

# Lokalisierung von Schallemissionsquellen in Faserverbundwerkstoffen mit künstlichen neuronalen Netzwerken

Sinan KALAFAT \*, Markus G. R. SAUSE \*

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

**Kurzfassung.** Die Lokalisierung von Schallemissionsquellen wird zur Schadensfrüherkennung und Materialcharakterisierung verwendet. In anisotropen Faserverbundwerkstoffen liefern klassische Lokalisierungsverfahren jedoch oftmals stark fehlerbehaftete Lokalisierungsergebnisse. Alternativ können zur Lokalisierung von Schallemissionsquellen künstliche neuronale Netzwerke (KNN) angewendet werden. Diese bieten unter anderem den Vorteil einer adaptiven Modellierung auf der Grundlage von experimentellen Daten. Als Testgeometrie für die Wellenausbreitung werden Platten aus Faserverbundwerkstoffen mit unterschiedlich stark ausgeprägter akustischer Anisotropie verwendet. Es werden Platten mit quasi-isotropem Lagenaufbau, einem Kreuzlagenaufbau und einem unidirektionalen Lagenaufbau untersucht. Dies bildet die maximal mögliche Varianz akustischer Anisotropie in Faserverbundwerkstoffen ab. Während einer Messung werden durch Hsu-Nielsen Quellen und piezoelektrische Pulsgeber Lambwellen erzeugt und diese durch vier multi-resonante piezoelektrische Sensoren aufgezeichnet. Die Laufzeitunterschiede der akustischen Welle zwischen den Sensoren werden als Eingabedaten für die Lokalisierung mittels KNN verwendet. Auf jeder Platte werden 121 Schallemissionsorte untersucht. Aus diesen 121 Schallemissionsorten dient eine systematisch gewählte Basis als Grundlage für die KNN Modellbildung. Die Ergebnisse der Lokalisierung von Schallemissionsquellen mit künstlichen neuronalen Netzwerken werden abschließend jeweils in Vergleich zu den Lokalisierungsergebnissen der klassischen hyperbolischen Verfahren gestellt. Die beiden verwendeten Anregungsmethoden unterscheiden sich stark in ihrer Schallemissionscharakteristik und führen zur Erzeugung unterschiedlicher Lambwellenmoden. Der Einfluss dieser unterschiedlichen Lambwellenmoden auf die Lokalisierungsgenauigkeit wird diskutiert. Die Untersuchungen zeigen, dass in den untersuchten Fällen durch eine Lokalisierung mittels KNN 20-mal so viele Schallemissionsquellen, im Vergleich zu klassischen Verfahren, lokalisiert werden können. Die Genauigkeit der Lokalisierung übertrifft in den untersuchten Strukturen die der klassischen Verfahren bis zu einem Faktor von 13.

## 1 Einführung

Lasttragende Strukturen erfahren im Allgemeinen eine anisotrope Belastung. Ein Optimum der gewichtsspezifischen Festigkeit ist dabei im Leichtbau mit carbonfaserverstärkten Kunststoffen (CFK) zu erreichen [1]. Mit diesen Materialien ist es möglich Bauteile entsprechend der zu erwartenden Belastungen auszulegen. Der komplexere Strukturaufbau, welcher für ein Optimum der gewichtsspezifischen Festigkeit verwendet wird, führt jedoch auch dazu, dass klassische Verfahren, welche für die Schadensfrüherkennung im Rahmen



einer Lokalisierung verwendet werden, nur noch eingeschränkt angewendet werden können. Dies ist darin begründet, dass eine Orientierung der Fasern, entsprechend der gewünschten Materialeigenschaften zu einer charakteristischen richtungsabhängigen Geschwindigkeit, Dispersion und Dämpfung führt. Klassische Verfahren zur Lokalisierung von Schallemissionsquellen betrachten dabei oftmals nur eine integrale isotrope Geschwindigkeit [2]. Diese Annahme führt jedoch abhängig von der Ausprägung der Anisotropie zu signifikanten Fehllokalisierungen.

Um eine zuverlässige Lokalisierung zu gewährleisten müssen neue Verfahren bzw. Algorithmen entwickelt werden, welche die Komplexität der jeweiligen Strukturen mit einbeziehen. Einige Ansätze verfolgen dazu simulationsgestützte Methoden. Die Beiträge der akustischen Anisotropie werden dabei numerisch berechnet und in Lokalisierungsmodelle mittels „Time difference of arrival“ oder „Angle of arrival“ integriert [3,9].

Einen vielversprechenden Ansatz stellt dabei eine Lokalisierung mittels künstlicher neuronaler Netzwerke dar. Mit diesen ist es möglich, ein an die Struktur angepasstes und adaptives Lokalisierungsmodell zu bilden. Die Modellierung findet dabei auf der Grundlage von experimentellen Daten statt.

Untersuchungen an unterschiedlich stark anisotropen Ausbreitungsmedien sollen zeigen, wie die Lokalisierungsgenauigkeit der neuronalen Netzwerke im Vergleich zu klassischen Verfahren ist. Als Teststrukturen werden dabei CFK-Platten mit quasi-isotropen Lagenaufbau, einem Kreuzlagenaufbau und einem unidirektionalem Lagenaufbau verwendet.

## 2 Methodik

### 2.1 Klassische Methoden

Bei der Lokalisierung von Schallemissionsereignissen ist der Entstehungszeitpunkt in der Regel nicht bekannt. Daher werden die Laufzeitunterschiede bei Ankunft des Signals zwischen zwei Sensoren betrachtet. Bei Anwendung von (1) ergeben sich daher im zweidimensionalen Fall Hyperbeln gleicher Laufzeiten. Für eine eindeutige Lokalisierung in zwei Dimensionen werden somit mindestens 3 Sensoren benötigt.

$$\vec{r}_i - \vec{r}_0 = c (t_i - t_0) \quad (1)$$

In Formel 1 ist zu erkennen, dass für die Bestimmung der Hyperbeln eine konstante Geschwindigkeit  $c$  angenommen wird. Dabei ist  $r_i$  der jeweilige Sensorort und  $t_i$  der Ankunftszeitpunkt beim jeweiligen Sensorort. Der Parameter  $r_0$  ist die Position der Schallquelle und  $t_0$  der Entstehungszeitpunkt. Ist eine bekannte bidirektionale Geschwindigkeitscharakteristik vorhanden, so kann die Geschwindigkeitsanisotropie durch eine entsprechende Skalierung der Sensorkoordinaten  $r_i$  kompensiert werden. Im Folgenden werden die Ergebnisse der Lokalisierung mittels neuronaler Netzwerke im Vergleich zu den Ergebnissen dieses verbesserten klassischen „delta-t“ Verfahrens dargestellt (Abbildung 1).

### 2.2 Neuronale Methoden

Der Vorteil von künstlichen neuronalen Netzwerken (KNN) ist die Eigenschaft der Erkennung von Mustern bzw. symbolischen Zusammenhängen aus Beispielen ohne explizite Programmierung auf das Anwendungsgebiet. Dies geschieht üblicherweise über eine Modellbildungsphase. Diese wird im KNN anhand einer repräsentativen Datenbasis approximiert, wobei der Prozess im Allgemeinen in der Terminologie der Neurowissenschaften „Lernen“ oder „Training“ des Netzwerks genannt wird. Während dieser Phase wird eine

Funktion approximiert welche die Charakteristik des untersuchten Systems wiedergibt. Nach der Modellbildungsphase kann das künstliche neuronale Netzwerk für die Approximation der gelernten Funktion an beliebigen Stellen verwendet werden.

Für die Lokalisierung von Schallemissionsquellen werden im Folgenden überwachte Lernverfahren verwendet. Als Trainingsalgorithmus werden unter anderem das Backpropagation und Derivate des Backpropagation wie z.B. das Resilient Backpropagation oder SuperSAB verwendet [4,10]. Bei diesen Verfahren wird der Netzwerkfehler durch eine Fehlerrückkopplung vom Ausgang zum Eingang über ein Gradientenverfahren minimiert. Für die Verwendung zur Lokalisierung wird in einem ersten Schritt das künstliche neuronale Netzwerk auf einen vollständigen Eingangsdatensatz trainiert. Dieser enthält die Laufzeitunterschiede zwischen den Sensoren sowie den jeweiligen Schallemissionsort und Art der Testquelle. Anschließend wird die Lokalisierungsgenauigkeit des Netzwerks anhand von Eingangsdaten überprüft die dem Netz unbekannt sind. Die Abweichung zwischen Vorhersage des Netzwerks und dem bekannten Ort der Testquelle wird als Qualitätskriterium herangezogen. Die verwendeten KNN hat dabei zwei Layer mit mindestens 2 bis maximal 10 künstlichen Neuronen. Als Aktivierungsfunktion wird für alle Neuronen eine sigmoidale  $\tanh()$  Funktion verwendet.

### 3 Experimenteller Aufbau

Für die systematische Untersuchung der Anwendbarkeit von künstlichen neuronalen Netzwerken werden CFK-Platten mit steigender akustischer Anisotropie verwendet. Die Platten wurden in einem Pressprozess entsprechend den Herstellerangaben aus dem Materialsystem Sigratex CE 1250-230-39 hergestellt. Die Plattenkonfiguration ist dabei wie folgt:

**Tabelle 1.** Plattenkonfigurationen

Konfiguration	Höhe y [cm] $\pm 0,5$	Breite x [cm] $\pm 0,5$	Dicke [mm] $\pm 0,05$
$[0_3]_{\text{sym}}$	57,5	57,8	1,26
$[0/90_2]_{\text{sym}}$	57,5	57,3	1,36
$[0/60/-60]_{\text{sym}}$	57,8	56,3	1,48

Aufgrund der verwendeten Plattendicken können mit den Testquellen nur die symmetrischen und antisymmetrischen Lambwellenmoden fundamentaler Ordnung im Frequenzbereich unterhalb 1 MHz angeregt werden.

Auf die Platten wurde ein Raster von  $11 \times 11$  Datenpunkten mit jeweils  $5 \text{ cm} \pm 0,7$  cm Abstand aufgebracht. Pro Platte ergeben sich somit 121 gleich verteilte Datenpunkte in einem Abstand von 0 cm bis 55 cm. Entsprechend des rechteckigen Messmusters wurden 4 Schallemissionssensoren (Typ WD) für die Lokalisierung verwendet. Diese wurden jeweils in einem Abstand von  $7,5 \text{ cm} \pm 0,7$  cm in x sowie auch in y Richtung von den Eckmesspunkten gesetzt. Zur Aufzeichnung der Testsignale wurde eine Abtastrate von 20 MS/s, ein Bandpassbereich von 100 kHz – 1200 kHz ein Schwellwert von 45 dB und eine Vorverstärkung von 40 dB gewählt.

Zur Erzeugung von Testsignalen wurden Hsu-Nielsen Quellen verwendet. Dabei werden Bleistiftminen mit einem Durchmesser von 0,5 mm und der Härte 2H auf eine definierte Länge von  $3 \text{ mm} \pm 0,5$  mm mit einem Druckbleistift ausgefahren und anschließend an einen Messpunkt auf der Struktur aufgebracht. Um einen definierten Bruchwinkel zu gewährleisten wird eine Führung um den Druckbleistift verwendet. Durch den Bruchvorgang werden akustische Wellen erzeugt, welche sich entsprechend im Material ausbreiten [7]. Hsu-Nielsen Quellen regen aufgrund ihrer Orientierung zur Plattenebene bevorzugt antisymmetrische Lambwellenmoden an. Die dadurch angeregte  $A_0$ -Mode ist stark niederfrequent. Da Bruchvorgänge in CFK Strukturen jedoch unterschiedliche Lambwellenmoden

und Frequenzen anregen können, müssen diese Effekte für die Lokalisierung von Schallquellen mit betrachtet werden.

Um symmetrische Lambwellenmoden mit höheren Frequenzen anzuregen wird daher eine Anregung mit Piezoaktuatoren gewählt. Ein Piezoaktor wird dabei an einem Frequenzgenerator angeschlossen und auf der Oberfläche mit einem Koppelmittel angebracht. Am Frequenzgenerator wird ein Rechteckpuls mit einer Flankenbreite von 20 ns und einer Pulsbreite von 10  $\mu$ s verwendet. Die Maximalspannung beträgt 10 V<sub>pp</sub>. Die Piezoaktuatoren haben eine kreisförmige Kontaktfläche mit einem Durchmesser von 2 cm. Beim Piezoaktor wird durch einen Kraftpuls definierter Breite eine Welle erzeugt. Die entstehende Welle hat eine Frequenzcharakteristik, welche speziell die S<sub>0</sub>-Mode stark anregt [5].

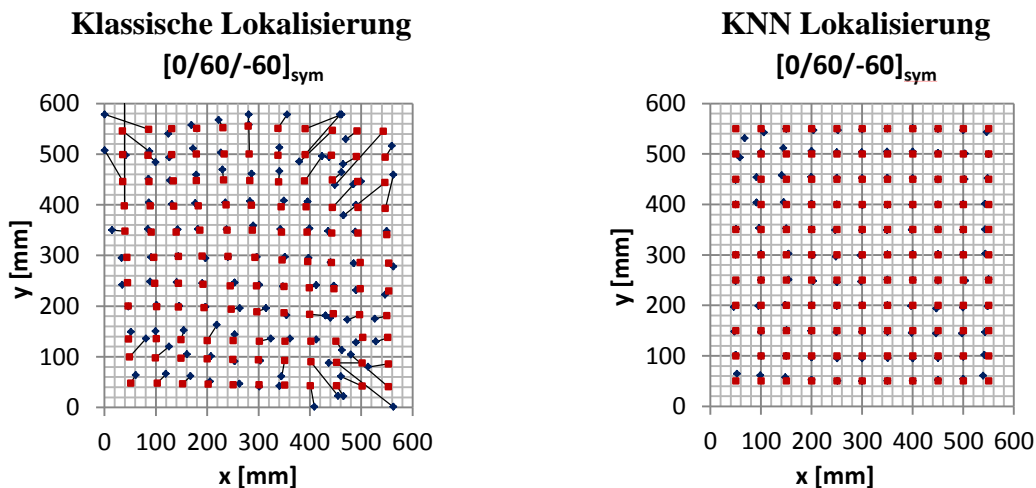
Um die Vergleichbarkeit der Ergebnisse zwischen klassischen und neuronalen Verfahren zu gewährleisten, werden nur die Erstankunftszeiten und die daraus berechneten Laufzeitunterschiede zwischen den Sensoren betrachtet. Zur Bestimmung des Ersteinsatz wurde das AIC-Kriterium verwendet [8].

## 4 Ergebnisse und Diskussion

### 4.1 Lokalisierung mit künstlichen neuronalen Netzwerken

Zunächst wird die Lokalisierungsqualität bei Verwendung einer Hsu-Nielsen Quelle auf der quasiisotropen Platte bewertet. Als Trainingsdaten dienen die 6 berechneten Laufzeitunterschiede zwischen den 4 Sensoren für alle 121 Messpunkte. Zu Beginn werden alle Messpunkte trainiert und anschließend die Anzahl der Messpunkte graduell verringert. Dadurch kann untersucht werden wie die Modellqualität sich bei weniger Trainingsdaten verändert.

So konnte im Rahmen dieser Messreihe gezeigt werden, dass die Modellqualität sich bei gleichmäßiger Verringerung der trainierten Messpunkte von 121 auf 62 kaum verändert. Die zugrunde gelegte Netzwerktopologie ist ein 5 x 5 Netzwerk.



**Abb. 1.** Links: Lokalisierungsergebnis (blau) für Testpositionen der Schallemissionsquellen (rot) mittels klassischem Verfahren. [6] Rechts: Optimales Lokalisierungsergebnis durch KNN (blau) für Testpositionen von Schallemissionsquellen (rot) bei 62 Trainingspunkten.

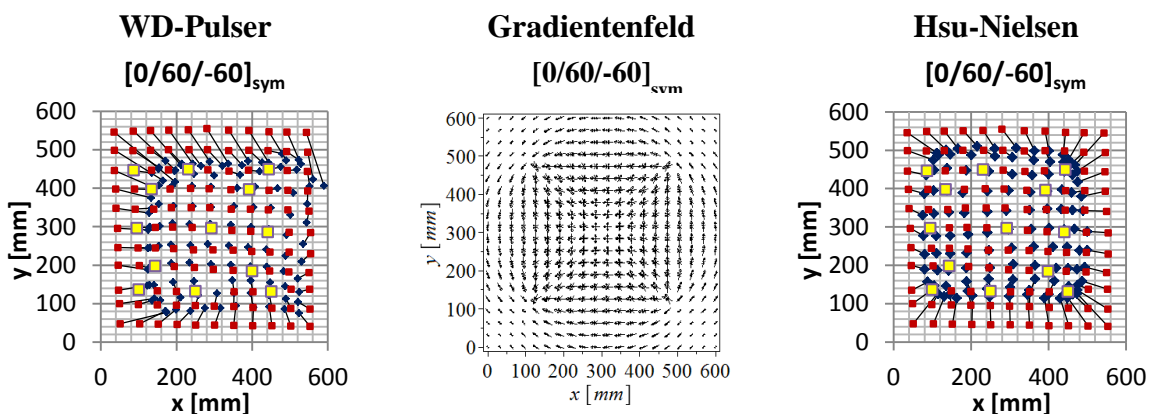
In Abbildung 1 ist der Vergleich der Lokalisierungsergebnisse für das klassische Verfahren und das künstliche neuronale Netzwerk veranschaulicht. In rot sind jeweils die verwendeten Testpositionen aufgetragen welche mit einer Hsu-Nielsen Quelle angeregt wurden. In blau sind die von den jeweiligen Verfahren bestimmten Schallemissionsorte dargestellt. Für das

klassische Verfahren ist zu erkennen, dass die Qualität der Lokalisierung zu den Außenbereichen, besonders aber zu den Sensorpositionen an den Ecken der Platte immer schlechter wird. Im Zentrum der Platte beträgt die Qualität der Lokalisierung etwa 10 mm, innerhalb des von den Sensoren aufgespannten Rechtecks ca. 15 mm im Durchschnitt. Wird der Außenbereich in die Bewertung mit einbezogen, beträgt die Lokalisierungsqualität über die gesamte Platte im Durchschnitt 23 mm.

Betrachtet man die Lokalisierungsgenauigkeit der künstlichen neuronalen Netzwerke rechts im Bild, kann festgestellt werden, dass diese im Allgemeinen homogener und genauer als die klassische Lokalisierung ist. Im Gegensatz zur klassischen Methode liefert eine Lokalisierung sehr nahe zu den Sensoren ebenfalls noch verlässliche Ergebnisse. Die Lokalisierungsqualität über die gesamte Platte betrug für das verwendete KNN 5 mm im Durchschnitt.

#### 4.2 Minimierung der Trainingsdatendichte

Da für die Anwendung in der Praxis eine Messung von Testsignalen an 62 Positionen immer noch einen erheblichen Aufwand bedeuten würde, wurde zusätzlich untersucht, wie das Verhalten der Lokalisierungsgenauigkeit bei weiterer Minimierung der Trainingsdatendichte ist. Eine stufenweise Verringerung ergab eine minimale Anzahl von nur 13 Testpositionen.



**Abb. 2.** Links: Lokalisierungsergebnis (blau) des Piezoaktuators als Schallemissionsquelle (rot) bei minimaler Trainingsdatendichte von 13 Punkten. Mitte: Darstellung des theoretischen Gradientenfeldes für alle vier Sensorpaare. Rechts: Lokalisierungsergebnis (blau) von Hsu-Nielsen Schallemissionsquellen (rot) bei minimaler Trainingsdatendichte von 13 Punkten.

Das Ergebnis eines KNN, welches mit nur 13 Messpunkten trainiert wurde ist in Abbildung 2 rechts zu sehen. Zusätzlich sind in dieser Darstellung die verwendeten Testpositionen für das Training in Gelb gekennzeichnet. Es ist zu erkennen, dass die Lokalisierungsgenauigkeit im Außenbereich der Sensoren verzerrt ist, wohingegen im mittleren Bereich immer noch eine recht genaue Lokalisierung möglich ist. Dies ist darin begründet, dass sich außerhalb der von den Sensoren aufgespannten Fläche, die Laufzeitunterschiede zwischen den Sensoren stark verändern. Das Gradientenfeld der Laufzeitunterschiede aller 4 Sensoren ist in Abbildung 2 mittig dargestellt. Innerhalb des von den Sensoren aufgespannten Rechteckes ist die Veränderung nahezu homogen, wohingegen nach außen hin besonders hinter den Sensoren die Änderung der Laufzeitunterschiede bei Veränderung des Schallemissionsortes deutlich schwächer ausfällt. Die Wahl der Laufzeitunterschiede als Eingabedaten verursacht daher sowohl für das klassische Verfahren, als auch für das KNN in diesen Bereichen eine ungenaue Lokalisierung. Für eine optimale Lokalisierung muss daher eine



Trainingsdatenbasis so gewählt werden, dass diese die physikalischen Eigenschaften des Systems, in den für die Lokalisierung relevanten Bereichen, abbildet.

#### 4.3 Vergleich zwischen Piezoaktuator und Hsu-Nielsen-Quelle


Einen zusätzlichen Einfluss auf die Lokalisierungsgenauigkeit kann die verwendete Art der Testschallquelle haben. Mittels eines Piezoaktuator werden daher höherfrequente Signale als mit der Hsu-Nielsen-Quelle erzeugt. Das zugehörige Lokalisierungsergebnis ist in Abbildung 2 links zu sehen. Dabei ist zu beachten, dass nur innerhalb des von den Sensoren aufgespannten Rechtecks trainiert wurde. Zur Bewertung der Lokalisierungsgenauigkeit werden daher auch nur die im Rechteck liegenden Daten verwendet. Als Vergleich ist das Lokalisierungsergebnis im gleichen Trainingsfeld für eine Hsu-Nielsen Quelle rechts dargestellt. Bei beiden liegt die Lokalisierungsgenauigkeit im Mittel bei 17 mm. Das erzielbare Lokalisierungsergebnis wird von unterschiedlichen Schallemissionsquellen im untersuchten Bereich somit nicht maßgeblich beeinflusst. Wird bei bekannter Emissionscharakteristik das Netzwerk auf unterschiedliche Quellen trainiert, so können mit einem Netzwerk unterschiedliche Schallemissionsquellen auch gleichzeitig lokalisiert werden [6].

#### 4.4 Einfluss der akustischen Anisotropie auf die Lokalisierungsgenauigkeit

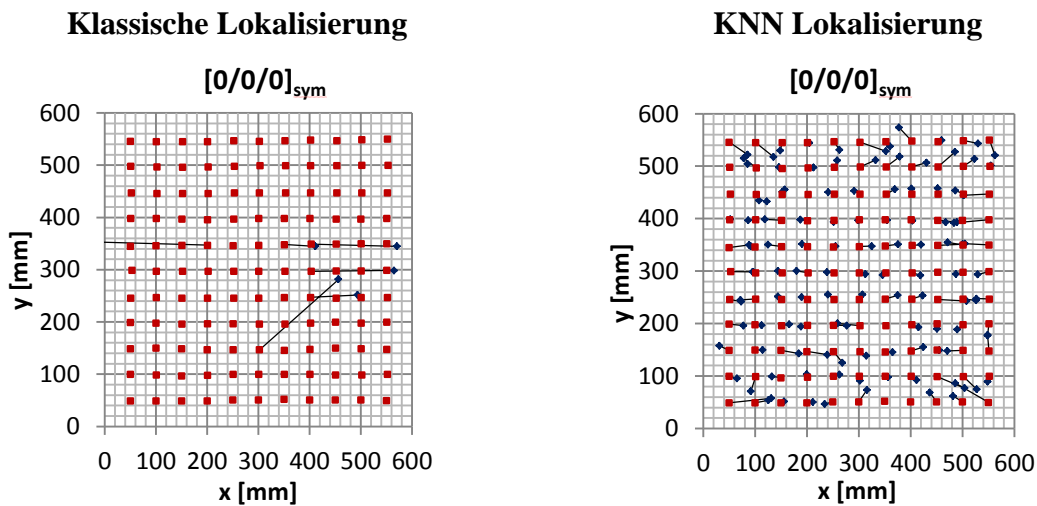
Da die Lokalisierungsergebnisse des KNN in der quasiisotropen  $[0/60/-60]_{\text{sym}}$  Platte eine deutlich höhere Genauigkeit als die klassische Methode aufweisen, wird nun das selbe Verfahren auf eine  $[0/90_2]_{\text{sym}}$  Platte und eine  $[0_3]_{\text{sym}}$  Platte angewendet, welche beide eine deutliche Geschwindigkeitsanisotropie aufweisen. Im Allgemeinen verhält sich die Qualität der Lokalisierung in diesen Strukturen bei Änderung der Trainingsdatendichte identisch zu der  $[0/60/-60]_{\text{sym}}$  Platte. Aus diesem Grund wird auf eine detaillierte Diskussion zur Untersuchung des Optimums der Modellbildung sowie auch auf das Verhalten bei Minimierung der Datenpunkte verzichtet. Sowohl die Verläufe als auch die sich ergebenden Charakteristiken sind identisch zu den zuvor beschriebenen.

Ein Schwerpunkt der untersucht wird ist die Qualität der Lokalisierung bei minimaler Datenpunktdichte. Diese konnte im quasiisotropen Fall auf mindestens 13 Datenpunkte im Inneren des von den Sensoren aufgespannten Rechtecks reduziert werden. Das Ergebnis dieser weiterführenden Untersuchungen ist in Abbildung 3 zu sehen. Dargestellt ist links das Ergebnis des klassischen Lokalisierungsverfahrens [6]. Es ist zu erkennen das lediglich 37 Punkte von 121 Punkten lokalisiert werden können, die anderen 84 Punkte können mit dem klassischen Verfahren nicht lokalisiert werden. Dies kommt daher, dass im Falle der  $[0/90_2]_{\text{sym}}$  Platte die akustische Anisotropie des Systems eine höhere Fehlbestimmung der realen Ersteinsatzzeitpunkte verursacht. Die 37 lokalisierten Punkte weisen einen Fehler von 70 mm - 80 mm auf. Das Ergebnis des KNN bei einer minimalen Datenpunktdichte von 13 Punkten ist in Abbildung 3 rechts zu sehen. Es ist zu erkennen, dass alle 121 Datenpunkte lokalisiert werden können. Des Weiteren liegt die Lokalisierungsgenauigkeit im trainierten Bereich innerhalb von 15 mm. Damit ist die Lokalisierungsgenauigkeit um einen Faktor 5 genauer als die klassische Methode.

Abschließend wird das Lokalisierungsverfahren basierend auf künstlichen neuronalen Netzwerken an einer stark anisotropen  $[0_3]_{\text{sym}}$  CFK-Platte überprüft. Auch in dieser maximal anisotropen Struktur verhält sich die Qualität der Lokalisierung mittels KNN gleich zu dem zuvor beschriebenen Verlauf.



**Abb. 3.** Links: Lokalisierungsergebnis (blau) von Schallemissionsquellen (rot) mittels klassischem Verfahren. [6] Rechts: Optimales Lokalisierungsergebnis (blau) von Schallemissionsquellen (rot) im von den Sensoren aufgespannten Rechteck mittels KNN mit minimaler Trainingsdatendichte von 13 Punkten.



**Abb. 4.** Links: Lokalisierungsergebnis (blau) von Schallemissionsquellen (rot) mittels klassischem Verfahren. [6] Rechts: Optimales Lokalisierungsergebnis (blau) von Schallemissionsquellen (rot) im gesamten Messfeld mittels KNN mit einer Trainingsdatendichte von 56 Punkten.

Dargestellt ist in Abbildung 4 links das Ergebnis einer Lokalisierung von Schallemissionsquellen mittels klassischem hyperbolischen Verfahren. In diesem Fall war es nur möglich 6 Schallemissionsorte zu lokalisieren [6]. Die Lokalisierungsgenauigkeit der Schallquellen liegt im Bereich von 100 mm - 150 mm. Im Vergleich dazu liegt die Lokalisierungsgenauigkeit mittels KNN in y-Richtung (quer zur Faser) im Mittel in einem Bereich von 11 mm und in x-Richtung bei ca. 24 mm. Auch in diesem Fall können im Gegensatz zur klassischen Methode alle Schallemissionsorte lokalisiert werden. Die Lokalisierungsgenauigkeit mittels KNN ist in x-Richtung um einen Faktor 6, in y-Richtung um einen Faktor 13 besser als die klassische Methode.

## 5 Zusammenfassung

Es konnte gezeigt werden, dass eine Lokalisierung von Schallemissionsquellen mittels KNN in allen untersuchten CFK-Platten möglich ist. Die Lokalisierungsgenauigkeit in der quasiisotropen  $[0/60/-60]_{\text{sym}}$  Platte ist mit 5 mm um einen Faktor 4 besser als die klassische Methode. Bei der Versuchsreihe zur Minimierung der Trainingsdaten konnte eine Lo-

kalisierung in einem von den Sensoren aufgespannten Rechteck mit einer Genauigkeit von 15 mm auf Basis von nur 13 Trainingsdatenpunkten durchgeführt werden.

Auch in den deutlich anisotropen  $[0/90_2]_{\text{sym}}$  und  $[0_3]_{\text{sym}}$  CFK-Platten steht die Lokalisierungsqualität der Schallemissionsorte im direkten Zusammenhang mit der Anzahl der Trainingsdaten. Mit der klassischen Lokalisierungsmethode konnten auf der  $[0/90_2]_{\text{sym}}$  Platte nur 37 von 121 Schallemissionsorten lokalisiert werden, wohingegen mittels KNN alle 121 Datenpunkte zu einem Lokalisierungsergebnis führten. Ist nur eine Lokalisierung innerhalb des von den Sensoren aufgespannten Rechtecks erforderlich, so reicht hier ebenfalls bereits eine Trainingsdatenanzahl von nur 13 Punkten um ein optimales Lokalisierungsergebnis zu erreichen. Die Grenze der Lokalisierungsgenauigkeit wird dabei von der Qualität der Ankunftszeitdifferenzen limitiert. Dies ist besonders bei der  $[0_3]_{\text{sym}}$  Platte zu erkennen. In dieser ist die Lokalisierungsgenauigkeit entlang der x- und y-Achse signifikant unterschiedlich. Dies lässt sich darauf zurückführen das Fehler bei der Bestimmung der Ankunftszeit bei der Lokalisierung entlang der Achse mit der höheren Schallgeschwindigkeit stärker niederschlägt als auf der Achse mit der geringeren Schallgeschwindigkeit.

Unter zusätzlicher Kenntnis der Testquelle des Schallemissionssignals, ist es möglich ein KNN so zu trainieren, dass die Quellorte sogar für verschiedene angeregte Lambwellenmoden lokalisiert werden können. Die Lokalisierungsqualität ist identisch zu der Lokalisierung eines einzelnen Quelltypen und hängt ebenfalls direkt von der Trainingsdatendichte und der Genauigkeit der Eingangsparameter ab.

Aufbauend auf diesen Ergebnissen sollen KNN zur Lokalisierung an komplexeren Verbundstrukturen, wie z.B. einem Drucktank aus einem hybridem CFK/Stahl Verbund, angewendet werden. Die Modellierung soll ebenfalls mit statistischen Verfahren ergänzt werden und die Erkenntnisse in einem Softwarekonzept zusammengeführt werden, welches eine Lokalisierung in beliebigen Faserverbundstrukturen ermöglichen soll.

## 6 Danksagung

Wir danken F. Schubert für die Herstellung der verwendeten Prüfkörper, sowie dem Bundesministerium für Bildung und Forschung für die Finanzierung des Projektes MAI Zfp im Rahmen des Spitzencluster MAI Carbon.

## 7 Referenzen

- [1] H. Kossira: Grundlagen des Leichtbaus: Einführung in die Theorie dünnwandiger stabförmiger Tragwerke, Springer, 1996.
- [2] C.U. Grosse, M. Ohtsu: Acoustic Emission Testing Basics for Research – Applications in Civil Engineering, Springer, 2008.
- [3] D. Aljets: Acoustic Emission Source Location in Composite Aircraft Structures using Modal Analysis, University of Glamorgan, 2011.
- [4] C. M. Bishop: Neural Networks for Pattern Recognition, Claredon Press - Oxford, 1995.
- [5] M. G. R. Sause, S. Horn: Quantification of the uncertainty of pattern recognition approaches applied to acoustic emission signals, Journal of Nondestructive Evaluation Online, 2013.
- [6] S. Kalafat: Lokalisierung von Schallemissionsquellen mit künstlichen neuronalen Netzwerken in Faserverbundwerkstoffen, Universität Augsburg, 2013.
- [7] M. Sause: Investigation of pencil lead breaks as acoustic emission sources, Journal of Acoustic Emission 29, 184 – 196, 2011.
- [8] H. Kurz : Verifikation von Bruchprozessen bei gleichzeitiger Automatisierung der Schallemissionsanalyse an Stahl- und Stahlfaserbeton, Universität Stuttgart, 2006.
- [9] D. Aljets, A. Chong, S. Wilcox: Acoustic Emission Source Location in Plate-Like Structures using a closely arranged Triangular Sensor Array, University of Glamorgan, 2010
- [10] R. Rojas: Neural Networks, A Systematic Introduction, Springer-Verlag, 1996