



UNIVERSITÄT FÜR BODENKULTUR WIEN

Masterarbeit

KI-gesteuerte Setzungsprognose von Tunnelvortrieben aus numerischen Ersatzmodellen

verfasst von

Christoph POCK, BSc BA

im Rahmen des Masterstudiums

Kulturtechnik und Wasserwirtschaft

zur Erlangung des akademischen Grades

Diplom-Ingenieur

Wien, März 2022

Betreut von:

Univ.Prof. Dr.Ing. Wei Wu

Institut für Geotechnik

Department für Bautechnik und Naturgefahren

Eidesstattliche Erklärung

Ich erkläre eidesstattlich, dass ich die Arbeit selbständig angefertigt habe. Es wurden keine anderen als die angegebenen Hilfsmittel benutzt. Die aus fremden Quellen direkt oder indirekt übernommenen Formulierungen und Gedanken sind als solche kenntlich gemacht. Diese schriftliche Arbeit wurde noch an keiner Stelle vorgelegt.

Wien, am 14.03.2022

.....

Christoph Pock

Kurzfassung

Ziel dieser Arbeit ist die Entwicklung von Artificial Neural Networks zur Prognose von tunnelbaubedingten Oberflächensetzungen. Die Datengrundlage für die Machine Learning Anwendung stellt eine Setzungsdatenbank dar, deren Einträge mit dem Finite-Differenzen-Programm FLAC3D erstellt werden. Der Tunnelvortrieb wird zweidimensional mithilfe der Convergence-Confinement-Methode simuliert, wobei die erwarteten Spannungsumlagerungen durch einen Vorentlastungsfaktor berücksichtigt werden. Als Materialgesetz wird das Plastic-Hardening-Materialgesetz verwendet. Die gesuchten Setzungsparameter sind die maximale Oberflächensetzung S_{vmax} sowie der zugehörige Wendepunktabstand der Quersetzungsmulde i .

Als Eingangsparameter für die mit Hilfe der Python-Bibliothek *TensorFlow* entwickelten Artificial Neural Networks dienen geometrische, geotechnische und bauablaufbedingte Kennwerte. Aufbauend auf die Setzungsdatenbank werden verschiedene Artificial Neural Networks mit unterschiedlichen Netzwerkarchitekturen entwickelt und die Modellperformances am Trainings-, Test- und Hold-Out-Validierungsset mittels verschiedener statistischer Gütemaße bestimmt. Anschließend werden die wichtigsten Inputfeatures mittels Permutation-Importance-Werten sowie SHAP-Werten ermittelt.

Die Ergebnisse zeigen eine hohe Übereinstimmung zwischen den numerisch berechneten und den prognostizierten Setzungen bei Verwendung von aussagekräftigen Eingangsparametern wie dem Vorentlastungsfaktor oder der Elastizitätsmoduln des Plastic-Hardening-Materialgesetzes. Die Resultate der Feature-Importance unterstützen diese These. In dieser Arbeit wurden als wichtigste Inputfeatures für die maximale Setzung die Elastizitätsmoduln, der Reibungswinkel sowie der Tunneldurchmesser ermittelt. Bezüglich des Wendepunktabstands waren die Überdeckung, der Durchmesser, das Überdeckungsverhältnis sowie die Elastizitätsmoduln am einflussreichsten.

Abstract

The purpose of this master's thesis is the development of artificial neural networks to predict surface settlements due to tunnelling. The machine learning application is based on a settlement database whose entries are calculated with the finite difference program FLAC3D. The tunnel construction is two-dimensionally modelled employing the convergence confinement method where the magnitude of the anticipated stress redistribution is controlled by a stress reduction factor whereas the surrounding soil is modelled using the Plastic-Hardening Constitutive law. The sought-after settlement indicators are the maximum surface settlement S_{vmax} together with the point of inflexion of the transverse settlement trough i .

Geometrical, geotechnical, and construction-related parameters are used as input features for the artificial neural networks which were developed using the python library *TensorFlow*. Based on the settlement database, various artificial neural networks with different network architectures are developed and the model performance is determined on the training, test, and hold-out validation set using various statistical quality measures. The most important input features are then calculated by means of permutation importance scores and SHAP-values.

The results indicate a high correlation between the numerically calculated and the predicted settlements when using meaningful input features such as the stress reduction factor or the moduli of elasticity of the Plastic-Hardening constitutive law. The outcome of the feature importance calculations supports this thesis. In this study, the most important input features regarding the maximum surface settlement were determined to be the moduli of elasticity, the friction angle, and the tunnel diameter. Regarding the point of inflexion of the transverse settlement trough, the overburden, the diameter, the overburden ratio, and the moduli of elasticity were identified as the most important input features.

Inhaltsverzeichnis

Eidesstattliche Erklärung	i
Kurzfassung	ii
Abstract	iii
Abbildungsverzeichnis	viii
Tabellenverzeichnis	x
Abkürzungsverzeichnis	xii
Symbolverzeichnis	xiii
1 Einleitung	1
1.1 Motivation	1
1.2 Aufgabenstellung und Zielsetzung	1
1.3 Aufbau der Arbeit	2
2 Literaturstudie und Grundlagen	3
2.1 Tunnelvortrieb	3
2.1.1 Zyklischer Vortrieb	3
2.1.2 Maschineller Vortrieb: Schildvortrieb	4
2.2 Tunnelbaubedingte Setzungen	7
2.2.1 Ortsbruststandsicherheit und Ausbreitung der Bodenbewegung in Richtung Oberfläche	7
2.2.2 Bautechnisch bedingte Setzungen	8
2.2.3 Setzungen durch den Einfluss von Grundwasser	9
2.2.4 Berechnungsmethoden für tunnelbaubedingte Setzungen	9
2.3 Künstliche Intelligenz und Machine Learning	15
2.3.1 Was ist Künstliche Intelligenz?	15
2.3.2 Machine Learning	15
2.3.3 Überblick über bekannte Machine Learning Konzepte	16
2.3.4 Allgemeine Herausforderungen von ML	17
2.4 Künstliche Intelligenz in der Geotechnik	19
2.5 Künstliche Intelligenz im Tunnelbau	21
2.5.1 Künstliche Intelligenz zur Vorhersage tunnelbaubedingter Setzungen	21
2.5.2 Andere KI-Anwendungen im Tunnelbau	23
2.5.3 Datenbank von Setzungsprognosen aus der Literatur	25
3 Methodologie	29
3.1 Finite Differenzen	29
3.1.1 Randbedingungen und Maße des FDM-Netzes	29
3.1.2 Anfangsbedingungen Erdruchedruck K_0	32
3.1.3 FDM-Netz	32

3.1.4	Materialgesetz	33
3.1.5	Bodenparameter	37
3.1.6	Modellierung und Parameter der Sicherungsmaßnahmen	39
3.1.7	2D-Methoden zur Berücksichtigung der 3D-Effekte während des Tunnelbaus	39
3.1.8	Implementation der 2D-Berechnung	42
3.1.9	Beispielberechnungen	43
3.1.10	Zuweisung der Geometrie- und Bodenparameter	45
3.2	Machine Learning	47
3.2.1	Funktionsweise eines ANN	47
3.2.2	Trainings-, Test- und Validierungsdatenset	53
3.2.3	Standardisierung der Eingangsdaten	54
3.2.4	Bestimmung der optimalen ANN-Architektur	54
3.2.5	Gütemaße	55
3.2.6	Vermeiden von Overfitting durch Early-Stopping	56
3.2.7	Feature Importance	56
3.2.8	Entwickelte ANN und verwendete Features	57
3.2.9	Ablauf der Entwicklung eines ANN	58
4	Ergebnisse	59
4.1	Datenbank der Setzungsprognosen aus den FDM-Berechnungen	59
4.2	Artificial Neural Network 1	72
4.2.1	Input- und Outputfeatures	72
4.2.2	Ergebnisse des GridsearchCV	73
4.2.3	Gewählte Netzwerkarchitektur ANN 1	74
4.2.4	Modellgüte des ANN 1: maximale Setzung	74
4.2.5	Feature Importance des ANN 1: maximale Setzung	76
4.2.6	Modellgüte des ANN 1: Wendepunktabstand	76
4.2.7	Feature Importance des ANN 1: Wendepunktabstand	78
4.3	Artificial Neural Network 1a	79
4.3.1	Ergebnisse des GridsearchCV	79
4.3.2	Gewählte Netzwerkarchitektur ANN 1a	80
4.3.3	Modellgüte des ANN 1a: maximale Setzung	80
4.3.4	Feature Importance des ANN 1: maximale Setzung	82
4.4	Artificial Neural Network 1b	83
4.4.1	Ergebnisse des GridsearchCV	83
4.4.2	Gewählte Netzwerkarchitektur ANN 1b	84
4.4.3	Modellgüte des ANN 1b: Wendepunktabstand	84
4.4.4	Feature Importance des ANN 1b: Wendepunktabstand	86
4.5	Artificial Neural Network 2	87

4.5.1	Input- und Outputfeatures	87
4.5.2	Ergebnisse des GridsearchCV	88
4.5.3	Gewählte Netzwerkarchitektur ANN 2	89
4.5.4	Modellgüte des ANN 2: maximale Setzung	89
4.5.5	Feature Importance des ANN 2: maximale Setzung	91
4.5.6	Modellgüte des ANN 2: Wendepunktabstand	91
4.5.7	Feature Importance des ANN 2: Wendepunktabstand	93
4.6	Artificial Neural Network 2a	94
4.6.1	Ergebnisse des GridsearchCV	94
4.6.2	Gewählte Netzwerkarchitektur ANN 2a	95
4.6.3	Modellgüte des ANN 2a: maximale Setzung	95
4.6.4	Feature Importance des ANN 2a: maximale Setzung	97
4.7	Artificial Neural Network 2b	98
4.7.1	Ergebnisse des GridsearchCV	98
4.7.2	Gewählte Netzwerkarchitektur ANN 2b	99
4.7.3	Modellgüte des ANN 2b: Wendepunktabstand	99
4.7.4	Feature Importance des ANN 2b: Wendepunktabstand	101
5	Diskussion der Ergebnisse	103
5.1	Qualität und Limitierungen der FDM-Berechnungen	103
5.2	Anzahl der Datensätze	103
5.3	Validierung mit Literaturdaten	104
5.4	Diskussion der ANN-Architekturen	105
5.4.1	Einfluss der Weight-Initialization-Methoden	105
5.4.2	Einfluss der Aktivierungsfunktionen	106
5.4.3	Anzahl an Layern und Neuronen	106
5.5	ANN Performance des Trainings-, Test- und Validierungssets	107
5.5.1	Single- und Multi-Output ANN	109
5.6	Feature Importance	110
5.7	Ausblick und Verbesserungen	112
6	Conclusio	115
7	Literaturverzeichnis	117
8	Anhang A: FLAC-Berechnungsfile Beispiel	123
9	Anhang B: TensorFlow-Codes	133

Abbildungsverzeichnis

Abb. 1: Kalottenvortrieb (Galler 2014: 104).....	3
Abb. 2: Schema einer Schildmaschine (Thewes 2014: 131).....	4
Abb. 3: Stabilitätsparameter der Ortsbruststandsicherheit.....	7
Abb. 4: Schematische Quersetzungsmulde.....	10
Abb. 5: tunnelbaubedingte Setzungsmulde nach Attewell et al. (1986) aus Möller (2006: 12)	11
Abb. 6: Klassisches Programmieren vs. Machine Learning (Chollet 2018: 5)	15
Abb. 7: Korrelationsmatrix des Literaturvalidierungssets	27
Abb. 8: Skizze des FDM-Modells und der Randbedingungen.....	30
Abb. 9: Beispiel eines FLAC3D Modells	32
Abb. 10: Fließfläche des Mohr-Coulomb-Materialgesetzes im Hauptspannungsraum für einen kohäsionslosen Boden (PLAXIS 2021: 34).....	33
Abb. 11: hyperbolische Spannungs-Dehnungsbeziehung im drainierten Triaxialversuch (PLAXIS 2021: 69).....	35
Abb. 12: Fließfläche des Plastic-Hardening-Materialgesetzes im Hauptspannungsraum für einen kohäsionslosen Boden (PLAXIS 2021: 81).....	36
Abb. 13: Beispiel einer Ground-Reaction-Curve aus FLAC3D (instabil ab $\lambda=0.9$).....	40
Abb. 14: Beispiel einer Längssetzungsmulde bei $R^*=2.1$	42
Abb. 15: Setzungsmulde bei der Nachrechnung von Do et al. (2014).....	43
Abb. 16: berechnete Setzungsmulde des Abschnitt SB1 der U-Bahn in Teheran	44
Abb. 17: berechnete Setzungsmulde des Abschnitt SB2 der U-Bahn in Teheran	44
Abb. 18: Durchmesser zu Überdeckungsverhältnis je Bodenart	46
Abb. 19: Durchmesser zu Überdeckung je Bodenart	46
Abb. 20: Schema eines einfachen Multilayer Perceptrons	47
Abb. 21: ReLU und GeLU Aktivierungsfunktionen	49
Abb. 22: Sigmoid Aktivierungsfunktion	49
Abb. 23: Gradientenverfahren (Géron 2019: 120).....	51
Abb. 24: ShuffleSplit-Beispiel: eigene Darstellung gemäß Pedregosa (2011).....	55
Abb. 25: Beispiel des Modell-Loss nach Trainingsepochen (ANN 1)	56
Abb. 26: Korrelationsmatrix des Trainings- und Testdatensets	70
Abb. 27: Korrelationsmatrix des FLAC-Validierungsdatensets.....	71
Abb. 28: Modellgüte des ANN 1 bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur	75
Abb. 29: Feature Importance (SHAP-Werte) des ANN 1 bezüglich der maximalen Setzung	76
Abb. 30: Modellgüte des ANN 1 bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur	77
Abb. 31: Feature Importance (SHAP-Werte) des ANN 1 bezüglich des Wendepunktabstandes	78

Abb. 32: Modellgüte des ANN 1a bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur	81
Abb. 33: Feature Importance (SHAP-Werte) des ANN 1a bezüglich der maximalen Setzung	82
Abb. 34: Feature Importance (Permutation Importance) des ANN 1a bezüglich der maximalen Setzung	82
Abb. 35: Modellgüte des ANN 1b bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur	85
Abb. 36: Feature Importance (SHAP-Werte) des ANN 1b bezüglich des Wendepunktabstands	86
Abb. 37: Feature Importance (Permutation Importance) des ANN 1b bezüglich des Wendepunktabstands	86
Abb. 38: Modellgüte des ANN 2 bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC.....	90
Abb. 39: Feature Importance (SHAP-Werte) des ANN 2 bezüglich der maximalen Setzung	91
Abb. 40: Modellgüte des ANN 2 bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC.....	92
Abb. 41: Feature Importance (SHAP-Werte) des ANN 2 bezüglich des Wendepunktabstands	93
Abb. 42: Modellgüte des ANN 2a bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC.....	96
Abb. 43: Feature Importance (SHAP-Werte) des ANN 2a bezüglich der maximalen Setzung	97
Abb. 44: Feature Importance (Permutation Importance) des ANN 2a bezüglich der maximalen Setzung	97
Abb. 45: Modellgüte des ANN 2b bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC.....	100
Abb. 46: Feature Importance (SHAP-Werte) des ANN 2b bezüglich des Wendepunktabstands	101
Abb. 47: Feature Importance (Permutation Importance) des ANN 2b bezüglich des Wendepunktabstands	101
Abb. 48: Übersicht über die Weight-Initialization-Methoden.....	105
Abb. 49: Übersicht über die Aktivierungsfunktionen.....	106

Tabellenverzeichnis

Tabelle 1: Datenbank der Setzungsprognosen aus der Literatur	25
Tabelle 2: Übersicht über FE/FDM-Netz Abmessungen	31
Tabelle 3: Übersicht über die Eingangsparameter des MC-Modells	34
Tabelle 4: Übersicht über die Eingangsparameter des PH-Modells	34
Tabelle 5: Verwendete Materialparameter für das Plastic-Hardening-Modell	38
Tabelle 6: Materialeigenschaften des Tunnelausbaus	39
Tabelle 7: Verwendete Hyperparameter für GridSearchCV	54
Tabelle 8: Überblick über die entwickelten ANN	58
Tabelle 9: Datenbank der Setzungsprognosen aus den FDM-Berechnungen	59
Tabelle 10: statistische Beschreibung der Input und Outputfeatures des ANN 1	72
Tabelle 11: Ergebnisse des GridSearchCV für das ANN 1	73
Tabelle 12: Hyperparameter des ANN 1	74
Tabelle 13: Modellgüte des ANN 1 bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse	74
Tabelle 14: Modellgüte des ANN 1 bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse	76
Tabelle 15: Ergebnisse des GridSearchCV für das ANN 1a	79
Tabelle 16: Hyperparameter des ANN 1a	80
Tabelle 17: Modellgüte des ANN 1a bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse	80
Tabelle 18: Ergebnisse des GridSearchCV für das ANN 1b	83
Tabelle 19: Hyperparameter des ANN 1b	84
Tabelle 20: Modellgüte des ANN 1b bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse	84
Tabelle 21: statistische Beschreibung der Input und Outputfeatures des ANN 2	87
Tabelle 22: Ergebnisse des GridSearchCV für das ANN 2	88
Tabelle 23: Hyperparameter des ANN 2	89
Tabelle 24: Modellgüte des ANN 2 bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse	89
Tabelle 25: Modellgüte des ANN 2 bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse	91
Tabelle 26: Ergebnisse des GridSearchCV für das ANN 2a	94
Tabelle 27: Hyperparameter des ANN 2a	95
Tabelle 28: Modellgüte des ANN 2a bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse	95
Tabelle 29: Ergebnisse des GridSearchCV für das ANN 2b	98
Tabelle 30: Hyperparameter des ANN 2b	99
Tabelle 31: Modellgüte des ANN 2b bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse	99

Tabelle 32: Ausschnitt aus Tabelle 1: Datenbank der Setzungsprognosen aus der Literatur.....	104
Tabelle 33: Übersicht über die Performance aller entwickelter ANN.....	108
Tabelle 34: Übersicht über die Performance der linearen Regressionsanalysen	108
Tabelle 35: Feature-Importance Rangfolge der ANN 1/a/b	110
Tabelle 36: Feature-Importance Rangfolge der ANN 2/a/b	110

Abkürzungsverzeichnis

Abb.	Abbildung
Adam	Adaptive Moment Estimation
ANFIS	Adaptive Neuro-Fuzzy Inference System
ANN	Artificial Neural Network
CCM	Convergence-Confinement-Method
EPBM	Earth-Pressure-Balance-Machine
FDM	Finite-Differenzen-Methode
FEM	Finite-Elemente-Methode
GeLU	Gaussian Error Linear Unit
GLR	Ground Loss Ratio
GP	Gaussian Process
GRC	Ground-Reaction-Curve
ITA-AITES	International Tunneling and Underground Space Association Association Internationale des Tunnels et de l'Espace Souterrain
KI	Künstliche Intelligenz
LDP	Longitudinal Displacement Profile
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MARS	Multivariate Adaptive Regression Splines
MC	Mohr-Coulomb
ML	Machine Learning
MSE	Mean Squared Error
NATM	New Austrian Tunneling Method
PCA	Principal Component Analysis
PH	Plastic-Hardening
PSO-ANN	Particle Swarm Optimization-Artificial Neural Network
ReLU	Rectified Linear Unit
RF	Random Forest
RMSE	Root Mean Squared Error
SM	Schildmaschine
SPT	Standard Penetration Test
SVM	Support-Vector Machine
TBM	Tunnelbohrmaschine
TVM	Tunnelvortriebsmaschine

Symbolverzeichnis

Große lateinische Buchstaben

A_t	Querschnittsfläche des Tunnels
C	Überdeckung
D	Tunneldurchmesser
E	Elastizitätsmodul
E_{50}	Sekantensteifigkeit
E_{50}^{ref}	Referenzsekantensteifigkeit bei 50 % der maximalen Deviatorspannung
E_{oed}	Tangentensteifigkeit
E_{oed}^{ref}	Referenztangenteensteifigkeit bei Erstbelastung im Ödometerversuch
E_{ur}	Steifigkeit bei Ent-/Wiederbelastung
E_{ur}^{ref}	Referenzsteifigkeit bei Ent-/Wiederbelastung im Triaxialversuch
H	Abstand von der Bodenoberfläche bis zur Tunnelachse
K	empirischer Beiwert zur Berechnung des Wendepunktabstands i
K_0	Erdruhedruck
P	Abstand der Tunnelstützung von der Ortsbrust
R	Tunnelradius
R^*	Normalisierter Radius der plastischen Zone
R_f	Versagensfaktor
R_p	Radius der plastischen Zone
R_t	Tunnelradius
$S(x)$	Oberflächensetzung in der Distanz x von der Ortsbrust
$S(y)$	Oberflächensetzung in der Distanz y von der Tunnelachse
S_{vmax}	maximale Oberflächensetzung in der Tunnelachse ($y=0$)
V_s	Volumen der Setzungsmulde
V_t	Ground Loss
W	Grenzwerte der ANN-Gewichte bei der Weight Initialization
X	horizontale Entfernung zum seitlichen Rand im FD-Modell
Z	vertikale Entfernung zum unteren Rand im FD-Modell

Kleine lateinische Buchstaben

a	oberer Grenzwert des Zufallszahlengenerators
b	unterer Grenzwert des Zufallszahlengenerators
b_j	Biasausdruck des Neurons j
c	Kohäsion
e	Exponentialfunktion
erf	Gaußsche Fehlerfunktion
f	Funktion; Aktivierungsfunktion
i	horizontaler Abstand des Wendepunktes der Quersetzungsmulde
m	Exponent für die Spannungsabhängigkeit im PH-Materialgesetz
n_j	Anzahl der in den Layer j eingehende Verbindungen
n_{j+1}	Anzahl der vom Layer j ausgehende Verbindungen
p	aufgebrachter Druck bei der CCM
p_0	in-situ Spannung zu Beginn bei der CCM
p_{ref}	Referenzspannung im Triaxialversuch
q	deviatorische Spannung
q_a	Asymptotische Scherfestigkeit
q_f	Versagensscherfestigkeit
s_u	undrainierte Scherfestigkeit (bei bindigen Böden)
u	radiale Verformung des ungesicherten Tunnels
u^*	normalisierte radiale Verformung des ungesicherten Tunnels
u_0	radiale Verformung an der Ortsbrust
u_0^*	normalisierte radiale Verformung an der Ortsbrust
u_{max}	maximale radiale Verformung des ungesicherten Tunnels
$w_{i,j}$	Gewichtung der einzelnen Inputs für das Neuron j
x	Entfernung von der Ortsbrust
x^*	normalisierte Entfernung
x	Ursprungswert bei der Standardisierung
x'	standardisierter Wert
$\bar{x}$	Mittelwert der Ursprungswerte
x_i	Input Neuron
y	horizontaler Abstand von der Tunnelachse
$\bar{y}$	Mittelwert der Beobachtungen
$\hat{y}_i$	berechneter Wert der i -ten Beobachtung
y_i	wahrer Wert der i -ten Beobachtung
y_j	Output des Neurons j

Kleine griechische Buchstaben

α	Strafausdruck bei der L2-Regularisierung
γ	Wichte des Bodens
ε_1	vertikale Verzerrung
λ	Vorentlastungsfaktor
ν	Poissonzahl
π	Kreiszahl
ρ	Dichte des Bodens
σ	Standardabweichung
σ'_v	effektive vertikale Spannung
$\sigma_1, \sigma_2, \sigma_3$	Hauptspannungen
σ^2	Varianz
σ_{MSE}	Standardabweichung des MSE während des GridsearchCV
σ_p	Stützdruck an der Ortsbrust
σ_s	Bodenauflast
σ_x	Standardabweichung der Ursprungswerte
φ	Reibungswinkel
ψ	Dilatanzwinkel

1 Einleitung

1.1 Motivation

Seichtliegende Tunnelbauvorhaben stellen in urbanen Räumen große Herausforderungen dar. Oft werden U-Bahn- oder Straßentunnel in Lockergestein unter dicht besiedeltem Raum gebaut; eine Tatsache, die sich in den letzten Jahren durch das Bevölkerungswachstum im städtischen Umfeld und der damit einhergehenden Nachfrage nach neuen öffentlichen Verkehrsmitteln bzw. durch den oberirdisch immer knapper werdenden Raum für neue Straßenbauten immer weiter akzentuiert hat. Hierbei stellen tunnelbaubedingte Oberflächensetzungen, wenn diese nicht bekannt sind, eine Gefahr für bestehende Gebäude und Infrastrukturen dar, da ansonsten keine weiteren Maßnahmen zur Vorbeugung oder Kontrolle der Setzungen getroffen werden können.

Tunnelbaubedingte Setzungen hängen von vielen verschiedenen Faktoren ab, welche geometrischer, bauablaufbedingter, hydro-geologischer und geotechnischer Natur sein können. Des Weiteren werden real vorkommende Böden stark durch heterogene Verhältnisse geprägt. Zusätzlich herrschen auch Unsicherheiten in der versuchstechnischen Bestimmung der Bodenparameter durch etwaige schlechte Probennahmen oder Versuchsdurchführungen vor. Zudem bestehen zwischen den vorhin genannten unterschiedlichen Faktoren Abhängigkeiten. Durch diese Limitierungen führt eine direkte Berechnung der Oberflächensetzung mit empirischen und analytischen Formeln nur in sehr einfachen Ausnahmefällen zu guten Ergebnissen. Deswegen sind numerische Simulationen durch Methoden der finiten Elemente bzw. finiten Differenzen der Stand der Technik der Tunnelvortriebssimulation.

Vor allem mit fortgeschrittenen Materialgesetzen wie z.B. dem Plastic-Hardening-Materialgesetz können mittels numerischer Berechnungen gute Ergebnisse erzielt werden. Durch dreidimensionale Berechnungen kann die Realität am besten nachgebildet werden, jedoch erfordern diese ein hohes Maß an fachlichen Kenntnissen sowie Zeit. Mit Vereinfachungen und Näherungen können schnellere zweidimensionale Berechnungen durchgeführt werden, welche, wenn die getroffenen Annahmen weitestgehend stimmen, ebenfalls gute Ergebnisse erzielen, wobei auch hier Expertise in der Handhabung gefragt ist.

Eine in den letzten Jahren vermehrt angewandte Alternative zu den herkömmlichen Setzungsberechnungen stellt die Verwendung von Machine Learning (ML) Methoden, welche eine Unterkategorie der Künstlichen Intelligenz (KI) sind, dar. In unterschiedlichen geotechnischen Fragestellungen wurden in den letzten Jahren ML-Techniken bereits mit Erfolg angewandt, so auch zur Voraussage von tunnelbaubedingten Setzungen. Durch die stetig besser werdenden Algorithmen und die generellen Rechenfähigkeiten von Computern sowie durch die Menge an verfügbaren Daten werden diese Methoden immer attraktiver. Nach Entwicklung eines ML-Algorithmus können Setzungsprognosen für neue Fälle in Sekundenschnelle ohne die Notwendigkeit von aufwendigen numerischen Rechnungen getroffen werden. Ein gut entwickelter ML-Algorithmus bietet somit die Möglichkeit, zeitsparend und mit weniger fachlichen Kenntnissen Setzungsvoraussagen zu erstellen. Naturgemäß sind die berechneten Prognosen nicht so exakt wie numerische Berechnungen, da sie nur eine Näherung darstellen, jedoch können hinreichend genaue Ergebnisse erzielt werden. Durch die Zeit- und Kosteneinsparung könnten in Zukunft ML-Anwendungen z.B. in der Vorstudienphase zur schnellen Abschätzung der zu erwartenden Setzungen eingesetzt werden.

1.2 Aufgabenstellung und Zielsetzung

Ziel dieser Arbeit ist die Entwicklung von mehreren Artificial Neural Networks (ANN) mit unterschiedlichen Netzwerkarchitekturen und Eingangsparametern zur Prognose von tunnelbaubedingten Oberflächensetzungen, wobei nachfolgend das beste Modell mittels

verschiedener statistischer Gütemaße bestimmt wird. Anschließend werden die wichtigsten Inputfeatures der ANN mit zwei unterschiedlichen Methoden berechnet, um einen Überblick über die für eine erfolgreiche Setzungsprognose wichtigsten Faktoren zu erlangen. Die Datengrundlage für die ML-Anwendung stellt eine im Zuge dieser Arbeit erstellte Datenbank an zweidimensionalen numerischen Berechnungen dar, welche mit dem Finite-Differenzen-Methoden-Programm FLAC3D (Itasca Consulting Group, Inc 2017) durchgeführt wurden.

1.3 Aufbau der Arbeit

Kapitel 2 Literaturstudie und Grundlagen

Zu Beginn der Arbeit werden die wichtigsten Grundlagen bezüglich Tunnelvortrieben und den damit verbundenen Oberflächensetzungen inklusive verschiedener Berechnungsansätze in einem kurzen Literaturstudium erörtert. Außerdem wird ein allgemeiner Überblick über KI, ML-Methoden sowie über bereits publizierte Anwendungen derer in geotechnischen und tunnelbaubezogenen Fragestellungen gegeben.

Kapitel 3 Methodologie

Das erste Unterkapitel 3.1 beschäftigt sich näher mit den Tunnelbausimulationen mittels der Methode der Finiten-Differenzen, wobei auf die Rand- und Anfangsbedingungen, die verwendeten Materialgesetze, Bodenparameter und Geometriekombinationen näher eingegangen wird. Des Weiteren wird die Convergence-Confinement-Methode zur Berücksichtigung der dreidimensionalen Effekte in einer zweidimensionalen Berechnung inklusive Berechnungsablauf und Beispielberechnungen beschrieben.

Unterkapitel 3.2 widmet sich der Funktionsweise und dem Entwicklungsablauf inklusive der Suche nach der optimalen Netzwerkarchitektur eines ANN. Die Gütemaße zur Beurteilung der Modellperformance werden ebenso vorgestellt wie die Bestimmungsmethoden der wichtigsten Inputfeatures.

Kapitel 4 Ergebnisse

Zuerst wird die berechnete Datenbank der Finiten-Differenzen-Berechnungen präsentiert. Anschließend wird für jedes entwickelte Netzwerk die ermittelte optimale Architektur, die Modellgüte anhand verschiedener Gütemaße sowie die wichtigsten Eingangsparameter wiedergegeben.

Kapitel 5 Diskussion der Ergebnisse

In diesem Kapitel werden die Ergebnisse zusammengefasst und diskutiert. Limitierungen der numerischen Berechnungen sowie die generelle Qualität der Datengrundlage werden ebenso untersucht wie der Einfluss unterschiedlicher Netzwerkarchitekturen auf die Modellperformance. Abschließend werden die wichtigsten Inputfeatures präsentiert sowie ein Ausblick und Verbesserungsvorschläge für etwaige zukünftige Anwendungen von ML-Techniken zur Prognose von tunnelbaubedingten Setzungen gegeben.

Kapitel 6 Conclusio

In der Conclusio werden die durchgeführte Forschung und die wichtigsten Ergebnisse zusammengefasst.

Anhang A: FLAC-Berechnungsfile Beispiel

Im Anhang A wird der FLAC-Berechnungscode eines Beispiels präsentiert.

Anhang B: TensorFlow-Codes

Im Anhang B liegen die entwickelten TensorFlow-Codes und die verwendete Datenbank auf einem Datenträger bei.

2 Literaturstudie und Grundlagen

2.1 Tunnelvortrieb

2.1.1 Zyklischer Vortrieb

Unter zyklischem Vortrieb wird laut Galler (2014: 89) „die Erschließung eines unterirdischen Hohlraums mit beliebigem Querschnitt unter Anwendung hintereinander ablaufender Arbeitsschritte“ verstanden. Ein mehr oder minder äquivalenter Begriff, welcher in der englischsprachigen Literatur zumeist verwendet wird, ist der der New Austrian Tunneling Method (NATM; Neue österreichische Tunnelbauweise NÖT). Die Arbeitsschritte des Ausbruchs durch Sprengen, Bohren oder mechanische Vortriebsmaschinen, die Förderung des Ausbruchs (Schuttern) und das Sichern mit temporären Maßnahmen wie Spritzbeton, Bewehrungsnetzen sowie Ankern wiederholen sich laufend, woher der Name des zyklischen Vortriebs stammt. Ein Vorteil dieser Vortriebsart ist es, dass sehr flexibel auf geänderte Baugrundverhältnisse und Gebirgsverhalten durch Anpassung der Sicherungsmaßnahmen reagiert werden kann. Darunter fallen z.B. die Veränderung der Stärke der Spritzbetonschale, der Anzahl und Länge der Anker, die Verringerung der Ringschlusszeit und der Distanz zwischen Ortsbrust und Ringschluss, die Veränderung der Abbauart oder der Abschlagslänge. Durch diese hohe Flexibilität ist der zyklische Vortrieb bestens für Tunnelbauten in stark veränderlichen geologischen-hydrogeologischen-geotechnischen Bedingungen geeignet (vgl. Galler 2014: 89-90).

Der Ausbruch geschieht entweder durch mechanischen Abbau z.B. unter Zuhilfenahme von Baggern oder Teilschnittmaschinen oder durch Sprengen und Bohren. Erstere Variante findet ihr Hauptanwendungsgebiet im Lockergestein, zweiteere vornehmlich im Festgestein. Die Abschlagslänge richtet sich nach der Standsicherheit des Bodens bzw. Gebirges und beträgt rund 1 m im Locker- und maximal 4 m im Festgestein. Prinzipiell gibt es viele unterschiedliche Ausbruchsabfolgen, die grob in einen Vollausbruch und einen Teilausbruch eingeteilt werden können. Beim Vollausbruch wird der gesamte Querschnitt auf einmal freigelegt, wodurch dieser nur bei guten Standsicherheitsbedingungen und eher kleineren Querschnitten angewandt wird. Im Lockergestein oder in großen Querschnitten werden jedoch vor allem teilflächige Ausbrüche durchgeführt, wobei der Querschnitt in Kalotte, Strosse und Sohle geteilt wird. Bei dieser Ausbruchsart wird die Kalotte den anderen Teilen vorseilend abgebaut (siehe Abb. 1), wodurch sich der Aufwand für die Ortsbruststützung reduziert. Ein weiterer Vorteil ist es, dass beim Teilausbruch unterschiedliche Ausbruchsmethoden innerhalb desselben Querschnittes möglich sind. Nachteilig wirken sich hingegen die mehrfachen Spannungsumlagerungen bei jedem Teilausbruch aus (vgl. Galler 2014: 101-103).




Abb. 1: Kalottenvortrieb (Galler 2014: 104)

Nach dem Ausbruch und dem Schottern erfolgt die Stabilisierung des gerade entstandenen Hohlraums mittels Spritzbeton, Ankern oder Stahlbögen, welche je nach der tatsächlichen Baugrundsituation möglichst nahe der Ortsbrust eingesetzt werden. Zweck der Sicherungsmaßnahmen ist die Stabilisierung des Tunnels als auch die Gewährleistung der Arbeitssicherheit. Zusätzlich werden oft noch andere Sicherungsmaßnahmen wie Baugrundverbesserungen, Voraussicherungen und Entwässerungen durchgeführt. Die häufigsten Baugrundverbesserungen sind das Verpressen (entweder radial oder der Ortsbrust), Hochdruckinjektionen (meist im First- und Kämpferbereich) und das Gefrierverfahren. Unter Voraussicherungsmaßnahmen fallen das vorausschneidende Einbringen von statisch wirksamen Stahlelementen wie Spießen, Rohrschirmen oder Ortsbrustankern. Ziel aller zusätzlichen Sicherungsmaßnahmen ist es, die mechanischen und/oder hydraulischen Eigenschaften des Baugrundes zu verbessern bzw. den Lastabtrag zu unterstützen, um so die Standsicherheit zu gewährleisten (vgl. Galler 2014: 103-108).

2.1.2 Maschineller Vortrieb: Schildvortrieb

Beim maschinellen Vortrieb - dem Tunnelbau mittels Tunnelvortriebsmaschinen (TVM) - wird grundsätzlich zwischen Tunnelbohrmaschinen (TBM) und Schildmaschinen (SM) unterschieden. Da bei TBM keine Möglichkeiten der Stützung der Ortsbrust gegeben sind, liegt ihr Anwendungsbereich in standfestem Festgestein (vgl. Thewes 2014: 124). Im Zuge dieser Arbeit werden jedoch Tunnel im Lockergestein behandelt, weswegen nachfolgend nur ein kurzer Überblick über die wichtigsten Verfahren des Schildvortriebs gegeben wird.

SM bestehen aus einem Bohrkopf bzw. Schneiderad und aus einem äußeren Mantel aus Stahl, welcher während des Baus den Untergrund stützt und Schutz vor herabfallendem Boden bietet (siehe Abb. 2). Maximale Durchmesser von SM belaufen sich auf rund 15 m. Innerhalb des Schildmantels werden Betonfertigteile (Tübbinge) zu einem geschlossenen Ring rund um den Ausbruchsquerschnitt zusammengefügt. In der Regel haben Tübbinge eine Stärke von 20 bis 50 cm mit einer Ringlänge von 1 bis 2 m und werden in der Betonfestigkeitsklasse C40/50 ausgeführt. Die zuletzt installierten Tübbinge dienen als Widerlager für das Vorpressen der SM. Ab dem Zeitpunkt des Verlassens des Stahlmantels übernehmen die Betonfertigteile die vollen Lasten aus der Umgebung und tragen diese vornehmlich über Ringnormalkräfte ab. Vorteilhaft bei der Verwendung von Fertigteilen ist, dass diese sofort statisch wirksam und bei entsprechender Abdichtung nach Erhärtung des Ringspaltmörtels auch wasserdicht sind (vgl. Fischer, et al. 2014: 236-258).




Abb. 2: Schema einer Schildmaschine (Thewes 2014: 131)

Zwischen dem Schildmantel und den eingebauten Tübbingern befindet sich während des Vortriebs aufgrund des Überschnitts, der Konizität des Schildmantels und der generellen Bauhöhe des Schildschwanzes der sogenannte, meist 13 bis 18 cm dicke, Ringspalt. Zur Verminderung von Setzungen des Bodens und von Verformungen der Tübbinge muss der Ringspalt kraftschlüssig verfüllt werden. Dies geschieht mit zementhaltigen Mörteln und gut gerundeten Sanden bzw. Kiesen, mit Perlkies oder Zwei-Komponenten-Verpressmitteln. Die Verpressung des Ringspalts geschieht kontinuierlich entweder durch den Schildschwanz oder durch mit Rückschlagklappen ausgestattete Öffnungen in den Tübbingern (bei Anwendung von Perlkies) (vgl. Thewes 2014: 131-134).

SM können je nach Bauart den Abbau entweder im Vollschnitt mittels eines Schneiderads oder im Teilschnitt mittels Bagger oder Fräse durchführen. Die Stützung der Ortsbrust erfolgt auf verschiedene Arten, wobei hier nur auf die drei gebräuchlichsten, nämlich die Stützung mit Druckluftbeaufschlagung, durch Flüssigkeit und durch Erddruck angeführt werden.

Der Einsatz von Druckluft verhindert im Tunnelbau den Eintritt von Grundwasser. Das Prinzip der Stützung ist es, dass in der Abbaukammer der SM ein Luftdruck aufgebracht wird, der gleich groß ist wie der Wasserdruck an der Sohle des Querschnittes. Es bildet sich eine Luftströmung bis an die Geländeoberfläche aus, sofern sich keine (wasser)undurchlässigen Schichten über der SM befinden. Die Druckluft darf jedoch nicht zur Aufnahme des Erddrucks angesetzt werden; diese muss mittels mechanischer Stützung geschehen (vgl. Thewes 2014: 128).

Bei den SM mit Flüssigkeitsstützung (Hydro-Schild und Slurry Schild) erfolgt die Stützung der Ortsbrust und die Förderung des Aushubs mittels einer Flüssigkeit. Zumeist wird eine Bentonitsuspension eingesetzt, da deren rheologische Eigenschaften einen positiven Einfluss auf die Stützung und die Förderleitung haben. Die Stützwirkung dieser Hydro-Schilde beruht darauf, dass die Suspension an der Ortsbrust in den Boden eindringt und dort einen gering-luftdurchlässigen Filterkuchen bildet. Dadurch kann Druckluft eingesetzt werden, um die Ortsbrust gegen den anstehenden Erd- und Wasserdruck zu stützen. Der anstehende Boden wird anschließend im Vollschnitt durch ein Schneiderad abgebaut und mittels der flüssigen Suspension zu einer Separations- und Aufbereitungsanlage befördert, wo die Bestandteile voneinander getrennt werden und die Bentonitsuspension wiederaufbereitet wird. Die Regelung des Luftdrucks geschieht nicht direkt über den Suspensionsdruck, sondern über eine Druckluftblase, welche sich in der hinteren, durch eine Tauchwand von der Abbaukammer getrennten Arbeitskammer über der Suspension befindet, da somit der Stützdruck besser eingehalten werden kann (vgl. Thewes 2014: 129).

Flüssigkeitsschilde sind sehr vielseitig über das größte Spektrum von verschiedenen Baugrundverhältnissen einsetzbar. Ideal ist jedoch der Einsatz in schluffigen Sanden bis hin zu Kiessanden, da diese einfach von der Bentonitsuspension zu separieren sind (vgl. Thewes 2014: 179).

SM mit Erddruckstützung werden auch als Earth-Pressure-Balance-Machines (EPBM) bezeichnet. Bei dieser Art des Schildvortriebs wird die Ortsbrust mittels des durch ein Schneiderad bereits abgebauten Materials, welches in der Abbaukammer unter Druck gesetzt wird, gestützt. Der Rest der SM ist von der Abbaukammer mittels einer Druckwand getrennt und befindet sich unter atmosphärischen Druck. Aus der Abbaukammer gelangt das Material über eine Förderschnecke in den hinteren Teil der SM, wobei die Druckdifferenz zwischen den beiden Kammern über Reibung entlang der Schnecke und den Widerstand der Schneckenwendel abgebaut werden muss.

Die Regulierung des Stützdrucks erfolgt durch das Regeln der Zuflüsse (durch die Vortriebsgeschwindigkeit begrenzt), die Zugabe von Konditionierungsmitteln (z.B. Bentonit oder Tenside), um den Boden in eine breiigere Konsistenz zu versetzen, und durch die Veränderung des Abflusses durch Regelung des Schneckenförderers (vgl. Thewes 2014: 129).

EPBM stellen heutzutage den am meisten verwendeten Typ der SM dar, da auch sie in einem weiten Spektrum eingesetzt werden können, gleichzeitig aber auch ohne einen allzu komplexen Aufbau im Vergleich zu Flüssigkeitsschilden auskommen. Ihr früheres

Einsatzgebiet von Böden mit mindestens 30 % Feinanteil hat sich durch Hinzugabe von den oben genannten Konditionierungsmitteln stark erweitert und überlappt mittlerweile sehr stark mit dem der flüssigkeitsgestützten SM (vgl. Thewes 2014: 184-185).

2.2 Tunnelbaubedingte Setzungen

Egal wie sorgsam und mit welchen Methoden ein Tunnel gebaut wird, kommt es zwangsläufig zu einer Spannungsumlagerung und damit verbundenen Bodendeformationen, welche sich an der Bodenoberfläche durch Setzungserscheinungen abzeichnen können. Prinzipiell kann im Tunnelbau zwischen Tunneln im Fels und Tunneln im Lockergestein unterschieden werden, die jeweils andere Setzungscharakteristika hervorrufen und für die meist auch andere Setzungstoleranzen gelten (vgl. Möller 2006: 11-12; Fillibeck 2012: 14-15). In dieser Arbeit wird im folgenden Kapitel jedoch nur ein Überblick über das durch Tunnel im Lockergestein hervorgerufene Setzungsverhalten geliefert und die Tunnel im Festgestein außen vor gelassen, da bei diesen vor allem durch größere Heterogenitäten wie Trennflächen und unterschiedliche Gebirgsfestigkeiten bedingte Mechanismen ausschlaggebend werden.

Gemäß der International Tunneling and Underground Space Association- Association Internationale des Tunnels et de l'Espace Souterrain (vgl. ITA-AITES 2007: 120) hängen tunnelbaubedingte Bodenbewegungen von mehreren Faktoren wie 1) den geologischen, hydro-geologischen und geotechnischen Bedingungen 2) der Tunnelgeometrie und -tiefe 3) der Vortriebsart und 4) der Qualität der Arbeitsausführung ab.

2.2.1 Ortsbruststandsicherheit und Ausbreitung der Bodenbewegung in Richtung Oberfläche

Die Betrachtung der Standsicherheit an der Ortsbrust gibt erste Hinweise auf die Parameter, auf die Bedacht genommen werden muss, und auf die Fehlermechanismen, welche zu erwarten sind. Im Generellen hängen die tunnelbaubedingten Setzungen an der Oberfläche von der Schichtung des Bodens, der kurz- und langzeitigen Verformbarkeit des Bodens, der Anisotropie und den vorherrschenden hydro-geologischen Bedingungen ab. In der folgenden Abbildung sind die geometrischen Parameter abgebildet, die aufgrund von theoretischen und experimentellen Untersuchungen ermittelt wurden (vgl. ITA-AITES 2007: 120-122):




Abb. 3: Stabilitätsparameter der Ortsbruststandsicherheit¹

Im Falle einer instabilen Ortsbrust kommt es in bindigen Böden zu einem Versagensmechanismus, bei dem sich ein Sinkhole vor der Ortsbrust bildet, wohingegen bei nicht-bindigen Böden eher ein kaminartiger Mechanismus zu erwarten ist (vgl. ITA-AITES 2007: 121).

¹ Genauere Betrachtungen der Ortsbruststandsicherheit können (ITA-AITES 2007: 122-133), Zizka, Z. & Thewes, M., 2016. Recommendations for Face Support Pressure Calculations for Shield Tunnelling in Soft Ground. Köln: Deutscher Ausschuss für unterirdisches Bauen e. V. (DAUB) sowie Broms, B.B., Bennemark, H., 1967. Stability of clay at vertical openings. ASCE, Journal of Soil Mechanics and Foundation Engineering Division, SMI 93, 71–94. entnommen werden.

Auch bei stabilen Verhältnissen kommt es ausgehend von der Ortsbrust zu Bodenbewegungen, die sich je nach geotechnischen und geometrischen Bedingungen unterschiedlich schnell in Richtung Oberfläche ausbreiten. Während der Tunnelbau fortschreitet, entstehen vertikale und horizontale Bodenbewegungen an der Oberfläche, welche eine dreidimensionale Setzungsmulde bilden (vgl. ITA-AITES 2007: 121-122). Die genauere Beschreibung dieser Setzungsmulde erfolgt in Kapitel 2.2.4.

2.2.2 Bautechnisch bedingte Setzungen

Bodenbewegungen entlang der Mittelachse eines Tunnels beginnen in einiger Entfernung vor der Ortsbrust und wachsen so lange an, bis eine endgültige steife Verbauung vorhanden ist. Aufgrund der unterschiedlichen Vortriebsweisen und den damit verbundenen Setzungsverhalten muss zwischen Spritzbeton- und Schildvortrieb unterschieden werden (vgl. ITA-AITES 2007: 123).

2.2.2.1 Zyklischer Vortrieb

Beim zyklischen Vortrieb werden laut ITA-AITES (2007: 124) vor allem vier Einflussfaktoren tragend:

- 1.) Ortsbruststabilität
- 2.) Temporäre Sicherungsmaßnahmen
- 3.) Ablauf des Vortriebs
- 4.) Installation und Eigenschaften der Tunnelschale

Der Einfluss der Ortsbruststabilität ist beim zyklischen Vortrieb sehr groß und es zeigt sich ein eindeutiger Zusammenhang zwischen der Ortsbruststabilität und den Setzungen, die sich vor der Ortsbrust ergeben (siehe Kapitel 2.2.1). Daher ist beim zyklischen Vortrieb die Kontrolle der Ortsbruststabilität von sehr großer Bedeutung (vgl. ITA-AITES 2007: 123-124).

Die Wahl und die Einbaugeschwindigkeit der temporären Sicherungsmaßnahmen wirken sich auf die zu erwartenden Setzungen aus. Einerseits müssen die Sicherungsmaßnahmen eine hinreichende Steifigkeit besitzen, andererseits ist auch die Installationszeit und die räumliche Entfernung der Sicherungsmaßnahmen zur Ortsbrust entscheidend für die Setzungsentwicklung. Im Allgemeinen ist eine zeitnahe Installation eines steifen Systems näher zur Ortsbrust am besten geeignet, Setzungen gering zu halten (vgl. ITA-AITES 2007: 123-124).

Auch der Ablauf des Tunnelvortriebs beeinflusst die Bodenverformungen. Vor allem an der Ortsbrust ist das Verhältnis der offenen Ortsbrust zur gesamten Ortsbrust wichtig. Für die Setzungen hinter der Ortsbrust ist die Länge des ungesicherten Abschlages der wichtigste Einflussfaktor. Die Setzungen in einiger Distanz zur Ortsbrust werden durch die Entfernung der permanenten Sicherungsmaßnahmen mit höherer Steifigkeit zur Ortsbrust beeinflusst. Eine schnelle Installation dieser führt zu weniger Verformungen (vgl. ITA-AITES 2007: 124).

In Tunneln mit geringer Überdeckung und großen Spannweiten ist auch die Verformung der Tunnelschale zu berücksichtigen (vgl. ITA-AITES 2007: 124). Die zuerst aufgebrachte Spritzbetonschicht hat eine geringere Festigkeit, wodurch es im Vergleich zu Tübbingfertigteilen zu höheren Verformungen kommt. Der Lastübertrag auf die endgültige Tunnelschale ruft hingegen nur noch geringe zusätzliche Verformungen hervor (vgl. Fillibeck 2012: 18).

2.2.2.2 Schildvortrieb

Beim Schildvortrieb sind gemäß ITA-AITES (2007: 124-125) folgende vier Einflussfaktoren besonders hervorzuheben:

- 1) Setzungen über und vor der Ortsbrust
- 2) Setzungen entlang des Schildes
- 3) Setzungen beim Schildschwanz
- 4) Setzungen durch die Verformungen der Tunnelschale

Setzungen über und vor der Ortsbrust entstehen durch den Eingriff in das in-situ Spannungsgleichgewicht durch den Bodenabbau. Um den Einfluss möglichst gering zu halten, sollte auf möglichst geringe Spannungsumlagerungen durch eine gute Stützung der Ortsbrust acht genommen werden (vgl. Fillibeck 2012: 15). Setzungen entstehen laut ITA-AITES (2007: 124) durch die Größe des Stützdrucks, die Bodenverhältnisse und die hydraulischen Bedingungen.

Entlang des Schildes entstehen Setzungen durch die Konizität des Schildmantels und den Überschnitt des Schneiderads, welcher aufgrund der geringeren Reibung eingesetzt wird. Auch das Einsinken des Schildes wegen seines hohen Gewichts, dem mittels leicht aufwärts gerichteten Vortriebes entgegengewirkt wird, bewirkt einen größeren Überschnitt. Es entsteht dadurch ein größerer Ausbruchsquerschnitt an der Ortsbrust, als das am Ende des Schildschwanzes der Fall ist. Durch die nachträglich eintretende Schließung dieses Ringspalt entstehen zusätzliche Setzungen entlang des Schildmantels (vgl. ITA-AITES 2007: 124-125).

Auch der am Schildschwanz entstehende Ringspalt (je nach Bauart der Tunnelvortriebsmaschine) zwischen dem Lockergestein und den Tübbing bewirkt Setzungen. Um diese gering zu halten, muss dieser Ringspalt ordnungsgemäß verpresst werden (vgl. ITA-AITES 2007: 125).

Setzungen durch die Verformung der Tunnelschale spielen, sofern der Ringspalt richtig verpresst wurde, eine untergeordnete Rolle, da diese bereits als Fertigteil vollständig ausgehärtet sind (vgl. ITA-AITES 2007: 125).

2.2.3 Setzungen durch den Einfluss von Grundwasser

In der ersten Kategorie treten Setzungen durch eine Grundwasserabsenkung vor oder während des Baufortschrittes ein. Dies betrifft zusammendrückbare Böden und verwitterten Fels. An der Ortsbrust kann sich Grundwasser negativ auf Setzungen auswirken. Der hydraulische Gradient schwächt die mechanischen Eigenschaften an der Ortsbrust, den Seiten und an der Sohle, wodurch höhere Verformungen auftreten (vgl. ITA-AITES 2007: 125).

In weichen, zusammendrückbaren Böden werden auch verzögerte Setzungen beobachtet. Durch den Bau eines Tunnels kann der Boden lokal einer höheren Spannung ausgesetzt werden, wodurch Porenwasserüberdrücke entstehen können. Zusätzlich können auch durch Sickerwasserströmungen hin zum Tunnel während oder nach dem Bau Konsolidierungserscheinungen im gesamten Boden auftreten. Im Allgemeinen sind die Konsolidierungssetzungen in Bereichen mit einer größeren Reduktion der Porenwasserdrücke höher (vgl. ITA-AITES 2007: 125).

2.2.4 Berechnungsmethoden für tunnelbaubedingte Setzungen

Zur Abschätzung von tunnelbaubedingten Setzungen gibt es mehrere Methoden, die in diesem Kapitel vorgestellt werden. Dazu zählen die - in der Vergangenheit am häufigsten angewandten - empirischen und semi-empirischen Methoden, numerische Analysen, analytische Lösungen sowie auch Methoden der künstlichen Intelligenz. Die ersten drei

Methoden werden nach der allgemeinen Beschreibung der Form von Setzungsmulden kurz vorgestellt, auf letztere wird in Kapitel 2.5 eingegangen.

2.2.4.1 Beschreibung der Quersetzungsmulde

Nach Auswertung verschiedener Setzungsmulden über Tunneln zeigten Peck (1969) und Schmidt (1969), dass die Setzungsmulden normal zur Vortriebsrichtung (Quersetzungsmulden) die Form einer Gauß'schen Normalverteilungskurve annehmen.




Abb. 4: Schematische Quersetzungsmulde

Diese Gauß'sche Kurve nimmt die folgende Form an (vgl. ITA-AITES 2007: 128):

$$S(y) = S_{vmax} \cdot e^{\frac{-y^2}{2 \cdot i^2}} \quad \text{Formel 2-1}$$

wobei:

$S(y)$ = Oberflächensetzung in der Distanz y von der Tunnelachse

S_{vmax} = maximale Oberflächensetzung in der Tunnelachse ($y=0$)

y = horizontaler Abstand von der Tunnelachse

i = horizontaler Abstand des Wendepunktes von der Tunnelachse

sind. Der Wendepunkt Abstand entspricht der Standardabweichung der Kurve und ist ein Maß der Breite der Setzungsmulde. Durch Integration von Formel 2-1 kann die Fläche der Setzungsmulde pro Meter des Vortriebs berechnet werden (vgl. O'Reilly & New 1982: 2):

$$V_s = \int_{-\infty}^{\infty} S(y) dy = \int_{-\infty}^{\infty} S_{vmax} \cdot e^{\frac{-y^2}{2 \cdot i^2}} dy = \sqrt{2\pi} \cdot i \cdot S_{vmax} \approx 2.5 \cdot i \cdot S_{vmax} \quad \text{Formel 2-2}$$

Zusätzlich zur Setzungsmulde machen sich Verformungen auch an der Ortsbrust bemerkbar. In der englischen Fachliteratur wird hierbei von Volume Loss/Ground Loss am Tunnel gesprochen. Dieses Ground Loss ist das Bodenvolumen, das sich in den Tunnel nach dem Bau des Tunnels verformt hat (vgl. Möller 2006: 15). Abschätzen lässt sich dieses Volumen mittels der Convergence-Confinement Methode (CCM), welche in Kapitel 3.1.7 näher beschrieben wird. Eine einfache Näherungslösung ist es jedoch, den Boden als inkompressibel zu betrachten, wodurch das Volumen der Setzungsmulde V_s gleich dem Ground Loss V_t ist. Natürlich ist diese Annahme stark abhängig von den Bodeneigenschaften und der Überdeckung und am ehesten für seichtliegende Tunnel in bindigen Bodenschichten gültig. Im Allgemeinen gilt auch, dass $V_s < V_t$ ist, wobei die Unterschiede gering sind und somit $V_s \approx V_t$ ist (vgl. ITA-AITES 2007: 128).

Wird die Ground Loss Ratio GLR eingeführt


$$GLR = \frac{V_t}{A_t} \approx \frac{V_s}{A_t} \quad \text{Formel 2-3}$$

wo A_t = die Querschnittsfläche des Tunnels ist, können die Setzungen unter Zuhilfenahme von Formel 2-1 und Formel 2-2 auch folgendermaßen ausgedrückt werden (vgl. Möller 2006: 16):

$$S_{vmax} \approx GLR \cdot \frac{A_t}{\sqrt{2\pi} \cdot i} \quad \text{Formel 2-4}$$

$$S(y) \approx GLR \cdot \frac{A_t}{\sqrt{2\pi} \cdot i} \cdot e^{\frac{-y^2}{2 \cdot i^2}} \quad \text{Formel 2-5}$$

2.2.4.2 Beschreibung der Längssetzungsmulde



Das Setzungsprofil in Richtung der Tunnelachse nimmt laut Attewell et al. (1986) die Form einer kumulierten Wahrscheinlichkeitsfunktion an, deren Form in Abb. 5 ersichtlich ist. Es kommt auch vor der aktuellen Ortsbrust zu Setzungen. Mit Formel 2-6 kann die Setzung über der Mittelachse eines Tunnels in der Entfernung x von der Ortsbrust berechnet werden (vgl. Möller 2006: 22). Die restlichen Parameter sind dieselben wie in Formel 2-1:

$$S(x) = S_{vmax} \cdot \frac{1}{i \cdot \sqrt{2\pi}} \cdot \int_{-\infty}^x e^{\frac{-x^2}{2 \cdot i^2}} \quad \text{Formel 2-6}$$

Abb. 5: tunnelbaubedingte Setzungsmulde nach Attewell et al. (1986) aus Möller (2006: 12)

2.2.4.3 Empirische Methoden zur Berechnung der Setzungen

Vor allem in der Vorstudienphase werden empirische Methoden noch immer recht häufig angewandt, da mit ihnen schnell und mit einfachen Mitteln erste Abschätzungen erzielt werden können. Der Nachteil dieser empirischen Methoden ist jedoch, dass oft die Vortriebsart nicht berücksichtigt wird, obgleich diese einen großen Einfluss auf die zu erwartenden Setzungen hat. Besonders schlechte Arbeitsausführung und unerwartete Bodenverhältnisse führen oft zu viel größeren Setzungen als berechnet (vgl. ITA-AITES 2007: 126-129).

2.2.4.3.1 Wendepunktabstand i

Auf Basis von Messungen im Feld, Berechnungen und Laborversuchen haben in den letzten 50 Jahren einige Forscher*innen eigene empirische Gleichungen zur Ermittlung des Wendepunktabstands i entwickelt. Peck (1969) schlug eine Formulierung in Abhängigkeit vom Tunneldurchmesser und vom Abstand von der Bodenoberfläche bis zur Tunnelachse (Tunneltiefe H) vor (vgl. Möller 2006: 16-17). O'Reilly und New (1982: 5-6) analysierten ihre Felddaten und führten mehrere lineare Regressionsanalysen durch, wobei sie keine signifikante Korrelation zwischen dem Wendepunktabstand i und dem Tunneldurchmesser, aber einen starken Zusammenhang zwischen der Tunneltiefe und dem Wendepunktabstand fanden, wobei H und i in Metern einzusetzen sind:

$$i = 0.43 \cdot H + 1.1 \approx K \cdot H = 0.5 \cdot H \quad \text{für bindige Böden} \quad \textbf{Formel 2-7}$$

$$i = 0.28 \cdot H - 0.1 \approx K \cdot H = 0.25 \cdot H \quad \text{für nicht-bindige Böden} \quad \textbf{Formel 2-8}$$

Mair und Taylor (1997) bestätigten die Ergebnisse von O'Reilly und New (1982) grundsätzlich, stellten aber andere K -Beiwerte fest. Für bindige Böden reicht K von 0.4 bis 0.6, für nicht bindige von 0.25 bis 0.45, was insgesamt breitere Setzungsmulden ergibt (vgl. Möller 2006: 17).

Für eine genauere Übersicht über die verschiedenen empirischen Berechnungsmethoden des Wendepunktabstands sei auf die Publikationen von Franza und Marshall (2019), Zhou et al. (2017: 3) und Fillibeck (2012: 86-88) verwiesen.

2.2.4.3.2 Maximale Setzung S_{vmax}

Mithilfe der in Formel 2-3 eingeführten GLR können mittels Formel 2-4 die maximalen Setzungen abgeschätzt werden. Abhängig von der Art des Tunnelvortriebs fasste Mair (1996: 43-49) die GLR für verschiedene Bodenarten zusammen. Im zyklischen Vortrieb in London Clay beträgt die GLR im Normalfall zwischen 1 % und 2 %. Im Schildvortrieb, wo die Ortsbruststabilität noch besser kontrolliert werden kann, liegt die GLR in der Größenordnung von 0.5 % bis 2 %, wobei die niedrigeren Werte eher in Sand und die höheren Werte in bindigen Böden vorzufinden sind.

Die Bandbreite der angegebenen Werte ist sehr groß, wodurch diese Methode nur in der Vorstudienphase und am besten in Kombination mit einer Vielzahl von Erfahrungswerten in der Umgebung des Projekts und des eingesetzten Tunnelvortriebs zum Einsatz kommen sollte. Im Generellen verbessern sich die bautechnischen Abläufe stetig und vor allem im Bereich der EPBM gibt es große Verbesserungen, was sich durch ein geringeres Ground Loss bemerkbar macht. GLR im Bereich von 0.5 % sind keine Seltenheit mehr (vgl. ITA-AITES 2007: 130-131).

2.2.4.4 Analytische Methoden zur Berechnung der Setzungen

Analytische Methoden beruhen auf Vereinfachungen der Geometrie, der Bodenschichtungen (meist wird nur eine homogene Schicht berücksichtigt), der konstitutiven Modelle (es wird von einem linear-elastischen Materialverhalten ausgegangen) und bei der Definition der Rand- und Anfangsbedingungen (vgl. ITA-AITES 2007: 126). Die Eingangsparameter für die analytischen Lösungen können auch mittels Beobachtungsdaten leicht kalibriert werden. Hauptanwendungsgebiet der analytischen Methoden finden sich in der Vorstudienphase und als Referenzpunkt für numerische Analysen (vgl. Zhang et al. 2017: 212).

Sagaseta (1987) entwickelte eine Lösung in geschlossener Form des Dehnungsfeldes in einem anfänglich isotropen und homogenen, inkompressiblen Boden aufgrund des Ground Loss nahe der Oberfläche.

Verruijt und Booker (1996: 753) entwickelten diese Methode für das Ground Loss in einem Boden mit unterschiedlicher Poisson Zahl weiter. In ihrer Lösung behandeln Verruijt und Booker zwei verschiedene Verformungsmechanismen, nämlich die gleichmäßige radiale Verschiebung und die Verformung des Tunnels zu einer Ellipse (ovalization).

Poulos und Loganathan (1998: 846) arbeiteten einen neu definierten Ground Loss Parameter auf der Basis des „gap parameters“ in die Lösung von Verruijt und Booker (1996) ein und erreichten somit analytische Näherungslösungen für das Ground Loss, die Quersetzungsmulde und die maximalen Setzungen. Wie auch die vorher genannten Lösungen sind hier die Ergebnisse für gleichmäßige Tone am besten.

Chou und Bobet (2002) ließen unterschiedliche Entwässerungsbedingungen in ihre Analyse einfließen und lösten das Verformungsproblem, wobei jedoch nur gleichmäßige, radiale Verformungen berücksichtigt wurden.

Auch Park (2005) baute auf die Lösung von Verruijt und Booker (1996) auf und berücksichtigte nur das elliptische Verformungsmuster.

Neuere Entwicklungen wie von Zhang et al. (2017) beschreiben neben den Bodenverformungen auch die inneren Kräfte in der Tunnelschale.

2.2.4.5 Numerische Simulation

Numerische Methoden wie die der Finiten-Elemente (FEM) oder der Finiten-Differenzen (FDM) betrachten im Gegensatz zu empirischen oder analytischen Methoden auch heterogene Bodenschichtverhältnisse und es besteht die Möglichkeit, bessere konstitutive Modelle zu implementieren. Auch der Bauablauf, zeitabhängige Prozesse und naturnahe Randbedingungen können in numerischen Simulationen zu einem gewissen Grad berücksichtigt werden. Dreidimensionale Analysen bleiben aber weiterhin recht anspruchsvoll und zeitintensiv, wodurch noch immer auf vereinfachte, zweidimensionale Methoden zurückgegriffen wird, wobei ein Genauigkeitsverlust der numerischen Simulation eintritt. Die besten Ergebnisse werden in Böden erzielt, die kontinuumsmechanisch modelliert werden können, also vor allem im Lockergestein (vgl. ITA-AITES 2007: 126).

Ziel der numerischen Berechnung im Falle der tunnelbaubedingten Setzungen ist es, die Bodenbewegungen an allen Punkten im Umfeld des Tunnels zu berechnen. Zusätzlich ist es auch möglich, innere Kräfte der Tunnelschale und somit die Eingangsparameter für die Bemessung des Tunnels zu bestimmen. Allerdings muss immer beachtet werden, dass numerische Simulationen eine hohe Genauigkeit vorspielen, die aber stark von den angenommenen Bodenverhältnissen, dem angenommenen Bauablauf und den konstitutiven Modellen abhängen und nicht immer der Realität entsprechen. Eine Sensitivitätsanalyse der Annahmen ist daher anzuraten (vgl. ITA-AITES 2007: 127).

Es gibt bereits viele in der Literatur publizierte Beispiele von numerischen Simulationen bzw. Publikationen, die die Grundlagen für die Verwendung von 2D und 3D FE- und FD-Berechnungen im Tunnelbau darlegen. Im Folgenden werden einige wenige kurz vorgestellt. Mehr zur Theorie und der Ausführung einer numerischen Berechnung wird in Kapitel 3 Methodologie beschrieben.

Cai (2008) betrachtete die Unterschiede, die durch die Wahl zwischen FEM und FDM bei der Anwendung im Tunnelbau zustande kommen. Durch die verschiedenen Formulierungen der beiden Methoden kann es zu großen Unterschieden der Ergebnisse kommen, wenn es sich um kein lineares Materialverhalten handelt. Im elasto-plastischen Material kommt es zu Unterschieden, da die impliziten FEM den Spannungspfad nicht immer realitätsgetreu nachbilden können. Bei Anwendung der CCM oder der Steifigkeitsreduktion des Kerns kommen keine relevanten Unterschiede zustande, da der Spannungspfad sowohl in FEM als auch FDM derselbe ist. Cai (2008) gibt keine Empfehlung für die zu verwendende Software ab, weist jedoch darauf hin, dass die unterschiedlichen Spannungspfade beachtet werden sollen.

Vlachopoulos und Diederichs (2014) untersuchten die Anwendbarkeit von verschiedenen 2D-FE-Methoden zur Berücksichtigung des realen Tunnelbauvorgangs und der eigentlichen 3D-Wirkung dessen. Es wurden die CCM und die Steifigkeitsreduktion des Kerns genauer untersucht und die erzielten Ergebnisse mit 3D-Berechnungen mit dem FDM-Programm FLAC3D verglichen. Generell wurden von den Autoren die aufwendigeren und genaueren 3D-Berechnungen empfohlen, wobei auch mit 2D-Berechnungen gute Ergebnisse erzielt werden können, wenn auf Folgendes achtgegeben wird: Die fixierten Ränder der Berechnung sollten sich mindestens in einer Entfernung von 12-mal dem Tunnelradius befinden. Des Weiteren sollte darauf geachtet werden, dass die Reduktionsschritte der aufgebrachten Spannung bzw. der Steifigkeit des Kerns nicht zu groß ausfallen, da die Berechnung der Längssetzungsmulde darauf sensitiv reagiert. Die Wahl der Methode hat jedoch keinen signifikanten Einfluss.

Karakuş (2007) wandte verschiedene 2D-Methoden an und verglich diese mit Beobachtungsdaten vom Bau eines Tunnels in NATM-Bauweise in London. Die besten Ergebnisse der Setzungsmulde konnten mit der CCM und der Modellierung des Spritzbetons als Balkenelemente erzielt werden, wobei die maximalen berechneten Setzungen größer als die gemessenen waren. Janin et al. (2015) verglichen Ergebnisse von 2D und 3D FE-Berechnungen mit den Setzungsaufzeichnungen des Toulon-Tunnels. Auch sie kamen zu dem Schluss, dass sowohl die 2D Berechnung mittels CCM als auch die 3D Berechnungen gut mit den gemessenen Setzungen im Einklang stehen.

2.3 Künstliche Intelligenz und Machine Learning

2.3.1 Was ist Künstliche Intelligenz?

Der Begriff *Künstliche Intelligenz* (KI) ist schwierig zu definieren, da das Feld ein sehr großes Spektrum abbildet und KI sozusagen als Oberbegriff für eine Reihe an unterschiedlichsten Konzepten, Ansätzen und Technologien dient. Der Begriff KI wurde in den 1950er Jahren geprägt, als Mathematiker*innen und frühe Computerwissenschaftler*innen sich mit der Frage, ob und wie Computer zu „denken“ anfangen könnten, zu beschäftigen begannen (vgl. Chollet 2018: 4). Alan Turing publizierte 1950 einen Artikel, in welchem er darüber schrieb, wie man intelligente Maschinen erschaffen und deren Intelligenz testen kann. Zum Test würde eine Testperson einerseits einem Menschen und andererseits einer Maschine Fragen stellen. Sollte die Testperson nicht in der Lage sein, zwischen dem Menschen und der KI zu unterscheiden, gilt der Test der Intelligenz der Maschine als bestanden. Gemeinhin ist dieser Test als Turing-Test bekannt. 1956 verwendete John McCarthy als Erster den Begriff *Künstliche Intelligenz*, womit er die Wissenschaft und die Herstellung intelligenter Maschinen beschrieb (vgl. Haenlein & Kaplan 2019: 6-7).

Es wird klar, dass der Begriff KI sehr vielfältig ist. Eine allgemeine Oberdefinition liefert auch Chollet (2018: 4), der KI als die Anstrengung, intellektuelle Aufgaben, die normalerweise von Menschen durchgeführt werden, zu automatisieren und Maschinen zu übertragen, definiert. Zu Beginn waren die meisten KI-basierten Programme sogenannte Experten-Systeme, welche mit einer Reihe „wenn-dann-Bedingungen“ die menschliche Entscheidungsfindung zu replizieren versuchten. Diese Systeme können in gewissen Teilbereichen, z.B. als Schachcomputer, eine gute Leistung abliefern, jedoch sind sie streng genommen keine echte KI. Außerdem werden für komplexere Anwendungsgebiete, wie der Bilderkennung, Klassifizierungsaufgaben oder Regressionsaufgaben von hochgradig nichtlinearen Datensets, die Grenzen der Experten-Systeme sichtbar. Für solche Aufgaben braucht es eine KI, die Daten interpretieren, aus den Daten lernen und das Gelernte auf andere Fälle anwenden kann. Diese Art von KI ist auch unter dem Namen *machine learning* bekannt (vgl. Chollet 2018: 4; Haenlein & Kaplan 2019: 8).

2.3.2 Machine Learning

Die Grundidee von Machine Learning (ML) ist es, dass ein Computer aus den ihm präsentierten Daten lernt. Daraus ergibt sich eine neue Art des Programmierens. Während bei den Experten-Systemen der KI manuell programmierte Regeln und die Daten präsentiert werden, um damit zu den richtigen Schlüssen zu kommen, gibt der Mensch bei ML die Daten und die zugehörigen Antworten vor, woraus sich die KI ihre eigenen Regeln ableitet, mit denen sie zu den Antworten gekommen ist (vgl. Abb. 6). Dadurch lassen sich diese Regeln auch auf neue, dem ML-System unbekannte Daten anwenden und so neue Erkenntnisse gewinnen. Durch diese Funktionsweise von ML spricht man auch davon, dass ein ML-System trainiert wird, da dem System eine Menge an Daten präsentiert wird, aus diesen es statistische Rückschlüsse zieht und eigene Regeln aufstellt. Das ML-System wendet diese Regeln dann auf die Input-Daten an und gelangt somit zu einem Output, der mit dem bereits im Vorhinein bekannten Output mithilfe eines Fehlermaßes abgeglichen wird. Dieses Fehlermaß dient dazu, die Regeln des ML-Systems so zu verändern, dass die Abweichung vom berechneten Output und bekannten Output möglichst klein wird. Dieser Anpassungsschritt ist das eigentliche Lernen des Systems (vgl. Chollet 2018: 5-6).




Abb. 6: Klassisches Programmieren vs. Machine Learning (Chollet 2018: 5)

2.3.3 Überblick über bekannte Machine Learning Konzepte

Das Feld der ML-Konzepte ist sehr groß und um es tiefgründig zu verstehen, ist ein langes Literaturstudium kombiniert mit vertieften mathematischen Kenntnissen und Programmierkenntnissen notwendig. Dieses Wissen zu reproduzieren, sprengt den Rahmen dieser Arbeit bei weitem, weshalb auf eine vertiefte Betrachtung der ML-Konzepte verzichtet und auf die Literatur (z.B. Géron (2019)) verwiesen wird. Im Folgenden wird nur ein sehr kurzer Überblick über die wichtigsten Konzepte geliefert, die derzeit und in der Vergangenheit in einem geotechnischen Rahmen Anwendung finden und fanden.

2.3.3.1 Support-Vector Machine (SVM)

Support-Vector Machines (SVM) werden meist für Klassifizierungsaufgaben angewandt, können aber auch für Regressionsprobleme verwendet werden. Die Idee hinter SVM ist es, Daten voneinander sauber zu trennen und in Klassen einzuteilen. Jeder Inputdatenpunkt ist ein n -dimensionaler Vektor im Raum. Eine $n-1$ -dimensionale Hyperebene wird berechnet, die die Datenpunkte der verschiedenen Klassen möglichst gut voneinander trennen soll, indem versucht wird, den Abstand der Datenpunkte zur Ebene zu maximieren. In weiterer Folge ist es nur notwendig zu beobachten, auf welcher Seite der Ebene sich ein neuer Datenpunkt befindet, um ihn richtig einteilen zu können (vgl. Chollet 2018: 15). Bei der Regression versucht die SVM im Gegensatz zur Klassifizierung möglichst viele Datenpunkte auf der Hyperebene zu platzieren und die Abweichungen davon möglichst klein zu halten (vgl. Géron 2019: 164).

2.3.3.2 Decision Trees and Random Forest

Decision Trees (Entscheidungsbäume) können auch für Klassifizierungs- und Regressionsfragestellungen verwendet werden. Im Aufbau ähneln die decision trees einem Flussdiagramm. Der Ursprung des decision trees ist die Wurzel, wobei diese den Input aufnimmt. An den Knoten werden Regeln aufgestellt, welche die Daten aufteilen und an darunterliegende Knoten weitergeben. Bei Regressionsbäumen gibt jeder Knoten einen numerischen Wert aus. Am Ende gelangen die Daten zu einem sogenannten Blatt, welches den Output darstellt. Die Performance wird wiederum mit einem Fehlermaß gemessen und die Entscheidungsregeln an den Knoten ausgehend von den Blättern bis zur Wurzel aktualisiert (vgl. Géron 2019: 178-186).

Ein random forest (RF, Zufallswald) ist die Kombination von vielen verschiedenen decision trees. Als Gesamtoutput dient die Kombination der einzelnen Outputs. Jeder einzelne Baum wird zufällig und unabhängig von den anderen erstellt und evaluiert. Als Ergebnis werden die Prognosen aller Bäume miteinander kombiniert, womit bessere Resultate erzielt werden können (vgl. Géron 2019: 191-199).

2.3.3.3 Artificial Neural Network (ANN)

Artificial Neural Networks (ANN, künstliche neuronale Netzwerke) sind eine ML-Technik, die von der Funktionsweise des Gehirns inspiriert wurde und die die Verbindungen der Neuronen im Gehirn imitiert. In einer einfachen Form besteht ein ANN aus einem Input-, einem versteckten Layer sowie einem Output-Layer, die miteinander verbunden sind. Die Eingangsdaten werden von den Neuronen gewichtet und an die Output-Neuronen weiterpropagiert. Der berechnete Output wird über ein Fehlermaß mit dem bekannten Output verglichen und die Gewichte der einzelnen Neuronen angepasst, um die Abweichungen möglichst gering zu halten (vgl. Géron 2019: 277-289).

Eine genauere Beschreibung der Funktionsweise von ANN wird in Kapitel 3.2 geliefert.

2.3.4 Allgemeine Herausforderungen von ML

Bei der Anwendung von ML gibt es einige Hürden, die die Performance von ML-Systemen behindern können. Darunter fallen sowohl die zugrundeliegenden Daten als auch die verwendete Architektur der Algorithmen. In weiterer Folge werden die Hauptherausforderungen bei ML gemäß Géron (2019: 24-33), die es zu überkommen gilt, kurz angeführt und beschrieben.

2.3.4.1 Quantität und Qualität der Daten

Damit ML ordentlich funktionieren kann, braucht es zuallererst eine ausreichend **hohe Anzahl an Datensätzen**. Wenn dies nicht der Fall ist, kann der ML-Algorithmus keine Rückschlüsse aus den Daten ziehen und somit auch keine belastbaren Vorhersageergebnisse liefern. Da jede Aufgabenstellung unterschiedlich ist, kann keine genaue Datenbankgröße genannt werden, ab dieser die Performance des ML-Systems akzeptabel ist. Im Grunde genommen gilt daher: Je mehr Datensätze, desto besser (vgl. Géron 2019: 24).

Eine weitere Herausforderung besteht darin, **repräsentative Trainingsdaten** zu verwenden, die den später verwendeten Daten, mit denen Prognosen getroffen werden sollen, ähnlich sind. Das rührt daher, dass ML-Systeme nur in der Lage sind, gute Voraussagen zu treffen, wenn die neuen Daten den Trainingsdaten ähnlich sind und der Trainingsdatensatz eine möglichst große Bandbreite der Eingangsparameter abdeckt, ohne dabei nur auf die Extremwerte acht zu nehmen (vgl. Géron 2019: 26). Umgelegt auf die Anwendung von ML für die Setzungsprognose von Tunneln bedeutet das, dass möglichst weit gestreute Eingangsparameter des Bodens und der geometrischen Verhältnisse verwendet werden sollen, wobei auch innerhalb der unteren und oberen Parametergrenzen hinreichend viele Daten liegen sollen, um somit für alle zukünftigen und realistischen Parameterkombinationen Voraussagen treffen zu können.

Auch die **Qualität der Daten** ist für den Erfolg von ML sehr wichtig. Wenn der Trainingsdatensatz von vielen Fehlern, Ausreißern und Datenrauschen geprägt ist, ist es für den ML-Algorithmus schwierig, die zugrundeliegenden Zusammenhänge der Daten zu erkennen (vgl. Géron 2019: 27). Bei den Berechnungen und der Datenbankerstellung muss daher große Sorgfalt auf die Richtigkeit und Plausibilität der Rechnungen gelegt werden. Gegebenenfalls müssen klare Ausreißer und nicht realistische Ergebnisse entfernt werden.

Die **Relevanz der Eingangsparameter** ist wichtig, da zu viele und nicht relevante Eingangsparameter den Lernprozess eines ML-Systems behindern. Im Vorhinein sollte daher ein Auswahlprozess der richtigen Features stattfinden und eventuell neue, aussagekräftigere Features durch Kombinationen existierender erstellt werden (vgl. Géron 2019: 27-28).

Im Allgemeinen kann daher gesagt werden, dass ein ML-Algorithmus nur so gut sein kann, wie es die zugrundeliegenden Trainingsdaten erlauben.

2.3.4.2 Qualität des ML-Algorithmus

Eine Gefahr beim ML ist die **Überanpassung (overfitting)** des ML-Algorithmus an die Trainingsdaten. In diesem Fall lernt das ML-System die zugrundeliegenden Zusammenhänge der Trainingsdaten sehr gut und entwickelt ein Modell, das diese Daten perfekt abbilden kann, jedoch versagt das ML-System bei der Vorhersage von bisher nicht gesehenen Datensätzen aufgrund der Überanpassung an die Trainingsdaten. Somit geht die Generalisierungsfähigkeit des ML-System verloren. Um dieser Gefahr Herr zu werden, können - wenn möglich - mehr Trainingsdaten hinzugezogen werden, Datenrauschen und Ausreißer entfernt werden oder das ML-System vereinfacht werden. Bei einem ANN kann die Reduktion der Komplexität unter anderem durch das Weglassen von einzelnen Layern oder Neuronen geschehen.

Auch das Gegenteil kann zum Problem werden, nämlich wenn der ML-Algorithmus zu einfach aufgebaut ist bzw. nicht lang genug trainiert wurde. Hier wird von

Unteranpassung (underfitting) gesprochen (vgl. Géron 2019: 28-30). Im Allgemeinen wird ein ML-System über Hyperparameter gesteuert, die für jeden Fall anzupassen sind. Die Qualität der Prognosefähigkeit wird mittels eines Fehlermaßes bestimmt, welches selbst auch einen Einfluss auf die Generalisierungsfähigkeit hat und selbst auch ein Hyperparameter ist. Genaueres findet sich hierzu in Kapitel 3.2.5.

2.4 Künstliche Intelligenz in der Geotechnik

Seit rund 35 Jahren werden Methoden der künstlichen Intelligenz auch in der Geotechnik in einer Vielzahl von unterschiedlichen Bereichen angewandt. Ein Überblick über die verschiedensten Einsatzbereiche wird von Ebid (2021) hergestellt und hier kurz wiedergegeben. Seine Analyse zeigt die am häufigsten in der Geotechnik verwendeten KI-Methoden auf, wobei in 48 % der untersuchten Publikationen ANN angewandt wurden (vgl. Ebid 2021: 668).

Bei der Anwendung von KI zur Bestimmung von **Boden- und Gesteinseigenschaften** werden Korrelationen von einfach zu bestimmenden Parametern mit nur aufwendig zu bestimmenden Parametern hergestellt. Beispielhaft kann hier die Korrelation der Lagerungsdichte von Sand mit der Scherfestigkeit oder auch die Bestimmung der Zugfestigkeit eines Gesteins mithilfe der Druckfestigkeit angeführt werden (vgl. Ebid 2021: 649).

Nicht nur die **Bodeneigenschaften** an sich sind von Bedeutung, sondern auch die **räumliche Verteilung**. Daher werden auch auf Basis von einfachen Feldversuchen mittels KI die Schichtung des Bodens und die Einteilung des Bodens in Homogenbereiche vorausgesagt (vgl. Ebid 2021: 651).

Bei der Bestimmung der **Böschungsstabilität** wird KI eingesetzt, um einerseits die kritische Gleitfläche in 2D und 3D, andererseits auch den Sicherheitsfaktor einer Böschung zu ermitteln (vgl. Ebid 2021: 651). Samui (2008), zum Beispiel, wandte in seiner Studie eine SVM an, um den Sicherheitsfaktor zu prognostizieren. Als Eingangsparameter dienten die Wichte des Bodens, die Kohäsion, der Reibungswinkel, die Neigung und Höhe der Böschung sowie der Porenwasserdruck. Obwohl das Datenset mit nur 46 Einträgen klein war, konnte Samui gute Ergebnisse erzielen.

Bei den **Boden-Wasser-Wechselwirkungen** wird versucht, eine Korrelation zwischen den Bodeneigenschaften und den hydraulischen Eigenschaften des Bodens herzustellen. Darunter fallen die Prognose von Bodenverschmutzungen basierend auf den hydraulischen Eigenschaften des Bodens, die Abschätzung der Erosion und der Auswaschungstiefe sowie die Prognose der Durchlässigkeit aufgrund von einfach zu ermittelnden Kennwerten (vgl. Ebid 2021: 654). Letzteres wurde von Erzin et al. (2009) durchgeführt. Im Labor wurden verschiedene schluffige Sande und Tone auf ihre hydraulische Durchlässigkeit untersucht. In das entwickelte ANN gingen fünf Kennwerte der Kornverteilungslinie, der Wassergehalt und die Trockendichte als Eingangswerte ein. Der hydraulische Durchlässigkeitsbeiwert konnte somit sehr genau und ohne experimentelle Versuche bestimmt werden.

Im Bereich von **Stützwänden bzw. im Baugrubenverbau** wird KI eingesetzt, um ohne die aufwendigeren FE-Methoden Verformungen und Setzungen vorauszusagen und auch die konstruktive Bemessung der Stützkonstruktionen und der Anker zu optimieren (vgl. Ebid 2021: 655). Von Leu und Lo (2004) wurden zwei ANN zur Prognose der vertikalen Setzungen hinter einer Schlitzwand entwickelt. Das erste ANN behandelte die Planungsphase, wo auf Basis realer Daten aus Taiwan, ein Modell erstellt wurde, mit dem aufgrund von Geometrie- und Bodeneigenschaften die maximale vertikale Setzung vorausgesagt wird. Das zweite ANN behandelte die Bauphase und verwendete als Eingangsparameter reale Beobachtungsdaten des Baufortschritts und der horizontalen Verformungen, um somit zeitnah die zu erwartenden Setzungen zu prognostizieren.

Bei **Flachgründungen** werden mit KI einerseits die Tragfähigkeit der Fundamente, andererseits die zu erwartenden Setzungen darunter abgeschätzt (vgl. Ebid 2021: 661). Shahin et al. (2002) entwickelten ein ANN, um aufgrund von einfach zu ermittelnden Parametern Setzungen unter Flachgründungen abschätzen zu können. Neben der Breite, Länge und Einbindetiefe des Fundaments wurden auch die Spannung unter dem Fundament und als einziger Bodenparameter der SPT-Wert als Eingangsparameter verwendet.

Auch die Tragfähigkeit und die zu erwartenden Setzungen von **Tiefgründungen** werden mit KI-Methoden behandelt (vgl. Ebid 2021: 661). Um auf teure und aufwendige

Probebelastungen von Pfählen, die derzeit noch die vertrauensvollste Methode zur Betrachtung der Tragfähigkeit ist, verzichten zu können, entwickelten Ismail und Jeng (2011) ein ANN. Die Datenbank bildeten Daten von Probebelastungen von Bohr- und Rammpfählen, wobei die Steifigkeit der Pfähle, die Geometrie, die aufgebrachte Last und die Steifigkeit des anstehenden Bodens entlang und unterhalb des Pfahls (SPT-Wert) als Eingangsparameter zur Setzungsabschätzung verwendet wurden.

Neben den oben genannten Anwendungsgebieten wird KI auch z.B. zur Voraussage der **Bodenverdichtungskurve**, bei der Betrachtung von **Bodenverflüssigung**, in der **Boden- und Felsdynamik** eingesetzt (vgl. Ebid 2021: 649-662). Der Anwendung von **KI im Tunnelbau** widmet sich das folgende Kapitel 2.5. Natürlich ist diese Aufzählung der Einsatzgebiete nicht allumfassend. Weitere Anwendungen werden in den kommenden Jahren mit Sicherheit folgen, da sich mit größer werdender Datenverfügbarkeit, der Verbesserung der Qualität dieser Daten, der Rechenleistung der Computer sowie der Effizienz der verwendeten Algorithmen viele Chancen auftun werden. Wenn die Anwendung von KI einen wirtschaftlichen Nutzen darstellt, sei es durch genauere Ergebnisse in der Bemessung oder durch Verzicht auf aufwendige numerische Berechnungen, wird der Einsatzbereich stetig wachsen.

2.5 Künstliche Intelligenz im Tunnelbau

In dieser kurzen Literaturrecherche wird ein Überblick über die Entwicklung und den Einsatz von KI-Methoden im Tunnelbau mit Fokus auf die Prognose von tunnelbaubedingten Setzungen gegeben. Am Ende (siehe Kapitel 2.5.3) wird auch eine Datenbank mit Daten aus der Literatur erstellt, mittels derer die eigene KI-Anwendung validiert werden soll.

2.5.1 Künstliche Intelligenz zur Vorhersage tunnelbaubedingter Setzungen

Vor rund 20 Jahren begann der Einsatz von KI-Methoden im Tunnelbau. Die ersten, die KI zur Voraussage von tunnelbaubedingten Setzungen verwendeten, waren Shi et al. (1998). Sie setzten ein ANN zur Vorhersage von Setzungen während des Baus eines U-Bahn-Tunnels in NATM-Bauweise in Brasília ein. Die Vorgehensweise bestand darin, dass sie die ersten 6 km der gebauten U-Bahn-Strecke für das Training verwendeten, während die letzten 500 m als Test verwendet wurden. Durch den Einsatz des ANN konnten R^2 -Werte von 0.832 für das Trainingsset bzw. 0.575 für das Testset erzielt werden.

Kim et al. (2001) wendeten auch ein ANN an, um den Wendepunktabstand i und die maximalen vertikalen Setzungen S_{vmax} auf Basis von Daten während des Baus der U-Bahn von Seoul mit Tunnelvortriebsmaschinen vorauszusagen. Als Eingangsparameter wurden insgesamt 19 Parameter verwendet, worunter sich geometrische Daten, wie Überdeckung oder Durchmesser, Bodenverhältnisse wie der Bodentyp oder der Grundwasserstand sowie Vortriebs- und Sicherungsmaßnahmen wie die Vortriebsgeschwindigkeit, Abschlagslänge oder die verwendeten Stützmaßnahmen befanden. Um die optimale Architektur des ANN zu finden, wurden die Knotenzahl, die Lernrate und der Momententerm systematisch variiert. Als Trainingsdatenset wurden 113 und als Testset 12 Datensätze verwendet. Die optimale ANN-Architektur schaffte es, die Setzungen mit einem average inference errors von 16.4 % für die maximale Setzung und von 11.2 % für den Wendepunktabstand und somit mit einer hinreichenden Genauigkeit vorauszusagen. Nach einer Sensitivitätsanalyse der Eingangsparameter wurden die Parameter bestimmt, die den größten Einfluss auf das Setzungsverhalten haben. Darunter fallen die Überdeckung, der Tunneldurchmesser, der Grundwasserstand, die Bodenart sowie die Vortriebsgeschwindigkeit. Gleichzeitig wurde darauf hingewiesen, dass diese Faktoren je nach den örtlichen Bedingungen unterschiedlich sein können und damit keine allgemein gültige Aussage getätigt werden sollte.

Basierend auf dem Bau von vier Abschnitten in Doppeltunnelbauweise mit EPBM der Bangkok U-Bahn sammelten Suwansawat und Einstein (2006) Beobachtungsdaten und erstellten eine Datenbank, mithilfe derer ein ANN zur Voraussage von maximalen tunnelbaubedingten Setzungen entwickelt wurde. Alle Aussagen bezüglich der Setzungen und der Parameter beziehen sich jedoch nur auf den jeweils zuerst gebauten Tunnel. Insgesamt wurden 13 Eingangsparameter, darunter geometrische, geologische und vortriebsbedingte Parameter verwendet.

Auch in dieser Studie wurde nach der optimalen ANN-Architektur gesucht. Zu diesem Zweck wurden Subsets aller Daten erstellt und die Anzahl der versteckten Layer, der versteckten Knoten und der Trainingsepochen variiert. Als Gütemaß dieser 18 verschiedenen ANN wurde der RSME herangezogen und das optimale Modell bestimmt. Danach wurde dieses zur Vorhersage der Setzungen für jeden Abschnitt getrennt, für alle Abschnitte gemeinsam und für einen Abschnitt nur mit den zu Beginn des Baus aufgezeichneten Daten für den restlichen Abschnitt angewandt. In allen Szenarien konnten gute Ergebnisse erzielt werden, wobei der RSME am kleinsten für Berechnungen einzelner Abschnitte und am größten für die gesamtheitliche Betrachtung war. Die größeren Abweichungen bei der gesamtheitlichen Betrachtung erklärten Suwansawat und Einstein durch den Einsatz von Maschinen von zwei unterschiedlichen Herstellern auf den einzelnen Abschnitten. In einem verbesserten ANN wurde dieser Einfluss berücksichtigt und der Maschinentyp als Eingangsparameter berücksichtigt, wodurch der RSME um rund 9 % verringert wurde.

Ein Vergleich der Leistung verschiedener KI-Methoden wurde mit Daten der Istanbuler Metro von Ocak und Şeker (2013) durchgeführt. Mittels zwei unterschiedlicher EPBM wurde ein rund 4 km langer Doppeltunnel gebaut, wobei der erste Tunnel ca. 100 m vorseilte. Die Oberflächensetzung wurde vor und nach dem Passieren der EPBM an 230 Abschnitten gemessen, welche somit die Datenbank bilden. Als Eingangsparameter wurden insgesamt 18 Faktoren berücksichtigt. Darunter fallen Betriebsfaktoren der beiden EPBM, nämlich der Stützdruck, die Vortriebsgeschwindigkeit, die Menge abgebauten Materials und die Ringspaltverfüllung. Die Bodenverhältnisse, wie die Schlaganzahl des Standard Penetration Tests, die Dichte und Klassifizierungen des Grundwasserstandes und der örtlichen Geologie flossen auch in die Betrachtung mit ein. Bei den geometrischen Faktoren wurden die jeweiligen Tunneldurchmesser (die leicht voneinander abweichen), die Überdeckung, der Abstand zwischen den Tunneln sowie die jeweiligen Abstände der Tunnel zu den Beobachtungsstellen der Setzungen berücksichtigt.

Innerhalb dieser Studie kamen neben einem ANN auch der GP (Gaussian Process) und SVM zum Einsatz, um somit eine Aussage zur Leistung der verschiedenen KI-Methoden treffen zu können. Als erster Schritt für alle drei Methoden wurden der Einfluss der Parameter evaluiert und drei Parameter dadurch entfernt. Die Einteilung in Trainings- und Testdatenset geschah durch 10-fache Kreuzvalidierung, wodurch zehn Paare der Datensets zum Einsatz kamen. Als Gütemaß wurde der RSME verwendet. Der Vergleich von ANN, GP und SVM zeigte, dass in dieser Studie mit GP der kleinste RSME erzielt werden konnte, gefolgt von SVM und ANN, welche beide fast gleiche RSME-Werte lieferten. Der R^2 -Wert zwischen gemessener und vorausgesagter Setzung war mit 0.986 beim GP und 0.968 bei der SVM beinahe gleich groß, der ANN lag mit 0.803 weiter zurück.

Der GP ist in dieser Studie die geeignetste KI-Methode zur Voraussage der maximalen Setzungen. Des Weiteren wurden die Menge des abgebauten Materials, die Ringspaltverfüllung, die Distanz zwischen den Tunneln, die Überdeckung und der Stützdruck als einflussreichste Parameter bestimmt, wobei der SPT-Wert und die Vortriebsgeschwindigkeit den geringsten Einfluss hatten.

Setzungsdaten vom Bau der U-Bahn von Karaj im Iran an 143 Stellen wurden von Hasanipanah et al. (2016) verwendet, um ein PSO-ANN (particle swarm optimization ANN) zur Setzungsprognose zu entwickeln. Der Tunnel wurde in der NATM mit einem Hufeisenprofil erbaut. Die Überdeckung des Tunnels schwankt zwischen 7 m und 14 m.

Im Zuge dieser Studie wurden mittels in-situ Versuchen und mit Laborversuchen geotechnische Parameter gemessen/bestimmt. Überraschend fällt dabei aus, dass nur drei Parameter als Eingangsparameter für das ANN verwendet wurden, nämlich das Verhältnis zwischen horizontalen und vertikalen Spannungen, die Kohäsion sowie der E-Modul, um damit die maximalen Oberflächensetzungen vorauszusagen.

Nach der Normalisierung der Daten und der Bestimmung der optimalen ANN-Architektur wurde das Datenset zu 80 % für das Training und zu 20 % für das Testen aufgewendet. Die Autoren konnten mit dem einfachen ANN einen R^2 von 0.940 für das Trainingsset, mit dem PSO-ANN jedoch schon einen R^2 von 0.968 erzielen. Mit einer Sensitivitätsanalyse bestimmten sie das Spannungsverhältnis als einflussreichsten Parameter.

Zhou et al. (2017) schlugen einen RF vor, um die maximalen Setzungen und den Wendepunktabstand i zu prognostizieren. Aufbauend auf zwei Datensets aus bereits publizierten Fallbeispielen verschiedener mit SM gebauter Tunnel wurden zwei RF generiert, da die Datensets unterschiedliche Parameter berücksichtigten. Im Allgemeinen lassen sich diese jedoch wieder in die Gruppen geometrische Daten, Bodenverhältnisse und Vortriebsparameter einteilen, wobei das Datenset A nur die Vortriebsart an sich, aber keine genauen Parameter berücksichtigt. Die Gesamtdaten wurden wiederum in ein Trainings- und ein Testset im Verhältnis 80 % zu 20 % eingeteilt. Der RF wurde optimiert, indem als Gütemaß der RSME und R^2 herangezogen wurden.

Nach der Optimierung wurden für das Testdatenset A für S_{vmax} ein R^2 von 0.57 und ein RSME von 47.30, für den Wendepunktabstand i ein R^2 von 0.73 und ein RSME von 2.79. Das Testdatenset B konnte bessere Ergebnisse erzielen: R^2 von S_{vmax} 0.94, RSME S_{vmax} 11.67, R^2 von i 0.83, RSME i 1.54. Es zeigt sich, dass bessere Ergebnisse für das Datenset B erzielt

werden konnten. Ein Grund dafür könnte sein, dass hier auch Parameter der SM verwendet wurden. Die Sensitivitätsanalyse zeigte, dass beim Datenset B neben der Kohäsion vor allem die Schubkraft der Tunnelvortriebsmaschine den größten Einfluss hatte. Beim Datenset A wurde das Volume Loss als einflussreichster Faktor bestimmt, was auch gut mit empirischen Gleichungen im Einklang steht.

Eine weitere Alternative zur Prognose der maximalen Setzung durch EPBM Tunnel lieferten Goh et al. (2018) mit der Anwendung von multivariate adaptive regression splines (MARS). Die Daten an 148 Stellen für die Analyse stammen aus drei U-Bahn-Tunneln in Singapur. Als Eingangsparameter wurde als einzige geometrische Größe die Überdeckung verwendet, da der Durchmesser konstant war. Die geologischen Verhältnisse wurden durch den SPT-Wert an verschiedenen Stellen, den E-Modul sowie den Wassergehalt berücksichtigt. Auch die drei vortriebsbedingten Parameter der Vortriebsgeschwindigkeit, der Ortsbruststützdruck und der Verpressdruck wurden verwendet.

78 % des Datensets wurden für das Training, 22 % für das Testen aufgewendet. Goh et al. (2018) stellten fest, dass der Trainingsprozess der MARS durch die Verwendung von logarithmierten Eingangsparametern verbessert werden kann. Es konnte ein R^2 von 0.721 für das Testdatenset erreicht werden. Zum Vergleich wurde in dieser Studie auch ein ANN angewandt, dessen R^2 bei 0.689 lag. Die Größe des mittleren Fehlers unterschied sich nicht signifikant zwischen MARS und ANN und lag bei rund 3.60 mm. Damit konnte die Eignung von MARS zur Setzungsprognose festgestellt werden.

Bouayad und Emeriault (2017) wandten eine kombinierte Methode basierend auf den Daten der Metro-Linie B von Toulouse an, um die nichtlineare Beziehung zwischen den Operationsparametern einer EPBM, den geologischen Verhältnissen und den tunnelbaubedingten Oberflächensetzungen zu beschreiben. Mit einer principal component analysis (PCA) beschrieben sie zuerst die wechselseitigen Beziehungen zwischen den EPBM-Parametern und den geologischen Profilen. Ziel der PCA ist es, die große Zahl der wechselseitigen Beziehungen der Variablen zu reduzieren, aber gleichzeitig die größtmögliche Varianz im Datenset zu behalten.

Dann wurde ein erstes adaptive neuro-fuzzy inference system Modell (ANFIS) entwickelt, welches nur zehn, aufgrund einer Literaturstudie ausgewählten, Betriebsparameter der EPBM als Eingangsparameter verwendete und die geologischen Verhältnisse als homogen betrachtete. Mit dieser Methode konnte ein R^2 von 0.8 für das Testdatenset erzielt werden. Das zweite entwickelte ANFIS verwendete als Eingangsparameter nur die mittels der PCA bestimmten sechs Hauptkomponenten. Damit konnte die Prognosekraft des ANFIS gesteigert werden und ein R^2 von 0.93 erreicht werden.

2.5.2 Andere KI-Anwendungen im Tunnelbau

Neben den im vorherigen Kapitel beschriebenen Anwendungen zur Bestimmung der tunnelbaubedingten Setzungen werden KI-Methoden im Tunnelbau auch zu anderen Zwecken eingesetzt, über einige derer nachfolgend ein kurzer Überblick gegeben wird. Für eine detailliertere Zusammenstellung wird auf die Publikationen von Zhang et al. (2020) und von Wang et al. (2020) verwiesen.

Nsubuga et al. (2021) wandten ein ANN an, um **Firstverschiebungen** entlang eines Doppeltunnels in Griechenland vorauszusagen. Als Eingangsparameter wurden geometrische, geologische und vortriebsbedingte Parameter verwendet, den Output bildeten gemessene Verschiebungen und Verformungen.

Goh und Zhang (2012) verwendeten ein ANN, um den **Sicherheitsfaktor einer Kaverne** zu prognostizieren. Aufbauend auf die Berechnung des Sicherheitsfaktors mittels FDM wurde ein ANN trainiert, welches dann aufgrund von Geometriedaten und den geologischen Verhältnissen fähig war, den Sicherheitsfaktor (für die Vorstudienphase) sehr genau vorauszusagen.

Auch zur Prognose der **Vortriebsgeschwindigkeit** einer TBM können KI-Methoden angewandt werden, wie es Armaghani et al. (2017) demonstrierten. Neben den geologischen

Festigkeits- und Qualitätsparametern des Festgesteins wurden auch Vortriebsparameter der TBM aufgezeichnet. Aufgrund dieser Daten wurde ein ANN entwickelt, mit dem es möglich ist, Prognosen der Vortriebsgeschwindigkeit für andere Tunnelbauprojekte zu treffen.

Adoko et al. (2013) entwickelten ein ANN und ein MARS, um die **Tunnel-Konvergenz** eines in NATM gebauten Tunnels vorauszusagen. Geometrische und geologische Parameter dienten neben der Zeit, die zwischen Bau und Datenaufnahme verstrichen ist, als Eingangsparameter, mittels derer die kumulierte radiale Verformung des Tunnelquerschnitts prognostiziert wurde.

2.5.3 Datenbank von Setzungsprognosen aus der Literatur

In Tabelle 1 werden Setzungsprognosen, die aus der Literatur zusammengetragen wurden, präsentiert. Die publizierten Fallbeispiele sind durch nur wenige Parameter beschrieben, weswegen sie nur als Validierungsdatenset für die einfachsten ANN (ANN 01/a/b) herangezogen werden können. Abb. 7 stellt die berechnete Korrelationsmatrix des Validierungsdatensets aus der Literatur dar. Überraschend fällt bei Betrachtung der Korrelationsmatrix vor allem die negative Korrelation zwischen der maximalen Setzung und dem Tunneldurchmesser aus, was nicht den Erwartungen entspricht. Eine weitere Behandlung der Korrelationsmatrix findet in Kapitel 5.3 statt.


Der Umfang der zusammengetragenen Datenbank ist eher beschränkt, da trotz umfangreicher Literaturrecherche nur wenige passende Daten gefunden werden konnten. Einerseits konnten einige Daten nicht verwendet werden, da nur die maximale Setzung jedoch nicht der Wendepunkt Abstand publiziert wurden, andererseits stützen sich viele publizierte Beispiele auf Betriebsparameter von TVM bei der Entwicklung eines ANN. Des Weiteren verzichteten die meisten Publikationen bezüglich Setzungsprognosen vollkommen auf die Veröffentlichung von einzelnen Datensätzen. Auch die Verwendung von Bodenkennwerten aus Feldversuchen wie dem Standard Penetration Test stellt ein Problem dar, da diese Werte nur sehr ungenau mittels Faustformeln in die Eingangsparameter des MC-Modells umgerechnet werden können.

Tabelle 1: Datenbank der Setzungsprognosen aus der Literatur

Index	Vortriebsart ²	c	φ	E	C	D	C/D	S_{vmax}	i	Ort	Quelle
		[kPa]	[°]	[MPa]	[m]	[m]	[-]	[mm]	[m]		
1	TVM	11.8	15.2	5.9	9.8	6.3	1.5	47.3	4.77	Shanghai Metro 2	Zhou et al. (2017)
2	TVM	28.1	32.8	5.4	13.3	6.4	2.1	9.6	9.71	Nanjing Metro 1	Zhou et al. (2017)
3	TVM	32.4	10.7	11.2	14.5	6.4	2.3	22.0	5.37	Nanjing Metro 1	Zhou et al. (2017)
4	TVM	31.1	44.1	40.8	20.0	6.3	3.2	4.3	9.77	Guangzhou Metro 2	Zhou et al. (2017)
5	TVM	11.9	13.8	5.2	11.9	6.3	1.9	21.2	7.25	Shanghai Metro 2	Zhou et al. (2017)
6	TVM	12.1	13.7	5.2	12.0	6.3	1.9	55.3	7.46	Shanghai Metro 2	Zhou et al. (2017)
7	TVM	11.7	16.4	6.5	5.2	6.3	0.8	63.3	4.64	Shanghai Metro 2	Zhou et al. (2017)
8	TVM	11.2	19.5	8.3	2.9	6.3	0.5	84.5	4.35	Shanghai Metro 2	Zhou et al. (2017)
9	TVM	11.8	14.7	5.7	7.2	6.3	1.1	40.6	5.39	Shanghai Metro 2	Zhou et al. (2017)
10	TVM	11.9	14.1	5.4	8.2	6.3	1.3	38.1	6.4	Shanghai Metro 2	Zhou et al. (2017)
11	TVM	12.0	13.4	5.0	9.5	6.3	1.5	32.8	9.34	Shanghai Metro 2	Zhou et al. (2017)

² TVM=0, NATM=1

Index	Vortriebsart ²	c	φ	E	C	D	C/D	S _{vmax}	i	Ort	Quelle
		[kPa]	[°]	[MPa]	[m]	[m]	[-]	[mm]	[m]		
12	TVM	15.3	23.9	3.9	8.8	6.4	1.4	7.6	6.84	Nanjing Metro 1	Zhou et al. (2017)
13	TVM	36.7	20.7	7.3	10.6	6.4	1.7	7.5	7.04	Nanjing Metro 1	Zhou et al. (2017)
14	TVM	32.4	12.4	11.2	11.0	6.4	1.7	14.8	6.39	Nanjing Metro 1	Zhou et al. (2017)
15	TVM	43.6	30.0	9.1	11.3	6.4	1.8	8.9	10	Nanjing Metro 1	Zhou et al. (2017)
16	TVM	34.2	9.2	7.3	11.3	6.4	1.8	22.8	5.22	Nanjing Metro 1	Zhou et al. (2017)
17	TVM	34.2	14.5	7.3	11.3	6.4	1.8	16.4	7.11	Nanjing Metro 1	Zhou et al. (2017)
18	TVM	234.0	44.9	35.0	8.9	6.3	1.4	9.2	8.91	Guangzhou Metro 2	Zhou et al. (2017)
19	TVM	680.0	30.3	23.6	20.9	6.3	3.3	16.8	16.32	Guangzhou Metro 2	Zhou et al. (2017)
20	TVM	650.0	29.8	21.8	19.9	6.3	3.2	38.0	14.54	Guangzhou Metro 2	Zhou et al. (2017)
21	TVM	11.8	14.4	5.5	7.7	6.3	1.2	27.1	5.81	Shanghai Metro 2	Zhou et al. (2017)
22	TVM	11.9	13.8	5.2	8.7	6.3	1.4	38.6	7.27	Shanghai Metro 2	Zhou et al. (2017)
23	TVM	11.9	13.8	5.2	8.0	6.3	1.3	62.5	7.32	Shanghai Metro 2	Zhou et al. (2017)
24	TVM	11.9	13.8	5.2	7.3	6.3	1.2	89.9	7.53	Shanghai Metro 2	Zhou et al. (2017)
25	TVM	12.0	13.7	5.2	8.8	6.3	1.4	57.0	7.48	Shanghai Metro 2	Zhou et al. (2017)
26	TVM	12.0	13.7	5.2	8.6	6.3	1.4	79.6	7.51	Shanghai Metro 2	Zhou et al. (2017)
27	NATM	9.8	30.7	103.6	9.5	13.0	0.7	23.5	6.11	Teheran Metro	Mohammadi et al. (2015)
28	NATM	6.9	34.9	149.9	6.3	13.0	0.5	25.4	4.58	Teheran Metro	Mohammadi et al. (2015)
29	NATM	11.8	34.8	131.8	17.0	13.0	1.3	21.5	9.52	Teheran Metro	Mohammadi et al. (2015)
30	NATM	8.8	38.1	129.9	27.7	13.0	2.1	33.6	14.1	Teheran Metro	Mohammadi et al. (2015)
31	NATM	8.8	34.7	154.2	18.8	13.0	1.4	28.5	10.3	Teheran Metro	Mohammadi et al. (2015)

**Abb. 7: Korrelationsmatrix des Literaturvalidierungssets**

3 Methodologie

3.1 Finite Differenzen

Die nachfolgenden numerischen Berechnungen werden mit dem Programm FLAC3D 6.0 der Itasca Consulting Group, Inc durchgeführt (vgl. Itasca Consulting Group, Inc 2017). FLAC3D ist ein explizites FD-Programm, mit dem verschiedene dreidimensionale Problemstellungen, vor allem in der Geotechnik, behandelt werden können. Im Unterschied zu FE-Programmen wird das mechanische Verhalten des Materials nicht nur von den generellen Definitionen der Verformungen und dem Stoffgesetz des verwendeten Materials bestimmt, sondern auch von den Newtonschen Gesetzen. Das mathematische Modell besteht aus partiellen Differenzialgleichungen, welche die mechanischen und kinematischen Parameter in Verbindung setzen. Mit gegebener Geometrie des Modells, Anfangs- und Randbedingungen können diese Differenzialgleichungen gelöst und ein Gleichgewichtszustand des Modells erreicht werden. Durch das explizite Lösungsschema wird das numerische Modell durch aufeinanderfolgende Zyklen (Zeitschritte) gelöst. In jedem Zeitschritt werden zuerst die Bewegungsgleichungen gelöst, woraus Kräfte und Spannungen berechnet werden. Mit diesen werden neue Geschwindigkeiten und Verformungen berechnet, wodurch die Dehnrates und in weiterer Folge neue Kräfte berechnet werden können und somit ein Zeitschritt abgeschlossen ist. Die Zeitschritte werden wiederholt, bis ein Gleichgewichtszustand erreicht wird (vgl. Itasca Consulting Group, Inc 2019a).

3.1.1 Randbedingungen und Maße des FDM-Netzes

Die Ränder des Berechnungsnetzes sollten ausreichend weit vom Tunnelquerschnitt entfernt sein, sodass die Randbedingungen die Berechnung nicht mehr maßgeblich beeinflussen. Aus Symmetriegründen reicht für die Setzungsrechnung ein Halbmodell.

Der obere horizontale Rand, der die Geländeoberfläche nachbildet, wird mit keinen fixierten Randbedingungen belegt und kann sich daher frei verformen. An den vertikalen Rändern an den Seiten wird die horizontale Verschiebung gesperrt, jedoch vertikale Verschiebungen zugelassen. Der untere horizontale Rand wird sowohl in horizontaler als auch in vertikaler Richtung gesperrt, wodurch ein sehr steifer Untergrund nachgebildet wird, wo auch in der Realität nur sehr geringe Bodendeformationen zu erwarten sind (vgl. Möller 2006: 43). In der Formulierung der FD geschieht die Sperrung, indem die Geschwindigkeiten der jeweiligen Richtung auf 0 gesetzt werden. Da die Berechnungen in FLAC3D geschehen, wird die dritte Dimension in Richtung der Tunnelachse durch eine 1 m breite Zone berücksichtigt und die Verschiebungen an der Stirn- und Rückseite des Modells wiederum gesperrt. In Abb. 8 werden die verwendeten Randbedingungen und die geometrischen Abmessungen des FDM-Netzes dargestellt.




Abb. 8: Skizze des FDM-Modells und der Randbedingungen

Da an den vertikalen Rändern vertikale Verformungen zugelassen werden, ist es sehr wichtig, dass sich die Ränder weit genug entfernt vom Tunnelquerschnitt befinden, da ansonsten mit zu großen Setzungen zu rechnen ist (vgl. Möller 2006: 47). Vlachopoulos und Diederichs (2014: 480) stellten fest, dass die genaueste Übereinstimmung zwischen dem 3D-Modell und der 2D-Berechnung mit einem freien vertikalen Rand in einer Entfernung von 12-mal dem Tunnelradius erzielt werden konnte. Da jedoch die kinematische Kontrolle freier Ränder schwieriger ist, empfehlen sie für die 2D-Berechnung mit einem fixierten vertikalen Rand im Abstand von 16 bis 20 Tunnelradien zu arbeiten.

In bereits publizierten Studien kommen auch andere Abmessungen des FE/FDM-Netzes zum Einsatz. Die Tabelle 2 gibt darüber Aufschluss:

Tabelle 2: Übersicht über FE/FDM-Netz Abmessungen

Durchmesser	Radius	C	X	Z	X/R	Z/R	Quelle
[m]	[m]	[m]	[m]	[m]	[-]	[-]	
12.4	6.2	25.0	143.8	32.6	23.2	5.3	Janin et al. (2015)
9.4	4.7	15.3	115.3	35.3	24.5	7.5	Do et al. (2014)
9.0	4.5	16.0	40.5	16.0	9.0	3.6	Karakuş (2007)
9.0	4.5	16.0	45.5	16.0	10.1	3.6	Svoboda und Masin (2009)
13.3	6.7	13.0	63.4	26.2	9.5	3.9	Svoboda und Masin (2009)

Möller (2006: 48) führte im Zuge seiner Dissertation auch eine Parameterstudie zur Bestimmung der optimalen Abmessungen des Berechnungsnetzes durch. Es wird ein Z/R-Verhältnis von 2.6 bis 4.4 empfohlen. Für den minimalen Abstand zwischen dem Tunnel und dem vertikalen Rand gibt er folgende Formel an:

$$X = 2 \cdot D \cdot \left(1 + \frac{C}{D}\right)$$

Formel 3-1

Mit Formel 3-1 kommen für kleinere Verhältnisse der Überdeckung zum Tunneldurchmesser relative kleine Entfernungen des vertikalen Randes zustande. Erst ab einem Verhältnis von C/D von 4 wird ein X/R-Verhältnis von 20, wie von Vlachopoulos und Diederichs (2014: 480) empfohlen, erreicht. Im Zuge dieser Arbeit wird daher den Empfehlungen von Vlachopoulos und Diederichs (2014: 480) nachgegangen und ein **X/R-Verhältnis** von mindestens **20**, auch bei geringerer Überdeckung, angewandt. Das **Z/R-Verhältnis** ist an den neueren publizierten Beispielen von Do et al. (2014) und Janin et al. (2015) orientiert und daher wird ein Z/R- Wert von **6** angewandt.

3.1.2 Anfangsbedingungen Erdruchdruck K_0

Als Initialspannungszustand wird der Erdruchdruck angesetzt. Hierbei wird von normalkonsolidierten Böden ausgegangen, für die der Erdruchdruckbeiwert K_0 gemäß Jaky folgendermaßen definiert ist:

$$K_0 = 1 - \sin(\varphi')$$

Formel 3-2

Der Erdruchdruck hängt somit nur vom effektiven Reibungswinkel φ' und der effektiven vertikalen Spannung σ'_v ab.

3.1.3 FDM-Netz

Das FDM-Netz besteht aus Zonen, die jeweils eine hexaedrische Gestalt annehmen. Bei der Netzerstellung wurde auf folgende Aspekte gemäß Itasca Consulting Group, Inc (2015: 46) achtgegeben:

- Feinere Berechnungsnetze führen zu genaueren Ergebnissen
- Es werden bessere Ergebnisse erzielt, wenn das Verhältnis der längsten und der kürzesten Seite einer Zone dem Wert 1 entgegenstrebt
- Der Übergang von kleinen Zonen zu größeren Zonen sollte möglichst gleichmäßig und in kleinen Schritten geschehen, um genauere Ergebnisse zu erlangen

Da ein feineres Berechnungsnetz zu längeren Berechnungszeiten führt, wurde das Netz abgestuft. Der Tunnel und die direkte Umgebung bis zu einer Entfernung von einmal dem Durchmesser vom Tunnelmittelpunkt aus gemessen wurden mit einem feinen Netz modelliert. Um die kreisrunde Form des Tunnels gut nachbilden zu können, wurde der Tunnelumfang eines Viertelkreises in 2-D Zonen eingeteilt. Oberhalb und seitlich des Tunnels wird das Netz größer. Der Bereich unterhalb des Tunnels ist für die Setzungsberechnung von der geringsten Bedeutung, wodurch dort die größten Zonen vorgefunden werden. Abb. 9 zeigt beispielhaft ein Modell und die Zonenverteilung:




Abb. 9: Beispiel eines FLAC3D Modells

3.1.4 Materialgesetz

Um das nichtlineare Spannungs-Verformungsverhalten von realen Böden bestmöglich abzubilden, muss auf komplexere Materialgesetze zurückgegriffen werden. Im Allgemeinen wird das Verhalten des Bodens von elastischen und plastischen Verzerrungen charakterisiert. Einfache Modelle wie das Mohr-Coulomb-Modell erfordern nur wenige Eingangsparameter, sind aber nicht für komplexere Berechnungen geeignet. In der Praxis geschieht somit immer ein Trade-Off zwischen der Komplexität des Modells, der Modellparameter und der erwarteten Genauigkeit der Rechnungen (vgl. Meschke et al. 2014: 190-191). In dieser Arbeit werden das Mohr-Coulomb (MC)- und das Plastic-Hardening (PH)-Modell verwendet und nachfolgend kurz beschrieben.

3.1.4.1 Mohr-Coulomb Materialgesetz

Das MC-Materialgesetz ist ein linear-elastisches und perfekt-plastisches Modell. Der linear-elastische Teil basiert auf dem Hookeschen Gesetz, wobei die Spannungen direkt proportional zu den Belastungen sind. Ob irreversible plastische Verformungen auftreten, wird durch eine Fließfunktion bestimmt. Diese Fließfunktion lässt sich im Hauptspannungsraum als Fläche darstellen (siehe Abb. 10) und ist nur von den effektiven Hauptspannungen sowie den Materialparametern c' und ϕ' abhängig. Spannungszustände, die innerhalb der Fließfläche liegen, sind durch rein elastisches Verhalten mit reversiblen Verformungen gekennzeichnet (PLAXIS 2021: 32-42; Meschke et al. 2014: 191-193).




Abb. 10: Fließfläche des Mohr-Coulomb-Materialgesetzes im Hauptspannungsraum für einen kohäsionslosen Boden (PLAXIS 2021: 34)

Als Eingangsparameter für das MC-Modell dienen die in Tabelle 3 angeführten Parameter.

Tabelle 3: Übersicht über die Eingangsparameter des MC-Modells

Kohäsion	c	[kN/m ²]
Reibungswinkel	φ	[°]
Elastizitätsmodul	E	[kN/m ²]
Poissonzahl	ν	[-]
Dilatanzwinkel	ψ	[°]

Als einfaches Materialgesetz berücksichtigt das MC nur konstante Materialkennwerte und weist keine Spannungsabhängigkeit auf. Deswegen sollte bei der Wahl des E-Moduls auf realistische Werte, die dem erwarteten in-situ Zustand entsprechen, Bedacht genommen werden (PLAXIS 2021: 36-37).

3.1.4.2 Plastic-Hardening-Modell

Das Plastic-Hardening (PH)-Modell ist ein elasto-plastisches Materialgesetz. Die Fließfläche des PH-Modells ist im Gegensatz zum MC-Modell im Hauptspannungsraum nicht fixiert, sondern kann sich aufgrund von voranschreitender plastischer Dehnung ausweiten, was als Verfestigung bezeichnet wird. Auch die Steifigkeiten sind im PH-Modell spannungsabhängig. Das PH-Modell in FLAC3D basiert auf der Arbeit von Schanz et al. (1999), die das Hardening Soil Model für die FE-Software PLAXIS eingeführt haben. Die folgenden Ausführungen beziehen sich auf die Publikationen von Schanz et al. (1999) und Cheng und Detournay (2016).

Als Eingangsparameter für das PH-Modell werden in FLAC3D folgende, in Tabelle 4 abgebildeten Kennwerte definiert:

Tabelle 4: Übersicht über die Eingangsparameter des PH-Modells

Kohäsion	c	[kN/m ²]
Reibungswinkel	φ	[°]
Poissonzahl	ν	[-]
Dilatanzwinkel	ψ	[°]
Referenzsekantensteifigkeit bei 50 % der maximalen Deviatorspannung	E_{50}^{ref}	[kN/m ²]
Referenztangentensteifigkeit bei Erstbelastung im Ödometerversuch	$E_{\text{oed}}^{\text{ref}}$	[kN/m ²]
Referenzsteifigkeit bei Ent-/Wiederbelastung im Triaxialversuch	$E_{\text{ur}}^{\text{ref}}$	[kN/m ²]
Exponent für die Spannungsabhängigkeit	m	[-]
Referenzspannung im Triaxialversuch (meist 100 kN/m ²)	p_{ref}	[kN/m ²]

Die Grundidee hinter der Formulierung des PH-Modells ist es, die hyperbolische Beziehung (siehe Abb. 11) zwischen den vertikalen Verzerrungen ε_1 und der deviatorischen Spannung q zu berücksichtigen. Der Boden zeigt bei primärer Belastung eine sich verringernde Steifigkeit. Gleichzeitig entwickeln sich irreversible plastische Verformungen. Bei Erreichen der maximalen deviatorischen Spannung/Scherfestigkeit q_f , deren Formulierung aus dem MC-Bruchkriterium abgeleitet ist, ist die Bruchbedingung erfüllt und es kommt zum plastischen Fließen (vgl. Schanz et al. 1999: 282):

Versagensscherfestigkeit	$q_f = \frac{6 \cdot \sin(\varphi)}{3 - \sin(\varphi)} \cdot (\sigma_3 + c \cdot \cot(\varphi))$	Formel 3-3
--------------------------	--	-------------------

Asymptotische Scherfestigkeit	$q_a = \frac{q_f}{R_f}$	Formel 3-4
-------------------------------	-------------------------	-------------------

Versagensfaktor	$R_f = 0.9$ (kann geändert werden)	Formel 3-5
-----------------	------------------------------------	-------------------




Abb. 11: hyperbolische Spannungs-Dehnungsbeziehung im drainierten Triaxialversuch (PLAXIS 2021: 69)

Die Spannungsabhängigkeit der Steifigkeiten wird folgendermaßen formuliert:

$$\text{Sekantensteifigkeit} \quad E_{50} = E_{50}^{ref} \cdot \left(\frac{\sigma_3 + c \cdot \cot(\varphi)}{p_{ref} + c \cdot \cot(\varphi)} \right)^m \quad \text{Formel 3-6}$$

$$\text{Tangentensteifigkeit} \quad E_{oed} = E_{oed}^{ref} \cdot \left(\frac{\sigma_3 + c \cdot \cot(\varphi)}{p_{ref} + c \cdot \cot(\varphi)} \right)^m \quad \text{Formel 3-7}$$

$$\text{Steifigkeit bei Ent-/Wiederbelastung} \quad E_{ur} = E_{ur}^{ref} \cdot \left(\frac{\sigma_3 + c \cdot \cot(\varphi)}{p_{ref} + c \cdot \cot(\varphi)} \right)^m \quad \text{Formel 3-8}$$

Der Parameter E_{oed} kann mit einem Ödometerversuch, die Parameter E_{50} , E_{ur} und der Exponent für die Spannungsabhängigkeit m mit einem Triaxialversuch kalibriert werden (vgl. Itasca Consulting Group, Inc 2019b). Typische Werte für den Exponenten m liegen bei Kies zwischen 0.4 und 0.6, bei Sand zwischen 0.5 und 0.9, bei Schluff zwischen 0.6 und 0.9 und bei Ton zwischen 0.9 und 1 (vgl. Obrzud & Truty 2018: 80/117).

Zur Verfestigung, also zur Tatsache, dass nach plastischen Verformungen größere Spannungen notwendig sind, um weitere plastische Deformationen hervorzurufen, kommt es einerseits durch plastische Scherbeanspruchung (Reibungskomponente), andererseits durch plastische volumetrische Beanspruchungen (Druckkomponente). Bei großen plastischen Stauchungen weitet sich die Fließfläche aus, das Versagenskriterium nach MC bleibt aber weiterhin bestehen (vgl. Schanz et al. 1999: 284; Cheng & Detournay 2016: 268-270).




Abb. 12: Fließfläche des Plastic-Hardening-Materialgesetzes im Hauptspannungsraum für einen kohäsionslosen Boden (PLAXIS 2021: 81)

Die gesamte Fließfläche (siehe Abb. 12) setzt sich aus der Fließfläche infolge der Scherbeanspruchung und aus einer volumetrischen Kappe infolge der Druckbeanspruchung zusammen. Die Fließfläche infolge der Scherbeanspruchung wird maßgeblich von den Modulen E_{50} und E_{ur} beeinflusst und ist in der sechseckigen Form der Fließfläche des MC-Modells. Die Gestalt der Kappe wird wiederum von E_{oed} und der Überkonsolidierungsrate des Bodens OCR beeinflusst. Bei einem hohen OCR verhält sich das PH-Modell so, als ob die Kappe nicht existieren würde (vgl. Schanz et al. 1999: 284-289; Cheng & Detournay 2016: 270).

3.1.5 Bodenparameter

Für das PH-Materialgesetz werden, wie oben bereits beschrieben, mehr Materialparameter benötigt als z.B. für das einfachere MC-Materialgesetz. Eine experimentelle Bestimmung der Materialkennwerte würde den Umfang dieser Arbeit sprengen, weswegen auf Daten und Beziehungen aus publizierter Literatur zurückgegriffen wurde. Um eine möglichst umfassende Datenbank an Setzungsprognosen erstellen und eine möglichst große Bandbreite an Materialparametern gewährleisten zu können, wurden insgesamt 10 verschiedene Böden in die Berechnungen miteinbezogen. Durch die große Streuung der Bodenkennwerte soll die Qualität des später entwickelten ANN, welches bekanntlich nur gute Prognosen treffen kann, wenn sich die zukünftigen Bodenparameter im Bereich der während des Trainings des ANN verwendeten Daten befinden, verbessert werden. Tabelle 5 gibt Aufschluss über die verwendeten Materialparameter und die jeweiligen Quellen. Die OCR bezieht sich auf eigene Abschätzungen nach Proheberechnungen, da bei normalkonsolidierten bindigen Böden die Proheberechnungen unrealistische Setzungsmulden ergaben, wobei sich sogar der Boden am äußeren Rand sehr stark setzte. Deswegen wurde für bindige, weiche Böden eine $OCR \geq 2$ verwendet. In der FDM-Berechnung wird der gesamte Untergrund homogen modelliert. Der Grundwasserspiegel befindet sich in allen Berechnungen unterhalb der Tunnelsohle. Um die Steifigkeiten des PH-Modells in den MC-Kennwert des Elastizitätsmoduls umzurechnen, wurde der Mittelwert der 3 Referenzsteifigkeitswerte gebildet.

Tabelle 5: Verwendete Materialparameter für das Plastic-Hardening-Modell

Bodenart	Index	ρ	c	φ	v	ψ	Quelle
		[kg/m ³]	[kPa]	[°]	[-]	[°]	
Gr	1	2100	0.0	42.0	0.2	2.0	Pramthawee et al. (2011: 330)
Sa	2	1900	0.0	35.0	0.2	5.0	PLAXIS (2021: 224)
Si	3	2000 ^a	10.0 ^a	25.2 ^a	0.2 ^a	0.0 ^b	Fu et al. (2020: 9) ^a Obrzud und Truty (2018: 107/117) ^b
Cl	4	1950	32.8	23.0	0.2	0.0	Surarak et al. (2012: 693-696)
Cl, si	5	2019	10.4	12.5	0.2	0.0	Momeni et al. (2013: 18)
Si, cl	6	2200	30.0	26.0	0.2	0.0	Scharinger et al. (2016: 972)
Cl marin	7	2200	33.6	17.5	0.2	1.6	Saleh et al. (2021: 9)
Cl	8	1800	5.1	20.8	0.2	0.0	Klai et al. (2015: 4)
Gr zementiert	9	1900	40.0	36.0	0.2	6.0	Sharifzadeh et al. (2013: 181)
Sa, si	10	2000	50.0	39.0	0.2	0.0	Govindasamy et al. (2019: 124)

Bodenart	Index	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	m	OCR	Quelle
		[MPa]	[MPa]	[MPa]	[-]	[-]	
Gr	1	90.0	90.0	270.0	0.40	1	Pramthawee et al. (2011: 330)
Sa	2	45.0	45.0	180.0	0.55	1	PLAXIS (2021: 224)
Si	3	4.4 ^a	3.4 ^a	14.0 ^a	0.70 ^b	2	Fu et al. (2020: 9) ^a Obrzud und Truty (2018: 107/117) ^b
Cl	4	9.5	12.0	30.0	1.00	4	Surarak et al. (2012: 693-696)
Cl, si	5	12.0	12.0	36.2	1.00	4	Momeni et al. (2013: 18)
Si, cl	6	37.6	37.6	150.4	0.30	4	Scharinger et al. (2016: 972)
Cl marin	7	3.4	3.6	12.0	0.70	4	Saleh et al. (2021: 9)
Cl	8	2.1	1.6	6.2	1.00	4	Klai et al. (2015: 4)
Gr zementiert	9	94.2	94.2	282.7	0.50	1	Sharifzadeh et al. (2013: 181)
Sa, si	10	75.0	60.0	150.0	0.75	4	Govindasamy et al. (2019: 124)

3.1.6 Modellierung und Parameter der Sicherungsmaßnahmen

Wie in Kapitel 2.1 beschrieben kommen je nach Vortriebsart unterschiedliche Sicherungsmaßnahmen zum Einsatz. Beim zyklischen Vortrieb geschieht die Sicherung des Ausbruchquerschnitts mittels Spritzbeton, wohingegen bei maschinelltem Vortrieb Betonfertigteile zum Einsatz kommen. Tübbinge werden oft in der Betonfestigkeitsklasse C40/50 ausgebildet. Bei Spritzbeton sollte zwischen jungem und bereits ausgehärtetem Spritzbeton unterschieden werden, wobei es schwierig ist, gute Anhaltswerte bezüglich der Materialeigenschaften zu liefern, da die Zusammensetzung von Spritzbeton sehr unterschiedlich ist. Eine Prüfung der Materialeigenschaften ist durchzuführen. Gemäß Leca (2001: 73) werden für ausgehärteten Spritzbeton meist Werte von 10 GPa bis 15 GPa für den E-Modul verwendet. Junger Spritzbeton z.B. 3 h nach der Aufbringung weist einen E-Modul von rund 4 GPa auf. Folgende Tabelle 6 gibt Aufschluss auf die in der Modellierung berücksichtigten Materialeigenschaften:

Tabelle 6: Materialeigenschaften des Tunnelausbaus

	Wichte γ [kN/m ³]	E-Modul [GPa]	Poissonzahl
Tübbing	25 ³	35 ⁴	0.2 ⁴
Spritzbeton jung	26 ³	4 ⁵	0.2 ⁴
Spritzbeton ausgehärtet	25 ³	15 ⁵	0,2 ⁴

Testberechnungen zeigten, dass der Einfluss der zeitlichen Festigkeitsentwicklung des Spritzbetons mit der CCM sehr klein ist, weswegen der Tunnelausbau als fix angesehen wird und nur mit der Endfestigkeit angesetzt wird. Die Stärke der aufgetragenen Spritzbetonschicht beträgt 35 cm, für die Tübbinge wird eine Dicke von 40 cm angenommen. Modelliert wird der Tunnelausbau mit den in Tabelle 6 genannten Parametern mit einem linear-elastischen Materialverhalten und als „structural shell“. Über das Inputfeature „Vortriebsart“ finden die Sicherungsmaßnahmen Einzug in das ANN. TVM-Tunneln wird der Wert 0, NATM-Tunneln der Wert 1 für den Parameter Vortriebsart zugewiesen.

3.1.7 2D-Methoden zur Berücksichtigung der 3D-Effekte während des Tunnelbaus

Der Bau eines Tunnels ist in der Realität ein dreidimensionaler Prozess, der nicht direkt in einer 2D-Berechnung mit ebenem Verzerrungszustand simuliert werden kann. Um die realen Spannungsumlagerungen und vorausseilende Deformationen während des Tunnelbaus näherungsweise berücksichtigen zu können, gibt es verschiedene Ersatzmethoden. Diese ermöglichen es, die Deformationen des Untergrundes zwischen dem Ausbruch an der Ortsbrust, der Installation der Sicherungsmaßnahmen und dem vollständigen Wirksamwerden/Aushärten der Sicherungsmaßnahmen zu berücksichtigen. Übliche Ersatzmethoden für 2D-Modellierungen sind u.a. (vgl. Meschke et al. 2014: 177-180):

- convergence-confinement method (Kennlinienverfahren)
- stiffness reduction method (Steifigkeits-Reduktions-Methode des Kerns)
- disk calculation method
- hypothetical modulus of elasticity (Methode des hypothetischen Elastizitätsmoduls)
- gap method (Verschiebungskontrolle)
- Volume loss control method (Volumenverlust-Methode)

³ (vgl. ÖNORM EN 1991-1-1:2011 09 01 2011: 25)

⁴ (vgl. ÖNORM EN 1992-1-1:2015 02 15 2015: 29)

⁵ (vgl. Leca 2001: 73)

Für einen genaueren Überblick über die verschiedenen Methoden sei auf Karakuş (2007: 48-50), Vlachopoulos und Diederichs (2014: 473-477) und Meschke et al. (2014: 177-180) hingewiesen. Nachfolgend wird nur auf die CCM eingegangen, da diese in dieser Arbeit Anwendung findet.

3.1.7.1 Die Convergence-Confinement-Methode

Mit Hilfe der CCM können die Kräfte, die auf die Tunnelschale hinter der Ortsbrust wirken, abgeschätzt werden. Nahe der Ortsbrust trägt der Tunnelausbau nicht die volle Last, da ein Teil von der Ortsbrust selbst aufgenommen wird. Je weiter entfernt die Ortsbrust rückt, desto mehr Last trägt auch die Tunnelschale. Ab einer gewissen Entfernung ist der Einfluss der Ortsbrust nicht mehr gegeben und die gesamten Lasten werden von der Tunnelschale übernommen (vgl. Carranza-Torres & Fairhurst 2000: 188).

Der Effekt der sich entfernenden Ortsbrust wird näherungsweise durch einen auf den Rand des Ausbruchquerschnitts aufgetragenen inneren Druck repräsentiert. Zu Beginn wird ein innerer Druck p_0 in der Größe der in-situ Spannung entlang des Randes des Ausbruchquerschnitts aufgebracht. Dieser Druck wird in weiterer Folge mittels des Faktors λ immer weiter reduziert, bis der Druck den Wert 0 erreicht. Bei nicht standfesten Bedingungen wird die Reduktion zuvor bei stabilen Bedingungen gestoppt (vgl. Karakuş 2007: 48; Vlachopoulos & Diederichs 2014: 475):

$$p = (1 - \lambda) \cdot p_0$$

Formel 3-9

wobei:

p = aufgetragener Druck

λ = Vorentlastungsfaktor [0;1]

p_0 = in-situ Spannung zu Beginn

sind. Die Ergebnisse dieser Reduktion lassen sich als Kurve darstellen, welche ground-reaction-curve (GRC, siehe Abb. 13) genannt wird und den Zusammenhang zwischen den radialen Verformungen des ungestützten Tunnels und dem Vorentlastungsfaktor λ abbildet. Der innere aufgetragene Druck, welcher mit einer gewissen radialen Verformung in Verbindung steht, ist ein Maß dafür, wie viel Lasten die Tunnelsicherungsmaßnahmen aufnehmen müssen, um eine weitere Verformung des Tunnels zu verhindern (vgl. Karakuş 2007: 48; Vlachopoulos & Diederichs 2014: 475).




Abb. 13: Beispiel einer Ground-Reaction-Curve aus FLAC3D (instabil ab $\lambda=0.9$; negative Werte durch umgekehrte Darstellung in FLAC3D bedingt)

3.1.7.2 Längssetzungsmulde aus der GRC

Zur Abschätzung, in welcher Entfernung von der Ortsbrust die Sicherungsmaßnahmen installiert werden, kann die Längssetzungsmulde (longitudinal displacement profile, LDP) verwendet werden. Mithilfe des LDP wird das Modell kalibriert und die GRC mit realen Distanzen korreliert. Das LDP kann nur mittels 3D- bzw. mittels 2D-Axisymmetrischen Analysen berechnet werden, jedoch kann eine einfache 2D-Berechnung im ebenen Verzerrungszustand dazu verwendet werden, gewisse Kennwerte zu ermitteln, aufgrund derer eine analytische Formulierung des LDP kalibriert wird (vgl. Vlachopoulos & Diederichs 2009: 133-136).

Analytische Formulierungen wurden u.a. von Panet (1995), Unlu und Gerçek (2003) oder Vlachopoulos und Diederichs (2009) aufgestellt, wobei die beiden erstgenannten Publikationen ihre Formulierung des LDP aus elastischen Analysen ableiteten. Vlachopoulos und Diederichs (2009) stellten jedoch fest, dass die radialen Verformungen eines Tunnels direkt im Einklang mit der sich entwickelnden plastischen Zone während des Tunnelvortriebs steht. Mit verschiedenen axisymmetrischen FE-Berechnungen und 2D-Berechnungen im ebenen Verzerrungszustand wurden Daten des LDP, der radialen Verformungen und der plastischen Zone generiert. Die Analyse zeigte eine starke Korrelation des LDP mit dem normalisierten Radius der plastischen Zone. Folgende drei Gleichungen wurden vorgeschlagen:

$$u_0^* = \frac{u_0}{u_{\max}} = \frac{1}{3} \cdot e^{-0.15R^*} \quad \text{für } x^* = 0 \text{ (an der Ortsbrust)} \quad \text{Formel 3-10}$$

$$u^* = \frac{u}{u_{\max}} = u_0^* \cdot e^{x^*} \quad \text{für } x^* \leq 0 \text{ (vor der Ortsbrust)} \quad \text{Formel 3-11}$$

$$u^* = 1 - (1 - u_0^*) \cdot e^{\frac{-3x^*}{2R^*}} \quad \text{für } x^* \geq 0 \text{ (im Tunnel)} \quad \text{Formel 3-12}$$

wobei:

u_0 = radiale Verformung an der Ortsbrust

u_0^* = normalisierte radiale Verformung an der Ortsbrust

u^* = normalisierte radiale Verformung des ungesicherten Tunnels

u = radiale Verformung des ungesicherten Tunnels

$u_{\max}$ = maximale radiale Verformung des ungesicherten Tunnels

$R^* = R_p/R_t$ = normalisierter Radius der plastischen Zone

R_p = Radius der plastischen Zone

R_t = Tunnelradius

x = Entfernung von der Ortsbrust

$x^* = x/R_t$ = normalisierte Entfernung

sind. Mithilfe der oben genannten Gleichungen können Verformungen mit einer Position entlang des Tunnels korreliert werden und somit der Ort der Installation von Sicherungsmaßnahmen in 2D-Analysen berücksichtigt werden. Als Eingangsparameter zur Berechnung des LDP dienen die maximale radiale Verformung des ungesicherten Tunnels $u_{\max}$ und der Radius der plastischen Zone R_p . Beide Werte können mit der CCM in einer 2D-Analyse im ebenen Verzerrungszustand ermittelt werden (vgl. Vlachopoulos & Diederichs 2009: 141). In Abb. 14 ist ein LDP beispielhaft dargestellt. Die Anwendung des LDP ist naturgemäß mit vielen Unsicherheiten behaftet und sollte daher nur zur Abschätzung des Vorentlastungsfaktor dienen (vgl. Vlachopoulos & Diederichs 2014: 487).




Abb. 14: Beispiel einer Längssetzungsmulde bei $R^*=2.1$

Aufgrund der unterschiedlichen Entfernungen der Sicherungsmaßnahmen zur Ortsbrust von TVM- und NATM-Tunneln ergeben sich unterschiedliche Vorentlastungsfaktoren λ . Für den Fall eines TVM-Tunnels wurde ein Vorentlastungsfaktor von 0.1 gewählt, bei NATM-Tunneln liegt der Vorentlastungsfaktor je nach Bodenart, Überdeckung und Geometrie bei 0.15 bis 0.5. Bei der Abschlagslänge von NATM-Tunneln wurde sich am Wert von 1 m orientiert.

3.1.8 Implementation der 2D-Berechnung

Im Folgenden wird der Ablauf der 2D-Berechnung⁶ im Programm FLAC3D 6.0 wiedergegeben:

- 1) Eingangsparameter für die automatische Netzerstellung sind der Tunneldurchmesser D , die Überdeckung C sowie die Bodenkennwerte
- 2) Die Geometrie wird über eine FISH⁷-Funktion automatisch erstellt
- 3) Die Randbedingungen werden gemäß Kapitel 3.1.1 aufgebracht
- 4) Allen Zonen wird das MC-Materialgesetz zugewiesen und der Initialspannungszustand mit Formel 3-2 berechnet
- 5) Das Materialmodell wird auf PH umgestellt
- 6) Der Tunnelkern wird deaktiviert und die vorherrschenden in-situ Spannungen entlang des Randes des Tunnels aufgebracht
- 7) Die aufgebrachte Spannung gemäß Formel 3-9 wird in 10 Schritten bis zum Wert 0 bzw. bei nicht standsicheren Bedingungen bis zu einem standsicheren Vorentlastungsfaktor λ reduziert
- 8) Die so berechnete GRC und der plastische Radius dienen als Eingangsparameter für das LDP von Vlachopoulos und Diederichs (2009). Mithilfe des berechneten LDP wird der Vorentlastungsfaktor λ abgeschätzt
- 9) Der Modellzustand wird gemäß dem ermittelten Vorentlastungsfaktor zurückgesetzt und entlang des Tunnelumfangs werden die Sicherungsmaßnahmen als „structural shell“ installiert

⁶ Im Anhang A FLAC-Berechnungsfile Beispiel befindet sich ein Beispielberechnungsfile

⁷ FISH ist die FLAC-eigene Skriptsprache

- 10) Die aufgebrachte Spannung wird auf 0 reduziert. Die gesamte Last wird vom Tunnelausbau getragen
- 11) Die maximale Oberflächensetzung wird ausgelesen und mittels Kurvenanpassung (Formel 2-1) an die Setzungsmulde wird der Wendepunktabstand i bestimmt

3.1.9 Beispielberechnungen

Zur Kontrolle des entwickelten FLAC-Codes wurden mehrere Beispielberechnungen durchgeführt. Hierzu wurde in der Literatur nach Beispielen gesucht, das Modell nachgebildet und die Ergebnisse miteinander verglichen.

3.1.9.1 Numerische Berechnungen mit dem MC-Materialgesetz von Do et al. (2014)

Do et al. (2014) führten eine 2D-Berechnung mit dem MC-Materialgesetz für einen Bahntunnel in TVM-Bauweise durch. Für die genauen Eingangsparameter sei auf die Publikation verwiesen. Im Unterschied zu der erwähnten Publikation wurde bei der Nachrechnung auf die Berücksichtigung der Verpressung des Ringspaltes verzichtet. Außerdem wurde die Tunnelschale hier als structural shell und nicht als embedded liner mit Gelenken wie bei Do et al. (2014) ausgebildet. Sowohl in der Publikation als auch hier wurde ein Vorentlastungsfaktor von 0.75 angewandt, was für TVM-Tunnel ein bereits sehr hoher Wert ist.




Abb. 15: Setzungsmulde bei der Nachrechnung von Do et al. (2014)

In der Publikation wurde eine maximale Setzung von 15 mm ermittelt, bei der Nachrechnung eine von 17 mm (siehe Abb. 15). Die Abweichung lässt sich durch die unterschiedlichen Berechnungsnetzgrößen und durch die unterschiedliche Modellierung der Sicherungsmaßnahmen erklären, wobei die Abweichung klein ist und die Vorgehensweise der Berechnung somit als annehmbar einzustufen ist.

3.1.9.2 Berechnung eines Teilabschnitts der U-Bahn in Teheran

Mohammadi et al. (2015) erstellten im Zuge der Entwicklung eines ANN eine kleine Datenbank mit den wichtigsten Geometriedaten, Bodenparametern und der maximalen, gemessenen Setzung eines Tunnels in NATM-Bauweise. Nachfolgend werden die Vorgehensweise und die Ergebnisse der Nachrechnung kurz präsentiert.

Im Unterschied zur Publikation wurde in dieser Arbeit der Tunnel kreisrund mit einem Durchmesser von 13 m modelliert. Als Testabschnitt wurde der Abschnitt SB1 gewählt und die Berechnungen mit den angegebenen Bodenparametern zuerst mit einem MC- und dann mit

dem PH-Materialgesetz mithilfe der CCM durchgeführt. Gemäß dem LDP nach Vlachopoulos und Diederichs (2009) wurde ein Vorentlastungsfaktor λ von 0.3 ermittelt.




Abb. 16: berechnete Setzungsmulde des Abschnitts SB1 der U-Bahn in Teheran

Der Vergleich der Berechnungen mit der Setzungsmessung zeigt eine deutlich bessere Übereinstimmung des PH- Modells mit der Setzungsmessung. Es wurde eine maximale Setzung von 24.5 mm berechnet, was gut mit der gemessenen Setzung von 21.5 mm übereinstimmt (siehe Abb. 16).

Für den Abschnitt SB7 mit größerer Überdeckung wurde ein Vorentlastungsfaktor λ von 0.4 ermittelt. Die Setzungsmulde nimmt folgende Form an:




Abb. 17: berechnete Setzungsmulde des Abschnitts SB2 der U-Bahn in Teheran

Die maximale berechnete Setzung beträgt 23 mm (siehe Abb. 17), was eine große Abweichung zur gemessenen Setzung von 33.6 mm ist. Der größte Unsicherheitsfaktor in der 2D-Berechnung ist die richtige Wahl des Vorentlastungsfaktors λ , da dieser nur relativ ungenau mittels des LDP oder mittels Erfahrungswerte abgeschätzt werden kann.

3.1.10 Zuweisung der Geometrie- und Bodenparameter

Sowohl TVM- als auch NATM-Tunnel werden in den Berechnungen näherungsweise kreisrund ausgebildet. Um realistische Tunnel zu simulieren, wurden für den Tunneldurchmesser D Grenzen definiert, innerhalb derer sich der jeweilige Durchmesser befinden darf. Als untere Grenze wurde 5 m und als obere 15 m (siehe Kapitel 2.1.2) festgelegt. Die Überdeckung C findet über das Überdeckungsverhältnis C/D indirekt Eingang in die Geometriebetrachtung. Auch hier wurden Grenzen festgelegt, wobei sich die untere Grenze bei einem C/D-Verhältnis von 0.5 und die obere bei 5 befindet.

Um die einzelnen Datensätze zu erstellen, wurde mit dem in MS-Excel integrierten Zufallszahlengenerator gearbeitet. Die Funktion ZUFALLSZAHL gibt eine gleichmäßig verteilte Zahl zwischen 0 und 1 zurück. Mittels Formel 3-13 wird die Zufallszahl auf die vorher festgelegten Grenzen umgerechnet, wobei hier a die untere und b die obere Grenze darstellt.

$$x = \text{ZUFALLSZAHL} \cdot (b - a) + a \quad \text{Formel 3-13}$$

Die mit Formel 3-13 berechneten Zufallszahlen wurden anschließend auf eine signifikante Stelle gerundet, da die numerischen Berechnungen keine höhere Genauigkeit erfordern.

Die Zuweisung der in Kapitel 3.1.5 definierten Bodenparameter zu den Geometriedaten wurde für die ersten vier Böden (und die ersten 100 Geometriekombinationen) auch mittels des Zufallszahlengenerators durchgeführt, wobei die Indices als Grenzen dienten und die ermittelten Zufallszahlen nachfolgend auf ganze Zahlen gerundet wurden. Im Laufe der FDM-Berechnungen und eines schnell entwickelten ANN zeigte sich, dass mit zusätzlichen Böden mit anderen Bodenparametern die Modellperformance verbessert werden kann. Somit wurden weitere 40 Geometriekombination mit Formel 3-13 berechnet, jedoch die Böden mit den Indices 5 bis 10 manuell zugewiesen, wobei auf eine möglichst breite Streuung der Geometriedaten innerhalb der jeweiligen Bodengruppen geachtet wurde.

In Abb. 18 und Abb. 19 werden die verschiedenen Geometriekonstellationen je nach zugewiesener Bodenart visualisiert. Gewisse Geometriekombinationen sind einander sehr ähnlich, jedoch sind die Bodenarten unterschiedlich. Die Korrelationskoeffizienten zwischen der Bodenart und C, D sowie C/D betragen 0.05, 0.016 sowie 0.054. Die Kombinationen sind somit voneinander weitestgehend unabhängig und zufällig verteilt.




Abb. 18: Durchmesser zu Überdeckungsverhältnis je Bodenart




Abb. 19: Durchmesser zu Überdeckung je Bodenart

3.2 Machine Learning

Im folgenden Abschnitt werden die Theorie hinter einem ANN sowie die konkret für diese Arbeit entwickelten Anwendungen beschrieben. Da das Forschungsfeld dazu sehr groß ist, werden hier nur die für diese Arbeit relevanten Teilaspekte eines ANN wiedergegeben.

3.2.1 Funktionsweise eines ANN

3.2.1.1 Layer und Neuronen

Die Grundbausteine eines ANN sind verschiedene Layer (Ebenen), innerhalb derer sich Neuronen befinden. Im einfachsten Fall besteht ein ANN aus drei Layern: einem Input-, einem versteckten Layer und einem Output-Layer. In weiterer Folge können jedoch mehr versteckte Layer zu dem Modell hinzugefügt werden, um dessen Leistungsfähigkeit zu verbessern. Die Zahl der Layer ist unbegrenzt, jedoch sind zu tiefe Netzwerke schwer zu trainieren. Ein Neuron eines ANN ist von den natürlich vorkommenden Neuronen im Gehirn von Lebewesen inspiriert. Neuronen erhalten einen Input und leiten diesen nach einer Transformation zu den nachfolgenden Neuronen weiter. Verbindungen zwischen den einzelnen Neuronen der unterschiedlichen Layer können entweder vollständig (man spricht von einem fully connected network) oder unvollständig sein. Der Input wandert von den Input-Neuronen zu den Output-Neuronen, wodurch das so aufgebaute ANN auch als feedforward neural network bezeichnet wird (vgl. Géron 2019: 281-287).




Abb. 20: Schema eines einfachen Multilayer Perceptrons

Die Verbindungen zwischen den Neuronen werden - damit eine Transformation der Daten überhaupt erst stattfinden kann - eine Gewichtung der Eingangsdaten an. Jedes Neuron i des Layers a leitet somit die Eingangsdaten versehen mit einem Gewicht an das nachfolgende Neuron j des Layers b weiter. Beim Neuron j des Layers b werden alle gewichteten Eingangsdaten der einzelnen Verbindungen aus dem Layer a zusammen mit einem bias-Ausdruck summiert. Auf diese Summe wird eine Aktivierungsfunktion f angewandt, wodurch der Output y eines jeden Neurons entsteht (vgl. Géron 2019: 281-287). Formel 3-14 (für das Neuron j) und Abb. 20 geben ein einfaches Schema eines ANN wieder:

$$y_j = f(\sum(w_{i,j} \cdot x_i) + b_j)$$

Formel 3-14

wobei:

x_i = Input Neuronen

$w_{i,j}$ = Gewichtung der einzelnen Inputs für das Neuron j

b_j = Biasausdruck des Neurons j

f = Aktivierungsfunktion

y_j = Output des Neurons j

sind. Der Output eines einzelnen Neurons wird mittels neuer Gewichtung wiederum zum Input des nächsten Neurons – in diesem einfachen Fall zum Input des Output-Layers. ANN mit dieser Funktionsweise werden auch als Multilayer Perceptron bezeichnet (vgl. Géron 2019: 281-287).

3.2.1.2 Aktivierungsfunktionen

Die Aktivierungsfunktion in einem ANN dient dazu, die ankommenden Werte eines Neurons zu transformieren und an die Neuronen des nächsten Layers weiterzuleiten. Je nach Wahl der Aktivierungsfunktion können spezifische Eigenschaften eines ANN erzielt werden. Vor allem durch nichtlineare Aktivierungsfunktionen können schwierige Aufgabenstellungen durch ein ANN gelöst werden (vgl. Chollet 2018: 72). Wichtig für die Performance des ANN ist es auch, dass die Aktivierungsfunktion möglichst an allen Stellen differenzierbar ist, sodass der Optimierungsalgorithmus (siehe Kapitel 3.2.1.4) ordnungsgemäß funktionieren kann. Folgend werden drei Aktivierungsfunktionen kurz präsentiert, die im Zuge dieser Arbeit Anwendung finden.

ReLU (Rectified Linear Unit) ist eine Funktion, die folgenderweise definiert ist:

$$ReLU = f(x) = \max\{0, x\}$$

Formel 3-15

Diese Funktion gibt bei Werten größer als 0 den Eingangswert zurück, ansonsten beträgt der Funktionswert 0. ReLU ist dadurch an der Stelle 0 nicht differenzierbar, was jedoch in der Praxis keine große Rolle spielt, da die Steigung als 0 angenommen werden kann. Durch die Einfachheit aber zugleich starke Performance der ReLU-Funktion wird diese oft als Standardaktivierungsfunktion für ANN verwendet (vgl. Brownlee 2020). Eine Weiterentwicklung stellt die **GeLU**-Funktion (Gaussian Error Linear Unit) dar, die in ihrer Formulierung die Gaußsche Fehlerfunktion verwendet und im Gegensatz zu ReLU auch negative Werte annehmen kann. Durch die erhöhte Krümmung können GeLU in manchen Anwendungsfällen kompliziertere Funktionen besser approximieren als ReLU. Die Formulierung der GeLU-Funktion nimmt folgende Gestalt an (vgl. Hendrycks & Gimpel 2016: 2):

$$GeLU = f(x) = \frac{1}{2} \cdot x \cdot \left(1 + \operatorname{erf}\left(\frac{x}{\sqrt{2}}\right)\right)$$

Formel 3-16

In Abb. 21 sind die ReLU und GeLU Aktivierungsfunktionen zusammen dargestellt.




Abb. 21: ReLU und GeLU Aktivierungsfunktionen

Die **Sigmoid**-Funktion war in der Vergangenheit die Standardaktivierungsfunktion und findet auch heutzutage noch Anwendung. Bei dieser Funktion handelt es sich um eine stetig monoton steigende Funktion (siehe Abb. 22), die überall differenzierbar ist, und Werte zwischen 0 und 1 annehmen kann (vgl. Géron 2019: 288):

$$\text{Sigmoid} = f(x) = \frac{1}{1 + e^{-x}}$$

Formel 3-17




Abb. 22: Sigmoid Aktivierungsfunktion

3.2.1.3 Loss Function

Die loss function (Fehlermaß/Kostenfunktion) eines ANN dient dazu, die bekannten Ergebnisse des Trainingsdatensets mit den vom ANN berechneten Ergebnissen abzugleichen. Mithilfe der loss function können somit die Abweichungen der Rechenergebnisse von den dem ANN bekannten echten Ergebnissen quantifiziert werden. Die Optimierung der Gewichte und des Bias, welche zu einem bestimmten Ergebnis führen,

werden somit, je nach Natur der loss function, durch Minimierung bzw. Maximierung der loss function durchgeführt. Für Regressionsprobleme, wie es in dieser Arbeit der Fall ist, wird oft der Mean Squared Error (MSE) verwendet. Es sind auch andere loss functions möglich, in dieser Arbeit fand jedoch nur der MSE Anwendung (vgl. Chollet 2018: 10; Géron 2019: 44, 116, 290):

$$MSE = \frac{1}{n} \cdot \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Formel 3-18}$$

wobei:

y_i = wahrer Wert der i-ten Beobachtung

$\hat{y}_i$ = berechneter Wert der i-ten Beobachtung

sind. Eine perfekte Übereinstimmung zwischen den wahren und den berechneten Daten würde für den MSE einen Wert von 0 ergeben, wodurch im Zuge der Optimierung der Modellparameter eine Minimierung dieses Fehlermaßes angestrebt wird.

3.2.1.4 Lernprozess, Optimierungsverfahren und Backpropagation

Der eigentliche Lernprozess eines ANN im überwachten Lernen besteht darin, dass die Gewichte und die Bias-Ausdrücke eines jeden Neurons nach jeder Trainingsepoche verändert werden, um die Abweichungen zwischen den wahren und den berechneten Ergebnissen zu minimieren, wozu die in Kapitel 3.2.1.3 genannte Kostenfunktion angewandt wird. Als Trainingsepoche bezeichnet man einen Durchlauf des gesamten Trainingsdatensatzes durch das ANN (vgl. Chollet 2018: 9-11).

In der Vergangenheit wurde für die Optimierung der loss function zumeist eine Art des Gradientenverfahrens eingesetzt. Für die Minimierung einer reell differenzierbaren Kostenfunktion wie des MSE werden hierbei die Gewichte und die Bias-Ausdrücke der einzelnen Neuronen in kleinen Schritten verändert, sodass sich die Kostenfunktion verringert. Entlang des negativen Gradienten der Kostenfunktion sucht der Algorithmus nun iterativ nach den optimalen Gewichten und Bias-Ausdrücken, um das globale Minimum der Funktion zu finden. Ein Schritt des Algorithmus wird auch als Lernrate bezeichnet. Ist diese zu klein, braucht es sehr lang, bis das Minimum gefunden wird; ist diese zu groß, kann es passieren, dass kein Optimum gefunden wird und das Verfahren divergiert. Eine Weiterentwicklung stellt das stochastische Gradientenverfahren dar, wobei immer ein zufälliges Beispiel des Trainingsdatensatzes ausgewählt wird und der Gradient nur an dieser Stelle berechnet wird, bevor der Algorithmus zum nächsten Eintrag springt. Dadurch ist das stochastische Verfahren schneller und kann auch selbst aus lokalen Minima wieder herausfinden. Damit schlussendlich das globale Minimum gefunden werden kann, wird eine adaptive Lernrate angewandt. Die Lernrate startet mit einem hohen Wert, um schnell zu konvergieren und gegebenenfalls aus lokalen Minima zu entkommen, und wird sukzessive verringert. Abb. 23 veranschaulicht in einfacher Form das Prinzip des Gradientenverfahrens (vgl. Géron 2019: 119-127).




Abb. 23: Gradientenverfahren (Géron 2019: 120)

Angepasst werden bei den genannten Optimierungsverfahren die Gewichte und die Bias-Ausdrücke ausgehend vom Output-Layer zurück zum Input-Layer. Die Anpassung der Parameter propagiert rückwärts, weshalb auch von **backpropagation** gesprochen wird. Bei der Optimierung verhält sich der Vorwärtsthroughlauf wie in Kapitel 3.2.1.1 beschrieben, jedoch werden die Gewichte und Bias-Ausdrücke gespeichert, da sie in weiterer Folge angepasst werden.

Nach dem Vorwärtsthroughlauf wird mittels der Kostenfunktion die Performance des Modells evaluiert. Ausgehend davon berechnet der Optimierungsalgorithmus den Beitrag der einzelnen Gewichte und Bias-Ausdrücke zum Gesamtfehlergradienten mithilfe der Kettenregel der Differentialrechnung. Der Gradient der Kostenfunktion wandert in weiterer Folge immer weiter in Richtung des Input-Layers und bestimmt auch hier mittels der Kettenregel die Beiträge der einzelnen Verbindungen zum Gesamtfehlergradienten.

Angepasst werden die Gewichte indem vom aktuellen Gewicht w_i die partielle Ableitung der Kostenfunktion in Bezug auf das Gewicht w_i multipliziert mit der Lernrate abgezogen wird (vgl. Géron 2019: 287-288).

Im Zuge dieser Arbeit wird für die Optimierung der Adam (adaptive moment estimation) Algorithmus von Kingma und Ba (2015) verwendet. Dieser Algorithmus ist eine Erweiterung des stochastischen Gradientenverfahrens. Es wird hierbei für jeden Parameter eine eigene adaptive Lernrate angewandt. Zusätzlich zieht Adam auch den Durchschnitt der vergangenen Gradienten (Momententerm) und den Durchschnitt der quadrierten Gradienten mit ein. Dadurch erweist sich Adam in vielen Fällen als bestes Optimierungsverfahren, welches einfach anzuwenden ist, da die vorgegebenen Standardwerte bereits zu sehr guten Ergebnissen führen (vgl. Géron 2019: 349-350). Für genauere Informationen über die Funktionsweise sei auf die Originalpublikation von Kingma und Ba (2015) verwiesen.

3.2.1.5 Vanishing Gradient und Weight Initialization

Da der Backpropagation-Optimierungsalgorithmus den Gradienten der Kostenfunktion ausgehend vom Output-Layer hin zum Input-Layer weiterleitet und dazu verwendet, die Gewichte anzupassen, kann es passieren, dass der Gradient immer kleiner wird, je näher man dem Input-Layer kommt. Bei sehr kleinen Gradienten werden die Gewichte fast gar nicht mehr aktualisiert, wodurch zumeist in den unteren Ebenen kein Lernprozess stattfindet. Eine Lösung, wie dieses Problem umgangen werden kann, ist die richtige Initialisierung der Gewichte. Die Grundidee dahinter ist es, die Varianz der einzelnen Aktivierungsfunktionen und der zurückpropagierten Gradienten über alle Layer möglichst konstant zu halten. Die Varianz des Outputs eines Layers soll gleich der Varianz des Inputs und die Varianz des Gradienten soll beim Rückwärtsdurchlauf vor und nach dem Passieren eines Layers gleich sein (vgl. Géron 2019: 326-327).

Speziell für die Sigmoid Aktivierungsfunktion wurde von Glorot und Bengio (2010) eine Gewichtsinitialisierungsstrategie entwickelt. Die Gewichte des ANN werden bei der „**Glorot-Uniform**“ genannten Initialisierung mit zufälligen Werten aus einer Gleichverteilung mit den Grenzen W nach Formel 3-19 initialisiert, sodass die Varianz σ^2 Werte nach Formel 3-20 annimmt. Die Variablen n_j und n_{j+1} beziehen sich auf die Anzahl der Verbindungen, die in den betrachteten Layer ein- bzw. ausgehen.

$$W = \pm \frac{\sqrt{6}}{\sqrt{n_j + n_{j+1}}} \quad \text{Formel 3-19}$$

$$\sigma^2 = \frac{2}{n_j + n_{j+1}} \quad \text{Formel 3-20}$$

In der Bibliothek TensorFlow gibt es auch eine Weiterentwicklung mit dem Namen „Glorot-Normal“, welche zufällige Werte aus einer abgeschnittenen Normalverteilung mit dem Zentrum 0 und einer Varianz gemäß Formel 3-20 auswählt.

Für ReLU und ähnliche Aktivierungsfunktionen werden oft die Gewichtsinitialisierungsstrategien von He et al. (2015) verwendet. Gleich wie bei der Glorot-Initialisierung werden auch bei der **He-Initialisierung** Werte aus einer Gleichverteilung oder einer Normalverteilung mit den Grenzwerten bzw. der Varianz laut Formel 3-21 und Formel 3-22 verwendet. Der einzige Unterschied liegt darin, dass bei der He-Initialisierung nur die Anzahl der eingehenden Verbindungen in den betrachteten Layer in die Definition einfließt:

$$W = \pm \frac{\sqrt{6}}{\sqrt{n_j}} \quad \text{Formel 3-21}$$

$$\sigma^2 = \frac{2}{n_j} \quad \text{Formel 3-22}$$

3.2.1.6 Weight Regularization

Weight Regularization stellt eine Variante dar, wie Overfitting des ANN an das Trainingsdatenset besser vermieden werden kann. Die Idee dahinter ist es, das ML-Modell in seinen Freiheitsgraden zu beschränken, damit die Gewichte nicht zu groß werden. Zu große Gewichte führen zu einem instabilen ANN, das auf geringfügige Änderungen des Inputs mit großen Unterschieden im Output reagiert. Um die Gewichte während des Trainings klein zu halten, wird zu der gewählten Kostenfunktion ein Strafausdruck hinzugefügt, welcher die Größe der Gewichte des ANN miteinbezieht (vgl. Géron 2019: 136-137).

In dieser Arbeit wird mit der nach der L2-Norm aus der Linearen Algebra benannten Regularisierungsfunktion gearbeitet.

$$g(w) = f(w) + \alpha \cdot \frac{1}{2} \cdot \sum_{i=1}^n w_i^2 \quad \text{Formel 3-23}$$

w_i sind die einzelnen Gewichte. Der Ausdruck α ist ein Parameter, der angibt, wie stark das Modell „bestraft“ werden soll. Bei einem hohen Wert nähern sich die Gewichte dem Wert 0 an und das Modell bildet den Mittelwert der Daten ab. Vorteilhaft bei der L2-Regularisierung ist es, dass sowohl große Gewichte stärker bestraft werden, als auch weniger Gewichte mit dem Wert 0 vorkommen (vgl. Géron 2019: 137).

3.2.2 Trainings-, Test- und Validierungsdatenset

Für das Training und die Evaluierung eines ML-Systems muss das vorliegende Datenset in ein Trainings-, Test- und gegebenenfalls Validierungsdatenset unterteilt werden, damit sichergestellt werden kann, dass das Modell die Fähigkeit besitzt, zuvor ungesehene Daten gut zu generalisieren. Für den Lernprozess des ML-Algorithmus wird das **Trainingsset** verwendet und mittels des **Testdatensets** wird die Modell-Performance während des Lernprozesses evaluiert. In diesem Stadium der Entwicklung sind Veränderungen in der Architektur des ANN möglich; das heißt, dass die Hyperparameter des Modells wie z.B. die Anzahl der Layer und der Neuronen verändert werden können.

Je öfter die Hyperparameter währenddessen aufgrund der Modell-Performance des Testsets verändert werden, desto mehr Informationen gelangen vom Testset in das ML-Modell. Durch diese Optimierung des Modells aufgrund des Testsets besteht die Gefahr der Überanpassung an das Trainings- und Testset. Daher wird die endgültige Güte des ML-Systems mit dem **Validierungsset** bestimmt. Hierbei handelt es sich um Datensätze, die während des Lernprozesses, weder direkt noch indirekt verwendet wurden und somit komplett neue Daten für das Modell darstellen (vgl. Chollet 2018: 97).

Die Aufteilung der Daten in das Trainings- und Testset geschieht zufällig. Dem Trainingsset werden 63 %, dem Testset 27 % des Gesamtdatensets zugewiesen. Die verbleibenden 10 % des Gesamtdatensets dienen dem im folgenden Absatz beschriebenen Hold-Out-Validierungssets.

Das Validierungsset in dieser Arbeit besteht nicht aus zufällig ausgewählten Daten aus dem Gesamtdatenset, sondern aus manuell ausgewählten Daten zwei verschiedener Bodenarten. Hierzu wurden die Böden 7 und 9 gemäß Kapitel 3.1.5 ausgewählt. Der Gedanke dahinter ist es, dass das ANN die Bodenparameter noch nie zuvor gesehen hat und somit die Generalisierungsfähigkeit des Modells für neue Bodenarten evaluiert werden kann.

Für die einfachen entwickelten ANN (1/a/b) (siehe Kapitel 4.2, 4.3, 4.4) wird auch die in Kapitel 2.5.3 aus der Literatur zusammengestellte Datenbank von realen Aufzeichnungen von tunnelbaubedingten Setzungen herangezogen, um die Anwendbarkeit des mithilfe von FDM-Berechnungen entwickelten ML-Modells auf in der Wirklichkeit aufgetretene Fälle zu überprüfen.

3.2.3 Standardisierung der Eingangsdaten

Da die Ergebnisse von ML-Systemen in vielen Fällen noch verbesserungsfähig sind, wenn die numerischen Eingangsdaten sehr unterschiedliche Skalen besitzen, müssen die Datensets vor der Entwicklung des ML-Modells transformiert werden (vgl. Géron 2019: 72). In dieser Arbeit geschieht dies durch die Anwendung der sogenannten Standardisierung der Eingangsdaten. Hierbei wird der Bereich jedes Features unabhängig voneinander mit Formel 3-24 transformiert:

$$x' = \frac{x - \bar{x}}{\sigma_x} \quad \text{Formel 3-24}$$

wobei:

x' = standardisierter Wert

x = Ursprungswert

$\bar{x}$ = Mittelwert der Ursprungswerte

σ_x = Standardabweichung der Ursprungswerte

sind. Vorteilhaft bei dieser Art der Datentransformation erweist sich die geringere Anfälligkeit gegenüber Ausreißern in den Daten (vgl. Géron 2019: 73). Die Implementierung in das ML-Modell wird mittels des StandardScaler der Python-Bibliothek „scikit-learn“ vorgenommen (vgl. Pedregosa et al. 2011). Der Skalierer wird nur an das Trainingsdatenset und Validierungsset angepasst, das Testset wird mit den zuvor berechneten Werten des Trainingsdatensets nur transformiert.

3.2.4 Bestimmung der optimalen ANN-Architektur

Im Generellen ist es nicht möglich zu sagen, welche Kombination von Layern, Neuronen und Aktivierungsfunktionen zu einer optimalen Netzwerkarchitektur führen, weswegen in diesem Feld sehr aktiv Forschung betrieben wird (vgl. Géron 2019: 315-318).

Um die bestmögliche Architektur zu finden, werden die einzelnen Hyperparameter im Trial und Error Prinzip verändert. In dieser Arbeit wurden dazu die Hyperparameter systematisch mithilfe der in scikit-learn integrierten Funktion „GridSearchCV“ variiert. Tabelle 7 gibt über die verwendeten Hyperparameter Auskunft:

Tabelle 7: Verwendete Hyperparameter für GridSearchCV

Anzahl der versteckten Layer:	1, 2, 3, 4, 5
Anzahl der Neuronen pro Layer:	5, 7, 10, 14, 18, 21, 25, 37, 50, 75, 100, 500, 1000
Aktivierungsfunktion:	ReLU, GeLU, Sigmoid
Weight-Initialization:	GlorotNormal, GlorotUniform, HeNormal, HeUniform

Als Kostenfunktion des Modells wurde einheitlich der Mean-Squared-Error (MSE) (siehe Kapitel 3.2.1.3) herangezogen. Während des GridSearch kommt ein vierfacher ShuffleSplit - eine zufälliger Variante des Kreuzvalidierungsverfahrens (siehe Abb. 24) - zum Einsatz. Der GridSearch-Algorithmus trainiert dadurch pro Parameterkombination 4 Modelle, wobei jeweils das Trainingsdatenset nochmals in 4 Subsets unterteilt wird. Pro GridSearch-Durchlauf werden somit 75 % des Trainingsdatensets für das Training verwendet, die restlichen 25 % dienen als GridSearch-Testset während der Parameteroptimierung. Das eigentliche gemäß Kapitel 3.2.2 erstellte Testset dient während des GridSearch zu Verhinderung von Overfitting durch die in Kapitel 3.2.6 beschriebene Callback-Funktion EarlyStopping. Der Wert der

Kostenfunktion wird als Mittelwert der Kostenfunktion der Subsets mit einer Standardabweichung angegeben.




Abb. 24: ShuffleSplit-Beispiel: eigene Darstellung gemäß Pedregosa (2011)

3.2.5 Gütemaße

Zu Bewertung der Modellgüte werden folgende statistische Gütemaße herangezogen:

Bestimmtheitsmaß
$$R^2 = 1 - \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n |y_i - \bar{y}|}$$
 Formel 3-25

Mean Absolute Error (MAE)
$$MAE = \frac{1}{n} \cdot \sum_{i=1}^n |y_i - \hat{y}_i|$$
 Formel 3-26

Mean Absolute Percentage Error (MAPE)
$$MAPE = \frac{1}{n} \cdot \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|}$$
 Formel 3-27

Mean Squared Error (MSE)
$$MSE = \frac{1}{n} \cdot \sum_{i=1}^n (y_i - \hat{y}_i)^2$$
 Formel 3-28

Root Mean Squared Error (RMSE)
$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$
 Formel 3-29

wobei:

y_i = wahrer Wert der i-ten Beobachtung

$\hat{y}_i$ = berechneter Wert der i-ten Beobachtung

$\bar{y}$ = Mittelwert der Beobachtungen

sind.

Als Benchmark für die Güte der entwickelten ANN dient des Weiteren eine multiple lineare Regressionsanalyse⁸.

⁸ Auf die Theorie einer multiplen linearen Regressionsanalyse wird in dieser Arbeit nicht eingegangen. Bei vertieftem Interesse sei auf James et al. (2013) ab Seite 59 verwiesen.

3.2.6 Vermeiden von Overfitting durch Early-Stopping

Um das Overfitting der ANN-Gewichte an den Trainingsdatensatz zu vermeiden, muss die Zahl der Trainingsepochen begrenzt werden. Die optimale Anzahl an Trainingsepochen kann jedoch nicht direkt bestimmt werden, sondern wird per Trial und Error ermittelt. In dieser Arbeit wurde hierfür die Callback-Funktion EarlyStopping von TensorFlow genutzt. Hierbei wird das ANN so lange trainiert, bis die Modellperformance für das Testdatenset über eine bestimmte Anzahl an Epochen (patience-Argument, 50 Epochen) keine Verbesserung mehr zeigt und danach automatisch gestoppt. Durch das Verwenden des patience-Arguments wird sichergestellt, dass das Training nicht sofort bei der kleinsten Verschlechterung der Modellperformance abgebrochen wird, um somit dem Optimierungsalgorithmus gegebenenfalls die Möglichkeit zu geben, aus lokalen Minima herauszufinden und das globale Optimum zu finden. Abb. 25 stellt das Trainings- und Testloss nach Trainingsepochen exemplarisch dar. Nach Auslaufen der patience-Epochen werden die Gewichte und Bias-Ausdrücke wieder auf das gefundene Optimum zurückgesetzt.




Abb. 25: Beispiel des Modell-Loss nach Trainingsepochen (ANN 1)

3.2.7 Feature Importance

ANN werden ob ihrer stark vernetzten Natur und der damit einhergehenden großen Zahl an Gewichten und Bias-Ausdrücken oft als Black Box-Modelle angesehen, bei denen es schwer zu erklären ist, warum eine gewisse Prognose getroffen wurde oder ein gewisser Wert berechnet wurde (vgl. Géron 2019: 181). Um mehr Verständnis zu erlangen, welche Inputfeatures die größten Auswirkungen auf den Output haben, kann mit gewissen Methoden die relative Wichtigkeit der einzelnen Features abgeschätzt werden. Im Zuge dieser Arbeit geschieht dies mittels der nachfolgend beschriebenen Methode der Permutation Importance sowie mittels SHAP-Werten.

3.2.7.1 Permutation Importance

Die Permutation Importance wurde erstmals von Breiman (2001) vorgeschlagen, um die Feature Importance eines RF zu berechnen, wobei der Ansatz auch bei ANN anwendbar ist. Die Grundidee der Permutation Importance ist es, die Veränderung der Modellgüte zu messen, wenn ein Inputfeature nicht verfügbar ist. Je größer der Fehler wird, desto wichtiger ist das nicht berücksichtigte Inputfeature für die Modellgüte.

Zur Bestimmung der Permutation Importance wird zuerst das ANN normal mittels des Trainingsdatensets trainiert und die Kostenfunktion berechnet. Nachfolgend wird jeweils ein Inputfeature bei der Prognose „weggelassen“, indem die Werte des Features untereinander mehrfach vermischt und vertauscht werden und für jede Vermischung die Kostenfunktion berechnet wird. Durch dieses Zufallsrauschen in den Daten wird die Abhängigkeit zwischen dem Feature und dem Output durchbrochen. Die Permutation Importance eines Features kann somit durch die Verschlechterung der Modellgüte gemessen werden. Bei stark korrelierten Eingangsfeatures ist es jedoch möglich, dass der Permutation Importance Score der betroffenen Features unterschätzt wird und sie dadurch in der Realität wichtiger sind, als es der Permutation Score ausdrückt, da das ANN auch auf das vermischte Feature Zugriff hat (vgl. scikit-learn 2021). In dieser Arbeit wird die Permutation Importance mit der Python-Bibliothek ELI5 (vgl. Korobov & Lopuhin 2017) berechnet. Der Permutation Importance Score gibt die Bedeutung der Inputfeatures immer für das Gesamtmodell an, wodurch er für die entwickelten ANN mit Multi-Output-Regression (1 und 2) nicht sinnvoll herangezogen werden kann.

3.2.7.2 Feature Importance mit SHAP-Werten

Die von Lundberg und Lee (2017) entwickelte Python-Bibliothek SHAP ist eine weitere Möglichkeit, die Feature-Importance in einem ANN abzuschätzen. Diese Methode beruht auf der Verwendung von Shapley-Werten, welche aus der kooperativen Spieltheorie stammen. Die Spieler sind im Falle von ML die Inputfeatures, welche verschiedene Koalitionen bilden, das Spiel ist die Reproduktion des Outputs des ML-Modells. Mithilfe der Shapley-Werte kann der Beitrag der einzelnen Features zur Modellprognose quantifiziert werden, während bei der Permutation-Importance die Veränderung der Modellgüte gemessen wird. Ein weiterer Unterschied zur Permutation-Importance ist, dass nicht nur das zu untersuchende Feature einmalig weggelassen wird, sondern zusätzlich auch alle anderen möglichen Kombinationen an Input-Features untersucht werden, um die Feature-Importance des untersuchten Features zu bestimmen. Die Shapley-Werte werden für einzelne Beobachtungen berechnet, können aber auch für eine globale Betrachtung der Feature-Importance durch Mittelwertbildung herangezogen werden. Für genauere Informationen über die Funktionsweise sei auf die Originalpublikation von Lundberg und Lee (2017) verwiesen.

3.2.8 Entwickelte ANN und verwendete Features

Für diese Arbeit wurden insgesamt sechs verschiedene ANN entwickelt, wobei jeweils drei dieselben Input- aber unterschiedliche Outputfeatures verwenden. Dadurch kann einerseits die Qualität eines ANN bezüglich der zugrundeliegenden Inputfeatures beurteilt werden, andererseits ist es auch möglich, Rückschlüsse zwischen den ANN mit denselben Input- aber unterschiedlichen Outputfeatures zu ziehen. Im Falle einer Multi-Output-Regression werden beide Outputfeatures durch die geteilte Netzwerkarchitektur als abhängige Variablen gesehen, deren Gewichte ausgenommen des Outputlayers ident sind. Bei einem ANN mit nur einem Outputfeature können die Netzwerkarchitektur und auch die Gewichte besser an die zugrundeliegenden Daten angepasst werden; es entsteht jedoch ein rechnerischer Mehraufwand durch die getrennten Netzwerke. Tabelle 8 gibt einen Überblick über die entwickelten ANN:

Tabelle 8: Überblick über die entwickelten ANN

Output	7 Inputfeatures	11 Inputfeatures
S_{vmax}, i	ANN 1 (siehe Kapitel 4.2)	ANN 2 (siehe Kapitel 4.5)
S_{vmax}	ANN 1a (siehe Kapitel 4.3)	ANN 2a (siehe Kapitel 4.6)
i	ANN 1b (siehe Kapitel 4.4)	ANN 2b (siehe Kapitel 4.7)

3.2.9 Ablauf der Entwicklung eines ANN

Im Folgenden werden die Schritte bei der Entwicklung eines ANN kurz beschrieben. Die ANN wurden in dieser Arbeit in der Programmiersprache Python der Version 3.8.5 (van Rossum 2021) unter Anwendung der deep-learning Bibliotheken von TensorFlow (Version 2.5 (Abadi et al. 2015)) und Keras (Version 2.5 (Chollet 2015)) entwickelt. Zusätzlich wurden für Datenvisualisierungszwecke und Evaluierungen der Modellgüte und der Feature Importance die Bibliotheken von scikit-learn (Version 0.24.2 (Pedregosa et al. 2011)), NumPy (Version 1.19.2 (Harris et al. 2020)), Pandas (Version 1.3.2 (McKinney 2010)), Matplotlib (Version 3.4.2 (Hunter 2007)), seaborn (Version 0.11.2 (Waskom 2021)), ELI5 (Version 0.11.0 (Korobov & Lopuhin 2017)) und shap (Version 0.39.0 (Lundberg & Lee 2017)) verwendet.

- 1) Die Daten aus der mit FLAC berechneten Setzungsdatenbank werden eingelesen
- 2) Je nach entwickeltem ANN werden unterschiedliche Features als X-Daten definiert; die Output-/y-Daten sind die maximale Setzung S_{vmax} und der Wendepunktabstand i in einem gemeinsamen Netzwerk oder jeweils einzeln in getrennten Netzwerken
- 3) In TensorFlow und allen anderen verwendeten Bibliotheken wird zur besseren Vergleichbarkeit der unterschiedlichen ANN der random seed 17 gewählt
- 4) Die Eingangsdaten werden gemäß Kapitel 3.2.2 zufällig in das Trainings- und Testdatenset eingeteilt
- 5) Die Daten werden gemäß Kapitel 3.2.3 standardisiert
- 6) Mithilfe der Funktion GridSearchCV wird nach der optimalen Netzwerkarchitektur gesucht
- 7) Gemäß den Ergebnissen des GridSearchCV wird eines der besten Modelle erstellt und trainiert
- 8) Mit dem trainierten Modell werden Voraussagen der maximalen Setzung und des Wendepunktabstandes für das Trainings-, das Test- und das Validierungsset berechnet
- 9) Die Modellgüte wird anhand der in Kapitel 3.2.5 aufgelisteten Gütemaße bestimmt und mit den Ergebnissen der multiplen linearen Regressionsanalyse verglichen
- 10) Der Einfluss der einzelnen Input-Features wird mittels Permutation Importance und Shap-Werten bestimmt

4 Ergebnisse

4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Für die Erstellung der Datenbank der Setzungsprognosen wurden insgesamt 140 verschiedene Kombinationen von Boden- (gemäß Kapitel 3.1.5) und Geometrieparametern (gemäß Kapitel 3.1.10) verwendet. Jeder Datensatz wurde sowohl als TVM-Tunnel als auch als NATM-Tunnel mit unterschiedlichen Vorentlastungsfaktoren berechnet. Dadurch ergibt sich eine Datenbank (siehe Tabelle 9) mit 280 Einträgen. Abb. 25 und Abb. 26 stellen die berechnete Korrelationsmatrix des Trainings- und Testdatensets sowie des FLAC-Validierungsdatensets dar.

Tabelle 9: Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
1	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	6.2	6.9	0.9	4.61	7.00
	1	NATM	0.21	2100	0.0	42.0	90.0	90.0	270.0	150.0	6.2	6.9	0.9	6.52	7.23
2	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	41.0	10.8	3.8	18.31	27.78
	4	NATM	0.30	1950	32.8	23.0	9.5	12.0	30.0	17.2	41.0	10.8	3.8	39.55	28.95
3	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	9.5	13.6	0.7	16.61	12.75
	2	NATM	0.25	1900	0.0	35.0	45.0	45.0	180.0	90.0	9.5	13.6	0.7	28.10	13.59
4	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	9.5	9.5	1.0	29.21	8.71
	3	NATM	0.20	2000	10.0	25.2	4.4	3.4	14.0	7.3	9.5	9.5	1.0	56.40	10.81
5	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	5.8	5.8	1.0	3.85	6.40
	2	NATM	0.18	1900	0.0	35.0	45.0	45.0	180.0	90.0	5.8	5.8	1.0	5.49	7.15
6	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	12.7	10.6	1.2	17.16	11.79
	4	NATM	0.23	1950	32.8	23.0	9.5	12.0	30.0	17.2	12.7	10.6	1.2	32.72	13.23
7	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	10.6	5.6	1.9	10.17	8.57
	3	NATM	0.22	2000	10.0	25.2	4.4	3.4	14.0	7.3	10.6	5.6	1.9	25.59	9.58
8	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	30.2	10.4	2.9	13.87	23.65
	2	NATM	0.28	1900	0.0	35.0	45.0	45.0	180.0	90.0	30.2	10.4	2.9	21.69	25.09
9	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	11.6	8.9	1.3	9.15	11.90

⁹ TVM=0, NATM=1

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
	2	NATM	0.30	1900	0.0	35.0	45.0	45.0	180.0	90.0	11.6	8.9	1.3	16.91	13.84
10	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	33.0	6.6	5.0	6.08	20.12
	1	NATM	0.30	2100	0.0	42.0	90.0	90.0	270.0	150.0	33.0	6.6	5.0	8.98	20.19
	1	NATM	0.50	2100	0.0	42.0	90.0	90.0	270.0	150.0	33.0	6.6	5.0	13.19	20.22
11	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	10.3	14.7	0.7	25.76	12.26
	4	NATM	0.20	1950	32.8	23.0	9.5	12.0	30.0	17.2	10.3	14.7	0.7	45.75	13.72
12	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	49.9	12.8	3.9	64.49	34.61
	3	NATM	0.20	2000	10.0	25.2	4.4	3.4	14.0	7.3	49.9	12.8	3.9	96.71	36.00
13	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	25.6	6.4	4.0	6.04	17.99
	2	NATM	0.40	1900	0.0	35.0	45.0	45.0	180.0	90.0	25.6	6.4	4.0	15.15	19.52
14	3	TVM	0.30	2000	10.0	25.2	4.4	3.4	14.0	7.3	2.5	5.0	0.5	10.71	3.39
	3	NATM	0.50	2000	10.0	25.2	4.4	3.4	14.0	7.3	2.5	5.0	0.5	47.29	3.6
15	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	21.0	10.5	2.0	18.09	16.88
	4	NATM	0.23	1950	32.8	23.0	9.5	12.0	30.0	17.2	21.0	10.5	2.0	32.49	17.65
16	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	38.1	12.7	3.0	19.16	27.25
	1	NATM	0.27	2100	0.0	42.0	90.0	90.0	270.0	150.0	38.1	12.7	3.0	27.38	28.22
17	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	28.4	14.2	2.0	21.63	24.52
	1	NATM	0.26	2100	0.0	42.0	90.0	90.0	270.0	150.0	28.4	14.2	2.0	31.32	25.60
18	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	13.5	7.5	1.8	10.18	11.37
	4	NATM	0.20	1950	32.8	23.0	9.5	12.0	30.0	17.2	13.5	7.5	1.8	17.25	12.30
19	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	40.0	12.9	3.1	20.07	30.63
	2	NATM	0.30	1900	0.0	35.0	45.0	45.0	180.0	90.0	40.0	12.9	3.1	32.47	32.25
20	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	10.6	11.8	0.9	44.47	10.77
	3	NATM	0.30	2000	10.0	25.2	4.4	3.4	14.0	7.3	10.6	11.8	0.9	132.97	15.37
21	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	62.9	13.1	4.8	21.42	43.25
	1	NATM	0.44	2100	0.0	42.0	90.0	90.0	270.0	150.0	62.9	13.1	4.8	38.58	46.20
22	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	15.1	6.3	2.4	4.86	12.77
	1	NATM	0.22	2100	0.0	42.0	90.0	90.0	270.0	150.0	15.1	6.3	2.4	6.57	13.21
23	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	60.0	12.5	4.8	60.90	37.69

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
	3	NATM	0.20	2000	10.0	25.2	4.4	3.4	14.0	7.3	60.0	12.5	4.8	90.41	39.00
24	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	65.6	14.9	4.4	81.31	44.86
	3	NATM	0.34	2000	10.0	25.2	4.4	3.4	14.0	7.3	65.6	14.9	4.4	192.30	49.15
25	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	36.5	7.6	4.8	25.76	24.17
	3	NATM	0.26	2000	10.0	25.2	4.4	3.4	14.0	7.3	36.5	7.6	4.8	51.33	24.31
26	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	23.3	5.3	4.4	11.75	15.09
	3	NATM	0.15	2000	10.0	25.2	4.4	3.4	14.0	7.3	23.3	5.3	4.4	18.15	15.93
27	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	37.0	10.0	3.7	42.41	25.00
	3	NATM	0.25	2000	10.0	25.2	4.4	3.4	14.0	7.3	37.0	10.0	3.7	79.17	27.69
28	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	46.0	11.8	3.9	56.43	32.12
	3	NATM	0.30	2000	10.0	25.2	4.4	3.4	14.0	7.3	46.0	11.8	3.9	121.78	35.18
29	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	34.4	8.0	4.3	11.44	22.72
	4	NATM	0.29	1950	32.8	23.0	9.5	12.0	30.0	17.2	34.4	8.0	4.3	24.10	23.90
30	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	18.1	13.9	1.3	18.97	16.54
	1	NATM	0.22	2100	0.0	42.0	90.0	90.0	270.0	150.0	18.1	13.9	1.3	26.32	18.12
31	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	18.1	6.7	2.7	8.68	13.19
	4	NATM	0.27	1950	32.8	23.0	9.5	12.0	30.0	17.2	18.1	6.7	2.7	18.53	14.02
32	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	41.9	9.1	4.6	35.82	27.86
	3	NATM	0.32	2000	10.0	25.2	4.4	3.4	14.0	7.3	41.9	9.1	4.6	84.77	29.17
33	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	6.8	11.3	0.6	10.81	9.02
	1	NATM	0.21	2100	0.0	42.0	90.0	90.0	270.0	150.0	6.8	11.3	0.6	15.50	9.72
34	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	14.2	7.1	2.0	5.90	12.25
	1	NATM	0.25	2100	0.0	42.0	90.0	90.0	270.0	150.0	14.2	7.1	2.0	8.53	12.08
35	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	28.8	11.5	2.5	15.45	23.76
	1	NATM	0.30	2100	0.0	42.0	90.0	90.0	270.0	150.0	28.8	11.5	2.5	23.70	24.66
36	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	41.3	11.8	3.5	21.11	28.40
	4	NATM	0.30	1950	32.8	23.0	9.5	12.0	30.0	17.2	41.3	11.8	3.5	45.77	29.79
37	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	21.6	12.0	1.8	54.04	17.12
	3	NATM	0.18	2000	10.0	25.2	4.4	3.4	14.0	7.3	21.6	12.0	1.8	82.30	19.91

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
38	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	47.6	13.6	3.5	20.07	33.02
	2	NATM	0.30	1900	0.0	35.0	45.0	45.0	180.0	90.0	47.6	13.6	3.5	35.48	36.51
39	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	35.8	14.3	2.5	76.32	27.18
	3	NATM	0.28	2000	10.0	25.2	4.4	3.4	14.0	7.3	35.8	14.3	2.5	160.21	31.79
40	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	29.7	10.6	2.8	18.43	21.25
	4	NATM	0.29	1950	32.8	23.0	9.5	12.0	30.0	17.2	29.7	10.6	2.8	39.80	23.10
41	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	11.9	5.4	2.2	3.95	9.99
	2	NATM	0.27	1900	0.0	35.0	45.0	45.0	180.0	90.0	11.9	5.4	2.2	6.60	10.00
42	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	11.0	11.0	1.0	34.33	11.55
	3	NATM	0.16	2000	10.0	25.2	4.4	3.4	14.0	7.3	11.0	11.0	1.0	53.05	12.53
43	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	30.0	6.0	5.0	6.92	18.62
	4	NATM	0.36	1950	32.8	23.0	9.5	12.0	30.0	17.2	30.0	6.0	5.0	19.13	19.31
44	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	23.5	8.4	2.8	12.83	17.46
	4	NATM	0.28	1950	32.8	23.0	9.5	12.0	30.0	17.2	23.5	8.4	2.8	27.16	18.11
45	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	27.0	7.1	3.8	9.55	17.52
	4	NATM	0.25	1950	32.8	23.0	9.5	12.0	30.0	17.2	27.0	7.1	3.8	17.95	18.52
46	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	51.4	10.7	4.8	17.16	32.49
	4	NATM	0.35	1950	32.8	23.0	9.5	12.0	30.0	17.2	51.4	10.7	4.8	43.16	33.42
47	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	29.7	9.0	3.3	28.60	20.91
	3	NATM	0.22	2000	10.0	25.2	4.4	3.4	14.0	7.3	29.7	9.0	3.3	50.15	21.73
48	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	44.7	14.9	3.0	25.74	35.33
	2	NATM	0.27	1900	0.0	35.0	45.0	45.0	180.0	90.0	44.7	14.9	3.0	38.82	36.76
49	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	68.6	14.3	4.8	25.68	45.20
	4	NATM	0.38	1950	32.8	23.0	9.5	12.0	30.0	17.2	68.6	14.3	4.8	70.68	45.95
50	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	14.7	10.5	1.4	12.39	13.88
	2	NATM	0.27	1900	0.0	35.0	45.0	45.0	180.0	90.0	14.7	10.5	1.4	20.51	14.89
51	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	24.2	6.2	3.9	5.13	17.19
	1	NATM	0.29	2100	0.0	42.0	90.0	90.0	270.0	150.0	24.2	6.2	3.9	7.56	17.49
52	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	25.0	5.1	4.9	4.02	17.25

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
	2	NATM	0.34	1900	0.0	35.0	45.0	45.0	180.0	90.0	25.0	5.1	4.9	7.32	17.82
53	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	18.6	14.3	1.3	68.31	16.96
	3	NATM	0.23	2000	10.0	25.2	4.4	3.4	14.0	7.3	18.6	14.3	1.3	130.83	19.09
54	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	37.3	8.1	4.6	28.85	25.21
	3	NATM	0.28	2000	10.0	25.2	4.4	3.4	14.0	7.3	37.3	8.1	4.6	61.12	26.18
55	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	31.8	12.7	2.5	18.49	26.21
	1	NATM	0.31	2100	0.0	42.0	90.0	90.0	270.0	150.0	31.8	12.7	2.5	28.75	28.05
56	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	6.9	13.8	0.5	11.78	6.96
	2	NATM	0.12	1900	0.0	35.0	45.0	45.0	180.0	90.0	6.9	13.8	0.5	14.64	7.12
57	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	36.0	7.5	4.8	7.71	25.12
	1	NATM	0.30	2100	0.0	42.0	90.0	90.0	270.0	150.0	36.0	7.5	4.8	11.40	26.54
58	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	41.0	11.4	3.6	16.13	29.59
	1	NATM	0.35	2100	0.0	42.0	90.0	90.0	270.0	150.0	41.0	11.4	3.6	26.07	31.15
59	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	12.9	7.6	1.7	7.32	12.44
	2	NATM	0.23	1900	0.0	35.0	45.0	45.0	180.0	90.0	12.9	7.6	1.7	11.00	13.35
60	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	47.4	14.8	3.2	25.31	36.30
	1	NATM	0.36	2100	0.0	42.0	90.0	90.0	270.0	150.0	47.4	14.8	3.2	41.46	38.78
61	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	31.6	10.2	3.1	12.86	24.33
	1	NATM	0.28	2100	0.0	42.0	90.0	90.0	270.0	150.0	31.6	10.2	3.1	18.68	25.04
62	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	21.8	8.4	2.6	9.43	17.25
	2	NATM	0.26	1900	0.0	35.0	45.0	45.0	180.0	90.0	21.8	8.4	2.6	14.43	18.00
63	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	75.0	15.0	5.0	24.71	50.65
	1	NATM	0.40	2100	0.0	42.0	90.0	90.0	270.0	150.0	75.0	15.0	5.0	41.28	52.20
64	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	14.1	12.8	1.1	15.68	14.53
	1	NATM	0.25	2100	0.0	42.0	90.0	90.0	270.0	150.0	14.1	12.8	1.1	23.46	16.71
65	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	33.9	12.1	2.8	18.01	27.36
	2	NATM	0.28	1900	0.0	35.0	45.0	45.0	180.0	90.0	33.9	12.1	2.8	28.03	29.18
66	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	73.0	14.6	5.0	25.81	52.10
	2	NATM	0.38	1900	0.0	35.0	45.0	45.0	180.0	90.0	73.0	14.6	5.0	46.07	53.54

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
67	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	12.8	7.1	1.8	18.14	10.51
	3	NATM	0.15	2000	10.0	25.2	4.4	3.4	14.0	7.3	12.8	7.1	1.8	29.07	10.96
68	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	22.4	10.2	2.2	12.88	19.42
	2	NATM	0.31	1900	0.0	35.0	45.0	45.0	180.0	90.0	22.4	10.2	2.2	22.33	20.31
69	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	9.0	6.4	1.4	4.43	9.07
	1	NATM	0.19	2100	0.0	42.0	90.0	90.0	270.0	150.0	9.0	6.4	1.4	5.85	9.65
70	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	27.4	14.4	1.9	22.65	24.14
	2	NATM	0.39	1900	0.0	35.0	45.0	45.0	180.0	90.0	27.4	14.4	1.9	47.07	27.48
71	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	16.6	12.8	1.3	56.36	15.23
	3	NATM	0.18	2000	10.0	25.2	4.4	3.4	14.0	7.3	16.6	12.8	1.3	88.28	16.49
72	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	35.0	7.0	5.0	6.86	22.62
	4	NATM	0.31	1950	32.8	23.0	9.5	12.0	30.0	17.2	35.0	7.0	5.0	15.50	23.47
73	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	16.0	14.5	1.1	27.53	16.12
	4	NATM	0.17	1950	32.8	23.0	9.5	12.0	30.0	17.2	16.0	14.5	1.1	41.20	17.05
74	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	12.8	5.1	2.5	5.00	10.19
	4	NATM	0.15	1950	32.8	23.0	9.5	12.0	30.0	17.2	12.8	5.1	2.5	7.48	10.25
75	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	33.7	9.1	3.7	14.23	22.80
	4	NATM	0.32	1950	32.8	23.0	9.5	12.0	30.0	17.2	33.7	9.1	3.7	33.56	24.34
76	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	10.8	9.0	1.2	7.10	11.56
	1	NATM	0.19	2100	0.0	42.0	90.0	90.0	270.0	150.0	10.8	9.0	1.2	9.30	12.10
77	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	16.1	13.4	1.2	18.30	16.65
	2	NATM	0.27	1900	0.0	35.0	45.0	45.0	180.0	90.0	16.1	13.4	1.2	30.50	18.21
78	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	55.9	13.3	4.2	24.11	37.75
	4	NATM	0.40	1950	32.8	23.0	9.5	12.0	30.0	17.2	55.9	13.3	4.2	72.95	37.79
79	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	49.4	10.5	4.7	45.80	33.10
	3	NATM	0.30	2000	10.0	25.2	4.4	3.4	14.0	7.3	49.4	10.5	4.7	97.90	33.17
80	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	35.3	7.5	4.7	8.25	26.24
	2	NATM	0.36	1900	0.0	35.0	45.0	45.0	180.0	90.0	35.3	7.5	4.7	15.19	27.24
81	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	17.3	7.5	2.3	6.85	14.45

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
	1	NATM	0.24	2100	0.0	42.0	90.0	90.0	270.0	150.0	17.3	7.5	2.3	9.60	15.54
82	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	34.5	11.9	2.9	56.98	24.76
	3	NATM	0.22	2000	10.0	25.2	4.4	3.4	14.0	7.3	34.5	11.9	2.9	95.52	27.16
83	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	15.4	9.6	1.6	15.30	13.22
	4	NATM	0.20	1950	32.8	23.0	9.5	12.0	30.0	17.2	15.4	9.6	1.6	25.30	14.17
84	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	5.1	8.5	0.6	9.63	6.27
	4	NATM	0.15	1950	32.8	23.0	9.5	12.0	30.0	17.2	5.1	8.5	0.6	14.35	6.99
85	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	19.1	6.6	2.9	17.94	14.09
	3	NATM	0.19	2000	10.0	25.2	4.4	3.4	14.0	7.3	19.1	6.6	2.9	31.89	14.42
86	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	45.8	10.4	4.4	14.42	35.60
	2	NATM	0.40	1900	0.0	35.0	45.0	45.0	180.0	90.0	45.8	10.4	4.4	28.09	36.38
87	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	71.5	14.9	4.8	80.60	47.53
	3	NATM	0.32	2000	10.0	25.2	4.4	3.4	14.0	7.3	71.5	14.9	4.8	175.24	49.93
88	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	16.0	9.4	1.7	10.60	14.66
	2	NATM	0.24	1900	0.0	35.0	45.0	45.0	180.0	90.0	16.0	9.4	1.7	16.01	15.90
89	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	26.7	12.7	2.1	17.88	23.24
	1	NATM	0.25	2100	0.0	42.0	90.0	90.0	270.0	150.0	26.7	12.7	2.1	25.26	24.85
90	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	33.0	7.5	4.4	10.32	21.81
	4	NATM	0.29	1950	32.8	23.0	9.5	12.0	30.0	17.2	33.0	7.5	4.4	21.89	22.85
91	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	9.5	7.9	1.2	7.21	10.26
	2	NATM	0.14	1900	0.0	35.0	45.0	45.0	180.0	90.0	9.5	7.9	1.2	8.97	10.76
92	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	6.4	12.7	0.5	12.60	5.00
	4	NATM	0.17	1950	32.8	23.0	9.5	12.0	30.0	17.2	6.4	12.7	0.5	21.59	5.50
93	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	21.7	5.3	4.1	4.24	16.00
	2	NATM	0.34	1900	0.0	35.0	45.0	45.0	180.0	90.0	21.7	5.3	4.1	7.79	17.20
94	2	TVM	0.10	1900	0.0	35.0	45.0	45.0	180.0	90.0	28.0	10.0	2.8	12.89	23.73
	2	NATM	0.35	1900	0.0	35.0	45.0	45.0	180.0	90.0	28.0	10.0	2.8	23.86	24.68
95	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	25.3	11.0	2.3	17.05	19.73
	4	NATM	0.34	1950	32.8	23.0	9.5	12.0	30.0	17.2	25.3	11.0	2.3	44.87	21.23

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
96	3	TVM	0.10	2000	10.0	25.2	4.4	3.4	14.0	7.3	30.0	7.7	3.9	26.27	20.92
	3	NATM	0.20	2000	10.0	25.2	4.4	3.4	14.0	7.3	30.0	7.7	3.9	43.12	20.68
97	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	47.5	9.9	4.8	12.93	34.32
	1	NATM	0.30	2100	0.0	42.0	90.0	90.0	270.0	150.0	47.5	9.9	4.8	18.87	35.34
98	4	TVM	0.10	1950	32.8	23.0	9.5	12.0	30.0	17.2	17.4	10.9	1.6	18.73	15.24
	4	NATM	0.28	1950	32.8	23.0	9.5	12.0	30.0	17.2	17.4	10.9	1.6	42.09	16.50
99	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	9.5	7.9	1.2	6.50	9.87
	1	NATM	0.17	2100	0.0	42.0	90.0	90.0	270.0	150.0	9.5	7.9	1.2	8.29	10.43
100	1	TVM	0.10	2100	0.0	42.0	90.0	90.0	270.0	150.0	27.9	13.3	2.1	19.40	24.35
	1	NATM	0.27	2100	0.0	42.0	90.0	90.0	270.0	150.0	27.9	13.3	2.1	28.54	25.55
101	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	22.0	6.1	3.6	3.45	15.38
	5	NATM	0.18	2019	10.4	12.5	12.0	12.0	36.2	20.1	22.0	6.1	3.6	6.88	15.96
102	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	25.3	11.0	2.3	7.13	22.81
	5	NATM	0.28	2019	10.4	12.5	12.0	12.0	36.2	20.1	25.3	11.0	2.3	29.79	21.93
103	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	33.0	11.0	3.0	7.07	25.20
	5	NATM	0.30	2019	10.4	12.5	12.0	12.0	36.2	20.1	33.0	11.0	3.0	30.77	25.91
104	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	13.8	9.2	1.5	6.05	13.39
	5	NATM	0.16	2019	10.4	12.5	12.0	12.0	36.2	20.1	13.8	9.2	1.5	11.77	14.25
105	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	32.7	9.9	3.3	6.92	24.47
	5	NATM	0.30	2019	10.4	12.5	12.0	12.0	36.2	20.1	32.7	9.9	3.3	30.47	25.20
106	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	29.4	12.8	2.3	10.02	23.92
	5	NATM	0.30	2019	10.4	12.5	12.0	12.0	36.2	20.1	29.4	12.8	2.3	50.12	25.11
107	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	12.7	6.7	1.9	3.93	11.21
	5	NATM	0.15	2019	10.4	12.5	12.0	12.0	36.2	20.1	12.7	6.7	1.9	6.81	11.92
108	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	71.5	14.6	4.9	11.29	49.06
	5	NATM	0.40	2019	10.4	12.5	12.0	12.0	36.2	20.1	71.5	14.6	4.9	76.12	50.20
109	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	49.5	10.1	4.9	6.67	34.59
	5	NATM	0.32	2019	10.4	12.5	12.0	12.0	36.2	20.1	49.5	10.1	4.9	29.18	35.30
110	5	TVM	0.10	2019	10.4	12.5	12.0	12.0	36.2	20.1	24.0	10.0	2.4	7.11	18.58

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
	5	NATM	0.25	2019	10.4	12.5	12.0	12.0	36.2	20.1	24.0	10.0	2.4	24.66	19.99
111	6	TVM	0.10	2200	30.0	26.0	37.6	37.6	150.4	75.2	34.5	15.0	2.3	17.91	28.20
	6	NATM	0.36	2200	30.0	26.0	37.6	37.6	150.4	75.2	34.5	15.0	2.3	42.21	29.68
112	6	TVM	0.10	2200	30.0	26.0	37.6	37.6	150.4	75.2	19.0	11.2	1.7	9.70	16.67
	6	NATM	0.23	2200	30.0	26.0	37.6	37.6	150.4	75.2	19.0	11.2	1.7	16.41	18.05
113	6	TVM	0.10	2200	30.0	26.0	37.6	37.6	150.4	75.2	36.0	12.0	3.0	13.79	26.62
	6	NATM	0.33	2200	30.0	26.0	37.6	37.6	150.4	75.2	36.0	12.0	3.0	29.13	28.25
114	6	TVM	0.10	2200	30.0	26.0	37.6	37.6	150.4	75.2	5.1	6.4	0.8	2.10	5.67
	6	NATM	0.18	2200	30.0	26.0	37.6	37.6	150.4	75.2	5.1	6.4	0.8	3.26	6.41
115	6	TVM	0.10	2200	30.0	26.0	37.6	37.6	150.4	75.2	16.4	7.8	2.1	5.08	13.95
	6	NATM	0.21	2200	30.0	26.0	37.6	37.6	150.4	75.2	16.4	7.8	2.1	7.94	14.86
116	7	TVM	0.10	2200	33.6	17.5	3.4	3.6	12.0	6.3	43.5	13.6	3.2	72.62	32.84
	7	NATM	0.30	2200	33.6	17.5	3.4	3.6	12.0	6.3	43.5	13.6	3.2	221.73	33.50
117	7	TVM	0.10	2200	33.6	17.5	3.4	3.6	12.0	6.3	21.3	5.2	4.1	12.02	14.57
	7	NATM	0.19	2200	33.6	17.5	3.4	3.6	12.0	6.3	21.3	5.2	4.1	24.28	14.90
118	7	TVM	0.10	2200	33.6	17.5	3.4	3.6	12.0	6.3	36.0	9.0	4.0	30.04	24.93
	7	NATM	0.30	2200	33.6	17.5	3.4	3.6	12.0	6.3	36.0	9.0	4.0	91.79	25.97
119	7	TVM	0.10	2200	33.6	17.5	3.4	3.6	12.0	6.3	16.5	10.3	1.6	35.44	14.35
	7	NATM	0.15	2200	33.6	17.5	3.4	3.6	12.0	6.3	16.5	10.3	1.6	55.42	15.84
120	7	TVM	0.10	2200	33.6	17.5	3.4	3.6	12.0	6.3	12.6	6.0	2.1	12.25	9.97
	7	NATM	0.15	2200	33.6	17.5	3.4	3.6	12.0	6.3	12.6	6.0	2.1	21.85	10.68
121	8	TVM	0.10	1800	5.1	20.8	2.1	1.6	6.2	3.3	43.2	10.8	4.0	52.09	29.80
	8	NATM	0.30	1800	5.1	20.8	2.1	1.6	6.2	3.3	43.2	10.8	4.0	136.54	32.79
122	8	TVM	0.10	1800	5.1	20.8	2.1	1.6	6.2	3.3	19.4	6.7	2.9	26.31	14.35
	8	NATM	0.17	1800	5.1	20.8	2.1	1.6	6.2	3.3	19.4	6.7	2.9	45.16	14.79
123	8	TVM	0.10	1800	5.1	20.8	2.1	1.6	6.2	3.3	11.3	12.5	0.9	71.42	12.77
	8	NATM	0.13	1800	5.1	20.8	2.1	1.6	6.2	3.3	11.3	12.5	0.9	95.73	13.83
124	8	TVM	0.10	1800	5.1	20.8	2.1	1.6	6.2	3.3	8.9	14.8	0.6	90.65	12.18
	8	NATM	0.13	1800	5.1	20.8	2.1	1.6	6.2	3.3	8.9	14.8	0.6	118.29	13.28

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
125	8	TVM	0.10	1800	5.1	20.8	2.1	1.6	6.2	3.3	57.8	14.1	4.1	73.00	41.24
	8	NATM	0.35	1800	5.1	20.8	2.1	1.6	6.2	3.3	57.8	14.1	4.1	229.28	43.10
126	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	30.8	7.0	4.4	3.69	19.36
	9	NATM	0.31	1900	40.0	36.0	94.2	94.2	282.7	157.1	30.8	7.0	4.4	5.42	19.68
127	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	73.0	14.9	4.9	12.15	45.55
	9	NATM	0.70	1900	40.0	36.0	94.2	94.2	282.7	157.1	73.0	14.9	4.9	39.29	45.37
128	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	26.5	12.6	2.1	12.25	21.16
	9	NATM	0.31	1900	40.0	36.0	94.2	94.2	282.7	157.1	26.5	12.6	2.1	18.87	22.96
129	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	42.6	9.9	4.3	9.17	27.50
	9	NATM	0.44	1900	40.0	36.0	94.2	94.2	282.7	157.1	42.6	9.9	4.3	17.01	28.01
130	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	5.6	11.1	0.5	3.66	4.50
	9	NATM	0.38	1900	40.0	36.0	94.2	94.2	282.7	157.1	5.6	11.1	0.5	8.24	6.36
131	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	49.9	12.8	3.9	14.40	32.53
	9	NATM	0.50	1900	40.0	36.0	94.2	94.2	282.7	157.1	49.9	12.8	3.9	30.29	33.39
132	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	13.0	8.1	1.6	3.41	11.24
	9	NATM	0.41	1900	40.0	36.0	94.2	94.2	282.7	157.1	13.0	8.1	1.6	6.55	12.44
133	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	13.3	5.3	2.5	1.59	10.20
	9	NATM	0.26	1900	40.0	36.0	94.2	94.2	282.7	157.1	13.3	5.3	2.5	2.29	10.69
134	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	30.6	8.5	3.6	4.41	19.84
	9	NATM	0.40	1900	40.0	36.0	94.2	94.2	282.7	157.1	30.6	8.5	3.6	7.98	21.11
135	9	TVM	0.10	1900	40.0	36.0	94.2	94.2	282.7	157.1	30.6	13.3	2.3	9.33	22.57
	9	NATM	0.40	1900	40.0	36.0	94.2	94.2	282.7	157.1	30.6	13.3	2.3	17.66	24.35
136	10	TVM	0.10	2000	50.0	39.0	75.0	60.0	150.0	95.0	52.4	11.9	4.4	11.69	30.96
	10	NATM	0.43	2000	50.0	39.0	75.0	60.0	150.0	95.0	52.4	11.9	4.4	21.29	31.97
137	10	TVM	0.10	2000	50.0	39.0	75.0	60.0	150.0	95.0	23.0	7.2	3.2	4.95	14.63
	10	NATM	0.28	2000	50.0	39.0	75.0	60.0	150.0	95.0	23.0	7.2	3.2	6.96	15.24
138	10	TVM	0.10	2000	50.0	39.0	75.0	60.0	150.0	95.0	7.8	13.0	0.6	10.02	9.24
	10	NATM	0.20	2000	50.0	39.0	75.0	60.0	150.0	95.0	7.8	13.0	0.6	13.25	9.86
139	10	TVM	0.10	2000	50.0	39.0	75.0	60.0	150.0	95.0	25.4	5.9	4.3	3.43	14.48

Ergebnisse: 4.1 Datenbank der Setzungsprognosen aus den FDM-Berechnungen

Index	Bodenart	Vortriebsart ⁹	Lambda	ρ	c	φ	E_{50}^{ref}	E_{oed}^{ref}	E_{ur}^{ref}	E	C	D	C/D	S_{vmax}	i
			[-]	[kg/m ³]	[kPa]	[°]	[MPa]	[MPa]	[MPa]	[MPa]	[m]	[m]	[-]	[mm]	[m]
	10	NATM	0.28	2000	50.0	39.0	75.0	60.0	150.0	95.0	25.4	5.9	4.3	4.84	15.85
140	10	TVM	0.10	2000	50.0	39.0	75.0	60.0	150.0	95.0	54.2	13.9	3.9	15.25	32.95
	10	NATM	0.47	2000	50.0	39.0	75.0	60.0	150.0	95.0	54.2	13.9	3.9	30.26	34.42




Abb. 26: Korrelationsmatrix des Trainings- und Testdatensets




Abb. 27: Korrelationsmatrix des FLAC-Validierungsdatensets

4.2 Artificial Neural Network 1

4.2.1 Input- und Outputfeatures

Das erste entwickelte ANN (ANN 1) weist insgesamt sieben Inputfeatures auf, welche die Bodenparameter, die Vortriebsart und die geometrischen Verhältnisse berücksichtigen. Der Output des ANN 1 ist die maximale Setzung und der Wendepunktabstand i . Tabelle 10 zeigt die verwendeten Input- und Outputfeatures sowie deren Spannweite, Mittelwert und Standardabweichung:

Tabelle 10: statistische Beschreibung der Input und Outputfeatures des ANN 1

Parameter		Typ	Min	Max	Mittel	σ	Einheit
Vortriebsart		Input	0	1	0.50	0.50	-
Kohäsion	c	Input	0	50	12.75	14.76	kPa
Reibungswinkel	φ	Input	12.5	42	29.52	8.96	°
Elastizitätsmodul	E	Input	3.28	150	61.78	55.38	MPa
Überdeckung	C	Input	2.5	75	28.23	16.84	m
Durchmesser	D	Input	5	15	10.23	2.95	m
Überdeckungsverhältnis	C/D	Input	0.5	5	2.79	1.40	-
maximale Setzung	S_{vmax}	Output	2.1	229.3	30.42	32.89	mm
Wendepunktabstand	i	Output	3.39	53.54	21.80	10.71	m

4.2.2 Ergebnisse des GridsearchCV

Die Suche nach der optimalen Netzwerkarchitektur wurde mittels des in Kapitel 3.2.4 erwähnten GridSearchCV-Algorithmus durchgeführt. Tabelle 11 gibt Auskunft über die 30 besten Hyperparameterkombinationen. Der angegebene MSE bezieht sich auf das Gesamtmodell, wodurch sowohl die Performance hinsichtlich der maximalen Setzung als auch des Wendepunktabstandes berücksichtigt wird. Die Standardabweichung des MSE wurde über alle ShuffleSplits während des GridSearchCV berechnet.

Tabelle 11: Ergebnisse des GridSearchCV für das ANN 1

Rang	Versteckte Layer	Neuronen pro Layer	Aktivierungsfunktion	Initializer	MSE	σ_{MSE}
1	4	14	GeLU	GlorotUniform	79.1	51.7
2	5	100	ReLU	GlorotUniform	79.2	45.7
3	4	75	GeLU	GlorotNormal	82.9	52.4
4	3	14	ReLU	HeUniform	84.2	45.0
5	5	50	GeLU	GlorotNormal	84.2	55.5
6	5	25	GeLU	GlorotNormal	84.3	50.2
7	4	25	ReLU	GlorotNormal	84.3	58.8
8	3	100	GeLU	GlorotNormal	84.4	54.3
9	4	100	GeLU	GlorotUniform	84.7	48.8
10	4	25	GeLU	GlorotNormal	84.8	48.1
11	3	75	GeLU	GlorotUniform	85.5	49.3
12	3	75	GeLU	GlorotNormal	85.7	52.9
13	5	50	GeLU	GlorotUniform	86.0	51.5
14	5	21	ReLU	HeNormal	86.5	54.6
15	4	14	ReLU	GlorotNormal	86.8	63.7
16	4	21	GeLU	GlorotNormal	87.1	55.8
17	4	50	GeLU	GlorotUniform	87.1	47.2
18	4	50	ReLU	GlorotNormal	88.5	61.8
19	4	40	ReLU	GlorotNormal	89.0	56.5
20	4	50	GeLU	GlorotNormal	89.4	51.4
21	4	14	ReLU	GlorotUniform	89.7	63.9
22	3	37	GeLU	GlorotNormal	89.9	57.1
23	4	50	ReLU	GlorotUniform	90.8	63.5
24	2	50	GeLU	GlorotNormal	91.2	58.8
25	3	50	GeLU	GlorotNormal	91.6	61.1
26	4	21	ReLU	HeNormal	92.3	56.1
27	4	18	GeLU	GlorotNormal	93.1	57.9
28	4	18	ReLU	GlorotNormal	93.6	61.0
29	4	10	GeLU	GlorotNormal	93.8	56.8
30	4	14	GeLU	HeNormal	94.3	56.4

4.2.3 Gewählte Netzwerkarchitektur ANN 1

Gemäß den Ergebnissen des GridSearchCV wurde die in Tabelle 12 aufgelistete Kombination ausgewählt. Es ist jedoch anzumerken, dass auch mit anderen Parameterkombination eine sehr ähnliche Modellgüte erreicht wird.

Tabelle 12: Hyperparameter des ANN 1

Anzahl der versteckten Layer:	4
Anzahl der Neuronen pro Layer:	14
Aktivierungsfunktion:	GeLU (ReLU beim Outputlayer)
Weight-Initialization:	GlorotUniform

4.2.4 Modellgüte des ANN 1: maximale Setzung

Tabelle 13 und Abb. 28 geben einen Überblick über die Modellgüte des ANN 1 bezüglich der maximalen Setzung aufgeschlüsselt nach der Performance des Trainings-, Test- und der Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 13 präsentiert:

Tabelle 13: Modellgüte des ANN 1 bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse

S_{vmax}	ANN 1			
	Training	Test	Validierung FLAC	Validierung Literatur
R^2 [-]	0.957	0.939	0.362	0.166
MAE [mm]	3.6	4.5	21.3	16.3
MAPE [-]	0.137	0.207	0.978	0.616
MSE [mm ²]	48.5	56.4	1111.0	466.5
RMSE [mm]	7.0	7.5	33.3	21.6

S_{vmax}	lineare Regression 1			
	Training	Test	Validierung FLAC	Validierung Literatur
R^2 [-]	0.671	0.576	0.541	-0.510
MAE [mm]	12.6	14.1	18.6	24.1
MAPE [-]	0.844	1.037	1.601	1.361
MSE [mm ²]	373.1	393.7	798.0	844.7
RMSE [mm]	19.3	19.8	28.2	29.1




Abb. 28: Modellgüte des ANN 1 bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur

4.2.5 Feature Importance des ANN 1: maximale Setzung

Abb. 29 stellt die SHAP-Werte des ANN 1 bezüglich der maximalen Setzung dar.




Abb. 29: Feature Importance (SHAP-Werte) des ANN 1 bezüglich der maximalen Setzung

4.2.6 Modellgüte des ANN 1: Wendepunktabstand

Tabelle 14 und Abb. 30 geben einen Überblick über die Modellgüte des ANN 1 bezüglich des Wendepunktabstands aufgeschlüsselt nach der Performance des Trainings-, Test- und der Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 14 präsentiert:

Tabelle 14: Modellgüte des ANN 1 bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse

i	ANN 1			
	Training	Test	Validierung FLAC	Validierung Literatur
R ² [-]	0.967	0.937	0.840	-54.615
MAE [m]	1.37	2.00	3.53	12.45
MAPE [-]	0.087	0.152	0.202	1.634
MSE [m ²]	3.86	6.70	16.96	259.31
RMSE [m]	1.97	2.59	4.12	16.10

i	lineare Regression 1			
	Training	Test	Validierung FLAC	Validierung Literatur
R ² [-]	0.989	0.981	0.974	-66.642
MAE [m]	0.81	0.99	1.25	14.89
MAPE [-]	0.046	0.065	0.086	2.001
MSE [m ²]	1.32	1.98	2.77	315.39
RMSE [m]	1.15	1.41	1.67	17.76




Abb. 30: Modellgüte des ANN 1 bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur

4.2.7 Feature Importance des ANN 1: Wendepunktabstand

Abb. 31 stellt die SHAP-Werte des ANN 1 bezüglich des Wendepunktabstands dar.




Abb. 31: Feature Importance (SHAP-Werte) des ANN 1 bezüglich des Wendepunktabstandes

4.3 Artificial Neural Network 1a

Bei dieser Netzwerkarchitektur wurden dieselben Inputfeatures wie beim ANN 1 verwendet (siehe Kapitel 4.2.1), der Output des ANN 1a ist jedoch nur die maximale Setzung.

4.3.1 Ergebnisse des GridsearchCV

Die Suche nach der optimalen Netzwerkarchitektur wurde mittels des in Kapitel 3.2.4 erwähnten GridSearchCV-Algorithmus durchgeführt. Tabelle 15 gibt Auskunft über die 30 besten Hyperparameterkombinationen. Der angegebene MSE bezieht sich auf das Gesamtmodell, wodurch hier die Performance hinsichtlich der maximalen Setzung berücksichtigt wird. Die Standardabweichung des MSE wurde über alle ShuffleSplits während des GridSearchCV berechnet.

Tabelle 15: Ergebnisse des GridSearchCV für das ANN 1a

Rang	Versteckte Layer	Neuronen pro Layer	Aktivierungsfunktion	Initializer	MSE	σ_{MSE}
1	5	25	GeLu	GlorotNormal	147.8	97.3
2	5	25	ReLu	GlorotNormal	150.5	98.0
3	5	37	GeLu	GlorotUniform	150.6	91.7
4	5	21	ReLu	HeNormal	151.6	95.9
5	5	100	ReLu	GlorotUniform	152.2	101.6
6	4	75	GeLu	GlorotUniform	152.6	89.4
7	2	500	GeLu	GlorotUniform	152.6	83.7
8	2	75	GeLu	GlorotNormal	154.5	92.1
9	3	14	GeLu	GlorotNormal	154.9	94.9
10	4	25	GeLu	GlorotNormal	154.9	90.5
11	4	25	ReLu	GlorotNormal	155.0	95.2
12	4	50	GeLu	GlorotUniform	155.2	94.5
13	2	100	GeLu	GlorotUniform	155.7	83.4
14	4	100	GeLu	GlorotNormal	155.8	97.7
15	3	25	ReLu	GlorotNormal	156.1	94.8
16	3	18	GeLu	GlorotNormal	156.3	94.6
17	4	100	ReLu	GlorotUniform	157.3	105.2
18	5	100	GeLu	GlorotNormal	157.9	95.3
19	4	18	GeLu	GlorotNormal	158.1	85.0
20	3	37	ReLu	GlorotNormal	158.2	92.9
21	5	500	ReLu	GlorotUniform	158.4	89.4
22	5	21	ReLu	GlorotNormal	158.8	96.4
23	3	100	GeLu	GlorotNormal	159.7	94.8
24	4	500	ReLu	GlorotNormal	159.7	93.8
25	5	100	GeLu	HeUniform	160.0	92.5
26	4	37	GeLu	GlorotNormal	160.0	93.3
27	5	21	GeLu	HeNormal	160.5	94.4
28	3	37	GeLu	GlorotUniform	160.6	94.0
29	3	500	ReLu	GlorotNormal	160.8	96.3
30	4	100	GeLu	GlorotUniform	160.9	97.1

4.3.2 Gewählte Netzwerkarchitektur ANN 1a

Gemäß den Ergebnissen des GridSearchCV wurde die in Tabelle 16 aufgelistete Kombination ausgewählt. Es ist jedoch anzumerken, dass auch mit anderen Parameterkombination eine sehr ähnliche Modellgüte erreicht wird.

Tabelle 16: Hyperparameter des ANN 1a

Anzahl der versteckten Layer:	5
Anzahl der Neuronen pro Layer:	21
Aktivierungsfunktion:	ReLU (keine Aktivierungsfunktion beim Outputlayer)
Weight-Initialization:	HeNormal

4.3.3 Modellgüte des ANN 1a: maximale Setzung

Tabelle 17 und Abb. 32 geben einen Überblick über die Modellgüte des ANN 1a bezüglich der maximalen Setzung aufgeschlüsselt nach der Performance des Trainings-, Test- und der Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 17 präsentiert:

Tabelle 17: Modellgüte des ANN 1a bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse

S_{vmax}	ANN 1a			
	Training	Test	Validierung FLAC	Validierung Literatur
R^2 [-]	0.946	0.921	0.334	-0.424
MAE [mm]	3.3	5.4	21.3	21.6
MAPE [-]	0.124	0.288	0.982	0.676
MSE [mm ²]	61.7	73.3	1158.9	796.7
RMSE [mm]	7.9	8.6	34.0	28.2

S_{vmax}	lineare Regression 1			
	Training	Test	Validierung FLAC	Validierung Literatur
R^2 [-]	0.671	0.576	0.541	-0.510
MAE [mm]	12.6	14.1	18.6	24.1
MAPE [-]	0.844	1.037	1.601	1.361
MSE [mm ²]	373.1	393.7	798.0	844.7
RMSE [mm]	19.3	19.8	28.2	29.1




Abb. 32: Modellgüte des ANN 1a bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur

4.3.4 Feature Importance des ANN 1: maximale Setzung

Abb. 33 stellt die SHAP-Werte, Abb. 34 den Permutation Importance Score des ANN 1a bezüglich der maximalen Setzung dar.




Abb. 33: Feature Importance (SHAP-Werte) des ANN 1a bezüglich der maximalen Setzung




Abb. 34: Feature Importance (Permutation Importance) des ANN 1a bezüglich der maximalen Setzung

4.4 Artificial Neural Network 1b

Bei dieser Netzwerkarchitektur wurden dieselben Inputfeatures wie beim ANN 1 verwendet (siehe Kapitel 4.2.1), der Output des ANN 1b ist jedoch nur der Wendepunktabstand.

4.4.1 Ergebnisse des GridsearchCV

Die Suche nach der optimalen Netzwerkarchitektur wurde mittels des in Kapitel 3.2.4 erwähnten GridSearchCV-Algorithmus durchgeführt. Tabelle 18 gibt Auskunft über die 30 besten Hyperparameterkombinationen. Der angegebene MSE bezieht sich auf das Gesamtmodell, wodurch hier die Performance hinsichtlich des Wendepunktabstands berücksichtigt wird. Die Standardabweichung des MSE wurde über alle ShuffleSplits während des GridSearchCV berechnet.

Tabelle 18: Ergebnisse des GridSearchCV für das ANN 1b

Rang	Versteckte Layer	Neuronen pro Layer	Aktivierungsfunktion	Initializer	MSE	σ_{MSE}
1	1	1000	GeLu	GlorotNormal	1.60	0.50
2	1	1000	GeLu	GlorotUniform	1.61	0.49
3	1	500	GeLu	GlorotNormal	1.62	0.49
4	1	500	GeLu	GlorotUniform	1.63	0.49
5	1	1000	GeLu	HeNormal	1.73	0.36
6	1	10	GeLu	GlorotUniform	1.73	0.48
7	1	1000	GeLu	HeUniform	1.74	0.37
8	1	100	GeLu	GlorotNormal	1.77	0.41
9	1	500	GeLu	HeNormal	1.77	0.46
10	3	500	GeLu	GlorotNormal	1.80	0.25
11	2	500	GeLu	GlorotUniform	1.80	0.48
12	1	500	ReLu	GlorotNormal	1.80	0.50
13	3	500	GeLu	GlorotUniform	1.81	0.33
14	1	1000	ReLu	GlorotNormal	1.82	0.44
15	1	500	ReLu	GlorotUniform	1.83	0.43
16	1	50	GeLu	GlorotUniform	1.84	0.44
17	1	25	GeLu	GlorotNormal	1.85	0.45
18	1	1000	ReLu	HeUniform	1.86	0.44
19	1	1000	ReLu	HeNormal	1.86	0.43
20	1	75	GeLu	GlorotUniform	1.86	0.45
21	1	1000	ReLu	GlorotUniform	1.86	0.51
22	1	100	GeLu	GlorotUniform	1.86	0.43
23	2	500	GeLu	GlorotNormal	1.87	0.50
24	1	500	ReLu	HeUniform	1.88	0.45
25	1	100	ReLu	GlorotNormal	1.88	0.44
26	2	1000	GeLu	GlorotUniform	1.88	0.43
27	1	500	ReLu	HeNormal	1.91	0.42
28	4	7	GeLu	GlorotNormal	1.91	0.24
29	1	500	GeLu	HeUniform	1.92	0.39
30	1	75	ReLu	GlorotNormal	1.92	0.52

4.4.2 Gewählte Netzwerkarchitektur ANN 1b

Gemäß den Ergebnissen des GridSearchCV wurde die in Tabelle 19 aufgelistete Kombination ausgewählt. Es ist jedoch anzumerken, dass auch mit anderen Parameterkombination eine sehr ähnliche Modellgüte erreicht wird.

Tabelle 19: Hyperparameter des ANN 1b

Anzahl der versteckten Layer:	1
Anzahl der Neuronen pro Layer:	1000
Aktivierungsfunktion:	GeLU (keine Aktivierungsfunktion beim Outputlayer)
Weight-Initialization:	GlorotNormal

4.4.3 Modellgüte des ANN 1b: Wendepunktabstand

Tabelle 20 und Abb. 35 geben einen Überblick über die Modellgüte des ANN 1b bezüglich des Wendepunktabstands aufgeschlüsselt nach der Performance des Trainings-, Test- und der Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 20 präsentiert:

Tabelle 20: Modellgüte des ANN 1b bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse

i	ANN 1b			
	Training	Test	Validierung FLAC	Validierung Literatur
R^2 [-]	0.993	0.989	0.982	-65.833
MAE [m]	0.64	0.74	1.13	15.01
MAPE [-]	0.037	0.048	0.064	2.028
MSE [m ²]	0.77	1.22	1.92	311.62
RMSE [m]	0.88	1.11	1.39	17.65

i	lineare Regression 1			
	Training	Test	Validierung FLAC	Validierung Literatur
R^2 [-]	0.989	0.981	0.974	-66.642
MAE [m]	0.81	0.99	1.25	14.89
MAPE [-]	0.046	0.065	0.086	2.001
MSE [m ²]	1.32	1.98	2.77	315.39
RMSE [m]	1.15	1.41	1.67	17.76




Abb. 35: Modellgüte des ANN 1b bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC d.) Validierung Literatur

4.4.4 Feature Importance des ANN 1b: Wendepunktabstand

Abb. 36 stellt die SHAP-Werte, Abb. 37 den Permutation Importance Score des ANN 1b bezüglich des Wendepunktabstands dar.




Abb. 36: Feature Importance (SHAP-Werte) des ANN 1b bezüglich des Wendepunktabstands




Abb. 37: Feature Importance (Permutation Importance) des ANN 1b bezüglich des Wendepunktabstands

4.5 Artificial Neural Network 2

4.5.1 Input- und Outputfeatures

Das zweite ANN (ANN 2) weist insgesamt elf Inputfeatures auf, welche die Bodenparameter, die Vortriebsart und die geometrischen Verhältnisse berücksichtigen. Der Output des ANN 2 ist die maximale Setzung und der Wendepunktabstand i . Tabelle 21 zeigt die verwendeten Input- und Outputfeatures sowie deren Spannweite, Mittelwert und Standardabweichung. Die im Vergleich zu den ANN 1 veränderten Features wurden farblich hinterlegt:

Tabelle 21: statistische Beschreibung der Input und Outputfeatures des ANN 2

Parameter		Typ	Min	Max	Mittel	σ	Einheit
Vortriebsart		Input	0	1	0.50	0.50	-
Vorentlastungsfaktor Lambda	λ	Input	0.1	0.5	0.19	0.10	-
Dichte	γ	Input	1800	2200	1992	87.8	kg/m ³
Kohäsion	c	Input	0	50	12.75	14.76	kPa
Reibungswinkel	φ	Input	12.5	42	29.52	8.96	°
Elastizitätsmodul ref 50	E_{50}^{ref}	Input	2.05	90	35.54	33.23	MPa
Elastizitätsmodul ref oed	E_{oed}^{ref}	Input	1.64	90	35.23	32.48	MPa
Elastizitätsmodul ref ur	E_{ur}^{ref}	Input	6.15	270	114.58	101.49	MPa
Überdeckung	C	Input	2.5	75	28.23	16.84	m
Durchmesser	D	Input	5	15	10.23	2.95	m
Überdeckungsverhältnis	C/D	Input	0.5	5	2.79	1.40	-
maximale Setzung	S_{vmax}	Output	2.1	229.3	30.42	32.89	mm
Wendepunktabstand	i	Output	3.39	53.54	21.80	10.71	m

4.5.2 Ergebnisse des GridsearchCV

Die Suche nach der optimalen Netzwerkarchitektur wurde mittels des in Kapitel 3.2.4 erwähnten GridSearchCV-Algorithmus durchgeführt. Tabelle 22 gibt Auskunft über die 30 besten Hyperparameterkombinationen. Der angegebene MSE bezieht sich auf das Gesamtmodell, wodurch sowohl die Performance hinsichtlich der maximalen Setzung als auch des Wendepunktabstandes berücksichtigt wird. Die Standardabweichung des MSE wurde über alle ShuffleSplits während des GridSearchCV berechnet.

Tabelle 22: Ergebnisse des GridSearchCV für das ANN 2

Rang	Versteckte Layer	Neuronen pro Layer	Aktivierungsfunktion	Initializer	MSE	σ_{MSE}
1	5	50	GeLu	GlorotNormal	27.0	17.3
2	4	50	GeLu	GlorotUniform	27.6	21.2
3	5	75	GeLu	GlorotUniform	31.2	17.8
4	4	50	GeLu	GlorotNormal	31.2	22.7
5	5	50	GeLu	GlorotUniform	31.6	22.3
6	4	37	GeLu	GlorotNormal	31.9	18.1
7	5	21	GeLu	GlorotNormal	32.2	25.1
8	5	28	GeLu	GlorotNormal	33.9	17.9
9	4	21	GeLu	GlorotNormal	34.7	14.4
10	4	25	GeLu	HeNormal	36.2	28.7
11	3	100	GeLu	GlorotUniform	36.9	24.1
12	5	18	GeLu	GlorotNormal	37.0	34.0
13	4	25	GeLu	GlorotNormal	37.1	23.3
14	5	37	GeLu	GlorotUniform	37.4	35.0
15	4	18	ReLu	HeNormal	37.4	29.9
16	3	50	GeLu	GlorotNormal	37.5	24.4
17	4	14	GeLu	HeNormal	37.7	22.9
18	4	21	GeLu	GlorotUniform	38.0	25.0
19	5	18	GeLu	HeNormal	38.2	8.0
20	3	37	GeLu	HeUniform	38.3	30.4
21	5	14	GeLu	GlorotUniform	38.6	20.4
22	4	37	GeLu	HeNormal	39.0	26.0
23	3	18	GeLu	HeNormal	39.1	25.7
24	2	500	GeLu	GlorotUniform	39.3	26.2
25	3	25	GeLu	HeNormal	39.5	21.1
26	3	50	GeLu	GlorotUniform	39.7	30.8
27	5	50	GeLu	HeNormal	40.8	30.1
28	4	18	GeLu	GlorotUniform	40.9	15.9
29	5	25	GeLu	GlorotNormal	41.0	32.3
30	3	37	GeLu	GlorotNormal	41.3	24.9

4.5.3 Gewählte Netzwerkarchitektur ANN 2

Gemäß den Ergebnissen des GridSearchCV wurde die in Tabelle 23 aufgelistete Kombination ausgewählt. Es ist jedoch anzumerken, dass auch mit anderen Parameterkombination eine sehr ähnliche Modellgüte erreicht wird.

Tabelle 23: Hyperparameter des ANN 2

Anzahl der versteckten Layer:	5
Anzahl der Neuronen pro Layer:	75
Aktivierungsfunktion:	GeLU (ReLU beim Outputlayer)
Weight-Initialization:	GlorotUniform

4.5.4 Modellgüte des ANN 2: maximale Setzung

Tabelle 24 und Abb. 38 geben einen Überblick über die Modellgüte des ANN 2 bezüglich der maximalen Setzung aufgeschlüsselt nach der Performance des Trainings-, Test- und des Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 24 präsentiert:

Tabelle 24: Modellgüte des ANN 2 bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse

S_{vmax}	ANN 2		
	Training	Test	Validierung FLAC
R^2 [-]	0.999	0.971	0.861
MAE [mm]	0.8	2.3	9.3
MAPE [-]	0.037	0.093	0.337
MSE [mm ²]	1.3	27.1	241.3
RMSE [mm]	1.1	5.2	15.5

S_{vmax}	lineare Regression 2		
	Training	Test	Validierung FLAC
R^2 [-]	0.701	0.668	0.476
MAE [mm]	12.0	12.2	20.8
MAPE [-]	0.833	0.840	2.024
MSE [mm ²]	339.1	308.6	912.6
RMSE [mm]	18.4	17.6	30.2




Abb. 38: Modellgüte des ANN 2 bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC

4.5.5 Feature Importance des ANN 2: maximale Setzung

Abb. 39 stellt die SHAP-Werte des ANN 2 bezüglich der maximalen Setzung dar.




Abb. 39: Feature Importance (SHAP-Werte) des ANN 2 bezüglich der maximalen Setzung

4.5.6 Modellgüte des ANN 2: Wendepunktabstand

Tabelle 25 und Abb. 40 geben einen Überblick über die Modellgüte des ANN 2 bezüglich des Wendepunktabstands aufgeschlüsselt nach der Performance des Trainings-, Test- und des Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 25 präsentiert:

Tabelle 25: Modellgüte des ANN 2 bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse

i	ANN 2		
	Training	Test	Validierung FLAC
R ² [-]	0.995	0.983	0.836
MAE [m]	0.62	1.00	3.57
MAPE [-]	0.035	0.074	0.212
MSE [m ²]	0.61	1.83	17.44
RMSE [m]	0.78	1.35	4.18

i	lineare Regression 2		
	Training	Test	Validierung FLAC
R^2 [-]	0.990	0.982	0.966
MAE [m]	0.74	0.95	1.26
MAPE [-]	0.044	0.066	0.083
MSE [m ²]	1.11	1.91	3.61
RMSE [m]	1.05	1.38	1.90




Abb. 40: Modellgüte des ANN 2 bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC

4.5.7 Feature Importance des ANN 2: Wendepunktabstand

Abb. 41 stellt die SHAP-Werte des ANN 2 bezüglich des Wendepunktabstands dar.




Abb. 41: Feature Importance (SHAP-Werte) des ANN 2 bezüglich des Wendepunktabstands

4.6 Artificial Neural Network 2a

Bei dieser Netzwerkarchitektur wurden dieselben Inputfeatures wie beim ANN 2 verwendet (siehe Kapitel 4.5.1), der Output des ANN 2a ist jedoch nur die maximale Setzung.

4.6.1 Ergebnisse des GridsearchCV

Die Suche nach der optimalen Netzwerkarchitektur wurde mittels des in Kapitel 3.2.4 erwähnten GridSearchCV-Algorithmus durchgeführt. Tabelle 26 gibt Auskunft über die 30 besten Hyperparameterkombinationen. Der angegebene MSE bezieht sich auf das Gesamtmodell, wodurch hier die Performance hinsichtlich der maximalen Setzung berücksichtigt wird. Die Standardabweichung des MSE wurde über alle ShuffleSplits während des GridSearchCV berechnet.

Tabelle 26: Ergebnisse des GridSearchCV für das ANN 2a

Rang	Versteckte Layer	Neuronen pro Layer	Aktivierungsfunktion	Initializer	MSE	σ_{MSE}
1	4	50	GeLu	GlorotUniform	48.9	43.6
2	4	18	ReLu	HeNormal	49.7	34.1
3	4	18	GeLu	GlorotNormal	54.4	44.3
4	3	21	GeLu	GlorotNormal	55.4	36.1
5	4	14	GeLu	GlorotUniform	55.4	32.3
6	3	50	GeLu	GlorotUniform	56.7	39.9
7	5	50	GeLu	GlorotUniform	56.9	51.4
8	3	18	GeLu	GlorotNormal	61.5	37.8
9	3	14	GeLu	GlorotUniform	61.5	34.0
10	3	37	GeLu	GlorotNormal	61.6	53.8
11	3	14	GeLu	HeUniform	62.2	25.6
12	5	50	GeLu	GlorotNormal	62.7	60.7
13	5	100	GeLu	GlorotUniform	63.2	44.2
14	4	50	GeLu	GlorotNormal	66.2	51.6
15	3	75	GeLu	GlorotUniform	66.4	52.6
16	5	18	ReLu	GlorotNormal	67.9	44.9
17	4	14	ReLu	HeNormal	68.1	38.3
18	3	18	GeLu	HeNormal	68.2	39.7
19	5	21	GeLu	GlorotNormal	68.5	55.4
20	4	37	GeLu	GlorotUniform	69.5	64.8
21	4	21	GeLu	GlorotNormal	69.7	76.2
22	3	37	GeLu	HeNormal	70.1	57.9
23	3	50	ReLu	GlorotUniform	70.6	62.8
24	4	18	GeLu	HeNormal	71.0	44.6
25	5	14	GeLu	HeNormal	71.2	53.6
26	3	21	GeLu	GlorotUniform	71.3	68.1
27	2	25	GeLu	GlorotNormal	73.0	56.7
28	4	18	ReLu	HeUniform	73.2	42.7
29	4	37	GeLu	HeNormal	73.5	35.9
30	5	75	GeLu	GlorotUniform	74.1	38.7

4.6.2 Gewählte Netzwerkarchitektur ANN 2a

Gemäß den Ergebnissen des GridSearchCV wurde die in Tabelle 27 aufgelistete Kombination ausgewählt. Es ist jedoch anzumerken, dass auch mit anderen Parameterkombination eine sehr ähnliche Modellgüte erreicht wird.

Tabelle 27: Hyperparameter des ANN 2a

Anzahl der versteckten Layer:	4
Anzahl der Neuronen pro Layer:	18
Aktivierungsfunktion:	ReLU (keine Aktivierungsfunktion beim Outputlayer)
Weight-Initialization:	HeNormal

4.6.3 Modellgüte des ANN 2a: maximale Setzung

Tabelle 28 und Abb. 42 geben einen Überblick über die Modellgüte des ANN 2a bezüglich der maximalen Setzung aufgeschlüsselt nach der Performance des Trainings-, Test- und des Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 28 präsentiert:

Tabelle 28: Modellgüte des ANN 2a bezüglich der maximalen Setzung im Vergleich mit einer multiplen linearen Regressionsanalyse

S_{vmax}	ANN 2a		
	Training	Test	Validierung FLAC
R^2 [-]	0.999	0.969	0.784
MAE [mm]	0.6	3.0	11.3
MAPE [-]	0.038	0.146	0.509
MSE [mm ²]	0.7	28.9	376.1
RMSE [mm]	0.8	5.4	19.4

S_{vmax}	lineare Regression 2		
	Training	Test	Validierung FLAC
R^2 [-]	0.701	0.668	0.476
MAE [mm]	12.0	12.2	20.8
MAPE [-]	0.833	0.840	2.024
MSE [mm ²]	339.1	308.6	912.6
RMSE [mm]	18.4	17.6	30.2




Abb. 42: Modellgüte des ANN 2a bezüglich der maximalen Setzung: a.) Training b.) Test c.) Validierung FLAC

4.6.4 Feature Importance des ANN 2a: maximale Setzung

Abb. 43 stellt die SHAP-Werte, Abb. 44 den Permutation Importance Score des ANN 2a bezüglich der maximalen Setzung dar.




Abb. 43: Feature Importance (SHAP-Werte) des ANN 2a bezüglich der maximalen Setzung




Abb. 44: Feature Importance (Permutation Importance) des ANN 2a bezüglich der maximalen Setzung

4.7 Artificial Neural Network 2b

Bei dieser Netzwerkarchitektur wurden dieselben Inputfeatures wie beim ANN 2 verwendet (siehe Kapitel 4.5.1), der Output des ANN 2b ist jedoch nur der Wendepunktabstand.

4.7.1 Ergebnisse des GridsearchCV

Die Suche nach der optimalen Netzwerkarchitektur wurde mittels des in Kapitel 3.2.4 erwähnten GridSearchCV-Algorithmus durchgeführt. Tabelle 29 gibt Auskunft über die 30 besten Hyperparameterkombinationen. Der angegebene MSE bezieht sich auf das Gesamtmodell, wodurch hier die Performance hinsichtlich des Wendepunktabstands berücksichtigt wird. Die Standardabweichung des MSE wurde über alle ShuffleSplits während des GridSearchCV berechnet.

Tabelle 29: Ergebnisse des GridSearchCV für das ANN 2b

Rang	Versteckte Layer	Neuronen pro Layer	Aktivierungsfunktion	Initializer	MSE	σ_{MSE}
1	1	1000	GeLu	HeNormal	1.72	0.34
2	1	1000	GeLu	HeUniform	1.73	0.27
3	1	1000	GeLu	GlorotNormal	1.79	0.29
4	1	1000	GeLu	GlorotUniform	1.80	0.31
5	1	500	GeLu	HeUniform	1.88	0.31
6	1	500	GeLu	HeNormal	2.00	0.35
7	2	1000	GeLu	GlorotUniform	2.04	0.33
8	1	500	GeLu	GlorotUniform	2.09	0.50
9	2	500	GeLu	GlorotUniform	2.11	0.35
10	1	100	GeLu	GlorotUniform	2.11	0.42
11	1	1000	ReLu	HeUniform	2.12	0.32
12	1	500	GeLu	GlorotNormal	2.13	0.41
13	2	1000	GeLu	GlorotNormal	2.13	0.37
14	1	1000	ReLu	GlorotNormal	2.14	0.47
15	1	1000	ReLu	HeNormal	2.16	0.39
16	1	75	GeLu	GlorotNormal	2.16	0.56
17	2	500	GeLu	GlorotNormal	2.17	0.36
18	1	500	ReLu	GlorotUniform	2.17	0.43
19	1	50	ReLu	GlorotUniform	2.17	0.47
20	1	1000	ReLu	GlorotUniform	2.19	0.46
21	1	37	ReLu	GlorotNormal	2.19	0.46
22	1	500	ReLu	GlorotNormal	2.20	0.42
23	1	100	ReLu	GlorotNormal	2.21	0.55
24	1	100	ReLu	GlorotUniform	2.22	0.52
25	2	18	GeLu	GlorotUniform	2.22	0.51
26	1	50	GeLu	GlorotUniform	2.29	0.60
27	1	100	ReLu	HeUniform	2.29	0.34
28	1	75	GeLu	GlorotUniform	2.31	0.40
29	1	500	ReLu	HeUniform	2.32	0.34
30	3	1000	ReLu	GlorotNormal	2.32	0.41

4.7.2 Gewählte Netzwerkarchitektur ANN 2b

Gemäß den Ergebnissen des GridSearchCV wurde die in Tabelle 30 aufgelistete Kombination ausgewählt. Es ist jedoch anzumerken, dass auch mit anderen Parameterkombination eine sehr ähnliche Modellgüte erreicht wird.

Tabelle 30: Hyperparameter des ANN 2b

Anzahl der versteckten Layer:	1
Anzahl der Neuronen pro Layer:	1000
Aktivierungsfunktion:	GeLU (keine Aktivierungsfunktion beim Outputlayer)
Weight-Initialization:	HeNormal

4.7.3 Modellgüte des ANN 2b: Wendepunktabstand

Tabelle 31 und Abb. 45 geben einen Überblick über die Modellgüte des ANN 2b bezüglich des Wendepunktabstands aufgeschlüsselt nach der Performance des Trainings-, Test- und des Validierungssets. Als Vergleichsmaßstab werden auch die Ergebnisse der linearen Regression in Tabelle 31 präsentiert:

Tabelle 31: Modellgüte des ANN 2b bezüglich des Wendepunktabstands im Vergleich mit einer multiplen linearen Regressionsanalyse

i	ANN 2b		
	Training	Test	Validierung FLAC
R^2 [-]	0.995	0.990	0.971
MAE [m]	0.54	0.67	1.41
MAPE [-]	0.031	0.048	0.071
MSE [m ²]	0.54	1.02	3.07
RMSE [m]	0.73	1.01	1.75

i	lineare Regression 2		
	Training	Test	Validierung FLAC
R^2 [-]	0.990	0.982	0.966
MAE [m]	0.74	0.95	1.26
MAPE [-]	0.044	0.066	0.083
MSE [m ²]	1.11	1.91	3.61
RMSE [m]	1.05	1.38	1.90




Abb. 45: Modellgüte des ANN 2b bezüglich des Wendepunktabstands: a.) Training b.) Test c.) Validierung FLAC

4.7.4 Feature Importance des ANN 2b: Wendepunktastand

Abb. 46 stellt die SHAP-Werte, Abb. 47 den Permutation Importance Score des ANN 2b bezüglich des Wendepunktastands dar.




Abb. 46: Feature Importance (SHAP-Werte) des ANN 2b bezüglich des Wendepunktastands




Abb. 47: Feature Importance (Permutation Importance) des ANN 2b bezüglich des Wendepunktastands

5 Diskussion der Ergebnisse

5.1 Qualität und Limitierungen der FDM-Berechnungen

Numerische Berechnungen beruhen immer auf einer Idealisierung und Vereinfachung der natürlichen Verhältnisse, weswegen die erhaltenen Ergebnisse immer mit Sorgfalt zu betrachten sind. Im Zuge dieser Arbeit wurde nur ein homogener Boden ohne Grundwassereinfluss betrachtet. Zusätzlich wurde die Tunnelgeometrie sowohl für TVM als auch für NATM als kreisrund angenommen. Durch diese simplifizierte Modellierung kann die Realität nur näherungsweise abgebildet werden. Dies ist bei Betrachtung der Ergebnisse zu berücksichtigen.

Als Materialgesetz während der FDM-Berechnungen wurde dem PH-Modell gegenüber dem MC-Modell der Vorzug gegeben, da sich in den Beispielrechnungen (siehe Kapitel 3.1.9) bessere Ergebnisse zeigten. Mit zusätzlicher Berücksichtigung der small-strain-stiffness hätte die Modellbildung noch verbessert werden können, jedoch war es nicht möglich, alle erforderlichen, experimentell bestimmten Eingangsparameter für viele verschiedene Bodenarten in der publizierten Literatur zu finden. Das PH-Modell war für diese Arbeit trotzdem ein akzeptabler Mittelweg zwischen rechnerischer Genauigkeit und Berechnungsaufwand. Als Folge ergeben sich laut Meschke et al. (2014: 192) breitere Setzungsmulden als sie in der Realität beobachtet werden.

Während den Berechnungen zeigte sich auch, dass die unterschiedliche Modellierung der Sicherungsmaßnahmen von TVM- und NATM-Tunneln nur einen untergeordneten Einfluss auf die maximale Setzung und die Form der Setzungsmulde hat.

Der größte Unsicherheitsfaktor der numerischen Berechnungen ist jedoch die Berücksichtigung der 3D-Effekte in den 2D-Simulationen mittels der CCM. Da aufgrund der hohen Zahl an durchgeführten 2D-Simulationen keine Kalibrierung des Vorentlastungsfaktor mittels 3D- oder zweidimensionalen axisymmetrischen Analysen durchgeführt wurde oder Vergleichsdaten aus der Realität zur Verfügung standen, musste der Vorentlastungsfaktor mittels der GRC und des LDP nach der Methode von Vlachopoulos und Diederichs (2009) abgeschätzt werden, was jedoch zu großen Unsicherheiten führt. Als Beispiel sei hier die FDM-Simulation mit dem Index 10 aus Tabelle 9 angeführt: Für diesen Fall eines in NATM-Bauweise ausgeführten Tunnels vergrößerte sich die maximale Setzung um 47 % von rund 9 mm auf rund 13 mm, wenn sich der Vorentlastungsfaktor von 0.3 auf 0.5 erhöhte. Auf die Form der Setzungsmulde und den Wendepunktabstand hat die Wahl des Vorentlastungsfaktors in allen in dieser Arbeit durchgeführten Berechnungen keinen nennenswerten Einfluss gezeigt.

5.2 Anzahl der Datensätze

Insgesamt besteht die Datenbank (siehe Kapitel 4.1) aus 140 verschiedenen Kombinationen von Boden- und Geometrieparametern, die jeweils als TVM- und NATM-Tunnel berechnet wurden. Für die ML-Anwendung ist es wichtig, eine möglichst große und repräsentative Datenbankgrundlage zu haben. Die Boden- und Geometrieparameter decken einen großen Bereich des als für seichtliegende Tunnel realistisch zu betrachtenden Wertebereichs ab. Des Weiteren ist mit dieser Anzahl an Datensätzen die statistische Signifikanz des Trainingsdatensets für das Gesamtdatenset erwiesen. Jedoch würden eine größere Datenbank und mehr unterschiedliche Bodenparameter die Performance eines ANN, vor allem für die Hold-Out-Validierung, weiter steigern.

5.3 Validierung mit Literaturdaten

Die Validierung der ANN 1/a/b mittels Daten aus der Literatur ist fehlgeschlagen. Kein einziges berechnetes Gütemaß zeigt eine zufriedenstellende Performance des ANN 1/a/b für das Validierungsset aus der Literatur an. Folgend werden einige mögliche Gründe dafür angeführt und kurz besprochen:

Die Daten aus der Literatur geben nur jeweils einen Wert für die jeweiligen Bodenparameter an, jedoch herrschen in der Realität immer **heterogene Bodenverhältnisse** vor, die im Zuge dieser Arbeit nicht modelliert wurden. Des Weiteren beruhen die 2D-FDM-Berechnungen auf vielen **Annahmen und Vereinfachungen**, wie bereits in den Kapiteln 2.2.4.5, 3.1 und 5.1 beschrieben wurde, weswegen die hier präsentierte **Datenbank an Setzungsprognosen nicht repräsentativ** für die in der **Literatur** gefundenen Beispiele ist. Das zeigt sich auch durch einen genaueren Blick auf die Korrelationsmatrizen des Gesamtdaten- und des Validierungssets aus der Literatur (Abb. 7 und Abb. 26). Die maximale Setzung im Validierungsset ist mit allen anderen Parametern negativ korreliert, während diese Korrelation im Gesamtdatenset nur bei den Parametern Elastizitätsmodul und Reibungswinkel in relevantem Ausmaß auftritt. Bei Betrachtung des Wendepunktabstands weisen die Parameter Vortriebsart, Reibungswinkel und Elastizitätsmodul des Validierungssets eine durchaus signifikante Korrelation zum Wendepunktabstand auf, während diese im Gesamtdatenset überhaupt nicht besteht. Die Korrelation zwischen der Überdeckung, dem Durchmesser und dem Überdeckungsverhältnis mit dem Wendepunktabstand fällt beim Gesamtdatenset stärker aus, wobei sie auch im Validierungsset in einer ähnlichen Größe besteht. Der vermutlich größte Faktor ist allerdings die **Nichtberücksichtigung von den EPBM-Betriebsparametern**, welche bei den Literaturdaten zusätzlich angegeben sind, aber in dieser Arbeit nur implizit über die Vorentlastung in den Parameter „Vortriebsart“ einfließen und somit Eingang in die Prognosen erhalten. Zusätzlich können auch **Ungenauigkeiten bei der Setzungsmessung** und im Generellen verschiedene, bei der **Bauausführung** aufgetretene Probleme, sowie im ANN nicht berücksichtigte Betriebsparameter zur Nichtanwendbarkeit der entwickelten ANN für die verwendeten Literaturdaten führen.

Bei einem genaueren Blick in die in Tabelle 1 zusammengestellte Datenbank zeigt sich, dass einige Datenpunkte fast idente Boden- und Geometrieparameter aufweisen, die zugehörigen maximalen Setzungen sich aber sehr stark voneinander unterscheiden. In folgender Tabelle 32 wird dies durch einen Ausschnitt aus Tabelle 1 noch einmal verdeutlicht: Obwohl die für die entwickelten ANN relevanten Eingangsparameter fast deckungsgleich sind, bewegen sich die maximalen Setzungen in einem Bereich von 27.1 mm bis 89.9 mm und weichen somit um mehr als 330 % voneinander ab.

Tabelle 32: Ausschnitt aus Tabelle 1: Datenbank der Setzungsprognosen aus der Literatur

Index	Vortriebsart	c	φ	E	C	D	C/D	S_{vmax}	i	Quelle
		[kPa]	[°]	[MPa]	[m]	[m]	[-]	[mm]	[m]	
21	TVM	11.8	14.4	5.5	7.7	6.3	1.2	27.1	5.81	Zhou et al. (2017)
22	TVM	11.9	13.8	5.2	8.7	6.3	1.4	38.6	7.27	Zhou et al. (2017)
23	TVM	11.9	13.8	5.2	8.0	6.3	1.3	62.5	7.32	Zhou et al. (2017)
24	TVM	11.9	13.8	5.2	7.3	6.3	1.2	89.9	7.53	Zhou et al. (2017)
25	TVM	12.0	13.7	5.2	8.8	6.3	1.4	57.0	7.48	Zhou et al. (2017)
26	TVM	12.0	13.7	5.2	8.6	6.3	1.4	79.6	7.51	Zhou et al. (2017)

5.4 Diskussion der ANN-Architekturen

5.4.1 Einfluss der Weight-Initialization-Methoden

Die Wahl der Weight-Initialization-Methode hatte in dieser Arbeit keinen nennenswerten Einfluss auf die Modellperformance der verschiedenen ANN. Wie die Ergebnisse aus den durchgeführten GridsearchCV-Suchen zeigen, konnten mit allen vier in Kapitel 3.2.1.5 gewählten Techniken gute Ergebnisse erzielt werden. Nach Analyse der gemäß des GridsearchCV jeweils 30 besten Netzwerkarchitekturen der sechs verschiedenen ANN lässt sich jedoch ein Trend erkennen, welcher in Abb. 48 dargestellt ist:




Abb. 48: Übersicht über die Weight-Initialization-Methoden

Unter den untersuchten 180 besten Netzwerkarchitekturen kam mit rund 43 % am häufigsten die GlorotNormal-Initialisierung gefolgt von der GlorotUniform-Initialisierung mit 34 % zum Einsatz. Die restlichen 23 % verteilen sich auf die He-Initialisierungen. Die Ergebnisse decken sich nicht zur Gänze mit den Erfahrungen aus der Literatur (siehe Kapitel 3.2.1.5), wonach zu erwarten wäre, dass die He-Initialisierungen für die ReLU- und GeLU-Aktivierungsfunktion die besten Resultate liefern sollten. Eine Erklärung dafür ist, dass die in dieser Arbeit entwickelten ANN wenig versteckte Layer beinhalten und daher die Relevanz der richtigen Gewichts-Initialisierung zusammen mit dem Vanishing-Gradient-Problem nicht ausschlaggebend für die Performance des ANN sind, wie dies bei sehr tiefen ANN der Fall wäre.

5.4.2 Einfluss der Aktivierungsfunktionen

In dieser Arbeit wurden die ReLU-, GeLU- sowie Sigmoid-Aktivierungsfunktionen (siehe Kapitel 3.2.1.2) in die Suche nach der optimalen Netzwerkarchitektur einbezogen. Die Analyse der durch GridsearchCV ermittelten 30 besten Netzwerkarchitekturen der unterschiedlichen ANN zeigte, dass die GeLU-Aktivierungsfunktion mit Abstand am öftesten zu einer guten ANN-Modellperformance führte. In 72 % der ermittelten Netzwerkarchitekturen führte GeLU zu den besten Ergebnissen, in den restlichen 28 % die ReLU Aktivierungsfunktion (siehe Abb. 49). ANN, welche die Sigmoid-Aktivierungsfunktion nutzten, konnten mit dem in dieser Arbeit verwendeten Datenset und der Regressionsaufgabenstellung, keine zufriedenstellende Performance erzielen. Das liegt an der Natur der Sigmoid-Funktion, welche alle Eingangswerte auf eine Skala von 0 bis 1 zusammendrückt und somit besser für Klassifizierungsaufgaben geeignet ist.




Abb. 49: Übersicht über die Aktivierungsfunktionen

Mit der GeLU-Aktivierungsfunktion konnten in dieser Arbeit die besten Ergebnisse erzielt werden. Durch die gekrümmte Form der Funktion und die Tatsache, dass GeLU auch leicht negative Werte annehmen kann, konnten in diesem Anwendungsfall die komplizierten Zusammenhänge besser approximiert werden als mit der ReLU-Aktivierungsfunktion, welche jedoch auch sehr gute Ergebnisse liefert. Im Allgemeinen ist die Berechnung mit GeLU rechenintensiver, jedoch spielt das bei einem für ML-Verhältnisse kleinen Datenset wie in dieser Arbeit keine Rolle, sollte aber bei anderen, größeren Anwendungen bedacht werden.

5.4.3 Anzahl an Layern und Neuronen

Die richtige Anzahl an versteckten Layern und Neuronen zu finden, ist grundlegend für den späteren Erfolg des ANN. Während dieser Arbeit wurde dies systematisch mittels des GridsearchCV-Algorithmus durchgeführt (siehe Kapitel 3.2.4), wodurch nur innerhalb der selbst gesetzten und nach Grundsätzen aus der Literatur erstellten Grenzen nach den optimalen Hyperparametern gesucht wurde. Während der verschiedenen Suchen zeigte sich, dass sich die gefundenen Kombinationen aus versteckten Layern und Neuronen bei den Single-Output-ANN (ANN 1a/b, ANN 2a/b) sehr stark voneinander unterschieden.

Bei den ANN, welche nur den Wendepunktabstand i als Outputvariable haben (ANN 1b, 2b), konnten die besten Ergebnisse mit Netzwerken mit nur einem versteckten Layer jedoch vielen Neuronen erzielt werden (zumeist 500 oder 1000 Neuronen per Layer). Das deutet daraufhin, dass die Zusammenhänge zwischen dem Wendepunktabstand und den Eingangsparametern durch einen relativ einfachen Zusammenhang modelliert werden können. Diese These wird auch durch die Ergebnisse aus den Feature-Importance Berechnungen (siehe Abb. 36, Abb. 37, Abb. 46 sowie Abb. 47) gestützt, wobei hierbei vor allem der Überdeckungsparameter C von großer und der Durchmesser D von untergeordneter Wichtigkeit sind.

Die Netzwerkarchitektur der **Single-Output-ANN** mit dem Output der **maximalen Setzung** (ANN 1a, 2a) wird von tieferen Netzwerken von zumeist drei bis fünf versteckten Layern dafür

mit weniger Neuronen (zumeist 14 bis 50) geprägt. Durch den tieferen Aufbau der ANN können die komplexen Zusammenhänge zwischen den Input- und den Outputvariablen besser modelliert werden. Auch die Feature-Importance-Berechnungen (siehe Abb. 33, Abb. 34, Abb. 43 sowie Abb. 44) zeigen, dass die maximale Setzung von mehreren Input-Parametern maßgeblich und in einer ähnlichen Größenordnung beeinflusst wird. Die komplexen Zusammenhänge könnten laut Géron (2019: 319) auch durch ein ANN mit nur einem versteckten Layer und mehreren tausend Neuronen approximiert werden, jedoch ist dies durch die hohe Anzahl an Neuronen weniger effizient als die Anwendung eines tieferen ANN.

Für die beiden **Multi-Output-ANN** (ANN 1, 2) ähneln die gefundenen Netzwerkarchitekturen sehr stark denen der Single-Output-ANN mit dem Outputparameter der maximalen Setzung. Hierbei wiegt der komplexere Zusammenhang zwischen der maximalen Setzung und den Inputvariablen stärker auf als der einfachere mit dem Wendepunktabstand, wodurch die Netzwerkarchitektur stärker an die durch die maximale Setzung gestellten Anforderungen angepasst wird.

5.5 ANN Performance des Trainings-, Test- und Validierungssets

In Tabelle 33 werden die berechneten Gütemaße aller entwickelten ANN aufgeschlüsselt nach der Performance des Trainings-, des Test- und des FLAC-Hold-Out-Validierungssets zusammen dargestellt. Zum besseren Vergleich mit der Benchmark wurden die Gütemaße der linearen Regressionsanalysen nachfolgend in Tabelle 34 zusammengefasst. Die Gegenüberstellung mit den linearen Regressionsanalysen zeigt, dass durch die Anwendung von ML in Form von ANN bessere Prognosemodelle entwickelt werden konnten als mit klassischen statistischen Methoden.

Die **Performance** der ANN am **Trainings- und Testdatenset** ist durchwegs sehr gut. Während des Trainings der ANN wurde bewusst darauf achtgegeben, die ANN nicht an das Trainingsset überanzupassen, was sich durch die nicht perfekten Gütemaße des Trainingssets widerspiegelt. Bei einer stärkeren Anpassung während des Trainings würde sich zwar die Trainingsperformance verbessern, im Gegenzug aber die Test- und Validierungsperformance verschlechtern. Es muss somit immer zwischen der allgemeinen Generalisierungsfähigkeit der ANN und einer nahezu perfekten Anpassung an das Trainingsset abgewogen werden. Die berechneten Gütemaße (siehe Tabelle 33 für genaue Werte) veranschaulichen die gute Performance der ANN. Das Bestimmtheitsmaß R^2 bewegt sich während des Trainings und des Tests bei allen entwickelten ANN zwischen 0.928 und 1 und somit nahe am Optimum von 1. Die Fehlermaße MAE, MAPE, MSE und RMSE deuten auf ein optimales Modell hin, wenn deren Wert 0 beträgt. In dieser Arbeit konnten gute Werte erzielt werden, welche in der Größenordnung der Unsicherheiten der zugrundeliegenden Daten aus den FDM-Berechnungen liegen.

Im Generellen wurde in dieser Arbeit - wie erwartet - deutlich, dass die Modellperformance durch die Berücksichtigung von mehr und aussagekräftigeren Inputfeatures verbessert werden konnte. So wurden für die entwickelten ANN 2/a/b alle E-Moduln des PH-Materialgesetzes, die Dichte des Bodens sowie der Vorentlastungsfaktor explizit miteinbezogen, wodurch die Modellperformance signifikant gesteigert werden konnte. Zum Beispiel konnte in Bezug auf die maximale Setzung der RMSE während des Tests von 8.6 mm (ANN 1a) auf 5.4 mm (ANN 2a) verringert werden.

Tabelle 33: Übersicht über die Performance aller entwickelter ANN

S_{vmax}	Training				Test				Validierung FLAC			
	ANN 1	ANN 1a	ANN 2	ANN 2a	ANN 1	ANN 1a	ANN 2	ANN 2a	ANN 1	ANN 1a	ANN 2	ANN 2a
R^2 [-]	0.957	0.946	0.999	0.999	0.939	0.921	0.971	0.969	0.362	0.334	0.861	0.784
MAE [mm]	3.6	3.3	0.8	0.6	4.5	5.4	2.3	3.0	21.3	21.3	9.3	11.3
MAPE [-]	0.137	0.124	0.037	0.038	0.207	0.288	0.093	0.146	0.978	0.982	0.337	0.509
MSE [mm ²]	48.5	61.7	1.3	0.7	56.4	73.3	27.1	28.9	1111	1159	241.3	376.1
RMSE [mm]	7.0	7.9	1.1	0.8	7.5	8.6	5.2	5.4	33.3	34.0	15.5	19.4

i	Training				Test				Validierung FLAC			
	ANN 1	ANN 1b	ANN 2	ANN 2b	ANN 1	ANN 1b	ANN 2	ANN 2b	ANN 1	ANN 1b	ANN 2	ANN 2b
R^2 [-]	0.967	0.993	0.995	0.995	0.937	0.989	0.983	0.990	0.840	0.982	0.836	0.971
MAE [m]	1.4	0.6	0.6	0.5	2.0	0.7	1.0	0.7	3.5	1.1	3.6	1.4
MAPE [-]	0.087	0.037	0.035	0.031	0.152	0.048	0.074	0.048	0.202	0.064	0.212	0.071
MSE [m ²]	3.9	0.8	0.6	0.5	6.7	1.2	1.8	1.0	17.0	1.9	17.4	3.1
RMSE [m]	2.0	0.9	0.8	0.7	2.6	1.1	1.4	1.0	4.1	1.4	4.2	1.8

Tabelle 34: Übersicht über die Performance der linearen Regressionsanalysen

S_{vmax}	Training		Test		Validierung FLAC	
	lin. Reg. 1	lin. Reg. 2	lin. Reg. 1	lin. Reg. 2	lin. Reg. 1	lin. Reg. 2
R^2 [-]	0.671	0.701	0.576	0.668	0.541	0.476
MAE [mm]	12.6	12.0	14.1	12.2	18.6	20.8
MAPE [-]	0.844	0.833	1.037	0.840	1.601	2.024
MSE [mm ²]	373.1	339.1	393.7	308.6	798.0	912.6
RMSE [mm]	19.3	18.4	19.8	17.6	28.2	30.2

i	Training		Test		Validierung FLAC	
	lin. Reg. 1	lin. Reg. 2	lin. Reg. 1	lin. Reg. 2	lin. Reg. 1	lin. Reg. 2
R^2 [-]	0.989	0.990	0.981	0.982	0.974	0.966
MAE [m]	0.8	0.7	1.0	1.0	1.2	1.3
MAPE [-]	0.046	0.044	0.065	0.066	0.086	0.083
MSE [m ²]	1.3	1.1	2.0	1.9	2.8	3.6
RMSE [m]	1.1	1.1	1.4	1.4	1.7	1.9

Bei Betrachtung der berechneten **Modellgüte** bezüglich der **FLAC-Hold-Out-Validierung** zeigen sich ähnliche Muster wie während des Trainings und des Tests (siehe Tabelle 33 für genaue Werte). Vor allem bezüglich der Prognose der maximalen Setzung zeigte sich, dass unter Zuzug der verschiedenen E-Moduln des PH-Materialgesetzes und des Vorentlastungsfaktor die Modellgüte erheblich gesteigert werden konnte. Der R^2 -Wert und der RMSE des ANN 1a betrugen 0.334 bzw. 34.0 mm, wohingegen beim ANN 2a dieselben Gütemaße Werte von 0.784 bzw. 19.4 mm annahmen. Im Allgemeinen ist die Performance der ANN 2/a/b während der Hold-Out-Validierung bezüglich der maximalen Setzung als auch des Wendepunktabstands zufriedenstellend, während bei den einfacheren ANN 1/a/b nur die Prognose des Wendepunktabstandes hinreichend möglich war. Das verdeutlicht erneut, dass es für eine Anwendung eines ANN vor allem wichtig ist, eine sehr große Datenbasis mit aussagekräftigen Inputfeatures mit geringstmöglichen Unsicherheiten zu verwenden. In Kapitel 5.7 werden unter anderem gewisse Verbesserungen vorgeschlagen, wodurch in Zukunft die Performance eines ANN verbessert werden könnte.

Als Benchmark für die entwickelten ANN wurden auch **lineare Regressionsanalysen** durchgeführt, deren Modellgüte in Tabelle 34 ersichtlich ist. Im Generellen ist die Performance der linearen Regression im Vergleich zu den entwickelten ANN deutlich schlechter, jedoch konnten in Bezug auf den Wendepunktabstand annähernd dieselben Ergebnisse wie mit den ANN erzielt werden. Der Grund dafür ist die sehr starke Korrelation zwischen der Überdeckung C und dem Wendepunktabstand i in dem in dieser Arbeit durch FDM-Berechnungen erstellten Datenset. Gemäß den in Abb. 26 und Abb. 27 dargestellten Korrelationsmatrizen beträgt der Korrelationskoeffizient rund 0.98, was für einen sehr starken linearen Zusammenhang zwischen den betrachteten Variablen spricht, wodurch auch mittels der linearen Regression sehr gute Ergebnisse erzielt werden konnten.

In Bezug auf die maximalen Setzungen konnten mittels linearer Regression jedoch keine zufriedenstellenden Ergebnisse erzielt werden. Eine große Schwäche der linearen Regression ist die Tatsache, dass auch negative Werte (Hebungen) aufgetreten sind. Es zeigte sich klar, dass die Zusammenhänge zwischen den Inputfeatures und der Setzung zu komplex sind, um mit einem linearen Modell abgebildet werden zu können.

5.5.1 Single- und Multi-Output ANN

Sowohl mit den entwickelten Single-Output-ANN (1a/b, 2a/b) als auch mit den Multi-Output-ANN (1, 2) konnten in dieser Arbeit sehr gute Ergebnisse erzielt werden (siehe Tabelle 33 für genaue Werte). Der größte Unterschied zwischen der Performance der Single- und Multi-Output-ANN tritt bei der Hold-Out-Validierung zu Tage. Hier zeigt sich, dass die Prognose der maximalen Setzung durch ein Multi-Output-ANN bessere Ergebnisse liefert als ein Single-Output-ANN. Ein Multi-Output-ANN unterliegt der Annahme, dass die beiden Outputvariablen abhängig sind. Die Korrelationsmatrizen in Abb. 26 und Abb. 27 zeigen einen Korrelationskoeffizienten von rund 0.4 an.

In allen anderen Fällen erreicht oder übertrifft ein Single-Output-ANN jedoch die Performance der Multi-Output-ANN. Durch die einander sehr ähnliche Modellperformance kann keine Empfehlung, ob Single- oder Multi-Output-Architekturen besser geeignet sind, abgegeben werden. Hierfür wären weitere Untersuchungen nötig.

5.6 Feature Importance

Die berechneten Feature-Importance Werte (zur Theorie siehe Kapitel 3.2.7) geben einen Überblick über die Wichtigkeit der einzelnen Inputfeatures für den Erfolg der entwickelten ANN. In Tabelle 35 und Tabelle 36 sind die Ergebnisse der Feature-Importance-Berechnungen der unterschiedlichen ANN zusammengefasst. Da die berechneten SHAP- und Permutation-Importance-Werte unterschiedliche Skalen besitzen, geben die nachfolgenden Tabellen nur die Rangfolge der Input-Features wieder. Für eine genauere Betrachtung der Verhältnisse der einzelnen Features zueinander sei auf die Abbildungen verwiesen.

Tabelle 35: Feature-Importance Rangfolge der ANN 1/a/b

S_{vmax}	SHAP		Permutation
	ANN 1	ANN 1a	ANN 1a
Rang	Abb. 29	Abb. 33	Abb. 34
1	E [MPa]	E [MPa]	E [MPa]
2	D [m]	D [m]	D [m]
3	Vortriebsart [-]	Vortriebsart [-]	Vortriebsart [-]
4	c [kPa]	c [kPa]	c [kPa]
5	ϕ [°]	ϕ [°]	ϕ [°]
6	C/D [-]	C/D [-]	C [m]
7	C [m]	C [m]	C/D [-]

i	SHAP		Permutation
	ANN 1	ANN 1b	ANN 1b
Rang	Abb. 31	Abb. 36	Abb. 37
1	D [m]	C [m]	C [m]
2	C/D [-]	D [m]	D [m]
3	C [m]	C/D [-]	C/D [-]
4	E [MPa]	ϕ [°]	ϕ [°]
5	ϕ [°]	c [kPa]	E [MPa]
6	c [kPa]	E [MPa]	c [kPa]
7	Vortriebsart [-]	Vortriebsart [-]	Vortriebsart [-]

Tabelle 36: Feature-Importance Rangfolge der ANN 2/a/b

S_{vmax}	SHAP		Permutation
	ANN 2	ANN 2a	ANN 2a
Rang	Abb. 39	Abb. 43	Abb. 44
1	E_{oed}^{ref} [MPa]	E_{oed}^{ref} [MPa]	E_{oed}^{ref} [MPa]
2	E_{ur}^{ref} [MPa]	Lambda [-]	ϕ [°]
3	Lambda [-]	E_{ur}^{ref} [MPa]	D [m]
4	D [m]	ϕ [°]	Lambda [-]
5	ϕ [°]	D [m]	E_{50}^{ref} [MPa]
6	E_{50}^{ref} [MPa]	c [kPa]	c [kPa]
7	C [m]	E_{50}^{ref} [MPa]	E_{ur}^{ref} [MPa]
8	C/D [-]	C [m]	γ [kg/m ³]
9	c [kPa]	C/D [-]	Vortriebsart [-]
10	γ [kg/m ³]	γ [kg/m ³]	C [m]
11	Vortriebsart [-]	Vortriebsart [-]	C/D [-]

i	SHAP		Permutation
	ANN 2	ANN 2b	ANN 2b
Rang	Abb. 41	Abb. 46	Abb. 47
1	D [m]	C [m]	C [m]
2	C/D [-]	D [m]	D [m]
3	C [m]	C/D [-]	C/D [-]
4	E_{oed}^{ref} [MPa]	E_{ur}^{ref} [MPa]	E_{ur}^{ref} [MPa]
5	E_{ur}^{ref} [MPa]	Lambda [-]	E_{50}^{ref} [MPa]
6	Lambda [-]	c [kPa]	Lambda [-]
7	E_{50}^{ref} [MPa]	E_{50}^{ref} [MPa]	c [kPa]
8	ϕ [°]	E_{oed}^{ref} [MPa]	E_{oed}^{ref} [MPa]
9	γ [kg/m ³]	γ [kg/m ³]	γ [kg/m ³]
10	c [kPa]	ϕ [°]	ϕ [°]
11	Vortriebsart [-]	Vortriebsart [-]	Vortriebsart [-]

Die Zusammenstellungen in Tabelle 35 und Tabelle 36 zeigen einen großen Unterschied in der Feature-Importance bezüglich des Wendepunktabstands i zwischen den Single- und Multi-Output-ANN. Bei den zwei Multi-Output-ANN (ANN 1, 2) bestimmt der komplexere Zusammenhang zwischen den Inputfeatures und der maximalen Setzung die Gewichte des ANN stärker als der Zusammenhang mit dem Wendepunktabstand. Die ANN konzentrieren sich während des Trainings dadurch gleichmäßiger auf die verschiedenen Inputfeatures. Dadurch wird der sehr starke lineare Zusammenhang zwischen der Überdeckung C und dem Wendepunktabstand i schwächer berücksichtigt. Das spiegelt sich in weiterer Folge in den Feature-Importance-Werten der Multi-Output-ANN bezüglich des Wendepunktabstands wider. Zur Beurteilung der relativen Wichtigkeit der Inputfeatures sind somit die Single-Output-ANN besser geeignet, weswegen der Fokus der anschließenden Ausführungen auf diese gelegt wird.

Auch zwischen den verwendeten Methoden der Feature-Importance-Berechnung – SHAP-Werten und dem Permutation-Importance-Wert – ergeben sich Unterschiede in der Rangfolge der wichtigsten Features, jedoch nur in einem untergeordneten Ausmaß. Die Größenordnung der Beiträge der Features ist bei beiden Vorgehensweisen indes sehr ähnlich.

Die **wichtigsten Inputfeatures** bezüglich der **maximalen Setzung** sind bei den einfachen ANN (1, 1a) der Elastizitätsmodul, der Tunneldurchmesser und die Vortriebsart. Der Parameter Vortriebsart umfasst in diesem Fall sowohl indirekt die Vorentlastungsfaktoren als auch die Tunnelsicherungsmaßnahmen. Bei den komplexeren ANN (2, 2a) sind die wichtigsten Features zwischen den verschiedenen ANN unterschiedlicher, jedoch zeigt sich auch hier ein eindeutiger Trend. Auch hier sind die Elastizitätsmoduln E_{oed}^{ref} , E_{ur}^{ref} , E_{50}^{ref} , der **Vorentlastungsfaktor** λ , der **Reibungswinkel** ϕ , der **Tunneldurchmesser** D sowie die **Kohäsion** c unter den wichtigsten Parametern.

Die ermittelten Features stimmen mit den Erwartungen überein. Der Elastizitätsmodul bestimmt die Steifigkeit des Bodens. Bei höheren Werten ist dadurch mit weniger Setzungen zu rechnen. Der Durchmesser beeinflusst durch seine Größe den betroffenen Bereich der Spannungsumlagerungen im Boden. Bei größeren Durchmessern ist ein größerer Teil des zuvor ungestörten Bodens von den Spannungsumlagerungen betroffen. Das Bruchverhalten des Bodens wird u.a. durch die Kohäsion und den Reibungswinkel beeinflusst, weswegen auch diese Parameter wichtig für das Setzungsverhalten sind. Durch den Vorentlastungsfaktor (bzw. bei den einfachen ANN nur die Vortriebsart) wird der Baubetrieb des Tunnels simuliert und die Größe der zugelassenen Spannungsumlagerungen festgelegt, wodurch auch dieses Feature von großer Wichtigkeit auf das Setzungsverhalten ist.

Keinen großen Einfluss auf die Performance der ANN bezüglich der maximalen Setzung hatten die Dichte des Bodens, die Tunnelsicherungsmaßnahmen sowie die Geometrieparameter der Überdeckung sowie das Überdeckungsverhältnis. Anzumerken ist

jedoch, dass ein etwaiges Weglassen der von den Feature-Importance-Methoden als weniger wichtig bestimmten Parametern die Performance der ANN nichtsdestotrotz verschlechtern würde, wenn auch in einem untergeordneten Ausmaß.

In Bezug auf den **Wendepunktstand** sind bei allen entwickelten ANN die **wichtigsten Inputfeatures** die Geometrieparameter der **Überdeckung**, der **Tunneldurchmesser** sowie das **Überdeckungsverhältnis**. Erst danach folgen die Bodenparameter in Form des Elastizitätsmoduls und des Reibungswinkels. Die restlichen Features sind für den Erfolg der ANN nur von geringer Bedeutung.

Vor allem die Überdeckung erreicht sehr hohe Feature-Importance-Werte und ist sehr wichtig für die Performance der ANN. Diese Tatsache deckt sich sehr gut mit der u.a. von O'Reilly und New (1982) oder Mair und Taylor (1997) (siehe Kapitel 2.2.4.3.1) nach Analyse von Felddaten festgestellten Abhängigkeit des Wendepunktstands von der Überdeckung. In Relation gebracht werden diese zwei Parameter durch die Multiplikation mit einem bodenspezifischen empirischen Faktor. Auch dies deckt sich mit den durch die Feature-Importance-Berechnungen ermittelten Inputfeatures.

Die Ergebnisse der Feature-Importance-Berechnungen zeigen, dass für eine gute Performance eines ANN zur Prognose von tunnelbaubedingten Setzungen vor allem die genaue versuchstechnische Bestimmung der Bodenparameter notwendig ist. Für zukünftige Anwendungen und Verbesserungen ist es daher sinnvoll, Zeit und Kosten in gute Laboruntersuchungen der Böden bzw. in die Suche nach publizierten Ergebnissen davon zu investieren, um genauere FDM-Berechnungen durchführen zu können und um somit in weiterer Folge ein gut performendes ANN trainieren zu können.

5.7 Ausblick und Verbesserungen

Im folgenden Abschnitt werden kurz einige Strategien beschrieben, wie in Zukunft die Setzungsprognose im Tunnelbau mittels ANN besser vonstattengehen könnten:

Im Allgemeinen funktionieren ML-Techniken besser, je **mehr Daten** verfügbar sind. Hierzu wäre es förderlich neben einer großen Datenbank an FE/FDM-Berechnungen auch möglichst viele Daten von realen Tunnelbauprojekten zu haben, um einerseits die Qualität der numerischen Berechnungen besser beurteilen zu können und andererseits diese Daten auch in das Training des ANN miteinfließen zu lassen.

Bei der Erstellung bzw. der Vergrößerung der FE/FDM-Datenbank sollte darauf geachtet werden, **möglichst viele verschiedene Bodenparameter** zu verwenden. In dieser Arbeit stammen die verwendeten Bodenparameter aus publizierten Laboruntersuchungen, weswegen nur zehn verschiedene Böden (siehe Kapitel 3.1.5) in die Analyse miteinfließen. Da es keine unbegrenzte Anzahl an veröffentlichten Versuchsauswertungen gibt und eine eigene Laboruntersuchung verschiedener Böden zeit- und kostenintensiv ist, könnte ein Ansatz sein, Böden innerhalb sinnvoller, aus der Literatur stammender Grenzen zufällig zu generieren. Durch die Verwendung einer größeren Anzahl unterschiedlicher Böden, würde der ANN an Generalisierungsfähigkeit gewinnen, was sich vor allem auf die Performance der Hold-Out-Validierung bzw. einer möglichen realen Anwendung z.B. in der Vorstudienphase positiv auswirken würde.

Auch das Miteinbeziehen von unterschiedlicheren **Geometriekombinationen** würde die Generalisierungsfähigkeit verbessern. In dieser Arbeit wurden Grenzen für den Tunneldurchmesser und für das Überdeckungsverhältnis definiert (siehe Kapitel 3.1.10), wodurch keine tieferliegenden Tunnel mit kleinem Durchmesser berücksichtigt wurden. In Zukunft könnten diese Geometriekombinationen jedoch betrachtet werden.

Eine Anwendbarkeit in einem breiteren Feld würde durch die **Berücksichtigung des Grundwassereinflusses** sowie von **Bodenschichtungen** gelingen. Die Schichthöhen und der Grundwasserstand könnten z.B. jeweils durch die Relation zur Überdeckungshöhe als zusätzliche **Inputfeatures** des ANN dienen. Bei der Erstellung der Datenbank könnten diese Relationskennwerte wiederum mit einem Zufallszahlengenerator erzeugt werden. Zusätzlich

könnten auch die Dicke des **Tunnelausbaus** und der **Elastizitätsmodul des Betons** als weitere Inputfeatures dienen. Hierbei wäre es bei den FDM-Berechnungen wichtig, nicht immer dieselben Werte zu verwenden, sondern den Tunnelausbau innerhalb sinnvoller Grenzwerte zu modellieren.

Die größten Unsicherheiten der 2D-FDM-Berechnungen liegen, wie in Kapitel 5.1 beschrieben, bei der Wahl des richtigen Vorentlastungsfaktors. Um diesen Einfluss zu minimieren, könnte in Zukunft bei der Datenbankerstellung eine **dreidimensionale oder axisymmetrische Kalibrierung des Vorentlastungsfaktors** ausgewählter Boden- und Geometriekombinationen durchgeführt werden, um somit ein tieferes Verständnis für die richtige Wahl des Vorentlastungsfaktors zu erlangen. Eine weitere Möglichkeit wäre es, pro Boden- und Geometriekombination mehrere FDM-Berechnungen mit unterschiedlichen Vorentlastungsfaktoren durchzuführen, um eine breitere Datengrundlage für den ANN zu haben.

6 Conclusio

In dieser Arbeit wurde die Anwendbarkeit von Artificial Neural Networks (ANN) - einer Methode der künstlichen Intelligenz - zur Prognose von tunnelbaubedingten Oberflächensetzungen aufbauend auf einer Datenbank von numerischen Berechnungen untersucht.

Die einzelnen Setzungsberechnungen wurden zweidimensional mit dem Finite-Differenzen-Programm FLAC3D durchgeführt, wobei zur Berücksichtigung der dreidimensionalen Effekte während des Tunnelvortriebs die Convergence-Confinement-Methode angewandt wurde, bei der die Größe der erwarteten Spannungsumlagerungen mittels eines Vorentlastungsfaktors definiert wird. Als Materialgesetz des Bodens wurde das Plastic-Hardening-Materialgesetz verwendet, da dieses spannungsabhängig ist, wodurch realistischere Setzungsverläufe zu erwarten sind. Die Bodenparameter stammen aus publizierten Beispielen. Für die Tunnelüberdeckung und den Tunneldurchmesser wurden anhand von Literaturbeispielen sinnvolle Grenzen gewählt; die Zuweisung der einzelnen Werte und auch der Böden geschah mithilfe eines Zufallszahlengenerators, um somit eine möglichst breit gestreute und unabhängige Datengrundlage für die Machine Learning Anwendung zu erschaffen. Insgesamt besteht die Setzungsdatenbank aus 280 Einträgen, wobei je die Hälfte als TVM- und als NATM-Tunnel, welche sich durch die verwendeten Vorentlastungsfaktoren sowie die Modellierung des Tunnelausbaus unterschieden, modelliert wurde.

Anschließend wurden sechs verschiedene ANN mithilfe der Python-Bibliothek TensorFlow entwickelt, wobei sowohl die Zahl der Inputfeatures als auch die Netzwerkarchitektur an sich variiert wurde. Die gesuchten Outputparameter der ANN waren die maximale Oberflächensetzung S_{vmax} sowie der Wendepunktabstand der horizontalen Setzungsmulde i . Als Inputfeatures dienten für die einfacheren Netzwerke (ANN 1, 1a, 1b) die Vortriebsart, Kohäsion, Reibungswinkel, Elastizitätsmodul, Tunnelüberdeckung, Tunneldurchmesser sowie das Überdeckungsverhältnis. Für die komplexeren ANN (2, 2a, 2b) wurden anstatt eines Elastizitätsmoduls die Elastizitätsmoduln des Plastic-Hardening-Materialgesetzes E_{50}^{ref} , E_{oed}^{ref} und E_{ur}^{ref} verwendet sowie zusätzlich die Dichte des Bodens und der Vorentlastungsfaktor der Convergence-Confinement-Methode als Inputfeatures hinzugefügt. Im Zuge dieser Arbeit wurde auch untersucht, ob der Netzwerkaufbau als Multi-Output- bzw. Single-Output-Regressionsproblem, also ob beide Outputparameter mit einem ANN prognostiziert werden oder ob für jeden Parameter ein eigenes Netzwerk entwickelt wird, einen nennenswerten Einfluss auf die Modellperformance hat.

Vor der Entwicklung der ANN wurde das Gesamtdatenset in ein Trainings-, Test- sowie Validierungsset eingeteilt, wobei 63 % für das Training, 27 % für den Test und die restlichen 10 % für die Hold-Out-Validierung verwendet wurden. Für die Hold-Out-Validierung wurden zuvor die Einträge zweier verschiedener Bodenarten manuell ausgewählt, um die Generalisierungsfähigkeit der ANN für zuvor noch nicht gesehene Bodenarten zu testen. Die Suche nach den optimalen Netzwerkarchitekturen wurde durch systematisches Variieren der Modellhyperparameter innerhalb selbst definierter Grenzen durchgeführt. Zur Bestimmung der Modellperformance und im Weiteren zur Bestimmung der besten Modelle wurden die statistischen Gütemaße R^2 , MAE, MAPE, MSE und RMSE herangezogen. Abschließend wurden die Inputfeatures, welche am meisten zu einer guten Modellperformance beitragen, bestimmt.

Die Resultate zeigen eine hohe Übereinstimmung im Trainings- und Testset zwischen den numerisch berechneten und den mittels Machine Learning prognostizierten Setzungen vor allem für die komplexeren ANN mit mehr und gleichzeitig auch aussagekräftigeren Inputparametern. Bei der Hold-Out-Validierung reduziert sich die Modellperformance erwartungsgemäß, befindet sich jedoch bei den komplexeren ANN (2, 2a, 2b) in einem annehmbaren Genauigkeitsbereich. Die Generalisierungsfähigkeit der entwickelten ANN ist somit gegeben. Bezüglich der Multi-Output- bzw. Single-Output-Regressionsproblematik kann keine eindeutige Empfehlung abgegeben werden, da, abgesehen von der Performance am

Validierungsset, sich keine großen Unterschiede aufgetan haben und mit beiden Netzwerkaufbauten sehr ähnliche Ergebnisse erzielt werden konnten. Als wichtigste Inputfeatures wurden bezüglich der maximalen Setzung die Elastizitätsmoduln des Plastic-Hardening-Materialgesetzes, der Reibungswinkel sowie der Tunneldurchmesser; bezüglich des Wendepunktabstands die Überdeckung, der Durchmesser, das Überdeckungsverhältnis sowie die Elastizitätsmoduln ausgemacht.

Limitierend für die Aussagekräftigkeit der präsentierten Untersuchung ist vor allem die Qualität der zweidimensionalen Finiten-Differenzen-Setzungsberechnungen mithilfe der Convergence-Confinement-Methode, da die Wahl des richtigen Vorentlastungsfaktors schwer zu bewerkstelligen ist. Axisymmetrische oder dreidimensionale Testberechnungen könnten in Zukunft bei der richtigen Kalibrierung helfen. Um eine gute Generalisierungsfähigkeit von ANN zur Voraussage von tunnelbaubedingten Setzungen zu gewährleisten, ist es für zukünftige Anwendungen wichtig, eine möglichst große Datenbank mit breit gestreuten Geometrie- und Bodenparameterkombinationen zur Verfügung zu haben, wobei bei Fehlen von Versuchsauswertungen die Bodenparameter innerhalb sinnvoller Grenzen per Zufallszahlengenerator modelliert werden könnten. In Zukunft könnten durch die Berücksichtigung des Grundwassereinflusses sowie von Bodenschichtungen neue Erkenntnisse gewonnen und Anwendungen in einem breiteren Feld ermöglicht werden. Abschließend sei gesagt, dass ein ANN nur so gut sein kann, wie es die zugrundeliegenden Daten erlauben. Wenn Daten von hoher Qualität in einem ausreichend großen Umfang zur Verfügung stehen, sind ANN oder auch andere Machine Learning Techniken geeignet, die komplexen Zusammenhänge in geotechnischen Fragestellungen zu erkennen und gute Prognosen zu treffen.

7 Literaturverzeichnis

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G.S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., Mane, D., Monga, R., Moore, S., Murray, D., Olah, C., Schuster, M., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viegas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y. & Zheng, X., 2015. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems*. Google Research: Software available from tensorflow.org.
- Adoko, A.-C., Jiao, Y., Wu, L., Wang, H. & Wang, ZH., 2013. Predicting tunnel convergence using Multivariate Adaptive Regression Spline and Artificial Neural Network. *Tunnelling and Underground Space Technology*, 38, S. 368-376.
- Armaghani, D. J., Mohamad, E.T., Narayanasamy, M.S., Narita, N. & Yagiz, S., 2017. Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition. *Tunnelling and Underground Space Technology*, 63, S. 29-43.
- Attewell, P., Yeates, J. & Selby, A., 1986. *Soil Movements Induced By Tunnelling and Their Effects On Pipelines and Structures..* London: Blackies and Sons Ltd.
- Bouayad, D. & Emeriault, F., 2017. Modeling the relationship between ground surface settlements induced by shield tunneling and the operational and geological parameters based on the hybrid PCA/ANFIS method. *Tunnelling and Underground Space Technology*, 68, S. 142-152.
- Breiman, L., 2001. Random Forests. *Machine Learning*, 45(1), S. 5-32.
- Brownlee, J., 2020. *A Gentle Introduction to the Rectified Linear Unit (ReLU)*. [Online] Available at: <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/> [Zugriff am 17.09.2021].
- Cai, M., 2008. Influence of stress path on tunnel excavation response – Numerical tool selection and modeling strategy. *Tunnelling and Underground Space Technology*, 23(6), S. 618-628.
- Carranza-Torres, C. & Fairhurst, C., 2000. Application of the Convergence-Confinement Method of Tunnel Design to Rock Masses That Satisfy the Hoek-Brown Failure Criterion. *Tunnelling and Underground Space Technology*, 15(2), S. 187-213.
- Cheng, Z. & Detournay, C., 2016. Plastic hardening model I: Implementation in FLAC3D. *Applied Numerical Modeling in Geomechanics*, S. 267-276.
- Chollet, F., 2015. *Keras*. Software available from <https://keras.io>
- Chollet, F., 2018. *Deep Learning with Python*. Shelter Island, NY: Manning Publications Co..
- Chou, W.-I. & Bobet, A., 2002. Predictions of ground deformations in shallow tunnels in clay. *Tunnelling and Underground Space Technology*, 17, S. 3-17.
- Do, N. A. & Dias, D., 2017. A comparison of 2D and 3D numerical simulations of tunnelling in soft soils. *Environmental Earth Sciences*, 76(3), S. 1-12.
- Do, N.-A., Dias, D., Oreste, P. & Djeran-Maigre, I., 2014. 2D Tunnel Numerical Investigation: The Influence of the Simplified Excavation Method on Tunnel Behaviour. *Geotechnical and Geological Engineering*, 32(1), S. 43–58.
- Ebid, A. M., 2021. 35 Years of (AI) in Geotechnical Engineering: State of the Art. *Geotechnical and Geological Engineering*, 39(2), S. 637–690.

- Erzin, Y., Gumaste, S., Gupta, A. & Singh, D., 2009. Artificial neural network (ANN) models for determining hydraulic conductivity of compacted fine-grained soils. *Canadian Geotechnical Journal*, 46(8), S. 955-968.
- Fillibeck, J., 2012. *Oberflächensetzungen beim Tunnelvortrieb in Lockergestein - Prognose, Messung und Beeinflussung*. München: Technische Universität München.
- Fischer, O., Nevrlý, T. & Behnen, G., 2014. Fertigteile im Tunnelbau. In: Bergmeister, K., Fingerloos, F. & Wörner, J., (Hrsg.) *Beton-Kalender 2014: Unterirdisches Bauen, Grundbau, Eurocode 7..* Berlin: Ernst & Sohn GmbH & Co. KG, S. 233-302.
- Franza, A. & Marshall, A. M., 2019. Empirical and semi-analytical methods for evaluating tunnelling-induced ground movements in sands. *Tunnelling and Underground Space Technology*, 88, S. 47-62.
- Fu, Y., He, S., Zhang, S. & Yang, Y., 2020. Parameter Analysis on Hardening Soil Model of Soft Soil for Foundation Pits Based on Shear Rates in Shenzhen Bay, China. *Advances in Materials Science and Engineering*, 2020, S. 1-11.
- Galler, R., 2014. Der zyklische Vortrieb von der Planung bis zur Ausführung – ein zusammenfassender Überblick. In: Bergmeister, K., Fingerloos, F. & Wörner, J., (Hrsg.) *Beton-Kalender 2014: Unterirdisches Bauen, Grundbau, Eurocode 7..* Berlin: Ernst & Sohn GmbH & Co. KG, S. 87-120.
- Géron, A., 2019. *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. 2.Auflage. Sebastopol, CA: O'Reilly Media, Inc..
- Glorot, X. & Bengio, Y., 2010. Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, PMLR*, 9, S. 249-256.
- Goh, A. & Zhang, W., 2012. Reliability assessment of stability of underground rock caverns. *International Journal of Rock Mechanics & Mining Sciences*, 55, S. 157-163.
- Goh, A., Zhang, W., Zhang, Y., Xiao, Y. & Xiang, Y., 2018. Determination of earth pressure balance tunnel-related maximum surface settlement: a multivariate adaptive regression splines approach. *Bulletin of Engineering Geology and the Environment*, 77(2), S. 489-500.
- Govindasamy, D., Ismail, M. A. M., Zaki, M. F. M. & Abidin, M. H. Z., 2019. Calibration of stiffness parameters for Hardening Soil Model in residual soil from Kenny Hill Formation. *Bulletin of the Geological Society of Malaysia*, 67, S. 119-125.
- Haenlein, M. & Kaplan, A., 2019. A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), S. 5–14.
- Harris, C. R., Millman, K.J., van der Walt, S.J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N.J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M.H., Brett, M., Haldane, A., Fernández del Río, J., Wiebe, M., Peterson, P., Gérard-Marchant, P., Sheppard, K., Reddy, T., Weckesser, W., Abbasi, H., Gohlke, C. & Oliphant, T.E., 2020. Array programming with NumPy. *Nature*, 585(7825), p. 357–362.
- Hasanipanah, M., Noorian-Bidgoli, M., Armaghani, D. J. & Khamesi, H., 2016. Feasibility of PSO-ANN model for predicting surface settlement caused by tunneling. *Engineering with Computers*, 32(4), S. 705-715.
- He, K., Zhang, X., Ren, S. & Sun, J., 2015. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *IEEE International Conference on Computer Vision (ICCV 2015)*, S. 1026-1034.
- Hendrycks, D. & Gimpel, K., 2016. Gaussian Error Linear Units (GELUs). *eprint arXiv:1606.08415*, S.1-9.

- Hunter, J. D., 2007. Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), S. 90-95.
- Ismail, A. & Jeng, D.-S., 2011. Modelling load–settlement behaviour of piles using high-order neural network (HON-PILEmodel). *Engineering Applications of Artificial Intelligence*, 24(5), S. 813–821.
- ITA-AITES, 2007. ITA/AITES Report 2006 on Settlements induced by tunneling in Soft Ground. *Tunnelling and Underground Space Technology*, 22, S. 119–149.
- Itasca Consulting Group, Inc, 2015. *FLAC 8 Basics: An introduction to FLAC 8 and a guide to its practical application in geotechnical engineering*. Minneapolis: Itasca Consulting Group, Inc.
- Itasca Consulting Group, Inc , 2017. *FLAC3D - Fast Lagrangian Analysis of Continua in Three-Dimensions, Ver. 6.0*. Minneapolis: Itasca Consulting Group, Inc.
- Itasca Consulting Group, Inc , 2019a. *FLAC3D - Fast Lagrangian Analysis of Continua in Three-Dimensions, Ver. 7.0: Formulation of a 3D Explicit Finite Volume Model*. [Online] Available at: <http://docs.itascacg.com/flac3d700/flac3d/docproject/source/theory/theoreticalbackground/formulation.html/> [Zugriff am 19 01 2022].
- Itasca Consulting Group, Inc , 2019b. *FLAC3D - Fast Lagrangian Analysis of Continua in Three-Dimensions, Ver. 7.0: Plastic-Hardening (PH) Model*. [Online] Available at: <http://docs.itascacg.com/flac3d700/common/models/hardening/doc/modelhardening.html?highlight=plastic%20hardening> [Zugriff am 19 01 2022].
- James, G., Witten, D., Hastie, T. & Tibshirani, R., 2013. *An Introduction to Statistical Learning: With Applications in R*. New York: Springer.
- Janin, J., Dias, D., Emeriault, F., Kastner, R., Le Bissonnais, H. & Guilloux, A., 2015. Numerical back-analysis of the southern Toulon tunnel measurements: A comparison of 3D and 2D approaches. *Engineering Geology*, 195, S. 42-52.
- Karakuş, M., 2007. Appraising the methods accounting for 3D tunnelling effects in 2D plane strain FE analysis. *Tunnelling and Underground Space Technology*, 22(1), S. 47-56.
- Kim, C.Y., Bae, G.J., Hong, S.W., Park, C.H., Moon, H.K. & Shin, H.S., 2001. Neural network based prediction of ground surface settlements due to tunnelling. *Computers and Geotechnics*, 28(6-7), S. 517–547.
- Kingma, D. P. & Ba, J., 2015. Adam: A Method for Stochastic Optimization. *eprint arXiv:1412.6980*, S. 1-15
- Klai, M., Bouassida, M. & Tabchouche, S., 2015. Numerical modelling of Tunis soft clay. *Geotechnical Engineering Journal of the SEAGS & AGSSEA*, 46(4), S. 1-9.
- Korobov, M. & Lopuhin, K., 2017. *Eli5*. [Online] Available at: <https://eli5.readthedocs.io/en/latest/index.html#> [Zugriff am 5 11 2021].
- Leca, E., 2001. Conception et dimensionnement du béton projeté utilisé en travaux souterrains. *Tunnels et ouvrages souterrains*, 165, S. 68-89.
- Leu, S.-S. & Lo, H.-C., 2004. Neural-network-based regression model of ground surface settlement induced by deep excavation. *Automation in Construction*, 13(3), S. 279-289.
- Lundberg, S. M. & Lee, S.-I., 2017. A Unified Approach to Interpreting Model Predictions. *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems*, S. 4768–4777.
- Mair, R. J., 1996. Settlement effects of bored tunnels. *Geotechnical Aspects of Underground Construction in Soft Ground*, S. 43-53.

- Mair, R. & Taylor, R., 1997. Bored tunnelling in the urban environment. *14th international Conference on Soil Mechanics and Foundation Engineering*, S. 2353–2385.
- McKinney, W., 2010. Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference*, S. 56-61.
- Meschke, G., Alsahly, A., Dang, T.S., Freitag, S., Gall, V.E., Ninić, J., Stascheit, J. & Zhou, M., 2014. Numerische Simulation im Tunnelbau. In: Bergmeister, K., Fingerloos, F. & Wörner, J., (Hrsg.) *Beton-Kalender 2014: Unterirdisches Bauen, Grundbau, Eurocode 7*. Berlin: Ernst & Sohn GmbH & Co. KG, S. 171-232.
- Mohammadi, S., Naseri, F. & Alipoor, S., 2015. Development of artificial neural networks and multiple regression models for the NATM tunnelling-induced settlement in Niayesh subway tunnel, Tehran. *Bulletin of Engineering Geology and the Environment*, 74(3), S. 827–843.
- Möller, S. C., 2006. *Tunnel induced settlements and structural forces in linings: Mitteilung 54 des Instituts für Geotechnik der Universität Stuttgart*. Stuttgart: Institut für Geotechnik der Universität Stuttgart.
- Momeni, E., Maizir, H., Gofar, N. & Nazir, R., 2013. Comparative Study on Prediction of Axial Bearing Capacity of Driven Piles in Granular Materials. *Jurnal Teknologi*, 61(3), S. 15-20.
- Nsubuga, S., Tsakiri, M. & Tsakiri, V., 2021. A smart decision tool for the prediction of tunnel crown displacements. *Applied Geomatics*, 13(1), S. 77-91.
- Obrzud, R. F. & Truty, A., 2018. *THE HARDENING SOIL MODEL - A PRACTICAL GUIDEBOOK*. Préverenges, Schweiz: Zace Services Ltd, Software engineering.
- Ocak, İ. & Şeker, Ş. E., 2013. Calculation of surface settlements caused by EPBM tunneling using artificial neural network, SVM, and Gaussian processes. *Environmental Earth Sciences*, 70(3), S. 1263–1276.
- ÖNORM EN 1991-1-1:2011 09 01, 2011. *Eurocode 1: Einwirkungen auf Tragwerke - Teil 1-1: Allgemeine Einwirkungen - Wichten, Eigengewicht und Nutzlasten im Hochbau (konsolidierte Fassung)*. Wien: Austrian Standards Institute.
- ÖNORM EN 1992-1-1:2015 02 15, 2015. *Eurocode 2: Bemessung und Konstruktion von Stahlbeton- und Spannbetontragwerken - Teil 1-1: Allgemeine Bemessungsregeln und Regeln für den Hochbau (konsolidierte Fassung)*. Wien: Austrian Standards Institute.
- O'Reilly, M. & New, B., 1982. Settlements above tunnels in the United Kingdom – their magnitude and prediction. *Tunnels & tunnelling international*, 82, S. 173-181.
- Panet, M., 1995. *Le calcul des tunnels par la méthode convergence-confinement*. Paris: Presses de l'Ecole nationale des ponts et chaussées.
- Park, K.-H., 2005. Analytical solution for tunnelling-induced ground movement in clays. *Tunnelling and Underground Space Technology*, 20(3), S. 249-261.
- Peck, R. B., 1969. Deep Excavation and Tunneling in Soft Ground: State-of-the-Art Report. *Proceedings of the 7th International Conference on Soil Mechanics and Foundation Engineering, Mexico*, S. 225-290.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. & Duchesnay, E., 2011. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), S. 2825–2830.
- PLAXIS, 2021. *Material Models Manual: CONNECT Edition V21.01*. Delft: Bentley

- Poulos, H. G. & Loganathan, N., 1998. Analytical Prediction for Tunneling-Induced Ground Movements in Clays. *Journal of Geotechnical and Geoenvironmental Engineering*, 124(9), S. 846-856.
- Pramthawee, P., Jongpradist, P. & Kongkitkul, W., 2011. Evaluation of hardening soil model on numerical simulation of behaviors of high rockfill dams. *Songklanakarin Journal of Science and Technology*, 33(3), S. 325-334.
- Rossum, G., 2021. *The Python Language Reference: Release 3.8.12*. Beaverton, OR: Python Software Foundation.
- Sagaseta, C., 1987. Analysis of undrained soil deformation due to ground loss. *Geotéchnique*, 37(3), S. 301-320.
- Saleh, S., Yunus, N. Z. M., Ahmad, K. & Said, K. N. M., 2021. Numerical simulation with hardening soil model parameters of marine clay obtained from conventional tests. *SN Applied Sciences*, 3(2), S. 1-13.
- Samui, P., 2008. Slope stability analysis: a support vector machine approach. *Environmental Geology*, 56(2), S. 255-267.
- Schanz, T., Vermeer, P. & Bonnier, P., 1999. The hardening soil model: Formulation and verification. In: R. Brinkgreve, Hrsg. *Beyond 2000 in Computational Geotechnics - 10 Years of PLAXIS*. Rotterdam: Balkema, S. 281-296.
- Scharinger, F., Schweiger, H. & Galavi, V., 2016. FE-analysis of deep excavations in lacustrine clay with different constitutive models. *Proceedings of the 16th International Conference on Soil Mechanics and Geotechnical Engineering*, S. 971-974.
- Schmidt, B., 1969. *Settlements and ground movements associated with tunneling in soils*. Dissertation, University of Illinois, Urbana.
- scikit-learn, 2021. *scikit-learn: Permutation feature importance*. [Online] Available at: https://scikit-learn.org/stable/modules/permutation_importance.html [Zugriff am 5 11 2021].
- Shahin, M. A., Maier, H. R. & Jaksa, M. B., 2002. Predicting Settlement of Shallow Foundations using Neural Networks. *Journal of Geotechnical and Geoenvironmental Engineering*, 128(9), S. 785-793.
- Sharifzadeh, M., Kolivand, F., Ghorbani, M. & Yasrobi, S., 2013. Design of sequential excavation method for large span urban tunnels in soft ground – Niayesh tunnel. *Tunnelling and Underground Space Technology*, 35, S. 178-188.
- Shi, J., Ortigao, J. & Bai, J., 1998. Modular Neural Networks for Predicting Settlements during Tunneling. *Journal of Geotechnical and Geoenvironmental Engineering*, 124(5), S. 389-395.
- Surarak, C., Likitlersuan, S., Wanatowski, D., Balasubramaniam, A., Oh, E. & Guan, H., 2012. Stiffness and strength parameters for hardening soil model of soft and stiff Bangkok clays. *Soils and Foundations*, 54(4), S. 682-697.
- Suwansawat, S., 2002. *Earth pressure balance (EPB) shield tunneling in Bangkok : ground response and prediction of surface settlements using artificial neural networks*. Dissertation, Massachusetts Institute of Technology, Cambridge, MA.
- Suwansawat, S. & Einstein, H., 2006. Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunneling. *Tunnelling and Underground Space Technology*, 21(2), S. 133-150.
- Svoboda, T. & Masin, D., 2009. Comparison of displacement field predicted by 2D and 3D finite element modelling of shallow NATM tunnels in clays. *Geotechnik*, 34(2), S. 115-126.

-
- Thewes, M., 2014. Tunnelbau im Schildvortrieb – Verfahrenstechniken und Planungsgrundlagen. In: Bergmeister, K., Fingerloos, F. & Wörner, J., (Hrsg.) *Beton-Kalender 2014: Unterirdisches Bauen, Grundbau, Eurocode 7*. Berlin: Ernst & Sohn GmbH & Co. KG, S. 121-170.
- Unlu, T. & Gerçek, H., 2003. Effect of Poisson's ratio on the normalized radial displacements occurring around the face of a circular tunnel. *Tunnelling and Underground Space Technology*, 18(5), S. 547-553.
- Verruijt, A., 1998. Deformations of an elastic half plane with a circular cavity. *International Journal of Solids and Structures*, 35(21), S. 2795-2804.
- Verruijt, A. & Booker, J., 1996. Surface settlements due to deformation of a tunnel in an elastic half plane. *Géotechnique*, 46(4), S. 753-756.
- Vlachopoulos, N. & Diederichs, M., 2009. Improved Longitudinal Displacement Profiles for Convergence Confinement Analysis of Deep Tunnels. *Rock Mechanics and Rock Engineering*, 42(2), S. 131–146.
- Vlachopoulos, N. & Diederichs, M. S., 2014. Appropriate Uses and Practical Limitations of 2D Numerical Analysis of Tunnels and Tunnel Support Response. *Geotechnical and Geological Engineering*, 32(2), S. 469–488.
- Wang, X., Lu, H., Wei, X., Wei, G., Behbahani, S.S. & Iseley, T., 2020. Application of Artificial Neural Network in Tunnel Engineering: A Systematic Review. *IEEE Access*, 8, S. 119527-119543.
- Waskom, M. L., 2021. seaborn: statistical data visualization. *The Journal of Open Source Software*, 6(60), S. 1-4.
- Zhang, W., Zhang, R., Wu, C., Goh, A.T.C., Lacasse, S., Liu, Z. & Liu, H., 2020. State-of-the-art review of soft computing applications in underground excavations. *Geoscience Frontiers*, 11(4), S. 1095–1106.
- Zhang, Z., Zhang, M., Jiang, Y., Bai, Q. & Zhao, Q., 2017. Analytical prediction for ground movements and liner internal forces induced by shallow tunnels considering non-uniform convergence pattern and ground-liner interaction mechanism. *Soils and Foundations*, 57(2), S. 211-226.
- Zhou, J., Shi, X., Du, K., Qiu, X., Li, X. & Mitri, H.S., 2017. Feasibility of Random-Forest Approach for Prediction of Ground Settlements Induced by the Construction of a Shield-Driven Tunnel. *International journal of geomechanics*, 17(6), S. 04016129-1 - 04016129-12.

8 Anhang A: FLAC-Berechnungsfile Beispiel

Hier wird ein Beispielcode für die FLAC3D (Version 6.0) Berechnung abgebildet. Es handelt sich hierbei um das Beispiel mit dem Index 112 der Tabelle 9: Datenbank der Setzungsprognosen aus den FDM-Berechnungen. Der Code kann in FLAC3D kopiert werden, die Berechnung sollte ohne Anpassungen durchführbar sein. Ein häufig auftretender Programmfehler ist jedoch die inkonsequente Benennung der „Zone-Faces“. Dadurch kann es notwendig sein, zu kontrollieren, ob der Tunnelumfang als West2 oder West3 bezeichnet wurde. Gegebenenfalls muss der richtige „Zone-Face“-Name eingesetzt werden, damit die Berechnung ordnungsgemäß funktioniert.

```
model new
model largestrain off
fish automatic-create on
model title 'Tunnel CCM' ; Model geometry and labels created interactively
```

```
;Eingabeparamter
```

```
;Kennzeichnung
```

```
[Nummer=0112]
```

```
;Geometrie
```

```
[D=11.2]
```

```
[C=19.04]
```

```
[CzuD=C/D]
```

```
[xz=3]; Parameter fuer die Zahl der Zonen in den Bloecken
```

```
[xr=1]; Parameter fuer die Ratio der Zonen
```

```
[xru=1]; Paramter fuer die Ratio der Zonen
```

```
;Bodenparameter
```

```
[reibungswinkel= 26]
```

```
[kohesion = 30e3]
```

```
[poisson_zahl = 0.2]
```

```
[dilat_winkel = 0]
```

```
[wichte = 2200]
```

```
[e_modul = 75.2e6]
```

```
;Bodenparameter Plastic hardening
```

```
[m= 0.3]
```

```
[poisson_vr=0.2]
```

```
[Eref50=37.6e6]
```

```
[Erefoed=37.6e6]
```

```
[Erufur=150.4e6]
```

[pref=1e5]

[OCR=4]

fish define geometrie

command

[Dr=math.round(D)]

[Cr=math.round(C)]

;zone generation as primitives

;oberer Zylinder

zone create radial-cylinder size [Dr] 1 [2*Dr] [Dr] rat 1 1 1 1 point 0 (0,0,0) point 1 ([D],0,0)
point 2 (0,1,0) ...

point 3 (0,0,[D]) point 4 ([D],1,0) point 5 (0,1,[D]) point 6 ([D],0,[D]) point 7 ([D],1,[D]) ...

point 8 ([D/2],0,0) point 9 (0,0,[D/2]) point 10 ([D/2],1,0) point 11 (0,1,[D/2]) group
'Umgebung'

;oberer Kern;

zone create cylinder size [Dr] 1 [2*Dr] point 0 (0,0,0) point 1 ([D/2],0,0) point 2 (0,1,0) ...

point 3 (0,0,[D/2]) point 4 ([D/2],1,0) point 5 (0,1,[D/2]) group 'Kern'

;oberer Block

fish define oberer_block

if CzuD>0.5

then

command

zone create brick size [Dr] 1 [Cr] point 0 (0,0,[D]) point 1 ([D],0,[D]) point 2 (0,1,[D])
point 3 (0,0,[C+D]) group 'Umgebung'

zone create brick size [xz*Dr] 1 [Cr] rat [xr] 1 1 point 0 ([D],0,[D]) point 1 ([9*D],0,[D])
point 2 ([D],1,[D]) point 3 ([D],0,[C+D]) group 'Umgebung'

end_command

end_if

end

@oberer_block

;rechter Block

zone create brick size [xz*Dr] 1 [2*Dr] rat [xr] 1 1 point 0 ([D],0,[-D]) point 1 ([9*D],0,[-D]) point
2 ([D],1,[-D]) point 3 ([D],0,[D]) group 'Umgebung'

zone create brick size [xz*Dr] 1 [5*Dr/(2*2)] rat [xr] 1 [xru] point 0 ([D],0,[-D-5*D/2]) point 1
([9*D],0,[-D-5*D/2]) point 2 ([D],1,[-D-5*D/2]) point 3 ([D],0,[-D]) group 'Umgebung'

;unterer Zylinder

```
zone create radial-cylinder size [Dr] 1 [2*Dr] [Dr] rat 1 1 1 1 point 0 (0,0,0) point 1 (0,0,[-D])
point 2 (0,1,0)...
```

```
    point 3 ([D],0,0) point 4 (0,1,[-D]) point 5 ([D],1,0) point 6 ([D],0,[-D]) point 7 ([D],1,[-D]) ...
    point 8 (0,0,[-D/2]) point 9 ([D/2],0,0) point 10 (0,1,[-D/2]) point 11 ([D/2],1,0) group
'Umgebung'
```

```
;unterer Kern;
```

```
zone create cylinder size [Dr] 1 [2*Dr] point 0 (0,0,0) point 1 (0,0,[-D/2]) point 2 (0,1,0)...
    point 3 ([D/2],0,0) point 4 (0,1,[-D/2]) point 5 ([D/2],1,0) group 'Kern'
```

```
;unterer Block
```

```
zone create brick size [Dr] 1 [5*Dr/(2*2)] rat 1 1 [xru] point 0 (0,0,[-D-5*D/2]) point 1 ([D],0,[-D-
5*D/2]) point 2 (0,1,[-D-5*D/2]) point 3 (0,0,[-D]) group 'Umgebung'
```

```
end_command
```

```
end
```

```
@geometrie
```

```
;automatisches Erstellen von face groups;
```

```
    zone face skin
```

```
;erstellen einer Gridpoint-Gruppe fuer die Oberflaechensetzungen
```

```
    zone gridpoint group 'Oberflaeche' range group 'Top'
```

```
    zone gridpoint group 'Vorne' range group 'South'
```

```
;Stoffgesetz zuweisen
```

```
zone cmodel assign mohr-coulomb
```

```
zone property cohesion [kohaesion] friction [reibungswinkel] density [wichte] dilation
[dilat_winkel] young [e_modul] poisson [poisson_zahl]
```

```
;Randbedingungen--> Geschwindigkeit an den Raendern = 0
```

```
zone face apply velocity-x 0 range group 'East' or 'West'
```

```
zone face apply velocity-y 0 range group 'North' or 'South'
```

```
zone face apply velocity (0,0,0) range group 'Bottom'
```

```
;Initialspannung;
```

```
model gravity 10
```

```
fish define k_wert
```

```
    k = 1- math.sin(([reibungswinkel]*math.pi/180))
```

```
end
```

@k_wert

zone initialize-stresses ratio [k] [k]

; Solve to initial equilibrium

model solve convergence 1.0

;zone initialize state 0

zone gridpoint initialize displacement (0,0,0)

zone initialize-stresses ratio [k]

zone cmodel assign plastic-hardening; Material Model aendern

zone property cohesion [kohesion] friction [reibungswinkel] density [wichte] dilation
[dilat_winkel] poisson [poisson_zahl] pressure-reference [pref] ...

stiffness-50-reference [Eref50] exponent [m] flag-smallstrain off stiffness-oedometer-
reference [Erefoed] stiffness-ur-reference [Erufur] ...

over-consolidation-ratio [OCR]

;fish Funktion fuer den Initial-Spannungszustand fuer das Plastic-Hardening Materialgesetz

fish def ini_ph

loop foreach local z zone.list

if z.model(z) = 'plastic-hardening'

;local pp = zone.pp(z) ; kein Porenwasserdruck

zone.prop(z,'stress-1-effective') = zone.stress.min(z) ;+ pp

zone.prop(z,'stress-2-effective') = zone.stress.int(z) ;+ pp

zone.prop(z,'stress-3-effective') = zone.stress.max(z) ;+ pp

endif

endloop

end

@ini_ph

; Solve to initial equilibrium

model solve convergence 1.0

; speichern des Modells;

;model save [string(Nummer)+'Grundzustand']

; Tabellen erstellen

table 'grc' label 'Ground Reaction Curve'; Ground reaction curve

[Gridpoint_Firste = gp.near(0,0,[D/2])]; Gridpoint an der Tunnelfirste

```
table 'Setzungen' label 'Oberflaechensetzungen';Oberflaechensetzungen
```

```
zone cmodel assign null range group 'Kern' ;Entfernen des Kerns;
```

```
    zone face skin ; automatisches Erstellen von face groups West3 = Umfang des Tunnels
```

```
    zone gridpoint group 'Tunnelumfang' range group 'West3'; Erstellen der Gridpoint-Gruppe entlang des Tunnelumfangs
```

```
fish define kraefte
```

```
command
```

```
    zone cmodel assign null range group 'Kern' ;Entfernen des Kerns;
```

```
    zone face skin ; automatisches Erstellen von face groups West3 = Umfang des Tunnels
```

```
    zone face apply velocity-normal 0 range group 'West3'; fixieren des Randes des Tunnels  
    ; Ruecksetzen der Verschiebungen und der Geschwindigkeiten
```

```
    zone gridpoint initialize displacement (0,0,0) range group 'Tunnelumfang'
```

```
    zone gridpoint initialize displacement-small (0,0,0) range group 'Tunnelumfang'
```

```
    zone gridpoint initialize velocity (0,0,0) range group 'Tunnelumfang'
```

```
end_command
```

```
command
```

```
;zone face apply-remove velocity-normal range group 'West3'
```

```
end_command
```

```
loop foreach local gp gp.list
```

```
    if gp.isgroup(gp,'Tunnelumfang') then
```

```
        gp.fix.x(gp) = 1
```

```
        gp.vel.x(gp)=0
```

```
        gp.fix.y(gp) = 1
```

```
        gp.vel.y(gp)=0
```

```
        gp.fix.z(gp) = 1
```

```
        gp.vel.z(gp)=0
```

```
        command
```

```
model solve convergence 1 or cycles 30000
```

```
    end_command
```

```
    gp.force.load.x(gp)= gp.force.unbal.x(gp)*-[1-lambda]
```

```
    gp.force.load.y(gp)= gp.force.unbal.y(gp)*-[1-lambda]
```

```
    gp.force.load.z(gp)= gp.force.unbal.z(gp)*-[1-lambda]
```

```
    endif
```

```
end_loop
```

end

fish define relaxation

loop foreach local gp gp.list

if gp.isgroup(gp,'Tunnelumfang') then

gp.fix.x(gp) = 0

gp.fix.y(gp) = 0

gp.fix.z(gp) = 0

gp.force.load.x(gp)= 0

gp.force.load.y(gp)= 0

gp.force.load.z(gp)= 0

endif

endloop

end

fish define CCM

loop n_steps (0,10,1)

lambda = (n_steps/10.0)

command

@kraefte

zone face apply-remove velocity-normal range group 'West3'

model solve convergence 1 or cycles 30000

end_command

table('grc',gp.disp.z(Gridpoint_Firste)) = [lambda]

command

model save ['lambda_'+string(lambda)]

;assign plastic hardening

@relaxation

zone cmodel assign mohr-coulomb

zone property cohesion [kohaesion] friction [reibungswinkel] density [wichte] dilation
[dilat_winkel] young [e_modul] poisson [poisson_zahl]

;boundary conditions;

zone face apply velocity-x 0 range group 'East' or 'West'

zone face apply velocity-y 0 range group 'North' or 'South'

zone face apply velocity (0,0,0) range group 'Bottom'

```
;Initialspannung;
model gravity 10
zone initialize-stresses ratio [k] [k]
; Solve to initial equilibrium
model solve convergence 1.0 or cycles 30000

zone initialize state 0
zone gridpoint initialize displacement (0,0,0)

zone cmodel assign plastic-hardening; Material Model aendern
  zone property cohesion [kohaesion] friction [reibungswinkel] density [wichte] dilation
[dilat_winkel] poisson [poisson_zahl] pressure-reference [pref] ...
  stiffness-50-reference [Eref50] exponent [m] flag-smallstrain off stiffness-oedometer-
reference [Erefoed] stiffness-ur-reference [Erufur] over-consolidation-ratio [OCR]
  zone gridpoint initialize displacement (0,0,0)
  @ini_ph
  model solve convergence 1 or cycles 30000
  end_command
end_loop
end

fish define setzungen
  loop x(0,[D],[D/Dr])
    table('Setzungen',x) = gp.disp.z(gp.near(x,0,[C+D]))
  end_loop
  loop x([D],[10*D],[xz*D/Dr])
    table('Setzungen',x) = gp.disp.z(gp.near(x,0,[C+D]))
  end_loop
end

model save [string(Nummer)+'Grundzustand'+Fish']

@CCM

@setzungen

;Tabellen und Plots exportieren
```

```
;table 'Setzungen' list
;table 'grc' list
table 'grc' export ['tab_Ground Reaction Curve_'+string(Nummer)+'.csv']
table 'Setzungen' export ['tab_Setzungen_ohne'+string(Nummer)+'.csv']
plot 'plot01' export bitmap filename ['plot_grc_'+string(Nummer)+'.png'] size 7600 3670
plot 'plot02' export bitmap filename ['plot_Setzungen_ohne'+string(Nummer)+'.png'] size 7600 3670
plot 'plot03' export bitmap filename ['plot_plastic_D'+string(Nummer)+'.png'] size 7600 3670
plot 'plot04' export bitmap filename ['plot_plastic02_D'+string(Nummer)+'.png'] size 7600 3670

;laden des Modelzustandes bei lambda = X.XX
[lambda_neu= 0.1]
[Typ='TVM']
model restore ['lambda_'+string(lambda_neu)]
zone cmodel assign null range group 'Kern' ;Entfernen des Kerns;
zone face skin

;Einbau der Tunnelsicherung
structure shell create by-face group 'Tunnelwand' range group 'West3'
structure shell property isotropic (35e9,0.2) thickness 0.35 density 2500 range group 'Tunnelwand'

model solve convergence 1

fish define relaxation
loop foreach local gp gp.list
  if gp.isgroup(gp,'Tunnelumfang') then
    gp.fix.x(gp) = 0
    gp.fix.y(gp) = 0
    gp.fix.z(gp) = 0
    gp.force.load.x(gp)= 0
    gp.force.load.y(gp)= 0
    gp.force.load.z(gp)= 0
  endif
endloop
end
@relaxation
```

model solve convergence 1

```
table      'Setzungen_Gesamt'      label      'Oberflaechensetzungen_mit_Ausbau'
;Oberflaechensetzungen
```

fish define setzungen_gesamt

```
  loop x(0,[D],[D/Dr])
    table('Setzungen_Gesamt',x) = gp.disp.z(gp.near(x,0,[C+D]))
  end_loop
  loop x([D],[10*D],[xz*D/Dr])
    table('Setzungen_Gesamt',x) = gp.disp.z(gp.near(x,0,[C+D]))
  end_loop
```

end

@setzungen_gesamt

;table 'Setzungen_Gesamt' list

```
table      'Setzungen_Gesamt'      export
['tab_Setzungen_Gesamt_'+string(Typ)+string(Nummer)+'_lambda='+string(lambda_neu*10)
+'.csv']
```

```
plot      'plot05'      export      bitmap      filename
['plot_Setzungen_Gesamt_'+TVM+string(Nummer)+'_lambda='+string(lambda_neu*10)+'.png'] size 7600 3670
```

```
.....
.....
.....
```

;NATM berechnen

;[lambda_neu= 0.23]

[Typ='NATM']

model restore [string(Nummer)+'Grundzustand'+Fish']

;[lambda= XXXXXX]

;CCM mit irgendeinem Lambda

fish define CCM_lambda

lambda = 0.23

command

@kraefte

zone face apply-remove velocity-normal range group 'West3'

```
end_command
end

@CCM_lambda
model solve convergence 1
zone cmodel assign null range group 'Kern' ;Entfernen des Kerns;
zone face skin

;Einbau der Tunnelsicherung
structure shell create by-face group 'Tunnelwand' range group 'West3'
structure shell property isotropic (15e9,0.2) thickness 0.30 density 2500 range group
'Tunnelwand'

model solve convergence 1

@relaxation

model solve convergence 1

table                                'Setzungen_Gesamt_NATM'                                label
'Oberflaechensetzungen_mit_Ausbau_NATM';Oberflaechensetzungen

fish define setzungen_gesamt_NATM
  loop x(0,[D],[D/Dr])
    table('Setzungen_Gesamt_NATM',x) = gp.disp.z(gp.near(x,0,[C+D]))
  end_loop
  loop x([D],[10*D],[xz*D/Dr])
    table('Setzungen_Gesamt_NATM',x) = gp.disp.z(gp.near(x,0,[C+D]))
  end_loop
end

@setzungen_gesamt_NATM
;table 'Setzungen_Gesamt_NATM' list

table                                'Setzungen_Gesamt_NATM'                                export
['tab_Setzungen_Gesamt_'+_NATM'+string(Nummer)+'_lambda='+string(lambda)+'_csv']

plot                                'plot06'                                export                                bitmap                                filename
['plot_Setzungen_Gesamt_'+_NATM'+string(Nummer)+'_lambda='+string(lambda)+'_png'] size
7600 3670
```

9 Anhang B: TensorFlow-Codes

Der Druckversion liegt an dieser Stelle ein Datenträger mit den entwickelten TensorFlow-Codes und der verwendeten Datenbank bei.