

eingereicht/handed in: 22.12.2021
angenommen/accepted: 05.09.2022

*Johannes Rittmann, M.Sc; Prof. Dr. rer. nat. habil. Marc Kreuzbruck,
Institut für Kunststofftechnik, Universität Stuttgart*

Defektcharakterisierung in isotropen und faserverstärkten Kunststoffen mittels aktiver Thermografie und neuronalen Netzen

Die optisch angeregte Lockin-Thermografie eignet sich gut zur schnellen und robusten Auffindung von oberflächennahen Defekten in isotropen und faserverstärkten Kunststoffen. Die daraus resultierenden Phasenbilder werden durch die Anregungsfrequenz als Messparameter beeinflusst und können im eindimensionalen Fall zur tiefenselektiven Auswertung betrachtet werden. Für reale Prüfkörper überwiegen jedoch diffuse Wärmeleitungsprozesse, die eine genaue Defektcharakterisierung aus Phasenbildern deutlich erschweren. Neuronale Netze werden innerhalb dieser Arbeit eingesetzt, um mehrere Phasenwerte unterschiedlicher Anregungsfrequenz zu bewerten und dadurch erstmals eine quantitative Defektcharakterisierung in isotropen und faserverstärkten Kunststoffen auf Basis eines LSTM-CNN Hybrid Modells umzusetzen. Es wird aufgezeigt, dass die bereits guten Vorhersagewerte des neuronalen Netzes durch zusätzliche Trainingsdaten, die aus Wärmeflussimulationen ermittelt wurden, nochmals signifikant verbessert werden.

Defect characterization in isotropic and fiber-reinforced plastics using active thermography and neural networks

Optically excited Lockin-Thermography is well suited for fast and robust detection of near-surface defects in isotropic and fiber-reinforced plastics. The resulting phase images are driven by the excitation frequency as a measurement parameter and can be analyzed in the one-dimensional case for depth-selective evaluation. For real test specimens, however, diffusive heat conduction processes overwhelm which makes accurate defect characterization from phase images much more difficult. Neural networks are used within this work to evaluate multiple phase values of different excitation frequencies with each other and thus implement for the first time a quantitative defect characterization in isotropic and fiber-reinforced plastics based on a LSTM-CNN hybrid model. It is shown that the already good prediction values of the neural network are again significantly improved by additional training data obtained from heat flow simulations.

Defektcharakterisierung in faserverstärkten Kunststoffen mittels aktiver Thermografie und neuronalen Netzen

J. Rittmann, M.Kreuzbruck

1 EINLEITUNG

Die Herstellung von FKV bringt potentielle Fehlerquellen mit sich mit. An diesem Punkt setzt die zerstörungsfreie Prüfung an und ermöglicht es, FKV zu inspizieren, ohne sie für den eigentlichen Anwendungszweck unbrauchbar zu machen. Verfahren zur Prüfung gibt es viele, und ad-hoc kann kein Verfahren als bestes Verfahren auserkoren werden. Dies hängt vom Einsatzzweck ab. Zur oberflächigen Rissprüfung in Metallen wird oftmals die Farbeindringprüfung verwendet [1], kleine hochkomplexe Bauteile und Schäden wie Delaminationen werden häufig mittels Computertomografie [2] im gesamten Volumen überprüft, und für FKV aus der Luftfahrtindustrie wird bis heute häufig auf die Ultraschallprüfung [3] als Volumenprüfverfahren gesetzt. Die aktive Thermografie [4, 5] wiederum ist ein Prüfverfahren, welches durch die Wechselwirkung einer thermischen Welle mit dem Bauteil Inhomogenitäten in Oberflächennähe detektieren kann. Speziell für flächige FKV ist das Verfahren durch seine kurze Messdauer und die geringen Sicherheitsmaßnahmen anderen zerstörungsfreien Prüfverfahren überlegen. Dabei sind diffuse Prozesse der Wärmeausbreitung im Medium ein wesentlicher Nachteil des Verfahrens. Durch die diffusen Wärmeleitungsprozesse wird die tatsächliche Defektgeometrie und Defektgröße häufig fehlinterpretiert. Dies stellt einen der Gründe dar, weshalb die aktive Thermografie, trotz ihrer schnellen und kostengünstigen Inspektion, bisher nur selten für die Defektcharakterisierung von faserverstärkten Kunststoffen eingesetzt wird.

Erfahrene Prüfer*innen wissen die diffusen Wärmeleitungsprozesse einzuschätzen und können die Unschärfe teilweise bei der Defektbewertung kompensieren. Numerische Ansätze zur dreidimensionalen Rekonstruktion und damit zur Eliminierung der diffusen Wärmeleitungsprozesse wurden im Labormaßstab zwar für isotrope Materialien gefunden [6, 7], für den Einsatz im technischen Umfeld, insbesondere an anisotropen Materialien, sind jedoch noch zu viele Störgrößen vorhanden. Eine Alternative stellt die Auswertung mittels neuronalen Netzen (NN) dar. In [8] wurde ein dreischichtiges Perzeptron [9] NN vorgestellt, das aus fünf für eine Fehlerstelle charakteristischen thermischen Zahlenwerten einer Pulserwärmung sowohl den Defektdurchmesser als auch die Defekttiefe von Flachbodenbohrungen bestimmen konnte. Obwohl das NN gute Ergebnisse erzielte, wurde nicht durch das NN selbst, sondern schon bei der Ermittlung der charakteristischen

thermischen Zahlenwerte durch den Prüfer die thermische Diffusion kompensiert.

Einen etwas anderen Ansatz verfolgten die Veröffentlichungen [10, 11], hierin wurde ebenfalls ein dreischichtiges Perzeptron NN zur Tiefenvorhersage verwendet, diesmal nicht an einem charakteristischen Punkt für den Defekt, sondern an jedem Pixel des Thermogramms individuell, ohne dabei die thermische Diffusion zu kompensieren. Ein anderer Ansatz verfolgte die Strategie des unüberwachten Lernens [12], um ohne zusätzliche Informationen über das Bauteil auf die Tiefeninformation schließen zu können. In allen Fällen wurden die thermischen Informationen pixelweise an das NN übergeben, ohne eine „Querverbindung“ der einzelnen Informationen zu ermöglichen. Damit wurde die Kompensation lateraler Wärmeflüsse und somit auch die Invertierung der thermischen Diffusion von Beginn an unterbunden, ähnlich wie es bei einer klassischen Auswertung in der aktiven Thermografie ist.

Im Rahmen dieses Beitrags wird ein Auswerteverfahren, basierend auf NN, für einfache Defekte aufgezeigt, welches pixelübergreifend agiert und somit in der Lage ist, die thermische Diffusion nach pulsformiger Anregung zu invertieren.

In den frühen 1940er Jahren beschrieben der Neuropsychologe Warren S. McCulloch und der Logiker Walter Pitts eine Art neurologischer Netze und legten somit den Grundstein für weitere Forschungen im Bereich der künstlichen Intelligenz. Angelehnt an das Prinzip von biologischen Neuronen bauten sie Schwellwertschalter nach und zeigten, dass deren Verknüpfung nahezu jede logische und arithmetische Funktion berechnen kann [13].

Neuronale Netze sind also, wie der Name schon deuten lässt, inspiriert durch das menschliche Gehirn und dessen komplexe neuronalen Verbunde und sollen Modelle des biologischen Lernens nachbilden. Sie sind ein (mehrdimensionaler) Zusammenschluss mathematischer Operationen und werden heute häufig zur Lösung von Optimierungsproblemen eingesetzt.

Die zu lösenden Optimierungsprobleme eines NN sind wie die Anforderungen an ein zerstörungsfreies Prüfverfahren sehr vielseitig und hängen vom jeweiligen Anwendungsfall ab. Als eines der bekanntesten Verfahren dient die Interpretation von Bildinformationen. Eine Vielzahl an Bildern wird zusammen mit der zugehörigen Bildinformation (was ist im Bild zu sehen) einem faltungsbasierten neuronalen Netz zum Training gegeben. Hieraus trainiert sich das Netzwerk in einem Optimierungsprozess bestimmte Merkmale zu den Bildklassen (Einteilung der vorliegenden Bildinformationen in Klassen) an, wodurch anschließend ähnliche Bilder in die zuvor definierten Bildklassen eingeteilt werden können. Dabei werden die trainierbaren Gewichte des NN als mathematische Faltungsoperationen betrachtet und mit den Eingabedaten multipliziert. Die Faltungsoperationen (engl. Convolutions) eines faltungsbasierten neuronalen Netzes (engl. Convolutional Neural Network, CNN) können dabei sowohl eine eindimensionale Struktur (zur Bewertung von Vektoren), eine zweidimensionale Struktur (zur Bewertung von Bildern) und in Einzelfällen auch eine Struktur höherer Ordnung aufweisen.

Rekurrente neuronale Netze besitzen im Gegensatz zu Feedforward-Netzen, wie dem oben beschriebenen CNN, Verschaltungen von Neuronen zu selben oder vorangegangenen Informationsschichten. Dies ist sehr hilfreich, wenn Informationen aus zeitlich codierten Datensätzen extrahiert werden soll. Neben der Spracherkennung wird dieser Ansatz zum Beispiel auch für maschinelle Übersetzungsprogramme verwendet.

2 GRUNDLAGEN ZUR AKTIVEN THERMOGRAFIE

Das im Rahmen des wissenschaftlichen Beitrags untersuchte zerstörungsfreie Prüfverfahren ist die aktive Thermografie. Es zählt zu den klassischen Prüfverfahren der zerstörungsfreien Prüfung und betrachtet die Ausbreitung thermischer Wellen im Prüfkörper. Im einfachsten Fall wird dabei ein Bauteil durch eine homogene Wärmequelle erwärmt und anschließend die Ausbreitung der Wärme im Bauteil durch eine Thermografiekamera (Wärmebildkamera) betrachtet.

Bei der Impulsthermografie erwärmt man das Bauteil durch einen zeitlich begrenzten Puls und betrachtet die Erwärmungs- und Abkühlkurve des Bauteils. [14] Trifft die von der Oberfläche injizierte thermische Welle in ihrer Ausbreitung auf einen thermischen Isolator (zum Beispiel einen Lufteinschluss), staut sich die Wärme auf und wird in einer lokal abweichenden Temperaturänderung an der Oberfläche sichtbar. Befindet sich hingegen ein gut leitender Fremdkörper im Bauteil (zum Beispiel ein metallischer Einschluss in einem Kunststoff), wirkt dieser als Wärmesenke, und die Oberflächentemperatur in Nähe des Fremdkörpers wird nachfolgend geringer als seine Umgebungstemperatur. Durch den Fremdkörper wird die Wärme in tiefere Schichten abgeleitet. Je tiefer eine Inhomogenität im Bauteil vorliegt, desto länger oder energiereicher muss der thermische Anregungspuls sein, und desto später und geringer wird seine Wechselwirkung mit der thermischen Welle an der Oberfläche sichtbar.

Im nachfolgend genauer betrachteten Messprinzip der optisch angeregten Lockin-Thermografie wird die Bauteiloberfläche mittels einer sinusförmig modulierten Wärmequelle erwärmt. Diese injizierte Wärmewelle mit definierter Frequenz breitet sich ins Bauteil aus, wird teilweise an Grenzflächen reflektiert und überlagert sich letztlich mit der periodisch angeregten Oberflächentemperatur des Bauteils. Dabei beruht die Messung auf dem Lockin-Messprinzip [4]. Zwischen der sinusförmig modulierten Wärmewelle und der mittels Thermografiekamera gemessenen thermischen Welle an der Oberfläche des Bauteils entsteht ein zeitlicher Versatz. Bezogen auf die Anregungsfrequenz wird dieser zeitliche Versatz als Phasenverschiebung der sinusförmigen Welle dargestellt. Der große Vorteil einer Lockin-Messung ist das rauscharme, selektive und robuste Messprinzip. Die Messung ist dabei weitgehend unabhängig von zeitlich zufällig auftretenden Störquellen sowie Reflektionen der Oberflächentemperatur des Bauteils.

2.1 Grundlagen zur Wärmeleitung

Für den vorliegenden Anwendungsfall einer Lockin-Messung mit flächiger homogener Ausleuchtung des Prüfkörpers kann die thermische Wellengleichung nach der Fourier'schen Differentialgleichung im eindimensionalen, quellfreien Fall wie folgt definiert werden [15]:

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

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

Für die Temperaturleitfähigkeit α gilt folgender 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 Oberfläche des Prüfkörpers ($x=0$) lässt sich die Temperatur im Prüfkörper als Lösung der Fourier'schen Differentialgleichung folgendermaßen bestimmen:

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

mit der Anfangsamplitude T_0 der thermischen Welle und der Kreisfrequenz ω .

μ beschreibt die thermische Eindringtiefe und ist definiert als

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

Wird eine thermische Welle in einen Prüfkörper eingeleitet, wechselwirkt die thermische Welle mit dem Bauteil. In der Lockin-Thermografie wird hierbei die Veränderung der Phasenlage und der Amplitude der thermischen Welle an der Prüfkörperoberfläche genauer untersucht. Im Grenzfall eines thermisch dicken Bauteils $d \gg \mu$ beträgt die Phasendifferenz zwischen der Wärmequelle und der sich an der Oberfläche des Prüfkörpers einstellenden thermischen Welle ($T(0, t)$) $-\pi/4$ bzw. -45° . Wird das thermische Wellenfeld durch Interferenzen gestört, bildet sich ein davon abweichendes Wellenfeld aus. Die einfachste Interferenz stellt die Reflexion der thermischen Welle an der Rückwand des Prüfkörpers dar. Hierbei gilt, dass die einfallende Welle T_E der Summe der reflektierten Welle T_R und der transmittierten Welle T_T entspricht.

$$T_E(x, t) = T_R(x, t) + T_T(x, t) \quad (5)$$

Dies lässt sich auch über den Reflexionskoeffizienten R_k und Transmissionskoeffizienten T_k ausdrücken.

$$1 = R_k + T_k \quad (6)$$

Aus der Fourier'schen DGL und Gleichung (6) lassen sich R_k und T_k folgendermaßen bestimmen.

$$R_k = \frac{e_1 - e_2}{e_1 + e_2} \quad (7)$$

$$T_k = \frac{2e_1}{e_1 + e_2} \quad (8)$$

Die thermische Effusivität $e = \sqrt{\lambda \rho c}$ gibt an, wie gut eine thermische Welle in ein Bauteil eindringen kann. Häufig wird dieser Koeffizient auch Wärme-eindringkoeffizient genannt.

Die sich von der Oberfläche eindimensional ausbreitende thermische Welle trifft bei der Dicke d auf die Grenzfläche zwischen der untersuchten Schicht 1 und dem dahinter befindlichen thermisch dicken Substrat 2 (Substrat 2 kann auch Luft sein). Aufgrund des Reflexionskoeffizienten R_{12} wird die thermische Welle dort teilweise reflektiert (7). Der reflektierte Anteil der thermischen Welle breitet sich in Richtung der Bauteiloberfläche aus und wird auch dort zu Teilen reflektiert, R_{01} . Diese Reflexion setzt sich bis zur vollständigen Dissipation der thermischen Welle fort, siehe Bild 1.

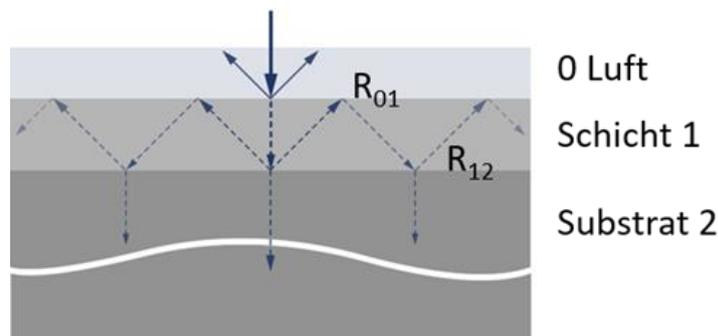


Bild 1: Reflexion an den Grenzflächen zur Beschreibung der Ausbreitung der thermischen Welle

Aus thermografischer Sicht ist nur die messbare thermische Größe von Relevanz. Bei im IR-Spektrum opaker Materialien ist dies die Oberflächentemperatur des Prüfkörpers.

Nach [16] ergibt sich durch Summation der einzelnen Reflexionen der sinusförmigen Anregung eine geschlossene Lösung für die Oberflächentemperatur, eine alternative Herleitung über die Green-Funktion ist ebenfalls möglich [17]:

$$T(0, t) = T_0 e^{i\omega t} \frac{1 + R_{12} e^{-2d\sigma}}{1 - R_{01} R_{12} e^{-2d\sigma}} \quad (9)$$

wobei die komplexe Wellenzahl durch $\sigma = (1+i)/\mu$ beschrieben wird.

Die in der optischen Lockin-Thermografie messbare Phase lässt sich aus Gleichung (9) mit

$$\varphi = \arg(T(0, t)) \quad (10)$$

berechnen. Für unterschiedliche Materialkombinationen des thermisch dicken Trägersubstrats unter einer Kunststoffschicht sind die Phasenverläufe in Abhängigkeit der thermischen Schichtdicke (d/μ) in Bild 2 angegeben. R_{01} wird nach [18] für den Übergang Luft-Epodydharz zu 0,95 angenommen. Das Bild beschreibt dabei den analytischen Zusammenhang zwischen der thermischen Schichtdicke und dem Reflexionskoeffizienten R_{12} .

Im idealen eindimensionalen Fall lässt sich bei Betrachtung der Phase für zwei unterschiedliche Prüffrequenzen (Veränderung von μ) eindeutig die Dicke d eines Bauteils bestimmen. Dabei sollten die Prüffrequenzen so gewählt werden, dass die Messung nicht als thermisch dick gilt. Zur Auffindung von Defekten in Bauteilen kann der oben beschriebene Ansatz nur bedingt übernommen werden. Dabei wirkt ein Einschluss häufig als ein zweites Medium, wodurch die in (9) beschriebene Gleichung auf ein Zwei- oder Mehrschichtsystem erweitert werden muss. Dank der Linearität thermischer Wellen kann das thermische Wellenfeld eines Zweischichtsystems (Luft, Substrat endlicher Dicke 1, Substrat endlicher Dicke 2, thermisch dickes Substrat 3) nach [17] wie in (11) angegeben beschrieben werden.

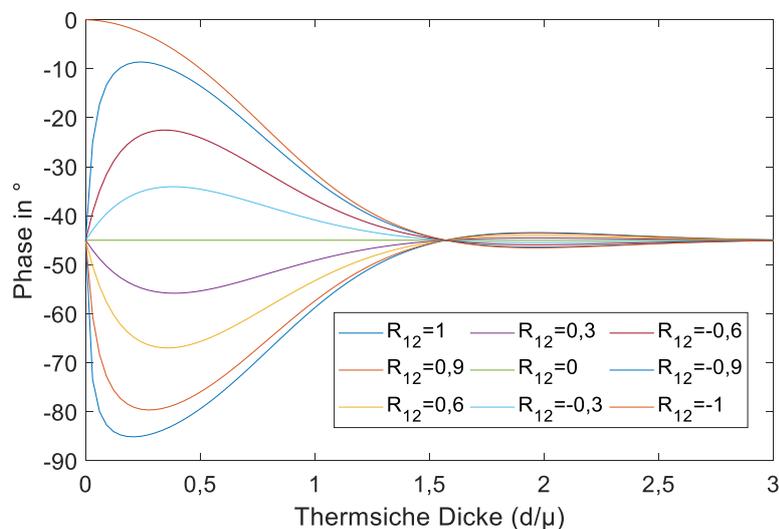


Bild 2: Analytischer Zusammenhang zwischen Phase und thermischer Dicke (d/μ)

$$T(0, t) = T_0 e^{i\omega t} \frac{Z}{N}, \quad (11)$$

mit

$$Z = 1 + R_{12} e^{-\frac{2d_1}{\mu_1}} + R_{12} R_{23} e^{-\frac{2d_2}{\mu_2}} + R_{23} e^{-\frac{2d_1}{\mu_1} - \frac{2d_2}{\mu_2}}$$

und

$$N = 1 - R_{01} R_{12} e^{-\frac{2d_1}{\mu_1}} + R_{12} R_{23} e^{-\frac{2d_2}{\mu_2}} - R_{12} R_{23} e^{-\frac{2d_1}{\mu_1} - \frac{2d_2}{\mu_2}}$$

Obwohl die Komplexität durch zusätzliche Schichten weiter zunimmt, kann auch im Falle eines (Zwei-) Mehrschichtsystems eine analytische Gleichung zur Lösung eines eindimensionalen Wärmeflussproblems gefunden werden. Wesentlich komplexer wird das Zusammenspiel der Wärmeleitung, sobald eine dreidimensionale Lösung gefunden werden muss. Während die Ausbreitung einer thermischen Welle im dreidimensionalen Fall noch beschrieben und simuliert werden kann, kann aus der zeitlichen Veränderung der Oberflächentemperatur nicht trivial auf die Geometrie eines Prüfkörpers oder Defekts durch Invertierung der Gleichungen geschlossen werden. Burgholzer et al. [6, 7] haben dazu den Ansatz der virtuellen Wellen entwickelt, bei dem die Lösung eines schlechtgestellten inversen Problems gefunden werden muss.

Eine andere Möglichkeit zur dreidimensionalen Charakterisierung innerer Geometrien stellt die Interpretation der Phasenwerte durch ein neuronales Netz dar und wird nachfolgend näher beschrieben.

3 GRUNDLAGEN ZU NEURONALEN NETZEN

Neuronale Netze werden, wie weiter oben beschrieben, mittlerweile in vielen unterschiedlichen Bereichen des alltäglichen Lebens eingesetzt und sind für viele von uns nicht mehr wegzudenken. Innerhalb des NN entsteht durch eine Kombination verschiedener, jeweils für sich genommen trivialer mathematischer Operationen eine komplexe Funktionsgleichung, die in der Lage ist, Zusammenhänge in einem Datensatz zu erkennen und andere unbekannte Datensätze darauf zu überprüfen. Dies geschieht, indem die in den mathematischen Operationen befindlichen Gewichte sukzessive angepasst werden, um eine möglichst gute Übereinstimmung für einen Trainings- und Validierungsdatensatz zu erhalten. Dabei werden die trainierbaren Gewichte eines Modells nach einigen Überprüfungsdurchläufen bei Abweichung von der Vorgabe um einen kleinen Betrag modifiziert, sodass die nachfolgenden Überprüfungsdurchläufe im besten Fall eine genauere Vorhersage des Datensatzes ermöglichen. Tritt dieser Fall nicht ein, werden die Gewichte nicht übernommen, und die Gewichte werden um einen anderen Betrag modifiziert. Erst sobald eine Verbesserung durch Anpassung der Gewichte erzielt wurde, wird vom neuen Standpunkt aus weitergesucht. Dabei gilt es, für das NN ein mehrdimensionales Optimierungsproblem zu lösen und bestmöglich das globale Minimum zu finden, ohne in einem lokalen Minimum „steckenzubleiben“. Je mehr trainierbare Gewichte innerhalb des NN zur Verfügung stehen, desto komplexere Zusammenhänge können innerhalb eines Datensatzes aufgefunden werden. Jedoch besteht dabei die Gefahr der Überanpassung (engl. Overfitting). Hier werden nicht mehr die Zusammenhänge zwischen den Daten im Datensatz gelernt, sondern die Daten selbst werden antrainiert. Ein überangepasstes Netz liefert gute Trainingsresultate innerhalb des Trainingsdatensatzes (und innerhalb des Validierungsdatensatzes), für ihm unbekannte Datensätze hingegen sind keine guten Vorhersagen zu erwarten.

Im vorliegenden Fall wird ein rekurrentes neuronales Netz (RNN) eingesetzt. Dieses hat im Gegensatz zu klassischen NN auch rückwärtsgerichtete Verbindungen. Diese Eigenschaft macht RNN vor allem für sequenzielle Daten wie Textverarbeitung oder Zeit-Sequenzen sehr hilfreich [19]. Ein wesentliches Problem im Optimierungsprozess von RNN ist das sogenannte exploding oder vanishing gradient problem, bei dem häufig die Gewichtsanzpassung der rückgeführten Fehler bei jedem Zeitschritt entweder größer oder kleiner wird und sich über sehr viele Zeitschritte (zum Beispiel bei Zeit-Sequenzen) aufschaukeln oder auslöschen. Dabei übersteuert oder untersteuert die Gewichtsanzpassung häufig. Die hier eingesetzten LSTM-Einheiten (Long short-term memory, dt. langes Kurzzeitgedächtnis) verhindern solch ein Problem, indem sie Gates (dt. Tore) verwenden, welche darüber entscheiden, ob Informationen gespeichert (forget gate), aktualisiert (input gate) oder ausgegeben (output gate) werden [20].

Ähnlich wie bei RNN wird ein Status (state) mit den Ausgaben der vorherigen Zeitschritte verknüpft. Durch die Gates wird allerdings geregelt, welche Information Einfluss auf den Status hat und welche nicht. Das Input Gate entscheidet hierbei, ob die Ausgabe des letzten Zeitschrittes (also die jetzige Eingabe) auf den Speicherstatus akkumuliert oder verworfen wird. So sammelt der Zellstatus Informationen über vergangene Zeitsequenzen. Durch eine zusätzliche selbstverknüpfte Schleife wird durch das Forget Gate entschieden, ob Informationen verworfen werden oder nicht. Zusätzlich ist es durch das Output Gate möglich, die Ausgabe der LSTM-Zelle partiell oder komplett zu verwehren [19]. LSTM-Zellen speichern also vergangene Informationen, um sie zu einem späteren Zeitpunkt wieder einzuführen [21].

Für das Training von NN wird der Datensatz in mindestens einen Trainingsdatensatz und Validierungsdatensatz aufgeteilt. Ziel des Trainingsprozesses ist es, die Gewichte des NN so anzupassen, dass für den Trainingsdatensatz eine bessere Vorhersage durch das NN entsteht. Im Idealfall wird ein NN solange trainiert, bis keine Verbesserungen durch den Trainingsprozess mehr erzielt werden. Dann wurde das (lokale) Minimum erreicht. Da die Daten nicht nur auf einem bekannten Datensatz funktionieren sollen, wird das NN mit dem Validierungsdatensatz überprüft. Verbessern sich auch hier die Vorhersagen bei den angepassten Gewichten, werden die Gewichte als Start für die neue Trainingsepoche oder als Ausgabe übernommen. Da auch die Auswahl des Validierungsdatensatzes einen Einfluss auf den Optimierungsprozess hat, werden NN typischerweise mit einem weiteren Datensatz, dem sogenannten Testdatensatz überprüft. Dieser überdeckt sich nicht mit den vorherigen Datensätzen und wird herangezogen um die Qualität des NN zu überprüfen.

4 DATENERZEUGUNG

In Abhängigkeit von der Netzarchitektur und der gesuchten Netzinterpretation kann die für ein NN benötigte Datenmenge stark variieren. Encoder-Decoder Netze funktionieren in der Regel schon mit einer sehr kleinen Anzahl an Trainingsdaten. Den Datensatz der ISBI cell tracking challenge mit insgesamt nur 30 Bildern mit biomedizinischen Zellen konnten Ronneberger et al. [22] mit einer Intersection of Union (IoU), also einer Überlappung zwischen der gesuchten und vorhergesagten Fläche, von 77,5 % vorhersagen. Dies stellt bereits einen guten Wert für eine semantische Segmentierung dar. Der zweitbeste bei der ISBI cell tracking challenge 2015 eingereichte Algorithmus erreichte eine IoU von 46 %. Seitdem sind große Fortschritte im Bereich der semantischen Segmentierung durch Encoder-Decoder Netze zu verzeichnen. Modelle zur Bildidentifizierung, wie die häufig verwendeten VGG [23] oder InceptionV3 [24] Netze, hingegen, werden teilweise mit mehreren Millionen Bild- bzw. Trainingsdaten trainiert und sind danach in der Lage, Bildinformationen in eine Vielzahl von Klassen zu unterteilen. Generell gilt dabei festzuhalten, je spezieller der Anwendungsfall ist, desto kleiner können die Datensätze

ausfallen und je allgemeiner und umfassender die Interpretation durch das NN ausfallen soll, desto größer sollten die Datensätze sein.

Im vorliegenden Fall wird neben Thermografie-Messungen eine Finite-Element-Methode Simulation (FEM) verwendet, um realitätsnahe Ergebnisse der Wärmeflussimulation von Flachbodenbohrungen (FBB) in isotropen Kunststoffen und in CFK zu erstellen.

4.1 Prüfkörpergeometrie und Messparameter

Zur Berücksichtigung und Rekonstruktion dreidimensionaler Wärmeflüsse werden in dieser Arbeit FBB in PMMA und CFK untersucht. In dünne plattenförmige Prüfkörper wurden dazu in mehreren Tiefen und mit mehreren Durchmessern FBB eingebracht. Die Kombinationen sind in Tabelle 1 oben aufgeführt, wobei alle möglichen angegebenen Kombinationen zwischen Tiefe und Durchmesser umgesetzt wurden. Neben den in Tabelle 1 oben aufgeführten experimentell vermessenen FBB Geometrien wurden weitere virtuelle FBB unterschiedlicher Abmaße erzeugt und einem Simulationsprogramm (s. u.) zur virtuellen Erstellung der Phasenbilder übergeben. Dabei wurden sowohl isotrope Materialien (PMMA, extrudiert und schwarz lackiert) als auch anisotrope Materialien (CFK, 8 Lagen unidirektionales Gewebe, VARI-Prozess, einseitig mit Epoxidharz versiegelt, Hersteller FACC) untersucht. Die Durchmesser sind in Tabelle 1 unten aufgeführt. Als Oberflächenverfahren wird die aktive Thermo-grafie hauptsächlich zur Erkennung oberflächennaher Defekte eingesetzt. Daher wurde die Prüfkörperdicke der experimentell vermessenen PMMA- und CFK-Platten auf 3 mm festgelegt und deckt die Dicke der meisten Anwendungsfälle von flächigen CFK-Strukturen ab. Alle FBB wurden in jeweils einen Prüfkörper je Material eingearbeitet. Die FBB im CFK-Prüfkörper wurden in einem regelmäßigem Loch- und Randabstand von 25 mm eingebracht. Im PMMA-Prüfkörper variierte der Loch- und Randabstand der FBB zwischen minimal 15 mm (bei kleinen Durchmessern) bis hin zu 25 mm (bei großen Durchmessern). Abbildungen der experimentell untersuchten Prüfkörper sind in Bild 3 aufgeführt. Nach Gleichung (4) geht hervor, dass die größte thermische Eindringtiefe μ bei der niedrigsten Anregungsfrequenz f erzielt wird. Für die kleinste untersuchte Anregungsfrequenz von 0,01 Hz beträgt die thermische Eindringtiefe μ bei PMMA 2,1 mm und bei CFK (in lateraler Richtung) 6,6 mm. Damit liegen die FBB jeweils außerhalb der thermischen Reichweite ($\sim 2\mu$) des Rands sowie anderer FBB. Die gegenseitige Beeinträchtigung des thermischen Felds an den FBB durch andere FBB beziehungsweise den Rand kann ausgeschlossen werden. Da die FBB im Experiment für CFK sowohl in der tiefsten Reihe (2,8 mm) als auch in der kleinsten Durchmesservariante (2 mm) nicht sicher detektiert werden kann, werden diese Messungen nicht in der nachfolgenden Auswertung betrachtet.

PMMA, Experiment	
FBB Tiefe in mm	0,7; 1,3; 1,8; 2,2; 2,7
FFB Durchmesser in mm	2; 4; 6; 8; 10
CFK, Experiment	
FBB Tiefe in mm	0,8; 1,4; 1,9; 2,4; 2,8
FFB Durchmesser in mm	2; 4; 6; 8; 10
PMMA, Simulation	
FBB Tiefe in mm	0,5; 0,8; 1; 1,4; 1,5; 1,9; 2; 2,4; 2,5
FFB Durchmesser in mm	2; 3; 4; 5; 6; 7; 8; 9; 10
CFK, Simulation	
FBB Tiefe in mm	0,5; 0,7; 1; 1,3; 1,5; 1,8; 2; 2,2; 2,5
FFB Durchmesser in mm	2; 3; 4; 5; 6; 7; 8; 9; 10

Tabelle 1: Tiefen- und Durchmesserkombinationen der künstlich eingebrachten Flachbodenbohrungen, Standardabweichung der Durchmesser- und Tiefeninformation für die experimentellen Daten: $\pm 0,1$ mm

Die Erstellung der virtuellen Prüfkörpergeometrie erfolgt in MATLAB, The MathWorks Inc., Natick, Massachusetts, Vereinigte Staaten, und wird über die Livelink-Schnittstelle für COMSOL an das Simulationsprogramm COMSOL Multiphysics, COMSOL AB, Stockholm, Schweden, übergeben.

Für jede FBB wird ein eigenständiges Simulationsprogramm angelegt. Dabei wird jeweils ein Block der Größe 40 mm x 40 mm und einer Dicke von 3 mm erstellt und mittig eine Bohrung definierter Tiefe und definiertem Durchmesser eingebracht, siehe Tabelle 1 unten. Für das isotrope PMMA wird eine homogene Wärmeleitfähigkeit von $\lambda_{\text{PMMA}} = 0,4 \text{ W/(m K)}$ definiert, beim CFK variiert diese nach den nachfolgend aufgeführten Vorgaben.

Beim Aufbau des CFK wird von einem symmetrischen Laminataufbau [0, 90, 0, 90]s mit insgesamt acht unidirektionalen Gelegesichten und einem Faser-Volumen-Gehalt von 60 % ausgegangen, wobei die oberste Schicht den größten Einfluss auf thermische Effekte hat. Die Schichtdicke beträgt jeweils 3/8 mm. Die Faserverteilung innerhalb der 0° bzw. 90° Schichten erfolgt unter Berücksichtigung des Faser-Volumen-Gehalts zufällig, jedoch wird aus Stabili-

tätsgründen der FEM Simulation die minimale Faser- bzw. Harzbreite zu 1 mm angenommen. Quer zur Hauptfaserrichtung innerhalb einer Schicht werden die Fasern und das Harz darin mit dem Verhältnis 60 zu 40 zufällig verteilt. Dabei wird die Wärmeleitfähigkeit einer Faser in Faserrichtung mit $\lambda_{CFK} = 7 \text{ W/(m K)}$ definiert, quer zur Faserrichtung und im Epoxidharz wird die Wärmeleitfähigkeit zu $\lambda_{Epoxy} = 0,4 \text{ W/(m K)}$ definiert. In jeder der acht Schichten orientiert sich die Hauptfaserrichtung nach dem oben dargestellten Laminataufbau neu. Damit wird ein CFK-Laminataufbau, bestehend aus einzelnen unidirektionalen Schichten, mit einfachen Mitteln in seinen thermischen Eigenschaften möglichst realitätsnah nachgebildet. Je angegebener FBB in CFK werden drei zufällige Wärmeleitfähigkeitsverteilungen erstellt und simuliert. Für das isotrope PMMA wird nur eine Simulation je FBB durchgeführt.

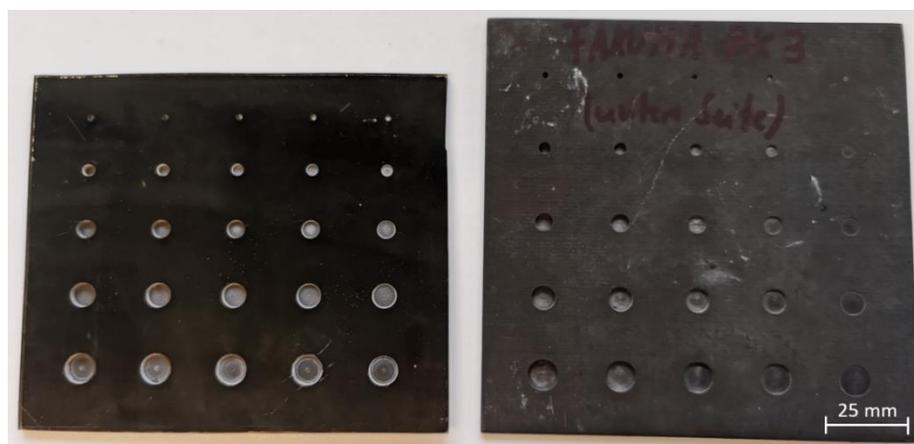


Bild 3: Abbildung der Prüfkörper mit FBB, links PMMA, rechts CFK

Die beschriebenen Prüfkörper werden sowohl experimentell als auch simulativ mit sieben unterschiedlichen Prüffrequenzen, siehe Tabelle 2, durch eine Wärmequelle (VCSEL) periodisch erwärmt. Dabei wurde im simulativen Ansatz jeweils für drei Messperioden simuliert und die letzten beiden Messperioden zur Bestimmung der Phase herangezogen. Die Phase φ wird aus der gemessenen Oberflächentemperatur $T(0, t_n)$ und der bekannten Anregungsfrequenz f_{Anr} nach Gleichung (12) und (13) ermittelt.

$$C = \sum_n T(0, t_n) (-\exp(i2\pi f_{Anr} t_n)) \quad (12)$$

$$\varphi = \text{angle}(C) \frac{360^\circ}{2\pi} \quad (13)$$

C stellt die komplexe Zahl des thermischen Wellenfelds dar, i beschreibt die imaginäre Einheit und t_n den Zeitvektor der Messung.

Für die experimentellen Messungen wurde eine unterschiedliche Anzahl an Messperioden in Abhängigkeit von der Anregungsfrequenz herangezogen. Die ersten 0,3 s einer jeden Messung werden verworfen und von dort an in Abhängigkeit der Prüffrequenz von einer bis maximal 15 Perioden, siehe Tabelle 2, nach Gleichungen (12) und (13) ausgewertet. Durch die Auswertung wird mit jeder zusätzlichen Auswerteperiode eine weitere Mittelung der Phase vorgenommen, dadurch nimmt das Messrauschen mit zunehmender Auswerteperiodenanzahl ab. Für tiefe Anregungsfrequenzen ist dies aufgrund des großen Wärmeeintrags nicht nötig. Hier erreicht man auch ohne Mittelung rauscharme Phasenbilder. Da die Simulation ohne Rauschen initialisiert wurde, genügen hier eine beziehungsweise zwei Auswerteperioden, um rauschfreie Phasenbilder zu erhalten. Zur Zeitersparnis wurde daher auf die Einbringung eines thermischen Rauschens in den Simulationen verzichtet und die Auswertung auf zwei Perioden beschränkt.

Prüffrequenz	1 Hz	0,5 Hz	0,25 Hz	0,1 Hz	0,05 Hz	0,025 Hz	0,01 Hz
Messperioden	15	12	6	3	3	3	1

Tabelle 2: Übersicht der Prüffrequenzen und Messperioden

Die in Gleichung (4) beschriebene thermische Eindringtiefe ist abhängig von der Anregungsfrequenz, und mit abnehmender Anregungsfrequenz dringen die thermischen Wellen immer tiefer in ein Bauteil ein. Für den eindimensionalen Fall der Wärmeleitung kann aus der Phase direkt die Bauteilgeometrie abgeleitet werden. Aber auch im mehrdimensionalen Fall und der Überlagerung durch diffuse Effekte können aus der Phase und Phasenveränderung bei abnehmender Anregungsfrequenz Informationen über die Bauteilgeometrie gewonnen werden. Diese durch diffuse Prozesse nicht mehr trivial decodierbaren Geometrien werden nachfolgend durch ein LSTM-CNN Modell decodiert und als Tiefen- und Durchmesserwert des Defekts ausgegeben.

4.2 Experimenteller Messaufbau und Durchführung der Messungen

Der Versuchsaufbau zur Erzeugung der experimentellen Testdaten ist in Bild 4 dargestellt. Darauf ist links die im mittelwelligen Infrarotbereich (3–5 μm) sensitive Thermografiekamera IRCAM EQUUS 327k SM PRO, ICAM, Erlangen, rechts ein VCSEL-Array, Philips Photonics, Aachen, in der Mitte der CFK-Prüfkörper sowie links oben die Photodiode PDA36A2, Thorlabs, Newton, Vereinigte Staaten, sichtbar. Zur Anregung wurden zwei von acht möglichen Kanälen des VCSEL-Array mit jeweils 200 Watt Maximalleistung verwendet. Angesteuert wird das VCSEL-Array über eine Labview Schnittstelle, die mit der Thermografiekamera über ein Triggersignal synchronisiert ist. Mit jeder der

oben beschriebenen Frequenzen wird dabei das VCSEL-Array für die angegebene Anzahl an Perioden + 0,5 Sekunden durch eine Sinusfunktion angesteuert und erwärmt dadurch die Prüfkörperoberfläche periodisch. Die Photodiode misst die emittierte Strahlung des VCSEL-Arrays und dient als zeitliche Synchronisierung zwischen Anregungsquelle und der von der Thermografiekamera gemessenen Oberflächentemperatur des Prüfkörpers, wodurch die gemessene Phasenlage (13) der Phasenlage bezogen auf das Anregungssignal (10) entspricht. Die Auswertung erfolgt nach den Gleichungen (12) und (13). Die Phasenbilder der CFK-Platte bei Anregungsfrequenzen von 0,1 Hz und 0,5 Hz sind nachfolgend abgebildet, siehe Bild 5. In den Phasenbildern sieht man die pixelweise aufgetragenen Phasenwerte (13) des gemessenen Signals der Thermografiekamera. FBB erkennt man in den Phasenbildern durch eine Veränderung (hier einer Absenkung) des Phasenwerts. Wie in Bild 3 dargestellt, befinden sich die größten FBB unten, die dünnsten Restwanddicken rechts im Phasenbild. Bei einer Anregungsfrequenz von 0,5 Hz können nur FBB in geringer Tiefe (nur die rechte Spalte) aufgefunden werden. Durch Absenken der Anregungsfrequenz auf 0,1 Hz nimmt die thermische Eindringtiefe zu, und mehr FBB (die rechten drei Spalten) können im Phasenbild erkannt werden. Die kleinste FBB von 2 mm Durchmesser kann in der dritten Spalte nicht mehr erkannt werden. Die noch als runde Defekte dargestellten FBB im Phasenbild mit 0,5 Hz Anregung, siehe Bild 5 (rechts), werden im Phasenbild mit 0,1 Hz Anregung deutlich größer und in Richtung der Hauptfaserorientierung verzerrt dargestellt. Dies ist durch den lateralen Wärmefluss zu begründen. Noch tiefere Anregungsfrequenzen dringen noch tiefer ins Bauteil ein, werden dann jedoch sehr verschwommen wahrgenommen und spiegeln die tatsächliche Defektgröße nicht mehr wider. Die Auffälligkeiten im linken oberen Eck der Messungen lassen sich auf von außen sichtbare Luftblasen in der Deckschicht des Prüfkörpers zurückführen.



Bild 4: Darstellung des experimentellen Versuchsaufbaus: Thermografiekamera (links unten), Photodiode (links oben), VCSEL Array (rechts), CFK-Prüfkörper (Mitte)

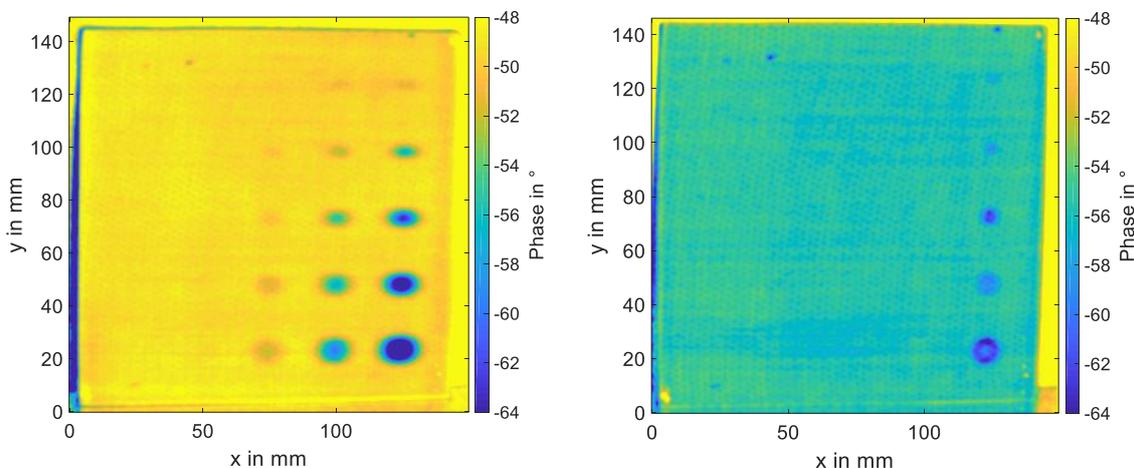


Bild 5: Phasenbilder des CFK-Prüfkörpers bei 0,1 Hz Anregungsfrequenz (links) und 0,5 Hz Anregungsfrequenz (rechts)

In Bild 6 sieht man die zwei Phasenbilder des PMMA-Prüfkörpers bei den Anregungsfrequenzen 0,05 Hz und 0,1 Hz. Wie auch in den Phasenbildern von CFK sieht man, dass die thermische Welle mit niedrigerer Anregungsfrequenz tiefer in den Prüfkörper eindringen kann und man auch tieferliegende FBB erkennen kann, siehe gelbe Kreise Bild 6 links. Im Gegensatz zum CFK-Prüfkörper sieht man bei einer Prüffrequenz von 0,1 Hz die mittlere Fehlerspalte noch nicht eindeutig, sondern erst bei der niedrigeren Prüffrequenz von 0,05 Hz. Auch im PMMA-Prüfkörper sind Oberflächenverschmutzungen vorhanden, die sich überwiegend im linken oberen Eck des Prüfkörpers sowie an der Position $x = 110$ mm, $y = 90$ mm darstellen. Aufgrund des isotropen Aufbaus werden die FBB im Phasenbild bei PMMA als kreisrunde Anzeigen dargestellt.

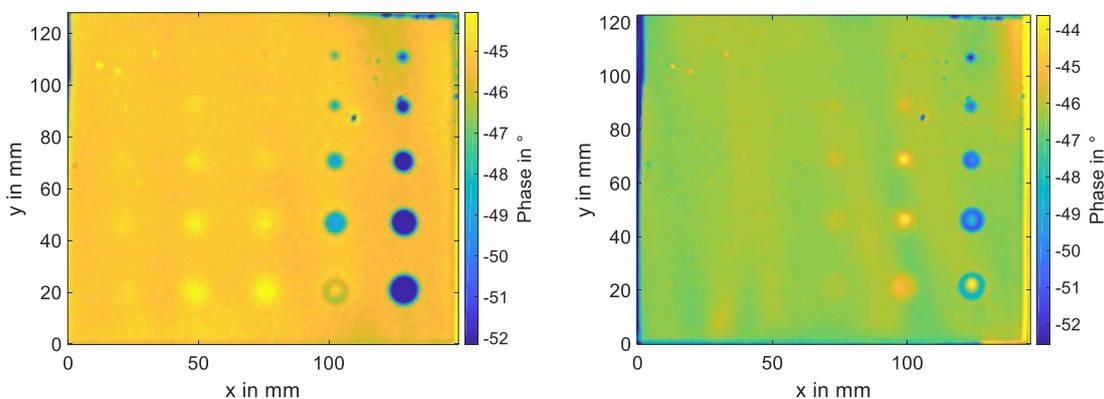


Bild 6: Phasenbilder des PMMA-Prüfkörpers bei 0,05 Hz Anregungsfrequenz (links) und 0,1 Hz Anregungsfrequenz (rechts)

4.3 Simulative Datengenerierung

Wie weiter oben beschrieben, wurden eine große Anzahl an Finite-Element-Modellen einer FBB erstellt (isotrop und anisotrop) und mit COMSOL simuliert. Die Wärmeflussimulation wird mit Lagrange-Elementen 2. Ordnung berechnet, das Netz wird mit Tetraedern mit einer Seitenlänge von etwa 0,5 mm erstellt, als Wärmequelle wird eine Sinusfunktion $I/2 + I/2 \sin(2\pi f t)$, mit der Anregungsintensität $I = 7385 \text{ W/m}^2$ des VCSEL-Arrays bei einem Meter Abstand auf der defektfreien Seite der Platte aufgebracht. An den Seiten der Platte wird eine Symmetrieebene angenommen, die gesamte Rückseite sowie die Oberfläche der FBB wird als thermisch isolierend angenommen, und die defektfreie Seite der Platte wird durch einen konvektiven Wärmefluss mit einem Wärmeübergangskoeffizient von $h = 5 \text{ W/(m}^2 \text{ K)}$ überlagert. Je Periode werden 20 gleichverteilte Zeitschritte abgespeichert, wobei die Rechenzeitschritte von COMSOL selbst gesteuert werden und kleiner, aber nicht größer ausfallen können.

Abschließend wird auch hier aus dem sich einstellenden Temperaturverlauf der Oberfläche nach Gleichungen (12) und (13) die Phase berechnet und ein Phasenbild erstellt. In Bild 7 sind simulativ ermittelte Phasenbilder von FBB aufgeführt. Die gezeigten Durchmesser- und Tiefenkombinationen entsprechen den Größen der späteren Testdatensätze. Die genauen Angaben sind der Bildunterschrift zu entnehmen. In den Phasenbildern kann die FBB jeweils als Schadensfläche in der Mitte des Bildes erkannt werden. Die horizontalen Linien in den Phasenbildern der CFK-Simulationen bilden sich aufgrund der in Kapitel 4.1 beschriebenen willkürlich erstellten Faserverteilung ein. Überlagert wird das Phasenbild durch ein numerisches Rauschen. Die eigentlich runden Defekte werden durch die Faserorientierung in CFK-Simulationen in X- und Y- Richtung verzerrt. In Simulationen mit isotropem Werkstoffverhalten werden die runden FBB auch als runde Struktur im Phasenbild wahrgenommen. Bild 8 stellt die Simulationsergebnisse und experimentellen Messergebnisse (Phasenwerte) eines 3 mm dicken PMMA Prüfkörpers gegenüber. Für Frequenzen ab 0,05 Hz und höher decken sich die Simulationsergebnisse sehr gut mit den experimentellen Messergebnissen. Abweichungen treten erst bei niedrigen Prüffrequenzen kleiner 0,05 Hz auf und sind auf die Nichtbetrachtung der Teiltransparenz innerhalb der Simulation zurückzuführen. Eine ausführliche Verifizierung zwischen Mess- und Simulationsergebnissen (Phasenwerte) sowie die Betrachtung der Teiltransparenz kann in [25] nachgeschlagen werden. Für die weiteren Untersuchungen wurde auf die simulative Betrachtung der Teiltransparenz und den damit einhergehenden stark erhöhten Rechenaufwand verzichtet.

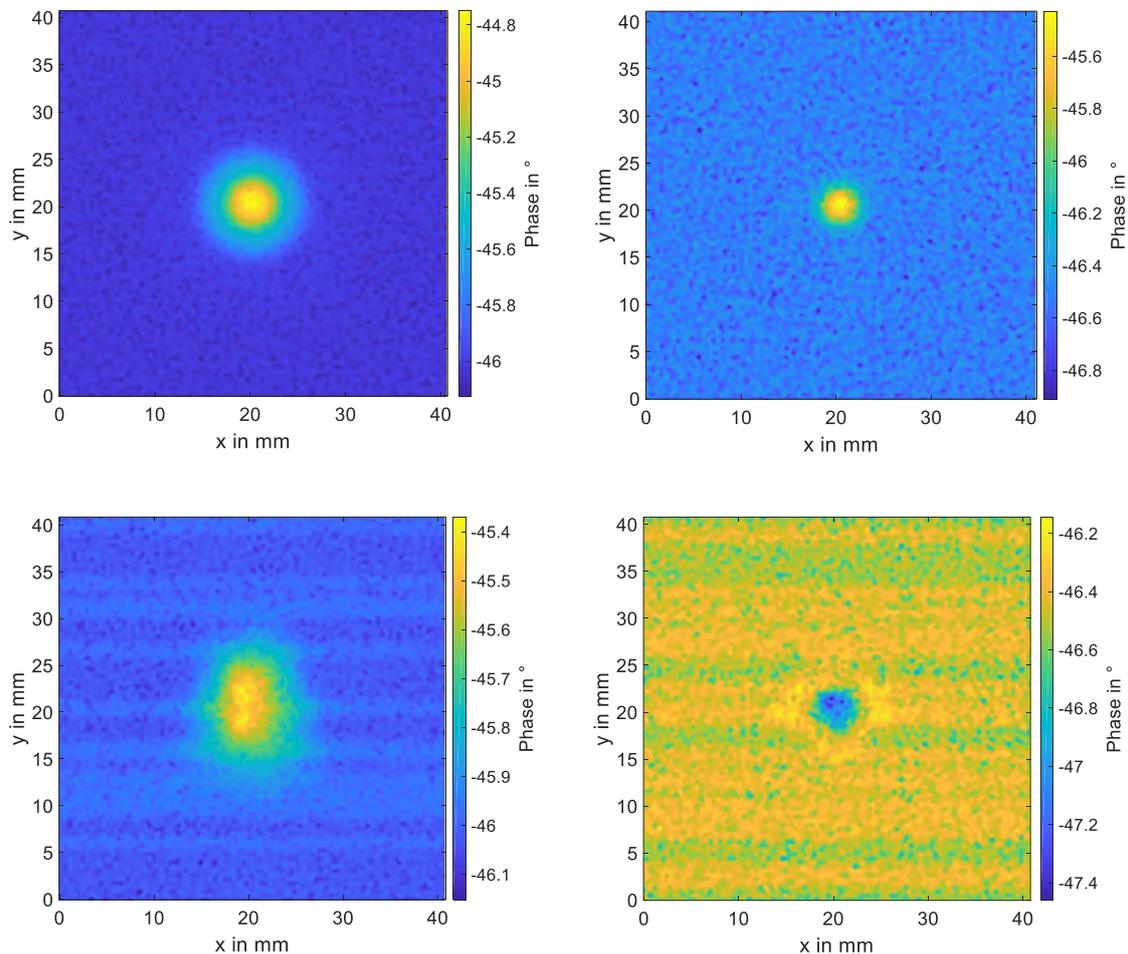


Bild 7: *Phasenbilder der Simulationsergebnisse von FFB, linksoben: PMMA, Tiefe FBB 1,8 mm, Durchmesser FBB 8 mm, Anregungsfrequenz 0,1 Hz, rechtsoben: PMMA, Tiefe FBB 1,3 mm, Durchmesser FBB 4 mm Anregungsfrequenz 0,25 Hz, linksunten: CFK, Tiefe FBB 1,9 mm, Durchmesser FBB 8 mm, Anregungsfrequenz 0,1 Hz, rechtsunten: CFK, Tiefe FBB 1,4 mm, Durchmesser FBB 4 mm, Anregungsfrequenz 0,25 Hz*

Insgesamt wurden auf diese Art 1701 Phasenbilder des anisotropen CFK und 567 Phasenbilder von FBB in PMMA erstellt. Die Simulationsdauer inkl. Erstellung des Phasenbilds auf der eingesetzten Desktop CPU (AMD Ryzen 9 5900X) betrug je FBB zwischen 100 s und 160 s. Dadurch ergab sich eine Gesamtsimulationszeit von etwas über vier Tagen.

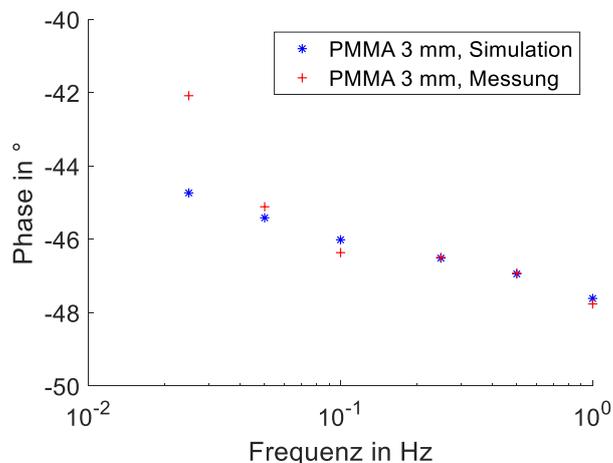


Bild 8: Verifizierung der Simulationsergebnisse (Phasenwerte) an einem 3 mm dicken PMMA Prüfkörper

4.4 Aufbereitung der Mess- und Simulationsdaten

Zur nachfolgenden Untersuchung wurden aus den erstellten Phasenbildern Linienschnitte durch die FBB extrahiert. Dabei dient jeweils der Kreismittelpunkt der FBB als Rotationsmittelpunkt. Über die jeweils sieben Prüffrequenzen und ihre zugehörigen Phasenbilder werden durch jede FBB sowohl bei den Simulationsergebnissen als auch bei den Messergebnissen 360 unterschiedliche Linienschnitte mit einer jeweiligen Länge von 22 mm gelegt. Dabei wird die Schnittlinie jeweils um ein zusätzliches Grad weitergedreht, bis 360 unterschiedliche Linienschnitte je FFB erstellt sind. Zur Erstellung der Linienschnitte wird innerhalb des Phasenbilds bilinear interpoliert. Aus einer FBB werden somit 360 Tupel mit je 7 Linienschnitte der Phasenverläufe extrahiert. Die 22 mm Länge der Schnittlinien wird dabei für alle Messungen auf 135 Pixel skaliert. Exemplarisch sind in Bild 9 Phasenverläufe der Labormessungen dargestellt. Die unteren zwei Phasenverläufe sowie die jeweils 359 weiteren entsprechenden Phasenverläufe gleicher Tiefen/Durchmesserkombination werden nachfolgend nicht zum Training oder zur Validierung verwendet und stellen den Testdatensatz dar. Ziel des NN ist es, den Durchmesser und die Tiefe der Daten im unbekanntem Testdatensatz möglichst genau vorherzusagen. Ähnlich den oben dargestellten Phasenbildern sind die Abweichungen von einem homogenen Phasenverlauf bei tiefen Anregungsfrequenzen größer und über mehr Pixel (über eine längere laterale Strecke) zu detektieren. FBB werden bei tiefen Anregungsfrequenzen größer wahrgenommen als bei hohen Anregungsfrequenzen. Mit sinkender Anregungsfrequenz nimmt auch die Sichtbarkeit der CFK-Faserstruktur im Phasenverlauf ab, bis sie bei 0,01 Hz nicht mehr detektiert werden kann. Bild 10 stellt die entsprechenden Linienschnitte der FEM-Simulationen dar. Obwohl sowohl die Messungen als auch die Simulationen denselben Effekten

unterliegen, sind hier große Unterschiede zu erkennen. Hier folgt die Simulation der Theorie und strebt bei thermisch dicken Bauteilen (alle Stellen außerhalb der FBB) gegen eine Phase von -45° . Im Gegensatz zu den realen Messungen wurde hier die IR-Teiltransparenz von Kunststoffen und CFK nicht berücksichtigt. Es wird erwartet, dass unter Berücksichtigung der Teiltransparenz Phasenverläufe ermittelt werden könnten, die sich mit dem Experiment decken.

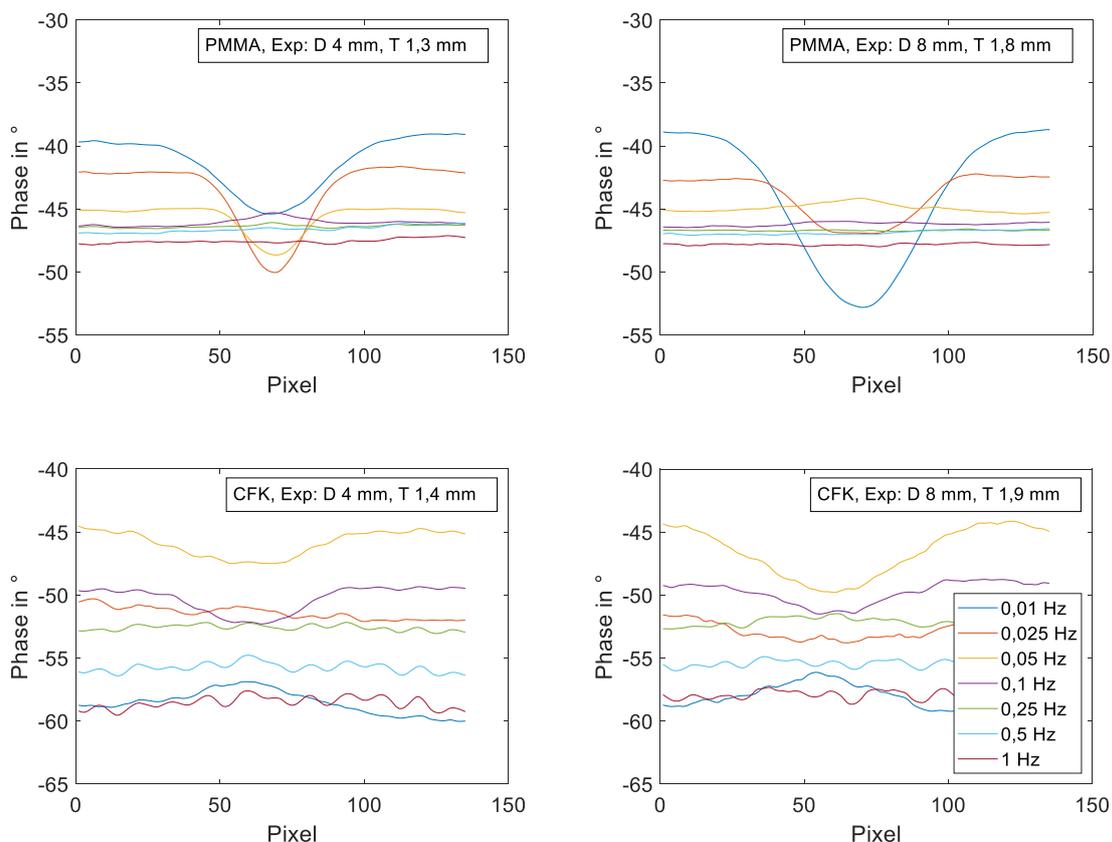


Bild 9: Experimentell ermittelte Phasenverläufe der FBB in PMMA (oben) und CFK (unten).

Abschließend werden die Phasenverläufe in einem 3D-Array mit dem Format (Anzahl an Messungen, Länge des Linienschnitts, Anzahl an Prüffrequenzen) abgespeichert. Die dazugehörige Ausgabeseite wird in einem 2D-Array mit dem Format (Anzahl an Messungen, FBB Informationen) abgespeichert. Die FBB Informationen unterteilen sich in je eine Datenspalte mit der jeweiligen Tiefe und eine Datenspalte mit dem jeweiligen Durchmesser der FBB.

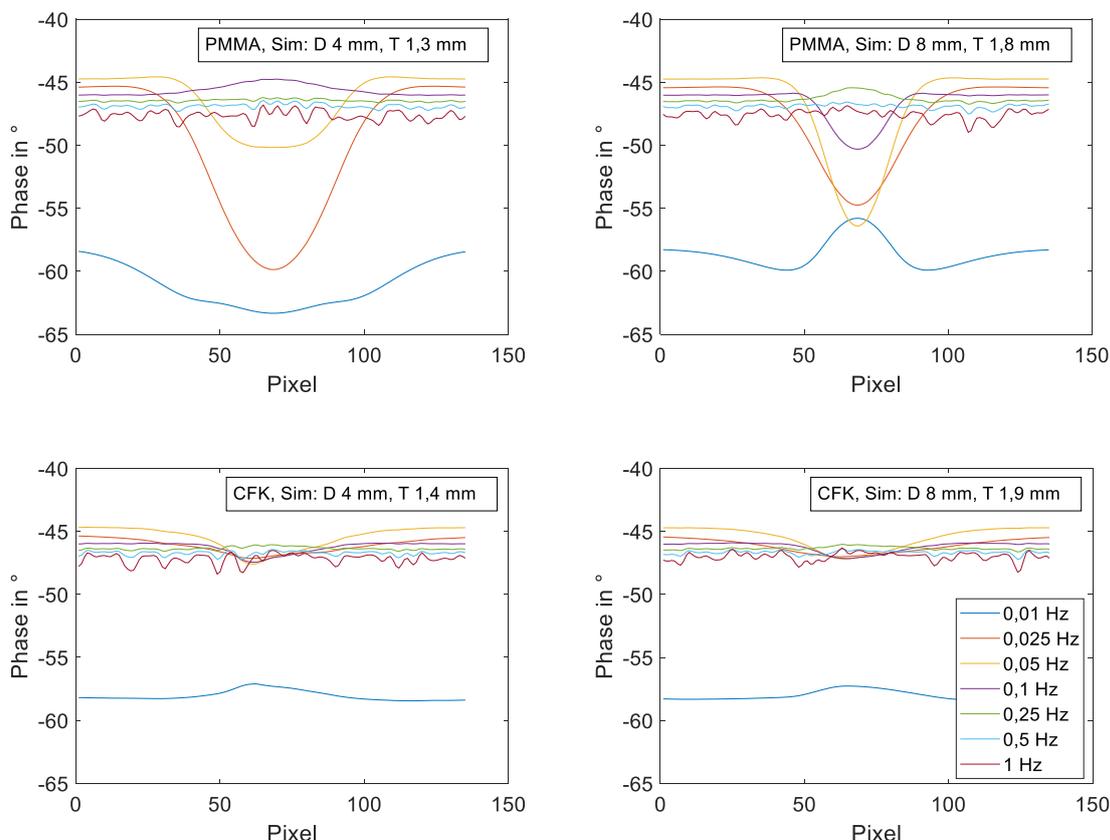


Bild 10: Simulierte Phasenverläufe der FBB in PMMA (oben) und CFK (unten).

5 AUFBAU UND TRAINING DES NEURONALEN NETZES

Zur Bewertung der zusammengehörigen Phasenverläufe wird, wie weiter oben beschrieben, ein NN basierend auf einer LSTM-Schicht und zwei eindimensionalen CNN-Schichten eingesetzt. Der schematische Aufbau des NN ist in Bild 11 dargestellt. Die 135 Pixel x 7 Frequenzen große Phasensequenz wird an die LSTM-Schicht mit 128 LSTM-Einheiten übergeben. Auf die LSTM-Schicht folgen eine eindimensionale Faltungsschicht mit 64 Filtern und einer Filtergröße von 27 Elementen, eine Max-Pooling Schicht, eine erneute Faltungsschicht mit 64 Filtern und einer Filtergröße von 18 Elementen, eine erneute Max-pooling Schicht sowie letztlich zwei vollverknüpfte Schichten mit zuerst 128 Elementen und zuletzt zwei Ausgabewerten. Zwischen den CNN-Schichten und den vollverknüpften Schichten (Dense-Layer) wird das vorliegende Array noch eingeebnet (Flatten-Layer). Die Max-Pooling Schichten mit einer Filtergröße von zwei übergeben jeweils den maximalen Wert von zwei benachbarten Werten und können so die Anzahl an trainierbaren Parametern eines Netzes effizient reduzieren, ohne wesentliche Trainingsinformationen zu

verlieren. Insgesamt stehen dem Netz dadurch etwas mehr als eine halbe Million Parameter zum Training zur Verfügung. Die Implementierung des NN erfolgte in Python mithilfe der Tensorflow 2.6 API.

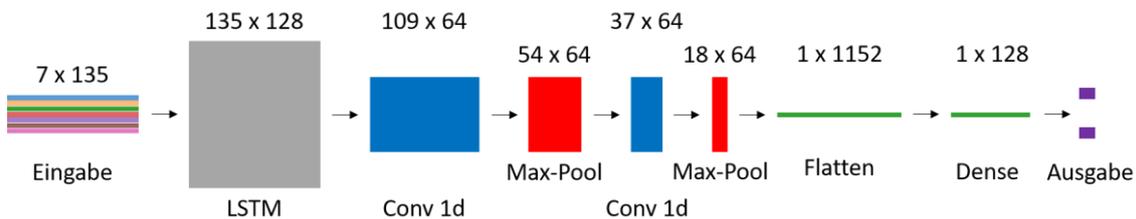


Bild 11: Schemaskizze des Datenflusses durch das LSTM-CNN

Die in Kapitel 4.4 beschriebenen sieben Phasenverlauf-Linienschnitte (jeweils ein Linienschnitt pro Anregungsfrequenz) pro FBB werden wie nachfolgend beschrieben in unterschiedlichen Kombinationen zu Datensätzen miteinander zusammengefasst. Die Mess- und Simulationsdaten der isotropen und anisotropen Prüfkörper werden nachfolgend nicht miteinander kombiniert, sondern jeweils parallel zueinander untersucht.

Der erste Datensatz D_{Iso1} beinhaltet nur Messdaten der FBB in PMMA und wird nur für die Interpretation von Messdaten verwendet. Entsprechend beinhaltet der Datensatz D_{Aniso1} nur Messdaten der FBB in CFK und wird für die Interpretation von Messdaten von FBB in CFK verwendet. Die zum Test vorherzusagenden Durchmesser- und Tiefenkombinationen von FBB werden wie weiter oben beschrieben nicht fürs Training oder zur Validierung herangezogen.

Der jeweilige Datensatz D_{Iso2} und D_{Aniso2} besteht nur aus Simulationsdaten und wird zur Vorhersage von Durchmessern und Tiefen von FBB aus Simulationen herangezogen.

Der jeweilige Datensatz D_{Iso2-1} und $D_{Aniso2-1}$ besteht aus Simulationsdaten für Training und Validierung, zum Test des NN werden jedoch die Testdaten aus den Datensätzen 1 verwendet.

Abschließend wird jeweils ein Hybriddatensatz aufgebaut, der sowohl Mess- als auch Simulationsdaten zum Training und zur Validierung verwendet. Interpretiert werden wiederum die Testdaten aus den Datensätzen 1. Die Datensätze werden nachfolgend $D_{Iso12-1}$ und $D_{Aniso12-1}$ genannt.

Die Validierungsdatsätze aller oben beschriebenen Datensätze sind jeweils unabhängig zum Trainingsdatensatz. Das heißt, die dort betrachteten Tiefen/Durchmesserkombinationen sind nicht im Trainingsdatensatz enthalten. Eine Ausnahme stellt der letztgenannte Hybriddatensatz dar. Hier gibt es Überlappungen in den Tiefen/Durchmesserkombinationen, jedoch sind jeweils alle Linienschnitte einer FBB entweder im Trainings- oder Validierungsdatsatz enthalten. Dabei wird eine Größenverteilung von etwa

80 % Trainingsdaten zu 20 % Validierungsdaten angestrebt. Für den Testdatensatz werden mit 4 mm Durchmesser / 1,3 mm Tiefe und 8 mm Durchmesser / 1,8 mm Tiefe für PMMA sowie 4 mm Durchmesser / 1,4 mm Tiefe und 8 mm Durchmesser / 1,9 mm Tiefe für CFK jeweils zwei unabhängige FBB Kombinationen betrachtet. Andere Kombinationen als Testdatensatz wurden untersucht und verhalten sich ähnlich.

Für eine Gleitkommazahlvorhersage gibt es in Tensorflow unterschiedlichste Möglichkeiten. Nachfolgend wird als Loss-Funktion, also das zu optimierende Bewertungskriterium des NN, die sogenannte mittlere absolute Fehler- (engl. mean absolute error, MAE) Funktion verwendet. MAE berechnet sich über alle Ausgabeparameter n (hier die Tiefe und der Durchmesser) mit den Ausgabewerten \hat{y} des NN und den tatsächlichen Werten y und wird wie nachfolgend angegeben ermittelt.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (14)$$

Da die Abweichungen der Eingangsparameter linear kombiniert und verrechnet werden, werden die Durchmesser um eine Größenordnung reduziert (aus 2 mm – 10 mm werden 0,2 – 1 als Vorhersagewert) und die Tiefen in ihrer vorgegebenen Tiefe in mm betrachtet. Durch diesen Aufbau der Vorhersagewerte wird die Tiefenlage linear gewichtet, der Durchmesser der FBB jedoch nur mit einem Faktor 0,1. Dadurch wird die in der Praxis durch den/die Prüfer*in schwerer zu interpretierende Tiefe der FBB überproportional im Trainingsprozess berücksichtigt.

Obwohl LSTM in der Regel mit kleinen Batch-Sizes, also derjenigen Anzahl an Datensätzen, die in einem Durchlauf betrachtet werden, bessere Ergebnisse erzielen, wird mit 2048 eine für NN große Batch-Size als optimal für die Datensätze gewählt. Für kleinere Batch-Sizes konvergierte das NN deutlich später und mit geringerer Genauigkeit. Es wird vermutet, dass dies durch die hohe Anzahl an ähnlichen Mess-/ bzw. Simulationsdaten, bedingt durch die Datenerzeugung (360 Linienschnitte je FBB), hervorgerufen wird. Häufig stellt auch der zur Verfügung stehende Grafikspeicher eine Limitierung der Batch-Size dar. Mit der verwendeten Nvidia RTX 3080 Ti mit 12 GB Grafikspeicher und dem kleinen Datensatz (135 x 7 Datenpunkte) konnten solch hohe Batch-Sizes erzielt werden. Noch größere Batch-Sizes verschlechterten jedoch, wie bei LSTMs zu erwarten, die Genauigkeit des NN. Zum konsistenten Vergleich der Vorhersagewerte wurde auch bei kleinen Trainingsdatensätzen die Batch-Size wie angegeben gewählt.

5.1 Interpretation des NN

Die Umsetzung des NN erfolgt in Tensorflow 2.6. Adam, ein stochastisches Gradientenabstiegsverfahren zur adaptiven Schätzung von Momenten erster und zweiter Ordnung, wird als Optimierer des NN mit einer Learning Rate von 0,001 eingesetzt. Das NN wird für jeweils 100 Epochen trainiert, und die besten Trainingsgewichte werden zur Beurteilung des Testdatensatzes übernommen. Ein Abbruchkriterium für den Trainingsprozess wird nicht verwendet, da das oben beschriebene NN für die vorliegenden Datensätze nur wenige Sekunden pro Epoche benötigt.

Durch den unabhängigen Aufbau von Trainings-, Validierungs- und Testdatensatz kann eine Überanpassung des NN verhindert werden. Das lässt sich aus Bild 12 entnehmen. Darin sind exemplarisch zu den Datensätzen D_{Aniso1} und $D_{\text{Aniso12-1}}$ die Trainings- und Validierungs-MAE über alle 100 Epochen aufgeführt. Die MAE-Kurven der anderen untersuchten Datensätze werden nicht dargestellt, verhalten sich ähnlich. Der Validierungs-MAE folgt dem Trainings-MAE und strebt innerhalb der 100 untersuchten Epochen gegen ein Minimum, erreicht dies jedoch in Einzelfällen noch nicht. Die unabhängig voneinander aufgebauten Datensätze konvergieren für eine hohe Epochenanzahl zueinander. Der im Mittel über den Trainings- und Validierungsdatensatz bestimmte minimale MAE ist in Tabelle 3 angegeben. Man sieht darin, dass die Trainings- und Validierungs-MAE für alle acht Datensätze gute Vorhersagen für bekannte Daten ermöglicht. Der größte mittlere Fehler wurde dabei für den Datensatz D_{Aniso1} erzielt. Wie man aus Bild 12 links abschätzen kann, sind die MAE-Werte voraussichtlich noch nicht gegen ein Minimum konvergiert und könnten sich nach weiteren Trainingsepochen weiter verringern. Durch Beschreibung der nach-folgenden Extremwerte kann die Bedeutung der Trainings- und Validierungs-MAE in tatsächliche Vorhersagewerte transferiert werden. Betrachtet man eine exakte Vorhersage des gesuchten Durchmessers, würde der maximale Validierungs-MAE aller Datensätze von 0,06 eine maximale Abweichung der mittleren Tiefe $2 \cdot \text{MAE} = 0,12$ mm entsprechen. Durch den weiter oben beschriebenen Skalierungsfaktor würde sich bei exakter Vorhersage der Tiefe eine maximale Abweichung des mittleren Durchmessers zu $20 \cdot \text{MAE} = 1,2$ mm ergeben. Da in der Regel sowohl bei der Tiefe als auch bei dem Durchmesser Abweichungen in der Vorhersage auftreten, stellt sich eine Linearkombination der genannten Abweichungen für die maximale mittlere Abweichung ein.

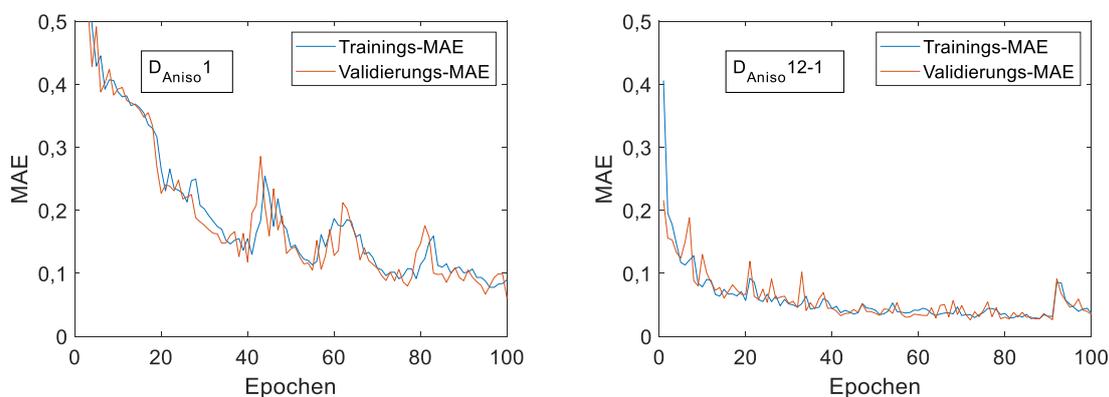


Bild 12: Trainings- und Validierungs-MAE über 100 Epochen für Datensatz $D_{Aniso 1}$ (links) und $D_{Aniso 12-1}$ (rechts)

	PMMA		CFK	
	Train_MAE	Val_MAE	Train_MAE	Val_MAE
D1	0,0621	0,0423	0,0898	0,0600
D2	0,0336	0,0181	0,0255	0,0240
D2-1	0,0336	0,0181	0,0255	0,0240
D12-1	0,0287	0,0206	0,0342	0,0260

Tabelle 3: Übersicht der Loss-Funktionen für Training und Validierung aller Datensätze

In Tabelle 4 sind die Test-MAE-Werte für den jeweiligen Datensatz angegeben. Wie zu erwarten war, sind die Test-MAE-Werte größer als die in Tabelle 3 für Training und Validierung angegebenen MAE-Werte. Das ist für NN üblich und wird durch einen sehr kleinen Testdatensatz begünstigt. Auch bei den kleinen Validierungsdatensätzen liegen die minimalen Validierungs-MAE unterhalb der Trainings-MAE, da darin bewusst mehr FBB und vor allem schwerer vorherzusagende FBB (sehr tiefe und / oder sehr kleine FBB) enthalten sind. Eine Besonderheit stellen die Datensätze D2-1 dar. Hierin wurde mit Simulationsdaten trainiert und validiert, jedoch mit Messdaten getestet. Während die Trainings- und Validierungs-MAE noch vielversprechend aussahen (identisch zu Datensatz D2), spiegeln die Vorhersagen am Testdatensatz nicht mehr die Realität wider. Um dies zu verwirklichen, müssten durch die Simulation die realen Messbedingungen identisch nachgebildet

werden. Die beste Vorhersage der Testdaten erzielte jeweils der Datensatz D2. Nach Training und Validierung erfolgte hier auch der Testdurchlauf an simulierten Phasenverläufen. Dies stellt eindrücklich dar, dass NN bei guter Regularisierung zur Umkehrung von Wärmeflussimulationen eingesetzt werden können. Aber auch schon bei nur 20 (für CFK) oder 25 (für PMMA) FBB kann ein NN eingesetzt werden, um aus Messdaten in einem einfach aufgebauten Anwendungsfall die Tiefe und den Durchmesser der FBB gut abschätzen zu können, siehe Datensätze D1. Kombiniert man, wie in Datensatz D12-1, die wenigen Messdaten mit den Simulationsdaten, nimmt die MAE der Testdaten im Vergleich zu den Datensätzen D1 deutlich ab. Anstatt einem mittleren D1-MAE = 0,1026 ergibt sich der optimierte mittlere MAE durch den größeren Trainings- und Validierungsdatensatz nun zu D12-1-MAE = 0,04054. Dies stellt eine Verbesserung des mittleren MAE auf die Messdatensätze D1 von 60,5 % dar.

	PMMA-Test-MAE		CFK-Test-MAE	
	4 mm / 1,3 mm	8 mm / 1,8 mm	4 mm / 1,4 mm	8 mm / 1,9 mm
D1	0,0988	0,0556	0,1170	0,1390
D2	0,0470	0,0519	0,0028	0,0171
D2-1	0,1520	0,3260	0,0999	0,3736
D12-1	0,0648	0,03785	0,0142	0,0453

Tabelle 4: Übersicht der Loss-Funktionen für die einzelnen FBB des Testdatensatz

In Tabelle 5 sind die mittleren vorhergesagten Durchmesser- und Tiefenangaben für die Testdatensätze angegeben. Die jeweils zwei untersuchten FBB je Material werden darin getrennt in Tiefen- und Durchmesser vorhersage angegeben. Auch hierin wird deutlich, dass die Vorhersage von Messdaten durch ein mit Simulationsdaten trainiertes NN nicht geeignet ist und große Abweichungen in der Größenvorhersage der FBB aufzeigt. Alle anderen Datensätze geben Vorhersagen mit nur geringen Abweichungen zur Zielgröße für den Testdatensatz aus. Die größte mittlere Abweichung stellt dabei der Datensatz D_{Aniso1} mit 1,08 mm Abweichung für die Interpretation des Durchmessers dar. Die größte mittlere Abweichung in der Tiefenvorhersage wurde im selben Datensatz D_{Aniso1} mit 0,21 mm aufgefunden.

Wie in Kapitel 5 beschrieben, wird durch die Anpassung der Durchmesser-
vorhersage eine Veränderung der Tiefeninformation stärker gewichtet.
Besonders durch die Datensätze D12-1, bei denen viele Trainings- und Vali-
dierungsdaten zur Verfügung stehen, kommt dieses Merkmal zu tragen.
Während der mittlere MAE bei PMMA für den Durchmesser von $D1_{\text{Iso}}\text{-MAE}_{\text{Durchmesser}} = 0,0275$ um 23 % auf $D12\text{-}1_{\text{Iso}}\text{-MAE}_{\text{Durchmesser}} = 0,0339$ zunahm,
sank der mittlere $D1_{\text{Iso}}\text{-MAE}_{\text{Tiefe}} = 0,1268$ durch den Hybridansatz um 46 % auf
 $D12\text{-}1_{\text{Iso}}\text{-MAE}_{\text{Tiefe}} = 0,0688$. Beim anisotropen CFK nahmen sowohl der mittlere
MAE des Durchmessers vom Ursprungswert $D1_{\text{Aniso}}\text{-MAE}_{\text{Durchmesser}} = 0,0864$ um
53 % auf $D12\text{-}1_{\text{Aniso}}\text{-MAE}_{\text{Durchmesser}} = 0,0401$, als auch der mittlere MAE der Tiefe
von $D1_{\text{Aniso}}\text{-MAE}_{\text{Tiefe}} = 0,170$ um 89 % auf $D12\text{-}1_{\text{Aniso}}\text{-MAE}_{\text{Tiefe}} = 0,0194$
signifikant ab. In beiden Fällen kann durch Einsatz des Hybridmodells die
Vorhersage des NN deutlich verbessert werden. Dabei wird besonders die
durch die Berechnung der MAE höhergewichtete Tiefeninformation gezielt
verbessert, siehe Gleichung (14).

	PMMA-FBB-Geometrie in Durchmesser mm / Tiefe mm		CFK-FBB-Geometrie in Durchmesser mm / Tiefe mm	
	4 / 1,3	8 / 1,8	4 / 1,4	8 / 1,9
D1	3,45 / 1,16	7,99 / 1,69	5,08 / 1,52	8,64 / 1,69
D2	4,23 / 1,23	7,52 / 1,74	4,0 / 1,41	8,17 / 1,88
D2-1	2,52 / 1,14	2,19 / 1,73	3,23 / 1,28	5,54 / 1,40
D12-1	4,02 / 1,17	7,33 / 1,79	4,17 / 1,39	8,63 / 1,87

*Tabelle 5: Übersicht der mittleren vorhergesagten FBB Größe aller
Testdatensätze*

6 FAZIT UND AUSBLICK

An einer bereits bekannten Schadensstelle lassen sich, wie aufgezeigt, neuronale Netze sehr gut dazu einsetzen, um aus (bestehenden) Datensätzen zusätzliche Informationen über das Schadensbild zu erlangen. Dabei grenzen sich die Erkenntnisse der Arbeit vom Stand der Forschung ab, indem nicht die Position eines Defekts durch eine semantische Segmentierung [22] aufgezeigt wird, sondern die bereits bekannte Position hinsichtlich im Vorfeld definierter Defektmerkmale charakterisiert wird. Dies ist als nachgelagerter Prozess angedacht und könnte als Ergänzung zu einer semantischen Segmentierung in einer vollautomatisierten Prüfung erfolgen. Dabei werden LSTM-Einheiten [20] eingesetzt, die aus einer Phasenverlaufssequenz zusätzliche Merkmale eines Defekts extrahieren, die der Anwender nicht offensichtlich aus dem Datensatz extrahieren kann. Damit stellt das NN eine völlig neue Betrachtungsweise von Phasenbildern dar. Die im Rahmen der Arbeit untersuchten Größenangaben von Flachbodenbohrungen in PMMA und CFK können durch das, für NN kleine, LSTM-CNN-Hybridmodell mit etwa einer halben Million trainierbaren Gewichten und kleinem Trainingsdatensatz von nur 20 (CFK) beziehungsweise 25 (PMMA) FBB mit nur geringer Abweichung vorhergesagt werden. Die gezielte Unterstützung durch virtuelle Messdaten, welche mittels Wärmeflussimulationen in FEM erstellt wurden, verbessern die Genauigkeit der Defektcharakterisierung nochmals deutlich. So konnten die bereits sehr guten Vorhersagewerte einer mittleren Fehlerabweichung von $D1\text{-MAE} = 0,1026$ im hybriden Ansatz durch Betrachtung von Simulations- und Messdaten für das Training des NN um 60,5 % auf $D12\text{-1-MAE} = 0,0410$ verbessert werden. Oder, in konkreten Zahlenwerten ausgedrückt, konnten Flachbodenbohrungen im PMMA-Testdatensatz mit einer maximalen Abweichung im Durchmesser von 0,66 mm (8 %) und einer maximalen Abweichung in der Tiefenlage von 0,13 mm (10 %) in ihren Dimensionen vorhergesagt werden. Für den CFK-Testdatensatz konnten mit einer maximalen Abweichung im Durchmesser von 0,63 mm (8 %) und einer maximalen Abweichung in der Tiefenlage von 0,03 mm (2 %) noch bessere Vorhersagen für einen dem Netz unbekanntem Datensatz erzielt werden. Einen großen Einfluss auf die Vorhersagequalität des NN hat dabei die Loss-Funktion und deren Aufbau. Die hier verwendete mean absolute error (MAE) Funktion betrachtet gleichverteilt alle Vorhersagewerte und kombiniert diese linear. Um einen höheren Fokus auf die schwieriger zu interpretierende Tiefeninformation zu legen, wurde der Durchmesser mit dem Faktor 0,1 skaliert. Daher wurden Abweichungen in der Tiefe höher bewertet, und so konnte letztlich durch das Hybridmodell sowohl bei PMMA als auch bei CFK eine Verbesserung des spezifischen MAE-Werts für die Tiefenvorhersage um 46 % sowie 89 % verbessert werden. Hier gilt es, für zukünftige Arbeiten einen optimierten Gewichtungsfaktor zu finden, um sowohl die Tiefe als auch den Durchmesser bestmöglich vorherzusagen zu können.

Durch das Training mit Datensatz D2 bzw. D2-1 haben zwei Erkenntnisse besonders herausgeragt. Zum einen lassen sich diffuse Wärmeleitungsprozesse durch neuronale Netze sehr gut invertieren, was ein riesiges Potential für zukünftige Forschungsarbeiten bietet. Zum anderen sind simulationsbasierte Trainingsdaten nicht in der Lage, reale Messdaten vorherzusagen - zumindest nicht, wenn die Simulationsdaten schnell in großer Anzahl erstellt werden sollten. Erst durch Berücksichtigung der wesentlichen Einflussfaktoren einer Simulation der Lockin-Thermografie an Kunststoffen (Teiltransparenz, Inhomogenitäten der Oberfläche, thermisches Rauschen der Kamera, Inhomogenitäten der Anregungsquelle, Anisotropie...) werden Simulationsdaten in der Lage sein, als alleiniger Trainingsdatensatz für reale Messungen zu dienen. Für Wärmeflussimulationen ist dies nicht unmöglich, müsste jedoch mit deutlich zeitaufwändigeren Simulationszeiten aufgewogen werden. Ob der Anwendungsfall dies notwendig macht oder ob der Einsatz eines wie oben beschriebenen Hybridmodells nicht sinnvoller ist, sollte, zumindest zum jetzigen Stand der verfügbaren Rechenleistung, im Einzelfall abgeklärt werden. Das hier aufgezeigte Modell ist bisher in der Lage, Größen und Tiefen von FFB in CFK und PMMA vorherzusagen. Mit einem entsprechenden Trainingsdatensatz wird es in Zukunft aber auch möglich sein, die Vorhersage realer Defekte vornehmen zu können. Dabei stellt das NN jedoch nur ein Werkzeug zur Verfügung, das ohne menschliche Fehler und mit perfektem Gedächtnis innerhalb des vorliegenden Trainingsdatensatzes interpolieren kann.

7 DANKSAGUNG

Die hier vorgestellten Ergebnisse entstanden im Rahmen eines von der Deutschen Forschungsgemeinschaft e.V. (DFG) geförderten Forschungsprojekts, 400857558.



Literatur

- [1] Hutchings, D.J. Neuartiges Verfahren der Farbeindringprüfung / New method of colour penetrant testing. *Materials Testing*, 1984, 26(5), 153–154.
Doi:10.1515/mt-1984-260510
- [2] Bull, D.J.; Spearing, S.M.; Sinclair, I.; Helfen, L. Three-dimensional assessment of low velocity impact damage in particle toughened composite laminates using micro-focus X-ray computed tomography and synchrotron radiation laminography. *Composites Part A: Applied Science and Manufacturing*, 2013, 52(4), 62–69.
Doi:10.1016/j.compositesa.2013.05.003
- [3] Krautkrämer, J.; Krautkrämer, H. Werkstoffprüfung mit Ultraschall. Fünfte, völlig überarbeitete Auflage
Springer Verlag Berlin Heidelberg GmbH, 1986
ISBN: 978-3-662-10909-0.
Doi: 10.1007/978-3-662-10909-0
- [4] Wu, D.; Busse, G. Lock-in thermography for nondestructive evaluation of materials. *Revue Générale de Thermique*, 1998, 37(8), 693–703.
Doi:10.1016/S0035-3159(98)80047-0
- [5] Rittmann, J.; Rahammer, M.; Holtmann, N.; Kreuzbruck, M. Fast and simple detection of impact damage
FRACTURE AND DAMAGE MECHANICS: Theory, Simulation and Experiment: AIP Publishing, 2020, 20048
Doi:10.1063/5.0028408
- [6] Burgholzer, P.; Thor, M.; Gruber, J.; Mayr, G. Three-dimensional thermographic imaging using a virtual wave concept
Journal of Applied Physics, 2017, 121(10), 105102.
Doi:10.1063/1.4978010

- [7] Burgholzer, P.; Mayr, G.; Gruber, J.; Stockner, G. Thermografische Rekonstruktion von internen Wärmequellen mittels virtueller Schallwellen *Materials Testing*, 2018, 60(6), 600–606.
Doi:10.3139/120.111192
- [8] Saintey, M. B.; Almond, D. P. An artificial neural network interpreter for transient thermography image data *NDT & E International*, Vol. 30, No. 5, 291-295, 1997
Doi:10.1016/S0963-8695(96)00071-0
- [9] Rosenblatt, F. The perceptron: a probabilistic model for information storage and organization in the brain *Psychological review*, 65(6), 386–408
Doi:10.1037/h0042519
- [10] Dudzik, S. Characterization of Material Defects Using Active Thermography and an Artificial Neural Network *Metrol. Meas. Syst.*, Vol. XX (2013), No. 3, pp. 491–500.
Doi:10.2478/mms-2013-0042
- [11] Vijaya Lakshmi, A.; Nagendra Babu, K. V. T.; Sree Ram Deepak, M.; et al. A Machine Learning based Approach for Defect Detection and Characterization in Non-Linear Frequency Modulated Thermal Wave Imaging *International Journal of Emerging Trends in Engineering Research*, 7(11), November 2019
Doi:10.30534/ijeter/2019/197112019
- [12] Vallerand, S.; Maldague, X. Defect characterization in pulsed thermography: a statistical method compared with Kohonen and Perceptron neural networks *NDT&E International* 33 (2000) 307-315
Doi:10.1016/S0963-8695(99)00056-0
- [13] Mcculloch, W.S.; Pitts, W. A logical calculus of the ideas immanent in nervous activity *Bulletin of mathematical biology*, 5(4), 115–133.
Doi:10.1007/BF02478259

- [14] Cielo, P Pulsed photothermal evaluation of layered materials. *Journal of Applied Physics*, 1984, 56(1), 230–234.
Doi:10.1063/1.333758
- [15] Darboux, G.;
Fourier, J.-B.-J. Oeuvres de Fourier. Volume 2.
Cambridge: Cambridge University Press, 1824.
Cambridge library collection. Mathematics.
ISBN 9781139568159
Doi: 10.1017/CBO9781139568159
- [16] Bennett, C.A.;
Patty, R.R. Thermal wave interferometry: a potential application of the photoacoustic effect
Applied optics, 1982, 21(1), 49–54.
Doi:10.1364/AO.21.000049
- [17] Mandelis, A. Diffusion-wave fields. Mathematical methods and Green functions.
Springer, 2001.
ISBN 0387951490
Doi: 10.1007/978-1-4757-3548-2
- [18] Spießberger, C. Merkmalsanalyse mit thermischen Wellen in der zerstörungsfreien Werkstoff- und Bauteilprüfung.
Dissertation, Universität Stuttgart, 2012.
- [19] Goodfellow, I.;
Bengio, Y.;
Courville, A. Deep learning (Adaptive computation and machine learning)
The MIT Press, 2016
ISBN 9780262035613
- [20] Hochreiter, S;
Schmidhuber, J. Long short-term memory.
Neural computation, 1997, 9(8), 1735–1780.
Doi:10.1162/neco.1997.9.8.1735
- [21] Chollet, F. Deep Learning with Python
Manning Publications, 2017.
ISBN 9781617294433
- [22] Ronneberger, O.;
Fischer, P.;
Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation
arXiv:1505.04597
Doi: 10.1007/978-3-319-24574-4_28

- [23] Simonyan, K.; Zisserman, A. Very Deep Convolutional Networks for Large-Scale Image Recognition
arXiv:1409.1556
- [24] Szegedy, C.; Vanhoucke, V.; Ioffe, S.; et al. Rethinking the Inception Architecture for Computer Vision
arXiv:1512.00567
Doi: 10.1109/CVPR.2016.308
- [25] Rittmann, J.; Kreuzbruck, M. Flächige photothermische Schichtdickenbestimmung und Materialcharakterisierung an Ein- und Mehrschichtsystemen
Tagungsband 27 Stuttgarter Kunststoffkolloquium 2021
ISBN 978-3-9818681-2-8

Bibliography

DOI 10.3139/O999.01052022
Zeitschrift Kunststofftechnik / Journal of Plastics
Technology 18 (2022) 5; page 234–267
© Carl Hanser Verlag GmbH & Co. KG
ISSN 1864 – 2217

Stichworte:**Neuronales Netz, Aktive Thermografie, Defektcharakterisierung****Keywords:****Neural network, Active Thermography, Defect characterization****Autor / author:**

M.Sc. Johannes Rittmann
Prof. Dr. rer. nat. habil. Marc Kreuzbruck
Institut für Kunststofftechnik
Universität Stuttgart
Pfaffenwaldring 32
70569 Stuttgart

E-Mail: gudrun.keck@ikt.uni-stuttgart.de
Webseite: www.ikt.uni-stuttgart.de
Tel.: +49 (0)711/685 62801
Fax: +49 (0)711/685 62066

Herausgeber / Editors**Europa / Europe**

Prof. Dr.-Ing. habil. Bodo Fiedler
Institut für Kunststoffe und Verbundwerkstoffe
Technische Universität Hamburg
Denickestr. 15 (K)
21073 Hamburg
Deutschland
Tel.: +49 (0)40 42878 3038
E-Mail: fiedler@kunststofftech.com

Prof. Dr.-Ing. Reinhard Schiffers
Institut für Produkt Engineering
Universität Duisburg-Essen
Lotharstr. 1, MA 222
47057 Duisburg
Deutschland
Tel.: +49 (0)203 379 2500
E-Mail: schiffers@kunststofftech.com

Amerika / The Americas

Prof. Prof. hon. Dr. Tim A. Osswald
Polymer Engineering Center, Director
University of Wisconsin-Madison
1513 University Avenue
Madison, WI 53706
USA
Tel.: +1 608 263 9538
E-Mail: osswald@engr.wisc.edu

Verlag / Publisher

Carl-Hanser-Verlag GmbH & Co. KG
Jo Lendle, Oliver Rohloff
Geschäftsführer
Kolbergerstraße 22
81679 München
Germany
Tel.: +49 (0)89 99830 0
E-Mail: info@hanser.de

Redaktion / Editorial Office

Dr.-Ing. Eva Bittmann
Janina Mittelhaus, M.Sc.
E-Mail: redaktion@kunststofftech.com

Beirat / Advisory Board

Experten aus Forschung und Industrie, gelistet unter
www.kunststofftech.com / www.plasticseng.com