

Defekterkennung von Impactschäden durch Convolutional Neural Networks

Phi-Long CHUNG¹, Johannes RITTMANN¹, Aristotelis CHARIZANIS¹,
Marc KREUTZBRUCK¹

¹ Universität Stuttgart, Institut für Kunststofftechnik, Stuttgart

Kontakt E-Mail: phi-long.chung@ikt.uni-stuttgart.de

Kurzfassung. Künstliche Intelligenzen (KI) stellen Zukunftslösungen mit großem Potenzial dar, welche selbst unerfahrenem Personal bei der Datenauswertung und Defekterkennung unterstützen können. In der Thermografie können bei der Auswertung von Thermogrammen auf Algorithmen der Bilddatenverarbeitung sowie der KI-Verarbeitung von Bilddaten zurückgegriffen werden. Hierzu werden häufig Convolutional Neural Networks (CNN) eingesetzt. Eine besondere Netzwerkarchitektur, basierend auf CNN, stellt das U-Net dar. Durch Querverbindungen zwischen Encoder und Decoder Seite des Netzwerks können hohe Abbildungsgenauigkeiten bei selbst kleinen Trainingsdatensätzen erreicht werden. Der Encoder reduziert das Eingabebild schrittweise auf ein Minimum und extrahiert dabei die relevanten Merkmale. Der anschließende Decoder verknüpft die extrahierten Merkmale miteinander und skaliert durch weitere Schichten die Informationen auf die Ausgangsgröße zurück. Dadurch ist es möglich, in einem kleinen Datensatz aus Lockin-Thermografie-Phasenbildern von CFK schnell und zuverlässig Impactschäden zu erkennen und zu segmentieren. Eine weitere untersuchte Netzwerkarchitektur ist das Long Short-Term Memory (LSTM) Netz, das in der Lage ist, Informationen in einem Zwischenspeicher zu hinterlegen und abzurufen. Ein weiteres Einsatzgebiet stellt die Verarbeitung von zeitabhängigen Mess- und Sensordaten, wie die Betrachtung von Abkühlkurven nach pulsformiger Erwärmung, dar. Durch Kombination von CNN und LSTM können die zuvor aufgenommenen Abkühlkurven pixelweise verarbeitet werden und die Tiefen und Durchmesser von Flachbodenbohrungen in CFK-Platten klassifiziert und quantifiziert werden. Als Ausgangsgröße wird die lokale Bauteildicke bis zur Schadensfläche bzw. die Bauteildicke bis zur Rückwandgeometrie verwendet. Dieser Beitrag demonstriert beispielhaft, dass mithilfe von CNN bereits ein vergleichsweise geringer Datensatz aus 475 Trainingsbildern ausreicht, um eine automatisierte Auswertung von 2,5D-Geometrien der Rückwand bzw. von Schadensflächen durchzuführen.

1. Einführung

Für die Detektion von Defekten in Verbundwerkstoffen können je nach Einsatzfall diverse Methoden der zerstörungsfreien Prüfung eingesetzt werden. Neben der Computertomografie zur Untersuchung kleiner, hochkomplexer Bauteile [1] oder im Bereich der Luftfahrt mittels Ultraschallprüfung [2], kann bei der Bestimmung von oberflächennahen Inhomogenitäten auf die aktive Thermografie zurückgegriffen werden [3, 4]. Bei Betrachtung der Oberfläche bzw. der Defektstelle können in den Thermogrammen die resultierenden Schäden ermittelt werden. Aufgrund der Tatsache, dass die diffusen Prozesse der Wärmeausbreitung häufig zu einer fehlerhaften Interpretation der Defektgeometrie und -größe führen, ist die Auswertung



dieser Thermogramme erfahrenen Prüfer/innen überlassen. Um den Prozess der Auswertung zu vereinfachen und zu automatisieren, könnten neuronale Netze eine zukunftssträchtige Lösung darstellen.

2. Thermografie und neuronale Netze

2.1 Grundlagen der Thermografie

Die aktive Thermografie basiert auf der Betrachtung der Ausbreitung thermischer Wellen in den zu betrachtenden Proben oder Prüfkörpern. Nach der Anregung über eine homogene Wärmequelle erfolgt als Antwortreaktion die Ausbreitung der aufgenommenen Wärme im Bauteil, welche wiederum mit einer Thermografie- bzw. Wärmebildkamera aufgenommen werden kann.

Die Lockin-Thermografie ist ein Messverfahren auf Basis des Lockin-Messprinzips. Dabei wird die jeweilige Bauteiloberfläche mittels einer sinusförmig modulierten Wärmequelle angeregt. Die anschließend ins Bauteil injizierte thermische Welle breitet sich mit definierter Frequenz im Bauteil aus und wird an Grenzflächen reflektiert und überlagert sich mit der periodisch angeregten Oberflächentemperatur des Bauteils. Wird die sinusförmige Wärmewelle mit der gemessenen thermischen Welle verglichen, entsteht ein zeitlicher Versatz, der die Phasenverschiebung der sinusförmigen Welle abbildet. [3]

Bei einer flächig homogenen Ausleuchtung eines Prüfkörpers wird die thermische Wellengleichung im quellfreien Fall definiert über die Fourier'sche Differentialgleichung [5]:

$$\alpha \frac{\partial^2 T}{\partial x^2} - \frac{\partial T}{\partial t} = 0 \quad (1)$$

mit dem Temperaturfeld T , der Ortsvariable x und der Zeitvariable t .

Für die Temperaturleitfähigkeit α gilt der Zusammenhang:

$$\alpha = \frac{\lambda}{\rho c} \quad (2)$$

mit der Wärmeleitfähigkeit λ , der Dichte ρ und der spezifischen Wärmekapazität c .

Für eine sinusförmig eingebrachte thermische Welle an der Bauteiloberfläche ($x = 0$) ergibt sich das orts- und zeitabhängige Temperaturfeld als Lösung der Fourier'schen Differentialgleichung zu:

$$T(x, t) = T_0 e^{\mu_e \left(\omega t - \frac{x}{\mu} \right)} \quad (3)$$

mit der Anfangsamplitude T_0 der thermischen Welle und der dazugehörigen Kreisfrequenz ω . Die thermische Eindringtiefe μ ist definiert als

$$\mu = \sqrt{\frac{2\alpha}{\omega}}. \quad (4)$$

Das Temperaturfeld wird von einer Thermografiekamera an der Oberfläche detektiert und ändert sich je nach Interaktion zwischen dem Wellenfeld und dem Prüfkörper. Aus den pixelweise erfassten Temperaturverläufen können Phasen- und Amplitudenwerte ermittelt werden. Werden die pixelweise ermittelten Phasenwerte betrachtet, ergibt sich das Phasenbild über:

$$\varphi = \arg(T(0, t)). \quad (5)$$

2.2 Aufbau, Funktionsweise und Training neuronaler Netze

Die dem menschlichen Gehirn nachempfundenen neuronalen Netze sind Systeme des maschinellen Lernens und der künstlichen Intelligenz [6]. Durch das Trainieren dieser Netze

anhand anwendungsspezifischer Datensätze können neuronale Netze diverse Problemstellungen lösen. Neuronale Netze bestehen dabei aus einer Vielzahl an Recheneinheiten, den Neuronen N , sowie deren Verbindungen V untereinander. Die Beziehung unter den Neuronen wird durch sogenannte Gewichtungen w beschrieben. Gewichtungen sind dabei reale Zahlen, die entweder verstärkend oder hemmend auf die Verbindung zwischen Neuronen wirken können. Vergleichbar zu biologischen Neuronen ist die Aufgabe künstlicher Neuronen die Datenverarbeitung. Zunächst wird über eine Propagierungsfunktion ein oder mehrere Eingangssignale aufgenommen und als Netzeingabe weitergereicht. [7] Anschließend entscheidet eine Aktivierungsfunktion darüber, ob die eingehenden Signale weitergereicht werden sollen. Häufig findet als Aktivierungsfunktion die Rectified-Linear-Unit (dt. Gleichrichterfunktion), kurz ReLu-Funktion in Gleichung 6, Anwendung. Sobald die Aktivierungsfunktion einen gewissen Schwellenwert übertrifft, wird das Signal als Ausgabe an weitere Neuronen gesendet. [8]

$$relu(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x > 0 \end{cases} \quad (6)$$

Neuronale Netze bestehen aus verschiedenen Schichten, denen wiederum eine bestimmte Anzahl Neuronen untergeordnet sind. Je mehr Schichten ein Netz besitzt, desto tiefer wird das Netz bezeichnet. Grundsätzlich existieren eine Eingabeschicht, eine beliebige Anzahl versteckter Schichten und zuletzt die Ausgabeschicht.

Damit das neuronale Netz die jeweilige Problemstellung lösen kann, bedarf es ein entsprechendes Training, damit die Gewichte und Verbindungen unter den Neuronen angepasst werden können. Innerhalb des Trainingsprozesses werden mindestens ein Trainings- und ein Validierungsdatensatz verwendet. Während des Trainings werden die Gewichte iterativ anhand des Trainingsdatensatzes auf die Genauigkeit quantifiziert. Mithilfe von Fehlerfunktionen werden so die Abweichungen von der angestrebten und erzielten Lösung innerhalb des Trainingsdatensatzes bestimmt und als spezifischer Fehler zurückgegeben (sog. Backpropagation). Anschließend werden die Gewichtungen der Neuronen untereinander entsprechend angepasst, um den Fehler zu minimieren. [9] Sollte eine Gewichtsangpassung nicht zielführend sein, werden die Einstellungen verworfen und neue Parameter verwendet, bis das Ziel erreicht ist. Nach jeder Trainingsepoche erfolgt dabei ein Abgleich mit dem Validierungsdatensatz zur Bestimmung des aktuellen Stands des Netzes. Je mehr Gewichte innerhalb eines Netzes zum Training verfügbar sind, desto komplexere Zusammenhänge können abgebildet werden.

2.3 Convolutional Neural Networks (CNN)

Die zuvor beschriebenen neuronalen Netze sind der Kategorie der feedforward Netze zuzuordnen, da der Informationsfluss grundsätzlich in Richtung der Ausgabe gerichtet ist. Aufgrund der Tatsache das diese neuronalen Netze häufig vollgeknüpft sind, d.h. dass ein Neuron mit allen Neuronen der nachfolgenden Schicht verbunden ist, können Bilddaten nur ressourcenintensiv verarbeitet werden. Im Gegensatz dazu sind Convolutional Neural Networks (CNN) eine spezielle Art der neuronalen Netze, die Faltungsoperationen (engl. convolutions) einsetzen, um Bilddaten effizient zu analysieren. Dabei werden die Bilddaten in den Faltungsschichten mithilfe einer Matrix, dem Kernel, abgerastert und das Hadamard-Produkt zwischen dem Kernel und dem betrachteten Bildbereich gebildet. Die Einzelwerte der resultierenden Matrix werden anschließend aufsummiert und als Wert in einer Ausgabematrix, den feature maps, gespeichert. Durch das Abrastern der Bilddaten werden diese feature maps erzeugt und stellen die relevanten Informationen innerhalb eines Bildes in komprimierter Form dar. Werden anschließend Pooling-Operationen durchgeführt, werden die feature maps weiter komprimiert. Um die komprimierten Daten bzw. extrahierten Merkmale schließlich einer Klasse zuzuordnen, werden in den letzten Schichten eines CNN vollverknüpfte Neuronen zur Klassifizierung verwendet. [10, 11]

Mit steigender Anzahl an Faltungsschichten können vor allem bei reduzierenden Bildauflösungen Schwierigkeiten bei der Referenzierung relevanter Bildbereiche hinsichtlich ihrer Lageinformationen auftreten. Abhilfe schafft das U-NET, welches aus einem Encoder und Decoder aufgebaut ist. Zunächst werden die Bilddaten durch den Encoder wie bisher vorgestellt komprimiert und diverse Merkmale extrahiert. Anschließend wird in einem nachgeschalteten Decoder das Bild schrittweise auf die Ausgangsgröße skaliert und die extrahierten Merkmale mit skip-connections verknüpft. Dadurch können extrahierte Informationen in ihrer Lage zugeordnet werden. Anders als bei herkömmlichen Klassifizierungen wird nicht das gesamte Bild, sondern jeder Pixel für sich klassifiziert. Dafür müssen in den Trainingsdaten zusätzlich Masken der relevanten Bereiche, wie z. B. Defekte, vorhanden sein. [12, 13]

3. Experimenteller Versuchsaufbau und Datengenerierung

Der Aufbau der neuronalen Netze wird in der Programmierumgebung Python 3.8 realisiert. Tensorflow ist dabei ein weitverbreitetes Framework für Deep Learning Algorithmen. Für die Programmierung und anschließende Ausführung wird die von Google bereitgestellt Colaboratory-Oberfläche verwendet. Das Training und die Berechnung kann dadurch direkt auf den bereitgestellten Recheneinheiten durchgeführt werden.

Zur Erkennung von Impactschäden setzen sich die Daten für das Training des neuronalen Netzes in 80 % Trainingsdaten, 10 % Validierungsdaten und 10 % Testdaten zusammen. Die im Rahmen dieser Arbeit untersuchten Bilddaten wurden mithilfe der Thermografiekamera FLIR SC6811 (Teledyne FLIR, Wilsonville, USA) in Frequenzen zwischen 0,01 und 1 Hz Lockin-Phasenbilder aufgenommen. Als Prüfkörper wurden verschiedene CFK-Platten mit Impact-Schäden verwendet. Insgesamt wurden 169 IO (in Ordnung) und 306 NIO (nicht in Ordnung) Bilder erstellt (Abb. 1, a). Zusätzlich dazu wurden 39 Bilder (13 IO, 26 NIO) als Testbilder verwendet. Damit das U-Net die Defekte erkennen kann, werden zu den NIO-Phasenbildern Masken über die Defekte erstellt. Innerhalb dieser binären Maske stellen die markierten Pixel mit Wert 1 Defekte dar, während Pixel mit Wert 0 den IO-Bereich beschreiben. Zur Generierung zusätzlicher Trainingsdaten werden mithilfe einer Funktion aus der Keras-Bibliothek, dem ImageDataGenerator, Bildmanipulationen an den Bildern und Masken durchgeführt. Mithilfe diverser Rotationen, Verschiebungen, Spiegelungen und Vergrößerungen können auf einfache Weise weitere synthetische Daten erzeugt werden. Die Anfangsauflösung der Thermografie-Bilder wird auf 224 x 224 Pixel festgelegt. Das verwendete U-Net auf Basis von InceptionV3 besitzt vier Max-Pooling-Stufen mit einer initialen Filtergröße von 16, die im Encoder-Teil stufenweise auf 256 verdoppelt und im Decoder-Teil auf die Ausgangsgröße von 16 halbiert wird.




Abb. 1 Verwendete NIO-Phasenbilder zur Erkennung von Defekten (a), CFK-Platte mit verschiedenen tiefen Flachbodenbohrungen (b)

Neben der Auswertung von Phasenbildern können auch Zeitverläufe mit neuronalen Netzen untersucht werden. Dazu wird eine CFK-Platte mit unterschiedlich tiefen Flachbodenbohrungen mit der Thermografie untersucht (Abb. 1, b). In dem so aufgezeichneten Bildbereich mit einer Auflösung von 512 x 640 Pixeln sind für jeden Pixel in 3.000 Zeitschritten von 0,01 s der Temperaturverlauf aufgezeichnet. Die Klassifizierung der Tiefen wird über eine LSTM-Schicht, gefolgt von einer vollverknüpften Dense-Schicht, durchgeführt. Für die Quantifizierung der Durchmesser wird die Kombination von LSTM-CNN verwendet. Nach der LSTM-Schicht folgen zwei Blöcke bestehend aus jeweils einer eindimensionalen Convolutional-Schicht und einer Max-Pooling-Schicht.

4. Ergebnisse und Diskussion

4.1 Auswertung von Impact-Schäden

Für die Bewertung der Genauigkeit des U-Net wird der Jaccard-Index bzw. die „Intersection of Union“ (IoU-Score) verwendet. Dabei wird die Vorhersage mit der wahren Maske verglichen und die gemeinsame Fläche zur Quantifizierung der Genauigkeit verwendet.

Das U-Net erreicht einen IoU-Score von 62,19 % in Bezug auf die Testdaten (45 Bilder). Dabei stimmen die meisten Vorhersagen mit den korrespondierenden Label-Masken sehr gut überein (Abb. 2). Lediglich bei drei der vorgegebenen Defekte konnten nicht erkannt werden. Diese Defekte sind jedoch selbst für den menschlichen Betrachter schwer zu erkennen.

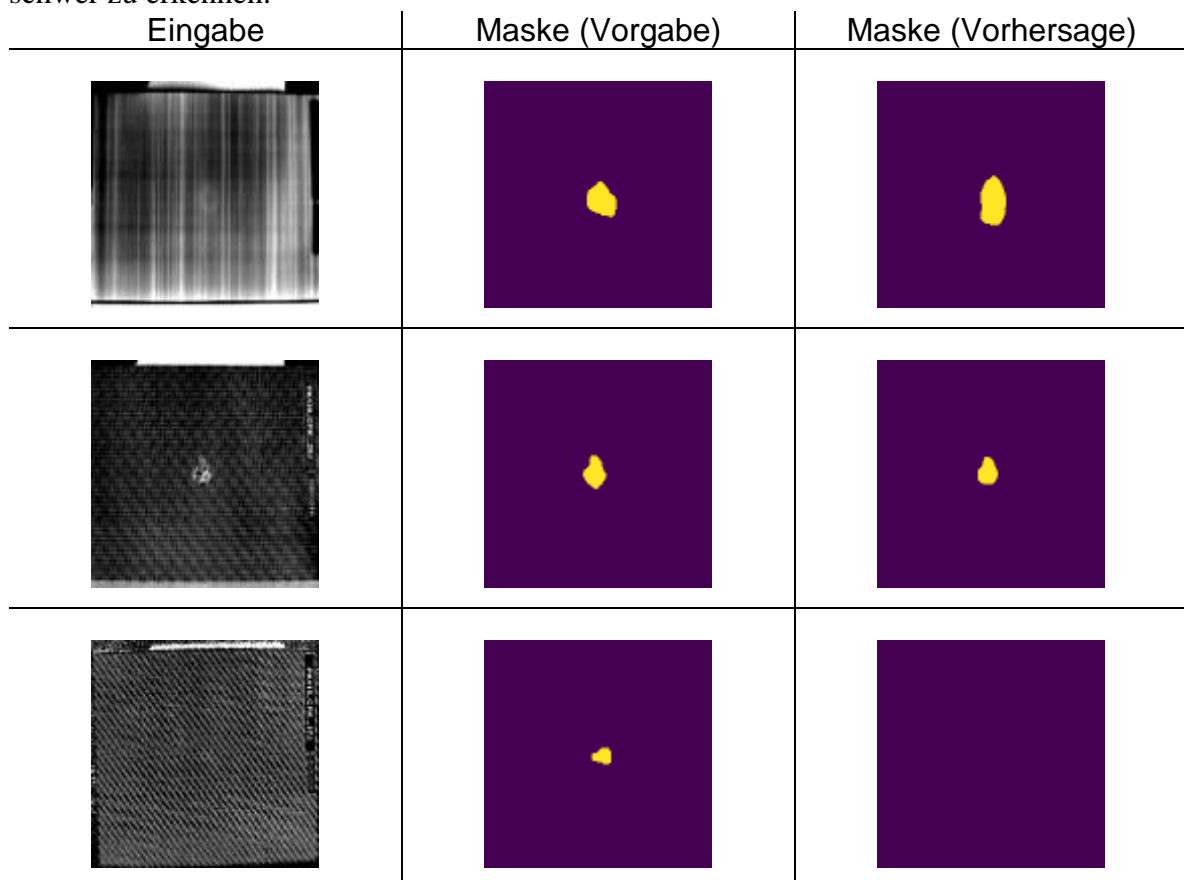


Abb. 2 Exemplarische Vorhersage der Masken durch das InceptionV3-U-Net

Abb. 3 stellt Auszüge der Ergebnisse der 39 zuvor ungesehenen Testbilder dar, die durch das U-Net analysiert wurden. Selbst kleine Defekte können mithilfe des neuronalen Netzes erkannt werden. Einzig bei einem der IO-Bilder wurde ein nichtvorhandener Defekt erkannt.

Die Vermutung liegt hier nahe, dass im Trainingsdatensatz ein ähnliches NIO-Bild existiert, in dem ein schwer erkennbarer Defekt vorhanden ist. Dadurch hat das Netz während des Trainings Verknüpfungen aufgebaut, die in der Bildanalyse dieses Bildes ebenfalls zu einem Defekt führen. Insgesamt ist das InceptionV3-U-Net in der Lage aus 84 IO- und NIO-Bildern 79 richtige Vorhersagen zu treffen und erreicht damit eine Vorhersagewahrscheinlichkeit von 94,05 % auf ungesehene Datensätze.

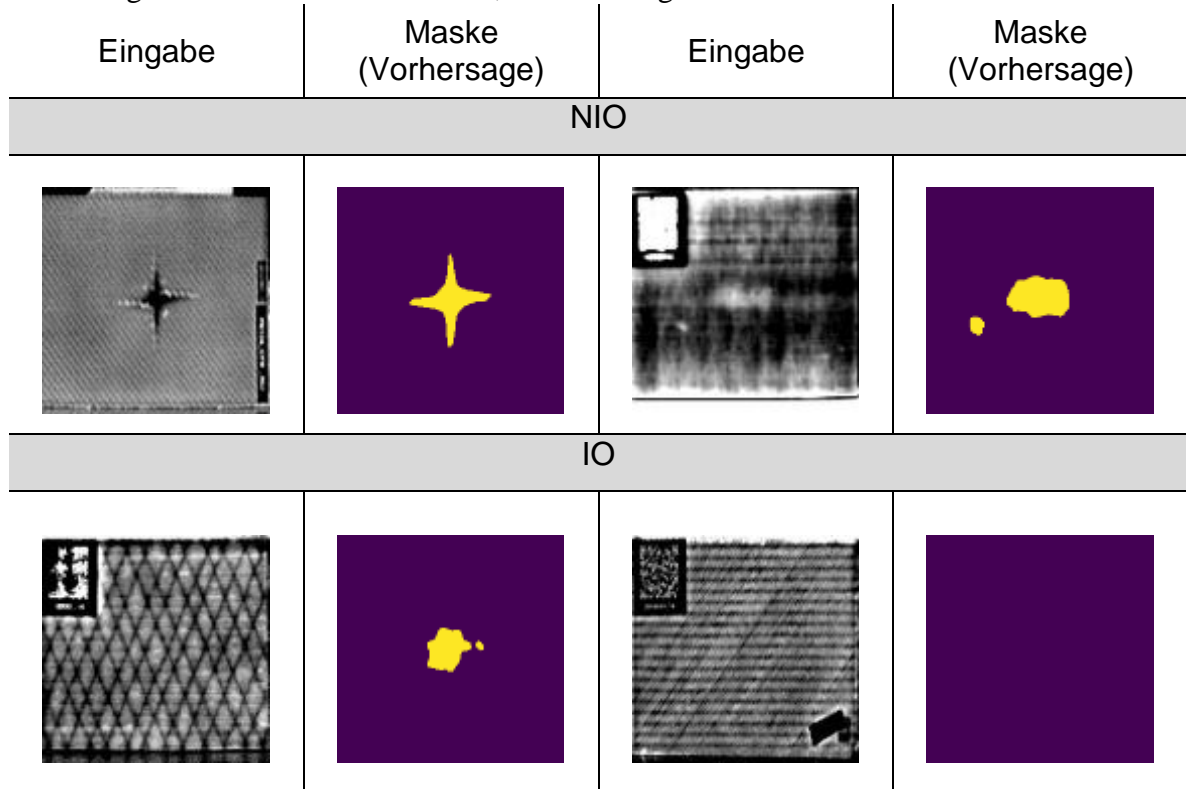


Abb. 3 Vorhersage der Testdaten durch das InceptionV3-U-Net

4.2 Auswertung von Temperatur-Sequenzen

Für die Bewertung der Klassifikation der Tiefe und des Durchmessers wird der F1-Score in Gleichung 7 verwendet, um die Genauigkeit der durchgeführten Klassifizierung zu bestimmen. Die Werte liegen dabei zwischen 0 und 1.

$$F1 = 2 * \frac{1}{\frac{1}{Precision} + \frac{1}{Recall}} \quad (7)$$

Die Quantifizierung wird mithilfe der mittleren quadratischen Abweichung (MQA) bewertet. Mithilfe des MQA wird ein direkter Bezug zum Vorhersagefehler in der Tiefe hergestellt. Ist der Fehler betragsmäßig klein, ist auch der Fehler zwischen wahrer und vorhergesagter Tiefe entsprechend klein.

Innerhalb der nachstehenden Abb. 4 ist der Verlauf des F1-Scores dargestellt. Trainings- und Validierungswerte zeigen einen fast identischen Verlauf auf, wobei die Validierungsdaten teilweise mit einer besseren Leistung abschneiden. Dies liegt an der Tatsache, dass die Daten untereinander sehr ähnlich sind und die Validierungswerte am Ende einer Epoche berechnet werden.

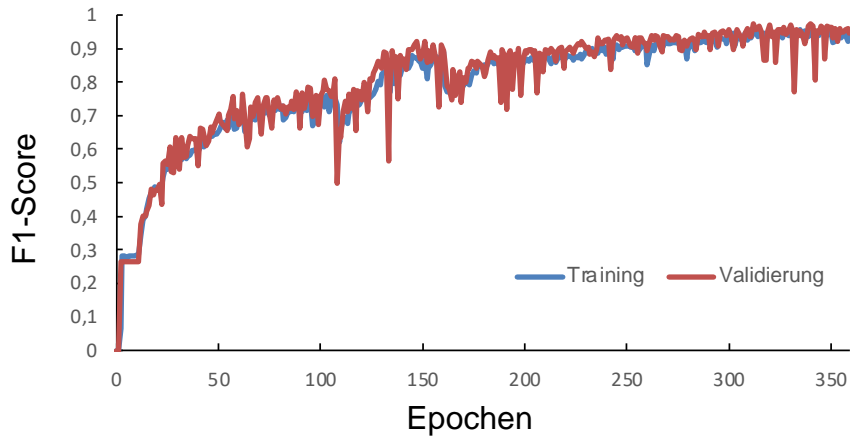


Abb. 4 Verlauf des F1-Scores über die Epochen

Werden nun die dazugehörigen Vorhersagen betrachtet (Abb. 5, a) kann festgestellt werden, dass alle Defekte im Kern erkannt werden. Bei vielen vorhergesehenen Tiefen kann in den Randbereichen ein zusätzlicher zweiter Klassifikationsbereich festgestellt werden. Grund für diesen Fehler ist der laterale Wärmefluss, welcher an den Rändern der Defekte zu einem Wärmestau führt.




Abb. 5 Klassifizierung der Tiefen in 10 verschiedene Klassen (a), Quantifizierung der Tiefen in mm (b)

Die Ergebnisse der Quantifizierung über den MQA sind in Abb. 6, a für eine Trainingsdauer von 130 Epochen dargestellt. Nach bereits sieben Epochen fällt die MQA auf unter 0,1 mm. Der Verlauf der Trainings- und Validierungswerte ist auch hier vergleichbar. Der am Ende erreichte Test-MQA beläuft sich auf 0,002 mm. Bei der Betrachtung der Vorhersage durch das LSTM-CNN-Netz in Abb. 5, b kann auch hier die Aussage getroffen werden, dass alle Defekte im Kern korrekt erkannt werden. Erneut ist in den Randbereichen der vorhergesagten Defekte ein zweiter Klassifizierungsrand durch den lateralen Wärmefluss zu erkennen. Neben der Vorhersage für die defektnahen Bildpixel ist eine Vorhersage für die gesamten Pixel eines Bildes möglich und in Abb. 6, b dargestellt. Erneut sind die Phänomene in den Randbereichen sichtbar.

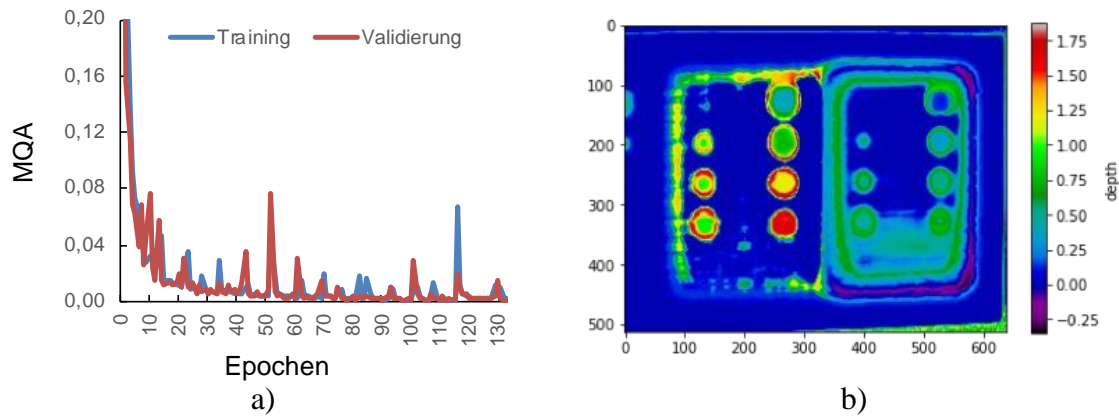


Abb. 6 Verlauf der mittleren quadratischen Abweichung (a), Vorhersage für die gesamte Prüfkörpergeometrie (b)

5. Fazit und Ausblick

Das Ziel dieser Arbeit war die Entwicklung eines neuronalen Netzes, welches zur Defekterkennung in Kunststoffbauteilen eingesetzt werden soll. Die dafür verwendeten Eingabedaten stammen dabei aus der aktiven Thermografie. Neben der Klassifizierung von Phasenbildern in defekt und nicht-defekt war die Aufgabe des Netzes auch eine Lokalisierung durchzuführen. Dafür wurde ein U-Net entwickelt, welches mithilfe eines Encoder- und Decoder-Teils die relevanten Merkmale der Bilder extrahiert hat. Der mit der Intersection of Union-Score erzielte Wert ergab für den bereitgestellten Testdatensatz 62,19 %. Das entwickelte Netz konnte aus den 84 gegebenen Testbildern 79 korrekte Vorhersagen treffen. Die Ergebnisse der dargestellten Arbeit zeigen, dass eine Defektlokalisierung durch Phasenbilder mit einem U-Net zu sehr guten Ergebnissen führt. Einzig der Mehraufwand durch das Training und damit verbunden die Maskenerstellung müssen in Kauf genommen werden. Das U-Net erreicht mit verhältnismäßig wenig Trainingsdaten sehr vielversprechende Ergebnisse und ist nicht nur in der Lage Defekte zu erkennen und zu lokalisieren, sondern auch zu segmentieren. Vor allem in Bezug auf Defekte, die für den menschlichen Betrachter schwer zu erkennen sind, ist dies von Vorteil.

Neben der Erkennung von Defekten konnte in ersten Versuchen gezeigt werden, dass eine Klassifizierung und Quantifizierung von Defekttiefen und -durchmessern möglich sind. Anhand des Temperaturverlaufs können bereits gute Ergebnisse erzielt werden, wobei der an den Rändern entstehende Wärmestau eine Störgröße darstellt. Es ist an dieser Stelle jedoch noch anzumerken, dass eine Einschätzung über die Leistungsfähigkeit des Netzes auf unbekannte Messdaten ausstehend ist.

In weiteren Untersuchungen sollte der Fokus auf neuronale Netze mit Lokalisationsmethoden, wie z.B. Single-Shot-Detektoren, gelegt werden. Weiteres Potential besteht in der Multi-Klassen-Segmentierung mittels des U-Net, in denen verschiedene Defektarten unterschiedlichen Schweregrades klassifiziert werden könnten. Für die Steigerung der Leistungsfähigkeit der neuronalen Netze könnten Phasenbilder unterschiedlicher Frequenzen in den Trainingsdatensatz integriert werden, um verschiedene Ansichten desselben Defekts hinzuzufügen.

Obwohl die Verwendung von Temperatursequenzen ansatzweise funktioniert, sollte eine Defekterkennung durch Auswertung der Phasensequenzen oder der Kombination beider in Betracht kommen. Dadurch könnte der Einfluss des Wärmestaus an den Randbereichen vermieden werden.

Referenzen

- [1] BULL, D.J, S.M. SPEARING, I. SINCLAIR und L. HELFEN. Three-dimensional assessment of low velocity impact damage in particle toughened composite laminates using micro-focus X-ray computed tomography and synchrotron radiation laminography. In: Composites Part A: Applied Science and Manufacturing, 2013, **52**(4), 62–69.
- [2] KRAUTKRÄMER, J. und KRAUTKRÄMER, H. Werkstoffprüfung mit Ultraschall. Heidelberg: Springer, 1986. ISBN 978-3-662-10909-0.
- [3] WU, D. und G. BUSSE. Lock-in thermography for nondestructive evaluation of materials. In: Revue Générale de Thermique, 1998, **37**(8), 693–703.
- [4] RITTMANN, J., M. RAHAMMER, N. HOLTSMANN und M. KREUTZBRUCK. Fast and simple detection of impact damage. In: FRACTURE AND DAMAGE MECHANICS: Theory, Simulation and Experiment: AIP Publishing, 2020, 20048. DOI: 10.1063/5.0028408.
- [5] FOURIER, J.-B.-J. Oeuvres de Fourier. Volume 2. Cambridge: Cambridge University Press, 1824. ISBN 978-1-139-56815-9.
- [6] GOODFELLOW, I., Y. BENGIO und A. COURVILLE. Deep learning. Cambridge: MIT Press, 2016. ISBN 978-0-262-03561-3.
- [7] KRAUTKRÄMER, J. und KRAUTKRÄMER, H. Werkstoffprüfung mit Ultraschall. Heidelberg: Springer, 1986. ISBN 978-3-662-10909-0.
- [8] KRIESEL, D. Ein Kleiner Überblick über Neuronale Netze. 2007.
- [9] RASHID, T. Neuronale Netze selbst programmieren: Ein verständlicher Einstieg mit Python. Heidelberg: O'Reilly, 2017. ISBN: 978-3-960-09043-4.
- [10] QIN, T. Dual Learning. Singapore: Springer Nature, 2020. ISBN 978-9-811-58883-9.
- [11] RAWAT, W. und Z. WANG. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. In: Neural computation, 2017, **29**(9), 2352–2449.
- [12] FALK, T., D. MAI, R. BENSCH, ET AL. U-Net: deep learning for cell counting, detection, and morphometry. In: Nature methods, 2019, **16**(1), 67–70.
- [13] RONNEBERGER, O und P. FISCHER. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Medical Image Computing and Computer-Assisted Intervention – MICCAI, 2015. 234–241. ISBN 978-3-319-24574-4.