

Ereignisbasierte Verteilte Zustandsüberwachung und Schadenserkennung in großskaligen und komplexen Konstruktionen mit hybrider Multisensorfusion

Stefan BOSSE^{1,2}, Peter KRÄMER²

¹ Universität Bremen, FB Mathematik und Informatik, Bremen

² Universität Siegen, FB Maschinenbau, Siegen

Kontakt E-Mail: sbosse@uni-bremen.de

Kurzfassung. Robuste und sichere Schadenserkennung in großskaligen Bauteilen und Konstruktionen ist immer noch eine Herausforderung, sowohl hinsichtlich der Messtechnik als auch der Datenauswertung. Beispiele sind Betonbauteile oder Stahlbetonkonstruktionen, insbesondere solche die unter widrigen Bedingungen wie Off-shore Windenergieanlagen betrieben werden. Für die Zustandsüberwachung, vor allem Risserkennung und Materialermüdung, können geführte Ultraschallwellen oder akustische Emissionen eingesetzt werden, die auf eine Rissentstehung oder Ausbreitung hindeuten. Beide Verfahren beruhen häufig auf Referenzmessungen (differentielle Diagnostik) und zeitaufgelösten Signalen. Diese können aber durch veränderte externe Einflüsse und Störungen ungültig werden. Werden z.B. akustische Messungen mit Abtastraten mit mehr als 1Ms/s durchgeführt und sind die Bauteile mit einer großen Anzahl von Sensoren ausgestattet können die Datenvolumen immens groß werden (Tera Bytes bis Peta Bytes), gerade auch auf der longitudinalen Achse. Eine echtzeitfähige Schadenserkennung ist nicht mehr möglich. Anstelle einer zentralisierten global Zustandsschätzung sollen Methoden der lokalen Zustandsschätzung mit globaler Fusion diskutiert und vorgestellt werden. Dabei wird ein verteiltes digitales Sensornetzwerk angenommen in dem Sensorknoten nur lokale Sensordaten verarbeiten um im ersten Schritt eine Anomalie festzustellen, die ein Ereignis für weitere Analysen auslösen. Durch selbst-organisierende, selbst-adaptive und agentenbasierte Nachbarschaftsinteraktion der Sensoren und Sensorfusion (mit Analyse geführter Wellen und akustische Emissionsanalyse) soll ein möglicher Schaden näher und durch datengetriebene Ensembleprädiktoren charakterisiert werden. Dabei soll ein möglichst großer Parameterraum abgedeckt werden und die Implementierung der Schadens- und Anomalie Prädiktoren in eingebetteten System realisierbar sein. Ein besonderes Augenmerk liegt auf der Erkennung von Rissentstehung und Propagation.

1. Einführung

Die Schadensüberwachung, allgemein Structural Health Monitoring (SHM), gliedert sich in verschiedene Schritte und Stufen:



1. Detektion von Anomalien
2. Detektion und Erkennung von Schäden, ggfs. mit einfacher Klassifikation
3. Lokalisation von Schäden
4. Bewertung und Charakterisierung von Schäden (Diagnose)
5. Bewertung des Gesamtzustandes eines Bauteils (Diagnose)
6. Einleitung von Maßnahmen (Wartung, Austausch, Weiterbetrieb)
7. Selbstheilung

Man unterscheidet zwei Klassen von Messverfahren für die Schadensdetektion und Diagnose:

1. Aktive Messverfahren, bei denen die Reaktion auf einen aktiven bekannten und generierten Stimulus gemessen und bewertet wird, z.B., geführte Ultraschallwellen mit einem oder mehreren Sendern und einem oder mehreren Empfängern;
2. Passive Messverfahren, bei denen Betriebs- oder Störungsstimuli gemessen werden, und keine aktive Anregung benötigen, z.B., Verfahren der Akustischen Emissionsanalyse.




Abb. 1. (Links) Entwicklung der Anlagengröße (Höhe) und Sensordichte über einen Zeitraum von 40 Jahren, berechnet aus dem Rotordurchmesser [1] (Rechts) Typische Sensorierungsdomänen einer Windkraftanlage

Windkraftanlagen haben schnell an Größe und werden voraussichtlich weiter wachsen, wenn sich die Technologien weiterentwickeln (siehe Abb. 1, links). Diese Größenzunahme hat zu erhöhten Ausfallraten geführt, u.A. in [2]:

1. Rotorblättern aus Glasfaserverbundmaterialien [1]; sowie verstärkt
2. Materialermüdung, Risse und Bruch im Sockelbereich durch hohe Dreh- und Biegemomente und niedrigfrequenten Schwingungen;
3. Risse und Ermüdung in Turmbereich
4. Schäden in der Generatoranlage, mechanisch, vor allem elektrisch,
5. Sensoren (!)

Aus diesem Grund ist es von größter Bedeutung, Versagensmechanismen in Glasfaserverbundwerkstoffen zu verstehen und neue Ansätze zur Vorhersage von Fehlern zu untersuchen. Dies hat zu Fortschritten bei der Überwachung des strukturellen Zustands großer Verbundwerkstoffstrukturen geführt, indem verbesserte Sensortechnologien eingesetzt wurden, um Materialschäden und -zustände zu bewerten und strukturelle Fehler vorherzusagen, bevor sie auftreten. Es gibt weiterhin neuartige Ansätze und Methoden, um mehrere Ultraschallüberwachungstechniken in Form von Schallemission und aktiv angeregten geführten Ultraschallwellen gleichzeitig auf die mechanische Prüfung von (z.B. glasfaserverstärkten) Verbundlaminate anzuwenden [1,3].

Im Labormaßstab ist die Anwendung und Fusion verschiedener Messmethoden und Sensoren gut möglich, zeigt jedoch in realen ausgedehnten und verbauten Strukturen Probleme. Eine typischerweise direkte Verdrahtung von Sensoren mit einem zentralen Messgerät ist aufgrund geometrischen und baulichen Randbedingungen nicht mehr möglich. Verteilte Sensornetzwerke mit aktiven digitalisierten Sensoren werden erforderlich, wie in der Abb. 1 rechts skizziert ist, deren Einsatz und Randbedingungen in diesem Beitrag diskutiert werden.

Um die Anforderungen und die Gestaltung von verteilten Sensornetzwerken und deren Algorithmen beurteilen zu können, werden nachfolgend Charakteristika von aktiven und passiven Messverfahren, Sensoren, und Algorithmen zusammengestellt, um schließlich den Einsatz von Verteilten Sensornetzwerken für Schadensdiagnostik und Sensorfusion (GUW+AE+Vibration) aufzuzeigen. verteilte Sensornetzwerke werden zunehmend für die Strukturüberwachung und automatisierten Überwachung zur frühzeitigen Erkennung von Schäden von Windenergieanlagen eingesetzt [4]. wenn eine hohe Genauigkeit in der Schadensdiagnostik und Vorhersage erreicht werden soll (sowohl bezüglich Zuverlässigkeit als auch geometrisch), muss die Anzahl von Sensoren und deren räumliche Dichte erhöht werden [2].

2. Aktive Schadensdiagnostik mit geführten Ultraschallwellen

Aktive Messverfahren benötigen eine bekannte und gezielte Anregung von Wellen. Datensignale von Geführten Ultraschallwellen (GUW) weisen bekannte und klar abgrenzbare Charakteristika und Parameter auf, die in Tab. 1 zusammengefasst sind.

Art	Eigenschaften
Sensor	Piezoelektrischer Aufnehmer, Temperatur, Feuchtigkeit
Sensordistanz	(Sender-Empfänger und Paarabstand) 10 - 100 cm
Dimension	Zeitaufgelöstes Signal, N diskrete Werte mit Auflösung D (nach ADK)
Spektralbereich	Frequenzbereich inkl. Oberschwingungen 10-1000 kHz; Angeregte Grundfrequenzen typisch im Bereich 40- 300 kHz; Abtastrate des ADK min. 300 kS/s; Zeitabstand der Samples im Bereich 1-5 μ s; Frequenz- und Modenselektion optional
Amplitude	Amplituden abhängig von Temperatur und Feuchtigkeit, (ohne Verstärkung): 1-10 mV (Piezoelektrischer Sensor); digitale Auflösung wenigstens 8 Bit; i.A. akkumul. Mittelung der Signale möglich
Ereignis	Schadensmerkmale im Signal sind i.A. auf einen bestimmten zeitliche Bereich (Fenster) beschränkt, und i.A., eine Überlagerung von weniger als 10% des Baseline Signals
Reinheit	Signale resultieren nur aus Anregung und Materialeigenschaften und Schäden
Auftreten	Stationär und periodisch durch Anregungssignal bestimmt, Zeitpunkt vom Messereignis durch generativen Stimulus ist bekannt (mit hoher Genauigkeit)
Varianz	Das Messsignal ist i.A. immer nutzbar und hat seinen Ursprung in der generativen Anregung (keine starken Fremdsignale, außer Rauschen)
Kausalität	Direkter und kausaler Zusammenhang von Schaden und Signalmerkmalen
Anregung	Extrinsisch, Sinusschwingung, maskiert mit Gaussfenster (Hammingfenster), typisch 3-5 Schwingungen, hohe Spannung (40-100V), hoher Energiebedarf im Vergleich zur Messung (1-100 mW versus 100 μ W)
Messung	Pitch-catch mit zwei Piezoelektrischen Transducern, Puls-Echo (ein Transducer), Matrixschaltung und Multiplexing mit räumlich verteilten Transducern

Tabelle 1. Eigenschaften von Sensordaten bei GUW Messtechnik

3. Passive Schadensdiagnostik mit Akustischer Emissionsanalyse

Passive Messverfahren nutzen bereits existierende Anregungen und daraus entstehende Wellen, wie Vibrationen, niederfrequente Betriebsschwingungen, und Wellenemission durch Energiefreisetzung bei Schadensentstehung. Datensignale von Wellen aus der Akustischen Emission von Betriebsschwingungen bei Schadensausbildung oder Schadenspersistenz weisen nicht abgrenzbare und eindeutige Charakteristika und Parameter auf, wie in Tab. 2 gezeigt.

Art	Eigenschaften
Sensor	Piezeoelektrischer Aufnehmer, Beschleunigung, Dehnung, Temperatur, Mikrofon, el. Sensoren
Sensordistanz	0.1 - 10 m
Messgrößen	Schwingung, Dehnung, Vibration, Impedanz, el. Größen
Dimension	Zeitaufgelöstes Signal, N diskrete Werte mit Auflösung D (nach ADK)
Spektralbereich	Frequenzbereich inkl. Oberschwingungen 10 Hz (Vibration)-100 kHz; Abtastrate des ADK min. 100 kS/s; Zeitabstand der Samples im Bereich $10 \mu\text{s}$; - 1 ms; breites Spektrum, DWT z.B. erzeugt große Anzahl von Koeffizienten [3]
Amplitude	Amplituden stark abhängig von Materialeigenschaften, Art des Schadens, und Abstand,(ohne Verstärkung): 0.1-10 mV (Piezeoelektrischer Sensor); digitale Auflösung wenigstens 12 Bit; Frequenzfilterung erforderlich; i.A. keine akkumul. Mittelung der Signale möglich
Ereignis	Zeitpunkt vom Messereignis ist unbekannt und muss kontinuierlich überwacht werden
Reinheit	Starkes Signalgemisch aus Betriebsschwingungen (breites Frequenzspektrum), Umgebungsstörungen, und Rauschen
Auftreten	Einmalig (nicht persistent) durch Schadensentstehung oder persistent als dauerhafte Veränderung von Betriebsschwingungen oder Vibrationen
Varianz	Hohe Varianz der Schadensmerkmale im Signal (Muster, Amplitude, Frequenz, Zeitbereich)
Kausalität	Das Messsignal kann durch zu untersuchende Effekte (Schäden) entstanden sein, kann aber auch andere Stimuli als Ursache haben (Reibung, andere Betriebsgeräusche oder Belastungen); nur kausal brauchbare Messsignale müssen ausgewählt und aufgenommen werden
Anregung	Intrinsisch, keine externe Energie erforderlich

Tabelle 2. Eigenschaften von Sensordaten bei AE Messtechnik

4. Sensoren und Schadensmerkmale

Häufig werden zeitaufgelöste Signale $s(t)$ verarbeitet. Neben der direkten Verarbeitung von rohen oder gefilterten Zeitsignalen, die aufgrund des hohen Datenvolumens bestenfalls nur lokal auf Sensorebene erfolgen können, gibt es aggregierte Attribute die mit Schäden korrelierbar sind [5]:

- Amplitude (Maximalwert einer Welle, Mittelwert, Varianz, Halbwertsbreite)
- Anzahl der Wellenzüge, Dauer, Steigung
- Aggregation durch Analytisches Signal (Einhüllende) [6]
- Zeitpunkt des Auftretens
- Spektrale Eigenschaften (Diskretes Frequenzspektrum, Frequenzfenster, Wavelet Transformation und Koeffizienten)
- Energie und Entropie von Signalen [7]
- Korrelationskoeffizienten

- Eigenvektoren und Eigenwerte aus Signaldekomposition

5. Lokalisation von Schäden

Für die Lokalisation von Schäden werden i.A. Gruppen aus Sensoren und Aktuatoren (bei aktiven Messverfahren) verwendet. Die Korrelation der einzelnen Messsignale ergibt die Position des Schadens (nicht immer eindeutig, vor allem bei Multischäden). Für die Bestimmung der Position müssen aggregierte oder analytisch ermittelte Merkmale aus Zeitsignalen abgeleitet werden. Die Verwendung von verteilten Sensornetzwerken bietet sich an [8], um lokal die Merkmale zu bestimmen, und global zu fusionieren.

Triangulation mit elliptischen und hyperbolischen Gleichungen wird wie in Abb. 2 gezeigt für GUV mit bekannten Ausbreitungsparametern (V_{gr} : Gruppengeschwindigkeit) verwendet um Korrelationsbilder mit Schadensverstärkung zu erlangen (Maximum der Intensitätsverteilung $I(x,y)$ ist mit Schaden korreliert, siehe auch [8]). Dabei werden Phasenbeziehungen zwischen Transducerpaaren in Gruppenanordnung ausgenutzt. Dieses Verfahren kann prinzipiell verteilt werden und zur dezentralen Schadenslokalisierung eingesetzt werden. Dabei ist $x_{ni,nj}$ die Kreuzkorrelation des Wandlerpaares n_i und n_j , wobei n der Sender und i und j die beiden Empfänger sind. Wiederum könnte die Kreuzkorrelation entweder das HF- oder das einhüllende Signal der ursprünglichen Differenzsignale sein.

Ein anderer Ansatz besteht darin, lokale Schadensdetektoren bei dem jeweiligen Sensor-knoten zu implementieren. Die Gruppe von Sensorknoten ergeben dann eine verteilte Karte von lokalen Schadensprädiktionen, die global z.B. mittels Mass-of-Centre Berechnung zu einem Schadensorts fusioniert werden können.




Abb. 2. Schadenslokalisierung mit Multitransducernetzwerk (nach [8]) (Oben) Elliptisches Verfahren (Unten) Hyperbolisches Verfahren

6. Verteilte Sensornetzwerke und Ereignisverarbeitung

Ereignisse in verteilten Strukturüberwachungsnetzwerken sind vielfältig:

- Bei aktiven Messverfahren der Startpunkt
- Bei passiven Messverfahren das Auftreten eines Messsignals
- Bei Multisensorsystemen die Konfiguration von Transducern und Einstellung von Messbereichen
- Erkennung von fehlerhaften Sensoren (zunehmende Ausfallraten)

- Energiegewinnung und -versorgung bei autonomen Sensorknoten (bzw. Energiemanagement)

Ereignisdetektion sowie Ereignisberichterstattung benötigen in verteilten Netzwerken eine Synchronisation. Ein Sensornetzwerk ist formal ein i.A. zyklischer ungerichteter Graph $\langle N, E \rangle$ mit einer Menge von Knoten N und verbindenden Kanten E . Die Kanten stellen nachrichtenbasierte Kommunikation zwischen den Knoten her. Die Netzwerktopologie kann sehr unterschiedlich sein, jedoch eignen sich für großflächige Netzwerke (wie bei der Windkraftanlage) nur i.A. irreguläre und unvollständige Maschennetzwerke. Die Kommunikation kann drahtlos (z.B. via Bluetooth oder WiFi WLAN) oder verdrahtet stattfinden (elektrisch wie optisch). Verdrahtete Netzwerke haben den Vorteil gleichzeitig über die Kommunikationsleitungen Daten und Energie zu übertragen.

Das gesamte Datenvolumen von zeitaufgelösten Signalen kann beträchtlich groß werden. Wird eine Samplefrequenz von 1MS/s angenommen, ein Aufzeichnungsintervall von 100 ms und 12 Bit Auflösung, erhält man bei N Sensoren ein Datenvolumen von $200 N$ kB pro Einzelereignis. Bei $M \approx 1000$ Wiederholungen und $N=100$ Sensorknoten ergibt sich bereits ein Datenvolumen von 20 GB! Dezentrale Vorverarbeitung und Ableitung von robusten Merkmalsvektoren ist unabdingbar, gerade wenn auch noch verschiedene Messverfahren kombiniert werden. Eine Signalkompression auf relevante Schadensmerkmale, z.B. mit nichtlinearen Autoencoder Verfahren [3] kann auch auf Knotenebene umgesetzt werden. Messungen werden häufig inkrementell durchgeführt und aufeinander folgende Änderungen der Signaleigenschaften erfasst (longitudinale Erfassung) [3].

7. Verteilte Uhrensynchronisation

Die Ableitung von Schadensmerkmalen inklusive Sensorfusion und vor allem die Lokalisation von Schäden bedarf einer synchronisierten Zuordnung der i.A. zeitaufgelösten Signale. Für verteilte Multisensorik wird eine Uhrensynchronisation der einzelnen Sensorknoten benötigt, um einer spätere Fusion der Messdaten zu ermöglichen (vor allem bei Zeitsignalen). Das bedeutet für GUW und AE eine Synchronisation der Uhren der einzelnen Knoten eines Sensornetzwerkes im Bereich 1 - 100 μ s.

Es gibt verschiedene Methoden, eine verteilte Knotenmenge N oder eine räumliche Untermenge $N_s \subset N$ zu synchronisieren. Primär können Kommunikationkanäle und Nachrichten genutzt werden, vor allem wenn der Ort des Sensors nicht genau bekannt ist. Alternativ können auch GUW verwendet werden, bei der alle Knoten in N_s ein Messsignal aufnehmen, und dann ihren Abstand und eine Referenzzeit über das Kommunikationsnetzwerk zugesendet bekommen.

Bei drahtgebundenen Netzwerken findet i.A. nur eine Punkt-zu-Punkt Kommunikation zwischen zwei benachbarten Knoten statt. Hier findet eine Uhrensynchronisation top-down statt, d.h. der erste Wurzelknoten synchronisiert die nächsten Nachbarn, dann die Nachbarn ihre Nachbarn, usw., was schließlich zu einer Fehlerakkumulation führt. Allerdings nimmt die Zeittoleranz von Abweichungen von Uhren für GUW und AE Messungen mit zunehmenden räumlichen Abstand ebenfalls zu. Besser ist eine separate funkbasierte Synchronisation die in zeitlichen Abständen einen Impuls sendet der von allen Knoten empfangen wird (Ungenauigkeit typisch kleiner als 1 μ s).

Durch Drift der Uhren (z.B. material-integrierte Sensorknoten werden nur mit instabilen RC Oszillatoren betrieben) muss eine häufigere Resynchronisation erfolgen. Wenn eine paarweise Synchronisation erfolgt, werden gegenseitig Nachrichten ausgetauscht und dabei Zeitstempel übertragen. Es muss dabei die Übertragungszeit (unbekannt) d heraus gerechnet werden, um den Uhrenversatz Δ bestimmen zu können:

$$\begin{aligned}\Delta &= \frac{(T_1 - T_2) - (T_4 - T_3)}{2} \\ d &= \frac{(T_2 - T_1) + (T_4 - T_3)}{2} \\ T_2 &= T_1 + \Delta + d\end{aligned}\tag{1}$$

Dabei sendet Knoten A in seiner lokalen Zeit T_1 diesen Zeitstempel an B, der diesen bei seiner lokalen Zeit T_2 empfängt, und bei T_3 seinen Zeitstempel an A zurücksendet, der diesen bei T_4 erhält. Mit diesem Verfahren und stabiler Kommunikation können Genauigkeiten von ca. 10 μs erreicht werden. Es nicht notwendig zu entscheiden welcher Knoten die "richtige" Uhrzeit hat, es reicht die Bestimmung des Versatzes Δ , um später Messsignale annotieren und ausrichten zu können.

8. Verteilte Sensorfusion und ML

Sensorfusion kann auf verschiedene Arten und unterschiedlicher räumlicher Ausdehnung erfolgen. Neben der Normalisierung von Sensorwerten, z.B. durch Temperaturkompensation, können z.B. auch Berechnungen aus G UW und AE kombiniert oder korreliert werden (Multivariate Signalanalyse, Details in [3]). Weiterhin ist Multisensorfusion gleichartiger aber räumlich verteilter Sensoren eine wichtige Methodik um auf Schäden zurück schließen zu können (inkl. Lokalisation, wie bereits gezeigt). Dabei werden die Zeitsignale in verschiedenen Frequenzbändern mit unterschiedlichen Auflösungen analysiert (Diskrete Wavelet Transformation), indem das Signal in eine grobe Näherung und Detailinformationen zerlegt wird (i.A. über kaskadierte Frequenzfilter). Die Auswertung von G UW und AE Signalen ist sehr ähnlich und kann algorithmisch zusammengelegt werden, lediglich die Auswahl von z.B. DWT Koeffizienten unterscheidet sich.

Ein interessanter Ansatz wurde in [2] beschrieben, der auf einem Maschennetz von PZT Sensoren beruht, die zeilen- und spaltenweise durch Analogcomputer verrechnet werden, und nur aggregierte und stark reduzierte Signale werden übermittelt. Diese Art der Nachbarschaftsberechnung kann gut in verteilten Sensornetzwerken auf digitaler Ebene realisiert werden, da auch nur Nachbarschaftskommunikation erforderlich ist.

Bisher wurden klassische numerische Methoden wie Triangulation, Korrelation, oder DWT betrachtet. Zunehmend werden datengetriebene Modelle eingesetzt, prominent sind Künstliche Neuronale Netzwerke (KNN), z.B. Autoencoder oder Clusteringmethoden wie Self-organizing Maps (SOM). KNN, sofern sie auf lokal begrenzten Daten arbeiten, können direkt auf dem Sensorknoten berechnet werden, selbst bei Mikrokontrollern mit geringen Ressourcen (<16 kB RAM) und Festpunktarithmetik [9]. SOMs können zudem im Netzwerk verteilt werden, allerdings besitzen sie keine strikte lokale Datenabhängigkeit.

In [3] werden DWT Merkmale aus AE Messungen mittels SOMs hinsichtlich Schäden klassifiziert. Die Verarbeitungsketten von G UW und AE Signalen sind gleichermaßen komplex (bzw. lang) unter Anwendung verschiedener Funktionen. Einige können bereits auf dem Sensorknoten durchgeführt werden.

9. Schlussfolgerungen

Die Analyse von Zeitsignalen aus G UW und AE Messungen erzeugt große Datenvolumen, die in großskaligen und ausgedehnten Strukturen nicht mehr direkt an zentrale Analyse-rechner übertragen werden können. Vielfach zeigt die Vorverarbeitung von Daten keine

große Rechenkomplexität, z.B. DWT, und kann direkt auf Sensorknoten ausgeführt werden. Multisensorfusion kann dann effizient in einem verteilten Netzwerk ausgeführt werden, wenn nur räumliche Nachbarschaftskorrelation erforderlich ist. Lokale Schadensprädiktion kann in einem Netzwerk auch zur Lokalisation verwendet werden [10]. Uhrensynchronisation der einzelnen Sensorknoten ist für räumliche und zeitliche Sensorfusion erforderlich.

10 Referenzen

- [1] P. Murdy, *Combining Acoustic Emission and Guided Ultrasonic Waves for global Property Prediction and Structural Health Monitoring of Glass Fiber Composites*, Montana State University Bozeman, Montana, 2018.
- [2] C. C. Ciang, J.-R. Lee, and H.-J. Bang, *Structural health monitoring for a wind turbine system: A review of damage detection methods*, Meas. Sci. Technol., vol. 19, 2008
- [3] M.-A. Torres-Arredondo et al., *Multivariate data-driven modelling and pattern recognition for damage detection and identification for acoustic emission and acousto-ultrasonics*, Smart Mater. Struct., vol. 22, 2013.
- [4] R. Rolfes, S. Zerbst, G. Haake, J. Reetz, and J. P. Lynch, *Integral SHM-System for Offshore Wind Turbines Using Smart Wireless Sensors*, in Proceedings of the 6th International Workshop on Structural Health Monitoring, Stanford, CA, September 11-13, 2007
- [5] T. I. Khan, *Structural Health Monitoring by Acoustic Emission Technique*, in Structural Health Monitoring from Sensing to Processing, Intech Open, 2018
- [6] C. Polle, S. Bosse, M. Koerdt, B. Maack, A. S. Herrmann, *Fast Temperature-Compensated Method for Damage Detection and Structural Health Monitoring with Guided Ultrasonic Waves and Embedded Systems*, Proc. of the SysInt Conference, Sep. 6, 2022 to Sep. 8, 2022 - Genova, Italy, DOI: 10.1007/978-3-031-16281-7_35 (2022)
- [7] E. Rojas, A. Baltazar, and K. Loh, *Damage detection using the signal entropy of an ultrasonic sensor network*, Smart Mater. Struct., vol. 24, no. 7, 2015
- [8] A. J. Croxford, P. D. Wilcox, and B. W. Drinkwater, *Guided wave SHM with a distributed sensor network*, in Proc. of SPIE Vol. 6935, 69350E, 2008
- [9] S. Bosse, S. Bornemann, B. Lüssum, *Virtualization of Tiny Embedded Systems with a robust real-time capable and extensible Stack Virtual Machine REXAVM supporting Material-integrated Intelligent Systems and Tiny Machine Learning*, arXiv, pre-print, 2023
- [10] S. Bosse, D. Weiss, D. Schmidt, *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