

# Akustisch basiertes Diagnosesystem zur Beurteilung des Bauteilzustandes

Martin Dannemann, Pawel Kostka, Frank Kolbe, Niels Modler

Institut für Leichtbau und Kunststofftechnik, 01307 Dresden, E-Mail: martin.dannemann@tu-dresden.de

## Einleitung

Stetig steigende Anforderungen in den Bereichen Sicherheit, Komfort und Effizienz in Verbindung mit einem wachsenden Umweltbewusstsein machen die Verwendung neuartiger Werkstoffe und Konstruktionsansätze für Hochtechnologieprodukte notwendig. Ein hohes Potential zur Bewältigung dieser Herausforderungen bieten faserverstärkte Konstruktionswerkstoffe wie glasfaser- oder kohlenstofffaserverstärkte Kunststoffe, da deren Eigenschaftsprofil durch hohe spezifische Steifigkeiten und Festigkeiten geprägt ist [1, 2]. Die volle Ausschöpfung des Leichtbaupotentials von Faserverbundstrukturen erfordert in Verbindung mit den prozess- und einsatzbedingten Streuungen der Bauteileigenschaften effiziente Qualitätssicherungs- und Überwachungsverfahren, die eine Vollprüfung erlauben, da die Kompensation der Streuungen über einen Sicherheitsfaktor i.A. das Leichtbauziel konterkariert. Verfahren wie etwa Ultraschallprüfung oder Computertomographie ermöglichen zwar detaillierte Aussagen über den Bauteilzustand, sind jedoch sehr zeit- und kostenintensiv und somit für eine Vollprüfung von großen Stückzahlen nicht geeignet [3, 4].

Am Beispiel eines generischen Bauteils wird in diesem Beitrag die Möglichkeit dargestellt, derartige Aufgaben mit Hilfe von statistisch basierten Lernstrategien zu lösen. Hierzu wurden die generischen Bauteile umfassend charakterisiert und anschließend einige Bauteile gezielt geschädigt. Mit Hilfe eines eigens entwickelten Prüfstandes wurden die akustischen Antworten auf eine mechanische Stoßerregung aufgezeichnet. Diese Messdaten bilden die Basis für Algorithmen zum Maschinellen Lernen, welche die im Signal enthaltenen Informationen über den Bauteilzustand in Form von Klassifikatoren extrahieren.

## Definition der Teststruktur

Untersuchungen wurden an mehreren Exemplaren einer generischen, endlosfaserverstärkten Struktur mit Epoxy-Matrix durchgeführt. Ihre Geometrie mit konstanter Dicke und seitlichen Versteifungen ist typisch etwa für selbsttragende Verkleidungsteile (vgl. Abbildung 1). Das Faserverstärkungsgewüst besteht aus vier Gewebelagen mit folgendem symmetrischen Aufbau:

1. CF-Körper 2/2, 600g/m<sup>2</sup>
2. GF-Körper 2/2, 390g/m<sup>2</sup>
3. GF-Körper 2/2, 390g/m<sup>2</sup>
4. CF-Körper 2/2, 600g/m<sup>2</sup>



**Abbildung 1:** Untersuchte Faserverbundstruktur (Abmessung: ca. 449 × 255 × 40 mm); Bauteilorientierung: R.

Es wurden Strukturen zweier Geometrievarianten (links- und rechtsgespiegelt) gewählt. Damit soll demonstriert werden, dass die erarbeitete Klassifizierungsmethode für die Unterscheidung schädigungsbedingter Merkmale der gemessenen akustischen Antworten geeignet ist und gegenüber definierten Schwankungen der Strukturparameter robust bleibt.

Eine Bauteilreihe wurde zunächst mittels Computertomographie (CT) untersucht, um eventuell existierende Fertigungsabweichungen zu identifizieren. Die im Weiteren beschriebenen Untersuchungen wurden an acht Bauteilen (vgl. **Tabelle 1**) durchgeführt. Drei Bauteile aus dieser Gruppe wurden kontrolliert geschädigt und bildeten die Klasse 'Schlechtteil' für die nachfolgend betrachtete Klassifizierungsaufgabe.

**Tabelle 1:** Übersicht der untersuchten Bauteile

Nr.	Orientierung	Gezielte Nachschädigung
1	R	keine
2	R	keine
3	L	keine
4	L	keine
5	L	keine
6	R	Beschuss, Stein
7	R	Beschuss, Impactor rund, mehrmals
8	L	Sandstrahlen

## Messaufbau und -prozedur

Entsprechend der Zielstellung einer schnellen und flexiblen Bauteilprüfung, wurden akustische Antworten auf manuelle Stoßerregung mittels eines Impulshammers ohne Kraftmessung als Grundlage für die Zustandsklassifizierung gewählt. Das geprüfte Bauteil wird dabei frei aufgehängt und die Messung erfolgt mit einem Messmikrofon (B&K4955), das in einem Abstand von etwa 250 mm über dem geometrischen Mittelpunkt des Bauteils positioniert ist.

Um einen – für die Zwecke des maschinellen Lernens – geeigneten Datensatz zu gewinnen, wurde eine Messserie an allen in **Tabelle 1** aufgelisteten Bauteilen durchgeführt. Dabei erfolgten jeweils zehn Messungen unter Verwendung der

drei Anregungspunkte AP1, AP2 und AP3 (vgl. Abbildung 1). Die Messumgebung war durch Geräusche laufender Werkstoffprüfmaschinen und deren Nebenaggregate akustisch verrauscht, was die Bedingungen eines industriellen Einsatzes des Diagnosesystems simulierte.

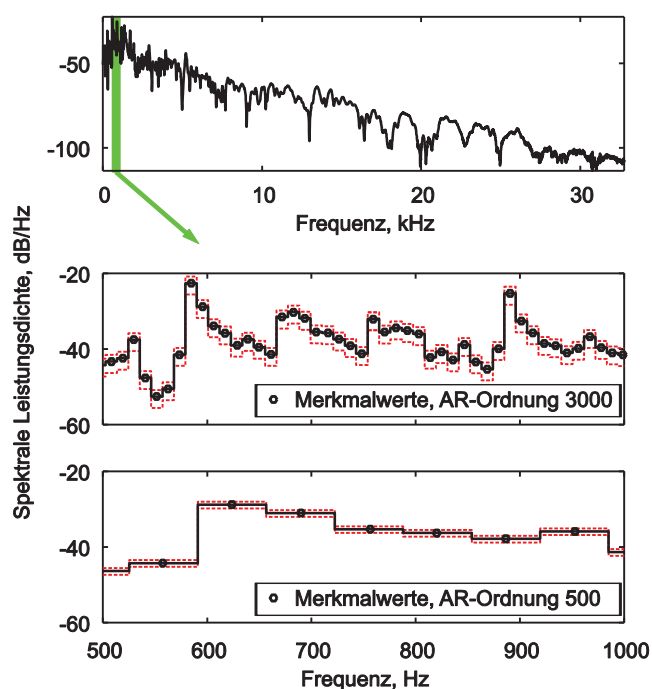
Eine getriggerte Signalaufzeichnung erfolgte mittels eines PC-basierten Frontends über eine Messdauer von 1 s inklusive 0,1 s pretrigger mit einer Abtastfrequenz von 65.536 Hz.

## Signalanalyse und Merkmalextraktion

Die aufgezeichneten Zeitsequenzen der akustischen Antworten bilden die Basis für die Berechnung von quantitativen Merkmalen, die sowohl bei der Klassifikatorenidentifikation als auch bei deren späteren Anwendung zur Bauteilerkennung verwendet werden.

Bei der Merkmaldefinition wurde die Hypothese verfolgt, dass die bauteilzustandsbedingten Veränderungen der akustischen Antworten charakteristische Muster im Frequenzbereich bilden. Dies ist in den bekannten Zusammenhängen zwischen Schädigungsmodi der Faserverbundmaterialien und deren elastischen Eigenschaften begründet [5]. So verändern die lokal variierenden Steifigkeiten sowie Dämpfungen das dynamische Strukturverhalten durch Verschiebungen der Eigenfrequenzen und Modifikationen der Eigenformen, was sich in veränderter spektraler Zusammensetzung der akustischen Signale widerspiegelt.

Das vorliegende Abklingverhalten der Bauteilschwingungen erzwingt eine geringe Messdauer. Hauptsächlich aus diesem Grund wurde auf Identifikationsmethoden parametrischer autoregressiver (AR)-Modelle zur Überführung der gemessenen Zeitsequenzen in den Frequenzbereich zurückgegriffen. Die untersuchte Struktur wurde dabei formal als ein lineares System betrachtet, das eine breitbandige Anregung in die gemessene Antwort transformiert. Diese Methode weist gegenüber nichtparametrischen Methoden, etwa auf Basis der FFT, Vorteile bezüglich der Auflösung ermittelter spektraler Leistungsdichten auf. Der im Identifikationsprozess verwendete AR-Modellgrad bestimmt dabei direkt die erreichbare Frequenzauflösung und soll grundsätzlich an die Eigenschaften des modellierten Prozesses angepasst werden. Bei einer endlichen Messdauer steigt jedoch die Breite der Konfidenzintervalle der Identifikationsergebnisse mit dem steigenden AR-Modellgrad, was die Bestimmung einer optimalen Parametrierung erschwert. Die **Abbildung 2** verdeutlicht diesen Zusammenhang am Beispiel eines Messsignals.



**Abbildung 2:** Gemittelte spektrale Leistungsdichte eines akustischen Signals im vollen Analysebereich sowie in einem schmalen Frequenzband, ermittelt mit unterschiedlichen Auflösungen des AR-Modells. Rot markiert sind die 90%-Konfidenzintervalle der Identifikationsmethode.

## Maschinelles Lernen

Als maschinelles Lernen wird hier ein Prozess zur Identifikation der sogenannten Klassifikatoren anhand aufgezeichneter Messdaten bezeichnet. Ein Klassifikator kann dabei als ein Regelsatz betrachtet werden, mit dem neu aufgenommene Messungen einer der vordefinierten Klassen zugeordnet werden. Derartige Klassifikatoren bilden das softwaretechnische Kernelement eines Bauteildiagnosesystems.

Verwendet wurde ein Algorithmus zur Identifikation von Entscheidungsbäumen, der zur Gruppe von Algorithmen des induktiven, überwachten Lernens gehört, d.h. er operiert an vorklassifizierten Lerndaten [6]. Im speziellen handelt es sich hierbei um eine klassische Variante mit Gini-Index als Kriterium zur Optimierung der rekursiven Datenteilung sowie mit Allgemeinheitsgradkontrolle des Baumes.

Die Lerndaten wurden aus den Werten spektraler Leistungsdichten an Frequenzstützstellen gebildet, die gleichmäßig zwischen Null und Nyquistfrequenz verteilt waren. Die Anzahl solcher Stützstellen wurde stets gleich der verwendeten AR-Modellordnung gewählt. Der **Abbildung 2** kann entnommen werden, dass die AR-Parametrierung den Informationsgehalt der Merkmale stark beeinflusst. Sie entscheidet über die Beobachtbarkeit einzelner Komponenten und zugleich über die statistische Relevanz der ermittelten Werte.

Aus diesem Grund wurde der Prozess des maschinellen Lernens an das Optimierungsproblem der Merkmalbestimmung gekoppelt. Zu diesem Zweck wurde eine Anzahl von Kombinationen der AR-Modellordnung und der Allgemeinheit der Klassifikatoren bewertet. Die letztere wurde durch die minimale Anzahl der Lernbeispiele, die jede Knotenbedingung des Entscheidungsbaumes abdeckt (MinLeaf-

Parameter), vorgegeben. Bevorzugt wurden dabei hohe Werte, die zu kompakten Klassifikatoren mit potentiell besserer Zuverlässigkeit bei Klassifizierung unbekannter Daten führen. Als Optimierungskriterium wurde der mittels Leave-One-Out-Kreuzvalidierung geschätzte Klassifizierungsfehler verwendet.

**Tabelle 2:** Optimierungsergebnisse des maschinellen Lernens

		Allgemeinheitsgrad des Baumes (MinLeaf)				
		2	3	4	6	8
AR-Modellordnung	10	28,8	30,0	23,8	33,8	46,3
	14	18,8	16,3	16,3	15,0	20,0
	19	30,0	30,0	27,5	28,8	26,3
	27	10,0	10,0	10,0	21,3	20,0
	37	28,8	35,0	31,3	23,8	35,0
	51	18,8	20,0	18,8	20,0	20,0
	71	11,3	10,0	15,0	12,5	13,8
	99	21,3	21,3	21,3	18,8	36,3
	137	16,3	20,0	12,5	10,0	11,3
	190	20,0	20,0	21,3	10,0	11,3
	263	27,5	23,8	25,0	27,5	35,0
	365	25,0	25,0	22,5	20,0	15,0
	507	6,3	7,5	8,8	8,8	16,3
	703	10,0	11,3	11,3	11,3	11,3
	974	21,3	20,0	20,0	17,5	21,3
	1351	10,0	15,0	15,0	16,3	15,0
	1874	16,3	17,5	20,0	18,8	16,3
	2599	3,8	3,8	6,3	11,3	7,5
3605	20,0	20,0	18,8	20,0	23,8	
5000	11,3	10,0	10,0	10,0	10,0	

Die **Tabelle 2** zeigt eine Matrix die ermittelten Fehlerwerte in Bereichen [2, 8] des MinLeaf-Parameters sowie [10, 5000] der AR-Modellordnung. Die beste geschätzte Zuverlässigkeit von 96,2 % bei einer Klassifizierung von nicht im Lernprozess enthaltenen Daten wird bei MinLeaf gleich 3 und AR-Modellordnung gleich 2599 erreicht. Der entsprechende Klassifikator wurde anhand von insgesamt 80 Messungen identifiziert, die bei der Stoßanregung am Punkt AP 2 (vgl. Abbildung 1) gewonnen wurden.

## Fazit

Die beschriebenen Untersuchungen haben die prinzipielle Tauglichkeit der vorgeschlagenen Lösung zur praxisgerechten Klassifizierung von Kompositstrukturen anhand einfacher akustischer Messungen bestätigt. Die Robustheit gegenüber akustisch verrauschter Messumgebung sowie der Streuung der Kraftamplitude bei manueller Impulshammeranregung ist ausreichend, um eine hohe Zuverlässigkeit bei binärer Klassifizierung zu erreichen.

Die hier gewonnenen Erkenntnisse ermöglichen keine abschließende Beurteilung der Diagnosemethode für eine konkrete Anwendung. Es sei vor allem darauf hingewiesen, dass sowohl die Anzahl von untersuchten Bauteilen als auch die Anzahl von deren Zuständen gering war.

Bei einem industriellen Einsatz zur Prüfung serienmäßig hergestellter Bauteile ergeben sich jedoch Vorteile bezüglich

verfügbarer Datenmengen für den Lernprozess. Möglich ist eine Lösung, in der das Diagnosesystem anfangs anhand akustischer Daten und Ergebnisse herkömmlicher zerstörungsfreier Prüfungen inkrementell trainiert wird und danach für eine schnelle, rein akustisch basierte Zustandserkennung eingesetzt wird.

## Literatur

- [1] Gude, M.: Innovative Leichtbaulösungen als Schlüssel zur Standortstärkung. *Kunststoffe* 09 (2014), 26-29
- [2] Malanowski, N.; Glitz, R.; Stahl-Rolf, S.: Bestandsaufnahme Leichtbau in Deutschland. VDI Zentrum Ressourceneffizienz GmbH, Berlin, 2015
- [3] Montalvao, D.; Maia, N. M. M.; Ribeiro, A. M. R.: A review of vibration-based structural health monitoring with special emphasis on composite materials. *Shock and Vibration Digest* 38.4 (2006), 295–326
- [4] Heida, J. H.; Müller, J. M.: In-service inspection and monitoring of composite aerospace structures. NLR-TP-2013-435 National Aerospace Laboratory NLR, Amsterdam, 2013.
- [5] Böhm, R.: Beitrag zur bruchmodebezogenen Beschreibung des Degradationsverhaltens textilverstärkter Verbundwerkstoffe. Dresden, Technische Universität, Dissertation, 2008
- [6] Breiman, L.; Friedman, J. H.; Olshen, R. A.; Stone, C. J.: *Classification and Regression Trees*. Chapman & Hall, Boca Raton, 1993

## Danksagung

Das Forschungsvorhaben KF 2305507BN3 wurde über die AiF Projekt GmbH vom Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages gefördert. Das Projekt wurde in Kooperation mit der SPEKTRA Schwingungstechnik und Akustik GmbH Dresden bearbeitet.