

BESTIMMUNG DER BETONFESTIGKEIT DURCH KÜNSTLICHE INTELLIGENZ

Mustafa Algan BSc

Kurzfassung: Die Druckfestigkeit ist bei Beton die wichtigste mechanische Kenngröße, die je nach Anforderungen und Belastungen bereits bei der Dimensionierung eines Bauwerks vorgegeben wird. Als Standard gilt bei Beton die Druckfestigkeit, welche am 28. Tag gemessen wird d.h. zu einen Zeitpunkt an den der Beton fast vollständig ausgehärtet ist. Die Messung von Druckfestigkeiten seitens des Betonherstellers ist sehr aufwendig und nimmt viel Zeit in Anspruch. In dieser Masterarbeit werden die Druckfestigkeiten mittels künstlicher Intelligenz (KI) geschätzt. Um ein KI-Modell zu erstellen, stehen zwei Datensätze zur Verfügung. Diese Trainings- und Testdaten werden eingesetzt, um die KI zu trainieren und zu evaluieren. Im Rahmen der Arbeit werden viele unterschiedliche KI Methoden überprüft und verglichen, als günstigstes Modell wird wegen seiner Flexibilität dann ein neuronales Netz gewählt, das ausschließlich in eine ausführbare Benutzeroberfläche implementiert wird, um das NN in der Praxis einzusetzen.

Schlüsselwörter: Beton, Neuronales Netz, Druckfestigkeit, Maschinelles Lernen

1. EINLEITUNG

Eines der wichtigsten Kriterien, die beim Bau von Gebäuden erfüllt sein muss, ist die Druckfestigkeit. Als Kennwert dient die Druckfestigkeit am 28. Tag, eine nach der Norm EN 206 [1] ermittelt wird. Genaue Festigkeitsvorhersagen haben in der Betonbranche tiefgreifende Auswirkungen auf die Effizienz und Qualität von Bauprojekten. Die Vorhersage der Druckfestigkeit von Beton war schon immer schwierig, da der Beton sehr empfindlich auf seine Ingredienzen, Mischverfahren, Verdichtung, Aushärtungszustand usw. reagiert. In dieser Masterarbeit ist das Ziel die Druckfestigkeit anhand von vorhandenen Rezepturen, das heißt der Zusammensetzung des Betons, mit einem Modell zu schätzen. Ähnliche Problemstellung behandeln [2], [3] und [4]. Die Unterschiede liegen in den Eingangsparametern und den verwendeten Modellen. In [2] wird ein neuronales Netz (NN) mit 7 Eingangsparameter entwickelt. Das NN wird mit 70% der Daten trainiert, 15% getestet und 15% validiert und erreicht ein Bestimmtheitsmaß R^2 0,9543. Andererseits wird in [3] ein Adaptive Neuro-Fuzzy Inference System (ANFIS) Modell trainiert. Das ANFIS Modell hat die gleiche Anzahl an Eingangsparameter wie bei [2] mit einer Datenaufteilung von 85% Trainings- und 15% Testdaten. Als Ergebnis wird ein mittlerer quadratischer Fehler (root means square error – RMSE) von 7,773N/mm² erreicht. Bei [4] werden drei verschiedene Modelle trainiert und verglichen. Die Modelle haben 8 Eingangsparameter und als Modell werden NN, Random Forest und Support Vector Machine (SVM) verwendet. Diese drei Modelle erreichen ein RMSE von 5,9N/mm², 5,6N/mm² und 7,5N/mm².

In dieser Arbeit werden die Rezepturen vom Unternehmen Wopfinger Transportbeton GmbH zur Verfügung gestellt. Dabei handelt es sich um zwei Datensätze. Der erste Datensatz (DS1) enthält nominelle Druckfestigkeiten und der andere gemessene Druckfestigkeiten. Zu Beginn wird DS1 verwendet, um die

Umsetzbarkeit des Projektes zu überprüfen. Aus der Erkenntnis, dass die Ergebnisse akzeptabel sind, wurde der zweite Datensatz (DS2) zur Verfügung gestellt. Nach dem Training mit DS2 wird ein systematischer Fehler entdeckt und korrigiert. Die Korrektur erfolgt auf drei verschiedene Arten: einem neuronalen Netz, einer linearen Regression mit Fehlerterm und der orthogonalen Regression. Bei dem schlussendlich ausgewählten Modell handelt es sich um das NN, welches die Druckfestigkeit ohne systematische Fehler schätzt. Für den einfachen Einsatz des Modells in der Praxis wird eine ausführbare Anwendung mit Benutzeroberfläche erstellt.

Neben dem Erstellen eines Modells, welches die Druckfestigkeit anhand der Betonzusammensetzung, schätzt muss das Modell für den Einsatz in der Praxis überprüft werden. Dazu werden die Daten bereinigt und passende Modelle ausgesucht, trainiert und validiert. Der Ablauf ist in Abb. 1 dargestellt. Dieser Prozess zeigt auch eine Rückkopplung mit Modelloptimierung die zu einer iterativen Verbesserung der Modelle führt, weil die Modell-Hyperparameter angepasst werden.




Abb. 1: Prozess bei Maschinelles Lernen.

2. MODELLE UND METHODEN

Als Software wird in dieser Arbeit Matlab [5] vom Unternehmen MathWorks eingesetzt, weil die Bibliotheken im Bereich der künstlichen Intelligenz bzw. maschinelles Lernen verfügbar sind. Alle vordefinierten Modelle werden eingesetzt, um die Auswahl des „besten“ Modells zu identifizieren und zu modifizieren.

Die beiden Datensätze sind sehr umfangreich. DS1 beinhaltet 20742 Zeilen und 329 Spalten. DS2 beinhaltet 2498 Zeilen und 70 Spalten. Am Ende des Projektes verbleiben nach sorgfältiger Bereinigung und Korrektur in DS2 noch 1674 Zeilen und 9 Spalten. Dieser Datensatz wird mit einer einfachen zweischichtigen NN verarbeitet.

2.1. NEURONALE NETZE

Ein künstliches neuronales Netz [6,7,8] wird meist als Graph mit Knoten und Kanten dargestellt. Abb. 2 zeigt ein einzelnes Neuron, in dem die Knoten die Eingangswerte und die Kanten die Gewichtungen darstellt.




Abb. 2: Einzelnes Neuron eines Netzwerks.

An der Vorwärtsberechnung lässt sich der Ausgang y berechnen. Die Eingangswerte $\mathbf{X} = [x_1, x_2, \dots, x_n]$ werden mit dem Gewichtungsvektor $\mathbf{w} = [w_{1j}, w_{2j}, \dots, w_{nj}]^T$ zum skalaren Netzeingang net aufsummiert.

$$net_j = \mathbf{X} \mathbf{w} \quad (1)$$

Der Ausgang y lässt sich mit Hilfe der Aktivierungsfunktion f und der Netzfunktion durch

$$y = f(net + \theta) \quad (2)$$

bestimmen. In der Tab. 1 sind gängige Aktivierungsfunktionen zusammengefasst.

Bezeichnung	Funktion
Sigmoid	$f(x) = \left(\frac{1}{1 + \exp^{-x}} \right)$
Tangens hyperbolicus	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
ReLU	$f(x) = \max(0, x) = \begin{cases} x & x > 0 \\ 0 & x < 0 \end{cases}$

Tab. 1: Bekannte Aktivierungsfunktionen bei KNN.

Damit ein NN komplexere Aufgaben lösen kann, werden die Neuronen in Schichten zusammengefasst. Die Eingabewerte laufen dabei über die Eingangsschicht und die verborgenen Schichten bis zum Ausgang. Solch eine Struktur wird als „feedforward-Netz“ bezeichnet, bei welcher die Ausgangsgröße in einer Vorwärtsanalyse ermittelt werden kann, siehe Abb. 3.




Abb. 3: Zweischichtiges feedforward-Netz.

Die Gewichtungen $\mathbf{w}$ sind die freien Parameter des Netzes und werden beim Trainieren mit der sogenannten Backpropagation angepasst. Dazu werden die Eingangswerte $\mathbf{X}$ an dem neuronalen Netz angelegt und vorwärts propagiert, sodass der geschätzte Ausgang $\hat{y} = g(x)$ berechnet werden kann. Die Modellgüte wird durch die Verlustfunktion $I(e)$ beschrieben,

$$I = \sum_{i=1}^N e_i^2 \quad (3)$$

Wobei $e = y - \hat{y}$ die Abweichung zwischen Messwert y und Modellausgang $\hat{y}$ beschreibt und über alle N Messwertpaare summiert wird. Um die Gewichtsparameter w optimal zu wählen wird der Fehler vom Ausgang bis zum Eingang zurückpropagiert. Parallel dazu werden die Gewichtungen vom Netz je nach Auswirkung auf die Knoten angepasst. Das Anpassen bzw. korrigieren der Gewichtungen erfolgt auf Basis des Gradientenverfahrens, welches den Einfluss des jeweiligen Parameters auf die Verlustfunktion abschätzt. Die Aktualisierung der Gewichtung erfolgt dann in Richtung des kleinsten Gradienten

$$w_{k+1} = w_k - \eta \frac{\partial I}{\partial w}, \quad (4)$$

wobei η wieder die Schrittweite ist.

3. VORVERARBEITUNG DS1

Die Eingangsparameter werden durch die Rezeptur bestimmt und sie sind die einzigen Informationen, um das Modell zu trainieren. Bei DS1 werden folgende Eingangsparameter verwendet:

- Zement
- AHWZ (Aufbereitete hydraulisch wirksame Zusatzstoffe)
- LP (Luftporenbilder)
- Gr-Korn (Größtes Korn)
- gWasser (Gesamt Wassermenge)
- Zugabewasser
- RW (Reinwasser)
- W/Zk (Wasser/Zement Verhältnis)
- Rohdichte
- Werk

DS1 beinhaltet sechs verschiedene Zementarten, diese werden in eine Zement Größe zusammengefügt. Bevor die Daten für das Trainieren nutzbar sind, müssen sie Vorverarbeitet werden. Dazu werden die Daten auf die Nulleinträge und Ausreißer überprüft.




Abb. 4: Nulleinträge in DS1.

Abb. 4 zeigt die Nulleinträge in DS1. Dabei ist zusehen, dass bei der Druckfestigkeit und bei den verschiedenen Wassermengen Nullwerte vorhanden sind. Diese werden von DS1 entfernt, da bei der Mischung Wasser für die chemische Reaktion benötigt wird. Ebenso werden Einträge mit fehlender Rohdichte entfernt. Anschließend werden die Ausreißer mit Boxplot Diagrammen analysiert (Abb. 5).




Abb. 5: Verteilung der Eingangsdaten, Ausreißer sind rot markiert.

Bei dem Eingangsparameter Rohdichte werden Ausreißer erkannt und entfernt.

4. MODELLAUSWAHL FÜR DS1

Für den Auswahl werden fünf verschiedene Modelltypen untersucht

- Lineare Regression
- Entscheidungsbäume
- Support Vector Machines
- Gaussian Process Regression
- Random Forest
- Neuronale Netze

Diese Modelle werden mit unterschiedlichen vordefinierten Parametern trainiert. Dazu wird DS1 in 85% Trainings- und 15% Testdaten aufgespalten. Die Ergebnisse in [9] zeigen, dass aus den Random Forest Modelle das „Bagged Tree“ die besten Resultate mit RMSE 1,7667N/mm² erzielt. Abb. 6 zeigt, den Einsatz des „Bagged Tree“ Modells auf DS1 und macht deutlich, dass bei hohen Druckfestigkeiten die Schätzungen stark abweichen.




Abb. 6: Vergleich zwischen geschätzter und gegebener Druckfestigkeit von Bagged Tree.

Der Grund dafür ist die geringe Anzahl der Rezepturen mit hoher Druckfestigkeit. Nach dem Entfernen der Rezepturen mit einer Druckfestigkeit von mehr als 55N/mm² wird das Modell nochmal trainiert. Abb. 7 zeigt, dass die Abweichungen nicht sehr groß sind. Mit dem angepassten Modell wird ein RMSE von

1,6405N/mm² erreicht und dabei befinden sich 95,85% der Schätzungen über dem Schwellenwert von -3N/mm². Aus dieser Erkenntnis wird DS2 zur Verfügung gestellt und weitergearbeitet.




Abb. 7: Abweichungen von Bagged Tree mit neuen Testdaten.

5. VORVERARBEITUNG DS2

Der Unterschied bei DS2 zu DS1 ist, dass die Eingangsparameter gemessene Werte sind und vor allem die Druckfestigkeit gemessen werden. Aus den drei Wasserangaben wird nur mehr eine verwendet, da die anderen redundante Größen sind, sodass insgesamt acht Eingangsgrößen zur Verfügung stehen

- Zement
- AHWZ
- LP
- Gr-Korn
- Wasser
- W/B (Wasser/Bindemittel Verhältnis)
- Rohdichte
- Werk

In DS2 sind keine Nulleinträge vorhanden. Trotzdem finden sich in der händisch erfassten Datensätze noch fehlerhafte Einträge. So zeigt etwa Abb. 8, dass es beim LP-Eintrag einen Ausreißer gibt, der durch einen Kommafehler entstanden ist (Faktor so 10 überhöht) und daher korrigiert werden konnte.




Abb. 8: Ausreißer bei dem Parameter LP rot markiert.

Mit einer Korrelationsanalyse werden die Abhängigkeiten der Druckfestigkeit von den Eingangsgrößen überprüft. Abb. 9 zeigt, dass die Größen „Zement“ und „Rohdichte“ positiv mit Druckfestigkeit korrelieren. Anders ist es bei den Größen „Wasser“ und „W/B“, welche die Ausgangsgröße reduzieren. Die restlichen Größen zeigen keine deutlichen Abhängigkeiten,

können aber nicht linear auf die Druckfestigkeit wirken, weshalb sie nicht aus DS2 entfernt werden.




Abb. 9: Korrelationsmatrix von DS2, Einfluss der Eingangsgrößen auf die Druckfestigkeit (1. Zeile bzw. 1. Spalte)

6. MODELLAUSWAHL FÜR DS2

Da das „Bagged Tree“ Modell mit dem DS1 gute Ergebnisse liefert, wird es für DS2 ebenfalls eingesetzt. Für das Trainieren werden 80%, die Validation 10% und das Testen 10% aus DS2 verwendet. Das Modell erzielt einen RMSE von 4,4669 N/mm². Die Schätzungen werden mit den gemessenen Druckfestigkeiten in Abb. 10 verglichen. Auf den ersten Blick sind die Fehler relativ gleichmäßig um die Modellgerade verteilt.




Abb. 10: Vergleich zwischen geschätzter und gemessener Druckfestigkeit (Bagged Tree Modell).

Erst auf einen Fehlerplot, Abb. 11, lässt sich ein systematischer Fehler erkennen. Der lineare Verlauf über die ganze Druckfestigkeit kann das Modell nicht korrekt schätzen.




Abb. 11: Abweichungen von den geschätzten Druckfestigkeiten (Bagged Tree Modell).

Weiters werden die Daten auf die anderen Modelle angewendet, um zu testen, ob der Fehler korrigiert werden kann. Dabei erzielt das Gaussian Process Regression (GPR) Modell gute Resultate mit einem RMSE von 1,4999 N/mm². In Abb. 12 werden die Fehler überprüft und der systematische Fehler lässt sich sehr leicht erkennen, deshalb kann das Modell nicht in der Praxis eingesetzt werden. In dem nächsten Kapitel werden die Lösungswege für diesen Fehler näher beschrieben.




Abb. 12: Abweichungen vom GPR Modell.

7. KORREKTUR DES SYSTEMATISCHEN FEHLERS

Nach Absprache mit dem Auftraggeber wird DS2 nochmals überprüft und auf 1674 Zeilen reduziert. Das entspricht 1423 Trainings- und 251 Testdaten in Verhältnis 80:20. Dieser Datensatz wird als DS3 bezeichnet.

7.1. LINEARE REGRESSION MIT FEHLERTERM

Der Fehlerterm e besitzt in allen Modellen das gleiche Muster. Deshalb wird die Lineare Regression, zur Korrektur des Fehlers e genutzt. Für die Messdaten y gilt, dass sie aus Datenmatrix X , den Parameter w und den Fehler e gebildet werden

$$y = X \cdot w + e. \quad (5)$$

Durch die Erkenntnis, dass der Fehler e von der Druckfestigkeit y linear abhängig ist, wird der Fehler e mit einer linearen

Gleichung, dadurch ergeben sich zwei zusätzliche unbekannte Koeffizienten a und b

$$e = a + y \cdot b + \varepsilon \quad (6)$$

und durch

$$y = X \cdot w + b \cdot y + a + \varepsilon. \quad (7)$$

Sind alle Ausgangsgrößen auf der linken Seite, kann ein unbekannter Faktor $\alpha = 1 + b$ bestimmt werden.

$$y \cdot \underbrace{(1 - b)}_{\alpha} = X \cdot w + a + \varepsilon \quad (8)$$

Durch Umformung kann das Modell auf die übliche lineare Form gebracht werden

$$y = (X \quad \mathbf{1}) \begin{pmatrix} w/\alpha \\ a/\alpha \end{pmatrix} + \varepsilon. \quad (9)$$

Anschließend werden die Koeffizienten von dem Modell berechnet und die Residuen verglichen. Nach der Korrektur verteilen sich die Residuen wie erwünscht, siehe Abb. 13. Rund 61% der Fehler befinden sich bei beiden Modellen in einem tolerierbaren Bereich. Der erzielte RMSE beträgt 6,6381 N/mm². Durch höhere Anzahl an Stichproben kann der RMSE Wert verbessert werden.




Abb. 13: Vergleich zwischen dem fehlerbehafteten Modell (oben) und korrigierten (unten).

7.2. ORTHOGONALE REGRESSION

Für die Berechnung der Ausgleichsgerade wird die Methode der kleinsten Fehlerquadrate [10] eingesetzt. Dabei wird entweder der horizontale oder der vertikale Abstand vom

Datenpunkt zur Modellgeraden verwendet. Falls davon ausgegangen wird, dass die Datenpunkte (x_i, y_i) wegen Messungen fehlerbehaftet, kann die orthogonale Regression [20] eingesetzt werden, die auch unter den Namen Total Least Squares bekannt ist. Damit wird der Normalabstand des Datenpunktes zur Geraden g berücksichtigt und die mit (x^*, y^*) bezeichneten Punkte berechnet, siehe Abb. 14.

$$x_i^* = x_i + \frac{\beta_1}{1 + \beta_1^2} (y_i - \beta_0 - \beta_1 x_i), \quad (10)$$

$$y_i^* = \beta_0 + \frac{\beta_1}{1 + \beta_1^2} (x_i + \beta_1 (y_i - \beta_0)). \quad (11)$$




Abb. 14: Orthogonaler Abstand zwischen der Geraden g und dem Punkt (x_i, y_i) .

Die Ergebnisse der orthogonalen Regression und der linearen Regression werden in Abb. 15 verglichen. Die Schätzungen haben eine geringere Varianz und der RMSE Wert beträgt 1,979 N/mm². Von den Schätzungen befinden 95,76% in einem tolerierbaren Bereich.




Abb. 15: Fehlerkorrektur mit orthogonaler Regression.

7.3. NEURONALES NETZ

Ein weiterer Lösungsansatz ist ein Neuronales Netz, das mit der Bayes Regularisierung trainiert wird. In Abb. 16 ist die Architektur des neuronalen Netzes dargestellt.




Abb. 16: Aufbau vom neuronalen Netz.

Es besteht aus zwei verdeckten Schichten mit 60 bzw. 30 Neuronen mit einer tanh-Aktivierungsfunktion. Die Ausgangsschicht besitzt eine Sigmoid-Aktivierungsfunktion. Am Ende werden die Ausgangswerte zurückskaliert, da die Sigmoid-Funktion zwischen 0 und 1 liefert. Die Größe von den Schichten wird empirisch ermittelt. Zum Trainieren benötigte das Netz 3,8s und erreicht einen RMSE Wert von 9,28N/mm². Von den Schätzungen befinden sich 63% im tolerierbaren Bereich. Auf Grund der reduzierten Stichproben ist die Varianz höher als bei den Modellen mit mehr Stichproben. Die Verteilung der Fehler ist in Abb. 17 dargestellt.




Abb. 17: Fehlerverteilung über die gemessenen Druckfestigkeiten.

Dabei wird für die Optimierung der Hyperparameter Bayes'sche Regularisierung [11] eingesetzt. Dabei minimiert sie eine lineare Kombination aus quadratischen Fehlern und Gewichten. Es modifiziert auch die Linearkombination, sodass das resultierende Netzwerk am Ende des Trainings eine gute Generalisierung hat.

8. ERGEBNISSE

Damit ein Modell ausgewählt werden kann, werden alle Modellergebnisse in Tab. 2 verglichen.

Modell	RMSE [N/mm ²]	Tolerierbare Werte [%]	Daten
BT	1,265	97,5%	DS1 / original
GPR	1,4999	97,33%	DS2 / normiert
LR mit FT	6,6381	61%	DS3 / original
OR	1,979	95,76	DS3 / original
NN	9,28	63%	DS3 / normiert

Tab. 2: Vergleich zwischen Bagged Tree (BT), Gaußsche-Prozess-Regression (GPR), Lineare Regression mit Fehlerterm (LR mit FT), Orthogonale Regression (OR) und Neuronales Netz (NN).

Als Modell wird weiters das Neuronale Netz mit der Bayes Regularisierung eingesetzt, weil dieses Netz auch nichtlineare Probleme lösen kann. Das Modell wird mit den am meist bereinigten Datensatz DS3 trainiert und die Residuen zeigen keine linearen Abhängigkeiten. Trotz der hohen RMSE Wert wird dieses Modell eingesetzt, weil die Druckfestigkeit von den Eingangswerten nichtlinear abhängig ist und mit den Daten ein

großer Festigkeitsbereich abgedeckt wird. Die linearen Modelle können nur dann eingesetzt werden, wenn sich die Änderungen der Festigkeit (abhängig von den Eingängen) in einem bestimmten Bereich linear verhalten.

Es wurde bereits gezeigt, dass die Größe des Datensatzes eine wichtige Rolle spielt, denn das NN-Modell kann nicht mit wenigen Daten angepasst werden. Deshalb sind die Ergebnisse bei einem Trainingsversuch vom GPR Modell mit dem DS3 nicht erfolgreich.

Eine weitere Verbesserungsmöglichkeit liegt bei den Eingangsparametern. In verschiedenen Publikationen werden die Eingangsparameter anders ausgewählt, als bei den zur Verfügung gestellten Datensatz.

Des Weiteren sollten in allen Werken dieselbe Rezeptur überprüft werden, um zu sehen ob die Druckfestigkeit sich wegen den verschiedenen Gesteinsorten sich ändert. Dazu könnte auch nur reiner Zement also CEM I aufgezeichnet werden, sodass das Modell mit reinem Zement trainiert wird.

9. GRAFISCHE BENUTZEROBERFLÄCHE

Nach dem alle Modelle entwickelt worden sind, wird das neuronale Netz in das ausführbare Programm eingebettet. Zusätzlich werden zwei Diagramme hinzugefügt, siehe Abb. 6.2. In diesen Diagrammen werden verschiedene Druckfestigkeiten angezeigt, bei denen die Zementmenge um bis zu 50% reduziert wird. Dabei bleiben die anderen vorgegebenen Eingangswerte erhalten. Bei dem zweiten Diagramm wird zusätzlich die Wassermenge um $\pm 50\%$ variiert. Das Diagramm hat eine weitere Funktionalität, bei der die Ergebnisfläche mit einer horizontalen Ebene geschnitten wird. Die Höhe der Ebene kann in dem Textfeld rechts angegeben werden und entspricht einer Druckfestigkeit. An den geschnittenen Punkten werden die Zementmenge und die Wassermenge in einer Tabelle wiedergeben. Somit bleibt die Mischung erhalten und für die eine gegebene Druckfestigkeit können die zwei Mengen angepasst werden.




Abb. 17: Graphische Oberfläche mit dem eingebetteten neuronalen Netz.

10. ZUSAMMENFASSUNG

In der vorliegenden Arbeit wird das Thema „Bestimmung der Betonfestigkeit durch Künstliche Intelligenz“ behandelt. Es wird die Frage beantwortet, ob die KI die physikalischen Druckfestigkeitsmessungen ersetzen kann oder nicht. Dabei wird gefordert, dass die Genauigkeit der Schätzung eine Abweichung von -3N/mm^2 nicht unterschreitet. Dazu werden zwei wesentliche Arbeitsschritte ausgeführt, die

Vorverarbeitung der Daten und das Erstellen eines passenden Modells, wobei drei Datensätze vorverarbeitet und analysiert werden. Datensatz 1 enthält nur nominelle Druckfestigkeiten, um die Machbarkeit des Projektes zu bewerten. Datensatz 2 enthält durchgeführte Druckmessungen und wird bereits für das Training eingesetzt. Durch die Betrachtung der Modellfehler kann der Datensatz 2 weiter bereinigt werden, woraus Datensatz 3 gebildet wird. Neben einer genauen Analyse mit Hilfe der linearen Regression werden 23 weitere Modelle aus dem Matlab Machine Learning Framework zur Modellierung eingesetzt. Die vier besten Modelle werden im Weiteren genauer analysiert und optimiert. Die dabei erzielten Ergebnisse sind sehr zufriedenstellend, teilweise wurden die in der Literatur publizierten Genauigkeiten sogar übertroffen. Für die in der Arbeit verwendeten Datensätze lieferten lineare Modelle die besten Ergebnisse. Trotzdem wird als endgültiges Modell ein Neuronales Netz ausgewählt, weil dieses für allfällige umfangreichere Datensätze in der Lage ist auch nicht lineare Beziehungen abzubilden.

Der Nachteil des NN-Modell ist die hohe Varianz der Residuen und nur 63% der Schätzungen befinden sich in einem tolerierbaren Bereich. Im Vergleich zu den Publikationen mit neuronalen Netzen zeigt sich, dass sich die Eingänge der Trainings-Datensätze teilweise substantiell unterscheiden. Die vorliegende Arbeit kann als Grundlage für nachfolgende Projekte genutzt werden, die erzielte Genauigkeit ist für den praktischen Einsatz zu gering.

11. LITERATURVERZEICHNIS

- [1] ÖNORM B 4710-1, *„Beton - Festlegung, Eigenschaften, Herstellung, Verwendung und Konformität - Teil 1: Regeln zur Umsetzung der ÖNORM EN 206 für Normal- und Schwerbeton“*, 2018.
- [2] Khademi, Faezehossadat & Jamal, Sayed Mohammadmehdi, *„Predicting the 28 Days Compressive Strength of Concrete Using Artificial Neural Network“*, i-manager's Journal on Civil Engineering. 6, 2016.
- [3] Tu Trung Nguyen & Kien Dinh, *„An Artificial Intelligence approach for concrete hardened property estimation“*, Journal of Science and Technology in Civil Engineering NUCE 2020. 14, USA, 2020.
- [4] Priscila F.S.S., Gray F.M., Vanderci F.A., *„Machine learning techniques to predict the compressive strength of concrete“*, International Journal of Numerical Methods for Calculation and Design in Engineering, Brasil, 2020.
- [5] MathWorks® Available from: <https://de.mathworks.com/> Accessed: 2022.11.18
- [6] I. Goodfellow, Y. Bengio, A. Courville, *„Deep Learning“*, MIT Press, ISBN 9780262035613, Cambridge, England, 2016.
- [7] B. Lantz, *„Machine Learning with R“*, Packt Publishing, ISBN 978-1-78216-214-8, Birmingham, England, 2013.
- [8] M. Hochrainer, *„Systemsimulation & Modellbildung“*, 1. Semester, Mechatronik, FH Wiener Neustadt, Wiener Neustadt, Österreich, 2018.
- [9] M. Algan, *„Bestimmung der Betonfestigkeit durch Künstliche Intelligenz“*, Masterarbeit, FH Wiener Neustadt, Wiener Neustadt, Österreich, 2022.
- [10] G. Casella, R. L. Berger, *„Statistical Inference“*, Cengage Learning, ISBN 978-0495391876, Boston, 2008.
- [11] Foresee, F. Dan, and Martin T. Hagan. *„Gauss-Newton approximation to Bayesian learning.“* Proceedings of the International Joint Conference on Neural Networks, USA, 1997.

AUTOR



Mustafa Algan BSc

Fachhochschule Wiener Neustadt, Johannes-Gutenberg-Straße 3, 2700 Wiener Neustadt, mustafa.algan@fhwn.ac.at

Lebenslauf: HTL Mödling Elektronik 2016, FHWN Bachelorstudiengang Mechatronik 2020, FHWN Masterstudiengang Mechatronik 2022, Studentischer Mitarbeiter in Robotik 2018-2021, aktuell FHWN Mitarbeiter Studiengang Robotik.