

Einsatz einer maschinell gelernten Bildsegmentierung zur Pulverbettüberwachung im Metalldruck

Andreas Schiffler, Kira Kristin Wehnert, Dennis Ochs

Short Facts

Förderkennzeichen: VALIDAD-IKK-1905-0013

Projektlaufzeit: 01.10.2019 – 30.09.2022

1 EINLEITUNG

3D-Metalldruck oder Additive Manufacturing (AM) umfasst eine breite Palette sich entwickelnder junger Technologien. Diese Prozesstechnologien versprechen die Fähigkeit, durch den schichtweisen Aufbau von Metall, komplexe dreidimensionale Komponenten zu erzeugen. Ursprünglich nur für das Prototyping verwendet, haben jüngste Fortschritte und Marktbedingungen es ermöglicht, dass der Metalldruck endkonturnahe Bauteile für den Endgebrauch produziert. Insbesondere wird der Metalldruck für hochentwickelte oder kundenspezifische Teile in kleinen bis mittleren Stückzahlen eingesetzt. Die Anwendung dieser spezifischen Bauteile z.B. in Luft- und Raumfahrt, medizinische Implantate und Automobilindustrie stellen jedoch auch hohe Anforderungen an die Qualitätssicherstellung, die Rückverfolgbarkeit des Produktionsprozesses und der Prozessfähigkeiten. Der Prozess des Metalldrucks zeichnet sich, unabhängig vom Verfahren, durch einen großen lokalen Energieeintrag aus. Daher sind so gefertigte metallische Bauteile besonders anfällig für Anomalien in thermischen Eigenschaften, stochastische Abweichungen der Pulverkorngrößen und allgemeine Maschinenfehler wie z.B. Positionsabweichungen. Einige dieser Anomalien treten in sehr kurzen Zeiten oder in sehr kleinen Längenskalen auf, sodass sie während des Aufschmelzens oder des Bindens des Materials erkannt werden müssen. Die dafür notwendigen Überwachungsmaßnahmen werden daher i.d.R. als in situ Prozessüberwachung bezeichnet. Einige der genannten Prozessabweichungen sind jedoch persistent und so charakterisiert, dass eine schichtweise Erkennung möglich ist.

Der Schwerpunkt der folgenden Ausführungen ist auf eine schichtweise Erkennung von Abweichungen durch die automatisierte Analyse von Bilddaten aus pulverbettbasierten Metalldruckprozessen gelegt. Bei diesen Prozessen wird eine dünne Schicht im Bereich von 20 bis 100 μm aus pulverförmigem Metallpulver aufgetragen. Ein zweidimensionaler Querschnitt des gewünschten Bauteils wird dann entweder mit einer selektiven Wärmequelle aufgeschmolzen oder mit einem Bindemittel zusammengebunden. Anschließend wird das Substrat um die Höhe einer Pulverschicht abgesenkt und der Vorgang wiederholt, bis der Aufbau abgeschlossen ist. Nach dem Abschluss des Aufschmelzens einer Schicht wird ein Bild mittels einer Kamera im sichtbaren Wellenlängenbereich erstellt. Abbildung 1 zeigt zwei Beispiele solcher Bilder. Diese bilden die Eingangsgröße für die Erkennung von Abweichungen. Durch die gewählte Schichtdicke kann die Herstellung eines Bauteils mehrere tausend Bilder erzeugen. Die automatisierte und zeitnahe Auswertung ist daher Inhalt aktueller Forschungs- und Entwicklungsaktivitäten [1]. Nicht zuletzt da die notwendige Sensorik – eine Kamera – wirtschaftlich und robust einsetzbar ist.




Abbildung 1:
Beispiele für Kameraaufnahmen der Baufäche im Pulverbett nach dem Aufschmelzen; (Links) Fehlerfreier Zustand; (Rechts) Störung/Fehler (orange markiert)

2 NEURONALES NETZ FÜR SEMANTISCHE SEGMENTIERUNG DER KAMERABILDER

Wie Abbildung 1 darstellen soll, ist die Aufgabe automatisiert Anomalien in Kamerabildern des Pulverbetts in jeder Schicht zuerkennen. Der hier beschriebene Ansatz geht in zwei Stufen vor:

- 1. Festlegung von Bereichen in dem Metall aufgeschmolzen wurde (= Vordergrund, Metall) und Bereichen, in denen kein Metall aufgeschmolzen wurde (= Hintergrund, Metallpulver)
- 2. Berechnung des Verhältnisses von Ist-Vordergrund zu Soll-Vordergrund

Aus dem letzten Schritt resultiert pro Schicht ein einfaches Überwachungskriterium welches im Idealfall gleich eins ist. Eine Abweichung von diesem Wert abzüglich einer gewählten Toleranz wird als Anomalie und somit Fehler im Pulverbett gewertet. Eine Klassifizierung, welche Art von Fehler vorliegt, erfolgt zunächst nicht.

Die Umsetzung des ersten Schrittes erfordert die sichere Erkennung der aufgeschmolzenen Bereiche im Pulverbettbild. Wie in Abbildung 1 links zu erkennen ist, ist die Festlegung eines einfachen Schwellwerts – Schwarz-Weiß-Konvertierung – nicht möglich. Dies liegt an den sich spiegelnden Oberflächen, Reflexionen und Schattenwürfen. Auch aufwendige Algorithmen zur Trennung von Vorder- und Hintergrund wie sie in der Softwarebibliothek *openCV* [5] vorgeschlagen werden, liefern keine befriedigenden Ergebnisse.

Der Einsatz eines trainierten neuronalen Netzes, als spezifischer Algorithmus zur Lösung des ersten Schritts, kam daher aus den folgenden Gründen in Betracht:

- Eine typische Zeitspanne zwischen zwei Bauteilschichten beträgt mindestens 0,5 Sekunden. Diese Zeit ist in den meisten Fällen mit modernen Geräten ausreichend, um ein Bild mit 1.024^2 Pixeln zu verarbeiten.
- Mit der Veröffentlichung des Beitrags [2] steht eine Netzwerkarchitektur – sog. U-Net – zur Verfügung, welche sich als geeignet und performant bei der Aufgabe automatisiert biomedizinische Bilder zu analysieren zeigte. Auch bei einer weiteren Anwendung zur Erkennung des Verschleißes von Werkzeugen wurde dieser Ansatz erfolgreich eingesetzt [4].

Aus dem Stand der Technik wurde daher eine U-Net Architektur gewählt. Jedoch nicht wie ursprünglich in [2] vorgeschlagen, sondern ein Netzwerk wie in der Arbeit [6] entwickelt, bei dem Vorteile hinsichtlich der Genauigkeit gezeigt werden konnten. Abbildung 2 zeigt diese Xception-Style Architektur angepasst auf eine Bildgröße von 256^2 Pixel mit beispielhaft gewählten Eingangs- und Ausgangsbildern.




Abbildung 2: Xception-Style U-Net Netzwerk Architektur vorgeschlagen in [6] auf Basis der Arbeiten aus [2]

Durch den Einsatz eines trainierten Netzes, wie in Abbildung 2 dargestellt, konnten trotz schwieriger Belichtungsszenen und Spiegelungen Bereiche, in dem Metall aufgeschmolzen wurde, pixelweise im Bild vom Hintergrund getrennt werden. Dies wird im weiteren Verlauf des Artikels noch erläutert.

3 SENSORGESTÜTZTE GENERIERUNG VON PIXELWEISE KLASSIFIZIERTEN TRAININGSBILDERN

Die Anwendung von künstlichen neuronalen Netzen als Algorithmus zur Bildverarbeitung erfordert ein vorheriges Training, also eine Parametrisierung des Netzes. Für die Anzahl der Bilder, welche zum Training verwendet werden, gilt stets: Je mehr, desto genauer kann später eine Aussage / Vorhersage erfolgen. Da nicht nur Bilder, sondern auch entsprechende Kontextinformationen eingegeben werden müssen, kann das Training sehr zeit- und ressourcenintensiv werden. Gerade im Falle einer semantischen Segmentierung, welche hier zum Einsatz kommt, muss jeder Pixel im Bild eine Kontextinformation erhalten um für das Training verwendet werden zu können. Im einfachsten Fall – wie hier – kann jeder Pixel maximal zwei Zustände haben. Vordergrund = Metall oder Hintergrund = Metallpulver. Wie in der aktuellen Veröffentlichung [1] berichtet, wurden hier etwa 6.000 Bilder per Hand pixelweise von Experten mit der notwendigen Kontextinformation erweitert. Dabei wird hier von »Labeling« gesprochen. Dieser Vorgang ist sehr zeitaufwendig. Allerdings muss dieser Vorgang nur einmal durchgeführt werden und später in der Anwendung des trainierten Netzes nicht mehr. Daher wird hier der Ansatz verfolgt, zusätzliche Sensoren einzusetzen, um den Vorgang des »Labelings« zu automatisieren. In der vorhandenen Anlage EOS M290 stehen zwei weitere Messsysteme zur Verfügung, welche sich eignen, aufgenommene Bilder vom Pulverbett zu klassifizieren. Eingesetzt wurde eine weitere Kamera welche Aufnahmen im nahen Infrarotwellenlängenbereich (900 bis 1.200 nm) erstellt.

Diese Bilder wurden mit einem festen Schwellwert schwarz-weiß transformiert um somit eine Maske zu erhalten, welche die Bereiche schwarz kennzeichnet, in dem Metall aufgeschmolzen und weiß, wo kein Metall aufgeschmolzen wurde. Abbildung 3 stellt anhand einer beispielhaften Bauschicht die unterschiedlichen Bilder dar. Ganz rechts ist das Bild, welches als Maske für das Training des neuronalen Netzes verwendet wird. Somit können Bilder zusammen mit der Verwendung von zusätzlicher Sensorik automatisiert als Trainingsdaten verwendet werden.

Das so trainierte Netz erfüllt die im Abschnitt zuvor definierte erste Aufgabe – das Trennen von Vordergrund und Hintergrund. Mit der Nutzung des neuronalen Netzes kann eine zweite Kamera im nahen Infrarotbereich – wie sie für das Training verwendet wurde – eingespart werden. Hier wird daher von einem Soft-Sensor gesprochen, da die Funktionalität durch die Software, genauer von einem Algorithmus, übernommen wird. Der Zeitbedarf für die Ausführung des Netzes auf ein Bild mit 256^2 Pixeln liegt kleiner 100 Millisekunden und kann daher als Lösung verwendet werden.



Abbildung 3: Beispielhafte Bilder einer Bauschicht. (links) Kamerabild, (Mitte) Kamerabild naher Infrarotbereich, (rechts) Erzeugte Maske für das automatisierte Labeling

Erste Versuche und das initiale Training des neuronalen Netzes wurden mit etwa 5.000 Bildern durchgeführt. Eine Validierung mit einem Testdatensatz ergab eine Genauigkeit (true-positiv) von 90 %. Allerdings muss dieses Ergebnis relativiert werden, da die Aussage stark von der Verteilung der Flächen von Hintergrund zu Vordergrund abhängt. Enthalten Bilder beispielsweise überwiegend Pixel welche als Hintergrund klassifiziert werden, ist nur aufgrund der Menge an Pixeln die Genauigkeit stets besser als für die Klassifizierung des Vordergrundes.

4 ANWENDUNG ZUR VERBESSERUNG DER ANOMALIEERKENNUNG

Im vorherigen Abschnitt wurde gezeigt, wie mit Hilfe eines neuronalen Netzes die Bereiche in denen Metall aufgeschmolzen wurde von Bereichen mit Metallpulver segmentiert werden können. Dies erfolgt ohne den Einsatz zusätzlicher Sensorik. Wird nun das trainierte Netz $UNet(P)$ während der Fertigung auf jedes Bild mit der Pixelmenge P_{powder} einer Schicht angewendet, kann die Fläche A_{metall} , also die Summe aller Pixel mit der Klassifizierung Vordergrund, beschrieben werden. Wird diese beobachtete bzw. berechnete Fläche A_{metall} auf Basis der Kamerabilder in Bezug zu der bekannten Sollfläche A_{soll} gesetzt, resultiert, wie eingangs beschrieben, ein Überwachungskriterium für eine fehlerfreie Schicht:

$$0,8 < \frac{A_{\text{soll}}}{A_{\text{metall}}} < 1,2 \quad (1)$$

mit

$$P_{\text{seg}} = UNet(P_{\text{powder}}) \quad (2)$$

$$P_{\text{metall}} = \{P_{\text{seg}} | P_{\text{seg}} \geq 1\} \quad (3)$$

$$A_{\text{metall}} = \sum P_{\text{metall}} \quad (4)$$

Abbildung 4 zeigt für ein Bauteil den Verlauf der berechneten / beobachteten Fläche und die Sollfläche für die ersten 7 mm der Bauhöhe. Im Bereich der Bauhöhe zwischen 1 und 1,5 mm kann deutlich eine signifikante Abweichung zwischen Sollfläche und im Pulverbett aufgeschmolzene Fläche erkannt werden. Die entsprechenden Ausschnitte aus den Kamerabildern bestätigen die Abweichung, wie in Abbildung 4 rechts in den Bildern zu erkennen. Der Bereich der geschlossen rechteckig aufgeschmolzen werden sollte hat sichtbare Fehlstellen.

Diese ersten Ergebnisse bestätigen zunächst den Ansatz und stellen zugleich ein einfaches Überwachungskriterium dar. Darin liegt aber auch das Optimierungspotenzial begründet, da diese Schwellwertüberwachung keine direkten Rückschlüsse auf die Position oder die Art der Anomalie im Pulverbett zulässt. Weiterhin wird im Folgenden noch untersucht wie die Auflösung der Kamerabilder einen positiven Einfluss auf die Genauigkeit der Flächenberechnung hat. Eine Verifizierung der Generalisierung des Ansatzes konnte bisher nicht gegeben werden, da nur Bildmaterial von einer Anlage zur Verfügung stand.



Abbildung 4: (links) Verlauf der berechneten Fläche des aufgeschmolzenen Metalls im Pulverbett und gewünschte Fläche, (rechts) beispielhafte Relation zu Kamerabildern im Fall A für eine signifikante Abweichung Soll zu beobachtet und Fall B fehlerfreier im gleichen Bauteilbereich

LITERATURVERZEICHNIS

- [1] Scime, L.; Derek S.; Seth B.; Vincent P. (2020), »Layer-wise anomaly detection and classification for powder bed additive manufacturing processes: A machine-agnostic algorithm for real-time pixel-wise semantic segmentation«. Additive Manufacturing 36, verfügbar in: <https://www.sciencedirect.com/science/article/pii/S2214860420308253>
- [2] Ronneberger, O.; Fischer, P.; Brox, T. (2015), »U-Net: Convolutional Networks for Biomedical Image Segmentation«, Medical Image Computing and Computer-Assisted Intervention (MICCAI), verfügbar in: <http://lmb.informatik.uni-freiburg.de/Publications/2015/RFB15a>

- [3] Akeret, J.; Chihway C.; Aurelien L.; Alexandre R. (2017), »Radio frequency interference mitigation using deep convolutional neural networks«. *Astronomy and Computing* 18, S. 35–39.
- [4] Benjamin, L; Kisskalt, D.; Regulin, D.; Reisch, R.; Schiffler, A.; Franke, J. (2019), »Evaluation of Deep Learning for Semantic Image Segmentation in Tool Condition Monitoring«, *International Conference on Machine Learning and Applications (ICMLA-2019)*, 2007–2012. Boca Raton
- [5] Bradski, G. (2000), »The OpenCV Library«. *Dr. Dobb's Journal of Software Tools*
- [6] Chollet, F. (2016), »Xception: Deep Learning with Depthwise Separable Convolutions«, 2017, *Computer Vision and Pattern Recognition*, verfügbar in: <https://arXiv:1610.02357>