

Ortsaufgelöste Schadensdiagnostik mit geführten Wellen und zustandsbasierten Modellen mit Modellfusion für Faserverbundwerkstoffe

Stefan Bosse¹, Daniel Schmidt²

¹Universität Bremen, FB Mathematik & Informatik, 28359 Bremen, Germany,

²DLR Braunschweig, Germany

1. Einführung

Schadensdiagnostik von verdeckten (intrinsischen) Schäden und Erkennen von Materialveränderungen ist immer noch eine Herausforderung, vor allem wenn diese automatisiert erfolgen soll. Bei Lamina-ten (Laminierter Schichtaufbau mit Kohlefaser, Glasfaser, Metallplatten usw.) ist häufig bei einem Schlagschaden keine äußere Beschädigung zu erkennen. Ein Schaden bleibt durch äußere Inspektion unentdeckt. Häufig wird die Interaktion von geführten Wellen (z.B. mit der Ultraschallmesstechnik) für die Erkennung von inneren Schäden genutzt. Die Analyse solcher Wellenfelder ist aufwändig und benötigt i.A. Expertenwissen, und die Robustheit und Zuverlässigkeit ist verbesserungswürdig [1].

Die Eingabedaten der Schadensanalyse sind zeitaufgelöste Ultraschallsignale und enthalten Schadensinformation. Differenzbildung mit Baselinemessung kann Schadensmerkmale zeigen, aber diese sind häufig schwach ausgeprägt und nicht automatisch detektierbar. Es gibt Anfälligkeit der Merkmale gegenüber Rauschen und Variation, Klassifikation von Schäden und Ortsbestimmung ist ebenfalls schwierig.

Formal wird eine Prädiktorfunktion $P(\vec{S})$ gesucht die aus gemessenen Wellenfeldern über Sensordaten \vec{S} auf Defekte und Materialschäden \vec{D} schließen kann. Dabei ist sowohl die sichere Erkennung (binäre Entscheidung) eines Schadens als auch die räumliche Position von großer Bedeutung. In der Strukturüberwachung und sicherheitskritischen

Bereichen muss die fehlerhaft-negativ Rate einer Schadensvorhersage null sein, wo hingegen eine fehlerhaft-positiv Rate durchaus ungleich Null (aber klein) sein darf.

2. Maschinelle Lernverfahren für Zeitseriendaten

Bei Messdaten unterscheidet man strukturierte und unstrukturierte Daten. Strukturierte Daten sind bereits Merkmale eines physikalischen Prozesses (einer Beobachtung) oder schon mit der Ausgangsvariable (der Schlussfolgerung) verbunden. Bei unstrukturierten Daten müssen erst Merkmale mit numerischen Verfahren abgeleitet werden (Merkmalsselektion). Die Ableitung von geeigneten Merkmalsvariablen erfordert i.A. Expertenwissen und einer vorangegangenen Datenanalyse (Statistische und Abhängigkeitsanalyse wie PCA).

In der Ultraschallmesstechnik fallen teils hochdimensionale Zeitseriendaten an die unstrukturierte Daten darstellen. Diese können entweder direkt von einer Schadensprädiktorfunktion verarbeitet oder davon abgeleitete Merkmalsvariablen verwenden. Typische Merkmale von Zeitserien sind statistische Parameter (Mittelwert, Varianz, Skewness, Kurtosis usw) oder auch Spektralparameter wie Frequenzspektren (FFT) und Wavelettransformationen (Diskrete Wavelet Transformation, DWT) sein [3]. Die Merkmale können dabei weiterhin Datenserien mit einer zeitlichen Dimension darstellen (z.B. DWT), von einer ortsräumlichen Dimension abhängen, oder unabhängig von einer Zeit- und Raumdimension sein (z.B. skalare statistische Merkmale und partiell FFT).

In dieser Arbeit werden Zeitseriendaten aus Ultraschallmessungen (die an CFK und FML Platten durchgeführt wurden) verwendet um eine automatische und sichere Schadenserkennung (binäres Klassifikationsproblem) zu erhalten und die Schadensposition räumlich approximativ zu bestimmen (Regressionsproblem). Es werden zwei maschinelle Lernverfahren vorgestellt die transformierte und reduzierte Zeitseriendaten direkt verarbeiten. Dabei wird sowohl ein überwachtes als auch unüberwachtes Training eingesetzt. Die große Schwierigkeit beim überwachten Lernen ist die Bereitstellung von Trainingsdaten mit einer gegebenen Relation $x \Rightarrow y$, wobei y hier ein Schadensmerkmal darstellt. Die Trainingsdaten werden aus Experimenten gewonnen. Jedoch ist die Varianz und Diversität dieser Messdaten begrenzt. Künstliche Datenerweiterung z.B. mit Monte Carlo Simulation durch Überlagerung von realen Messdaten mit einem Gaußschen stochastischen Prozess kann neue künstliche Datensätze erzeugen.

Liegen Zeitseriendatensätze der Form $s(t)=\{x_1, x_2, \dots, x_t\}$ vor so ist häufig der relevante Bereich (Region of Interest) $\text{ROI}=[t_1, t_2]$ der mit dem Schadensmerkmal γ korreliert ist unbekannt und zudem variabel. Werden Zeitserien nicht auf zeitunabhängige Merkmalsvektoren abgebildet kann für das Training nötige ebenfalls zeitaufgelöste Labeling nur schätzungsweise erfolgen. I.A. soll eine Schadenprädiktorfunktion $P(\hat{S}(t)) : \hat{S}(t) \rightarrow \gamma$ eine dynamische Zeitserie auf einen statischen zeitunabhängigen Endwert γ (die Zielvariable y , hier Schadensmerkmal) abbilden. Aufgrund der Schwierigkeit zeitabhängige Datenserien mit einem ebenfalls dynamischen und "zeitabhängigen" künstlichen Schadensmerkmal $y(t)$ verknüpfen zu müssen sind unüberwachte Trainingsverfahren attraktiv wo das (direkte) Labeling entfällt. Eine Merkmalsselektion, z.B. durch Wavelettransformation [3] kann hilfreich sein.

Die durch iterative Approximation zu bestimmende Schadenprädiktorfunktion P ist dabei generell gege-

ben durch:

$$\begin{aligned} P(\hat{S}(t)) : \hat{S}(t) &\rightarrow \gamma \\ s(t) \in \hat{S} : \{x_i\}_{i=1}^t, \\ \gamma : \left(\begin{array}{c} \{false, true\} \\ \{\vec{l}_d, \perp\} \end{array} \right) \end{aligned} \quad (1)$$

$$p(\sigma, x_i) : \sigma_{i-1}(x_0, x_1, \dots, x_{i-1}) \times x_i \rightarrow \sigma_i \times \gamma_i$$

Dabei ist \vec{l}_d eine ein- oder zweidimensionale Schadensposition und S geordnete Zeitseriendaten eines Sensors mit einzelnen Messwerten x_i . Um gleitende Zeitseriendaten zu verarbeiten werden häufig zustandsbehaftete Funktionen P^σ verwendet. Diese Funktionen, z.B. rückgekoppelte Funktionen und Funktionsgraphen (Künstliche Neuronale Netzwerke), besitzen einen Historienspeicher, d.h. eine sequenziell in Einzelschritten mit x_i aktivierte sequenzielle Funktion p liefert eine kumulative Entwicklung des Schadensmerkmals γ . Dabei ist meistens nur der letzte Ausgangswert γ_t einer Zeitserie (also hier eines vollständig gemessenen Wellenzuges) von Relevanz.

Die Approximation dieser Prädiktorfunktion ist ein iterativer und teils randomisierter Prozess, der beeinflusst wird durch Sensorrauschen, Variation der Umgebungsbedingungen (Temperatur, Luftfeuchtigkeit), Abhängigkeiten vom Ort, Verzerrung, Materialzusammensetzung \Rightarrow Spezialisierung, Zuverlässigkeit (falsch-negativ/falsch-positiv), sowie gleichzeitig multiple Schäden die nicht trennbar sind. Das betrifft auch die anschließende Inferenz.

Die Verwendung eines reinen (zustandslosen) Funktionsgraphens (Künstliches Neuronales Netzwerk) ist schwierig. Klassische Vorwärtsgekoppelte Neuronale Netze (VNN) sind gängige Approximatoren. Besser ist die Verwendung eines zustandsbehafteten Funktionsmodells wo der Ausgang von der Historie der Eingabewerte abhängt. Das sind die Rückgekoppelten Künstlichen Neuronalen Netzwerke (RNN) mit Zustandsspeicher. Diese sind aber wiederum schwierig zu trainieren (Problem der Instabilitäten und Nichtkonvergenz). Long-Short Term Memory (LSTM) Architekturen sind besser geeignet und stabiler zu trainieren [AMI15][4]. In dieser Arbeit verwenden wir daher LSTM Netzwerke für die Vorhersage von Schadensmerk-

malen mit einem überwachten und einem unüberwachten Trainingsverfahren (Einzelheiten in [2]). Die grundlegenden Architektur des überwachten Multiinstanz Vorhersagemodells ist in Abbildung 1 gezeigt.

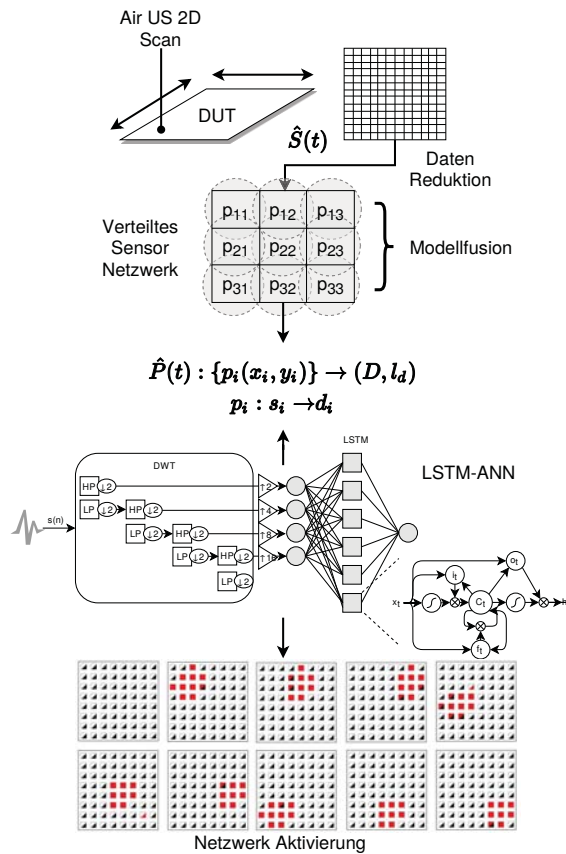


Abbildung 1. Lokale Vorhersage eines Schadens aus zeitaufgelösten lokalisierten Ultraschallmessdaten mit globaler Modellfusion in einem verteilten Sensornetzwerk. Jedes lokale Prädiktormodell m_i arbeitet nur mit lokalen Sensordaten $s_i(t)$, und liefern eine binäre Klassifikation (typische Aktivierungsmuster bei einem räumlich nahen Schaden sind unten gezeigt)

Dabei wird angenommen dass es ein räumlich verteiltes Sensornetzwerk gibt (physisch oder virtuell aus Messdaten berechnet), und jeder Netzwerkknoten misst und verarbeitet nur lokale zeitaufgelösten Sensordaten. Jeder Sensorknoten implementiert eine binäre Prädiktorfunktion für Schäden in seiner unmittelbaren Umgebung (die Vorhersage darf noch unsicher sein). Globale Modellfusion (mit Konsens und geometrischer Berechnung) liefert dann eine sichere Aussage über das Vorliegen eines Schadens und der Approximation des Schadens. Das Training findet überwacht statt.

Ein zweiter Ansatz mit unüberwachten Lernen umgeht das Problem des ungenauen Labelings und unbekanntem Schadens ROI im Signal der für ein dynamisches ebenfalls zeitabhängiges Label $y(t)$ erforderlich wäre. Dabei wird ein Autoencoder (AE) Ansatz verwendet. Mit diesem wird versucht eine Identitätsfunktion $f(s(t)) : s(t) \rightarrow s(t)$ aus Trainingsdaten mit zeitaufgelösten Sensorsignalen (wieder aus der Ultraschallmessung) zu lernen. Dabei ist entscheidend dass das Signal zunächst in seinem Informationsgehalt reduziert wird, d.h., irreversible kodierte Kompression (Autoencoder) angewendet, und anschliessend wieder dekomprimiert wird und approximiert das Ausgangssignal ergibt. Der Autoencoder wird ausschliesslich mit Baseline Signalen iterativ trainiert, wie in Abb. 2 gezeigt ist.

Verarbeitet nun dieser Autoencoder ein Signal mit Schadensinformation wird eher nicht in der Lage sein dass ursprüngliche Signal korrekt zu rekonstruieren und es gibt einen signifikanten Fehler (der nur quantitativ ausgewertet wird). Das bedeutet der Autoencoder ist kein Schadensklassifikator, sondern vielmehr ein lokaler Merkmalsmarkierer und Anomaliedetektor.

Es gibt nur noch eine ortuanhängige Prädiktorfunktion $p(s(t))$ die als Ergebnis den Rekonstruktionsfehler liefert. Das Autoencoder Modell wird auf allen Messpunkten (Messorte) sequenziell trainiert. Hat man nun ein räumlich aufgelöstes Sensorbild, wie man dieses z.B. aus Luftultraschallmessung und 2D Scanverfahren erhält, ergibt die Anwendung des Autoencoders ein markiertes Bild mit binär Anomaliemerkmalen gleicher Dimensionalität, welches dann mit

geometrischer Bildanalyse zu einer Schadensinformation führt (hier die globale Fusion), wie in Abbildung 2 gezeigt ist, sowohl qualitativ als auch ortsaufgelöst.

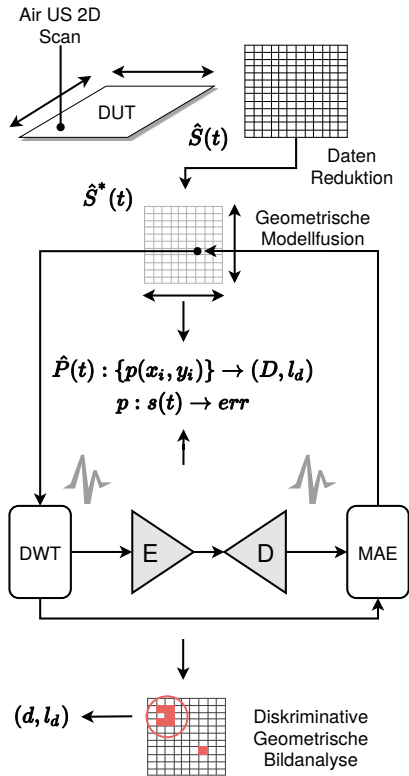


Abbildung 2. Training und Anwendung eines Autoencoders auf zeitaufgelösten Sensorsignalen an multiple Sensororten. Der Autoencoder besteht aus einem Merkmalsselektor (Diskrete Wavelet Transformation), zwei LSTM Netzwerken für den En- und Dekoder, und einem Mean Average Error Diskriminator.

3. Ergebnisse

Experimente wurden mit räumlich gescannten Luftultraschallmessungen an einer CFK Platte durchgeführt (62500 Messpunkte, 2mm Scanraster). Dabei wurden Pseudodefekte [2] an der Oberfläche des Testkörpers angebracht. Je nach Befestigungsart war die Defektinteraktion mit den geführten

schwach bis mittel ausgeprägt. Bei dem ersten Multiinstanz Ensemble Ansatz wurde eine virtuelles 8×8 Sensornetzwerk (60mm virtueller Sensorabstand) aus den Messdaten berechnet. Bei dem Einzelinstanz AE Ansatz wurden zunächst mit voller Bildauflösung gearbeitet (virtueller Sensorabstand 2mm), d.h. die Prädiktorfunktion wurde auf alle Messpunkte angewendet und trainiert. Die Ergebnisse der Vorhersage der Prädiktion sind in Tabelle 1 für beide Verfahren zusammengefasst.

Defekt	FP [%]	FN [%]	Positionfehler [mm]
MMA	0 ¹ /0 ²	0 ¹ /10 ²	23 ¹ /20 ²
VST	0 ¹ /0 ²	0 ¹ /20 ²	60 ¹ /20 ²
MMA/VST	0 ¹ /0 ²	0 ¹ /20 ²	65 ¹ /20 ²

Tabelle 1. Prüfobjekt: CFK Platte 500×500 mm, virtueller Sensorabstand ist: 60mm^1 , 2mm^2 , Defekt Durchmesser 10mm, Befestigungsarten MMA (geklebt) und VST (Kit), 50 verschiedene Messungen, $f=80\text{kHz}$, FP/FN: falsch-positiv und falsch-negativ Rate, Multiinstanzverfahren¹, Einzelinstanzverfahren² [2]

Bei beiden Verfahren wurden die Rohdaten (zeitaufgelöste Ultraschallmesssignale an einem bestimmten Ort) durch Downsampling und einer folgenden DWT Transformation reduziert (DWT Ebenen 3. und 4. Ordnung erwiesen sich als geeignete Signalmerkmale). Beim Multiinstanzverfahren wurden LSTM-KNN mit geringer Neuronenanzahl verwendet, typisch waren 10 LSTM Zellen pro Netzwerk. Die Rechenkomplexität ist gering, Trainingszeiten im Minutenbereich. Da die einzelnen Modellfunktionen unabhängig sind lässt sowohl das Training als auch die Inferenz mit linearer Skalierung parallelisieren. Bei Einzelinstanzverfahren wurden LSTM-KNN mit mittlerer Komplexität verwendet, typisch waren 200 LSTM Zellen. Die Rechenzeiten waren deutlich höher, eine Parallelisierung nur gering möglich. Die Prädiktorfunktion musste an 250×250 Messpunkten sequenziell trainiert und angewendet werden.

4. Zusammenfassung

Zustandsbasierte Künstliche Neuronale Netzwerke können für die Schadensdiagnostik mit zeitaufgelösten Sensorsignalen eingesetzt werden. Sowohl überwachtes Multiinstanz als auch nicht-überwachtes Einzelinstanzlernen ist erfolgreich. Verteilte Sensornetzwerke können mit binären lokalen Schadensklassifikatoren und globaler Fusion gute Ergebnisse erzielen. Es können Positionsgenauigkeiten in der Größenordnung des räumlichen Sensorabstandes oder sogar darunter erzielt werden. Beachtlich ist dass das Multiinstanzverfahren mit geringer Sensordichte (Abstand 60mm) und geringer Rechenkomplexität eine vergleichbare Auflösung bei sogar höherer Zuverlässigkeit gegenüber dem Einzelinstanzverfahren (mit 2mm Sensorabstand) aufweist.

Das Multiinstanzverfahren lässt sich mit linearer Skalierung parallelisieren (da die einzelnen Lokalmodelle unabhängig sind und nur auf lokalen Sensordaten arbeiten). Weiterhin ist dieses Verfahren unter Wahrung von Genauigkeit und Robustheit auf ein Sensornetzwerk mit eingebetteten Rechnern übertragbar. Speicher-, Kommunikations- und Rechenbedarf sind gering.

5. Literatur

- [1] Roseiro, L., Ramos, U., Leal, R., *Neural networks in damage detection of composite laminated plates*, in Proceedings of the 6th WSEAS Int. Conf. on NEURAL NETWORKS, Lisbon, Portugal, June 16-18, 2005, 2005, vol. 2005, pp. 115-119.
- [2] Bosse, S. Weiss, D., Schmidt, D., *Supervised Distributed Multi-Instance and Unsupervised Single-Instance Autoencoder Machine Learning for Damage Diagnostics with High-Dimensional Data—A Hybrid Approach and Comparison Study*, Computers 2021, 10(3), 34; doi:10.3390/computers10030034
- [3] Amin, H.U., Malik, A.S., Ahmad, R.F. et al., *Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques*, Australas Phys Eng Sci Med 38, 139–149 (2015). <https://doi.org/10.1007/s13246-015-0333-x>
- [4] Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., Zhang, H., *Deep Learning with Long Short-Term Memory for Time Series Prediction*, IEEE Communications Magazine, vol. 57, no. 6, 2019.