

# Simulationsbasiertes Deep Learning-Modell für die Detektion von Fehlstellen in Betonstrukturen

Claudia THURNHERR<sup>1</sup>, Aurelia MULLER<sup>1</sup>, Daniel ALGERNON<sup>1</sup>

<sup>1</sup> SVTI Schweizerischer Verein für technische Inspektionen, Wallisellen, Schweiz

Kontakt E-Mail: [claudia.thurnherr@svti.ch](mailto:claudia.thurnherr@svti.ch)

**Kurzfassung.** Das Ziel der aktuellen Arbeit liegt in der Entwicklung eines Deep Learning-Modells zur Detektion und Charakterisierung relevanter Fehlstellen in Stahlbetonstrukturen. Insbesondere erfolgt dies unter Berücksichtigung einer mitunter starken Beeinträchtigung der Signale durch das materialbedingte Gefügerauschen. Das Trainieren anwendungsorientierter Deep Learning-Modelle verlangt ein grosses und vollständiges Datenset. Eine experimentelle Datenerhebung ist allerdings aufgrund des Designs und der Herstellbarkeit von Testproben in ihrer Menge beschränkt. Ein Deep Learning-Modell alleine mit experimentellen Daten zu trainieren, ist daher fast nicht möglich. Daher werden in der aktuellen Studie verschiedene virtuelle Ultraschalluntersuchungen mit der kommerziellen Simulationssoftware CIVA durchgeführt. Die Simulationen berücksichtigen dabei strukturbedingtes Rauschen, um die Detektion von Fehlstellen in Beton so realistisch wie möglich abzubilden. Beispielhaft werden hierfür Kiesnester betrachtet. Die Nutzung von Simulation bietet hierbei die Chance, eine grosse Datenmenge zu erzeugen, was für das zuverlässige Trainieren von Deep Learning-Modellen unabdingbar ist. Zudem können die Parameter mithilfe der Simulation systematisch variiert werden, was ein umfangreiches Datenset garantiert. Die Simulationsdaten, welche Rauschsignale enthalten, werden anschliessend genutzt, um mit der intern entwickelten Software Echolyst A.I. ein Deep Learning-Modell zu trainieren. Abschliessend wird dieses Modell getestet und validiert. Die Studie zeigt das Potenzial von künstlicher Intelligenz, um die Effektivität von Ultraschallprüfungen zur Detektion von Fehlstellen in Betonstrukturen deutlich zu steigern.

## Einführung

Die Sicherstellung der Dauerhaftigkeit von Betonstrukturen ist ein wichtiger Aspekt unserer Infrastruktur. Nebst einer fehlerhaften Auslegung oder Herstellung können auch im Laufe der Lebensdauer Fehlstellen in Betonstrukturen entstehen. Daher ist eine zuverlässige Detektion solcher Fehlstellen in der Bauwerksdiagnose von grosser Bedeutung. Die Zerstörungsfreie Prüfung (ZfP) im Bauwesen (ZfPBau) bietet hierzu diverse moderne Verfahren, wie z.B. Ultraschall. Diese Messmethoden liefern große Datenmengen, woraus Informationen für die Analyse zu extrahieren sind. Eine automatisierte Auswertung von Ultraschalldaten und deren Untersuchung auf Fehlstellen in der Struktur würde den Analyseprozess daher stark vereinfachen und beschleunigen. Eine Berücksichtigung des gesamten Signals ist allerdings mit herkömmlichen und analytischen Methoden komplex. Dies ist aufgrund von Artefakten und Störungen wie dem Gefügerauschen allerdings ein




wichtiger Aspekt. Methoden der Datenwissenschaften und insbesondere der künstlichen Intelligenz haben das Potenzial, das volle Signal zu analysieren und so automatisiert Fehlstellen zu erkennen [1, 2]. Insbesondere die Nutzung von neuronalen Netzwerken (Deep Learning) bietet hierzu gute Möglichkeiten [3, 4]. In vielen Industriezweigen wie z.B. der Medizin und Biotechnologie wird maschinelles Lernen bereits erfolgreich angewendet [5]. Auch in der ZfPBau wurde Machine Learning bereits in einigen Studien z.B. zur Datenfusion verwendet [6]. Häufig wird dabei überwachtes („supervised“) Lernen angewendet, bei dem *a-priori* der Inputvariable der Trainingsdaten die korrekte Zielvariable zugeordnet wird [7].

Ziel der vorliegenden Arbeit ist die Entwicklung eines Deep Learning-Modells, welches Ultraschalldaten analysiert und daraus im Sinne einer Klassifizierung automatisch Fehlstellen detektiert. Dies wird am Beispiel von Kiesnestern demonstriert. Kiesnester entstehen durch Entmischen während des Betonierens und stellen eine signifikante Gefahr für eine bewehrte Betonstruktur dar [8, 9, 10, 11]. Im Modell wird jeder Scanpunkt ausgewertet und als „Fehlstelle“ oder „keine Fehlstelle“ klassifiziert. Das verwendete Deep Learning-Modell wird dabei mit CIVA-Simulationsergebnissen trainiert, welches verschiedene Fehlstellen-Größen, -Positionen und Wandstärken betrachtet. Um eine Übertragung auf experimentelle Daten zu ermöglichen, ist die realistische Modellierung des Simulationsproblem essenziell, weshalb das Gefügerauschen mithilfe von Superposition adressiert wird. Dies führt zu einer numerisch effizienten Modellierung, was für das Erstellen von ausreichend großen Datensätzen für das maschinelle Lernen sehr wichtig ist.

Das Manuskript beinhaltet in einem ersten Abschnitt eine Beschreibung der Simulationen von Ultraschallinspektionen in Betonbauten. Anschließend wird der verwendete Simulationsworkflow präsentiert, welcher für die Erzeugung des Datensets angewendet wird. Danach werden das Deep Learning-Modell sowie der zugrunde liegende Algorithmus sowie die Modellparameter aufgezeigt. Abschließend werden die Resultate sowie ein Fazit mit Ausblick präsentiert.

## 1. Ultraschallinspektion in Beton

In der aktuellen Studie wird die Inspektion von Betonstrukturen mit Ultraschall untersucht. Hierbei gilt es zu beachten, dass im Beton im Vergleich zu Metallen andere Fehlstellen auftreten, wie z.B. Delaminationen oder Kiesnester. Die zerstörungsfreie Untersuchung der Bewehrungsüberdeckung ist mit magnetisch-induktiven Verfahren etabliert [12, 13]. Der Nachweis von fehlerfreiem Beton mit zerstörungsfreien Methoden wird hingegen aktuell nur in Einzelfällen angewendet. Um die Qualität und Dauerhaftigkeit von Betonstrukturen zu prüfen, müssen daher diese Fehlstellen zuverlässig detektiert werden können. In Betonstrukturen ist die Ultraschall-Antwort stark von Gefügerauschen beeinflusst, was bei der Untersuchung und Simulation von Ultraschallinspektionen berücksichtigt werden muss, um die Realität akkurat abbilden zu können. Im Vergleich zu Metallen werden für Beton auch andere Arten von Ultraschallköpfen verwendet, namentlich werden hierzu Transversalwellen ausgesendet. Hierfür wurde in der kommerziellen Software CIVA [14] durch die Softwareentwickler EXTENDE eine neue Art von Prüfkopf implementiert („Shear vibration (along x)“ verfügbar ab Version 2021), um Transversalwellenprüfköpfe abzubilden, siehe **Abb. 1**.



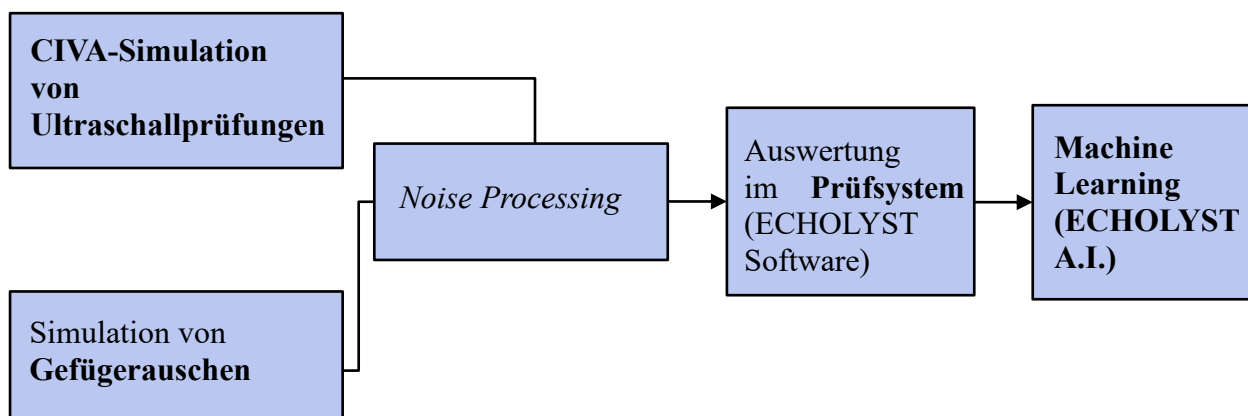
**Abb. 1:** Simulation einer Betoninspektion mit Transversalwellenprüfkopf

## 2. Modellierung und Simulationsworkflow

Im Folgenden wird der verwendete Simulationsworkflow zur Erzeugung von CIVA-Simulationsergebnissen dargestellt. Anschließend wird die CIVA-Simulation von Kiesnestern sowie die CIVA-Simulation von Gefügerauschen und das Zusammenführen der beiden Simulationen genauer beschrieben.

### *Simulationsworkflow*

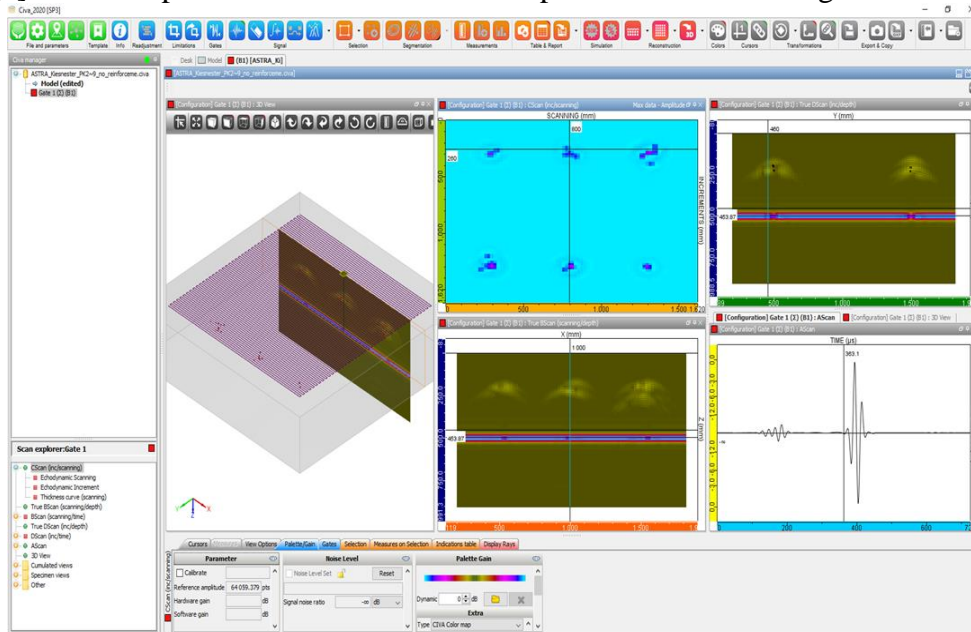
Grundsätzlich ist es in CIVA möglich, in jeder beliebigen Simulation Gefügerauschen zu berücksichtigen. Dies ist allerdings rechnerisch sehr aufwendig und führt zu langen Simulationszeiten, was für das Erzeugen von großen Datenmengen (wie sie für Deep Learning benötigt werden) nicht zweckmäßig ist. Daher wird ein Simulationsworkflow vorgeschlagen, welcher ein effizientes Simulieren von Ultraschallinspektionen unter Berücksichtigung von Gefügerauschen ermöglicht, siehe **Abb. 2**. Dabei wird zuerst das Inspektionsproblem in einer CIVA-Simulation ohne Gefügerauschen abgebildet. Zusätzlich wird zufälliges Gefügerauschen simuliert. Anschließend wird in einem Noise Processing die CIVA-Simulation mithilfe von Superposition mit dem Gefügerauschen überlagert. Dadurch muss das Gefügerauschen nur einmal simuliert werden und kann danach beliebig mit Ultraschall-Simulationen kombiniert werden. Dadurch kann die Rechenzeit enorm reduziert werden, was ein Schlüssel für die Erzeugung von großen Datensets darstellt. Anschließend werden die Daten in ECHOLYST [15] ausgewertet und für die Anwendung von Machine Learning in ECHOLYST A.I. überführt.



**Abb. 2:** Simulationsworkflow

## Modellierung von Kiesnestern in CIVA

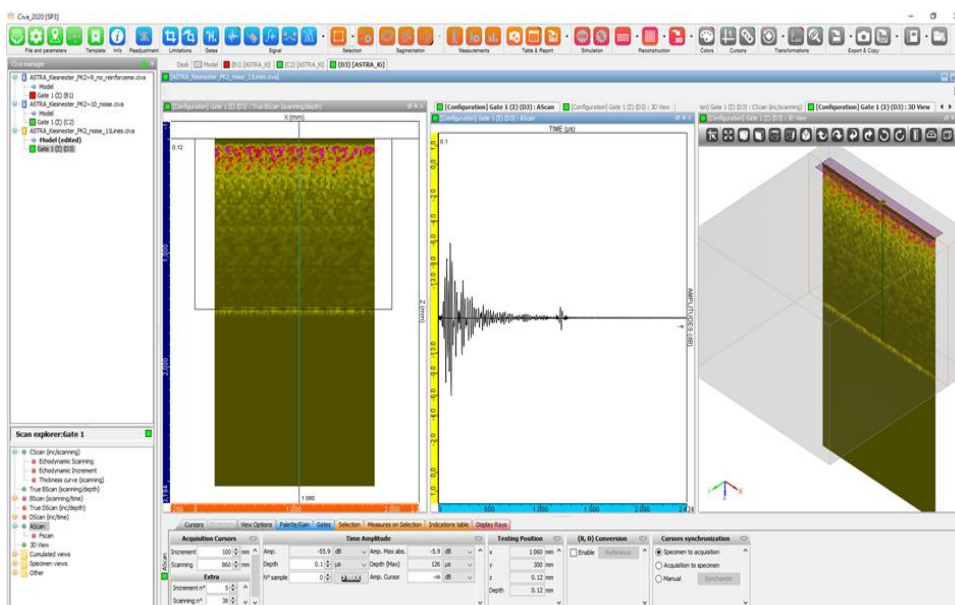
Bei der untersuchten Simulation handelt es sich um eine dry-contact Matrix-Phased-Array-Simulation in CIVA mit einer Mittenfrequenz von 50kHz. Pro Simulation wird jeweils ein Netz von 82x82 Punkten gescannt. Die Kiesnester werden in CIVA als eine Agglomeration von kleinen sphärischen Fehlstellen modelliert, da sich in einer vorherigen Studie gezeigt hat, dass diese Modellierung im Vergleich mit experimentellen Daten die besten Ergebnisse liefert [8]. Eine entsprechende Simulation ist beispielhaft in **Abb. 3** dargestellt.



**Abb. 3:** CIVA-Simulation einer Phased-Array-Ultraschallinspektion am Beispiel von Kiesnestern

## Modellierung von Gefügerauschen in CIVA

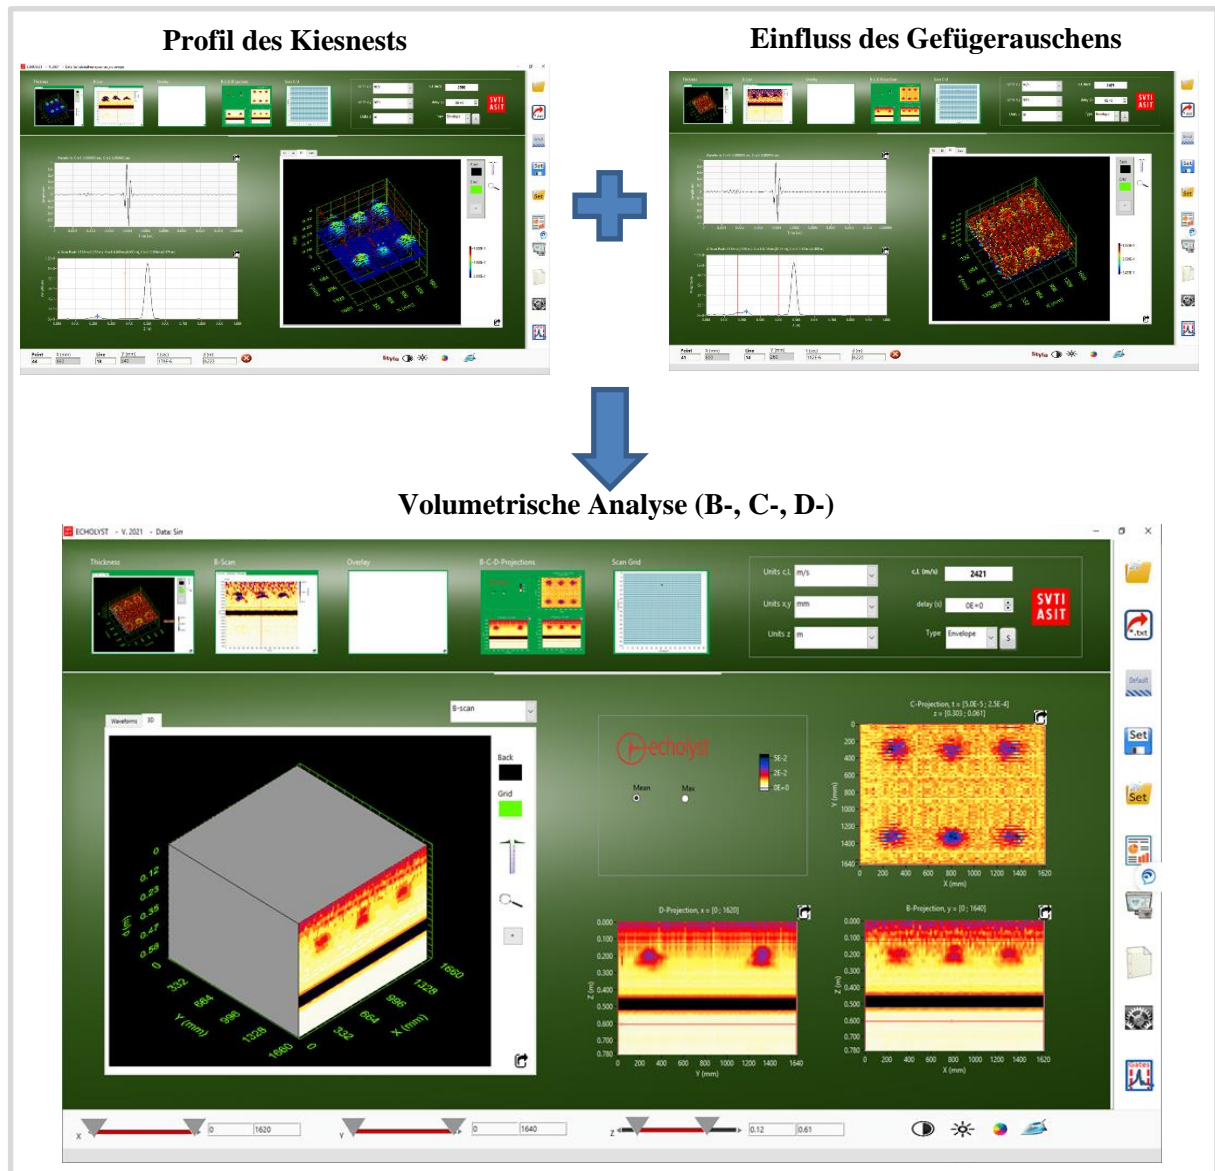
In **Abb. 4** ist die Simulation von Gefügerauschen für mehrere Scanlinien dargestellt. Hierbei wird ein Ausschnitt aus einem Betonblock (ohne Fehlstellen) unter Berücksichtigung von Gefügerauschen („noise“) gescannt.



**Abb. 4:** CIVA-Simulation von Gefügerauschen

## Analyse der kombinierten Simulation von Kiesnestern und Gefügerauschen

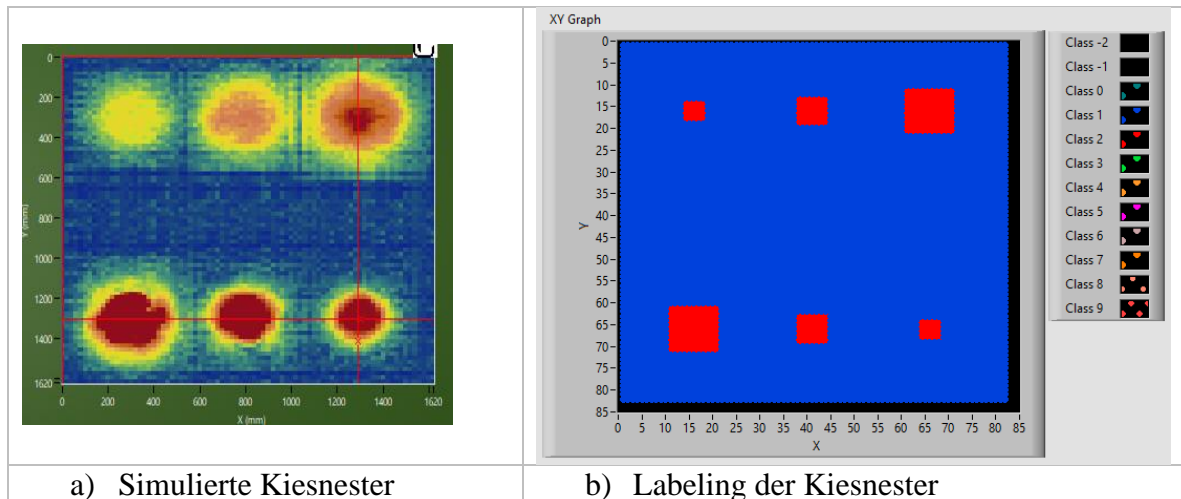
Die folgende Darstellung, **Abb. 5**, zeigt die Kombination der Inspektions- und Gefügerauschensimulation. Zur besseren Übersicht und Analyse werden diese Daten in der Software ECHOLYST dargestellt. Die Darstellung zeigt, dass mit dem Superpositionsansatz realistische Ultraschalldaten erzeugt werden können.



**Abb. 5:** Analyse von zusammengeführten Ultraschall- und Gefügerauschensimulationen in ECHOLYST, um realistische Inspektionsdaten zu erzeugen

### 3. Deep Learning-Modell

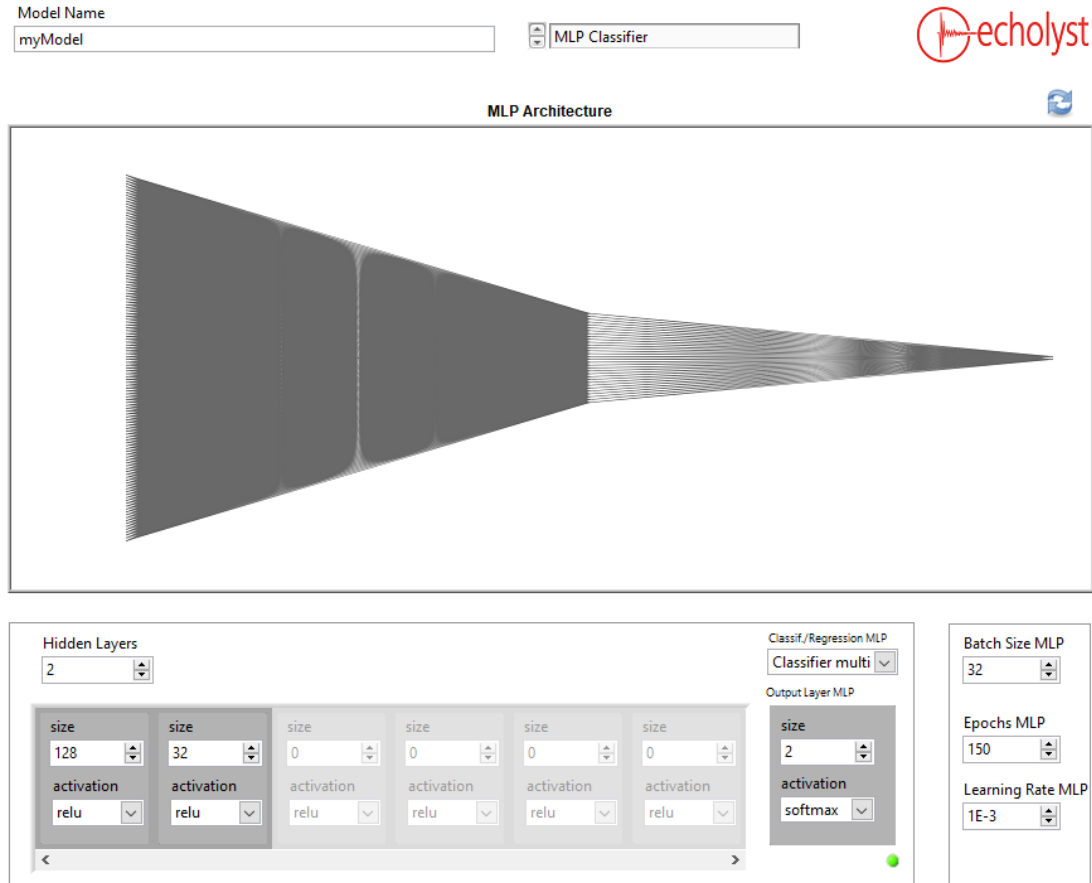
Die so erzeugten Simulationsdaten werden nun genutzt, um ein Deep Learning-Modell zu trainieren. Dabei wird überwachtes („supervised“) Lernen angewendet und die Daten werden zu Beginn als „Fehlstelle“ oder „keine Fehlstelle“ gelabelt, siehe **Abb. 6**.



**Abb. 6:** Prinzip des Labelings der Daten als Klasse 1 "kein Kiesnest" (blau) und Klasse 2 "Kiesnest" (rot), a) simulierte Kiesnester und b) Labeling der Kiesnester

Das Datenset wird für das Trainieren des Algorithmus aufgesplittet in Trainings- und Testdaten. Dabei werden 60% der Daten fürs Training und die restlichen 40% für die Validierung verwendet.

Die Architektur des Deep Learning-Modells ist in **Abb. 7** dargestellt. Es wird ein MLP-Klassifizierungsalgorithmus mit zwei versteckten Schichten („hidden layers“) verwendet. Das Training wird in Echolyst A.I. realisiert, welches mit integrierten Python-Skripts arbeitet, die Keras TensorFlow Skripts verwenden [16]. Das Modell erreicht eine Trainingsgenauigkeit von 99% und eine Validierungsgenauigkeit von knapp 94%.




**Abb. 7:** Algorithmus-Architektur

#### 4. Anwendung des Deep Learning-Modells für Vorhersagen

**Abb. 8** zeigt die Vorhersage von Kiesnestern (rot) angewendet auf simulierte Ultraschalldaten. Die Darstellung zeigt, dass das Deep Learning-Modell eindeutig einen Trend im Bereich der erwarteten Kiesnester erkennt. Der Algorithmus muss allerdings noch detaillierter trainiert und abgestimmt werden, um die Vorhersagen noch weiter zu präzisieren. Die ersten Ergebnisse sind aber bereits sehr vielversprechend.

Aktuell findet zudem eine weitere Optimierung des Modells zur Übertragung auf experimentell erhobene Ultraschalldaten statt.



**Abb. 8:** Analyse von simulierten Ultraschalldaten mit dem Machine Learning-Modell zur Auffindung von Kiesnestern

#### 5. Fazit

In der vorliegenden Arbeit wurde ein effizienter Workflow zur Simulation von Ultraschallinspektionen unter Berücksichtigung von Gefügerauschen in Betonstrukturen vorgestellt. Dabei wird die Simulation der Fehlstelle und die Simulation des Gefügerauschens separat durchgeführt und in einem anschließenden Noise Processing zusammengeführt. Dadurch muss das Gefügerauschen nur einmal simuliert werden und kann anschließend beliebig kombiniert werden, was den Rechenaufwand deutlich reduziert. Die so erzeugten Simulationsdaten wurden anschließend genutzt, um ein Deep Learning-Modell zu trainieren, mit dem Ziel, Fehlstellen automatisch zu identifizieren. Dies wurde erfolgreich mit simulierten Daten von Kiesnestern demonstriert.

## 6. Ausblick

Die ersten Resultate des Deep Learning-Modells sind sehr vielversprechend und das Modell sollte daher weiterverfolgt und optimiert werden. In einer nächsten Studie sollen verschiedene Niveaus von Gefügerauschen weiter untersucht werden, um die Ultraschallinspektion noch realistischer darstellen zu können. Zudem soll das Deep Learning-Modell erweitert werden, mit dem Ziel, experimentelle Daten akkurat auf Fehlstellen untersuchen zu können. Diesbezüglich sollen auch andere Algorithmen wie zum Beispiel Convolutional Neural Networks getestet werden. Zukünftig soll das Modell auf weitere Arten von Fehlstellen ausgebaut werden, was eine automatisierte und schnelle Auswertung von Ultraschallmessdaten ermöglichen würde.

## Referenzen

- [1] D. Algernon, „Machine Learning – Potenzial und Anwendung in der Zerstörungsfreien Bauwerksprüfung,“ in *Fachtagung Bauwerksdiagnose 2020*, Berlin, 2020.
- [2] M. Kearns und U. Vazirani, *Computational Learning Theory*, Cambridge, MA: MIT Press, 1994.
- [3] I. Goodfellow, Y. Bengio und A. Courville, *Deep Learning*, MIT Press, 2016.
- [4] T. Hastie, R. Tibshirani und J. Friedman, *The elements of Statistical Learning - Data Mining, Inference, and Prediction*, Berlin: Springer-Verlag, 2001.
- [5] P. Baldi und S. Brunak, *Bioinformatics: A Machine Learning Approach*, Cambridge, MA: MIT Press., 2002.
- [6] C. Völker, *Datenfusion zur verbesserten Fehlstellendetektion bei der zerstörungsfreien Prüfung von Betonbauwerken*, Berlin: Universität des Saarlandes, 2017.
- [7] T. Mitchell, *Machine Learning*, New York: Mc Graw-Hill, 1997.
- [8] D. Algernon, S. Feistkorn, Y. Schiegg und B. Mühlán, „Zerstörungsfreie Detektion von Kiesnestern in Stahlbetonbauteilen,“ *ASTRA Forschungsbericht*, 2021.
- [9] F. "Stützmauern": „er Einsturz am Brenner rückt die Stützmauern stärker in den Fokus von Forschung und Erhaltung,“ *Strasse und Verkehr*, p. Ausgabe 11, 2017.
- [10] W. Kaufmann, „AGB-Forschungsprojekt 2015/028 Tragwiderstand und Verformungsvermögen von Winkelstützmauern bei lokaler Korrosion der Bewehrung“ *.ETHZ-IBK*.
- [11] Cemsuisse, „Sichtbeton - Vorbeugende Massnahmen,“ [Online]. Available: [http://www.cemsuisse.ch/sichtbeton/maengel/maengel\\_kiesnester/index.html?lang=de](http://www.cemsuisse.ch/sichtbeton/maengel/maengel_kiesnester/index.html?lang=de). [Zugriff am 20 10 2018].
- [12] „Merkblatt zur zerstörungsfreien Bewehrungsüberdeckungsmessung und Bewehrungsörtung an Stahl- und Spannbetonbauteilen,“ *DGZFP Merkblatt B02*, p. 54, April 2014.
- [13] A. Taffe und B. Jungen, „Untersuchungen zur Genauigkeit von magnetisch induktiven Bewehrungsüberdeckungsmessungen,“ *Beton- und Stahlbetonbau*, pp. 484-495, 2016.
- [14] E. S.A., „General Introduction to CIVA,“ Massy.
- [15] D. Algernon, „ECHOLYST - Entwicklung eines anwenderorientierten Impact-Echo-Systems für Scanning, Visualisierung und Machine Learning,“ *DGZfP-Zeitung*, 2021.
- [16] M. Abdolajnejad, R. Bhagwat und M. Moocar, *Applied Deep Learning with Keras*, Packt Publishing, 2019.