

3D-Thermografie innerer Strukturen mittels künstlicher Intelligenz

Johannes RITTMANN¹, Marc KREUTZBRUCK¹

¹ Institut für Kunststofftechnik der Universität Stuttgart, Stuttgart

Kontakt E-Mail: johannes.rittmann@ikt.uni-stuttgart.de

Kurzfassung. Für den eindimensionalen Fall der Wärmeausbreitung in der aktiven Thermografie können über bekannte Auswertemethoden, wie die Laser-Flash-Analyse oder die Thermographic Signal Reconstruction und Betrachtung einer charakteristischen Zeit, direkt auf die Dicke des untersuchten Prüfkörpers geschlossen werden. Für den mehrdimensionalen Fall beeinflussen diffusive Effekte die Wärmeausbreitung der thermischen Welle, was bei der Auswertung der Dicke speziell an Rändern und Abweichungen einer ebenen Platte zur Fehlinterpretation führt. Je tiefer ein Defekt im Bauteil liegt, desto diffuser wird er in einer Veränderung der Oberflächentemperatur wahrgenommen, bis er bei zu großer Tiefe nicht mehr erkannt wird. Obwohl bei tiefliegenden Strukturen die Effekte nicht an der Oberfläche durch einen Temperaturgradienten ersichtlich sind, beeinflussen auch tiefliegende Defekte die Oberflächentemperatur.

Innerhalb dieses Papers werden Wärmeflussimulationen der Impulsthermografie unterschiedlicher Defektgeometrien herangezogen, um ein neuronales Netz zur tiefenaufgelösten Defektinterpretation zu trainieren. Die Defektgeometrien orientieren sich dabei an Geometrien realer Impactschäden in Verbundwerkstoffen und wurden mittels FEM aus einem mikromechanischen Bruchmodell realitätsnah gewonnen. Das neuronale Netz basiert auf einem Encoder – Decoder Ansatz wobei als Eingabeinformationen die Temperaturwerte der Abkühlkurve nach einer pulsformigen Anregung dienen. Die Segmentierung erfolgt in Abhängigkeit von der Rückwandgeometrie. Durch das Training von mehreren tausend Defektgeometrien mittels einem Encoder – Decoder Netz sind wir erstmals in der Lage, ohne zusätzliche Informationen über das Bauteil, direkt auf dessen innere Geometrie sowie die Rückwandgeometrie schließen zu können.

Einführung zur aktiven Thermografie

Anfang des 19. Jahrhundert veröffentlichte Joseph Fourier seine analytischen Untersuchungen zur Ausbreitung von Wärme in Festkörpern und legte damit den Grundstein für viele wissenschaftliche Erkenntnisse im Bereich der Wärmeleitung sowie der aktiven Thermografie. Basierend auf dem Fourier'schen Gesetz und der Energieerhaltungsgleichung lässt sich für den quellfreien Fall die nachfolgend angegebene Diffusionsgleichung bzw. Wärmeleitungsgleichung ableiten.

$$\alpha \Delta T(\vec{x}, t) - \frac{\partial}{\partial t} T(\vec{x}, t) = 0 \quad (1)$$

Mit der Temperatur T an der Stelle \vec{x} zum Zeitpunkt t und der Temperaturleitfähigkeit α im Medium.



Besonders die Diffusion, wie sie auch namensgebend für die Gleichung aufgeführt wird, erschwert die Interpretation der Ausbreitung thermischer Wellen im Sinne einer zerstörungsfreien Bauteilprüfung. Durch den damit einhergehenden Informationsverlust, lässt sich nicht trivial aus der gemessenen Wärmeinformationen auf die gesuchte Geometrie rückrechnen. Bei eindimensionalen Problemen, wie der Vermessung von dünnen Schichten mittels einer homogenen flächigen Erwärmung, vgl. [1] und [2], kann das Problem umgangen werden. Für reale Defekte hingegen ist dieser Ansatz unzureichend und führt, speziell an Inhomogenitäten, zum Beispiel durch Material- oder Geometrieänderung, zur Verzerrung der Messergebnisse. Wie in Abb. 1 dargestellt, verändern sich die wahrnehmbaren Merkmale und Geometrien von Flachbodenbohrungen und eines ausgeprägten Tiefsprungs in kohlenstofffaserverstärkten Kunststoffen (CFK) im Phasenbild von Lockin-Messungen bei verändernder Lockin-Frequenz. Dadurch lässt sich nicht eindeutig aus dem Messergebnis auf die Fehlergröße schließen. Die Flachbodenbohrungen in Abb. 1 sind durch helle oder dunkle Kreise zu erkennen, die Stufe des Tiefsprungs überstreckt sich über große Bereiche des Messausschnitts und ist jeweils in der linken oberen und linken unteren Ecke besonders ausgeprägt zu erkennen. Ähnlich verhält sich die Oberflächentemperatur eines Bauteils nach pulsartiger Erwärmung. Je länger die Schadstelle nach einer pulsartigen Erwärmung betrachtet wird, desto größer und verschwommener erscheint die lokale Temperaturüberhöhung im Thermogramm, bis sie letztlich nicht mehr vom thermischen Rauschen der Kamera zu unterscheiden ist. Qualitativ können so Defekte erkannt, in ihrer Größe und Tiefenlage jedoch nur abgeschätzt werden.

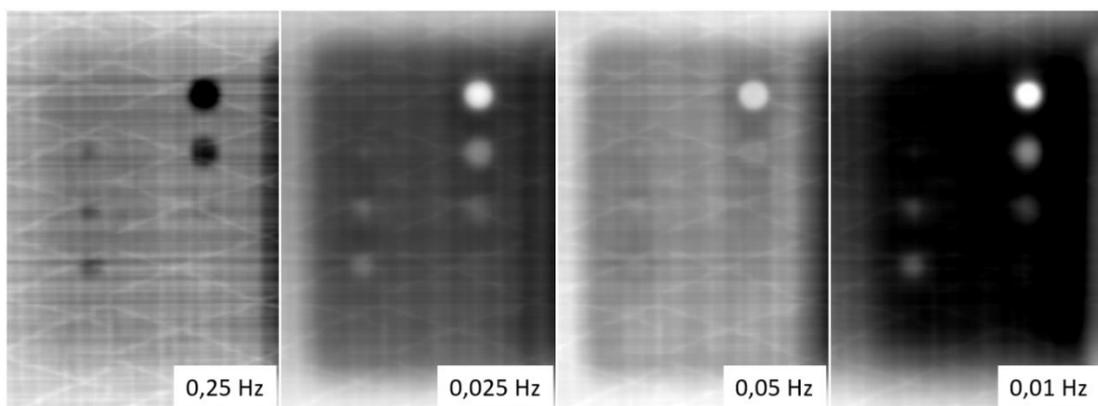


Abb. 1: Phasenbilder einer CFK Platte mit Flachbodenbohrungen unterschiedlicher Tiefe und Durchmesser sowie einer eingebrachten Stufe bei unterschiedlichen Frequenzen. Die Flachbodenbohrungen sind durch helle oder dunkle Kreise zu erkennen, die Stufe überstreckt sich über große Bereiche des Messausschnitts und ist jeweils in der linken oberen und linken unteren Ecke besonders ausgeprägt zu erkennen.

Sowohl das Ziel der dreidimensionalen Defektdarstellung als auch die Nähe zu anderen ZfP-Verfahren führte dazu, dass aus der Ultraschall- und Radartechnik bekannte Algorithmen auch auf Messdaten der aktiven Thermografie angewandt werden. Mulaveesala und Tuli stellte 2006 sein Verfahren Thermal Wave Imaging [3] vor, welches eine Chirpanregung mit einer Fouriertransformation als Auswertung vereint. Die Forschergruppe um Mandelis veröffentlichte 2009 das Thermal Wave Radar [4, 5] Verfahren, worin eine Chirpanregung mit dem Pulscompressionsverfahren kombiniert wird. Zeitlich nachfolgend veröffentlicht wurden Änderungen an den Signalformen untersucht bei denen nicht näher definierte binär codierte Signalformen [6], Barker Codes [7, 8] sowie Golay Paare [9] betrachtet wurden. In [10] und [11] setzte die Forschergruppe Mandelis et. al erstmals die zeitlich codierten Signalformen ein, um eine quantitative dreidimensionale Tomografie tiefliegender Defekte (Flachbodenbohrungen in Stahl) zu erstellen. Basierend auf der punktwisen Auswertung einzelner Bildpixel, berücksichtigt die dort aufgeführte dreidimensionale Darstellung sowie

alle vorangegangenen Arbeiten nicht die diffusionsbedingte laterale Wärmeausbreitung in ihrer Auswertung, sondern betrachten jeden Bildpixel individuell.

Die Forschergruppe Burgholzer et al. ging bei der 3D-Vorhersage einen anderen Weg und führte das virtuelle Wellenkonzept (VWC) [12] ein. Die virtuellen Wellen stellen das Bindeglied zwischen punktförmiger Wärmequelle im diffusionsfreien Raum und der mit Diffusion beaufschlagten Ausbreitung thermischer Wellen dar. Die Lösung des inversen Problems, und der damit einhergehenden Berücksichtigung des lateralen Wärmeflusses, kann dabei bei guter Wahl der Randbedingungen die diffusiven thermischen Wellen in virtuelle diffusionsfreie Wellen überführen. Es wird dabei definiert, dass diese virtuellen Wellen sich ähnlich wie die gut erforschten akustischen Wellen im Raum ausbreiten. Auf die virtuellen Wellen können jegliche für akustische Wellen geltenden Auswertelgorithmen angewandt werden. 2020 zeigte Thummerer et al. [13] auf, dass sich mit dem VWC bei geeigneter Regularisierung anisotrope Verbundmaterialien untersuchen lassen. Auch die Umsetzung des Verfahrens bei nur einseitiger Zugänglichkeit zum Bauteil konnte in [14] veranschaulicht werden. Zu einem etwas früheren Zeitpunkt demonstrierten Richter et al., dass ein nichtlinearer Optimierungsalgorithmus (Levenberg-Marquardt-Algorithmus) zur Rekonstruktion von unbekanntem Rückwandgeometrien [15] eingesetzt werden kann. Ebene Geometrien konnten dabei gut rekonstruiert werden, an Bereichen mit großen Dickenänderungen nahm die Rekonstruktionsgenauigkeit jedoch ab.

Einführung zur künstlichen Intelligenz

Künstliche Intelligenz (KI), im speziellen neuronale Netze (NN) mit all ihren Unterarten, sind seit einigen Jahren nicht mehr aus unserem alltäglichen Leben wegzudenken. Die KI kann dabei in zwei völlig unterschiedliche Herangehensweisen untergliedert werden. Das überwachte Lernen und das unüberwachte Lernen. In letzterem ist ein „intelligentes“ System in der Lage, nur aus Eingabedaten eine Vorhersage abzuleiten, ohne genauere Informationen über die Aufgabe zu bekommen. Ein Anwendungsgebiet ist zum Beispiel die Mustererkennung. Dabei teilt ein System selbstständig Daten in zueinander passende Gebiete ein. Daten die von den zuvor betrachteten Gebieten abweichen, werden in ein „neues“ Gebiet gruppiert. Unüberwachtes Lernen benötigt keine beschrifteten Daten und kann schnell mit einer Vielzahl an Daten trainiert werden. Ein funktionierendes unüberwachtes KI System stellt in vielen KI-Bereichen den „heiligen Gral“ dar. Häufiger kommt bisher das besser zu verstehende und parametrisierbare System des überwachten Lernens zum Einsatz. Der Datensatz für überwachtes Lernen besteht zum einen aus den Eingabeparametern X (ähnlich dem unüberwachten Lernen) und zusätzlich aus den Ausgabeparametern Y (Zielgröße, was vorhergesagt werden soll). Die durch die KI abgebildete mathematische Funktion wird in einem Trainingsprozess so angepasst, dass sie bestmöglich die Eingabeparameter X auf die Ausgabeparameter Y abbildet. Je universeller die Daten X und Y gefasst werden, desto robuster kann eine KI die gewünschte Vorhersage durchführen. Wesentlichen Erfolg für ein NN stellt die an vielen Stellen eingefügte nichtlineare Aktivierungsfunktion dar. Erst dadurch unterscheidet sich ein NN grundlegend von einer linearen Funktion und gibt dem NN die Möglichkeit, die Vorhersage komplexer Datensätze abbilden zu können.

Die Historie von NN in der aktiven Thermografie reicht bis ins letzte Jahrtausend zurück. Saintey und Almond konnten 1997 durch ein dreischichtiges Perceptron NN [16] die Tiefe und den Durchmesser von Flachbodenbohrungen durch Betrachtung spezieller Merkmale (halbe Anstiegszeit, halbe Abklingzeit, geometrische Überstreckung zur halben Anstiegszeit, geometrische Überstreckung zur halben Abklingzeit und Maximaler Temperaturkontrast) in der Aufheiz- und Abkühlkurve des Thermogramms an einer Flachbodenbohrung vorhersagen. Mittels Puls-Phasen-Thermografie und Puls-Thermografie

untersuchten Vallerand und Maldague im Jahr 2000 [17] ebenfalls Flachbodenbohrungen und unterteilten die Flachbodenbohrungen sowohl mit unüberwachten Kohonen NN als auch mit überwachten Perceptron NN pixelweise in defektfreie sowie defektbehaftete Gebiete ein und ordneten einzelnen Pixeln eine Tiefe zu. Speziell an den Rändern traten jedoch Abweichungen von der tatsächlichen Größe auf. 2013 konnte Dudzik durch pixelweise Betrachtung der Thermogramme und einer Hauptkomponentenanalyse ähnliche Ergebnisse für Flachbodenbohrungen in PMMA aufzeigen [18]. In den letzten Jahren veränderte sich die Methodik der KI durch neue Erkenntnisse auf dem Themengebiet deutlich und in vielen Fachbereichen konnten große Fortschritte durch immer tiefere und komplexere NN erzielt werden. Duan et. al [19] zeigten mittels einem mehrschichtigen NN auf, dass unterschiedlich tiefe und unterschiedlich gefüllte (Öl, Wasser, Luft) Flachbodenbohrungen aus den Abkühlkurven der Thermogramme separiert werden können. Mittels sogenannten Encoder-Decoder Netzen (häufig auch U-Net genannt) konnte aus Bildsequenzen (Lockin-Messungen, Thermographic Signal Reconstruction, oder Puls-Phasen-Thermografie) die pixelweise Lokalisierung von Defekten bei nur wenigen Messungen vorhergesagt werden [20, 21]. Auch Zeitsequenzen wurden betrachtet um mittels sogenannten rekurrenten NN (zum Beispiel einem LSTM-Netz) pixelweise die Tiefe oder die Eigenschaft eines Bauteils vorherzusagen [20, 22, 23]. Im Gegensatz zu den oben beschriebenen Methoden wird nachfolgend die Auswertung mittels eines Encoder-Decoder-Netzes in Kombination mit eindimensionalen Faltungsoperationen verwendet, um im Rahmen des überwachten Lernens von Thermogrammsequenzen auf dreidimensionale Tiefengeometrien schließen zu können.

Trainingsdaten

Zum Training des nachfolgend aufgezeigten NN werden simulativ erstellte Trainingsdaten X mit den dazugehörigen Geometrien als Ausgabeparameter Y verwendet. Für die Wärmeflussimulation wird COMSOL Multiphysics, COMSOL AB, Stockholm, Schweden, mit dem Heat Transfer Module in der Version 5.6 eingesetzt. Das thermografische Messprinzip erfolgt nach der Pulsthermografie. Das heißt, einem zeitlich definierten Wärmeeintrag durch eine optische Wärmequelle folgt eine ebenfalls zeitlich genau definierte Abkühlperiode in der die Oberflächentemperatur festgehalten wird. Aus Veränderung der Oberflächentemperatur des Bauteils über der Zeit werden Rückschlüsse über die inneren Strukturen des Bauteils getroffen. Die Simulationsparameter werden entsprechend der Laborausstattung des Instituts für Kunststofftechnik der Universität Stuttgart gewählt.

Die Pulsanregung erfolgt für 0,5 s mit einer Strahlungsintensität von 10.000 W/m². Das zu untersuchende Material wird mit einer Dichte von 1410 kg/m³, einer Wärmeleitfähigkeit von 0,31 W/(m K) sowie einer spezifischen Wärmekapazität von 1500 J/(kg K) angenommen und deckt sich damit mit den Werkstoffeigenschaften von Polyoxymethylen (POM). Die Bauteildicke des Prüfkörpers wird zu 6 mm definiert und durch lokal abweichende Rückwandgeometrien an den Defektstrukturen von Impactschäden in Verbundwerkstoffen angelehnt. Die Größe einzelner POM-Platten (100 mm x 150 mm) orientiert sich an der Größe von CAI-Prüfkörpern. Die Geometrien der Impactschäden entstammen numerischer Struktursimulationen von CAI Prüfkörpern [24] und werden als Grenzflächendelaminationen von CFK in diskreten Tiefen angenommen. Die Delaminationen werden zur vereinfachten Darstellung und anschließenden Verifikation als unendlich dicke Grenzflächen angenommen. In Abb. 2, Mitte und links sind zwei von insgesamt 500 unterschiedlichen Impactgeometrien abgebildet. Neben 500 über der Tiefe gleichverteilten Grenzflächendelaminationen aus den 500 unterschiedlichen Impactgeometrien, wurden 2000 weitere Simulationen (4 je Impactgeometrie) durchgeführt, bei denen die Schichttiefen regelmäßig wie auch arbiträr variiert, einzelne

Grenzflächendelaminationen in ihrer Tiefenlage untereinander vertauscht oder ganz weggelassen wurden. Den Datensatz vervollständigen 2000 weitere Simulationen mit arbiträr erstellten 3D-Geometrien. Dabei werden sowohl die Anzahl der möglichen „Delaminationen“ je Ebene, die Anzahl der Delaminationsebenen sowie auch deren Geometrie und Größe zufällig bestimmt, Beispielbild einer Geometrie siehe Abb. 2 rechts.

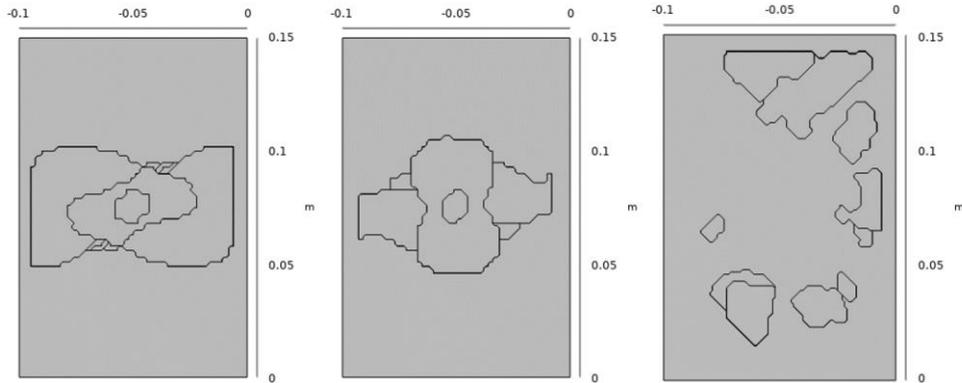


Abb. 2: CAD-Darstellung von zwei Impactgeometrien (Mitte und links) sowie CAD-Darstellung einer arbiträr erstellten Geometrie (rechts). Genaue Tiefenlagen sind nicht aus der 2D-CAD-Darstellung zu entnehmen.

Zu den wie oben beschriebenen 3D-Geometrien, welche die Ausgabeparameter Y darstellen, wird mittels COMSOL jeweils eine Wärmeflussimulation durchgeführt um die Eingabeparameter X des NN zu ermitteln. Zur Datenreduktion werden die Thermogramme in unterschiedlich verteilten Zeitschritten abgespeichert. Direkt nach der Erwärmung werden Temperaturwerte im Zeitabstand von 10 ms abgespeichert. Entsprechend den abnehmenden Temperaturgradienten mit zunehmender Messdauer und der damit einhergehenden Abnahme des Informationsgehalts pro Zeitschritt, werden in der Simulation die diskreten Zeitintervalle stückweise vergrößert, bis sie letztlich bei einem Intervall von fünf Sekunden angekommen sind und sich über eine Gesamtsimulationsdauer von 50 s erstrecken. Dabei werden insgesamt 49 diskrete Thermogramme und somit 49 diskrete Temperaturwerte je Pixel aufgezeichnet. Die Ergebnisse der Wärmeflussimulationen werden vor der Übergabe ans NN mit einem normalverteilten Rauschen von 20 mK überlagert und in ihrem Betrag linear skaliert. Die Raumtemperatur wird zu Zahlenwert 0 angenommen und abweichende Temperaturwerte in Kelvin werden um den Faktor 30 skaliert dargestellt. Durch die Skalierung der Eingabeparameter zu Zahlenwerten zwischen 0 und 1 (wobei sowohl kleinere als auch größere Zahlenwerte theoretisch möglich sind), wird das NN schneller und robuster trainiert als ohne die Skalierung. Das NN wird anschließend dazu eingesetzt um von den ermittelten Temperaturwerten auf die Ausgangsgeometrie zu schließen. Das NN nimmt sich damit der Lösung des inversen Wärmeleitungsproblems an.

Erstellung des neuronalen Netzes

Das nachfolgend verwendete NN basiert auf der Kombination einer eindimensionalen Faltungsschicht (Conv 1x1) und eines NN basierend auf dem von Ronneberger et. al eingeführten U-Net [25]. Der Aufbau des Netzes ist in Abb. 3 dargestellt. Abweichend von der ursprünglichen Auslegung des U-Net wurden die einzelnen Faltungsoperationen (Conv 3x3) so ausgeführt, dass die Datengröße dadurch nicht verringert wurde. Dieses Vorgehen wird häufig als SAME padding bezeichnet. Zusätzlich wird nach jeder 2D-Faltungsoperation eine Normalisierung des Datenflusses durchgeführt um die Stabilität des NN zu erhöhen. Dies war zum Zeitpunkt der ursprünglichen Veröffentlichung des U-Net (2015) noch nicht üblich, ist heutzutage jedoch Standard für KI-Anwendungen. Dem U-Net wird eine

eindimensionale Faltungsschicht vorangestellt um die Thermografiesequenz effizient in ihrer Größe zu reduzieren, ohne dabei einen wesentlichen Informationsverlust zu erhalten. Da die Operation pixelweise durchgeführt wird, werden in diesem Schritt keine lateralen Wärme-flüsse berücksichtigt. Hierbei wird die Videosequenz von 45 diskreten Werten pro Pixel auf 30 diskrete Werte pro Pixel reduziert. Die Besonderheit dabei ist, dass die 30 erlernten Werte keinen trivialen Zusammenhang zum zuvor vorliegenden Temperaturverlauf haben müssen, sondern aus 30 diskreten Werten bestehen können, die für die Interpretation der Tiefenstruktur bestmöglich geeignet sind. Durch die Funktion wird das NN zeitabhängig, das heißt Zeitverschiebungen im Eingabeparameterdatensatz X würden zur Fehlinterpretation des NN führen. Da der Datensatz jedoch immer mit Beginn der Abkühlkurve startet, stellt diese keine Einschränkung für den vorliegenden Datensatz dar. Laterale Wärme-flüsse werden im nachfolgenden U-Net durch sowohl die 3x3 Faltungsoperationen als auch durch die Maxpool 2x2 Operationen (Reduzierung der Datenmenge um Faktor 4 durch Substitution einer 2x2 Matrix durch größten Zahlenwert der Matrix) erzielt. Mit zunehmender Tiefe des NN nimmt der laterale Informationstransfer stetig zu und überstreckt sich in der letzten Schicht über alle Pixel des Eingangsbilds. Aus dem lediglich mit 14 x 18 Pixeln und 1024 Informationskanälen bestehenden Datensatz werden im Decoder des U-Net (der rechten Seite des „U“) stückweise durch die transponierten Faltungsoperationen und die Verkettung mit Datensätzen aus dem Encoder des U-Net (linke Seite des „U“) lokale Informationen des Datensatzes hinzugefügt bis in der letzten Schicht des NN die lokale Tiefeninformation vorliegt. Als Aktivierungsfunktion wird die sogenannte ReLU Funktion und als Fehlerfunktion die mean squared error (MSE) Funktion, also die Funktion der mittleren Fehlerquadrate zwischen der vorhergesagten Tiefe und der tatsächlichen Tiefe, verwendet. Die Learningrate, also der Anpassungsfaktor von neuen Erkenntnissen auf vorherige Erkenntnisse im Trainingsprozess des NN, wird zu 0,0001 definiert. Innerhalb eines Trainingsschritts werden jeweils 16 Datensätze (Batchsize) auf einer Grafikkarte, NVIDIA GeForce RTX 3080 Ti für insgesamt 150 Trainingsdurchläufe (Epochen) berechnet. Innerhalb weniger Stunden kann das NN auf den aus 4500 Thermografiesequenzen bestehenden Datensatz in der Entwicklungsumgebung PyTorch Version 1.10.1 trainiert werden.

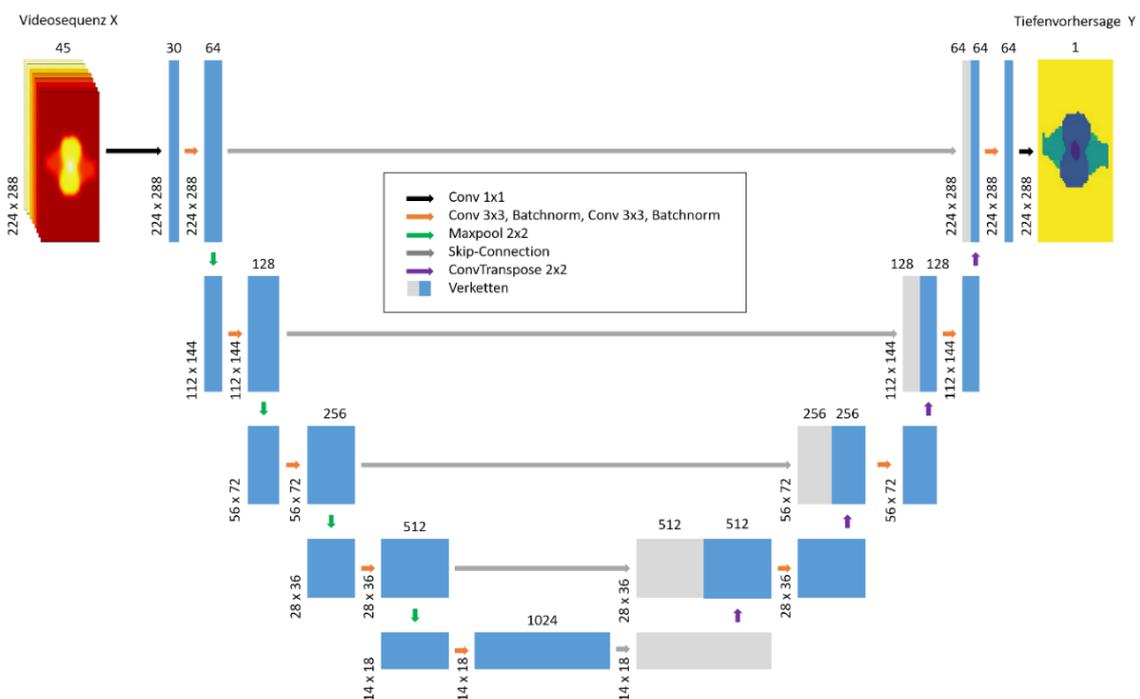


Abb. 3: Schemaskizze des neuronalen Netz, links Eingabeparameter X, rechts Ausgabeparameter Y

Ergebnisse und Diskussion

Zur Validierung des NN wird der 4500 Simulationen umfassende Datensatz in einen Trainingsdatensatz mit etwa 90 % der Simulationsdaten, einen Validierungsdatensatz mit etwa 10 % der Simulationsdaten sowie einem Testdatensatz mit 16 Simulationen unterteilt. Die gradientenbasierte Fehlerrückführung (Backpropagation) des Trainingsprozesses wird nach jeder „Batch“ von 16 Datensätzen durchgeführt und erfolgt somit 252-mal pro Trainingsepoche. Die pixelweise bestimmten mittleren Fehlerquadrate zwischen Vorhersage des NN und der realen 3D-Geometrie über die jeweils 252 Batches einer Epoche sowie die mittleren Fehlerquadrate über die 28 Batches des Validierungsdatensatzes je Epoche sind in Abb. 4 dargestellt. Man sieht für beide Kurven eine kontinuierliche Abnahme der mittleren Fehlerquadrate bis ca. Epoche 100, danach ist ein Plateau erreicht und kein weiterer Trainingsfortschritt wird erzielt. Eine weitere Verringerung der Vorhersagegenauigkeit könnte durch eine adaptive Anpassung der Lernrate erzielt werden. Auf dies wurde im Rahmen der Untersuchungen jedoch verzichtet. Die Schwankungen innerhalb der mittleren Fehlerquadrate der Trainingsgenauigkeit sind auf nicht durch das NN zuverlässig vorherzusagende 3D-Geometrien der arbiträr erstellten Geometrien in Kombination mit einer zu hohen Learningrate zurückzuführen. Ein Großteil des Datensatzes weist tannenbaumartig angeordnete Delaminationsflächen auf, wie man sie typischerweise von Impactschäden kennt. Die Rückwandgeometrie verläuft dabei mit diskreten Plateaus wie eine konvexe Funktion. Je tiefer die Delamination liegt, desto größer ist deren Durchmesser. Einige der arbiträr erstellten Geometrien weisen jedoch im Verlauf ihrer Rückwandgeometrie einen Wechsel von konvexen zu konkaven und zurück zu konvexen Strukturen auf. Die damit abgebildeten Rippen- und Stegstrukturen werden (noch) nicht zuverlässig durch das NN vorhergesagt und führen teilweise zum Anstieg der mittleren Fehlerquadrate und damit zur Fehlinterpretation an der Rippenstruktur, siehe Abb. 5 d.

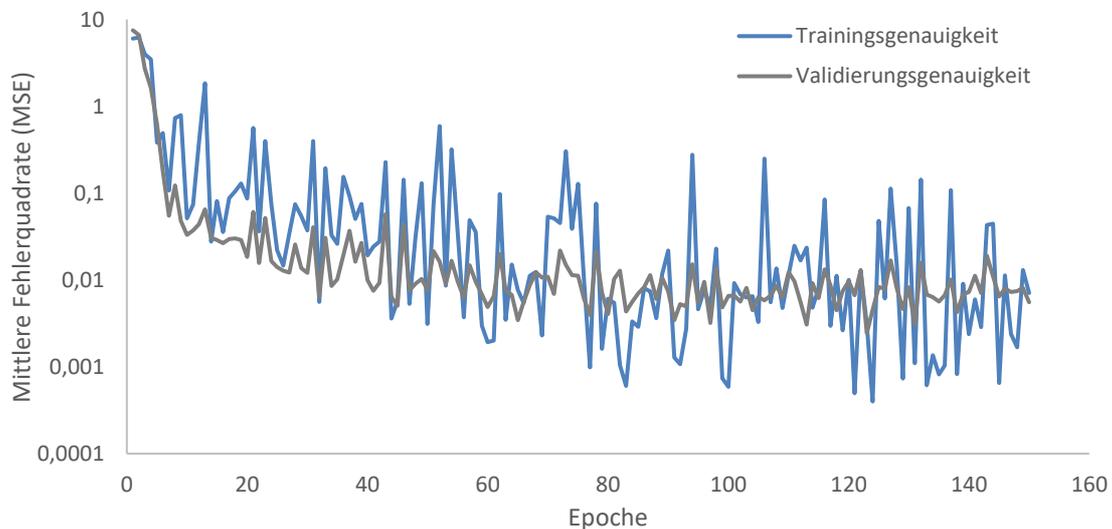


Abb. 4: Trainings- und Validierungsfortschritt der mittleren Fehlerquadrate

Abb. 5 stellt die Tiefenvorgabe (reale 3D-Geometrie) an das NN, die Tiefenvorhersage des NN, sowie deren Differenz für die drei in Abb. 2 aufgezeigten Geometrien sowie für eine 3D-Geometrie mit Rippelement zur Epoche 100 dar. Alle darin abgebildeten Strukturen sowie deren Variationen entstammen dem Testdatensatz und wurden nicht zum Training oder zur Validierung des NN verwendet. Die Bauteildicke ist farbcodiert dargestellt. Gelb entspricht einer dicken Bauteilstruktur (6 mm Plattendicke) und blau der obersten Grenzfläche der Delamination, also einer dünnen Bauteilgeometrie bzw. einer nicht vorhandenen Abweichung im Differenzbild. Die drei konvexen Geometrien können ohne

nennenswerte Abweichungen bestimmt werden und decken sich mit den Erkenntnissen der Validierungsgenauigkeit des NN ab Epoche 100. Die mittlere lokale Geometrieabweichung des Validierungsdatensatzes kann zu einem mittleren quadratischen Fehler von etwa $\sqrt{0,008} \text{ mm}$ bzw. einer mittleren lokalen Geometrieabweichung von $\pm 0,09 \text{ mm}$ bestimmt werden. 3D-Geometrien mit Rippenelementen, siehe Abb. 5 d, weisen hingegen lokal an den Rippen eine höhere Geometrieabweichung auf.

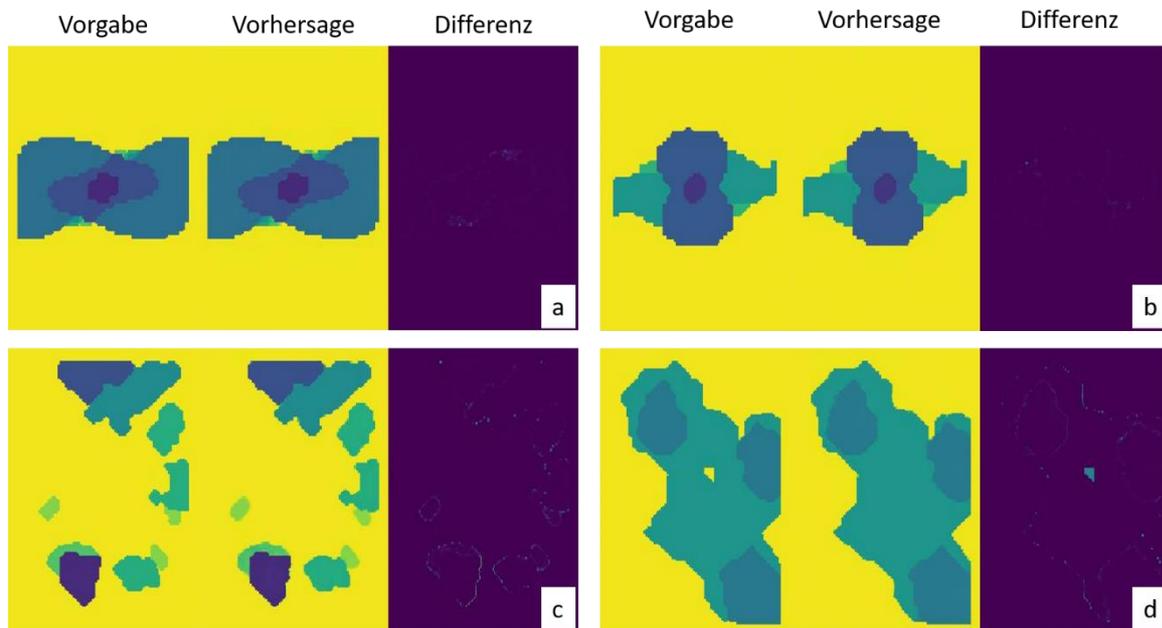


Abb. 5: Farbcodierte Darstellung der Tiefenvorgabe, Tiefenvorhersage und Differenz von vier 3D-Geometrien zur Epoche 100. Geometrien a und b sind nach Vorgaben der Impactgeometrien erstellt worden, Geometrien c und d arbiträr. Geometrie d beinhaltet eine Rippengeometrie (gelbe Geometrie in blauem Gebiet) und wird an dieser Stelle nicht zuverlässig durch das NN vorhergesagt.

Fazit und Ausblick

Es wurde aufgezeigt, dass sich NN zur Vorhersage von impactähnlichen Defektgeometrien sowie arbiträr erstellten 3D-Geometrien aus Thermogrammen eignen. Encoder-Decoder-Netze eignen sich dabei gut, um die laterale Wärmeausbreitung der Thermogramme zu invertieren. Rippenähnliche Strukturen, welche durch den Trainingsdatensatz nur unzureichend abgebildet wurden, können hingegen nicht zuverlässig vorhergesagt werden. Über alle Validierungsdaten hinweg erreicht das NN nach etwa 100 Epochen ein Plateau der Vorhersagegüte und kann die Bauteildicke mit einem mittleren quadratischen Fehler von $\sqrt{0,008} \text{ mm} \sim 0,09 \text{ mm}$ vorhersagen. Im Vergleich zur Tiefenbestimmung mit klassischen Methoden der aktiven Thermografie, kann die Vorhersage als hinreichend exakt betrachtet werden. In zukünftigen Untersuchungen zu dem Thema werden sowohl das NN als auch die Datensätze weiter angepasst, um neben simulativen Daten auch reale Messdaten vorherzusagen.

Literaturverzeichnis

- [1] ALMOND, D. und P. PATEL. *Photothermal science and techniques*. London: Chapman & Hall, 1996. Physics and its applications. 10. ISBN 0412578808.
- [2] RITTMANN, J. and M. KREUTZBRUCK. Flächige photothermische Schichtdickenbestimmung und Materialcharakterisierung an Ein- und Mehrschichtsystemen. In: *Tagungsband 27 Stuttgarter Kunststoffkolloquium 978-3-9818681-2-8, 2021*.

- [3] MULAVEESALA, R. and S. TULI. Theory of frequency modulated thermal wave imaging for nondestructive subsurface defect detection. In: *Applied Physics Letters*, 2006, **89**(19), 191913. Doi:10.1063/1.2382738
- [4] TABATABAEI, N. and A. MANDELIS. Thermal-wave radar: a novel subsurface imaging modality with extended depth-resolution dynamic range. In: *The Review of scientific instruments*, 2009, **80**(3), 34902. Doi:10.1063/1.3095560
- [5] TABATABAEI, N. and A. MANDELIS. Thermal-wave radar. In: *Journal of Physics: Conference Series*, 2010, **214**, 12088. Doi:10.1088/1742-6596/214/1/012088
- [6] TABATABAEI, N. and A. MANDELIS. Thermal coherence tomography using match filter binary phase coded diffusion waves. In: *Physical review letters*, 2011, 165901. Doi:10.1103/PhysRevLett.107.165901
- [7] GHALI, V.S., S.S.B. PANDA and R. MULAVEESALA. Barker coded thermal wave imaging for defect detection in carbon fibre-reinforced plastics. In: *Insight - Non-Destructive Testing and Condition Monitoring*, 2011, **53**(11), 621–624. Doi:10.1784/insi.2011.53.11.621
- [8] SHI, Q., J. LIU, W. LIU, F. WANG and Y. WANG. Barker-coded modulation laser thermography for CFRP laminates delamination detection. In: *Infrared Physics & Technology*, 2019, **98**, 55–61. Doi:10.1016/j.infrared.2019.02.007
- [9] ARORA, V. and R. MULAVEESALA. Application of golay complementary coded excitation schemes for non-destructive testing of sandwich structures. In: *Optics and Lasers in Engineering*, 2017, **93**(7), 36–39. Doi:10.1016/j.optlaseng.2017.01.009
- [10] KAIPLAVIL, S. and A. MANDELIS. Truncated-correlation photothermal coherence tomography for deep subsurface analysis. In: *Nature Photonics*, 2014, **8**(8), 635–642. Doi:10.1038/nphoton.2014.111
- [11] TAVAKOLIAN, P., K. SIVAGURUNATHAN and A. MANDELIS. Enhanced truncated-correlation photothermal coherence tomography with application to deep subsurface defect imaging and 3-dimensional reconstructions. In: *Journal of Applied Physics*, 2017, **122**(2), 23103. Doi:10.1063/1.4992807
- [12] BURGHOLZER, P., M. THOR, J. GRUBER and G. MAYR. Three-dimensional thermographic imaging using a virtual wave concept. In: *Journal of Applied Physics*, 2017, **121**(10), 105102. Doi:10.1063/1.4978010
- [13] THUMMERER, G., G. MAYR, P.D. HIRSCH, M. ZIEGLER and P. BURGHOLZER. Photothermal image reconstruction in opaque media with virtual wave backpropagation. In: *NDT & E International*, 2020, **112**, 102239. Doi:10.1016/j.ndteint.2020.102239
- [14] THUMMERER, G., G. MAYR and P. BURGHOLZER. Photothermal testing of composite materials: Virtual wave concept with prior information for parameter estimation and image reconstruction. In: *Journal of Applied Physics*, 2020, **128**(12), 125108. Doi:10.1063/5.0016364
- [15] RICHTER, R., C. MAIERHOFER and M. KREUTZBRUCK. Numerical method of active thermography for the reconstruction of back wall geometry. In: *NDT & E International*, 2013, **54**(4), 189–197. Doi:10.1016/j.ndteint.2012.10.010
- [16] SAINTEY, M.B. and D.P. ALMOND. An artificial neural network interpreter for transient thermography image data. In: *NDT & E International*, 1997, **30**(5), 291–295. Doi:10.1016/S0963-8695(96)00071-0
- [17] VALLERAND, S. and X. MALDAGUE. Defect characterization in pulsed thermography: a statistical method compared with Kohonen and Perceptron neural networks. In: *NDT & E International*, 2000, **33**(5), 307–315. Doi:10.1016/S0963-8695(99)00056-0
- [18] DUDZIK, S. Characterization of Material Defects Using Active Thermography and an Artificial Neural Network. In: *Metrology and Measurement Systems*, 2013, **20**(3), 491–500. Doi:10.2478/mms-2013-0042
- [19] DUAN, Y., S. LIU, C. HU, J. HU, H. ZHANG, Y. YAN, N. TAO, C. ZHANG, X. MALDAGUE, Q. FANG, C. IBARRA-CASTANEDO, D. CHEN, X. LI and J. MENG. Automated defect classification in infrared thermography based on a neural network. In: *NDT & E International*, 2019, **107**(12), 102147. Doi:10.1016/j.ndteint.2019.102147
- [20] MÜLLER, D., U. NETZELMANN and B. VALESKE. Defect shape detection and defect reconstruction in active thermography by means of two-dimensional convolutional neural network as well as spatiotemporal convolutional LSTM network. In: *Quantitative InfraRed Thermography Journal*, 2020, **214**, 1–19. Doi:10.1080/17686733.2020.1810883
- [21] OLIVEIRA, B.C.F., A.A. SEIBERT, V.K. BORGES, A. ALBERTAZZI and R.H. SCHMITT. Employing a U-net convolutional neural network for segmenting impact damages in optical lock-in thermography images of CFRP plates. In: *Nondestructive Testing and Evaluation*, 2021, **36**(4), 440–458. Doi:10.1080/10589759.2020.1758099
- [22] WANG, Q., Q. LIU, R. XIA, G. LI, J. GAO, H. ZHOU and B. ZHAO. Defect Depth Determination in Laser Infrared Thermography Based on LSTM-RNN. In: *IEEE Access*, 2020, **8**, 153385–153393. Doi:10.1109/ACCESS.2020.3018116
- [23] XU, L. and J. HU. A Method of Defect Depth Recognition in Active Infrared Thermography Based on GRU Networks. In: *Applied Sciences*, 2021, **11**(14), 6387. Doi:10.3390/app11146387
- [24] BASTEK, M. *Entwicklung einer Methodik zur schnellen Impact-Simulation von Faserverbundwerkstoffen mittels maschinellen Lernens*. Masterarbeit. Stuttgart, 2020.
- [25] RONNEBERGER, O., P. FISCHER und T. BROX. *U-Net: Convolutional Networks for Biomedical Image Segmentation*, 2015.