

Zerstörungsfreie Bauwerksdiagnostik

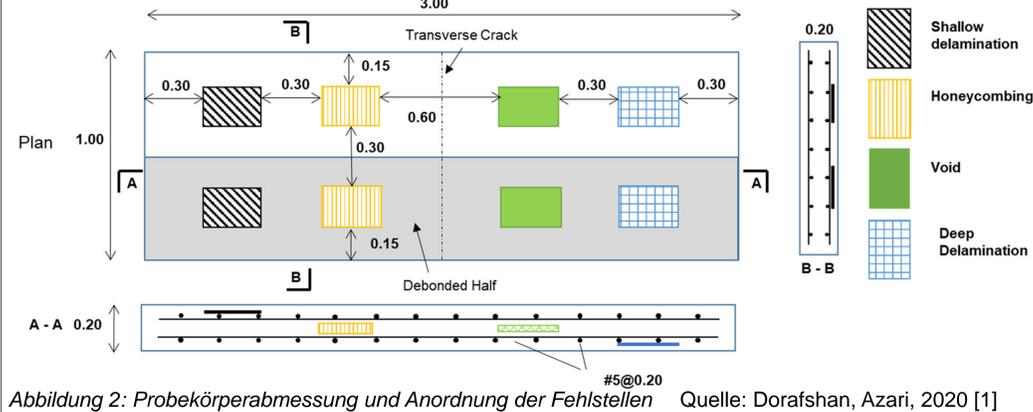
Entwicklung eines KI-Modells mittels Machine Learning

Machine Learning als Supervised Learning



Abbildung 1: Prozessdarstellung Machine Learning

Versuchsaufbau



- Verwendung von Datensätze aus Impact-Echo-Messungen des NDE-Labors Federal Highway Administration (FHWA) Advanced Sensing Technology (FAST)
- 8 Stahlbetonprobekörper
- Länge: 3,0 m; Breite: 1,0 m; Höhe: 0,2 m
- Normalbeton C25/30
- Einbau von 4 verschiedenen Fehlerquellen:
 - flache Delamination (ausgehend von oberer Bewehrungslage)
 - tiefe Delamination (ausgehend von unterer Bewehrungslage)
 - Wabenstruktur
 - Hohlraum
- Auf der Probenoberfläche wurde ein Messraster von 100x100 mm mit 261 Gitternetzpunkten aufgetragen

Abbildung 2: Probekörperabmessung und Anordnung der Fehlstellen Quelle: Dorafshan, Azari, 2020 [1]

Entwicklung eines KI-Modells

Die Versuchsdaten der 8 Testkörper aus der Impact-Echo-Messung werden für die Entwicklung der KI in das Modul Echolyst A.I importiert. Die Verarbeitung der Daten erfolgt in der Originalsequenz, als Fast-Fourier-Transformation (FFT) oder als Short-Time-Fourier-Transformation (STFT).

1. Binäre Zuweisung der Messpunkte in die Klassen
1: Fehlstelle, 2: Keine Fehlstelle
• Das labeln der Daten erfolgt über das Versuchsmessraster
2. Trainieren des KI-Modells mittels Supervised Learning
• Ein Teil der Daten wird für das Training des Modells, ein anderer Teil zur Validierung zur Verfügung gestellt
0: Trainingsdaten, 1: Testdaten, -1: Deaktivierte Daten
• Die Wahl der prozentualen Gewichtung der Trainings- und Testdaten beeinflusst die Genauigkeit des Modells
3. Erzeugen des KI-Modells mittels Deep Learning unter Anwendung eines Algorithmus
• Wahl zwischen Multi Layer Perceptron (MLP) und Convolutional Neural Networks (CNN)
• Anpassung der Genauigkeit des Modells durch beispielsweise Steigerung der Epochen
4. Ausgabe der Daten als Lernkurve des trainierten Modells
• Die Auswertung der auf das Modell angewendeten Testdaten kann abgelesen werden
5. Anwendung des Machine Learning Modells auf die Datensätze und Ergebnisausgabe in grafischer Form

[2]

Auswertung

Tabelle 1: Trainingsergebnisse bei Epochs:30

Processing	Split [%-Anteilen]	Algorithm	Lernkurve - Trainingsdaten [%]	Lernkurve - Validation (Max.-Wert) [%]
Original Sequence	80 / 20	MLP	95	77
Original Sequence	70 / 30	MLP	95	80
FFT	80 / 20	MLP	95	89
FFT	70 / 30	MLP	95	90,5
STFT	80 / 20	MLP	96	91,5
STFT	70 / 30	MLP	95	90,5
STFT	80 / 20	CNN	96	93
STFT	70 / 30	CNN	95	92

Tabelle 2: Trainingsergebnisse bei Epochs:100

Processing	Split [%-Anteilen]	Algorithm	Lernkurve - Trainingsdaten [%]	Lernkurve - Validation (Max.-Wert) [%]
Original Sequence	80 / 20	MLP	100	77
Original Sequence	70 / 30	MLP	100	81
FFT	80 / 20	MLP	98	90,5
FFT	70 / 30	MLP	97,5	90
STFT	80 / 20	MLP	100	92
STFT	70 / 30	MLP	99	92
STFT	80 / 20	CNN	100	93
STFT	70 / 30	CNN	100	93

- Unter Verwendung der Algorithmus-Architektur CNN liefert STFT die höchste Genauigkeit des trainierten Modells in Bezug auf die Lernkurve
- Sowohl bei einem Split von 80/20 als auch bei 70/30
- Insgesamt berechnete Parameter: 533.313
- Für Impact-Echo-Daten ist die Verwendung von STFT-Sequenzen am sinnvollsten durch die Zeit-Frequenz-Darstellung (Spektrogramm)
- Eine gesteigerte Akkuranz der Trainingskurve wird durch eine Erhöhung der Epoche erreicht
- Overfitting
 - Überanpassung des trainierten Modells in den ersten Epochen
 - Modell ist an die Trainingsdaten überangepasst und ist daher für die Vorhersage neuer Daten nicht aussagekräftig
- Das trainierte Modell stellt kein allgemeingültiges KI-Modell dar und ist daher nicht auf andere Problemstellungen übertragbar

Quellenangabe:

[1] Dorafshan, S; Azari, H. (2020): Automation in Construction, Elsevier, www.elsevier.com/locate/autcon

[2] Algeron; Feistkorn; Hagenbruch; Kicherer; Rösseler; Scherrer (2020): Echolyst-Entwicklung eines Impact-Echo-Systems für Scanning, Analyse und Machine Learning, ZfP-Zeitung (172), www.svti.ch