

Einfluss der Signallaufzeit auf die Unterscheidbarkeit von Schallemissionsquellen in Faserverbundwerkstoffen

Markus G. R. SAUSE*, Siegfried HORN*

* Universität Augsburg, Institut für Physik, Experimentalphysik II, D-86135 Augsburg

Kurzfassung. In Faserverbundwerkstoffen können zur Identifikation von typischen Schadensmechanismen wie Matrixrissen, Faser-Matrix Grenzflächenversagen und Faserbrüchen parameterbasierte Mustererkennungsverfahren auf Schallemissionssignale angewendet werden. Zur Abschätzung des intrinsischen Klassifizierungsfehlers solcher Mustererkennungsverfahren wurden Studien an künstlichen Datensätzen mit bekannten Klassenstrukturen durchgeführt. Durch Variation des Separationsgrades der Klassen lässt sich der systematische Fehler des Klassifizierungsverfahrens quantifizieren. Bei der Anwendung von Mustererkennungsverfahren auf reale Schallemissionssignale muss beachtet werden, dass es aufgrund der verlustbehafteten und dispersiven Wellenausbreitung zu einer laufzeitabhängigen Verschiebung des Frequenzgehaltes des detektierten Signals kommt. Dadurch wird die Lage der extrahierten Frequenzparameter verschoben, was mit zunehmender Signallaufzeit zu einer schlechteren Unterscheidbarkeit von Signalklassen führt. Experimentell wurde dieser Effekt durch Bleistiftminenbruchtests mit variierendem Abstand zum Sensor im Bereich von 40 mm bis 300 mm untersucht. Die auftretende Verschiebung der Frequenzgehalte wird verglichen mit Verschiebungen durch Einflüsse von Sensorankopplung und Sensortyp. Es wird gezeigt, dass die Signallaufzeit im gewählten Abstandsbereich eine signifikante Rolle spielt.

1. Einführung

Faserverbundwerkstoffe spielen in modernen Leichtbauanwendungen eine zunehmende Rolle als lasttragende Strukturen, da sie eine hohe gewichtsspezifische Festigkeit besitzen und eine lastpfadgerechte Auslegung der Bauteile erlauben. Zur vollen Ausnutzung dieses Potentials ist eine zuverlässige Vorhersage des Ersteinsatzes und des Fortschritts von Schädigungen im Material erforderlich. Da sich die unterschiedlichen mikroskopischen Schädigungen, wie Matrixrisse, Faserbrüche, Faser-Matrix Auszug und Faser-Matrix-Debonding gegenseitig beeinflussen und letztendlich das makroskopische Werkstoffversagen verursachen, trägt eine Detektion und Unterscheidung dieser Mechanismen wesentlich zum Verständnis des Werkstoffverhaltens bei. Die Schallemissionsanalyse bietet hier die Möglichkeit in Abhängigkeit der Belastung Schädigungen im Faserverbundwerkstoff zu detektieren und den Entstehungsort der Schallquelle zu lokalisieren. Basierend auf den Untersuchungen zahlreicher Autoren lässt sich in plattenförmigen Geometrien eine Unterscheidungen von Matrixrissen und Faserbrüchen anhand des Frequenzgehaltes der aufgezeichneten Lambwellen bei niedrigen Frequenzen (Matrixrisse) und hohen Frequenzen (Faserbrüche) vornehmen [1-7].




Bruchvorgänge an der Grenzfläche zwischen Faser und Matrix verursachen Signale, die Frequenzspektren mit dominanten Beiträgen im gesamten Frequenzbereich von 20 kHz bis 1 MHz aufweisen [2,8]. Die unterschiedlichen Frequenzbeiträge der Schallemissionssignale stammen von den verschiedenen Ausbreitungsmoden der Lambwellen in Faserverbundwerkstoffen. Dabei breiten sich die beiden fundamentalen Lambwellenmoden vorwiegend bei niedrigen Frequenzen (antisymmetrische Mode) oder hohen Frequenzen (symmetrische Mode) aus. Aufgrund der Position der Schädigung innerhalb der Platte, der Mikrostruktur, der Abstrahlrichtung und den mikroskopischen elastischen Eigenschaften in der Nähe der Schallquelle werden durch die verschiedenen Schädigungsmechanismen unterschiedliche Intensitäten von symmetrischen und antisymmetrischen Lambwellen erzeugt [8, 9].

2. Mustererkennungsverfahren zur Identifizierung von Schadensmechanismen

Da die exakte Form der Lambwellen von der Geometrie des Faserverbundwerkstoffes und der Faserorientierung abhängt, lassen sich außer den qualitativen Aussagen zur Frequenzlage keine festen Frequenzbereiche für die Schallemission der einzelnen Schadensmechanismen angeben. Stattdessen müssen die entsprechenden Frequenzbereiche für jede Verbundstruktur neu überprüft werden. Standardmäßig werden zur Analyse von Schallemissionssignalen Parameter errechnet, die eine Reduktion der Informationen des aufgezeichneten Signals und eine Darstellung in Streudiagrammen erlauben. In solchen Diagrammen lassen sich anschließend Gruppen von Signalen anhand charakteristischer Gemeinsamkeiten im Parameterraum (Häufungspunkte) identifizieren. Bei parameterbasierten Mustererkennungsverfahren werden anstelle eines einzigen oder von zwei Parametern mehrere Parameter verwendet um ein Entscheidungskriterium für die Zuordnung zu finden. Ziel der Untersuchung bleibt die Gruppierung von Signalen anhand ihrer Ähnlichkeit zueinander.

Abbildung 1. Parameterextraktion im Zeit- und Frequenzraum



Beispiele für die Errechnung von Parametern sind in Abbildung 1 gezeigt und die in den folgenden Untersuchungen verwendeten Parameter in Tabelle 1 aufgelistet. Die Berechnung der Parameter basiert entweder auf den Charakteristiken im Zeitraum, wie Ankunftszeit t_0 , Maximalamplitude U_{max} , Zeitdauer t_{AE} , Anzahl der Schwellwertüberschreitungen bis zur Maximalamplitude N_{peak} und Gesamtzahl der Schwellwertüberschreitungen N_{AE} oder auf Charakteristiken im Frequenzraum, wie der Frequenzposition maximaler Intensität f_{peak} oder dem ersten Trägheitsmoment des Frequenzspektrums $f_{centroid}$. Es sei angemerkt, dass Tabelle 1 keine vollständige Liste an

möglichen Parametern zur Beschreibung eines Schallemissionssignals darstellt. Insbesondere wurden energetische Parameter, wie die Signalenergie oder die Maximalamplitude für die Mustererkennung nicht verwendet. Dies basiert auf den Ergebnissen zahlreicher Voruntersuchungen [8,10], die in Faserverbundwerkstoffen keine direkte Korrelation zwischen dem Schädigungsmechanismus und der abgestrahlten Energie der Schallquelle vermuten lassen.

Tabelle 1. Verwendete Frequenzparameter

| Feature | Definition |
|------------------------------|--|
| Average Frequency [Hz] | $\langle f \rangle = N_{AE} / t_{AE}$ |
| Reverberation Frequency [Hz] | $f_{rev} = \frac{N_{AE} - N_{peak}}{t_{AE} - t_{peak}}$ |
| Initiation Frequency [Hz] | $f_{init} = \frac{N_{peak}}{t_{peak}}$ |
| Peak Frequency [Hz] | f_{peak} |
| Frequency Centroid [Hz] | $f_{centroid} = \frac{\int f \cdot \tilde{U}(f) df}{\int \tilde{U}(f) df}$ |
| Weighted Peak-Frequency [Hz] | $\langle f_{peak} \rangle = \sqrt{f_{peak} \cdot f_{centroid}}$ |
| Partial Power 1-6 [%] | $\int_{f_1}^{f_2} \tilde{U}^2(f) df / \int_{0 \text{ kHz}}^{1200 \text{ kHz}} \tilde{U}^2(f) df$ Partial Power 1: $f_1 = 0 \text{ kHz}; f_2 = 150 \text{ kHz}$ Partial Power 2: $f_1 = 150 \text{ kHz}; f_2 = 300 \text{ kHz}$ Partial Power 3: $f_1 = 300 \text{ kHz}; f_2 = 450 \text{ kHz}$ Partial Power 4: $f_1 = 450 \text{ kHz}; f_2 = 600 \text{ kHz}$ Partial Power 5: $f_1 = 600 \text{ kHz}; f_2 = 900 \text{ kHz}$ Partial Power 6: $f_1 = 900 \text{ kHz}; f_2 = 1200 \text{ kHz}$ |

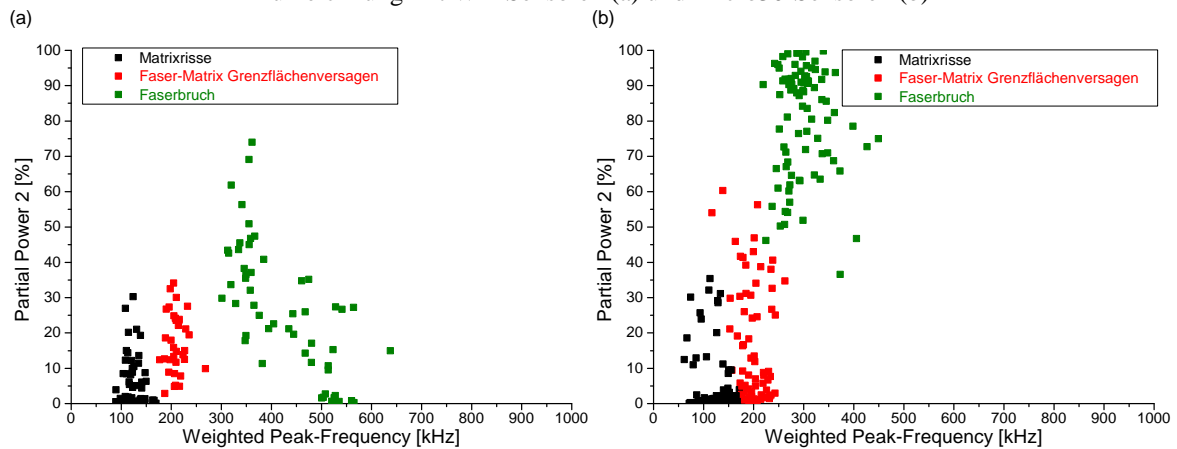
Basierend auf den in Tabelle 1 definierten Frequenzparametern lässt sich nun eine Untersuchung der Schallemissionssignale auf Ähnlichkeit vornehmen. Hierzu wurde kürzlich ein verallgemeinertes Verfahren zur Detektion von natürlichen Signalklassen vorgestellt [11], das auf den Ansätzen von Anastassopoulos et al. und Günter et al. basiert [12, 13]. Dieses Klassifizierungsverfahren trifft keine initialen Annahmen über die Anzahl der Klassen oder deren Positionen im Frequenzraum. Stattdessen werden die wichtigsten Parameter zur Beschreibung des Klassifizierungsproblems automatisch ausgewählt und die Anzahl der natürlichen Klassen, sowie die beste Partition der Schallemissionssignale bestimmt. Im Anschluss lässt sich eine Zuordnung der einzelnen Klassen von Schallemissionssignalen zu bestimmten Schadensmechanismen durch Vergleich mit mikroskopischen Beobachtungen oder den Vergleich von Schallemissionssignalen mit Ergebnissen von entsprechenden Finite-Elemente Berechnungen erreichen [8,11,14].

Im Folgenden wurden Untersuchungen an Platten des Prepreg-Systems CE 1250-230-39 mit einem Lagenaufbau $[0/90_2]_{sym}$ durchgeführt. Als beispielhaftes Ergebnis des Mustererkennungsverfahrens ist in Abbildung 2 das Resultat der Messung von Schallemissionssignalen bei Belastung von Vier-Punkt Biegeproben nach DIN-EN-ISO 14125 gezeigt. Zur Aufzeichnung wurden für die Messung in Abbildung 2-a zwei WD-Sensoren, für die Messung in Abbildung 2-b zwei Micro30-Sensoren, jeweils mit einem Schwellwert von 35 dB, einem Vorverstärkungsfaktor von 40 dB und einer Aufzeichnungsrate von 10 MSP/s verwendet (s. auch [8,10,11,14]).

Es ist gut zu erkennen, dass die Lage der experimentell gefundenen Signalklassen im Diagramm von Weighted Peak-Frequency gegen Partial Power 2 charakteristische

Trennungen aufweist. Anhand der berechneten Frequenzparameter von Schallemissionssignalen, die für Matrixrisse, Faser-Matrix Grenzflächenversagen und Faserbrüchen simuliert wurden, lässt sich die in Abbildung 2 gezeigte Zuordnung treffen [8,10,14]. Während bei der in Abbildung 2-a gezeigten Messung mit den WD-Sensoren eine eindeutige Abgrenzung der Signalklassen vorliegt, ist dies für die in Abbildung 2-b gezeigte Messung mit den Micro30-Sensoren nicht mehr der Fall. Stattdessen erlaubt die Überlappung der Signalklassen hier nur eine fehlerbehaftete Zuordnung zu den zugrunde liegenden Schadensmechanismen. Ziel der durchgeführten Untersuchungen ist daher die Quantifizierung des Klassifizierungsfehlers aufgrund solcher Überlappungen und die Bestimmung experimenteller Einflussfaktoren auf die erzielte Genauigkeit des Klassifizierungsverfahrens.

Abbildung 2. Ergebnis des Mustererkennungsverfahrens für Vier-Punkt Biegeproben bei Aufzeichnung mit WD-Sensoren (a) und Micro30-Sensoren (b)



3. Korrelation zwischen Überlappung und Klassifizierungsgenauigkeit

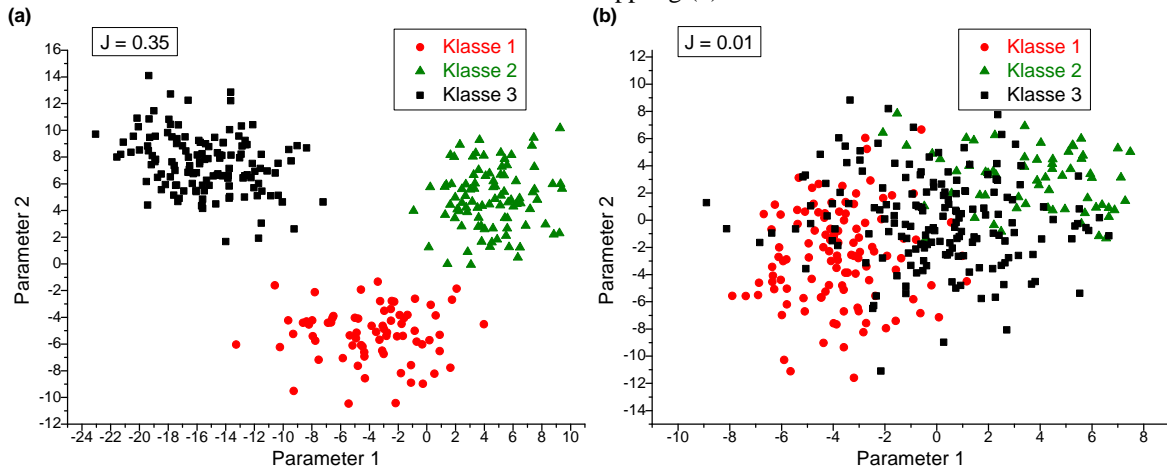
Zur Quantifizierung der unterschiedlichen Schadensmechanismen ist es notwendig eine Abschätzung des Fehlers der Klassifizierung vorzunehmen. Diese wird maßgeblich durch die Überlappung der einzelnen Klassenstrukturen im mehrdimensionalen Parameterraum verursacht. Um diesen Einfluss zu untersuchen wurden innerhalb der Statistiksoftware R mit Hilfe des Paketes ClusterGen von Qiu et al. künstliche Datensätze mit definierter Trennung zwischen verschiedenen Klassen erzeugt [11,15,16]. Ein Beispiel für solche künstlichen Datensätze mit starker Trennung der Signalklassen, bzw. starker Überlappung ist hierzu in Abbildung 3 gezeigt. Als Maß für die Trennung wird im Folgenden der Wert J verwendet, dessen Definition in [15,16] beschrieben ist. Niedrige Werte von J beschreiben eine schlechtere Trennung der Klassen.

Für das in [11] beschriebene Verfahren werden zur numerischen Bewertung von Klassifikationsergebnissen verschiedene statistische Indizes verwendet. Im Einzelnen sind dies der Davies-Bouldin Index, der Tou Index, der Silhouettenkoeffizient und die Gamma Statistik [17-20]. Gute Trennung der Signalklassen wird dabei durch hohe Werte für den Tou-Index, den Silhouettenkoeffizient und die Gamma Statistik, aber niedrige Werte für den Davies-Bouldin Index angezeigt.

Zur Untersuchung der Klassifikationsgenauigkeit wurden für den Bereich von $J = 0.01$ bis $J = 0.35$ jeweils drei künstliche Datensätze mit drei Klassen erstellt und mit dem Klassifizierungsverfahren aus [11] ausgewertet. In allen Fällen wurde die korrekte Anzahl von drei Klassen ermittelt. Das Ergebnis der errechneten statistischen Indizes für

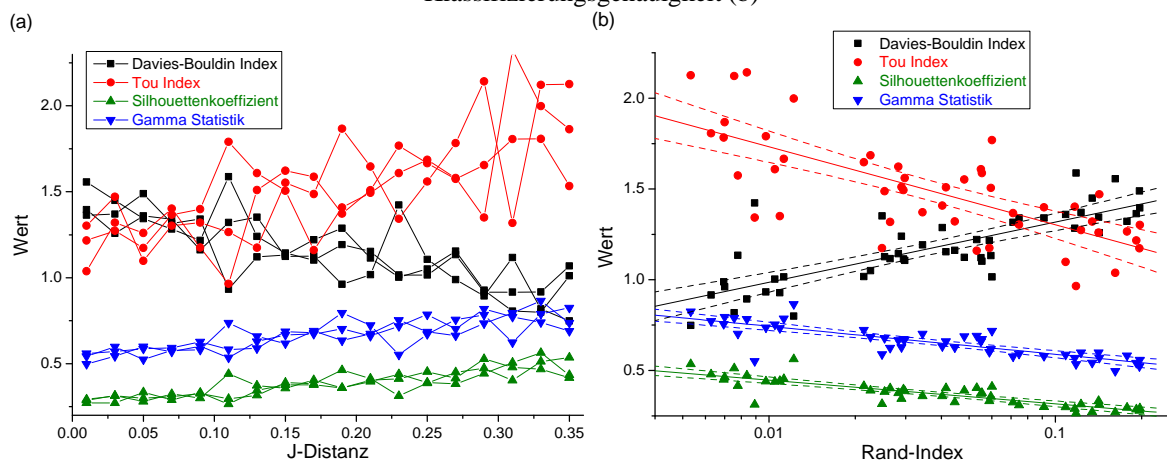
die jeweils beste Trennung ist in Abbildung 4-a in Abhängigkeit von J gezeigt. Es zeigt sich, dass die einzelnen Indizes die erwartete Abhängigkeit von J, aber unterschiedlich starke Streuung aufweisen. Dies ist durch die Definition der statistischen Indizes bedingt und muss bei der Bestimmung der Klassifizierungsgenauigkeit berücksichtigt werden.

Abbildung 3. Beispiel für künstliche Datensätze mit starker Trennung der Signalklassen (a) und starker Überlappung (b)



Zum Vergleich der vorgegebenen Klassenstruktur und der über das Klassifizierungsverfahren erreichten Zuordnung wurde für die Partition jedes Datensatzes der Rand Index berechnet [21]. Dieser Index lässt sich direkt als Klassifizierungsfehler interpretieren, erfordert aber die exakte Kenntnis der Zuordnung der einzelnen Datenpunkte zu den Klassen. Daher kann dieser nicht direkt auf experimentelle Daten angewendet werden, bei denen die richtige Zuordnung ab initio nicht bekannt ist. Trägt man nun, wie in Abbildung 4-b gezeigt, die statistischen Indizes über dem errechneten Rand-Index in logarithmischer Skalierung auf, so erkennt man einen näherungsweise linearen Zusammenhang zu den Werten der statistischen Indizes. Nicht dargestellt sind aufgrund der logarithmischen Skalierungen die Ergebnisse für den Wert des Rand Index 0, was einer fehlerfreien Zuordnung entsprechen würde und insbesondere bei hohen Werten von J häufig auftritt.

Abbildung 4. Evaluation der Klassifizierungsindizes in Abhängigkeit der Überlappung (a) und der Klassifizierungsgenauigkeit (b)



Zur genaueren Bestimmung der Klassifizierungsgenauigkeit wurde zusätzlich eine lineare Regression (durchgezogene Linien) mit 95 % Konfidenzintervallen (gestrichelte Linien) für die einzelnen statistischen Indizes durchgeführt. Basierend auf diesem


Diagramm kann nun auf Basis der errechneten statistischen Indizes für experimentelle Datensätze eine Abschätzung der Klassifizierungsgenauigkeit vorgenommen werden.

4. Experimentelle Einflüsse auf die Klassifizierungsgenauigkeit

4.1 Reproduzierbarkeit der Sensorankopplung

Zum Vergleich der Ergebnisse von verschiedenen Messungen ist es notwendig, die Reproduzierbarkeit der Ankopplung des verwendeten Sensors zu berücksichtigen. Hierzu wurden Messungen mit einem WD-Sensor als Pulsgeber in einem Abstand von 100 mm mit einer Wiederholrate von 5 Hz durchgeführt. Der zu prüfende Sensor wurde mehrfach angekoppelt und es wurden jeweils 50 Pulse aufgezeichnet. Aus den detektierten Signalen wurde mit Hilfe der Software Aware++ das mittlere Frequenzspektrum der Signale und die zugehörige Standardabweichung errechnet [22]. Das Ergebnis des errechneten Frequenzspektrums ist mit den zugehörigen Fehlerbalken aus 10 Ankoppelversuchen in Abbildung 5-a dargestellt. Für jedes der aufgezeichneten Signale wurden nun die Frequenzparameter aus Tabelle 1 errechnet und in einem der Abbildung 2 entsprechenden Diagramm aufgetragen. Zur besseren Darstellung wurde nur ein Teilbereich der Achsen aus Abbildung 2 verwendet. Das mittlere Frequenzspektrum zeigt ebenso wie die Darstellung der errechneten Signalparameter eine deutliche Streuung als Konsequenz der unterschiedlichen Qualität der Ankopplungen. Die damit verbundene Streuung der Frequenzparameter ist signifikant und liegt bei etwa 100 kHz auf der x-Achse und 4 % auf der y-Achse. Diese Streuung der Parameter liegt in der gleichen Größenordnung wie die Ausdehnung der beobachteten Signalklassen (vgl. Abbildung 2). Eine unterschiedliche Ankopplung kann daher zu Schwankungen der Frequenzlagen der identifizierten Signalklassen zwischen verschiedenen Experimenten führen, aber beeinflusst die Lage der Signalklassen innerhalb eines Experiments zueinander nicht.

Abbildung 5. Gemitteltetes Frequenzspektrum aus 10 Ankoppelversuchen (a) und Vergleich der Lage der errechneten Signalparameter der Einzelpulse mit Standardabweichung (b)

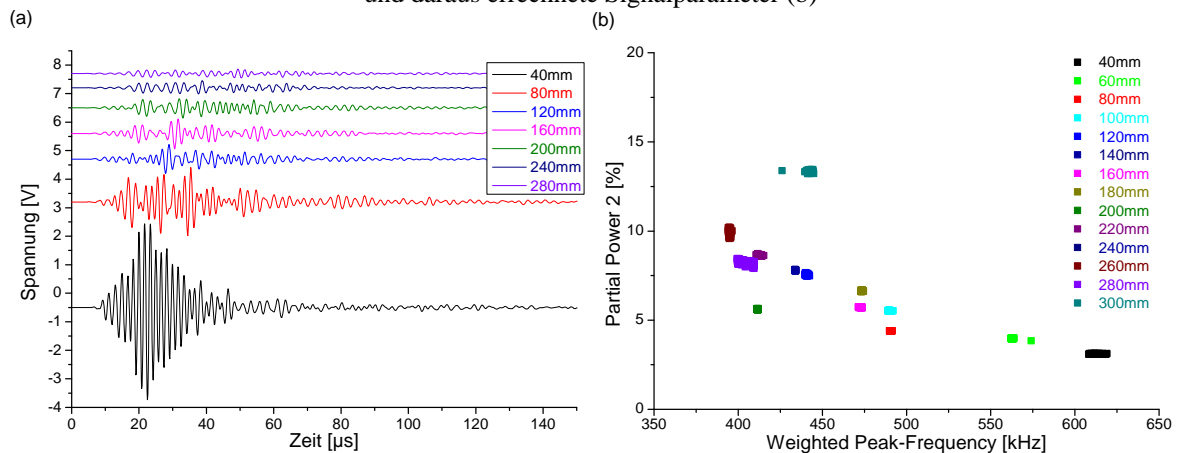


4.2 Einfluss der Signallaufzeit

Grundsätzlich führen Änderungen des Abstands zwischen Schallquelle und Sensor aufgrund von modenselektiver Dämpfung und Dispersion zu einer Änderung des detektierten Frequenzgehaltes der Lambwelle [8-10]. Zusätzlich führt die Verschiebung der vertikalen Position der Schallquelle vom Zentrum zum Rand innerhalb der Platte zu einer starken Verschiebung der Intensität zu antisymmetrischen Moden und damit zu niedrigen Frequenzen. Dieser Effekt, sowie die laterale Ausbreitung führen zu einer Streuung der

errechneten Signalparameter und damit letztlich zur Ausdehnung der Signalklassen, wie in Abbildung 2 zu erkennen. Im Folgenden liegt der Fokus der Untersuchung auf den lateralen Ausbreitungseffekten der Lambwellen. Dazu wurden Untersuchungen mit Bleistiftminenbrüchen auf einer 0,5 m × 0,5 m großen Platte des Prepreg-Systems CE 1250-230-39 mit einem Lagenaufbau $[0/90_2]_{\text{sym}}$ mit variierendem Abstand zum WD-Sensor im Bereich von 40 mm bis 300 mm durchgeführt. Die vertikale Position der Schallquelle ist festgelegt auf die Oberfläche der Platte und kann damit als konstant erachtet werden. In Abbildung 6-a sind repräsentative Schallemissionssignale dargestellt, die in unterschiedlichen Abständen zum WD-Sensor erzeugt wurden. Die Effekte der Signaldämpfung und Dispersion sind gut zu erkennen und führen mit zunehmendem Abstand zu einer starken Intensitätsabnahme und einer Verbreiterung des Signals. In der zugehörigen Abbildung 6-b wurden die für alle detektierten Signale (10 je Abstand) errechneten Frequenzparameter in einem Teilbereich eines der Abbildung 2 entsprechenden Diagramms aufgetragen. Die Verschiebung der Frequenzparameter ist mit 200 kHz auf der x-Achse und 10 % auf der y-Achse stärker ausgeprägt als bei der wiederholten Sensorankopplung, bewegt sich aber wie zuvor in einem Bereich der typischen Ausdehnung der Signalklassen aus Abbildung 2.

Abbildung 6. Repräsentative Schallemissionssignale in unterschiedlichem Abstand zum Sensor (a) und daraus errechnete Signalparameter (b)



4.3 Einfluss des verwendeten Sensors


Wie bereits Abbildung 2 zu entnehmen ist, wirkt sich die Wahl des Schallemissionssensors deutlich auf die Lage der Signalklassen aus. Dies wird durch die unterschiedliche spektrale Sensitivität der Sensoren verursacht und führt im Falle von resonanten Sensoren, wie dem Micro30 zu einem Verlust an Bandbreite und damit zu einer Verdichtung und Überlappung der Klassen von Schallemissionssignalen. Im Einzelfall ist damit eine gültige Zuordnung durchaus möglich, jedoch ist der entsprechende Klassifizierungsfehler deutlich höher als bei Verwendung eines breitbandigen Sensors.

5. Diskussion und Zusammenfassung

In Abbildung 7 sind die Einflüsse von Sensorankopplung und Laufzeit auf die errechneten Signalparameter im Vergleich zu den experimentellen Daten gezeigt. Die mittlere Ausdehnung der Signalparameter wird durch die ebenfalls dargestellte Ellipse visualisiert. Im Vergleich zur Ausdehnung der experimentellen Daten wird deutlich, dass eine Überlagerung mit der Unsicherheit aus Signallaufzeit und Sensorankopplung eine deutliche Überlagerung der Signalklassen verursachen kann. Konkret kann für experimentelle Daten der Klassifizierungsfehler anhand der berechneten statistischen Indizes abgeschätzt werden.

Für den vorliegenden Fall ergibt sich für die Messung mit WD Sensoren anhand von Abbildung 4-b ein Klassifizierungsfehler von 0,0 %, da sich die Klassen nicht überlagern. Im Unterschied dazu ergibt sich für die Messung mit Micro30 Sensoren bereits ein Klassifizierungsfehler von 4,5 %. Bezieht man den Effekt der Sensorankopplung mit ein, so ergibt sich durch die erwartete mittlere Verbreiterung der Signalklassen ein maximaler Fehler für die Klassifizierung von 5,1 % für die Messung mit WD Sensoren und 21,0 % für die Messung mit Micro30 Sensoren. Die Reproduzierbarkeit der Sensorankopplung hat also starken Einfluss auf den Vergleich von Experimenten zueinander, spielt aber für die Klassifizierungsgenauigkeit innerhalb eines Versuches nur eine untergeordnete Rolle.

Abbildung 7. Vergleich des Einfluss von Sensorankopplung und Signallaufzeit (Testsignale) auf Signalparameter mit Lage der experimentellen Klassen aus Vier-Punkt Biegung



Im Vergleich dazu wirkt sich die Signallaufzeit für die Messung mit WD Sensoren mit einem maximalen Fehler von 5,4 %, für die Messung mit Micro30 Sensoren mit einem maximalen Fehler $> 25,0$ % aus. Es kommt also mit zunehmender Streuung der Propagationslänge der Signale im Material zu einer stärkeren Ausdehnung der Klassen und damit auch zu einer zunehmenden Überlappung. Dies beeinflusst die Genauigkeit der Klassifizierung innerhalb einer Messung und wirkt sich damit signifikant auf den minimalen erzielbaren Klassifizierungsfehler aus.

Referenzen

- [1] J. Bohse. Acoustic emission characteristics of micro-failure processes in polymer blends and composites. *Composites Science and Technology*, 60, 1213-1226, 2000.
- [2] W. Haselbach, B. Lauke. Acoustic emission of debonding between fibre and matrix to evaluate local adhesion. *Composites Science and Technology*, 63:15, 2155-2162, 2003.
- [3] C. R. Ramirez-Jimenez, N. Papadakis, N. Reynolds, T. Gan, P. Purnell, M. Pharaoh. Identification of failure modes in glass/polypropylene composites by means of the primary frequency content of the acoustic emission event. *Composites Science and Technology*, 64, 1819-1827, 2004.

- [4] A. Marec, J.-H. Thomas, R. Guerjouna. Damage characterization of polymer-based composite materials: Multivariable analysis and wavelet transform for clustering acoustic emission data. *Mechanical Systems and Signal Processing*, 22, 1441-1464, 2008.
- [5] X. Li, C. Ramirez, E. L. Hines, M. S. Leeson, P. Purnell, M. Pharaoh. Pattern Recognition of Fiber-reinforced Plastic Failure Mechanism using Computational Intelligence Techniques. *Neural Networks*, pages 2340-2345. *IEEE World Congress on Computational Intelligence*, 2008.
- [6] J. Bohse, J. Chen. Acoustic Emission Examination of Mode I, Mode II and Mixed-Mode I/II Interlaminar Fracture of Unidirectional Fiber-Reinforced Polymers, *Journal of Acoustic Emission*, 19, 1-10, 2001.
- [7] M. Eaton, K. Holford, C. Featherston, R. Pullin. Damage in Carbon Fibre Composites: The Discrimination of Acoustic Emission Signals Using Frequency, *Journal of Acoustic Emission*, 25, 140-148, 2007.
- [8] M. G. R. Sause, S. Horn. Simulation of acoustic emission in planar carbon fiber reinforced plastic specimens. *Journal of Nondestructive Evaluation*, 29:2, 123-142, 2010.
- [9] M. A. Hamstad, A. O. Gallagher, J. Gary. A Wavelet Transform Applied To Acoustic Emission Signals: Part I: Source Identification, *Journal of Acoustic Emission*, 20, 39-61, 2002.
- [10] M. G. R. Sause. Identification of failure mechanisms in hybrid materials utilizing pattern recognition techniques applied to acoustic emission signals. Dissertation, mbv-Verlag, Berlin, 2010.
- [11] M. G. R. Sause, A. Gribov, A. R. Unwin, S. Horn. Pattern Recognition Approach to Identify Natural Clusters of Acoustic Emission Signals, *Pattern Recognition Letters*, 2011.
- [12] A. A. Anastassopoulos, T. P. Philippidis. Clustering Methodology for the Evaluation of Acoustic Emission from Composites. *Journal of Acoustic Emission*, 13, 11-21, 1995.
- [13] S. Günter, H. Bunke. Validation indices for graph clustering. *Pattern Recognition Letters*, 24, 1107-1113, 2003.
- [14] M. G. R. Sause, S. Horn. Simulation of Lamb Wave Excitation for Different Elastic Properties and Acoustic Emission Source Geometries. *Journal of Acoustic Emission* 28, 109-121, 2010.
- [15] W.-L. Qiu, H. Joe, Generation of Random Clusters with Specified Degree of Separation. *Journal of Classification*, 23:2, 315-334, 2006.
- [16] W.-L. Qiu, H. Joe, Separation Index and Partial Membership for Clustering. *Computational Statistics and Data Analysis*, 50, 585-603, 2006.
- [17] D. L. Davies, D. W. Bouldin, A Cluster Separation Measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1:2, 224-227, 1979.
- [18] L. J. Hubert, P. Arabie, Comparing partitions. *Journal of Classification*, 2, 193-218, 1985.
- [19] P.J. Rousseeuw, Silhouettes: a graphical aid to the interpretation and validation of cluster analysis, *Journal of Computational and Applied Mathematics*, 20, 53-65, 1987.
- [20] J. T. Tou, DYNOC - A dynamic optimal cluster-seeking technique. *International Journal of Computer and Information Sciences*, 8:6, 541-547, 1979.
- [21] W.M. Rand, Objective criteria for the evaluation of clustering methods, *Journal of the American Statistical Association*, 846-850, 1979.
- [22] M. G. R. Sause. AWARE++ Software manual Rev. 1.3., <http://www.physik.uni-augsburg.de/exp2/downloads.de.html>, 2011.