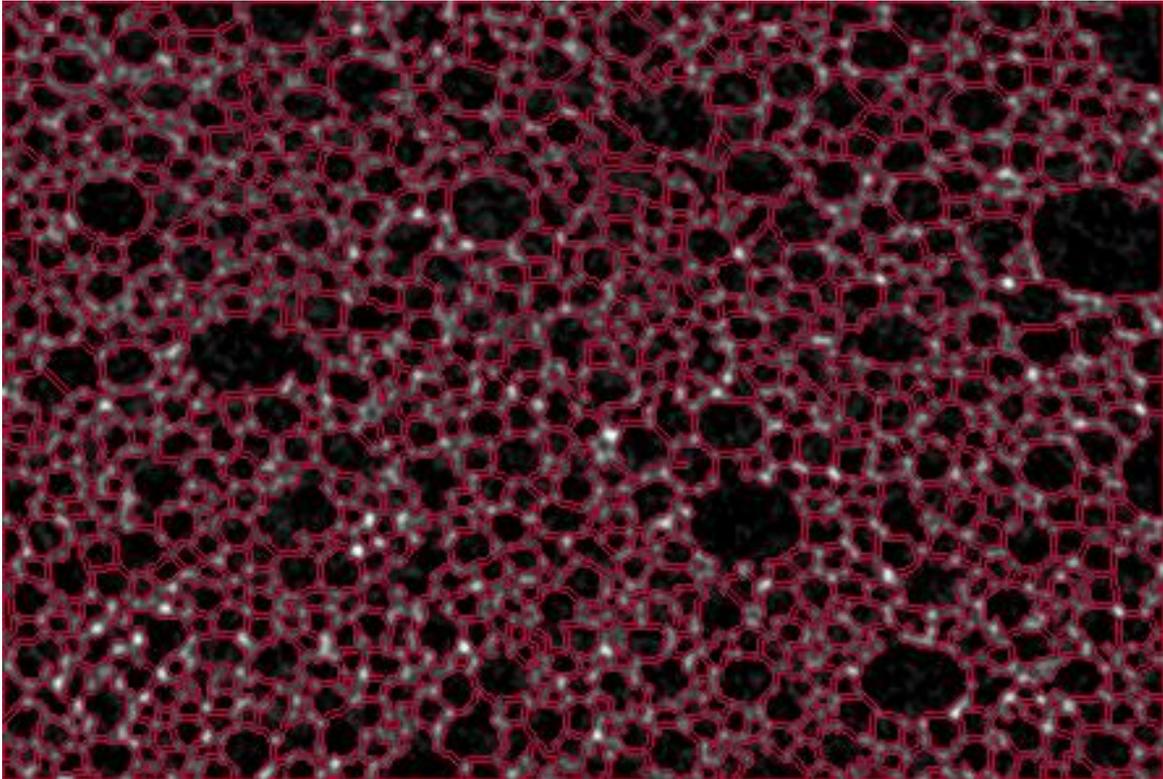


Abbildung 46: Ergebnis der Zellsegmentierung mit Detectron2 (Eigene Darstellung)



*Abbildung 47: Ergebnis der Zellsegmentierung mit klassischer Bildverarbeitungsmethode (Eigene Darstellung)*

Insgesamt hat der Vergleich der beiden Methoden gezeigt, dass die klassische Bildverarbeitungsmethode in dieser Arbeit die überlegene Leistung erbrachte. Dennoch sollten die Potenziale der Deep-Learning-Methode nicht außer Acht gelassen werden. Zukünftige Forschungen könnten sich darauf konzentrieren, die Herausforderungen der Deep-Learning-Methode zu überwinden und ihre Vorteile für die Analyse von Fernwärmeisoliermaterialien nutzbar zu machen.

#### **4.5.4 Vergleich mit den Anforderungen der EN 253 und Implikationen für die Prüfmethodik**

Die Entwicklung des Analysetools zur automatischen Erkennung und Vermessung von Zellstrukturen in Fernwärmeisoliermaterialien bietet nicht nur Vorteile hinsichtlich Genauigkeit und Geschwindigkeit, sondern hat auch weitreichende Implikationen für die Prüfmethodik nach EN 253.

Nach der aktuellen Fassung der EN 253 erfolgt die Bewertung der Zellgröße durch manuelle Messungen entlang einer Linie in der Probe. Diese Methode ist anfällig für subjektive Einflüsse, da die Auswahl der Messlinie und des Probenbereichs das Ergebnis beeinflussen kann. Es besteht die Möglichkeit, die Ergebnisse zu manipulieren, indem gezielt Bereiche

mit kleineren Zellen oder vorteilhaften Zellstrukturen ausgewählt werden, um die Anforderungen zu erfüllen.

Im Gegensatz dazu analysiert das entwickelte Tool das gesamte Bild und ermöglicht die Auswertung aller Bilder einer Probe. Dadurch wird eine objektive und repräsentative Bewertung der durchschnittlichen Zellgröße in der gesamten Probe erreicht. Die manuelle Selektion günstiger Bereiche wird eliminiert, was die Zuverlässigkeit und Vergleichbarkeit der Ergebnisse erhöht.

Es ist nachvollziehbar, dass die manuelle Vermessung der gesamten Probe nach der aktuellen Methode der EN 253 sehr zeitaufwendig und praktisch kaum durchführbar ist. Die automatisierte Analyse durch das Tool bietet hier einen erheblichen Vorteil. Es ermöglicht eine schnelle und umfassende Bewertung der Zellstrukturen in großen Probenbereichen, was mit manuellen Methoden nicht realisierbar wäre.

Angesichts der Möglichkeiten, die das Analysetool bietet, ist es sinnvoll, eine Anpassung der Prüfmethodik in der EN 253 zu erwägen. Die Integration automatisierter Analyseverfahren könnte die Prüfung von Fernwärmeisoliermaterialien objektiver, zuverlässiger und effizienter gestalten. Eine Überarbeitung der Norm unter Berücksichtigung des technischen Fortschritts würde die Qualitätskontrolle verbessern und den Vergleich zwischen verschiedenen Materialien und Herstellern erleichtern.

Ein weiterer Aspekt, der in der aktuellen Fassung der EN 253 nicht berücksichtigt wird, ist die Bewertung der Zellwanddicken. Mit dem entwickelten Tool ist es möglich, schnell und einfach Informationen über die Zellwanddicken zu erhalten. Diese zusätzlichen Daten könnten wertvolle Erkenntnisse über die Materialeigenschaften und die Leistungsfähigkeit der Isolierung liefern. Eine Anpassung der Norm, um auch Anforderungen an die Zellwanddicken zu definieren, könnte dazu beitragen, die Qualität und Langlebigkeit von Fernwärmeisoliermaterialien weiter zu verbessern.

Insgesamt zeigt der Vergleich mit den Anforderungen der EN 253, dass das entwickelte Analysetool nicht nur die Prüfmethodik verbessern kann, sondern auch neue Möglichkeiten für die Bewertung und Optimierung von Fernwärmeisoliermaterialien eröffnet. Die Nutzung des Tools ermöglicht eine detailliertere Analyse der Zellstrukturen, einschließlich Aspekten wie der Homogenität der Zellgrößenverteilung und der Identifizierung von Anomalien, die auf Herstellungsfehler hinweisen könnten. Eine Anpassung der Norm unter Berücksichtigung automatisierter Analyseverfahren und zusätzlicher Parameter wie der

Zellwanddicke könnte einen wichtigen Schritt in Richtung einer objektiven und zukunftsorientierten Qualitätskontrolle darstellen.

#### **4.5.5 Implikationen für die Praxis**

Die Implikationen des entwickelten Analysetools für die Praxis sind vielfältig und weitreichend. Die Möglichkeit, Materialmorphologie schnell und genau zu analysieren, bietet erhebliche Vorteile für die Qualitätskontrolle von Fernwärmeisoliermaterialien. Durch die Automatisierung des Analyseprozesses können Unternehmen Zeit und Ressourcen sparen, während sie gleichzeitig die Genauigkeit und Zuverlässigkeit ihrer Prüfungen erhöhen.

Ein weiterer praktischer Vorteil ist die Fähigkeit des Tools, umfassende Daten über eine gesamte Probe zu liefern, anstatt sich auf eine kleine Stichprobe zu beschränken. Dies ermöglicht eine repräsentativere Bewertung der Materialqualität und kann dazu beitragen, potenzielle Schwachstellen frühzeitig zu identifizieren.

Die Integration solcher Analysetools in den Produktionsprozess könnte auch zur Optimierung der Herstellungsverfahren beitragen. Durch kontinuierliches Monitoring der Zellstrukturen können Anpassungen im Produktionsprozess vorgenommen werden, um die Materialqualität zu verbessern.

Schließlich eröffnet das Tool neue Möglichkeiten für Forschung und Entwicklung im Bereich der Isoliermaterialien. Die Fähigkeit, detaillierte Informationen über Zellgrößen und -wanddicken zu liefern, kann dazu beitragen, neue Materialien mit verbesserten Eigenschaften zu entwickeln. Dies könnte insbesondere im Hinblick auf Energieeffizienz und Nachhaltigkeit von Bedeutung sein.

Insgesamt zeigt diese Arbeit das Potenzial automatisierter Analysetools zur Verbesserung der Qualitätssicherung in der Fernwärmeindustrie auf und legt den Grundstein für zukünftige Entwicklungen in diesem Bereich.

## 5 FAZIT UND AUSBLICK

In dieser Masterarbeit wurde ein KI-gestütztes Analysetool zur automatischen Erkennung und Vermessung von Zellen in Polyurethan-Hartschaumproben entwickelt. Das Tool basiert auf Computer-Vision-Techniken und Deep-Learning-Methoden und zielt darauf ab, die Qualitätsprüfung von Fernwärmedämmstoffen zu verbessern und zu automatisieren. Die Arbeit leistet einen wichtigen Beitrag zur Digitalisierung in der Materialprüfung und zeigt das Potenzial von KI-Anwendungen in diesem Bereich auf.

Die Hauptforschungsfrage zielte darauf ab, zu untersuchen, inwieweit ein KI-gestütztes Analysetool auf Basis von Computer Vision die Qualitätsprüfung von Fernwärmedämmstoffen effektiver und effizienter gestalten kann. Die Ergebnisse dieser Arbeit zeigen deutlich, dass die entwickelte Methode, insbesondere die klassische Bildverarbeitungsmethode, eine präzise und automatisierte Charakterisierung der Zellstruktur in PUR-Hartschaumproben ermöglicht. Durch den Einsatz von Schwellenwertverfahren, Wasserscheidentransformation und Konturerkennung konnten die Zellen zuverlässig segmentiert und ihre geometrischen Eigenschaften wie Fläche, Durchmesser und Wanddicke quantifiziert werden. Die automatisierte Analyse liefert reproduzierbare und objektive Ergebnisse und reduziert den Zeit- und Arbeitsaufwand im Vergleich zu manuellen Prüfmethodeen erheblich. Somit konnte gezeigt werden, dass KI-basierte Ansätze ein vielversprechendes Werkzeug zur Optimierung der Qualitätskontrolle von Dämmstoffen darstellen.

Die Validierung des Analysetools anhand synthetischer Testbilder bestätigte die hohe Genauigkeit der Messungen. Die berechneten Werte stimmten sehr gut mit den bekannten Parametern der Testbilder überein, was die Zuverlässigkeit des Tools untermauert. Des Weiteren ermöglicht das Tool die Durchführung einer Gesamtprobenanalyse, um festzustellen, ob die Anforderungen der EN 253 für Zellengrößen erfüllt sind. Dies belegt die Eignung des Tools für die Qualitätskontrolle von Fernwärmedämmstoffen.

Eine untergeordnete Forschungsfrage beschäftigte sich mit der Identifikation geeigneter Computer-Vision- und Machine-Learning-Methoden zur Erkennung und Bemessung von Zellen in PUR-Hartschaumproben. Es zeigte sich, dass die klassischen Methoden, insbesondere die Kombination aus Schwellenwertverfahren und Wasserscheidentransformation, eine robuste und effiziente Segmentierung der Zellen ermöglichen. Im Gegensatz dazu lieferte der Deep-Learning-Ansatz unter Verwendung von

Detectron2 keine zufriedenstellenden Ergebnisse. Trotz sorgfältiger Datenvorverarbeitung und Modellanpassung blieb die Segmentierungsleistung hinter den Erwartungen zurück, was sich zum Teil auf die begrenzte Datenmenge und die Komplexität der Schaumstruktur zurückführen lässt.

Eine weitere Fragestellung widmete sich den Herausforderungen bei der Ersetzung manueller Inspektionen durch automatisierte Messverfahren. Die Ergebnisse zeigen, dass die entwickelte Methode das Potenzial hat, die manuelle Prüfung von PUR-Hartschaumproben weitgehend zu ersetzen. Dennoch sind für eine vollständige Automatisierung noch einige Herausforderungen zu bewältigen, wie die Sicherstellung einer konsistenten Bildqualität, die Handhabung von Artefakten und Rauschen sowie die Integration in bestehende Prüfprozesse.

Die Untersuchung der Einflussfaktoren auf die Genauigkeit und Robustheit des KI-Modells zeigte, dass die Qualität der Eingabedaten, die Wahl geeigneter Algorithmen und Parameter sowie die Menge und Qualität der Trainingsdaten von entscheidender Bedeutung sind. Eine sorgfältige Abstimmung dieser Faktoren ist erforderlich, um optimale Ergebnisse zu erzielen.

Die Auswirkungen der Zellstruktur auf die Wärmeleitfähigkeit und Alterungsbeständigkeit von PUR-Hartschaum wurden ebenfalls untersucht. Die Ergebnisse bestätigen, dass die Zellgröße und -verteilung einen signifikanten Einfluss auf die thermischen Eigenschaften des Materials haben. Kleinere Zellen führen zu einer geringeren Wärmeleitfähigkeit und verbessern somit die Isolationswirkung. Die entwickelte Methode ermöglicht eine präzise Quantifizierung dieser Parameter und kann somit dazu beitragen, die Struktur-Eigenschafts-Beziehungen besser zu verstehen und Dämmstoffe gezielt zu optimieren. Auch für die Alterungsbeständigkeit spielt die Zellstruktur eine wichtige Rolle. Eine feinzellige Struktur mit dicken Zellwänden erhöht die Stabilität und verringert die Anfälligkeit für thermische und chemische Degradation. Die automatisierte Analyse der Zellwanddicken liefert wertvolle Informationen für die Bewertung der Langzeitstabilität von PUR-Dämmstoffen. Insgesamt konnten durch die Beantwortung der Forschungsfragen wichtige Erkenntnisse über das Potenzial KI-gestützter Analysetools für die Qualitätsprüfung von Fernwärmedämmstoffen gewonnen werden. Die entwickelte Methode stellt einen vielversprechenden Ansatz dar, um die Charakterisierung von PUR-Hartschäumen zu automatisieren und zu verbessern. Gleichzeitig wurden Herausforderungen und Limitationen identifiziert, die zusammen mit den vielfältigen Möglichkeiten für zukünftige

Forschungsarbeiten und praktische Anwendungen des entwickelten KI-gestützten Analysetools als Ausgangspunkt für weiterführende Untersuchungen dienen können.

Ein naheliegender nächster Schritt wäre die Entwicklung einer benutzerfreundlichen grafischen Benutzeroberfläche (GUI) für das Tool. Dadurch könnten auch Anwender ohne Programmierkenntnisse oder spezielle Softwareinstallationen von den Funktionen des Tools profitieren. Eine intuitive GUI würde die Zugänglichkeit und den potenziellen Nutzerkreis des Tools erheblich erweitern.

Obwohl die Deep-Learning-Methode in dieser Arbeit keine zufriedenstellenden Ergebnisse lieferte, sollte ihr Potenzial nicht unterschätzt werden. Durch die Verwendung größerer Datensätze, die systematische Erprobung verschiedener Hyperparameter und die Untersuchung alternativer Modellarchitekturen wie YOLO (You Only Look Once) könnte die Leistungsfähigkeit des Deep-Learning-Ansatzes verbessert werden. Da Deep-Learning-Modelle oft schnellere Inferenzzeiten aufweisen als klassische Bildverarbeitungsmethoden, wäre eine Weiterentwicklung in dieser Richtung besonders für Echtzeitanwendungen vielversprechend.

Eine Erweiterung des Tools zur Automatisierung weiterer Kriterien der EN 253, wie beispielsweise die Bestimmung des Anteils geschlossener Zellen, wäre ebenfalls ein lohnendes Ziel. Durch die Analyse aller Röntgenmikroskopiebilder einer Probe ließe sich ein 3D-Modell erstellen, das sowohl das Material als auch die Hohlräume visualisiert. Diese ganzheitliche Betrachtung der Probenstruktur würde neue Einblicke in die Materialeigenschaften ermöglichen.

Die Fähigkeit des Tools, schnell und objektiv die gesamte Probenstruktur zu analysieren, legt nahe, dass eine Anpassung der Prüfmethoden in der EN 253 in Betracht gezogen werden sollte. Durch die Integration automatisierter Analyseverfahren könnten subjektive Einflüsse minimiert und die Zuverlässigkeit der Prüfergebnisse erhöht werden.

Insgesamt zeigt sich, dass das in dieser Arbeit entwickelte KI-gestützte Analysetool nicht nur einen wertvollen Beitrag zur Qualitätskontrolle von Fernwärmedämmstoffen leistet, sondern auch weitreichende Potenziale für zukünftige Forschungs- und Entwicklungsarbeiten bietet. Durch die kontinuierliche Weiterentwicklung und Erweiterung des Tools können neue Erkenntnisse gewonnen, Prüfprozesse optimiert und

Materialeigenschaften verbessert werden. Diese Masterarbeit bildet somit eine solide Grundlage für vielfältige zukünftige Innovationen im Bereich der Materialanalyse und Qualitätssicherung.



Boesch, G. (2024, 19. Juni). Detectron2: A Rundown of Meta's Computer Vision Framework. Abgerufen am 6. Oktober 2024, von <https://viso.ai/deep-learning/detectron2/>

BRUGG Rohrsysteme - Spezialist für flexible und starre Rohrsyst - [info@pipesystems.com](mailto:info@pipesystems.com). (o. D.). CASAFLEX UNO – die Fernwärmeleitung | BRUGG Pipes. BRUGG Rohrsysteme - Spezialist für flexible und starre Rohrsyst. Abgerufen am 14. Juni 2024, von <https://www.bruggpipes.com/fernwaermeleitung-casaflex-uno-deutschland/>

Burger, W. & Burge, M. J. (2016). Digital Image Processing. In Texts in computer science. <https://doi.org/10.1007/978-1-4471-6684-9>

Careerera. (2021, 22. Juni). Exploring the Advantages and Disadvantages of Deep Learning. Careerera.com. Abgerufen am 22. Juli 2024, von <https://www.careerera.com/blog/advantages-and-disadvantages-of-deep-learning>

Cheng, D., Sha, W., Xu, Z., Huang, L., Du, Y., Tang, S., Guo, Y., Cao, Y. & Cheng, S. (2021). Computer Vision Analysis on Material Characterization Images. *Advanced Intelligent Systems*, 4(3). <https://doi.org/10.1002/aisy.202100158>

Choe, H., Choi, Y. & Kim, J. H. (2019). Threshold cell diameter for high thermal insulation of water-blown rigid polyurethane foams. *Journal Of Industrial And Engineering Chemistry/Journal Of Industrial And Engineering Chemistry - Korean Society Of Industrial And Engineering Chemistry*, 73, 344–350. <https://doi.org/10.1016/j.jiec.2019.02.003>

COCO - Common Objects in context. (o. D.). Abgerufen am 8. Oktober 2024, von <https://cocodataset.org/#home>

Cunningham, A., Jeffs, G., Rosbotham, I. & Sparrow, D. (1988). Recent Advances in the Development of Rigid Polyurethane Foams of Improved Thermal Insulation Efficiency. *Cellular Polymers*, 7(1), 1–15. <https://doi.org/10.1177/026248938800700101>

DeCost, B. L., Francis, T. & Holm, E. A. (2017). Exploring the microstructure manifold: Image texture representations applied to ultrahigh carbon steel microstructures. *Acta Materialia*, 133, 30–40. <https://doi.org/10.1016/j.actamat.2017.05.014>

Detectron2. (o. D.). Abgerufen am 6. Oktober 2024, von <https://ai.meta.com/tools/detectron2/>

detectron2 documentation. (o. D.). Abgerufen am 6. Oktober 2024, von <https://detectron2.readthedocs.io/en/latest/modules/config.html#>

DIN EN 253:2020-03, Fernwärmerohre- Einzelrohr-Verbundsysteme für direkt erdverlegte Fernwärmenetze\_- werkmäßig gefertigte Verbundrohrsysteme, bestehend aus Stahl-Mediumrohr, einer Wärmedämmung aus Polyurethan und einer Ummantelung aus Polyethylen. (2020). Deutsches Institut für Normung e.V. <https://doi.org/10.31030/3072082>

DIN EN ISO 4590:2016-12, Harte Schaumstoffe- Bestimmung des Volumenanteils offener und geschlossener Zellen (ISO\_4590:2016); Deutsche Fassung EN\_ISO\_4590:2016. (2019). DIN Deutsches Institut für Normung E. V. <https://doi.org/10.31030/2417378>

Doyle, L. & Weidlich, I. (2022). Moisture uptake and effects of hygrothermal exposure on closed-cell semicrystalline polyethylene terephthalate foam. *Polymer Degradation And Stability*, 202, 110009. <https://doi.org/10.1016/j.polymdegradstab.2022.110009>

Fabbri, R., Da F Costa, L., Torelli, J. C. & Bruno, O. M. (2008). 2D Euclidean distance transform algorithms. *ACM Computing Surveys*, 40(1), 1–44. <https://doi.org/10.1145/1322432.1322434>

Facebookresearch. (o. D.). GitHub - facebookresearch/detectron2: Detectron2 is a platform for object detection, segmentation and other visual recognition tasks. GitHub. Abgerufen am 5. August 2024, von <https://github.com/facebookresearch/detectron2>

Gama, N., Ferreira, A. & Barros-Timmons, A. (2018). Polyurethane Foams: Past, Present, and Future. *Materials*, 11(10), 1841. <https://doi.org/10.3390/ma11101841>

Gietzelt, M., Grage, T. & Kahle, M. (2006). Stability of PUR insulation in pipes for heat- and refrigeration-transmission. Fernwärme-Forschungsinstitut Hannover e.V. Abgerufen am 17. Juni 2024, von [https://lsta.lt/files/events/29\\_gietzelt.pdf](https://lsta.lt/files/events/29_gietzelt.pdf)

Girshick, R. (2015). Fast R-CNN. *IEEE International Conference On Computer Vision*. <https://doi.org/10.1109/iccv.2015.169>

Girshick, R., Donahue, J., Darrell, T. & Malik, J. (2013). Rich feature hierarchies for accurate object detection and semantic segmentation. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1311.2524>

Gonzalez, R. C. & Woods, R. E. (2017). Digital Image Processing, Global Edition. Pearson Higher Education.

Goodfellow, I., Bengio, Y. & Courville, A. (2016). Deep learning. MIT Press.

Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J. & Chen, T. (2017). Recent advances in convolutional neural networks. Pattern Recognition, 77, 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>

He, K., Gkioxari, G., Dollár, P. & Girshick, R. (2017). Mask R-CNN. IEEE International Conference On Computer Vision. <https://doi.org/10.1109/iccv.2017.322>

Horlacher, H. & Helbig, U. (2016). Rohrleitungen 1: Grundlagen, Rohrwerkstoffe, Komponenten. Springer-Verlag.

*Informationen zu Git - GitHub-Dokumentation.* (o. D.). GitHub Docs. Abgerufen am 16. Oktober 2024, von <https://docs.github.com/de/get-started/using-git/about-git>

Ionescu, M. (2016). Chemistry and Technology of Polyols for Polyurethanes, 2nd Edition. Smithers Information Ltd. Abgerufen am 22. September 2024, von <https://perpus.univpancasila.ac.id/repository/EBUPT180570.pdf>

Kellner, J. & Shen, R. (2000). Production techniques for polyurethane pre-insulated pipes and foam systems suitable for the manufacture of high quality pipes applied in district heating. UTECH Asia, Shanghai, China.

Konstantin, P. & Konstantin, M. (2022). Praxisbuch der Fernwärme- und Fernkälteversorgung. In Springer eBooks. <https://doi.org/10.1007/978-3-662-64343-3>

Lake, B. M., Ullman, T. D., Tenenbaum, J. B. & Gershman, S. J. (2016). Building Machines That Learn and Think Like People. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1604.00289>

- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lefter, R. C. & Popescu, D. (2012). Analysis of “CONTI” pre-insulated pipes with diffusion barrier versus traditional pre-insulated pipes used in district heating networks. *IEEE*. <https://doi.org/10.1109/ICEPE.2012.6463806>
- Lin, T., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L. & Dollár, P. (2014). Microsoft COCO: Common Objects in context. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1405.0312>
- Lund, H., Werner, S., Wiltshire, R., Svendsen, S., Thorsen, J. E., Hvelplund, F. & Mathiesen, B. V. (2014). 4th Generation District Heating (4GDH). *Energy*, 68, 1–11. <https://doi.org/10.1016/j.energy.2014.02.089>
- Lund, R. S., Østergaard, D. S., Yang, X. & Mathiesen, B. V. (2017). Comparison of Low-temperature District Heating Concepts in a Long-Term Energy System Perspective. *DOAJ* (DOAJ: Directory Of Open Access Journals). <https://doi.org/10.5278/ijsepm.2017.12.2>
- Mangs, S. (2005). Insulation materials in district heating pipes: Environmental and thermal performance of polyethylene terephthalate and polyurethane foam. Abgerufen am 11. September 2024, von <https://publications.lib.chalmers.se/records/fulltext/9176/9176.pdf>
- Maxwell, A. S., Broughton, W. R., Dean, G. D. & Sims, G. D. (2005). Review of accelerated ageing methods and lifetime prediction techniques for polymeric materials. NPL Report DEPC MPR 016. Abgerufen am 28. August 2024, von <https://eprintspublications.npl.co.uk/3161/>
- Mohimont, L., Alin, F., Rondeau, M., Gaveau, N. & Steffanel, L. A. (2022). Computer Vision and Deep Learning for Precision Viticulture. *Agronomy*, 12(10), 2463. <https://doi.org/10.3390/agronomy12102463>
- Navickas, J. & Madsen, R. A. (1977). Aging Characteristics of Polyurethane Foam Insulation. In *Springer eBooks* (S. 233–241). [https://doi.org/10.1007/978-1-4613-9850-9\\_25](https://doi.org/10.1007/978-1-4613-9850-9_25)

Ostrogorsky, A., Glicksman, L. & Reitz, D. (1986). Aging of polyurethane foams. *International Journal Of Heat And Mass Transfer*, 29(8), 1169–1176. [https://doi.org/10.1016/0017-9310\(86\)90148-1](https://doi.org/10.1016/0017-9310(86)90148-1)

Persson, U. & Werner, S. (2011). Heat distribution and the future competitiveness of district heating. *Applied Energy*, 88(3), 568–576. <https://doi.org/10.1016/j.apenergy.2010.09.020>

Pham, V. V. (2023). *Object Detection and Segmentation Using Detectron2: A Hands-On Coding and Visualized Approach for Object Detection Models*. Packt Publishing.

Ramiah, M. (2021, 10. Dezember). Convolution Neural Network- The backbone of image classification. Medium. Abgerufen am 6. September 2024, von <https://madhuramiah.medium.com/convolution-neural-network-the-backbone-of-image-classification-ddd2a49a6efa>

Randall, D. & Lee, S. (2002). *The Polyurethanes Book*.

Raschka, S. & Mirjalili, V. (2017). *Python Machine Learning: Machine Learning and Deep Learning with Python, Scikit-learn, and TensorFlow*.

Ren, S., He, K., Girshick, R. & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1506.01497>

Zheng, T., Duan, Z., Wang, J., Lu, G., Li, S. & Yu, Z. (2021). Research on Distance Transform and Neural Network Lidar Information Sampling Classification-Based Semantic Segmentation of 2D Indoor Room Maps. *Sensors*, 21(4), 1365. <https://doi.org/10.3390/s21041365>

Rezaie, B. & Rosen, M. A. (2012). District heating and cooling: Review of technology and potential enhancements. *Applied Energy*, 93, 2–10. <https://doi.org/10.1016/j.apenergy.2011.04.020>

Roerdink, J. B. & Meijster, A. (2000). The Watershed Transform: Definitions, Algorithms and Parallelization Strategies. *Fundamenta Informaticae*, 41(1,2), 187–228. <https://doi.org/10.3233/fi-2000-411207>

- Rosenfeld, A. & Pfaltz, J. L. (1966). Sequential operations in digital picture processing. *Journal Of The ACM*, 13(4), 471–494. <https://doi.org/10.1145/321356.321357>
- Saha, P. K., Borgefors, G. & Di Baja, G. S. (2015). A survey on skeletonization algorithms and their applications. *Pattern Recognition Letters*, 76, 3–12. <https://doi.org/10.1016/j.patrec.2015.04.006>
- Sankur, B. & Sezgin, M. (2004). Survey over image thresholding techniques and quantitative performance evaluation. *Journal Of Electronic Imaging*, 13(1), 146. <https://doi.org/10.1117/1.1631315>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Singh, S. N. (2002). *Blowing Agents for Polyurethane Foams*. iSmithers Rapra Publishing.
- SKYSCAN 2214. (o. D.). Bruker. Abgerufen am 6. September 2024, von <https://www.bruker.com/en/products-and-solutions/diffractometers-and-x-ray-microscopes/3d-x-ray-microscopes/skyscan-2214.html>
- Smits, G. (1994). Effect of Cellsize Reduction on Polyurethane Foam Physical Properties. *Journal Of Thermal Insulation And Building Envelopes*, 17(4), 309–329. <https://doi.org/10.1177/109719639401700403>
- Sokolova, M. & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *Journal Of Machine Learning Research*, 15(1), 1929–1958. Abgerufen am 9. August 2024, von <https://jmlr.csail.mit.edu/papers/volume15/srivastava14a/srivastava14a.pdf>
- Stavropoulos, P., Papacharalampopoulos, A. & Petridis, D. (2020). A vision-based system for real-time defect detection: a rubber compound part case study. *Procedia CIRP*, 93, 1230–1235. <https://doi.org/10.1016/j.procir.2020.04.159>

- Sutton, R. S. & Barto, A. G. (2014). Reinforcement Learning: An Introduction (Second edition, in progress). The MIT Press. Abgerufen am 22. August 2024, von <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>
- Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I. & Fergus, R. (2013, 21. Dezember). Intriguing properties of neural networks. Abgerufen am 10. August 2024, von arXiv.org. <https://arxiv.org/abs/1312.6199>
- Szeliski, R. (2022). Computer Vision: Algorithms and Applications. Springer.
- Szycher, M., PhD. (2012). Szycher's Handbook of Polyurethanes, Second Edition. CRC Press.
- Voulodimos, A., Doulamis, A., Doulamis, A. & Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. Computational Intelligence And Neuroscience, 2018, 1–13. <https://doi.org/10.1155/2018/7068349>
- Weidlich, I. (2016). Mantelrohrsysteme in der Wärmeverteilung. In Springer eBooks (S. 475–494). [https://doi.org/10.1007/978-3-642-39782-0\\_13](https://doi.org/10.1007/978-3-642-39782-0_13)
- Wuttke, L. (2023, 11. Dezember). Machine Learning: Definition, Algorithmen, Methoden und Beispiele. Datasolut GmbH. Abgerufen am 13. Juli 2024, von <https://datasolut.com/was-ist-machine-learning/>
- Yoon, S., Kim, A., Cantwell, W. J., Yeun, C. Y., Cho, C., Byon, Y. & Kim, T. (2022). Defect detection in composites by deep learning using solitary waves. International Journal Of Mechanical Sciences, 239, 107882. <https://doi.org/10.1016/j.ijmecsci.2022.107882>
- Zehendner, H. (2001). Wärmeleitfähigkeit von Rohrdämmstoffen für Heizungsanlagen. Bauphysik, 23(1), 25–32. <https://doi.org/10.1002/bapi.200100050>
- Zinko, H., Bergström, G., Nilsson, S., ZW Energiteknik, SP, Jarfelt, U. & Chalmers Tekniska Högskola, Inst för Byggnadsfysik. (2002). FUKTDIFFUSION I PLASTRÖRSYSTEM. In FOU 2002:73. Abgerufen am 5. Juli 2024, von <https://energiforskmedia.blob.core.windows.net/media/20447/fuktdiffusion-i-plastrorsystem-hetvattenrapport-2002-73.pdf>