

# Fortschritte in der Anwendung von künstlicher Intelligenz bei der zerstörungsfreien Prüfung im Karosseriebau

Roman MAEV<sup>1</sup>, Robert KITZMANN<sup>2</sup>, York OBERDÖRFER<sup>2</sup>

<sup>1</sup> The Institute for Diagnostic Imaging Research, Physics Department, University of Windsor, Windsor, Kanada

<sup>2</sup> Tessonics Europe GmbH, Frechen

Kontakt E-Mail: york@tessonics.com

**Kurzfassung.** Um mit der steigenden Produktionsgeschwindigkeit und Vernetzung der Fertigung im Rahmen von Industrie 4.0 Schritt halten zu können, befindet sich die zerstörungsfreie Prüfung (ZfP) unter ständigen Innovationsdruck. Die Leistungsfähigkeit der Prüfsysteme kann durch maschinelle, insbesondere aber durch informationstechnische Verfahren deutlich gesteigert werden. Die in der ZfP übliche Interpretation von Bilddaten kann durch Künstliche Neuronale Netze (KNN) im Vergleich zu herkömmlichen Auswertalgorithmen signifikant beschleunigt und in ihrer Güte verbessert werden.

Zunächst erfolgt eine kurze Einführung zu KNN und eine Beschreibung der Schweißpunktprüfung mit einer integrierten Ultraschallanwendung im Automobilbau. Danach werden die Grundlagen verknüpft und mit Beispielen aus der Fertigung angereichert. Abschließend wird ein Ausblick auf weitere Anwendungsmöglichkeiten gegeben.

## Einführung

Die industrielle Fertigung unterliegt einer fortwährenden Beschleunigung bei einer sich gleichzeitig erhöhenden Komplexität. Anhand des Automobilbaus kann dies gut veranschaulicht werden. Das Ford Modell T wurde aus 1.500 Einzelteilen gefertigt. Zu Beginn der Fließbandfertigung im Jahre 1914 wurden Taktzeiten von 93 Minuten realisiert. Ein aktueller Ford F-150 besteht hingegen aus über 30.000 Einzelteilen und verlässt alle 53 Sekunden das Band. Hohe Stückzahlen in Verbindung mit kurzen Taktzeiten und gravierenden Auswirkungen bei fehlerhafter Produktion rechtfertigen enge Prüfintervalle, sogar bis zu einer 100%-Prüfung kritischer Bauteile [1].

Die zerstörungsfreie Prüfung ist eine etablierte, kosten- und ressourcensparende Methode zur Qualitätssicherung im Karosseriebau. Ein wesentliches Verfahren ist die Ultraschallprüfung [2, 3, 4]. Üblicherweise werden die Prüfstücke aus der Linie ausgeschleust und mit mobilen Endgeräten überprüft. Neben bildgebenden Technologien werden in den letzten Jahren vermehrt Inline-Systeme eingesetzt. Diese weisen aber bezüglich Geschwindigkeit, Informationsgehalt und Verlässlichkeit noch Defizite auf. Insbesondere die Aufbereitung und Bereitstellung der Messergebnisse in Quasi-Echtzeit stellt eine große Herausforderung an die Prüfsysteme dar. Durch Fortschritte in aktueller Hard- und vor allem Softwareentwicklung ist es möglich, diese Nachteile auszugleichen.

Während die bisherigen Prüfmethode der Anforderung bezüglich der Fehlererkennung weiterhin genügt, muss die Prüfgeschwindigkeit im Zusammenhang mit der Fertigungsgeschwindigkeit beständig erhöht werden. Dem hohen personellen Aufwand der ZfP kann begrenzt durch höhere Parallelisierung begegnet werden. Die



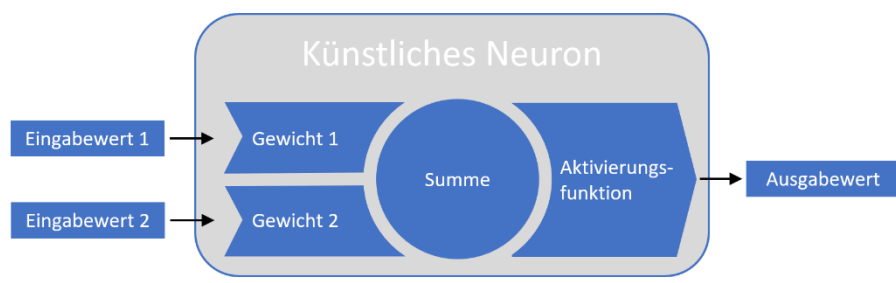
steigenden Kosten motivieren jedoch weitere Schritte in Richtung Technisierung, hier insbesondere der maschinellen Unterstützung bei der Auswertung und Interpretation der Messdaten [3]. Diese liegen oftmals in bildlicher Form vor und sind ein prädestiniertes Anwendungsfeld für moderne Algorithmen wie der Mustererkennung mithilfe neuronaler Netze.

## 1. Künstliche Neuronale Netze

Künstliche neuronale Netze bilden in Ihrer der Wirkungsweise den Lern- und Speichermechanismus des menschlichen Gehirns nach. Wie bei den biologischen Vorbildern ist die Leistungsfähigkeit eines einzelnen Neurons sehr begrenzt. Erst Vernetzung und Parallelität führen zu einem signifikanten Sprung in der Performanz.

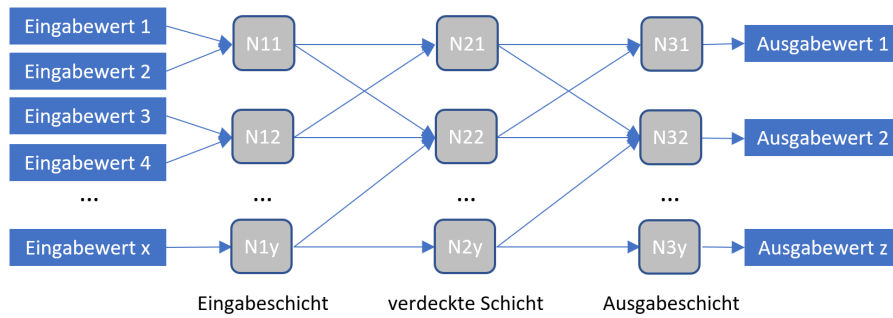
Jedes künstliche Neuron hat eine gewisse Anzahl an Signaleingängen (siehe Abb. 1). Diese Eingangssignale, gewissermaßen die künstlichen Reize, werden innerhalb des Neurons gewichtet addiert. Die Gewichtung verstärkt oder dämpft die Eingangssignale. Darin liegt ein wesentlicher Baustein des Lernprozesses. Wenn die im Neuron errechnete Summe einen vorgegebenen Schwellwert überschreitet, wird eine Antwort- oder Aktivierungsfunktion ausgelöst und ein Ausgabewert berechnet. Dieser kann wiederum als Eingangswert für weitere Neuronen dienen.

Das Trainieren des Netzwerkes geschieht durch die Veränderung der Gewichte. Jede Iteration verändert die Antwort des Neuronalen Netzes und wird so lange durchgeführt, bis die gewünschte Leistung erreicht ist. Die Antwort ist reproduzierbar, solange Gewichtung oder Verknüpfungen der Neuronen nicht verändert werden. Vereinfacht betrachtet berechnet jedes Neuronale Netz eine Vektor- oder Matrixmultiplikation eines Eingabevektors mit der Gewichtungsmatrix. [5]



**Abb. 1.** Schematische Darstellung eines künstlichen Neurons mit symbolischer Signalverarbeitung [5].


Das Netz besitzt immer eine Eingabeschicht, eine Ausgabeschicht und, je nach Komplexität der Problemstellung, oftmals mehrere verdeckte Zwischenschichten (siehe Abb. 2). Im Falle von mehreren Zwischenschichten werden diese auch als „deep neural network“ bezeichnet. Durch die Zwischenschichten wird die Anzahl der Neuronen, und damit der Gewichte, erhöht. Dadurch können die Aussagen des Modells vielschichtiger und komplexer werden. Allerdings besteht dadurch die Gefahr, einer Überanpassung (overlearning) an die Modelldaten zu erliegen. Es wird dann nicht die gewünschte Modellabstraktion, sondern auch das Rauschen in den Daten reproduziert. Ab diesem Punkt nimmt die Modellgüte mit steigender Modellkomplexität ab.



**Abb. 2.** Einfaches, künstliches neuronales Netz mit 3 Schichten und  $3y$  Neuronen (siehe Abb. 1). Die Verknüpfungen sind beispielhaft, in der Praxis werden häufig deutlich komplexere Topografien verwendet [5].

## 2. Vorstellung des RIWA-Systems

Ein System, bei dem ein KI-basierter Auswertungsansatz erfolgreich demonstriert wurde, ist das RIWA-System der Firma Tessonics. In eine Schweißzange ist in einer der Schweißelektroden ein Ultraschallprüfkopf verbaut. Dieser sendet kontinuierlich Messimpulse, welche durch das Kühlwasser und die Elektrodenkappe in den Blechstapel eindringen (siehe Abb. 3). Aufgrund von Impedanzunterschieden an Grenzflächen werden Teile des Messsignals reflektiert und gelangen zum Prüfkopf zurück. Da die Schallgeschwindigkeiten der Materialien bekannt sind, kann durch eine Laufzeitauswertung auf die räumliche Lage der Reflektoren geschlossen werden. Die Bildung, Formung und Erstarrung der Schweißlinse kann aus den Schallreflexionen direkt beobachtet werden [7].



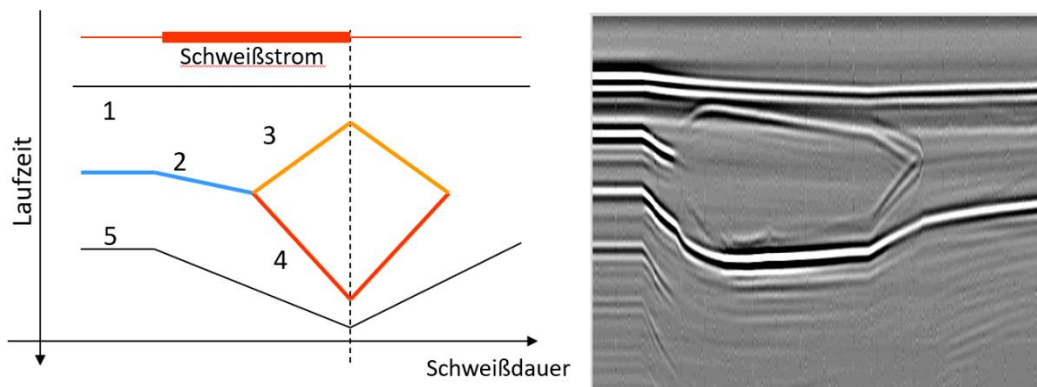
**Abb. 3.** Zusammenhang von Blechdicken, Signallaufzeiten und Aufschmelzung sowie deren Darstellung in Hochfrequenzbildern [1].

Die Darstellung der Messdaten erfolgt zunächst über so genannte A-Bilder. Die Höhe der Echos (Amplituden) werden über die Laufzeit aufgetragen. Dabei zeigen sich bereits charakteristische Muster, welche für eine grobe Einschätzung der Schweißpunktqualität

herangezogen werden können. Aussagekräftiger ist jedoch die Beobachtung der Schweißpunktbildung im Zeitverlauf. Dafür ist die Darstellung der bisher zweidimensionalen A-Bilder unzureichend, sie müssen um eine Zeitinformation ergänzt werden [7, 8].

Diese so genannten M-Bilder zeigen die Amplituden auf einer Achse nach Helligkeit kodiert, vergleichbar mit einer Höhenkarte. Auf der anderen Achse werden die einzelnen Hochfrequenzbilder nebeneinander angeordnet, das Diagramm wächst mit der Anzahl der Messungen im Zeitverlauf mit (siehe Abb. 4). Die Datenaufnahme ist zweckmäßigerweise auf einen kurzen Zeitraum im Prozessfenster beschränkt. Hier bietet sich der Empfang und die Verarbeitung entsprechender Signale der Robotersteuerung an [7, 8].

Obwohl jede einzelne Fügeverbindung eine charakteristisches M-Bild ähnlich einem Fingerabdruck aufweist, sind bestimmte Merkmale bei jeder Messung anzutreffen. Die oberste und unterste Linienschar (1, 5) kennzeichnen beispielsweise die Ober- und Unterseite des Blechstapels. Die Linienschar im mittleren Bereich (2) stellt die Fügeebene dar. Typischerweise werden sich diese Linien in der ersten Bildhälfte in einem Grauschleier verlieren, ein Indiz dafür, dass sich die Grenzfläche verflüssigt und Schweißlinse aus der Fügeebene wächst. Stattdessen treten zwei weitere Linienschar (3, 4) auf, welche die Fest-Flüssig-Grenze (3, 4) markieren. Deren Zusammentreffen zu einem späteren Zeitpunkt kann als Erstarrung der Schweißlinse verstanden werden. Auf diese Weise können 11 verschiedene, die Ausprägung der Schweißlinse charakterisierenden Merkmale identifiziert werden [1].



**Abb. 4.** Schematische Darstellung des M-Bildes (links) mit Beschriftung gemäß Abb. 3. Im Vergleich dazu ein M-Bild, aufgenommen mit dem RIWA-System. Deutlich erkennbar die Verlängerung der Signallaufzeit und das Erstarren der Schweißlinse. [1, 6].

### 3. Motivation für die Verwendung künstlicher Intelligenz

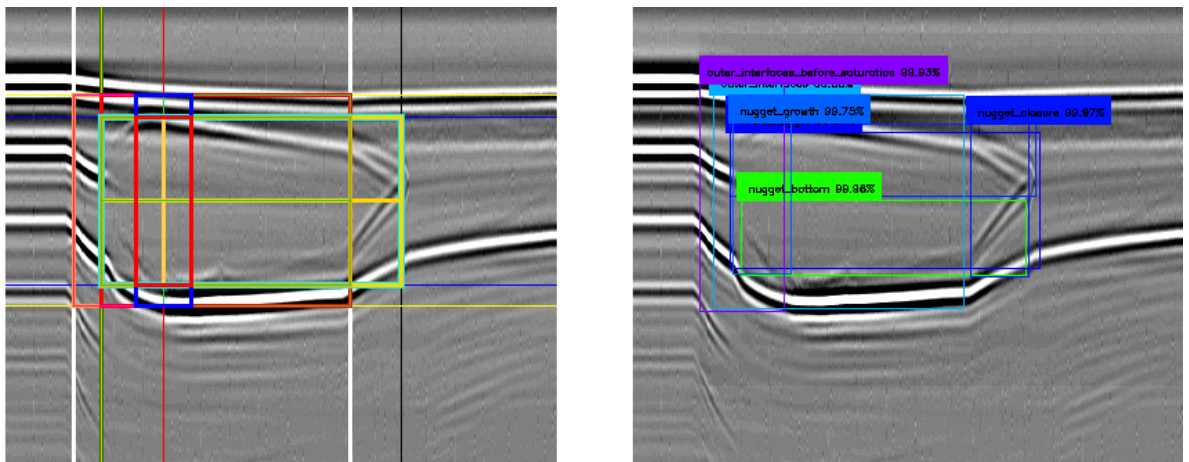
Die Erkennung der Merkmale und deren Verortung innerhalb des M-Bildes sollte im Sinne der ZfP 4.0 automatisiert erfolgen. Bisher wurden dafür Zielbereiche im Bild festgelegt, in denen ein bestimmtes Merkmal auftreten musste. Dieses Verfahren erfordert jedoch eine genaue Kenntnis vom zeitlichen Verlauf der einzelnen Etappen des Schweißprozesses. Darüber hinaus können zeitliche oder räumliche Abweichungen, wie sie zum Beispiel durch die Verwendungen adaptiver Schweißsteuerungen oder beim Auftreten von Schweißspritzern vorkommen, aufgrund der vielfältigen Variationen nur ungenügend berücksichtigt werden. Selbst der Abnutzung der Schweißelektroden kann nur bedingt

Rechnung getragen werden. Die Hauptforderung lautet nunmehr nach einem flexiblen System, welches die relevanten Bereiche innerhalb des kurzen Prozessfensters zuverlässig identifizieren kann.

#### 4. Anlernen des Neuronalen Netzes

Als Trainingsdaten wurden Messungen von über 47.000 Schweißpunkten verwendet. Neben den M-Bildern gehören dazu auch Metadaten wie Schweißzeiten, Werkstoff- und Blechdickenkombinationen. Für den Anlernprozess wurden bei über 22.000 M-Bildern die entsprechenden Merkmale per Hand eingetragen, so dass das neuronale Netz diese zum Abgleich mit den Ausgabewerten verwenden konnte (Abb. 5). Die Optimierung der Gewichtung, der Summen- und Aktivierungsfunktionen benötigt auf handelsüblicher Hardware zwischen 75 und 200 Stunden.

Die weit überwiegende Anzahl der Schweißpunkte in den Trainingsdaten sind qualitätsgerecht. Daher wurde durch gezielte Auswahl von nicht qualitätsgerechten Punkten ein so genannter balancierter Datensatz erstellt. Würden die Modelle mit der realen Häufigkeit von beispielsweise Schweißspritzern trainiert werden, so würden diese bei der späteren Anwendung mit einer vergleichbar geringen Wahrscheinlichkeit detektiert werden. Darüber hinaus ist auf ein möglichst breites Spektrum in Bezug auf die spätere Anwendung zu achten. So umfasst der Datensatz Linsen bis 6 Millimeter Durchmesser und Materialdickenkombinationen von 0,7 bis 1,9 Millimeter, jeweils in Zwei- und Dreiblechverbindungen. Zusätzlich wird unterschiedlichen Werkstofffestigkeiten und, damit einhergehend, auch unterschiedlichen Blechverformungen Rechnung getragen.



**Abb. 5.** Darstellung von M-Bildern desselben Schweißpunktes wie aus Abb. 4. Die von Hand eingetragenen Markierungen für die Anlernung des Algorithmus sind farbig hervorgehoben (links). Im Vergleich dazu die vom KNN erkannten Muster (rechts). Überschneidungen der computergenerierten Markierungen werden durch einen geringeren Konfidenzwert bestraft (siehe Beschriftung) [1].

Das Anlernen kann ist ein fortwährender, iterativer Prozess. Neue Materialkombinationen oder beobachtete Sondereffekte wie mehrfache Spritzerbildung können durch Hinzufügen entsprechender Trainingsdaten nachträglich eingepflegt werden. In der Regel sind 150, in

seltenen Fällen 500 Messungen dafür notwendig. So kann neuen Problemstellungen mit angepassten oder erweiterten Lösungsstrategien begegnet werden.

Der Lernfortschritt des Netzes kann durch ständigen Abgleich mit weiteren Datensätzen überwacht werden. Dies können einerseits zusätzliche Messdaten sein. Darüber hinaus kann durch geringfügige Mutation bereits vorhandenen Daten, beispielsweise durch Einfügen von Rauschen, Rotation, Verzerren und/oder Zuschneiden der Bilder, die Datenbasis künstlich erweitert werden. Insbesondere zu Beginn des Anlernprozesses kann dieses Vorgehen interessant sein.

## **5. Ergebnisse des Neuronalen Netzes**

Nach der oben geschilderten Anlernphase wurden die KNN in der Serienfertigung eingesetzt. Es konnte gezeigt werden, dass für jedes der 11 charakteristischen Merkmale eine Erkennungsrate von mindestens 97% gewährleistet werden kann. Die falsch-positiv-Rate liegt bei unter 2%. Darüber hinaus wurde festgestellt, dass zur Einschätzung der Schweißpunktqualität nicht alle 11 Merkmale korrekt erkannt werden müssen. Einerseits wird jedem Merkmal ein Vertrauens- oder Konfidenzwert zugewiesen. Liegt dieser unterhalb einer bestimmten Schwelle, geht dieser mit weniger Gewicht in die Gesamtbeurteilung ein. Andererseits ergeben sich Redundanzen, so dass einzelne Merkmale auch komplett wegfallen können.

Diesem Umstand konnte bei der bisherigen Auswertung über starre Algorithmen nur unzureichend Rechnung getragen werden. Darüber hinaus ist die Flexibilität des gezeigten Ansatzes deutlich höher und, im Sinne der ZfP 4.0, auch wesentlich performanter. Während die bisherige Auswertung zunächst nach Prozessende (post-process) erfolgte, ist nunmehr die Auswertung zur Prozesslaufzeit (in-process) möglich. Das bedeutet die Qualitätsentscheidung wird getroffen, bevor der folgende Schweißpunkt gefertigt wird.

## **6. Ausblick**

Die hier vorgestellten Ergebnisse zeigen Auswertungen, die nach abgeschlossenen Schweißvorgängen durchgeführt wurden. Die KNN wurde auf M-Bilder angewandt, die einen ganzen Schweißvorgang abbilden. Dies ist allerdings keine Voraussetzung, sondern es besteht die Möglichkeit, die KNN mit M-Bild-Segmenten anzulernen, die eine deutlich kürzere Zeitspanne des Schweißvorgangs darstellen. Damit wäre die KNN in der Lage, Aussagen zur Qualität des Schweißprozesses schon während des Schweißprozesses zu geben. Diese Qualitätsaussagen ließen sich dann konsequenter Weise als Feedback-Signal für den Schweißcontroller nutzen, der daraufhin – im Falle einer sich anbahnenden schlechten Schweißung – seine Parameter adaptiv derart anpassen könnte, so dass eine den Qualitätsanforderungen genügende Schweißlinse entsteht.

Die dahingehende Weiterentwicklung des hier vorgestellten Systems wird in Kürze verfügbar sein.

## Referenzen

- [1] Maev, R. Gr, Chertov, A., Scott, R., Stocco, D., Oulette, A., Denisov, A. Oberdörfer, Y. (2021): NDE in The Automotive Sector, in: Meyendorf, N. et. al., Handbook of Nondestructive Evolution 4.0, Springer Nature Switzerland AG.
- [2] Summerville, C., Compston, P., Doolan, M. (2019): A comparison of resistance spot weld quality assessment techniques. 18th International Conference on Sheet Metal SHEMET 2019.
- [3] Lehmann, N., Jüttner, S. (2017): Automatisierte Luftultraschallprüfung im Automobilbau, DGZfP-Seminar des FA Ultraschallprüfung 2017.
- [4] Maev, R. Gr., Seviaryn, F. (2011): Ultrasonic Imaging Inspection of Projection Welds, 5th Pan American Conference for NDT, Cancun, Mexiko.
- [5] Hilbert, A. (2001): Künstliche neuronale Netze im Data Mining, in: Schneider, D., Pflaumer, P., Power Tools: Management-, Beratungs- und Controllinginstrumente, Gabler Verlag.
- [6] Chertov, A., Maev, R. Gr. (2004): Determination of resistance spot weld quality in real time using reflected acoustic waves. Comparison with through-transmission mode.
- [7] Andreoli, A. F., Chertov, A., Maev, R. Gr. (2016): Correlation between Peel Test and Real Time Ultrasonic Test for Quality Diagnosis in Resistance Spot Welding.
- [8] Baradarani, A., Khanli, L.M., Chertov, A.M., Regelado, W. P., Maev, R. Gr. (2017): Efficient Feature Extraction in Ultrasonic Spot Weld Inspection, in: 30th Canadian Conference on Electrical and Computer Engineering.
- [9] Müller, S. (2014): Füge-technologien für den Karosserie-Leichtbau, Audi AG, [https://www.fast.kit.edu/download/DownloadsLeichtbautechnologie/Fuegen\\_Leichtbau\\_Uni\\_Karlsruhe\\_070214\\_kompr.pdf](https://www.fast.kit.edu/download/DownloadsLeichtbautechnologie/Fuegen_Leichtbau_Uni_Karlsruhe_070214_kompr.pdf).
- [10] Baccan, F. (2017): The New Chevrolet Cruze Sport6, in: SAE Brazil CarBody Symposium 2017.