

Conference Proceedings

# **Workshop**

**smartGeotech**

Künstliche Intelligenz, Automatisierung, Robotik

25<sup>th</sup> & 26<sup>th</sup> of September 2025

Hamburg, Germany

Editor

**J. Grabe**

Hamburg University of Technology

Institute of Geotechnical Engineering and Construction Management

# Publications by the Institute of Geotechnical Engineering and Construction Management

**63**

Editor:

Univ.-Prof. Dr.-Ing. Jürgen Grabe  
Hamburg University of Technology  
Institute of Geotechnical Engineering and Construction Management  
Schellerdamm 22 (Channel 7)  
D – 21079 Hamburg  
e-mail: *grabe@tuhh.de*

**ISBN-13: 978-3-9363120-65-8 (first edition)**

**DOI:** 10.15480/882.15997

**License:** CC BY 4.0

Printery

Druckzentrum Neumünster GmbH  
Rungestraße 4  
D – 24537 Neumünster

Published in the same series:

1. J. Grabe (eds.), 2000: Verbrennungsrückstände. Conference Proceedings, ISBN 3-936310-00-9
2. J. Grabe (eds.), 2001: Schaden- und Risikomanagement im Tiefbau. Conference Proceedings, ISBN 3-936310-01-7
3. J. Grabe, 2003. Bodenmechanik und Grundbau. ISBN 3-936310-03-3
4. J. Grabe (eds.), 2003: Euronormen in der Geotechnik – Was ändert sich? Conference Proceedings, ISBN 3-936310-04-1
5. J. Grabe (eds.), 2003: Bodenverdichtung, Experimente - Modellierung - Geräteentwicklung - Baustellenberichte - F+E-Bedarf. Conference Proceedings, ISBN 3-936310-05-X
6. M. Kelm, 2004: Numerische Simulation der Verdichtung rolliger Böden mittels Vibrationswalzen. Dissertation, ISBN 3-936310-06-8
7. J. Grabe (eds.), 2004: Kaimauern - Messungen und Numerik. Conference Proceedings, ISBN 3-936310-07-6
8. J. Stein, 2005. Experimentelle und numerische Untersuchungen zum Düsenstrahlverfahren. Promotion, ISBN 3-936310-09-2
9. J. Grabe (eds.), 2005: Grenzschicht Wasser und Boden - Phänomene und Ansätze. Conference Proceedings, ISBN 3-936310-10-6
10. J. Grabe (eds.), 2005: FEM in der Geotechnik - Qualität, Prüfung, Fallbeispiele - Conference Proceedings, ISBN 3-936310-11-4
11. B. Mardfeldt, 2006: Zum Tragverhalten von Kaikonstruktionen im Gebrauchszustand. Dissertation, ISBN 3-936310-12-2
12. J. Grabe (eds.), 2006: Optimierung in der Geotechnik - Strategien und Fallbeispiele. Conference Proceedings, ISBN-13: 978-3-936310-13-9
13. T. Bierer, 2007: Bodenschwingungen aus Straßenverkehr auf unebener Fahrbahn im Zeitbereich - experimentelle und theoretische Untersuchungen. Dissertation, ISBN-13: 978-3-936310-14-6
14. J. Grabe (eds.), 2007: Bemessen mit Finite-Elemente-Methoden. Conference Proceedings, ISBN-13: 978-3-936310-15-3
15. K.-P. Mahutka, 2008: Zur Verdichtung von rolligen Böden infolge dynamischer Pfahleinbringung und durch Oberflächenrüttler. Dissertation, ISBN-13: 978-3-936310-16-0

16. J. Grabe (eds.), 2008: Seehäfen für Containerschiffe zukünftiger Generationen. Conference Proceedings, ISBN-13: 978-3-936310-17-7
17. F. König, 2008: Zur zeitlichen Traglastentwicklung von Pfählen und der nachträglichen Erweiterung bestehender Pfahlgründungen. Dissertation, ISBN-13: 978-3-936310-18-4
18. S. Henke, 2008: Herstellungseinflüsse aus Pfahlrammung im Kaimauerbau. Dissertation, ISBN-13: 978-3-936310-19-1
19. J. Grabe (eds.), 2009: Spundwände – Profile, Tragverhalten, Bemessung, Einbringung und Wiedergewinnung. Conference Proceedings, ISBN-13: 978-3-936310-20-7
20. J. Dührkop, 2009: Zum Einfluss von Aufweitungen und zyklischen Lasten auf das Verformungsverhalten lateral beanspruchter Pfähle in Sand. Dissertation, ISBN-13: 978-3-936310-21-4
21. O. Möller, 2009: Zum Langzeit-Kompressionsverhalten weicher organischer Sedimente. Dissertation, ISBN-13: 978-3-936310-22-1
22. J. Grabe (eds.), 2011: Ports of container ships of future generations. Conference Proceedings, ISBN-13: 978-3-936310-23-8
23. S. Kinzler, 2011: Zur Parameteridentifikation, Entwurfs- und Strukturoptimierung in der Geotechnik mittels numerischer Verfahren. Dissertation, ISBN-13: 978-3-936310-24-5
24. G. Qiu, 2012: Coupled Eulerian Lagrangian Simulations of Selected Soil-Structure Problems. Dissertation, ISBN-13: 978-3-936310-25-2
25. X. Ma, 2013: Nutzung der oberflächennahen Geothermie mittels Energiepfählen und Erdwärmesonden. Dissertation, ISBN-13: 978-3-936310-26-9
26. J. Grabe (eds.), 2013: Proceedings of the Conference on Maritime Energy COME 2013. Conference Proceedings, ISBN-13: 978-3-936310-28-3
27. J. Grabe (eds.), 2013: Bemessen mit numerischen Methoden. Conference Proceedings, ISBN-13: 978-3-936310-29-0
28. T. Pucker, 2013: Stoffmodell zur Modellierung von stetigen Materialübergängen im Rahmen der Optimierung geotechnischer Strukturen. Dissertation, ISBN-13: 978-3-936310-30-6
29. S. Henke, 2013: Untersuchungen zur Pfropfenbildung infolge der Installation offener Profile in granularen Böden. Habilitation, ISBN-13: 978-3-936310-31-3
30. J. Grabe (eds.), 2014: Ports for Container Ships of Future Generations. Conference Proceedings, ISBN-13: 978-3-936310-32-0

31. J. Grabe (eds.), 2014: Offshore Basishäfen, Conference Proceedings, ISBN-13: 978-3-936310-33-7
32. C. Rudolph, 2015. Untersuchungen zur Drift von Pfählen unter zyklischer, lateraler Last aus veränderlicher Richtung, Dissertation, ISBN-13: 978-3-936310-34-4
33. J. Grabe (eds.), 2015: Morphodynamics 2015, Conference Proceedings, ISBN-13: 978-3-936310-35-1
34. T. Hamann, 2015: Zur Modellierung wassergesättigter Böden unter dynamischer Belastung und großen Bodenverformungen am Beispiel der Pfahleinbringung, Dissertation, ISBN-13: 978-3-936310-36-8
35. B. Schümann, 2015: Beitrag zum dynamischen Dreiphasenmodell für Boden auf Basis der Finite-Elemente-Methode, Dissertation, ISBN-13: 978-3-936310-37-5
36. M. Milatz, 2015: Untersuchungen zum Einfluss der Kapillarität auf das hydraulisch-mechanische Verhalten von granularer Tragschichten für Verkehrswege, Dissertation, ISBN-13: 978-3-936310-38-2
37. H. Kaya, 2016: Bodenverschleppung und Spaltbildung infolge der Einbringung von Profilen in Dichtungsschichten aus Ton, Dissertation, ISBN-13: 978-3-936310-39-9
38. J. Grabe (eds.), 2017: Proceedings of the Conference on Maritime Energy COME 2017. Conference Proceedings, ISBN-13: 978-3-936310-40-5
39. B. Kocak, 2017: Zur numerischen Modellierung von hydraulisch-mechanisch gekoppelten Prozessen in gesättigten granularen Böden mittels Smoothed Particle Hydrodynamics, Dissertation, ISBN-13: 978-3-936310-41-2
40. K. Siegl, 2017: Zur Pfahldynamik von geramnten Großrohrpfählen und der daraus resultierenden Wellenausbreitung in Wasser und im Meeresboden, Dissertation, ISBN-13: 978-3-936310-42-9
41. J. Grabe (eds.), 2017: Numerical Methods in Geotechnics, Conference Proceedings, ISBN-13: 978-3-936310-43-6
42. J. Grabe (eds.), 2018: Digitale Infrastruktur und Geotechnik (DIG 2018), Conference Proceedings, ISBN-13: 978-3-936310-44-3
43. D. Osthoff, 2018: Zur Ursache von Schlosssprengungen und zu einbringbedingten Lageabweichungen von Spundwänden, Dissertation, ISBN-13: 978-3-936310-45-0
44. E. Heins, 2018: Numerical based identification of the pile-soil interaction in terms of the axial pile bearing capacity, Dissertation, ISBN-13: 978-3-936310-46-7

45. K.-F. Seitz, 2021: Zur Topologieoptimierung von geotechnischen Strukturen und zur Tragfähigkeitssteigerung des Baugrunds durch Scherfugenverfestigung, Dissertation, ISBN-13: 978-3-936310-47-4
46. D. Plenker, 2021: Physical and numerical investigations of the dynamic interaction of saturated granulates and fluid, Dissertation, ISBN-13: 978-3-936310-48-1
47. J. Grabe, J.-O. Backhaus & P. Vogel, 2021: Bauprojektmanagement, ISBN-13: 978-3-936310-49-8
48. M. Kanitz, 2021: Experimental and numerical investigations of particle-fluid systems in geotechnical engineering, Dissertation, ISBN-13: 978-3-936310-50-4
49. J.-O. Backhaus, 2021: A methodology for the numeric time-cost forecast and pareto optimization of large injection projects in tunneling, Dissertation, ISBN-13: 978-3-936310-51-1
50. S. N. Sinduri, 2021: Optimisation of deep compaction as liquefaction mitigation measure, Dissertation, ISBN-13: 978-3-936310-52-8
51. J. Bubel, 2022: Zum Versagen von Unterwasserböschungen im Seegang, Dissertation, ISBN-13: 978-3-936310-53-5
52. J. Grabe (eds.), 2022: Adaptive Structures at Shore, Conference Proceedings, ISBN-13: 978-3-936310-54-2
53. J. Grabe (eds.), 2022: Numerische Methoden in der Geotechnik, Conference Proceedings, ISBN-13: 978-3-936310-55-9
54. J. Grabe (eds.), 2022: Processes in natural and technical Particle-Fluid Systems (PintPFS), Conference Proceedings, ISBN-13: 978-3-936310-56-6
55. T. Törzs, 2022: Zum hydraulisch-mechanisch gekoppelten Verhalten teilgesättigter granularer Geomaterialien infolge hydraulischer und mechanischer Beanspruchungen, Dissertation, ISBN-13: 978-3-936310-57-3
56. M. Milatz, 2022: Investigation of capillary effects on the grain scale by means of in situ experiments, imaging and numerical simulations, Habilitation, ISBN-13: 978-3-936310-58-0
57. A. Chmelnizkij, 2023: Regularized MPM for porous media, Dissertation, ISBN-13: 978-3-936310-59-7
58. J. Grabe (ed.), 2023: Herausforderungen in der Geotechnik – 25 Jahre Institut für Geotechnik und Baubetrieb, TU Hamburg, Conference Proceedings, ISBN-13: 978-3-936310-60-3

59. J. Beuße, 2023: Zur Einbringung und zum Tragverhalten von kombinierten Spundwänden von Ufereinfassungen, Dissertation, ISBN-13: 978-3-936310-61-0
60. D. Zobel, 2023: Zur Implementierung höherwertiger Stoffmodelle am Beispiel der Hypoplastizität, Dissertation, ISBN-13: 978-3-936310-62-7
61. A. Hagemann, 2024: On cyclic and dynamic pile-bearing behaviour, Dissertation, ISBN-13: 978-3-936310-63-4
62. P. Kaminski, 2024: Experimental investigations on the mechanics of gassy sands – testing methodology, shear tests, and imaging, Dissertation, ISBN-13: 978-3-936310-64-1

## Table of Contents / Inhaltsverzeichnis

<b>Preface/Vorwort</b> .....	1
Modell trifft Messwert – KI in der Parameterbestimmung .....	3
<i>Barbara Schneider-Muntau</i>	
Smart Lab: Konzept zur automatisierten Bodenansprache und zur Generierung von digitalen Partikelmodellen unter Nutzung von KI .....	13
<i>Göta Bürkner, Mohamed Abdennadher</i>	
Innovative Automatisierung zum Einbau reproduzierbarer Bodenproben .....	27
<i>Tim Pucker</i>	
„Baustelle KI“: Chancen und Grenzen von künstlicher Intelligenz im Bauingenieurwesen ..	41
<i>Alexander Chmelnizkij und Kay Smarsly</i>	
Data-driven and Numerical Modeling of Control Strategies for Vibrodriving Processes and Rover Mobility on Sandy Terrains .....	53
<i>Rahul Somasundaram, Francisco Williams-Riquer</i>	
Artificial Intelligence Applications in Computational Geomechanics .....	67
<i>Raul Fuentes</i>	
Anwendung von KI zur Programmierung von Python-Skripten am Beispiel der Visualisierung von Dispersion .....	75
<i>Abdulsalam Abdulrahman, Eugen Perau</i>	
Automated parameter determination: From in-situ measurements to constitutive models ...	85
<i>Islam Marzouk, Haris Felić, Franz Tschuchnigg, Ronald Brinkgreve</i>	
AI watches us build – tracking the construction process with smart algorithms .....	95
<i>Marcus Daubner</i>	
Automatisierung und KI im maschinellen Tunnelbau: Entwicklungen und Perspektiven ...	103
<i>Frederic Seng, Lasse Klein</i>	
Digitalisierung in der Geotechnik – Wohin führt der Weg? .....	115
<i>Sascha Henke, Johannes Beck</i>	

KI gestützte Überwachung von Ufereinfassungen .....	131
<i>Kacper Cerek</i>	
Intelligente Zukunft: KI-gestützte Innovationen im Bauwesen am Beispiel des STRABAG-Konzerns .....	145
<i>Marina Ivanova, Jörg Schreiber</i>	
Die Zukunft des digitalen Lean bei Drees & Sommer SE – Der Weg von analog über digital, smart und autonom bis zum ultraeffizienten Bauprojekt .....	147
<i>Jan Onne Backhaus</i>	
KI-Anwendungen bei geotechnischen Bauverfahren .....	159
<i>Christian Thienert, Lara Gutberlet, Christoph Klaproth, Reiner Otterbein, Frank Ludwig, Frank Könemann, André Heim, Christoph Budach</i>	

## **Preface/Vorwort**

Sprachmodelle wie beispielsweise ChatGPT verändern die Arbeitsprozesse des Ingenieurs: Die Sprachmodelle werden mit Daten aus Normen, Büchern und Schriften ständig trainiert und lernen dadurch unermüdlich dazu. Eine Lernleistung, die ein Mensch beim besten Willen nicht bewältigen kann. Wenn man nur an den in den letzten Jahrzehnten enorm gewachsenen Umfang der Normen (EC0, EC7, DIN 1054, ... und Empfehlungen (EAB, EAU) denkt, wird einem bewusst, dass ein Mensch inzwischen überfordert ist, alles zu wissen und den Überblick zu bewahren. Durch die Rückkopplung mit dem Nutzer oder einem anderen unabhängigen Sprachmodell wird zudem die Antwort von Sprachmodellen immer zutreffender. Standardaufgaben wie einfache Berechnungen lassen sich schneller durchführen, standardisierte Gutachten erstellen und vieles Alltägliches damit zügig erledigen. Für den Anwender ist es jedoch wichtig, die Frage an solche Sprachmodelle genau zu formulieren und das Ergebnis bewerten zu können, da die Ergebnisse nicht notwendigerweise richtig sind. Mit Erfahrung ist so ein Sprachmodell schon jetzt ein sehr nützliches und in Zukunft vermutlich sogar notwendiges Werkzeug. Berufsanfängern fehlt allerdings die Erfahrung, die Ergebnisse zu falsifizieren. Hier braucht es von den Lehrenden der Universitäten ein Umdenken, um den Auftrag „berufsqualifizierend auszubilden“ erfüllen zu können. Ein interessanter Aspekt ist auch, dass der Ingenieur nach dem Stand der Technik zu planen, zu dimensionieren und zu bauen hat. Definieren zukünftig solche Sprachmodelle den Stand der Technik? Treten später Mängel oder Schäden auf, wie weise ich nach, dass ich zum Zeitpunkt der Erstellung nach dem Stand der Technik gearbeitet habe? Haftet wird weiterhin der Ingenieur, der die Berechnung bzw. den Bericht unterzeichnet. Fehler im Sprachmodell gehen damit zu seinen Lasten. Haftet er zukünftig auch, wenn er die Arbeit ohne ein Sprachmodell zu befragen erledigt hat? Wie ist es eigentlich mit dem Urheberrecht? Hier ergeben sich offensichtlich auch ungeklärte Rechtsfragen und Fragen zum Berufsethos.

Die Automatisierung vieler Bauprozesse schreitet weiter voran. Zum einen lassen sich dadurch höhere Leistungen und Qualitäten erzielen, zum anderen fehlen immer öfter qualifizierte Facharbeiter, die auf den Baustellen unter teils schwierigen oder mitunter gefährlichen Bedingungen arbeiten wollen. Durch Nutzung von moderner Regelungstechnik lassen sich viele Prozesse insbesondere im Tiefbau „Vor der Hacke ist es dunkel“ automatisieren, beschleunigen und in höherer reproduzierbarer Qualität ausführen. Die Automatisierung und Robotik wird sich zweifelsfrei durchsetzen.

Ziel des Workshops ist es die durch Sprachmodelle und durch die Automatisierung/Robotik entstehenden neuen Möglichkeiten und Herausforderungen zu diskutieren. Der Workshop ist hierfür dreigeteilt: Zunächst geht es darum, aufzuzeigen, woran aktuell beispielhaft geforscht wird. Danach soll über die Veränderung der täglichen Arbeit des Bauingenieurs diskutiert werden. Der dritte Teil gibt Einblick in das, was die Praxis bereits umsetzt oder als Zukunft sieht.

Ich freue mich über einen spannenden Workshop und bedanke mich für alle Beiträge und die Teilnahme.

Jürgen Grabe

Hamburg, den 25. September 2025



# **Title: Modell trifft Messwert – KI in der Parameterbestimmung**

**Barbara Schneider-Muntau**

**Abstract:** The reliable identification of geotechnical parameters remains a major challenge for numerical modeling in geotechnical engineering. This contribution explores the integration of classical and AI-based approaches to improve parameter determination, focusing on laboratory tests and back-calculations from field measurements, particularly in tunneling and slope stability. Statistical methods such as confidence hyperbolae are compared with machine learning techniques and surrogate modeling. Case studies demonstrate how adaptive calibration using monitoring data can enhance prediction quality. Furthermore, the paper discusses the impact of natural inhomogeneity, the reproducibility of triaxial tests, and the potential of inverse modeling. The combination of numerical simulation, data-driven methods, and real-time monitoring is presented as a pathway toward resilient geotechnical design.

## **1 Einleitung**

Die Bestimmung von Materialparametern stellt eine der zentralen Herausforderungen für geotechnische Berechnungen dar. Ob bei der Nachrechnung geotechnischer Laborversuche, bei Standsicherheitsbetrachtungen von Hängen oder im Tunnelvortrieb, die Qualität numerischer Simulationen hängt maßgeblich von der Verlässlichkeit und Streuung der eingegebenen Parameter ab. Bei dem Vergleich mit Messwerten aus Feldversuchen zeigt sich jedoch häufig eine deutliche Abweichung zwischen berechneten und gemessenen Verformungen, was eine ungewünschte, deutliche Abweichung zwischen den natürlichen Verhältnissen und den Modellierungsergebnissen darstellt. Dies kann auf eine unzureichende Abbildbarkeit der Materialeigenschaften im Materialmodell oder auf falsche oder unberücksichtigte Einflüsse oder Randbedingungen zurückzuführen sein. Diese Unterschiede wirken sich nicht nur auf die Prognosegenauigkeit, sondern auch auf die Wirtschaftlichkeit und Sicherheit geotechnischer Bauwerke aus. Künstliche Intelligenz (KI), in diesem Zusammenhang insbesondere maschinelles Lernen (ML), bietet innovative Möglichkeiten, diese Herausforderungen zu adressieren. Durch den gezielten Einsatz datenbasierter Methoden können nicht nur Fehlerquellen identifiziert, sondern auch Parameter schneller und eventuell auch mit höherer Genauigkeit bestimmt werden, ML benötigt, wie allgemein bekannt ist, große Anzahl an Mess-/Versuchsdaten. Wo diese vorhanden sind kann durch adaptive Kalibrierung die Zuverlässigkeit numerischer Modelle verbessert werden.

Ziel dieses Beitrags ist es, das Potenzial und die Grenzen altbewährter und neuer Verfahren (wie ML) anhand konkreter Beispiele zu diskutieren, vor allem die Parameterbestimmung aus Laborversuchen oder durch Rückrechnung von Messwerten aus Anwendungen im Tunnelbau

oder bei Massenbewegungen. Der Fokus liegt dabei auf einer effizienteren Parameteridentifikation mit bestenfalls adaptiver Parameteranpassung, sowie der Integration KI-basierter Verfahren in geotechnische Planungs- und Monitoringsysteme, sowie deren Datenauswertung.

## **2 Geotechnische Laborversuche und Reproduzierbarkeit**

### **2.1 Streuung geotechnischer Parameter**

Geotechnische Parameter unterliegen aufgrund der natürlichen Inhomogenität des Untergrunds einer hohen Streuung. Selbst bei Proben aus derselben geologischen Einheit kann es zu signifikanten Unterschieden in natürlicher Dichte, Wassergehalt oder Porenzahl kommen. Zudem können diese Werte im Feld sich über die Zeit ändern. Als eindrucklichstes Beispiel kann hier der natürliche Wassergehalt genannt werden. Diese Inhomogenitäten wirken sich insbesondere auf Überlegungen bezüglich charakteristischer Parameter aus. Die Wahl dieser charakteristischen Parameter als Grundlage aller geotechnischen Berechnungen ist von zentraler Bedeutung für Standsicherheitsprognosen und Prozessanalysen. Die Wahl charakteristischer Parameter, als vorsichtig geschätzte Mittelwerte, ist aufgrund der großen Inhomogenität und gleichzeitig der wenigen Versuchsdaten in der Bodenmechanik schwer in objektiven/statistischen Verfahren zu erfassen.

### **2.2 Reproduzierbarkeit von Triaxialversuchen**

Die Kalibrierung von Materialparametern anhand von Laborversuchen findet fast immer unter der Annahme statt, dass Laborversuche als Elementversuche gesehen werden können. Mehrere Studien – u. a. von Schneider-Muntau et al. in [9] – haben aber gezeigt, dass die Ergebnisse aus Scherversuchen in erheblichem Maße von der Homogenität des Probeneinbaus beeinflusst werden und die Annahme formtreuer Verformung auch schon bei kleinen Scherwegen nicht gegeben ist. Für den Probeneinbau, kann nur die mittlere Dichte bestimmt werden und daher ist auch diese die einzig steuerbare Größe. Auch wenn die mittlere Dichte bei mehreren Probeneinbauten konstant gehalten wird, zeigen Wiederholungsversuche unter identischen Randbedingungen (gleicher Versuchsstand, Laborant, Messzellen, Kraftmessdosen, usw.) Unterschiede in der Peakfestigkeit. Mehrelement Nachrechnungen von Laborversuchen als Finite Element Berechnungen und über die Elemente leicht gestreuter Porenzahl ( $\pm 0,04 \text{ g/cm}^3$ ) haben gezeigt, dass kleine Inhomogenitäten sich auf die Peakfestigkeit auswirken [2]. Ein identischer Probeneinbau ist trotz aller Sorgfalt bei natürlichen Materialien nicht möglich, daher ist davon auszugehen, dass diese geringen Unterschiede im Probeneinbau und daraus resultierenden Inhomogenitäten für die Unterschiede in der Peakfestigkeit auch im Laborversuch verantwortlich sind. Dies erschwert die zuverlässige Ableitung charakteristischer Scherparameter.

## 2.3 Statistische Verfahren zur Parameterermittlung




Abbildung 1: Streuung der Peakfestigkeit in Abhängigkeit von Anzahl an untersuchten Laststufen [9]

Schneider-Muntau et al. schlagen in [9] einen objektiven Zugang zur Festlegung charakteristischer Scherparameter vor, indem nicht nur Mittelwerte, sondern Konfidenzbereiche berücksichtigt werden. Besonders effektiv hat sich dabei die Auswertung über Konfidenzhyperbeln erwiesen, welche die statistische Korrelation zwischen Reibungswinkel und Kohäsion berücksichtigen. Triaxialversuche werden üblicherweise an 3 Laststufen (Seiten Spannungsniveaus) ausgewertet, was zu größeren Konfidenzintervallen führt. Der Einsatz von mindestens sechs Spannungsniveaus reduziert nachweislich die Bandbreite der möglichen Parameterkombinationen. Bei drei Spannungsniveaus lagen die 5%-Fraktilwerte für den Reibungswinkel zwischen  $27,9^\circ$  und  $36,9^\circ$ , bei sechs Spannungsniveaus zwischen  $33,9^\circ$  und  $35,2^\circ$ , was exemplarisch den Mehrwert von mehreren Laststufen auf die Zuverlässigkeit der Parameter zeigt (Abbildung 1). Vorteil dieses Ansatzes ist es, dass zum einen auf bewährte Versuche (Scherversuche im Allgemeinen) zurückgegriffen wird, die statistische Abhängigkeit von Reibungswinkel und Kohäsion (als die zwei Parameter einer Regressionsgerade) genutzt wird und mit wenig Mehraufwand (mehr Laststufen) zu Streubreite der Parameter reduziert werden kann. Dieses Verfahren kann gut die Streuung einer Versuchsprobe im Labor abbilden, gibt aber natürlich keine Aufschlüsse über die Streuung im Feld und die Wahl des Probeentnahmestandes.

## 2.4 Numerische Untersuchungen zur Inhomogenität

Da sich Laborversuche mit homogener Probenstruktur, wie oben erwähnt, kaum realisieren lassen, wurde in [2] qualitativ der Einfluss innerer Inhomogenitäten in numerischen Simulationen untersucht. Mit feinvernetzten Biaxialversuchen und dem hypoplastischen Materialmodell als Grundlage, konnte gezeigt werden, dass über die Elemente verteilte unterschiedliche Porenzahlen zu unterschiedlichen Peakfestigkeiten führen. Es wurden bei gleicher mittlerer globaler Dichte verschiedene Schwankungsbreiten der Porenzahl untersucht ( $0,01 - 0,05 \text{ g/cm}^3$ ). Größere Unterschiede in der Porenzahl führen zu einer stärkeren Reduktion der Peakfestigkeit – um bis zu 5,4 % im Vergleich zur homogeneren Probe.

Diese Erkenntnisse bestätigen die Notwendigkeit, geotechnische Parameter nicht als deterministische Größen zu betrachten, sondern sie probabilistisch zu behandeln. Der Einsatz von KI in der Parameterbestimmung könnte eine gute Ergänzung zu den oben genannten statistischen Regressionsmodellen bilden. Die Schwierigkeit kleiner Datengrundlage bleibt allerdings für beide Verfahren (analytisch und KI-basiert) bestehen.

## **2.5 Anwendungen in Finite Elementberechnungen**

In vielen geotechnischen Untersuchungen, z.B. bei Tunnelbauprojekten werden Finite-Elemente-Modelle (z. B. Abaqus, PLAXIS, RS2) eingesetzt, um erwartete Verformungen, Setzungen und Spannungsverteilungen zu prognostizieren. Die Berechnungen basieren auf geotechnischen Eingangsparametern, die wie oben beschrieben aus Laborversuchen oder Erfahrungswerten abgeleitet werden und daher einer gewissen Unsicherheit unterliegen. Umso schwieriger die Probenahme und desto unzugänglich der Standort (wie es z.B. bei Tunnelbauprojekten oder unzugänglichen Massenbewegungen der Fall sein kann), desto größeren Unsicherheiten ist die Parameterbestimmung unterworfen. In diesen Fällen ist eine sorgfältige Abschätzung einer möglichen Bandbreite der Eingangsparameter notwendig, welche dann als Grundlage einer Parameterstudie bei den Berechnungen verwendet werden sollte. Bei den Ergebnissen dieser numerischen Modellierungen von Randwertproblemen sollten daher alle im Feld messbaren und bekannten Größen zur Validierung herangezogen werden (z.B. Verformungsmessung während des Tunnelvortriebs, Kriechraten von Hängen in Abhängigkeit des Grundwassers, Lage von Gleitflächen). Diese bekannten Größen können sich von Anwendungsfall zu Anwendungsfall unterscheiden und sind individuell zu wählen. Grundsätzlich gilt natürlich, umso mehr Details bekannt und messbar sind, desto besser die Prognosen. Zusätzlich helfen Sensitivitätsanalysen dabei, diejenigen Parameter zu bestimmen, die für die jeweilige Fragestellung relevant sind [8]. Neben den Unsicherheiten in der Parameterbestimmung spielt auch eine andere Unsicherheit bei geotechnischen Untersuchungen eine große Rolle, nämlich die Unsicherheit bezüglich des geologischen Untergrundmodells. Die geologischen Untergrundmodelle, vor allem jene, die dann Einzug in die geotechnischen Berechnungen finden, sind zumindest starke Vereinfachungen, wenn nicht sogar oftmals abgeleitete Interpretationen von Oberflächendaten der tatsächlichen Gegebenheiten vor Ort. Um diesen Unsicherheiten Rechnung zu tragen, wäre es notwendig verschiedenen geologisch mögliche Modelle in den Modellierungen mitzuberechnen. Zudem wäre eine Kategorisierung der Unsicherheiten wünschenswert, z. B. nach Art (Messunsicherheit, Modellunsicherheit), nach Wissensstand (knowns, unknowns), oder nach quantifizierbar/nicht quantifizierbar. Damit ließe sich eine systematischere Bewertung der Unsicherheiten erreichen.

## **3 Parameteridentifikation durch Rückrechnung**

### **3.1 Finite Element Prognose**

Für repräsentative Finite Element Modellierung ist die Auswahl geeigneter Materialmodelle (z. B. Mohr-Coulomb, Hardening Soil, Hypoplastizität) genauso entscheidend wie die Bestimmung (spannungsabhängiger) Parameter. Auch hier gilt, dass das Materialmodell ebenfalls der Fragestellung angepasst sein muss. So haben „einfache“ Materialmodelle durchaus ihre Berechtigung, wenn die Fragestellung dazu passt. Bei Tunnelbauprojekten, mit einer Kombination

aus Entlastungs- und Belastungsbereichen, ist es aber zumindest nötig, die Möglichkeit zu haben verschiedene Steifigkeit für Be- und Entlastung zu berücksichtigen [1, 7].

Im Rahmen einer Studie von Saadati et al. [6] wurde während der Planungsphase eine FEM-basierte Prognose für einen Tunnel in der Karwendel-Region durchgeführt. Die geologische Komplexität des Standortes, inklusive starker Faltung und inhomogener Gesteinszusammensetzung, erschwerte die numerische Abbildung. Der Tunnel wurde mit RS2 in einer 2D-Plane-Strain Berechnung unter Berücksichtigung möglichst realitätsnaher Randbedingungen modelliert, dies berücksichtigte die Vortriebsphasen, die unterschiedlichen Stützsysteme (Spritzbeton, Gitterträger) und die verschiedenen Querschnitte.

Eine weitere Studie in diesem Bereich, ist die Modellierung von Tunnel- und Hangstabilität im Projekt St. Michael [5]. Das Zusammenspiel zwischen Tunnelstatik und Hangbewegungen hat einen starken Einfluss auf die Parameteridentifikation und macht diese, durch die fortlaufend wechselnde Geometrie und Geologie komplex. In dieser Fallstudie wurden dreidimensionale Interaktionen über RS2 und Dips analysiert, um Wechselwirkungen zwischen Tunnelvortriebsrichtung und Felsrutschungen im Modell möglichst realitätsnah abzubilden.

Bei beiden oben erwähnten Tunnelbauprojekten wurden Finite Element Modellierungen als Planungs- und Vortriebsgrundlage erstellt und während der Bauausführung mit Messwerten validiert, bzw. die Prognosen entsprechend angepasst.

### **3.2 Feldmessungen**

Der vertretbare Aufwand der Messkampagne hängt vom Projektrisiko ab. Ab einem Punkt, an dem zusätzliche Messungen keinen Mehrwert hinsichtlich Kosten-Nutzen-Abwägung oder Sicherheitsrelevanz mehr bringen, sollte das Messkonzept überdacht werden. Dies ist allerdings nicht immer im Vorfeld genau abschätzbar. Während des Baus beider oben genannter Projekte [5, 6] wurde ein umfassendes Monitoring durchgeführt: Konvergenzmessungen, Setzungsmessungen (wenn möglich), Inklinometer- sowie Deformationsmessungen an der Ortsbrust und bildeten die Grundlage für eine kontinuierliche Bauüberwachung. Solche kontinuierlichen Messdatensätze ermöglichen es, das Verformungsverhalten des Gebirges während der Bauphasen direkt mit den Modellergebnissen zu vergleichen. Als anschauliches Beispiel kann ein Detail einer der beiden Fallstudien herangezogen werden bei dem deutliche Diskrepanzen zwischen Finite Element Prognose und Messdaten, insbesondere zwischen Tunnelmeter 135 und 160 festgestellt wurden. Das stellt die im Vorfeld getroffene Annahme einer homogenen Lithologie berechtigterweise in Frage (Abbildung 2).

Die Studie „AI-Powered Geotechnics“ in [3] stellt anschaulich zusammen, dass Auswertungen des Monitoringsystems im Tunnelbau zunehmend durch KI-gestützte Verfahren ergänzt wird. Diese Systeme erlauben eine Fast-Echtzeit-Auswertung der Gebirgsreaktion und liefern ein kontinuierliches Datenfeedback für modellbasierte Entscheidungen und bieten somit eine schnelle und fundierte Voraussetzung für adaptive Kalibrierungen.




Abbildung 2: Rückgerechnete Tunnelverformung durch eine Backanalyse [5]

### 3.3 Backanalysis

Zur fortlaufenden Anpassung der numerischen Modelle um eine Minimierung der Abweichungen zu erreichen kam unter anderem die Methode der Backanalysis zum Einsatz. Die Modellparameter wurden im Berechnungsmodell systematisch händisch angepasst, um eine möglichst gute Übereinstimmung zwischen berechneten und gemessenen Verschiebungen zu erzielen. Die Fehlerfunktion basiert auf mittleren quadratischen Abweichungen zwischen simulierten und gemessenen Verschiebungen an diskreten Punkten (Hier: Tunnelmeter) quantifiziert und unter der Annahme, dass alle Messpunkte gleiches Gewicht haben [5, 6].

Diese Methode ermöglichte die gezielte Anpassung von Parametern wie dem Elastizitätsmodul, dem Reibungswinkel, der Kohäsion und der einaxialen Druckfestigkeit. Die auf diesem Wege rückgerechneten Werte wichen in mehreren Tunnelabschnitten signifikant von den ursprünglich angenommenen Werten ab (z. B. eine Reduktion des Elastizitätsmoduls von 5000 MPa auf 4250 MPa in Meter 145, siehe Abbildung 3). Infolgedessen wurde auch das geplante Stützsystem hinsichtlich seiner Wirksamkeit überprüft und entsprechend angepasst.




Abbildung 3: Rückgerechnete Werte des Elastizitätsmoduls bei Backanalysis [5]

### 3.4 KI-basierte Optimierungsverfahren

Der Einsatz von KI kann diesen Kalibrierungsprozess erheblich beschleunigen und strukturieren. Algorithmen wie genetische Algorithmen, Particle Swarm Optimization oder Bayes'sche Optimierung ermöglichen eine vortriebsbegleitende und auf aktuelle Messwerten basierenden effiziente Suche der am besten geeigneten Parameter im mehrdimensionalen Parameterraum für die im Vorfeld durchgeführten und so laufend adaptierten FE-Berechnungen [3, 4]. Zusätzlich gibt es auch die Möglichkeit durch sogenannte Surrogate Models, vereinfachte Ersatzmodelle auf Basis neuronaler Netze oder Regressionsverfahren die in manchen Fällen aufwendige FE-Berechnungen substituieren können. So kann eine große Zahl möglicher Parameterkombinationen in vertretbarer Rechenzeit getestet und bewertet werden.

In Zukunft ist es denkbar und sogar wahrscheinlich, dass inverse Modellierung, also die Rückrechnung bestpassender Parameter für ein numerisches Modell, direkt mit Echtzeitdaten aus dem Monitoring verbunden wird. KI-gestützte Verfahren könnten dann adaptive Modelle erzeugen, die sich kontinuierlich an das reale Gebirgsverhalten anpassen. Die in [6] gezeigte methodische Kombination aus Forward- und Back-analysis kann hierfür eine fundierte Grundlage bilden. Im Umkehrschluss können neben der Nutzung von Monitoring Daten für eine fortlaufende Anpassung der numerischen Modelle auch Ergebnisse der Modellierung verwendet werden um neue sensitive Bereiche während des Bauablaufs zu identifizieren und entsprechend das Monitoringsystem anzupassen.

In diesem Zusammenhang identifizieren Saadati et al. [3] mehrere Herausforderungen für den aktuellen Einsatz von KI in der Tunnelstabilitätsanalysen: unstrukturierte Datensätze, mangelnde Standardisierung bei geotechnischen Datenformaten, nicht immer eindeutige Interpretierbarkeit der Modelle, sowie das Fehlen validierter Trainingsdatenbanken. Die Autoren schlagen daher die Einigung auf standardisierte Datenformate, die Entwicklung zentraler Datenplattformen und domänenspezifischer ML-Frameworks für unterirdische Bauwerke vor, um eine breitere Anwendbarkeit und Validierbarkeit zukünftig zu erreichen.

## 4 Fazit

Die Kombination aus klassischen geotechnischen Verfahren und modernen KI-Methoden bietet große Chancen zur Verbesserung der Parameteridentifikation für charakteristische Werte bei Laborversuchen und auch bei Randwertproblemen. Während in den Laborversuchen die Streuung charakteristischer Parameter durch Untersuchungen zur Reproduzierbarkeit von Laborversuchen durch z.B. mehrfachen Einbau unter möglichst identischen Einbaubedingungen untersucht werden kann, eignen sich weiterführend eine systematische Datenerfassung als Grundlage für eine probabilistische Auswertung, die durchaus durch ML Methoden ergänzt werden sollte. Zusätzlich unterstützen numerische Sensitivitätsanalysen ein Gefühl für relevante Parameterbandbreiten zu bekommen.

Bei Randwertproblemen, wie Tunnelbauprojekten und Stabilitätsanalysen ist eine fortlaufende Validierung der gewählten Berechnungsansätze während der Planung, spricht geologisches Modell, Materialmodell, Randbedingungen und Eingangsparameter fortlaufend während der Bauausführung oder Projektüberwachung notwendig. Hier eignen sich ebenfalls statistische Methoden, aber zunehmend auch KI-basierte Inversanalysen. Diese gekoppelten inversen Analysen können auf der einen Seiten aus den Monitoringdaten heraus eine Anpassung der Bauausführung bedingen, aber auch aus den Modellierungsergebnissen heraus Defizite im Monitoringsystem erkenntlich machen. Die vorgestellten Fallstudien zeigen das Potenzial datengetriebener Verfahren für eine effektivere Nutzung der erhobenen Monitoringdaten, ein fortlaufende und robustere FE-Kalibrierung und führt letztlich zu einer resilientere geotechnische Planung. Gleichzeitig bestehen weiterhin Herausforderungen für die Anwendung datengetriebener statistischer Methoden und Methoden im Machine Learning: Datenstandardisierung, Integration inverser Methoden in Planungsprozesse sowie der Zugang zu ausreichend großen, qualitätsgesicherten Trainingsdatensätzen. Die Erfassung und Bereitstellung ausreichend großer Datensätze und die Weiterentwicklung entsprechender KI-Werkzeuge wird entscheidend sein, um das volle Potenzial intelligenter Modell-Messwert-Integration auszuschöpfen. Den Ingenieur:innen der Zukunft wird in diesem Zusammenhang eine wichtige zusätzliche Rolle zukommen: Die Modelle werden immer komplexer werden, die inversen Analysen immer automatisierter, die Plausibilitätskontrolle sollte aber dennoch noch nicht gänzlich aus menschlicher Hand gegeben werden, denn alle die KI nutzen, wissen dass diese mitunter auch dazu neigt zu Gefallen und zu Halluzinieren.

## References

- [1] Focke, N.; Bathaeian, I.; Schneider-Muntau, B. (2025) On the sensitivity of model parameters to tunnel deformations in soft soils. *Geotechnik* 1–10. <https://doi.org/10.1002/gete.202400029>
- [2] Medicus, G.; Schneider-Muntau, B. (2019) Simulations of Fine-Meshed Biaxial Tests with Barodesy. *Geosciences*, 9, 20. <https://doi.org/10.3390/geosciences9010020>
- [3] Saadati, G., Javankhoshdel, S., Mohebbi Najm Abad, J. *et al.* (2024) AI-Powered Geotechnics: Enhancing Rock Mass Classification for Safer Engineering Practices. *Rock Mech Rock Eng.* <https://doi.org/10.1007/s00603-024-04189-7>
- [4] Saadati, G.; Schneider-Muntau, B.; Javankhoshdel, S.; Mett, M.; Kontrus, H. (2023): Future Challenges in Tunnel Stability Analysis Using Artificial Intelligence and Machine

- Learning. In: Proceedings of the Rocscience International Conference (RIC 2023). Paris: Atlantis Press (= Atlantis Highlights in Engineering), ISBN 978-94-6463-258-3, S. 317 - 324. <https://www.atlantis-press.com/proceedings/ric-23/125993936>
- [5] Saadati, G.; Schneider-Muntau, B.; Javankhoshdel, S.; Mett, M.; Kontrus H. (2023): Interaction of Tunneling and Rock Slope Stability, Case Study St. Michael Rail Ways Tunnel (Wachau Railway/Lower Austria). In: Proceedings of the Rocscience International Conference (RIC 2023). Paris: Atlantis Press (= Atlantis Highlights in Engineering), ISBN 978-94-6463-258-3, S. 278 - 284. <https://www.atlantis-press.com/proceedings/ric-23/125993929>
- [6] Saadati, G.; Schneider-Muntau, B.; Javankhoshdel, S.; Mett, M.; Kontrus, H. (2023): Usage of Monitoring Data to Optimize and Validate the Geotechnical Parameters of Rock Properties in the Underground Space. In: Schubert, W; Kluckner, A: Proceedings of the ISRM 15th International Congress on Rock Mechanics and Rock Engineering & 72nd Geomechanics Colloquium – Challenges in Rock Mechanics and Rock Engineering. Salzburg, Austria, October 9-14, 2023. Salzburg: Austrian Society for Geomechanics, S. 1108 - 1113.
- [7] Salehi, B.; Golshani, A.; Rostami, J.; Schneider-Muntau, B. (2024) Simulation of Complex Support Systems for Large Span Tunnels: Investigation on Support Interferences and Effects of Constitutive Models. KSCCE Journal of Civil Engineering, 28, 11, 5309-5324, <https://doi.org/10.1007/s12205-024-5581-4>.
- [8] Schneider-Muntau, B., Dai, X. and Fellin, W. (2022), Sensitivity analyses of the different influencing factors on numerical investigations of landslides. Geomechanics and Tunneling, 15: 582-595. <https://doi.org/10.1002/geot.202200014>
- [9] Schneider-Muntau, B., Schranz, F. and Fellin, W. (2018), The possibility of a statistical determination of characteristic shear parameters from triaxial tests. Beton- und Stahlbetonbau, 113: 86-90. <https://doi.org/10.1002/best.201800038>

## Author

Univ.-Prof. Dr.-Ing. Barbara Schneider-Muntau  
Universität Innsbruck  
Institut für Infrastruktur  
Technikerstr. 13  
6020 Innsbruck  
Tel.: +43 (0) 512 - 507 / 62382  
e-mail: [barbara.schneider-muntau@uibk.ac.at](mailto:barbara.schneider-muntau@uibk.ac.at)  
Web: [https://www.uibk.ac.at/geotechnik/staff/schneider\\_muntau.html.de](https://www.uibk.ac.at/geotechnik/staff/schneider_muntau.html.de)



# **Smart Lab: Konzept zur automatisierten Bodenansprache und zur Generierung von digitalen Partikelmodellen unter Nutzung von KI**

**Göta Bürkner, Mohamed Abdennadher**

## **Abstract:**

Soil is examined using the human senses: by sight, smell, and haptically by pressing and rubbing the soil between thumb and finger. Soil examination is influenced by the experience and geological background knowledge of the person conducting the analysis. Experienced laboratory technicians can roughly accurately predict the soil parameters to be determined in laboratory tests. By using an automated laboratory soil analysis procedure with the use of machine learning techniques it should be in first step at least possible to predict the difference between cohesive and non-cohesive soils.

This study presents a generative framework for synthesizing complex 3D particle geometries, addressing the challenges of microstructural design and data scarcity in material science. Our pipeline leverages a Autoencoder (AE) to efficiently compress high-dimensional 3D point clouds into a compact, semantically rich 2D latent space. Subsequently, a Denoising Diffusion Probabilistic Model (DDPM) learns the intricate distribution of these latent representations. By sampling from the trained diffusion model and decoding via the AE, we demonstrate the ability to generate diverse, novel, and geometrically plausible 3D particle shapes.

## **1 Konzept zur automatisierten Bodenansprache im Labor unter Zuhilfenahme der Technik des Maschinellen Lernens**

### **1.1 Ausgangslage**

Bei der Bohrung wird der Baugrund vom Bohrmeister und/oder von der beauftragten Bohrüberwachung angesprochen. Die Bodenansprache erfolgt organoleptisch mit den menschlichen Sinnen; durch Betrachten, durch Riechen und haptisch, indem der Boden zwischen Daumen und Zeigefinger gedrückt und verrieben wird. Die frühere Ansprache durch Schmecken und Fühlen im Mund wird aufgrund der im Boden oft vorhandenen Schadstoffe nicht mehr praktiziert. Minerale werden meist unter Zuhilfenahme einer Lupe identifiziert, Karbonate werden meist mittels Salzsäure identifiziert. Im Labor wird der Boden erneut angesprochen (Abbildung 1) und das Laborprogramm festgelegt.

Die Bodenansprache ist geprägt von der Erfahrung des Ansprechenden sowie seines Geologischen Wissen hinsichtlich der Genese des Bodens. Erfahrene Laboranten können bereits auf Grundlage der Bodenansprache grob zutreffend die in den nachfolgenden Laborversuchen zu

ermittelnden Bodenparameter voraussagen. Mittels eines automatisierten Laborverfahrens und unter Zuhilfenahme der Technik des Maschinellen Lernens unter Berücksichtigung der physikalischen Randbedingungen (Physics-Informed Neural Networks, PINN) müsste es möglich sein, mindestens die Unterscheidung in bindige und nichtbindige Böden vorzunehmen.



Abbildung 1: Bodenansprache an einem Kern/Liner

## 1.2 Stand der Forschung

Die weltweit dynamische Fortentwicklung der Technik des Maschinellen Lernens führt bereits aktuell in vielen Bereichen des Lebens zu einer Vielzahl von Anwendungsmöglichkeiten (Ertel, W., 2025; Pajankar, A., & Joshi, A., 2022).

Ansatzweise findet erste Forschung in der Bodenartbestimmung der Bodenkunde statt. Hier wird insbesondere die Unterscheidung verschiedener Ackerböden ausgewählter Standorte angestrebt. Landwirtschaftliche Bodenoberflächen werden fotooptisch erfasst und mittels Künstlicher Intelligenz unterschieden nach vorgegebenem Benennungsschema. Zum Beispiel beschreiben Prabhavathi und Kuppusamy (2022) sowie Alsolai et al. (2023) erste Ansätze, wie mittels Photographien von unterschiedlichen Böden anhand der Farben unterschieden wird in mehrere Bodentypen. Auch Ishtiaq et al. (2024), Wachter et al. (2022), Jalapur und Patil (2025) und Inazumi et al. (2020) widmen sich diesem Thema. Es zeichnet sich zwar ein zunehmender Trend ab, Datensätze öffentlich und frei zugänglich zu machen (Cerek et al., 2024a; Sekulic et al., 2024; Dao und Banduch, 2023), jedoch liegt die Anzahl der verwendeten Datengrundlagen bei allen Arbeiten oftmals im Bereich sehr kleiner Stückzahlen vor.

In der Geotechnik beschreiben Chala und Ray (2023) maschinelles Lernen an vorhandenen Datensätzen von 232 Spitzendrucksondierungen. Die Bestimmung der Bodenarten nach der Klassifikation von Robertson, Index IC, erfolgt, indem die Daten unterteilt wurden in 80 % zu Trainingszwecken und 20 % zu Testzwecken. Saadati et al. (2024) geben eine aktuelle Zusammenfassung zu Methoden der Klassifizierung von Felsmassen mittels Techniken der Künstlicher Intelligenz mit dem Ziel, Felsmassen zu klassifizieren hinsichtlich ihrer Hangstabilität. Cerek et al. (2024b,2024c,2025) zeigen auf, dass es mit der Technik des Deep Learning (DL) möglich ist, Vorhersagen des komplexen, nichtlinearen Spannungs-Dehnungs-Verhaltens von Böden bei Versuchen mit konstanter Dehnungsrate (CRS, Constant Rate of Strain) zu treffen.

Weitere Beispiele dafür, subjektive menschliche Sinneswahrnehmungen durch maschinelle Methoden zu objektivieren und im Mittel zutreffender zu gestalten finden sich in der Medizin. Es gibt Bestrebungen, dass Ärzte mittels hochentwickelter Sensorhandschuhe beim Abtasten des Menschen Daten digital erfassen. Neben der Erfassung der Bewegung der Finger liegt ein Schwerpunkt auf dem Druckempfinden in den Fingerkuppen. Vergleichbar den Druckmessmatten, welche zum Beispiel in der Orthopädie oder dem Autobau zum Einsatz kommen, wird an in den Fingerkuppen von Handschuhen verbauten Drucksensoren geforscht. Die Kräfte werden gemessen und über die Fingerkuppenfläche wird eine Spannungsverteilung, zeitlich aufgelöst, ermittelt und aufgezeichnet. Pasquale (2018) beschreibt Handschuhe, die mit kommerziellen druckempfindlichen Widerstandssensoren (Resistive Force Sensor, FSR), im Bereich der Fingerkuppen bestückt wurden. Ozioko und Dahiya (2022) beschreiben Handschuhe mit kommerziellen Berührungssensoren, welche in Echtzeit Informationen wie zum Beispiel Drücke aufnehmen können. Pattabiraman et al. (2025) haben einen magnetischen Tastsensor, genannt eFlesh, entworfen. Das Messprinzip beruht auf Magnetfeldänderungen. Die Technik der druckempfindlichen Widerstandssensoren kommt aktuell noch nicht annähernd der Feinauflösung der menschlichen Fingerkuppe nahe. Zudem ist die Messtechnik selbst bislang im Bereich weniger Millimeter noch sehr grob und mit nennenswerter Materialdicke behaftet. Interessant ist ein Ansatz von Lee et al. (2020a und 2020b), veröffentlicht in Science. Sie entwarfen eine Sensortechnik, welche klein ist, kaum aufträgt und damit das natürliche Tastgefühl lediglich sehr gering beeinflusst. Entwickelt wurde eine lediglich 2  $\mu\text{m}$  dünne Polymerfolie, genannt Nanomesh-Drucksensor (Abbildung 2), bestehend aus einem Nanomesh-Sensor, laminiert auf Polymerfolie mit einem Neigungswinkel von  $52^\circ$ . Der Messbereich dieser Technik ist bislang noch sehr eingeschränkt. Zudem kann bei der Erfassung von Echtzeitdaten starkes Rauschen auftreten; der Einsatz von Algorithmen wie DMD, AugDMD oder AugDMDc kann hier Abhilfe schaffen (Abdennadher et al., 2025, Williams-Riquier et al., 2024).




Abbildung 2: Nanomesh-Drucksensor an einem Zeigefinger befestigt, Maßstab 5 mm, Lee et al., 2020

### 1.3 Methode und erwartbare Zusammenhänge

Mit einem automatisierten und vom subjektiven Eindruck des Laboranten unabhängigen physikalischen Laborverfahrens zur Bodenprüfung sollen Datensätze an Modellböden und natürlichen Böden erzeugt werden. Mit diesen Labordatensätzen und zusätzlich aus numerischen Finite-Elemente-Berechnungen mit Parametervariationen generierten Datensätzen der Nachrechnungen des Laborversuchsaufbaues soll kommerzielle Software zu Maschinellern Lernen unter

Berücksichtigung der physikalischen Randbedingungen (Physics-Informed Neural Networks, PINN) trainiert werden, eine Unterscheidung in bindige und nichtbindige Böden vorzunehmen.

Im Einzelnen wird im Labor eine Bodenprobe in einem Stahlzylinder zentrisch unter eine Einaxiale Druckpresse positioniert, eine Druckmessfolie wird mittig auf die Bodenoberfläche platziert, ein zylindrischer Stahlstempel wird mittig auf die Druckmessfolie platziert und ange-dockt an die Einaxiale Druckpresse. Abbildung 3 zeigt schematisch den Versuchsaufbau zu Versuchsbeginn.




Abbildung 3: Versuchsaufbau zu Versuchsbeginn, schematisch, zum Zeitpunkt  $t = 0$  min.  
Links: Beispiel nichtbindiger Boden. Rechts: Beispiel bindiger Boden.

Das Versuchsprogramm sieht eine axiale Verschiebung von 4 mm vor mit einer Geschwindigkeit von 1 mm/min. Nach 4 Minuten beendet die Einaxiale Druckpresse den Vorschub, die axiale Kraftmessdose zeichnet jedoch noch fur weitere 16 Minuten auf. Abbildung 4 zeigt schematisch den Versuchsaufbau zum Zeitpunkt von Minute 4 bis Minute 20.

Es steht zu erwarten, dass ein bodenabhangiges Belastungs- und ein bodenabhangiges Relaxationsverhalten eintritt. Beides wird von der Kraftmessdose der Einaxialen Presse (Abbildung 5) sowie spannungs- und zeitabhangig von der Druckmessfolie detektiert. Einen schematischen Uberblick auf die in den Versuchen erwarteten Spannungsverteilungen zu ausgewahlten Zeitpunkten gibt Abbildung 6.

Die Oberflache der Bodenprobe soll vor Versuchsbeginn und direkt nach Abschluss der 16minutigen Relaxationszeit in der vertikalen Draufsicht mittels Oberflachen-3D-Messung, kontaktlos, hochauflosend, aufgenommen werden. Eine Auswertung hinsichtlich Oberflachenanderungsverteilung im Profilschnitt sowie die Ermittlung der Rauigkeit der Bodenoberflache soll vorgenommen werden.

Es steht zu erwarten, dass eine bodenabhangige Oberflachenanderungsverteilung im Profilschnitt zu detektieren ist. Ferner steht zu erwarten, dass die Bodenoberflachenrauigkeitsmessungen zwischen bindigen und nichtbindigen Boden eindeutig differieren.




Abbildung 4: Versuchsaufbau, schematisch, zum Zeitpunkt t = 4 min bis t = 20 min




Abbildung 5: Im Versuch erwarteter Verlauf der Kraft, schematisch




Abbildung 6: Im Versuch erwartete Spannungsverteilungen zu  $t = 0 \text{ min}$ ,  $t = 4 \text{ min}$  und  $t = 20 \text{ min}$ , schematisch

## 1.4 Fazit

Die beschriebene Methode könnte langfristig zur Qualitätskontrolle im Labor dienen. Es ist zu erwarten, dass sich die Fehlertoleranz des Maschinellen Lernens mit jedem neuen Datensatz verbessert und sehr langfristig im Mittel zutreffendere Ergebnisse liefert als ein Laborant. Die Stärke des Maschinellen Lernens, dass ein System nicht vollumfänglich qualitativ und quantitativ beschrieben sein muss, soll sich hierbei zu Nutze gemacht werden. Da es sich um einen neuartigen Ansatz zur Bodenansprache handelt, sind Modifikationsnotwendigkeiten zu vermuten.

## 2 Generierung von digitalen Partikelmodellen unter Nutzung von KI

### 2.1 Einleitung

In der Materialwissenschaft und im Maschinenbau ist das Verständnis und die Manipulation der Mikrostruktur von Partikeln entscheidend für die Leistungsfähigkeit von Materialien. Insbesondere die komplexen Geometrien von Granulaten und deren räumliche Anordnung beeinflussen maßgeblich Eigenschaften wie Schüttdichte, Fließverhalten und Stabilität. Traditionelle Methoden zur Charakterisierung und Synthese solcher Partikel sind oft zeitaufwändig, kostspielig und können die inhärente Komplexität dieser Strukturen nur unzureichend erfassen.

Um diese Herausforderungen zu adressieren, präsentiert dieser Beitrag einen Ansatz zur Generierung und Analyse komplexer 3D-Partikelgeometrien mittels generativer Modelle. Wir nutzen die Synergien eines Autoencoders (AE) und eines Denoising Diffusion Probabilistic Models (DDPM), um eine Pipeline zu schaffen, die in der Lage ist, realistische Partikelformen zu lernen, im latenten Raum zu manipulieren und neue, plausible Geometrien zu synthetisieren. Der Autoencoder dient dazu, hochdimensionale Punktwolken von Partikeln in einen kompakten, niedrigdimensionalen latenten Raum zu transformieren, während das Diffusionsmodell diesen latenten Raum lernt und es ermöglicht, neue Punkte darin zu erzeugen.

### 2.2 Methodik

Unser Ansatz kombiniert zwei neuronale Netzwerkarchitekturen: einen Punktwolken-Autoencoder für die dimensionsreduzierte Darstellung von 3D-Geometrien und ein DDPM Modell zur Generierung neuer Latent Space-Repräsentationen.

#### 2.2.1 Datenakquise und Preprocessing

Der Ausgangspunkt unserer Pipeline sind 3D-Mesh-Daten realer Partikel. Diese wurden zunächst in einheitliche Punktwolken umgewandelt. Um die Komplexität der Partikelgeometrie zu erfassen und gleichzeitig eine standardisierte Eingabe für die neuronalen Netze zu gewährleisten, wurden folgende Schritte durchgeführt:

1. **Laden und Abtasten der OBJ-Dateien:** Jede OBJ-Datei, die ein Partikel repräsentiert, wurde geladen. Um eine konsistente Anzahl von Punkten zu erhalten und die Komplexität zu reduzieren, wurde die Farthest Point Sampling (FPS)-Methode angewendet, um eine feste Anzahl von 1000 Punkten pro Partikel zu extrahieren.
2. **Zentrierung und Skalierung:** Die gesampelten Punktwolken wurden um ihren Schwerpunkt zentriert und anschließend normalisiert, indem die Punkte durch den maximalen absoluten Wert entlang aller Dimensionen geteilt wurden. Dies gewährleistet, dass alle Partikel in einem einheitlichen Koordinatensystem und Größenbereich  $(-1, 1)$  liegen, was für das Training neuronaler Netze unerlässlich ist.
3. **Merkmalextraktion:** Zusätzlich zu den 3D-Koordinaten  $(x, y, z)$  wurden für jeden Punkt geometrische und topologische Merkmale extrahiert. Dies erfolgte durch die Konstruktion eines  $k$ -nearest neighbors ( $k$ -NN)-Graphen für jede Punktwolke und die

Anwendung von Vektoreinbettungen für jeden Knoten im Graphen basierend auf Random Walk. Diese Einbettungen liefern kontextuelle Informationen über die lokale Struktur des Partikels. Die resultierenden Datenpunkte sind somit 19-dimensionale Vektoren (3D-Koordinaten + 16 Merkmale).

4. **Datenaugmentation:** Um die Robustheit und Generalisierungsfähigkeit der Modelle zu erhöhen und Overfitting zu reduzieren, wurde eine Datenerweiterung durch Rotation der Partikel durchgeführt. Jedes Partikel im Datensatz wurde zufällig um die x-, y- und z-Achse rotiert, wodurch die effektive Größe des Trainingsdatensatzes verdoppelt wurde.

## 2.3 Der Punktwolken-Autoencoder

Der Autoencoder ist das Herzstück unserer Dimensionsreduktion. Seine Hauptaufgabe ist es, die hochdimensionalen 19-dimensionalen Punktwolken in eine kompakte, semantisch reiche sogenannte 2D-Latent-Space-Repräsentation zu überführen und umgekehrt.

### 2.3.1 Architektur des Autoencoders

Der Autoencoder besteht aus einem Encoder und einem Decoder:

- **Encoder:** Der Encoder ist als 1D- Convolutional Neural Network aufgebaut, da er Merkmale entlang der Punktachse extrahiert. Er verarbeitet die Eingabe von (Batch\_Size, Input\_Dim, Num\_Points). Die Convolutional Layer mit ReLU-Aktivierung reduzieren schrittweise die Dimensionalität, bevor eine finale Schicht die Daten auf 2304 Dimensionen abbildet. Eine Adaptive Max Pooling 1D-Schicht aggregiert die Merkmale über alle Punkte zu einem einzigen Vektor. Eine Tanh-Aktivierungsfunktion sorgt dafür, dass die latenten Werte im Bereich von (-1, 1) liegen, was für das nachfolgende Diffusionsmodell vorteilhaft ist. Der resultierende „flache“ Vektor wird dann in ein 2D-Bild der Größe 48 x 48 umgeformt, das als Eingabe für das Diffusionsmodell dient.




Abbildung 7: Schematische Darstellung des Autoencoders

- **Decoder:** Der Decoder ist ein „Fully Connected“ Netzwerk. Er nimmt den Vektor aus dem latenten Raum entgegen, expandiert ihn über mehrere Schichten mit ReLU-Aktivierung und gibt schließlich einen Vektor der Größe  $3 \times 1000$  aus. Dieser Vektor wird dann zu einer 3D-Punktwolke umgeformt. Der Decoder ist darauf trainiert, die ursprüngliche 3D-Punktwolke aus ihrer latenten Repräsentation so genau wie möglich zu rekonstruieren.

### 2.3.2 Trainingsziel des Autoencoders

Der Autoencoder wurde mit einer **Chamfer-Distanz** als Verlustfunktion trainiert. Die Chamfer-Distanz misst die durchschnittliche nächstgelegene Entfernung zwischen zwei Punktwolken, was sie ideal für die Formrekonstruktion macht, da sie sowohl die Formähnlichkeit als auch die Punktverteilung berücksichtigt. Das Training zielte darauf ab, die Rekonstruktionsqualität zu maximieren, sodass die latenten Vektoren eine effiziente und aussagekräftige Darstellung der Partikelgeometrie bilden.

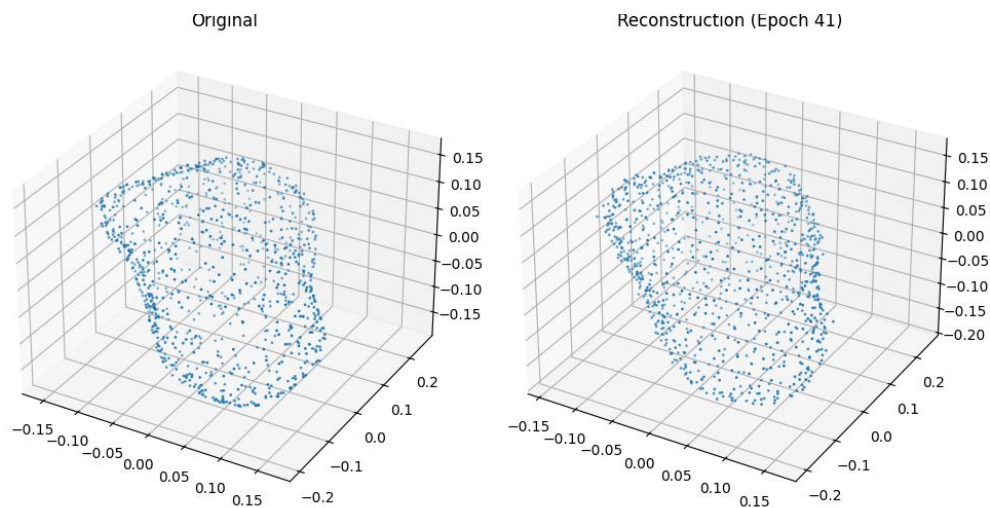


Abbildung 8: Gegenüberstellung der Punktwolken Darstellung eines Originalpartikels und seiner Autoencoder-Rekonstruktion

## 2.4 Denoising Diffusion Probabilistic Models (DDPM)

Sobald der Autoencoder trainiert ist und effiziente 2D-Latent-Space-Repräsentationen erzeugen kann, kommt das Diffusionsmodell zum Einsatz. DDPMs sind generative Modelle, die darauf trainiert werden, Rauschen (Noise) schrittweise aus Daten zu entfernen und dabei lernen, die zugrundeliegende Datenverteilung zu modellieren.

### 2.4.1 Funktionsweise des Diffusionsmodells

Das Diffusionsmodell arbeitet in zwei Phasen:

1. **Forward Diffusion (Rauschprozess):** In dieser Phase wird das 2D-Latentbild schrittweise mit Gaußschem Rauschen angereichert bis das Bild vollständig zu reinem Rauschen wird. Dies geschieht über eine feste Anzahl von Zeitschritten. Die Intensität des hinzugefügten Rauschens wird durch ein spezielles Steuerungsprofil, den *Beta*

*Schedule*, kontrolliert. In diesem Fall verwenden wir hierfür eine Cosinus-Funktion, die eine kontinuierliche Steuerung des Rauschpegels über die gesamte Diffusionskette hinweg ermöglicht.

2. **Reverse Diffusion (Denoising-Prozess):** Dies ist die Lernphase des Modells. Ein neuronales Netzwerk, wird darauf trainiert, das Rauschen aus den verrauschten latenten Bildern zu prognostizieren und zu entfernen. Bei jedem Zeitschritt  $t$  lernt das Netzwerk den ursprünglichen, nicht verrauschten Zustand oder das hinzugefügte Rauschen zu schätzen. Ziel ist es, von einem zufälligen Rauschbild ausgehend schrittweise das ursprüngliche latente Bild wiederherzustellen.

#### 2.4.2 Architektur des Neuronalen Netzwerkes

Das Neuronale Netzwerk ist ein spezielles Convolutional Neural Network (CNN), das für Denoising-Aufgaben optimiert ist und wie folgt aufgebaut ist:

- **Encoder-Pfad:** Mehrere Downsampling-Blöcke reduzieren die räumliche Auflösung des latenten Bildes. Jeder Block besteht aus ResidualBlock-Modulen und einem Layer mit Stride (2x2), um die Dimensionen zu halbieren.
- **Bottleneck:** In der niedrigsten Auflösung befindet sich ein Bottleneck, der weitere ResidualBlocks und eine **SelfAttention**-Schicht enthält. Die SelfAttention-Schicht ermöglicht es dem Netzwerk, globale Abhängigkeiten über das gesamte latente Bild hinweg zu erfassen.
- **Decoder-Pfad:** Mehrere Upsampling-Blöcke rekonstruieren die räumliche Auflösung. Diese Blöcke im Decoder-Pfad verwenden transponierte Convolutional Layer (ConvTranspose2d), um die räumliche Auflösung schrittweise wieder zu erhöhen. Auch hier kommen die ResidualBlock-Module zum Einsatz. Entscheidend für eine präzise Rekonstruktion ist die Einbindung von *Skip-Connections*: Diese Verbindungen verknüpfen Merkmale aus den korrespondierenden Schichten des Encoder-Pfades direkt mit denen des Decoder-Pfades. Das unterstützt das Netzwerk erheblich dabei, feine Details während der Bildrekonstruktion zu bewahren
- **Zeiteinbettungen:** Um die Abhängigkeit vom aktuellen Zeitschritt  $t$  zu modellieren, werden die Timesteps in hochdimensionale, sinusförmige Einbettungen transformiert und an jeder ResidualBlock-Schicht in das Netzwerk eingespeist.

#### 2.4.3 Training des Diffusionsmodells

Das Diffusionsmodell lernt, sich auf den 2D-Latentbildern des Autoencoders zurechtzufinden. Im Kern geht es beim Training darum, den Fehler bei der Rauschvorhersage über alle Zeitschritte hinweg so gering wie möglich zu halten.

Dafür setzen wir einen Adam-Optimierer ein, der die Gewichte des Modells anpasst. Um die Lernrate während der Trainings-Epochen optimal zu steuern, nutzen wir einen *CosineAnnealingLR-Scheduler*. Dieser sorgt dafür, dass die Lernrate sanft abnimmt. Das ist wichtig, denn so kann das Modell stabiler konvergieren und "überschießt" nicht unnötig, wenn es sich einem optimalen Zustand nähert.

Da wir hier bewusst auf Techniken wie GradScaler oder autocast verzichten, findet das Training komplett im Standard-Gleitkommaformat (FP32) statt, ohne den Einsatz von gemischter Präzision.

## 2.5 Ergebnisse und Diskussion

Nach dem Training beider Modelle wird die gesamte Pipeline zur Generierung neuer Partikel genutzt.

### 2.5.1 Synthese neuer Partikelgeometrien

Der Prozess zur Generierung neuer Partikel ist wie folgt:

1. **Rausch-Sampling:** Das Diffusionsmodell startet seine Generierung mit einem völlig zufälligen Rauschbild, das einer Gaußschen Verteilung folgt.
2. **Denoising-Schritte:** Das Diffusionsmodell führt eine Sequenz von Denoising-Schritten durch, um dieses Rauschbild schrittweise in ein strukturiertes 2D-Latent-Bild umzuwandeln. Jeder Schritt entfernt einen Teil des Rauschens, bis ein plausibles latentes Bild entsteht.
3. **Dekodierung:** Das generierte 2D-Latent-Bild wird in einen flachen Vektor umgewandelt und dem Decoder des Punktwolken-Autoencoders zugeführt.
4. **3D-Punktwolken-Generierung:** Der Decoder transformiert den latenten Vektor zurück in eine 3D-Punktwolke.

Die resultierenden Punktwolken repräsentieren neu synthetisierte Partikelgeometrien, die zuvor nicht im Trainingsdatensatz vorhanden waren, aber die gelernten morphologischen Eigenschaften der realen Partikel widerspiegeln.

### 2.5.2 Bewertung der Generierungsqualität

Die visuelle Inspektion der generierten Partikel zeigt, dass das Modell in der Lage ist, plausible und kohärente 3D-Formen zu erzeugen. Die Partikel weisen eine Vielfalt an Formen und Merkmalen auf, die den Eigenschaften des ursprünglichen Datensatzes entsprechen. Qualitative Beobachtungen legen nahe, dass das Modell erfolgreich die Verteilung der Partikelgeometrien gelernt hat.

Zukünftige Arbeiten könnten eine quantitative Bewertung der Generierungsqualität umfassen, beispielsweise durch die Berechnung der Fréchet Inception Distance (FID) oder der Coverage-Metriken im latenten Raum oder sogar direkt auf den Punktwolken, um die Vielfalt und Realismus der generierten Proben objektiv zu beurteilen.

## 2.6 Fazit und Ausblick

Dieses Paper hat eine vollständige Pipeline zur **generativen Modellierung komplexer 3D-Partikelgeometrien** mittels eines Autoencoders und eines Denoising Diffusion Probabilistic Models vorgestellt. Wir haben demonstriert, wie die Kombination dieser Architekturen es ermöglicht, hochdimensionale Punktwolken in einen latenten 2D-Raum zu komprimieren, diesen Raum zu modellieren und anschließend neue, qualitativ hochwertige Partikelformen zu synthetisieren.




Abbildung 9: Beispielhafte Visualisierung synthetisch generierter 3D-Partikelgeometrien

Als zukünftige Arbeiten könnten die Integration von Konditionierungen in das Diffusionsmodell untersucht werden, um Partikel mit spezifischen Eigenschaften (z.B. Größe, Rauheit) zu generieren. Auch die Skalierung auf größere Datensätze und komplexere Geometrien sowie die Verfeinerung der Modelle für noch höhere Rekonstruktions- und Generierungsqualität stellen spannende Forschungsrichtungen dar. Letztendlich ebnet dieser Ansatz den Weg für eine effizientere und datengesteuerte Entwicklung von Materialien mit präzise kontrollierten Mikrostrukturen.

## References

- [1] Abdennadher, M.A., Williams-Riquer, F., Dao, D. A. & Grabe, J. (2025): Data-Driven Modeling of Structural Dynamics: Improving Measurement Noise Robustness with Augmented Dynamic Mode Decomposition. In: Proceedings of the 10th International Conference on Computational Methods in Structural Dynamics and Earthquake Engineering (COMPDYN 2025) at Rhodes Island, Greece, No. 24480

- [2] Alsolai, H., Rizwanullah, M., Maashi, M., Othman, M., A. Alneil, A., & Atta Abdelmaheed, A. (2023): Leveraging Gradient-Based Optimizer and Deep Learning for Automated Soil Classification Model. *Computers, Materials & Continua*, 76(1), 975–992.
- [3] Cerek, K., Dao, D. A., Hadjiloo, E. & Grabe, J. (2024a): Dataset of Simulated CRS Tests for Advanced Soil Parameter Identification. *Datensatz*, TUHH Universitätsbibliothek, DOI 10.15480/882.9435
- [4] Cerek, K., Gupta, A., Dao, D. A.; Hadjiloo, E. & Grabe, J. (2024b): Python Implementation of Bidirectional LSTM for Sequential Data Processing. *Source Code*, TUHH Universitätsbibliothek, DOI 10.15480/882.13190
- [5] Cerek, K., Dao, D. A., Hadjiloo, E. & Grabe, J. 2024c. Application of LSTM time series forecasting method for predicting compression curves of soil. *Proceedings of the 17th Pan-American Conference on Soil Mechanics and Geotechnical Engineering*, La Serena, Chile
- [6] Cerek, K., Gupta, A., Dao, D. A., Hadjiloo, E., & Grabe, J. (2025): Predicting soil stress-strain behaviour with bidirectional long short-term memory networks. *Machine Learning and Data Science in Geotechnics*.
- [7] Chala, A. T., & Ray, R. (2023): Assessing the Performance of Machine Learning Algorithms for Soil Classification Using Cone Penetration Test Data. *Applied Sciences*, 13(9), Article 9.
- [8] Dao D. A. & Banduch M. (2023): Geotechnical Laboratory Investigation on the Baltic Sea Sand Sample Z\_VC\_011. *Datensatz*, TUHH Universitätsbibliothek, DOI 10.15480/882.8440
- [9] Ertel, W. (2025): *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*. Springer Fachmedien Wiesbaden.
- [10] Inazumi, S., Intui, S., Jotisankasa, A., Chaiprakaikeow, S., & Kojima, K. (2020): Artificial intelligence system for supporting soil classification. *Results in Engineering*, 8, 100188.
- [11] Ishtiaq, A., Abrar, M. M., Haque, M. M., Goswami, P., Rahman, M. A., Rishad, J. K., Hassan, M. T., & Asif, K. A. (2024): A comprehensive study of soil classification and identification using deep machine learning algorithm based on soil images.
- [12] Jalapur, S., & Patil, N. (2025): An Integrated Deep Learning Framework for Soil Type Classification. *SN Computer Science*, 6(3), 251.
- [13] Lee, S., Franklin, S., Hassani, F. A., Yokota, T., Nayeem, M. O. G., Wang, Y., Leib, R., Cheng, G., Franklin, D. W., & Someya, T. (2020a): Nanomesh pressure sensor for monitoring finger manipulation without sensory interference. *Science*, 370(6519), 966–970.

- [14] Lee, S., Franklin, S., Hassani, F. A., Yokota, T., Nayeem, M. O. G., Wang, Y., Leib, R., Cheng, G., Franklin, D. W., & Someya, T. (2020b): Nanomesh pressure sensor for monitoring finger manipulation without sensory interference. *Science*, 370(6519), 966–970.
- [15] Ozioko, O., & Dahiya, R. (2022): Smart Tactile Gloves for Haptic Interaction, Communication, and Rehabilitation. *Advanced Intelligent Systems*, 4(2), 2100091.
- [16] Pajankar, A., & Joshi, A. (2022): *Hands-on Machine Learning with Python: Implement Neural Network Solutions with Scikit-learn and PyTorch*. Apress.
- [17] Pattabiraman, V., Huang, Z., Panozzo, D., Zorin, D., Pinto, L., & Bhirangi, R. (2025): eFlesh: Highly customizable Magnetic Touch Sensing using Cut-Cell Microstructures (No. arXiv:2506.09994). arXiv.
- [18] Prabhavathi, V., & Kuppusamy, P. (2022): A study on Deep Learning based Soil Classification. 2022 IEEE 4th International Conference on Cybernetics, Cognition and Machine Learning Applications (ICCCMLA), 428–433.
- [19] Saadati, G., Javankhoshdel, S., Mohebbi Najm Abad, J., Mett, M., Kontrus, H., & Schneider-Muntau, B. (2024): AI-Powered Geotechnics: Enhancing Rock Mass Classification for Safer Engineering Practices. *Rock Mechanics and Rock Engineering*.
- [20] Sekulic, L., Hadjiloo, E., Kacper, C., Grabe, J. (2024): Experimental dataset of triaxial tests with cemented sand. TUHH Open Research (TORE), DOI: 10.15480/882.9674
- [21] Wachter, P., Schoning, J., Kedieng Ebongue Fendji, J. L., & Deiglmayr, K. (2022): A Smartphone App for Simple Soil Structure Analysis. 2022 IEEE International Humanitarian Technology Conference (IHTC), 101–107.
- [22] Williams-Riquer, F., Chmelnizkij, A., Alkateeb, D. & Grabe, J. (2024): Prediction of induced soil vibration during pile vibrodriving using Dynamic Mode Decomposition (DMD). International Conference on Recent Advances in Structural Dynamics (RASD). Southampton, UK.

## **Author**

Univ.-Prof. Dr.-Ing. Jürgen Grabe  
 Technische Universität Hamburg  
 Institut für Geotechnik und Baubetrieb  
 Harburger Schloßstraße 36  
 21079 Hamburg  
 Tel.: +49 (0) 40 - 42878 / 3762  
 Fax: +49 (0) 40 - 42878 / 3721  
 e-mail: grabe@tu-harburg.de  
 Web: www.tu-harburg.de/gbt

# Innovative Automatisierung zum Einbau reproduzierbarer Bodenproben

Tim Pucker

**Abstract:** Es wird ein innovativer Ansatz zur reproduzierbaren Herstellung von Sandproben mithilfe von Roboterarmen vorgestellt. Ziel ist die Erzeugung gleichmäßiger Lagerungsdichten in Sandproben zur anschließenden weiterführenden Untersuchung des mechanischen Verhaltens. Zwei verschiedene Roboterarme, der industrielle KUKA KR 16 R1610-2 und der kompakte RoArm-M2-S, wurden zur Durchführung standardisierter Einbauverfahren verwendet. Die Einbauversuche mit drei unterschiedlichen Sandtypen (Fein- bis Grobsand) zeigen eine gute Reproduzierbarkeit bei der Herstellung unterschiedlich dicht gelagerter Sandproben. Durch gezielte Steuerung von Fallhöhe und Bewegungspfaden konnten die Einbaudichten und Porenzahlen mit sehr geringen Variationskoeffizienten reproduziert werden.

## 1 Einleitung

Für eine systematische Untersuchung des mechanischen Materialverhaltens von Böden ist die Herstellung reproduzierbarer Proben unerlässlich. Soll beispielsweise die Scherfestigkeit eines Sandes in Abhängigkeit vom Anfangsspannungszustand analysiert werden soll, wird die Probe im Verlauf des Versuchs zerstört. Um den Versuch unter einem veränderten Anfangsspannungszustand zu wiederholen, muss die Probe idealerweise erneut in denselben Anfangszustand gebracht werden. Eine zentrale Rolle spielt hierbei die Lagerungsdichte des Sandes, die bei allen Proben homogen und identisch sein sollte. Das Erreichen einer homogenen Ziel-Lagerungsdichte stellt selbst erfahrene Laborfachkräfte vor erhebliche Herausforderungen.

Zur möglichst exakten Reproduktion der Einbau- bzw. Lagerungsdichte bei Sandproben wurden im Rahmen dieser Arbeit erste Versuchsdurchläufe mit zwei verschiedenen Roboterarmen durchgeführt. Ziel ist es, beim wiederholten Probeneinbau stets eine definierte, gleichmäßige Lagerungsdichte zu erzielen.

Zur Sicherstellung der Homogenität und Wiederholgenauigkeit wurden in der Vergangenheit unterschiedliche Methoden entwickelt, etwa Einrieseln, Sedimentieren, Verdichten durch Stampfen oder Vibration. In den hier vorgestellten Versuchen mit Roboterarmen wird ausschließlich die Einrieselmethode eingesetzt.

Das Einrieseln von Sand aus einer festgelegten Fallhöhe gehört zu den am häufigsten verwendeten Verfahren zur Präparation trockener Sandproben. [1] untersuchten den Einfluss der Fallhöhe auf die erzielte relative Dichte. Die beim Auftreffen übertragene Energie bestimmt maßgeblich

die erreichte Lagerungsdichte. Größere Fallhöhen führten dabei in der Regel zu höheren Lagerungsdichten.

Um eine hohe Reproduzierbarkeit zu erreichen, wurden verschiedene Einrieseltechniken sowie Automatisierungslösungen entwickelt. So stellt [2] ein mechanisches Streugerät zur Herstellung großvolumiger Proben mit bis zu  $6,80 \text{ m}^3$  vor. Dabei gewährleistet ein automatisierter Trichter mit Bewegungssensoren eine konstante Fallhöhe. Die Wiederholgenauigkeit wird mit  $\pm 1\%$  angegeben, lässt sich jedoch anhand der veröffentlichten Daten nicht vollständig nachvollziehen. Innerhalb einzelner Proben variiert die Lagerungsdichte zwischen  $0,25\%$  und  $2,78\%$ . Die Versuche wurden mit Ticino-Sand durchgeführt.

[3] setzen eine bewegliche Einrieselvorrichtung ein, bei der sowohl die Fallhöhe als auch die Ausflussöffnung variiert werden. Dadurch konnten Proben mit definierter relativer Dichte und hoher Gleichmäßigkeit erzeugt werden. In [4] wurden große Proben mit Abmessungen von bis zu  $900 \text{ mm} \times 900 \text{ mm} \times 1000 \text{ mm}$  mittels Einrieselverfahren hergestellt. Durch Anpassung der Fallhöhe und Sieböffnungen wurden relative Dichten von bis zu  $99\%$  erzielt, wobei innerhalb der Proben Schwankungen der relativen Dichte von bis zu  $7\%$  festgestellt wurden.

Der Einsatz von Robotern zur Untersuchung von Bodenproben ist bislang wenig dokumentiert. [5] beschreibt eine mobile, robotische Plattform zur automatisierten Bodenprobennahme. Dieses System kann eigenständig navigieren, Proben entnehmen und speichern. Der Einsatz erfolgt insbesondere für oberflächennahe Bodenprobenentnahmen im Gelände. [6] entwickeln ebenfalls ein autonomes Robotersystem zur Entnahme oberflächennaher Bodenproben, das zusätzlich den Nitratgehalt automatisiert bestimmen kann.

[7] setzen einen Roboterarm ein, um planetare Landesysteme mit definierten Geschwindigkeiten in ein Sandbett fallen zu lassen und die daraus resultierenden Interaktionskräfte zwischen Boden und Landeeinheit zu analysieren. In [8] wird ein industrieller Sechssachsroboter zur Durchführung kleiner geotechnischer Modellversuche verwendet, unter anderem zur Analyse des Versagensverhaltens von Streifenfundamenten sowie zur Untersuchung von Boden-Schneidprozessen.

Eine weitere Entwicklung stellt das ROBOCONE Projekt dar ([9] und [10]), bei dem eine CPT-Sonde um zwei robotische Module erweitert wird. Die Entwicklung zielt auf die Anwendung im Offshorebereich zur Ermittlung der Mobilisierungsfunktionen axialer und lateraler Pfahlwiderstände ab. Ein Modul dient zur Ermittlung des Mobilisierungsverhaltens der Mantelreibung und wird als t-z Modul bezeichnet, siehe [10]. Das zweite Modul soll genauere Informationen zur Mobilisierung des lateralen Widerstands in Form von p-y Kurven liefern, siehe [9].


In [11] werden erste Untersuchungen zum Einsatz von Roboterarmen bei der Bestimmung der lockersten Lagerung von Sanden vorgestellt. Weiterhin wird die Reproduzierbarkeit bei der Bestimmung des Schüttwinkels von Sanden untersucht.

## 1.1 Roboterarm KUKA

Für die durchgeführten Versuche kommt der Roboterarm KUKA KR 16 R1610-2 zum Einsatz. Dieser verfügt über eine maximale Reichweite von 1612 mm sowie eine Nenntaglast von 16 kg. Der Arm ist in der Lage sechs Achsen unabhängig voneinander zu bewegen, wobei je nach Achse Geschwindigkeiten von bis zu 630 %/s erreicht werden können. Eine grafische Darstellung des Arbeitsbereichs ist in Abbildung 1 zu sehen.



Arbeitsraumgrafik



Traglastdiagramm




Abbildung 1: Versuchsaufbau und Spezifikationen des Roboterarm KUKA KR 16 R1610-2

## 1.2 Roboterarm RoArm-M2-S

Zum Einbau kleinerer Bodenproben wird der Roboterarm RoArm-M2-S verwendet. Der RoArm-M2-S von Waveshare ist ein 4-achsiger Roboterarm mit einer maximalen Traglast von 500 g. Er besitzt eine 360° drehbare Basis und drei bewegliche Gelenke, wodurch ein Arbeitsbereich mit einem Durchmesser von bis zu einem Meter möglich ist. Durch sein direkt angetriebenes Gelenkdesign erreicht der Arm eine Wiederholgenauigkeit von etwa 0,088°. Der Roboter ist auf einer mobilen Plattform montiert und wird über eine USB-Schnittstelle angesteuert (siehe Abbildung 2).




Abbildung 2: Versuchsaufbau zur Herstellung einer Bodenprobe in lockerster Lagerung mit Hilfe des Roboterarms RoArm-2M-S

### 1.3 Untersuchte Sande

Zur Untersuchung der Reproduzierbarkeit beim Einbau von Sandproben werden drei verschiedene Sande eingesetzt. Elbsand und HCU Sand werden als Mittelsande, der Hamburger Sand als Grobsand eingestuft. Die Kornverteilungskurven der verwendeten Sande sind in Abbildung 4 dargestellt. Die Ergebnisse der jeweils lockersten und dichtesten Lagerungszustände, ermittelt nach klassischen Laborverfahren gemäß [12], sind in Tabelle 1 zusammengefasst.

Tabelle 1: Übersicht über die durchgeführten Versuche

Versuchssand	Dichte $\rho$ [g/cm <sup>3</sup> ]		Porenzahl $e$ [-]		Verdichtungsfäh.	Ungleichförm.
	min	max	min	max	$I_f$ [-]	$U$ [-]
BigBag	1,517	1,767	0,500	0,746	0,492	2,51
Elbsand	1,498	1,732	0,524	0,761	0,452	1,77
Hamburger Sand	1,398	1,666	0,579	0,882	0,523	1,91

Abbildung 3 zeigt mikroskopische Aufnahmen der drei Versuchssande bei identischer Vergrößerung. Der Elbsand (Mitte) weist als typischer Flusssand überwiegend rundliche Körner auf. Beim HCU-Sand (links) sind ebenfalls größtenteils rundliche Partikel vorhanden, jedoch ist auch ein Anteil kantiger oder gebrochener Körner erkennbar. Der Hamburger Sand (rechts) enthält hingegen nur wenige rundkörnige Bestandteile.




Abbildung 3: Mikroskopaufnahmen der Versuchssande bei gleicher Vergrößerung; von links nach rechts: HCU Sand, Elbsand, Hamburger Sand

## 2 Versuche zur lockersten Lagerung

Die Reproduzierbarkeit des Einbaus von Bodenproben wird anhand der Bestimmung der lockersten und dichtesten Lagerung in Anlehnung an [12] untersucht. Da der Roboterarm RoArm-M2-S für eine Traglast von maximal 500 g ausgelegt ist, wird das Zylindervolumen zur Bestimmung der lockersten Lagerung abweichend zu [12] von 443 cm<sup>3</sup> auf 183 cm<sup>3</sup> reduziert. Daraus resultiert eine erforderliche Probenmasse von ca. 350 g, die der Roboterarm gut handhaben kann. Die




Abbildung 4: Sieblinien der untersuchten Sande

Abmessungen des Zylinders betragen 83 mm in der Höhe und 53 mm im Durchmesser. Der Einbau des Bodens in den Zylinder erfolgt mit Hilfe eines Trichters, der mit konstanter Geschwindigkeit von 0,5 mm/s angehoben wird. Dadurch wird ein konstantes Ausfließen des Bodens aus dem Trichter gewährleistet und gleichzeitig das Entstehen einer signifikanten Fallhöhe verhindert. Der Durchmesser des Trichterauslaufs beträgt 12 mm. Der Versuchsaufbau ist in Abbildung 2 dargestellt.

## 2.1 Ergebnisse

Es wurden jeweils 15 Versuche am HCU Sand, am Elbsand und am Hamburger Sand durchgeführt. Die Ergebnisse sind in Abbildung 5, Abbildung 6 und Abbildung 7 dargestellt. Die ermittelten Einbaudichten  $\rho_d$  bei lockerster Lagerung zeigen für die drei untersuchten Sande eine sehr gute Reproduzierbarkeit. Für die minimale Dichte  $\rho_d$  beträgt der Variationskoeffizient 0,29 % für den HCU Sand, 0,16 % für den Elbsand und 0,20 % für den Hamburger Sand. Für die maximale Porenzahl  $e_{\max}$  beträgt der Variationskoeffizient 0,68 % für den HCU Sand, 0,37 % für den Elbsand und 0,42 % für den Hamburger Sand.

## 2.2 Vergleich mit Versuchsergebnissen nach [12]

Die Ergebnisse des automatisierten Probeneinbaus bei lockerster Lagerung werden mit den vorangegangenen Untersuchungen zur Bestimmung der lockersten Lagerung nach [12] verglichen. Der Vergleich ist in Tabelle 2 dargestellt. Die Abweichungen zwischen der Dichte in




Abbildung 5: Auswertung der erreichten lockersten Einbaudichte  $\rho_d$  und der entsprechenden Porenzahl  $e$  für den HCU Sand

Tabelle 2: Vergleich der Ergebnisse mit den nach [12] ermittelten Werten

Versuchssand	Dichte $\rho_d$ [g/cm <sup>3</sup> ]			Porenzahl $e$ [-]		
	Roboter	DIN	Abweichung	Roboter	DIN	Abweichung
HCU Sand	1,498	1,517	-1,25 %	0,770	0,746	3,22 %
Elbsand	1,491	1,498	-0,47 %	0,777	0,761	2,10 %
Hamburger Sand	1,403	1,398	0,36 %	0,889	0,882	0,79 %

genormten Versuch und dem automatisierten Einbau sind kleiner als 1,25 %. Für den Vergleich der Porenzahlen sind die Abweichungen kleiner 3,22 % .




Abbildung 6: Auswertung der erreichten lockersten Einbaudichte  $\rho_d$  und der entsprechenden Porenzahl  $e$  für Elbsand

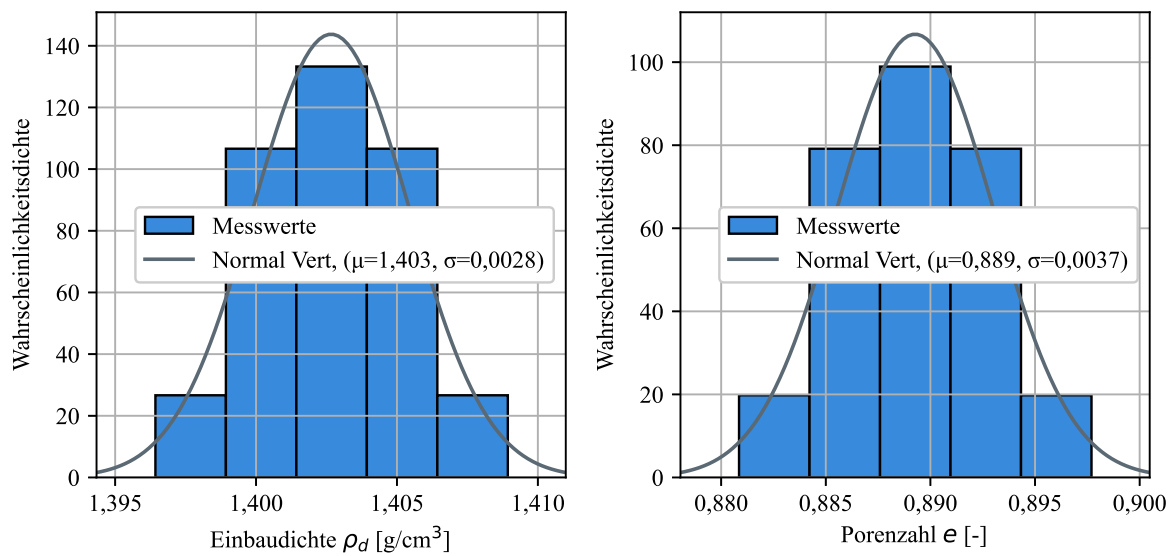


Abbildung 7: Auswertung der erreichten lockersten Einbaudichte  $\rho_d$  und der entsprechenden Porenzahl  $e$  für den Hamburger Sand

## 3 Probeneinbau

### 3.1 Versuchsaufbau und Durchführung RoArm 2 MS

Die Reproduzierbarkeit der Herstellung von Sandproben mit vorgegebener Lagerungsdichte wird ebenfalls mit dem Roboterarm RoArm-M2-S und dem in Abbildung 2 dargestellten Probenbehälter untersucht. Es werden Versuche mit einer konstante Fallhöhe von 100 mm durchgeführt. Dazu wird die Einrieselvorrichtung mit konstanter Geschwindigkeit zentrisch über dem Probekörper hochgezogen. Anschließend wird das Gewicht der Probe und über das Probenvolumen die Lagerungsdichte bestimmt. Insgesamt wurden 15 Versuche mit Elbsand durchgeführt.

Der Versuchsaufbau zur Bestimmung der lockersten Lagerungsdichte wird für diese Versuchsreihe modifiziert. Der gelenkig gelagerte Trichter wird durch ein starr geführtes Rohr mit einem Innendurchmesser von 7 mm ersetzt. An das Rohr wird mit einem Zulaufschlauch ein Sandreservoir angeschlossen, das einen stetigen Sandzulauf gewährleistet. Der Versuchsaufbau ist in Abbildung 8 dargestellt.




Abbildung 8: Versuchsaufbau zur Einbau der definierten Lagerungsdichten mit dem Roboterarm RoArm MS 2, links: Darstellung mit Zulaufschlauch und Sandreservoir, rechts: Detailaufnahme des fest geführten Einfüllrohres.

Die Ergebnisse der Versuchsreihe sind in Abbildung 9 dargestellt. Die erreichte Porenzahl liegt im Mittel bei 0,57 mit einer Abweichung von 0,78%. Die relative Lagerungsdichte  $D_R$  liegt im Mittel bei 80,73% mit einer Abweichung von 2,2%.

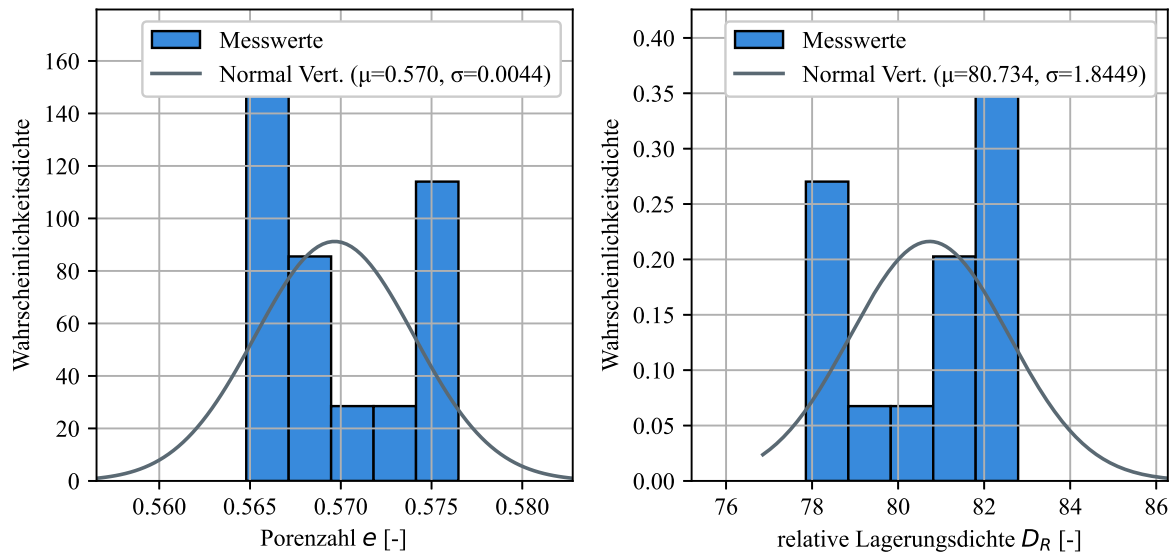


Abbildung 9: Auswertung der an Versuchen mit Elbsand erreichten Porenzahlen  $e$  und relativen Lagerungsdichten  $D_R$  bei einer konstanten Fallhöhe von 100 mm

### 3.2 Versuchsaufbau und Durchführung KUKA

An den KUKA Roboterarm wird ein Trichter mit einem Auslaufrohr befestigt. Der Trichter ist fest mit dem Arm verbunden und die Neigung des Trichters wird durch den Arm kontrolliert. Damit wird sichergestellt, dass der Trichter während der Versuche nicht verkippen kann. Das Auslaufrohr ist vor Versuchsbeginn durch eine Kugel verschlossen, die durch den Arm gesteuert geöffnet werden kann. Über die Öffnungsgröße kann der Durchfluss kontrolliert werden. Der Versuchsaufbau ist in Abbildung 1 links dargestellt.

Zu Versuchsbeginn wird der Trichter mit trockenem Sand gefüllt. Anschließend wird der Trichter in einen Eimer, der an einem fest vorgegebenen Ort platziert ist, bewegt. Dort wird das Kugelventil geöffnet und das Auslaufrohr des Trichters wird vom Zentrum des Eimers ausgehend in einer spiralförmigen Bewegung nach außen bewegt. Sobald das Auslaufrohr auf der äußeren Bahn am Rand des Eimers angekommen ist, wird der Trichter leicht angehoben und die spiralförmige Bewegung wieder in Richtung des Zentrums fortgesetzt. Dadurch erfolgt ein lagenweiser Bodeneinbau in den Eimer bei konstanter Fallhöhe und konstanter Bewegungsgeschwindigkeit. Der Bewegungspfad des Roboterarms ist in Abbildung 10 dargestellt.

Der Einbau erfolgt bis zu einer vorgegebenen Füllhöhe von 200 mm wobei die Füllhöhe auf drei Achsen im Eimer gemessen und kontrolliert wird. Anschließend wird der Eimer gewogen und das Gewicht der eingebauten Bodenmasse bestimmt. Aus dem Gewicht und dem Volumen wird die Einbaudichte  $\rho$  bestimmt.

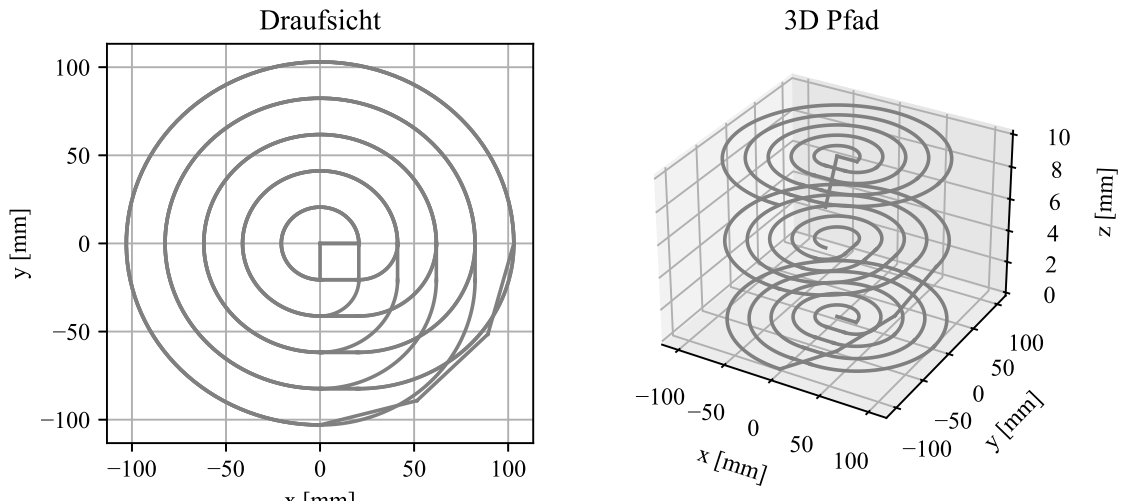


Abbildung 10: Bewegungspfad des Roboterarms zum Einbau von Sandproben in einen Eimer.

### 3.3 Ergebnisse

Es wurden 10 Versuche bei einer Bewegungsgeschwindigkeit des Roboterarms von 50 mm/s durchgeführt. Die gemessenen Einbaudichten und die resultierenden relativen Lagerungsdichten sind in Abbildung 11 dargestellt. Es zeigt sich eine sehr gute Reproduzierbarkeit bei dem Einbau des Versuchssandes. Die Standardabweichung beträgt bei Auswertung der Einbaudichte  $0,0016 \text{ g/cm}^3$  und bei Auswertung der relativen Lagerungsdichte  $0,6048 \%$ . Das entspricht einem Variationskoeffizienten von  $0,1 \%$  für die Einbaudichte und  $0,9 \%$  für die relative Lagerungsdichte.

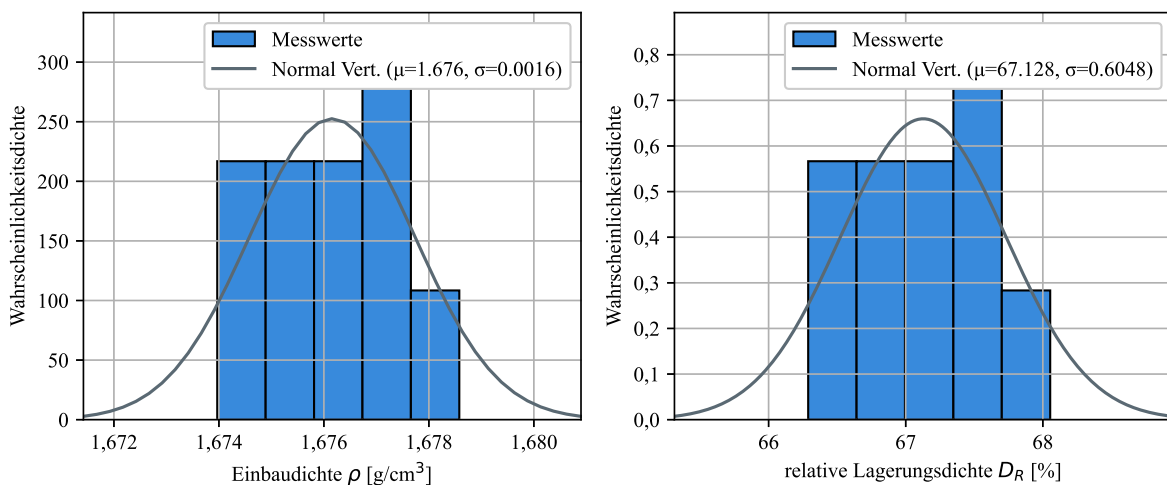


Abbildung 11: Auswertung der erreichten Einbaudichte  $\rho$  und der relativen Lagerungsdichte  $D_R$  bei einer Bewegungsgeschwindigkeit von 50 mm/s

## 4 Zusammenfassung

Der Beitrag beschreibt die Entwicklung und Anwendung automatisierter Verfahren zur reproduzierbaren Herstellung von Sandproben. Dabei soll die Lagerungsdichte von Sandproben gezielt und reproduzierbar eingestellt werden. Zur Umsetzung wurden zwei Roboterarme verwendet: der sechssachsige Industrieroboter KUKA KR 16 R1610-2 für größere Probenmengen und der kleinere vierachsige RoArm-M2-S für präzise Kleinproben. Drei unterschiedliche Sande wurden klassifiziert und in Versuchsreihen eingebaut. Die Methode des Einrieselns wurde dabei als einheitliches Einbauverfahren verwendet.

Die Ergebnisse zeigen eine sehr gute Wiederholgenauigkeit sowohl bei der lockersten Lagerung als auch beim gezielten Einbau einer definierten Lagerungsdichte. Abweichungen von Einbaudichte und Porenzahl zum genormten Verfahren zur Bestimmung der lockersten Lagerung nach [12] lagen jeweils unter 1,25 % für die Einbaudichte  $\rho_d$  bzw. 3,22 % für die Porenzahl  $e$ . Damit belegt die Studie, dass robotergestützte Verfahren einen vielversprechenden Beitrag zur Standardisierung und Automatisierung in der geotechnischen Versuchstechnik leisten können.

## Literatur

- [1] Vaid Y.P. und Negussy, D. (1984): Relative density of pluviated sand samples. *Soils and Foundations*, 24(2):101–105
- [2] Passalacqua R. (1991): A sand-spreader used for the reconstitution of granular soil models. *Soils and Foundations*, 31(2):175–180
- [3] Fretti C., Lo Presti D. C. F., und Pedroni, S. (1995): A Pluvial Deposition Method to Reconstitute Well-Graded Sand Specimens. *Geotechnical Testing Journal*, 18(2):292–298
- [4] Hariprasad C., Rajashekhar M. und Umashankar, B. (2016): Preparation of uniform sand specimens using stationary pluviation and vibratory methods. *Geotechnical and Geological Engineering*, 43:1909–1922
- [5] Väljaots E., Lehiste H., Kiik M. und Leemet, T. (2018): Soil sampling automation using mobile robotic platform. *Agronomy Research*, 16(3):917–922
- [6] Kitić, G., Krklješ, D., Panić M., Petes C., Birgermajer S. und Crnojević, V. (2022): Agrobot Lala - An autonomous robotic system for real-time, in-field soil sampling, and analysis of nitrates. *Sensors*, 22:4207
- [7] Schröder S., Witte L. und Zoest, T. (2011): Footpad-Terrain Interaction Tests with the robotic landing and mobility test facility (LAMA). *62nd International Astronautical Congress, IAC-11.A5.1.9*
- [8] Jin Z., Shi Z. und Hambleton, J.P. (2020): Small-scale geotechnical testing using a six-axis robot. *SPREE Internal Report No. 20-7/495S*, Northwestern University, Illinois

- [9] Creasey J., El Hajjar A., Conn A.T., Ibraim E., Martin G., Mahadik Y., Diambra A., Mylonakis G. und White, D.J. (2025): ROBOCONE: P-Y module design development and calibration chamber testing in sand. *Proceedings of ISFOG 2025, 5th International Symposium on Frontiers in Offshore Geotechnics, Nantes, France*
- [10] El Hajjar A., Creasey J., Conn A.T., Ibraim E., Martin G., Mahadik Y., Diambra A. und White, D.J. (2025): Concept design and preliminary testing towards a new ROBOCONE t-z module for in-situ cyclic soil characterization. *Proceedings of ISFOG 2025, 5th International Symposium on Frontiers in Offshore Geotechnics, Nantes, France*
- [11] Pucker, T. (2025): Zur Reproduzierbarkeit von Laborversuchen an Sandproben bei Anwendung von Roboterarmen. *Geotechnik, S. 1-8. <https://doi.org/10.1002/gete.202500005>*
- [12] DIN 18126 (2022): Baugrund, Untersuchung von Bodenproben - Bestimmung der Dichte nicht bindiger Böden bei lockerster und dichtester Lagerung 2022-10. *Beuth Verlag GmbH*

## Author

Univ.-Prof. Dr.-Ing. Tim Pucker  
HafenCity Universität Hamburg  
Arbeitsgebiet Geotechnik  
Henning-Voscherau-Platz 1  
20457 Hamburg  
Tel.: +49(0)40/42827-5494  
e-mail: [tim.pucker@hcu-hamburg.de](mailto:tim.pucker@hcu-hamburg.de)  
Web: [www.hcu-hamburg.de](http://www.hcu-hamburg.de)



# „Baustelle KI“: Chancen und Grenzen von künstlicher Intelligenz im Bauingenieurwesen

Alexander Chmelnizkij und Kay Smarsly

**Abstract:** Methoden der künstlichen Intelligenz (KI) prägen zunehmend nahezu sämtliche Bereiche des beruflichen und privaten Alltags und eröffnen auch im Bauingenieurwesen vielfältige Innovationspotenziale. Um diese Möglichkeiten sinnvoll zu erschließen, ist es erforderlich, geeignete KI-Anwendungen gezielt zu identifizieren und deren Integration in Lehre, Forschung und Praxis verantwortungsvoll umzusetzen. Allerdings birgt der unkritische oder uninformierte Einsatz von KI-Methoden das Risiko fehlerhafter Ergebnisse und irreführender Schlussfolgerungen. Zugleich zeigt sich, dass grundlegende Kenntnisse über Prinzipien des maschinellen Lernens, neuronale Netzwerkarchitekturen sowie Optimierungs- und Evaluationsmethoden derzeit in den Curricula des Bauwesens nur unzureichend vermittelt werden. Von zentraler Bedeutung sind hierbei insbesondere Kompetenzen zur kritischen Bewertung bestehender KI-Lösungen. Vor diesem Hintergrund gewinnen Methoden der erklärbaren KI (engl. „Explainable AI“, XAI) zunehmend an Bedeutung, da sie dazu beitragen, die KI-generierten Entscheidungen nachvollziehbar zu machen und die Modelltransparenz zu erhöhen. Der vorliegende Beitrag vermittelt nach einer kurzen Einführung wesentliche Grundlagen und Besonderheiten des maschinellen Lernens anhand eines exemplarischen Approximationsproblems, um deren Bedeutung für die ingenieurwissenschaftliche Lehre aufzuzeigen. Anschließend werden typische Netzwerkarchitekturen sowie beispielhafte Anwendungsfelder im Bauwesen vorgestellt und kritisch beleuchtet. Hierbei wird insbesondere auf die Rolle von XAI-Verfahren zur Validierung und Interpretation von KI-Modellen eingegangen. Abschließend werden zentrale Erkenntnisse zusammengefasst und Perspektiven für zukünftige Forschungsarbeiten aufgezeigt.

## 1 Einleitung

Die rasante Entwicklung der künstlichen Intelligenz (KI) und des maschinellen Lernens führte in den vergangenen Jahrzehnten zu tiefgreifenden Veränderungen und substanziellen Fortschritten in zahlreichen wissenschaftlichen und technischen Disziplinen [1]. KI-basierte Verfahren durchdringen mittlerweile nahezu sämtliche Bereiche des privaten wie beruflichen Alltags und eröffnen erhebliches Innovations- und Effizienzsteigerungspotenzial [2]. Mit diesen Möglichkeiten verbunden ist jedoch zugleich die Herausforderung, KI-Methoden reflektiert und verantwortungsvoll einzusetzen, um Fehlinterpretationen und daraus resultierende fehlerhafte Entscheidungen zu vermeiden [3].

Auch im Bauingenieurwesen gewinnt der bewusste Einsatz KI-basierter Methoden zunehmend an Bedeutung. Konkrete Anwendungsfelder reichen dabei von der automatischen Zustandsüberwachung und Schadensdiagnose über die datenbasierte Prognose bautechnischer Zustände mittels Sensorauswertung bis hin zur KI-gestützten Optimierung baulicher Strukturen und Baustoffe. Trotz dieser vielversprechenden Perspektiven zeigen die Curricula vieler Studiengänge im Bauwesen bislang deutliche Defizite in der Vermittlung fundamentaler KI-Konzepte, wie neuronaler Netzwerkarchitekturen, Optimierungsverfahren und geeigneter Evaluationsmethoden. Ein zielführender Einsatz der KI-Technologien im Bauwesen setzt deshalb nicht nur ein umfassendes Verständnis grundlegender Prinzipien des maschinellen Lernens voraus, sondern verlangt zugleich die Fähigkeit, KI-Modelle sowie deren Ergebnisse kritisch bewerten zu können [4]. An dieser Stelle gewinnen Verfahren der erklärbaren künstlichen Intelligenz (engl. "Explainable AI", XAI) eine zentrale Bedeutung, deren Ziel darin besteht, komplexe und ansonsten intransparente KI-Modelle für den Menschen nachvollziehbar und interpretierbar zu gestalten [6].

Um die dargestellten Potenziale der künstlichen Intelligenz umfassend und effektiv nutzen zu können, bedarf es einer fachübergreifenden Expertise, die sowohl informatische als auch bauingenieurwissenschaftliche Kompetenzen integriert. Genau hierin liegt die zentrale Stärke der Bauinformatik. Als etablierte Schnittstellendisziplin zwischen Bauwesen und Informatik nimmt die Bauinformatik sowohl in der Forschung als auch in der Lehre eine Schlüsselrolle ein, um komplexe digitale Herausforderungen praxisorientiert und zugleich wissenschaftlich fundiert zu lösen [19]. Die Bauinformatik hat sie seit Langem weltweit als Innovationsmotor etabliert, der nicht nur die Implementierung, sondern insbesondere auch die kritische Weiterentwicklung von KI-Technologien im Bauwesen entscheidend vorantreibt [20]. Um angehende Bauingenieurinnen und Bauingenieure optimal auf die digitalen Herausforderungen vorzubereiten und sie zu einer eigenständigen Weiterentwicklung von KI-basierten Lösungen zu befähigen, ist eine nachhaltige Verankerung bauinformatischer Inhalte in den Curricula der Bauingenieurstudiengänge unerlässlich [21].

Dieser Beitrag gliedert sich wie folgt: Zunächst werden grundlegende Prinzipien und Begriffe der künstlichen Intelligenz eingeführt sowie deren praktische Bedeutung anhand eines einfachen neuronalen Netzwerks veranschaulicht. Darauf aufbauend erfolgt eine Übersicht über Netzwerkarchitekturen mit besonderer Relevanz für das Bauingenieurwesen. Sodann wird die zentrale Rolle der erklärbaren KI für die Validierung und Interpretation neuronaler Modelle des Bauingenieurwesens vorgestellt. Abschließend fasst der Beitrag die wesentlichen Erkenntnisse zusammen und gibt einen Ausblick auf zukünftige Forschungs- und Lehransätze.

## **2 Prinzipien und Begriffe der künstlichen Intelligenz am Beispiel neuronaler Netzwerke**

In diesem Kapitel wird anhand des Beispiels eines einfachen neuronalen Netzwerks verdeutlicht, wie wichtig das grundlegende Verständnis der Funktionsweise von Methoden der künstlichen Intelligenz ist. Unter dem Begriff künstliche Intelligenz werden im Allgemeinen Systeme

me zusammengefasst, die Aufgaben lösen, für deren Bearbeitung typischerweise menschliche Intelligenz erforderlich ist. Aufgrund dieser sehr allgemeinen Definition erfolgt häufig eine Unterteilung in spezifische Teilgebiete [7], wobei besonders die Fähigkeiten zu adaptieren und zu lernen hervorgehoben werden. Systeme, deren Entscheidungsregeln vordefiniert sind und ohne menschliches Eingreifen nicht verändert werden können, gehören zur *symbolischen KI*. Demgegenüber basiert die *subsymbolische KI* auf neuronalen Netzwerken, die eigenständig Regeln direkt aus Daten ableiten [6]. Mit anderen Worten, symbolische KI beruht auf vordefinierten, expliziten Regeln und Wissensrepräsentationen, d.h. die Systeme agieren deterministisch und verändern ihr Verhalten nur durch gezielte menschliche Eingriffe; subsymbolische KI, wie neuronale Netzwerke, lernt hingegen implizit aus Beispieldaten, indem sie komplexe Muster ohne ausdrückliche Regelvorgaben erfassen [15]. Darüber hinaus existiert mit der *neurosymbolischen KI* ein hybrider Ansatz, der symbolische und subsymbolische Elemente kombiniert, indem beispielsweise logische Randbedingungen zur Steuerung des Lernprozesses eingesetzt werden. Abbildung 1 zeigt die Einteilung der künstlichen Intelligenz in symbolische, subsymbolische und neurosymbolische Verfahren einschließlich ihrer jeweiligen Unterkategorien. Neben dieser Klassifizierung ist insbesondere das Verständnis der spezifischen Merkmale jeder Kategorie von Bedeutung. Im weiteren Verlauf liegt der Fokus auf neuronalen Netzwerken als prominentem Vertreter der subsymbolischen KI. Diese Netzwerke haben sich mittlerweile zu einer eigenständigen Forschungsrichtung entwickelt und werden häufig stellvertretend für KI insgesamt genannt.

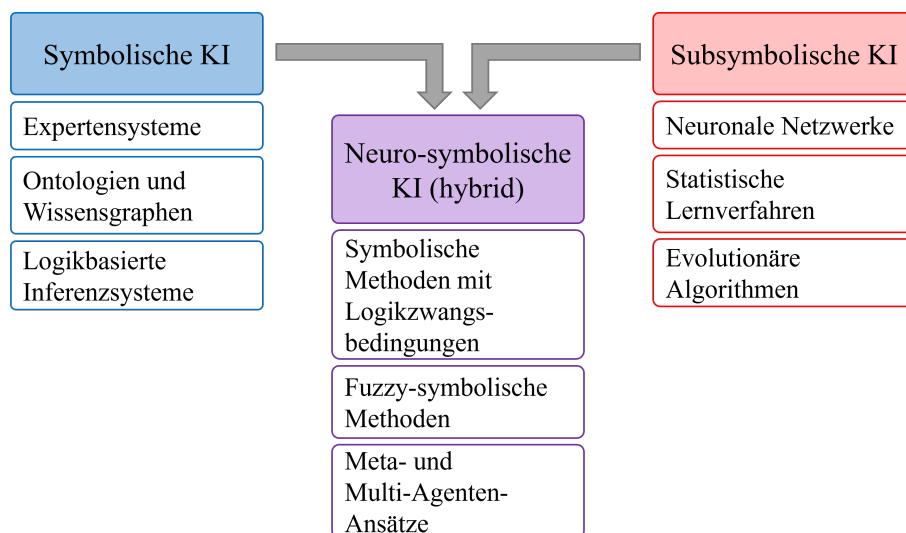


Abbildung 1: Übersicht über die Teilgebiete der künstlichen Intelligenz.

Zur Veranschaulichung der Funktionsweise und Bedeutung eines grundlegenden Verständnisses neuronaler Netzwerke wird im Folgenden ein einfaches Beispiel zur Approximation fehlender Messwerte einer typischen Bauingenieur-anwendung betrachtet. Als Datengrundlage dient eine fiktive Temperaturmessreihe, bei der täglich ein Messwert aufgenommen wurde, wobei viele dieser Werte fehlen oder unzuverlässig sind. Ziel der Aufgabe ist es, eine Funktion  $y(x)$  zu bestimmen, die den Messwert für einen beliebigen Tag  $x$  approximiert und somit fehlende Daten ergänzt. Diese klassische Approximationsaufgabe wird mithilfe eines neuronalen Netzwerks

gelöst. Im Gegensatz zu herkömmlichen Approximationsverfahren erfolgt hier keine Festlegung einer spezifischen Funktionsklasse. Stattdessen basiert der Lösungsansatz auf einer speziellen Netzwerkarchitektur, dem sogenannten *Multilayer Perceptron (MLP)*.

Abbildung 2 zeigt die verwendete MLP-Netzwerkarchitektur mit einem Input Layer (grün), einem Hidden Layer (gelb), der  $N$  Neuronen (blaue Punkte) umfasst, und einem Output Layer (rosa). Der skalare Eingabewert  $x$  wird zunächst mit einer Gewichtsmatrix  $W_1$  multipliziert und anschließend um den Bias-Vektor  $b_1$  ergänzt. Nach Anwendung der Aktivierungsfunktion werden die so erhaltenen Zwischenergebnisse mittels einer weiteren Gewichtsmatrix  $W_2$  und eines Bias-Vektors  $b_2$  im Output Layer zu einem Ausgabewert  $y$  kombiniert. Die Werte der Gewichtsmatrizen und Bias-Vektoren werden im Trainingsprozess aus den vorliegenden Messdaten gelernt, wobei sie zu Beginn zufällig initialisiert sind. Nach Abschluss des Trainings erfolgt die Auswertung eines beliebigen Eingabewerts  $x$  in folgenden Schritten:




Abbildung 2: Netzwerkarchitektur (Multilayer Perceptron).

- Input Layer  $\rightarrow$  Hidden Layer:  $a_1 = W_1 x + b_1$
- Aktivierungsfunktion (hier tanh):  $a_{12} = \phi_{act}(a_1)$
- Hidden Layer  $\rightarrow$  Output Layer:  $y = W_2 a_{12} + b_2$

Als freier Parameter wurde in diesem Beispiel die Anzahl der Neuronen im Hidden Layer variiert. Die nachfolgenden Abbildungen 3, 4 und 5 zeigen die jeweiligen Ergebnisse bei der Approximation einer abfallenden Sinuskurve, wobei für das Training jeweils nur die Hälfte der verfügbaren Messwerte genutzt wurde. Die dargestellten Ergebnisse verdeutlichen, dass eine unreflektierte Wahl der Netzwerkarchitektur zu fehlerhaften Resultaten führen kann. Insbesondere lässt sich erkennen, dass sowohl eine zu geringe Anzahl von Neuronen im Hidden Layer (Underfitting, Abb.3) als auch eine zu große Anzahl von Neuronen (Overfitting, Abbildung 5) zu ungenauen und unzuverlässigen Vorhersagen führen. Die optimale Wahl der Neuronenzahl ist von weiteren Faktoren abhängig, die hier nicht im Detail betrachtet wurden. Ebenso

ist die Wahl der Aktivierungsfunktion  $\phi_{\text{act}}$  entscheidend; deren Einfluss zeigt sich beispielsweise darin, dass die Prognosen des Netzwerks für zukünftige Zeitpunkte nahezu konstant beim zuletzt berechneten Wert verbleiben. Dieses Beispiel unterstreicht, dass neben der geeigneten Architekturwahl insbesondere das grundlegende Verständnis der Modellstruktur und ihrer Parameter maßgeblich den Erfolg einer KI-Anwendung beeinflussen. Da neuronale Netzwerke in der Praxis häufig Tausende oder sogar Millionen von Parametern besitzen, entsteht schnell ein intransparenter, sogenannter Black-Box-Charakter. Gerade deshalb sind Methoden der erklärbaren KI unerlässlich, um die Funktionsweise und Entscheidungsprozesse neuronaler Modelle besser nachvollziehen zu können [17].

Das vorgestellte Beispiel eignet sich besonders gut zur Approximation von Funktionen, die einem Eingabewert  $x \in \mathbb{R}^n$  einen Ausgabewert  $y \in \mathbb{R}^m$  zuordnen. Dabei stellt sich jedoch die Frage, wie neuronale Netzwerke komplexere, strukturierte Daten wie Zeitreihen, Bilder oder Graphen verarbeiten können. Die Antwort liegt darin, dass solche Daten zunächst in Vektorform überführt werden müssen. Gerade die zugrunde liegende Vektor-Matrix-Struktur neuronaler Netze ermöglicht dabei eine effiziente und parallele Verarbeitung der Eingabedaten. Diese universelle Eigenschaft eröffnet vielfältige Anwendungsfelder, ganz besonders im Bauwesen.




Abbildung 3: Ergebnis der Approximation mittels MLP für 5 Neuronen im Hidden Layer.




Abbildung 4: Ergebnis der Approximation mittels MLP für 20 Neuronen im Hidden Layer.




Abbildung 5: Ergebnis der Approximation mittels MLP für 100 Neuronen im Hidden Layer.

### 3 Netzwerkkonstrukturen für Anwendungen im Bauingenieurwesen

Dieses Kapitel gibt einen kurzen Überblick über die Vielfalt von Netzwerkkonstrukturen mit besonderer Relevanz für das Bauingenieurwesen und verdeutlicht anhand ausgewählter Beispiele deren Einsatzmöglichkeiten bei unterschiedlichen Problemstellungen.

- **Convolutional Neural Networks (CNN)** sind eine weitverbreitete Klasse von neuronalen Netzwerken, die insbesondere in der Analyse von Bilddaten zur Mustererkennung und Anomaliedetektion eingesetzt werden. Typische Anwendungen im Bauingenieurwesen sind die Schadenserkennung an Leichtbaubrücken unter beweglichen Lasten [10], die automatische Detektion von Rissen in Betonbauteilen [8], die semantische Segmentierung von Gebäudefassaden oder die thermografische Qualitätsprüfung von Schweißnähten.
- **Graph Neural Networks (GNN)** ermöglichen die Modellierung komplexer baulicher Strukturen und Sensornetze als Graphen. Diese Netzwerke kommen insbesondere beim Bauwerksmonitoring, der Ermüdungsanalyse in Rohrleitungssystemen sowie bei der Optimierung des Energieflusses in Smart-Building-Systemen zum Einsatz.
- **Rekurrente neuronale Netzwerke (RNN)**, wie Long Short-Term Memory (LSTM)- oder Gated Recurrent Unit (GRU)-Architekturen, werden bevorzugt zur Bearbeitung von Zeitreihendaten und zeitabhängigen Prognosen eingesetzt, etwa der Vorhersage des Baufortschritts, der Ressourcen- und Kostenplanung oder der Prognose klimatischer Einflüsse auf Baustellen.
- **Neural Scene Graphs (NSG)** eignen sich hervorragend für die semantisch strukturierte 3D-Rekonstruktion von Baustellen, die dynamische As-Built-Dokumentation sowie virtuelle Begehungen mithilfe von Virtual Reality.
- **Neural Radiance Fields (NeRF)** ermöglichen eine fotorealistische Modellierung komplexer räumlicher Geometrien, indem sie aus einer Vielzahl von Einzelbildern eine konti-

nuerliche 3D-Szene rekonstruieren und realistische Ansichten aus beliebigen Blickwinkeln erzeugen können [9].

- **Multimodale Large Language Models (MLLM)** bilden eine weiteren bedeutende Klasse. Diese Netzwerke analysieren und generieren textbasierte Baudokumente und ermöglichen darüber hinaus die integrative Interpretation von Ergebnissen, die mit den zuvor beschriebenen Architekturen erzeugt wurden [16].

Abbildung 6 zeigt die zuvor beschriebenen Netzwerkarchitekturen sowie typische Anwendungsfelder im Bauingenieurwesen. Als derzeit besonders leistungsfähige und prominente Klasse sind darin die multimodalen Large Language Models hervorgehoben. Diese Modelle lösen nicht nur spezifische Anwendungsfälle, sondern unterstützen durch ihre Fähigkeit zur Interaktion gezielt komplexe Problemlösungen. Mittels systematischer durchgeführter Abfragen (Prompting) können MLLMs nicht nur Daten analysieren und Ergebnisse generieren, sondern ermöglichen auch eine kritische Auseinandersetzung mit deren inhaltlicher Korrektheit und logischer Konsistenz (wobei mit kritisch nicht die moralische, sondern eine methodische Überprüfung der generierten Inhalte gemeint ist). Prompting ist dabei lediglich eine von zahlreichen Strategien zur Validierung und Interpretation neuronaler Netzwerke. Weitere Verfahren, insbesondere aus dem Bereich der erklärbaren KI die grundsätzlich auch auf alle anderen in Abbildung 6 dargestellten Architekturen anwendbar sind [18], werden im nachfolgenden Abschnitt vorgestellt.

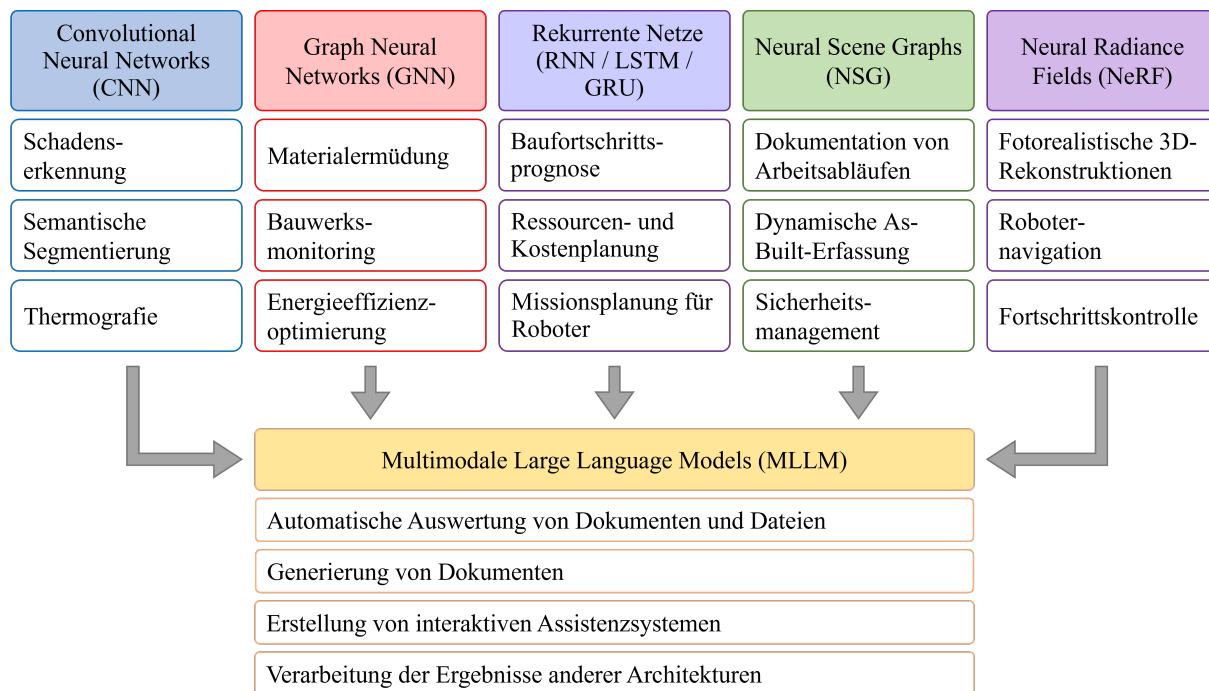


Abbildung 6: Netzwerkarchitekturen und typische Anwendungsfelder.

## 4 Validierung und Interpretation von neuronalen Netzen

Die Notwendigkeit, KI-Modelle und deren Entscheidungsprozesse nachvollziehbar zu machen, ist im Bauingenieurwesen seit Langem bekannt [6]. Ein häufig zitierter Beitrag von Ribeiro et al. [11] unterstreicht hierbei die Bedeutung eines grundlegenden Verständnisses darüber, wie neuronale Netzwerke Entscheidungen treffen und wie diese hinsichtlich ihrer Aussagekraft und Qualität bewertet werden können. Hierzu wurde im Beispiel von Bildklassifikationen die Methode der *Local Interpretable Model-agnostic Explanations* (LIME) eingesetzt, um Bereiche in Bildern hervorzuheben, die für die Klassifizierungsentscheidung des neuronalen Netzes besonders relevant sind.

Abbildung 7 zeigt beispielhaft die Anwendung der LIME-Methode auf ein Bild der Köhlbrandbrücke (Bildquelle: Hamburg Port Authority), das mittels googlenet klassifiziert wurde. In Abbildung 7a ist das Input-Bild dargestellt. In Abbildung 7b sind die für die Klassifizierung *Pier* entscheidenden Bereiche dargestellt und in Abbildung 7c sind die für die Klassifizierung *Suspension bridge* entscheidenden Bereiche dargestellt. Es wird deutlich, dass das untersuchte neuronale Netzwerk bei der Klassifizierung maßgeblich die Wassernähe und weniger das zu klassifizierende Objekt berücksichtigt: *Pier* (57%); *Suspension bridge* (20%); *Dock* (6%). Ein solches, grundsätzlich fehlerhaftes Entscheidungskriterium kann unterschiedliche Ursachen haben. So sollte in derartigen Fällen zunächst überprüft werden, ob der verwendete Trainingsdatensatz über eine ausreichende Vielfalt und Repräsentativität verfügt. Insbesondere ist hierbei auf eine ausreichende Variation sowohl bei den Objekten selbst als auch bei deren Hintergründen zu achten. Führt eine Anpassung des Datensatzes nicht zum gewünschten Erfolg, müssen gegebenenfalls Veränderungen an der Netzwerkarchitektur oder den verwendeten Lernparametern vorgenommen werden. Während in Abbildung 7 die Bildbereiche für die einzelnen Klassen gezeigt wurden, ist in Abbildung 8 die gesamte Relevanz der Bildanalyse sowie die wichtigsten Ausschnitte des Originalbildes dargestellt.

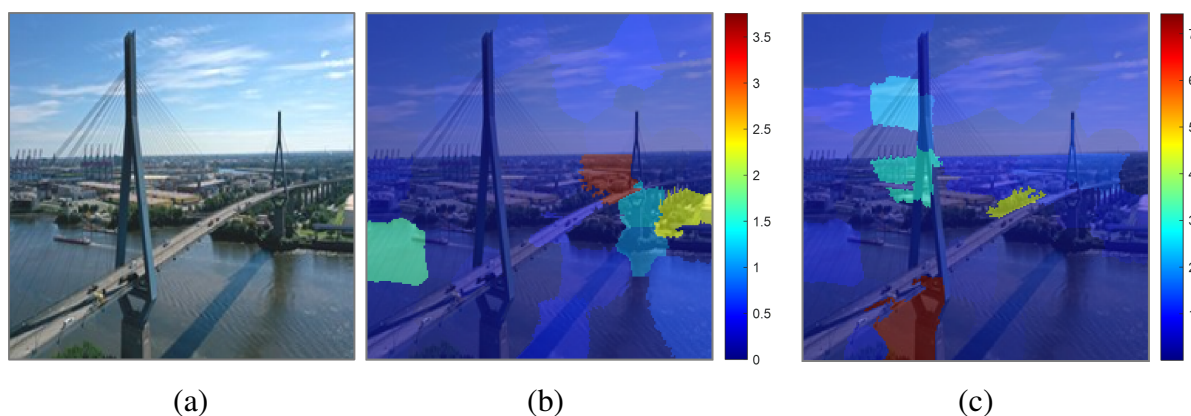


Abbildung 7: Anwendung der LIME-Methode auf ein Bild der Köhlbrandbrücke (Bildquelle: Hamburg Port Authority).

Die LIME-Methode zählt zum Bereich der erklärbaren KI und bietet eine sogenannte lokale Interpretierbarkeit. Dies bedeutet, dass die ermittelten Ergebnisse lediglich für die konkret analysierte Eingabe sowie sehr ähnliche Eingaben gültig sind. Eine globale Interpretierbarkeit,




Abbildung 8: (a) Relevanz der gesamten Bildanalyse beim Klassifizierungsprozess und (b) die entscheidenden Bereiche im Originalbild.

die grundsätzlich wünschenswert wäre, lässt sich mit diesem Ansatz nicht erreichen. Während LIME somit Klassifikationsentscheidungen auf lokaler Ebene erklärt, ermöglicht die *SHapley Additive exPlanations*-Methode (SHAP) [12] die Quantifizierung der Relevanz einzelner Eingabeparameter für das Modellverhalten. Die speziell für Zeitreihen angepasste Variante Window-SHAP [13] erlaubt darüber hinaus eine dementsprechend differenzierte Analyse sequenzieller Daten. Beide Verfahren bieten ebenfalls eine lokal fokussierte Interpretierbarkeit und wurden bereits erfolgreich in ingenieurwissenschaftlichen Anwendungen eingesetzt, etwa zur Validierung und Bewertung von KI-Modellen im Bauingenieurwesen [14].

## 5 Zusammenfassung und Ausblick

Künstliche Intelligenz repräsentiert eine transformative Technologie, deren Methoden inzwischen weite Bereiche von Wissenschaft, Wirtschaft und Gesellschaft durchdringen. Auch im Bauingenieurwesen eröffnet KI erhebliche Potenziale zur Effizienzsteigerung und Qualitätsverbesserung ingenieurtechnischer Lösungen. Voraussetzung für die erfolgreiche Nutzung dieser Potenziale ist eine intensive Auseinandersetzung mit den methodischen Grundlagen sowie ein reflektierter, kritischer und verantwortungsbewusster Einsatz der eingesetzten KI-Verfahren.

Anhand eines exemplarischen Approximationsproblems wurde im Rahmen dieses Beitrags verdeutlicht, dass bereits grundlegende Entscheidungen zur Modellarchitektur, wie etwa die Wahl der Neuronenzahl oder der verwendeten Aktivierungsfunktion, maßgeblich die Qualität der Ergebnisse beeinflussen. Angesichts der inhärenten Komplexität neuronaler Netze zeigt sich dabei der Einsatz erklärbarer KI-Methoden als unerlässlich, um Entscheidungsprozesse nachvollziehbar zu machen und Modelltransparenz sicherzustellen. Darüber hinaus wurden gängige Netzwerkarchitekturen und deren spezifische Anwendungsmöglichkeiten im Bauingenieurwesen vorgestellt. Neben den etablierten Convolutional Neural Networks (CNN) zur bildbasierten Analyse und Graph Neural Networks (GNN) zur Modellierung komplexer Strukturen gewinnen

rekurrente neuronale Netze, Neural Scene Graphs, NeRF-Modelle sowie multimodale Large Language Models (MLLM) zunehmend an Bedeutung. Letztere ermöglichen nicht nur die Analyse umfangreicher Daten, sondern erlauben durch systematisches Prompting eine interaktive Reflexion komplexer Zusammenhänge. Zur Validierung und Interpretation der Modelle wurden exemplarisch die Methoden LIME, SHAP und WindowSHAP diskutiert. Diese Verfahren ermöglichen derzeit zwar keine globale, jedoch eine lokal differenzierte Einsicht in das Entscheidungsverhalten von KI-Modellen, was bereits einen substantziellen Mehrwert für die ingenieurtechnische Praxis darstellt.

Zukünftige Forschungsarbeiten sollten sich vorrangig auf die Weiterentwicklung bestehender XAI-Verfahren konzentrieren, um eine erhöhte Nachvollziehbarkeit insbesondere für komplexe Architekturen, wie multimodale oder hybride KI-Systeme, zu erreichen. Zudem ist die systematische Integration grundlegender KI-Kompetenzen in die Curricula des Bauingenieurwesens als essenziell, um die nächste Generation von Fachkräften nicht nur zur sachgerechten Anwendung, sondern auch zur kritischen Bewertung und Weiterentwicklung von KI-gestützten Lösungen zu befähigen. Hierbei genügt es nicht, dass Absolventinnen und Absolventen des Bauingenieurwesens KI-basierte Methoden lediglich anwenden können; vielmehr ist es unerlässlich, dass sie über ein fundiertes Verständnis der zugrunde liegenden Funktionsweisen verfügen, um KI-Ansätze eigenständig kritisch bewerten, optimieren und weiterentwickeln zu können [20]. Diese Aufgabe kann nicht allein von Spezialistinnen und Spezialisten aus der allgemeinen Informatik erfüllt werden, da diesen das notwendige bauingenieurspezifische Domänenwissen fehlt [19]. Es bedarf deshalb einer intensiven Zusammenarbeit zwischen den Disziplinen, in der insbesondere die Bauinformatik als etablierte Schnittstellendisziplin weiterhin eine zentrale und richtungweisende Funktion einnehmen muss. Dies muss sich adäquat in den Curricula widerspiegeln, denn erst durch die umfassende Vermittlung bauinformatischer Kompetenzen kann die effektive Nutzung und nachhaltige Weiterentwicklung von KI-basierten Technologien im Bauingenieurwesen gewährleistet werden.

## 6 Danksagung

Die Autoren danken der Deutschen Forschungsgemeinschaft für die finanzielle Unterstützung im Rahmen des Forschungsprojekts mit dem Geschäftszeichen SM 281/30-1.

## Literatur

- [1] Y. LeCun, Y. Bengio & G. Hinton. *Deep learning*. Nature, 521(7553):436–444, 2015.
- [2] S. Russell & P. Norvig *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson Education, Hoboken. 2021.
- [3] C. Rudin. *Stop explaining blackbox models for highstakes decisions and use interpretable models instead*. Nature Machine Intelligence, 1(5):206–215, 2019.

- [4] W. Samek, G. Montavon, A. Vedaldi, L.K. Hansen, and K.R. Müller. *Explainable AI: interpreting, explaining and visualizing deep learning*. Springer, Cham, 2019.
- [5] A. Adadi and M. Berrada. *Peeking inside the blackbox: A survey on Explainable Artificial Intelligence (XAI)*. IEEE Access, 6:5213852160, 2018.
- [6] D. Luckey, H. Fritz, D. Legatiuk, J. Peralta, C. Walther, and K. Smarsly. *Explainable artificial intelligence to advance structural health monitoring*. In: A. Cury, D. Ribeiro, F. Ubertini, and M.D. Todd (eds.), *Structural health monitoring based on data science techniques*, pp. 331346. Springer, Cham, 2022.
- [7] A.S. dAvila Garcez, L.C. Lamb, and D.M. Gabbay. *Logic and Knowledge Representation*. In: *NeuralSymbolic Cognitive Reasoning*. Cognitive Technologies, pp. 921. Springer, Berlin, Heidelberg, 2009.
- [8] Y.-J. Cha, W. Choi, and O. Büyüköztürk. *Deep learningbased crack damage detection using convolutional neural networks*. ComputerAided Civil and Infrastructure Engineering, 32(5):361378, 2017.
- [9] B. Mildenhall, P.P. Srinivasan, M. Tancik, J.T. Barron, R. Ramamoorthi, and R. Ng. *NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis*. In: *European Conference on Computer Vision (ECCV)*, pp. 405 – 421, 2020.
- [10] G. Dadoulis, G.D. Manolis, K. Katakalos, K. Dragos, and K. Smarsly. *Damage detection in lightweight bridges with traveling masses using machine learning*. Engineering Structures, 322:119216, 2025.
- [11] M.T. Ribeiro, S. Singh, and C. Guestrin. *"Why Should I Trust You? Explaining the Predictions of Any Classifier"*. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 1135 – 1144, 2016.
- [12] S.M. Lundberg and S.-I. Lee. *A Unified Approach to Interpreting Model Predictions*. Advances in Neural Information Processing Systems, 30:47654774, 2017.
- [13] A. Nayebi, S. Tipirneni, C.K. Reddy, B. Foreman, and V. Subbian. *WindowSHAP: An Efficient Framework for Explaining TimeSeries Classifiers Based on Shapley Values*. arXiv preprint arXiv:2211.06507, 2022.
- [14] C.-H. Hsiao, K. Kumar, and E. Rathje. *Explainable AI models for predicting liquefaction-induced lateral spreading*. arXiv preprint arXiv:2404.15959, 2024.
- [15] K. Smarsly, K. Lehner, and D. Hartmann. *Structural Health Monitoring based on Artificial Intelligence Techniques*. In: Proceedings of the ASCE International Workshop on Computing in Civil Engineering, Pittsburgh, PA, USA, doi:10.1061/40937(261)14, 2007.
- [16] H. Pu, X. Yang, J. Li, R. Guo, and H. Li. *AutoRepo: a general framework for multimodal LLMbased automated construction reporting*. arXiv preprint arXiv: 2310.07944, 2023.

- [17] H. Al-Nasser, K. Dragos, and K. Smarsly. *Explainable sensor fault diagnosis for structural health monitoring*. In: Proceedings of the 11th ECCOMAS Thematic Conference on Smart Structures and Materials (SMART 2025), Linz, Austria, 07 March 025.
- [18] J. Peralta, H. Fritz, G. Dadoulis, K. Dragos, and K. Smarsly. *Automated decision making in structural health monitoring using explainable artificial intelligence*. In: Proceedings of the 28th International Workshop on Intelligent Computing in Engineering (EGICE), Berlin, Germany, 30June2021.
- [19] M. König, A. Borrmann, K.-U. Bletzinger, E. Rank, K. Smarsly, and W. Huhnt. *Aktuelle Entwicklungen und Herausforderungen der Bauinformatik*. Bauingenieur, 8:320329, 2015.
- [20] K. Smarsly, T. Hartmann, U. Rüppel, M. König, and A. Borrmann. *Das Fachgebiet Bauinformatik als Wegbereiter und Träger der Digitalisierung des Bauwesens*. Bauingenieur, 2017/2018:2325, 2017.
- [21] K. Smarsly, T. Hartmann, U. Rüppel, and M. König. *Positionspapier des Arbeitskreis Bauinformatik*. Hannover, Germany, 20 September 2016.

## Author

Dr.-Ing. Alexander Chmelnizkij  
Hamburg University of Technology  
Institute of Digital and Autonomous Construction  
Blohmstraße 15  
21079 Hamburg  
Tel.: +49(0)40/42878-4038  
e-mail: alexander.chmelnizkij@tuhh.de  
Web: www.tuhh.de/idac

Prof. Dr.-Ing. Kay Smarsly  
Hamburg University of Technology  
Institute of Digital and Autonomous Construction  
Blohmstraße 15  
21079 Hamburg  
Tel.: +49(0)40/42878-5023  
e-mail: kay.smarsly@tuhh.de  
Web: www.tuhh.de/idac

# **Data-driven and Numerical Modelling of Control Strategies for Vibrodriving Processes and Rover Mobility on Sandy Terrains**

**Rahul Somasundaram, Francisco Williams-Riquer**

**Abstract:** Automation and data-driven modelling in the field of geotechnical engineering are still in their early stages of development. There are several reasons for this. On the one hand, traditional control strategies for automation require a simplified mathematical model, often linear, which is then used to generate a controller to achieve the desired behaviour. Nonetheless, this is not always possible when soil is present. The granular nature of soil introduces high complexity and uncertainty, which traditional control strategies often struggle to address. Therefore, two methods and case studies are presented in this work to circumvent these complications. On one hand, the implementation of automation strategies in a numerical simulation environment is presented using the Smoothed Particle Hydrodynamics (SPH) methodology. In this case, a trajectory tracking control algorithm is implemented for a tracked vehicle within the numerical framework, which provides a more realistic environment that accounts for the complex interaction between tracks and soil. On the other hand, the study of the vibrodriving process is approached from a purely data-driven perspective, where the Dynamic Mode Decomposition is introduced. By employing an equation-free method that utilises only the data collected during installation, the local complexities of the soil can be considered.

## **1 Numerical Modelling of Control Strategies for Rover Mobility on Sandy Terrains**

### **1.1 Introduction**

Unlike in on-road vehicular mobility, the interaction between wheels and soil forms a cornerstone that profoundly influences performance and safety in off-road vehicles. From construction sites and agricultural fields to off-road trails and extraterrestrial landscapes, the dynamics of soil-wheel interaction influence the traction, manoeuvrability, energy efficiency, and overall stability of the vehicle. The motion of the wheels on loose soil is distinct from that of on-road vehicles because of the different wheel slip/skid behaviours. Therefore, conventional kinematics-based steering models for on-road vehicles are not applicable in off-road vehicles, especially when moving over loose soil.

Bekker pioneered research on wheel-terrain and track-terrain interaction [1, 2]. These works laid the foundation for a new engineering discipline called *terramechanics*. With the increasing number of lunar/planetary rovers, numerous studies have been conducted on the dynamical model based on terramechanics for the motion behaviour of a rover on loose soil ([3, 4, 5]). These studies are necessary because the surface terrain of the Moon or a planet like Mars is primarily composed of a loose, fine soil called *regolith*. There are many numerical methods for the dynamics of wheel-soil interaction, including the finite element method (FEM) [6], Discrete Element Method (DEM) [7, 8], Material Point Method (MPM) [9], Smoothed Particle Hydrodynamics (SPH) [10, 11], and coupled FEM-DEM [12]. Particle-based or Lagrangian methods, such as SPH, have proven effective in simulating granular material problems with large deformations. SPH was initially developed for astrophysics applications ([13, 14]), but soon became popular for various engineering applications.

As rovers are vital tools for exploration and data collection in places that humans cannot access directly, and where real-time manual driving is difficult, such as in planetary exploration, control strategies must be incorporated into rovers. This work extends [11], which incorporates a control strategy to regulate the speed and direction of rotation of each track, enabling the rover to navigate to randomly generated target locations during the program run.

## 1.2 Control strategy

The control strategy to drive the rover to the target location is designed such that by adjusting the rotation speed and the direction of the tracks, the moving direction of the rover aligns with the vector ( $\vec{R}$ ) connecting the centre of mass (COM) of the rover and the target. Vectors  $\vec{t}_d$  and  $\vec{t}_n$ , as shown in Fig. 1, are introduced to decide on the instantaneous velocity and direction of rotation of each track.  $\vec{t}_d$  is the vector connecting the centre of track support at the rear to that at the front end of the track. The rover being rigid,  $\vec{t}_d$  is the same for both tracks.  $\vec{t}_n$  is the vector connecting the centre of track support of *Track L* to that of *Track R* on the same end. Again, due to the rigidity of the rover,  $\vec{t}_n$  is the same for the front and rear track supports. The axis of rotation of the tracks around the corresponding track supports is always along  $\pm \vec{t}_n$ . All the defined vectors are the projections in the XZ plane. The instantaneous speed of the rover at time  $t$ ,  $v_t$ , is introduced, which denotes the desired speed of the rover if it is driven in a straight path. In a non-slipping condition of driving the rover straight, the speed of rotation of each track is equal to the rover's speed ( $v_t$ ).  $v_t$  can be both positive and negative, depending on the forward or backwards movement of the rover. At the start of the simulation, both tracks are rotated at the same rate so that the rover's initial speed ( $v_{t=0}$ ) is 0.25 m/s.

Since  $\hat{t}_d$  is along the direction from the rear end to the front end of the rover,  $\frac{v_t}{|v_t|} \hat{t}_d$  indicates the direction of translation of the COM in a non-slipping condition at time  $t$ , when both tracks are rotated at a speed of rotation of  $v_t$ . Angles  $\theta_0$  and  $\theta_1$  are defined such that  $\theta_0$  is the angle between  $\vec{R}$  and  $\frac{v_t}{|v_t|} \hat{t}_d$ , and  $\theta_1$  is the angle between  $\vec{R}$  and  $\vec{t}_n$ , i.e.,

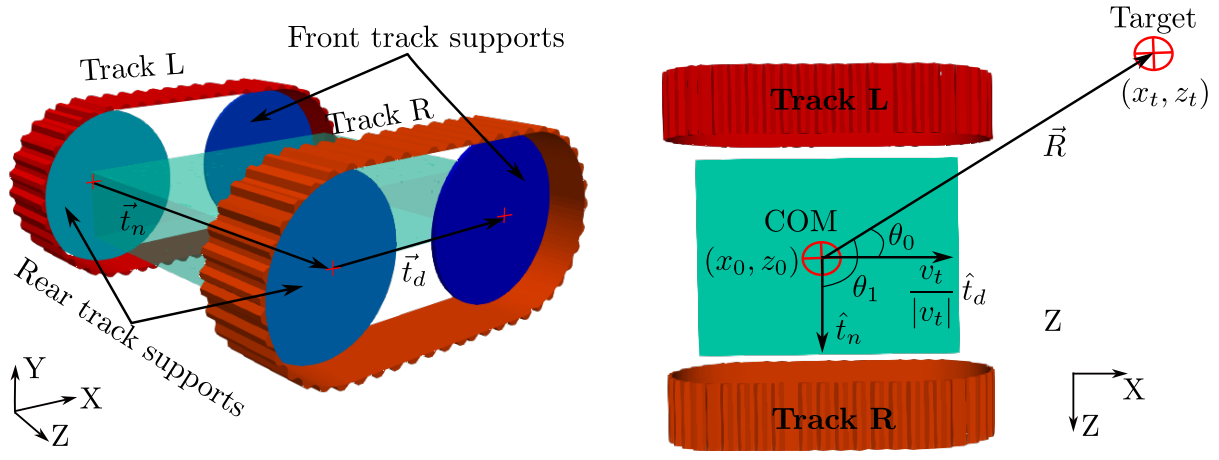


Figure 1: Schematic view of the rover including the vectors:  $\vec{t}_n$  and  $\vec{t}_d$ , and angles:  $\theta_0$  and  $\theta_1$

$$\theta_0 = \cos^{-1} \left( \frac{v_t \vec{R} \cdot \hat{t}_d}{|\vec{R}| |v_t|} \right) \text{ and} \quad (1)$$

$$\theta_1 = \cos^{-1} \left( \frac{\vec{R} \cdot \hat{t}_n}{|\vec{R}|} \right). \quad (2)$$

A proportional control system is designed such that the instantaneous speed of rotation of each track is adjusted according to the values of  $\theta_0$  and  $\theta_1$  at time  $t$ , as described below.

1. Reversing the rover's direction: When  $\theta_0 > \frac{\pi}{2}$ , it indicates that the target is located in the opposite direction of the rover's translation direction, and hence the  $v_t$  should be reversed, i.e., the value of  $v_t$  is updated as  $v_t = -v_t$ .  $\theta_0$  is recalculated with updated  $v_t$  using Equ. 1. Since only change is the reversal of  $v_t$ , the updated value of  $\theta_0$  can be calculated by deducting  $\frac{\pi}{2}$  from the earlier value. If  $\theta_0 < \frac{\pi}{2}$ , this step is skipped and proceeds directly to Step 2 or 3. The rotation speed of the tracks is then calculated as in Step 2 or 3, depending on the value of  $\theta_1$ .

2. Track R is given a higher speed of rotation than Track L: When  $\theta_1 > \frac{\pi}{2}$ , Track R should be ideally rotated at a higher rate than Track L, to move the rover in the direction of the target (ref. Fig. 1). The speed of rotation of Track R is, in such a case, derived from  $\theta_0$  using a proportionality constant  $K_p$ . The instantaneous speed of rotation of Track R,  $v_R$  is calculated as,

$$v_R = v_t (1 + K_p \theta_0) \quad (3)$$

To orient the rover's translation direction more quickly and efficiently towards the required direction of the target, the instantaneous speed of rotation of Track L is simultaneously reduced,

as,

$$v_L = v_t (1 - \lambda K_p \theta_0), \quad (4)$$

where  $\lambda$  is a factor linearly dependent on  $\theta_0$  with maximum value ( $\lambda_{\max}$ ) at  $\theta_0 = \frac{\pi}{2}$  and zero at  $\theta_0 = 0$ .

3. Track L is given a higher speed of rotation than Track R: When  $\theta_1 < \frac{\pi}{2}$ , Track L should be rotated at a higher rate relative to Track R in the same way as in Equ. 3, and the speed of rotation of Track R is reduced as in Equ. 4.

At every time step during the simulation run, the steps mentioned above are followed to achieve the required rotational speed of the tracks, until  $\theta_0$  becomes zero, at which point both tracks rotate at  $v_t$  (Equ. 4 and 3 converge to  $v_t$  when  $\theta_0$  becomes zero).

The critical condition occurs when the target is located exactly perpendicular to the moving direction of the rover, or simply,  $\theta_0 = \frac{\pi}{2}$ . In such a condition, it is logical that the tracks should rotate in opposite directions at the same speed. Applying this logic in Equ. 3 and 4, by substituting the value of  $\theta_0 = \frac{\pi}{2}$ , one get,

$$v_t \left(1 + K_p \frac{\pi}{2}\right) = -v_t \left(1 - \lambda_{\max} K_p \frac{\pi}{2}\right). \quad (5)$$

By rearranging Equ. 5,  $\lambda_{\max}$  is derived as

$$\lambda_{\max} = 1 + \frac{4}{\pi K_p}. \quad (6)$$

By limiting the maximum value of instantaneous track speed to twice  $v_t$ ,  $K_p$  can be calculated by substituting  $\theta_0 = \frac{\pi}{2}$  in Equ. 3. i.e.,

$$v_t \left(1 + K_p \frac{\pi}{2}\right) = 2 v_t, \quad (7)$$

which gives  $K_p = \frac{2}{\pi}$ . Substituting this value in Equ. 6 gives  $\lambda_{\max} = 3$ . Since  $\lambda(\theta_0)$  is linearly dependent on  $\theta_0$ ,

$$\begin{aligned} \lambda(\theta_0) &= \lambda_{\max} \frac{2}{\pi} \theta_0 \\ &= \frac{6}{\pi} \theta_0 \end{aligned} \quad (8)$$

### 1.3 SPH simulation

The SPH model is based on the tracked rover A4WD3 of Lynxmotion (see Fig. 2). The dimensions of the chassis and tracks, including the grousers on the tracks, as well as the overall weight of the model, are based on the physical prototype.




Figure 2: Tracked rover A4WD3 of Lynxmotion (right) and the SPH model of it (left). The opacity of the chassis is reduced to make the battery inside it visible

The governing equations of SPH and the contact model are explained in [11]. The SPH code GADGET-Soil, written in the C language, is used to model the simulation. GADGET-Soil [15] is derived from GADGET-2 [16, 17], and GADGET- $H_2O$ , [18]. The developed control strategy is tested on the SPH model, which consists of a sand bed measuring  $1.5\text{ m} \times 1.5\text{ m}$ . The target positions are randomly generated, and a new target is assigned once the distance between the centre of mass (COM) and the current target falls below 10 cm. The simulation results (see Fig. 3 and 4) show that this simple control strategy is highly efficient for navigating the tracked rover to the desired location within the SPH framework.




Figure 3: The rover is driven towards the first target by the control strategy in the simulation, including the details of the vertical deformation on the sand surface




Figure 4: The rover when it reached the fifth target (left), and the trajectory of COM during the complete run of the rover (right)

## 2 Data-driven modelling of soil vibrations during the vibro-driving process

Pile installation with vibrodrivers is an efficient alternative to impact driving, offering faster penetration rates while minimising pile damage [20]. However, it introduces challenges related to excessive ground vibrations, which can disturb nearby structures and residents [24]. Traditionally, practitioners have relied on empirical knowledge to select vibratory parameters such as frequency, amplitude, and surcharge force [26, 24], often without systematically accounting for local soil conditions. Recent advances in numerical simulation, such as Finite Element Method (FEM) models, have enabled more detailed analyses of the pile–soil interaction. However, such models require extensive soil characterisation and computational resources, limiting their practical use for real-time field applications. Moreover, they often rely on assumptions (e.g., soil homogeneity or idealised boundary conditions) that may not reflect the complexity of in-situ conditions [28, 22].

To address these challenges, we explore the use of data-driven strategies for modelling and ultimately controlling the vibrodriving process. Specifically, we apply Dynamic Mode Decomposition (DMD) and its extensions to geophone measurements collected during pile installation. DMD offers an equation-free approach that enables short-term prediction of soil vibrations while inherently capturing the influence of local site conditions. Previous results presented in [30] and [31] have shown that delay-augmented variants of DMD significantly improve time-ahead predictions of ground motion, suggesting their potential for real-time control applications.

To further test the proposed data-driven strategies, we designed and constructed a miniaturised electrical gearless vibrator for 1g laboratory and field studies. The system integrates high-resolution sensors to measure reaction forces, pore pressure, acceleration, and wave propagation

during installation. This experimental setup serves both as a validation tool for data-driven models and as a testbed for control strategies aimed at optimising pile insertion by balancing the competing objectives of minimising installation time and limiting transmitted vibrations.

## 2.1 Dynamic Mode Decomposition (DMD)

Dynamic Mode Decomposition (DMD) is a data-driven method used to extract spatiotemporal patterns from time-series data, commonly applied to physical systems where the underlying equations are unknown or difficult to model [27, 29]. The key idea is to approximate the evolution of the system using a linear model of the form

$$\mathbf{x}(k+1) \approx \mathbf{A}\mathbf{x}(k), \quad (9)$$

where  $\mathbf{x}(k) \in \mathbb{R}^n$  represents the system state at discrete time  $k$ , and  $\mathbf{A}$  is an unknown linear operator. To identify  $\mathbf{A}$ , DMD constructs two data matrices from  $m$  snapshot measurements:

$$\mathbf{X}_1 = [\mathbf{x}(1) \ \cdots \ \mathbf{x}(m-1)], \quad (10)$$

$$\mathbf{X}_2 = [\mathbf{x}(2) \ \cdots \ \mathbf{x}(m)]. \quad (11)$$

A low-rank approximation of  $\mathbf{X}_1$  is obtained via truncated singular value decomposition (SVD), followed by projection to compute a reduced-order operator whose eigenvalues and eigenvectors represent the system's temporal behaviour and spatial modes.

In real applications, measurement noise introduces bias in the estimated operator  $\mathbf{A}$ , which persists even with large datasets [21]. This bias disproportionately affects modes associated with small signal energy.

There are several strategies to reduce the influence of noise in the estimation of the system dynamics, such as Forward-backward DMD [21]. The authors propose Augmented DMD (AugDMD) as a denoising strategy. AugDMD incorporates time-delay coordinates by stacking multiple past measurements into extended state vectors [19]. This results in larger data matrices with higher singular values, which helps reduce noise-induced errors.

For the case of actuated systems, standard DMD is incapable of producing a corresponding input-output model; therefore, DMD with control (DMDc) extends the original formulation to account for external inputs. It models the system as

$$\mathbf{x}(k+1) \approx \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k), \quad (12)$$

where  $\mathbf{u}(k)$  is the control input, and  $\mathbf{B}$  captures the input influence [23]. Control input data is assembled into a matrix

$$\Upsilon = [\mathbf{u}(1) \quad \cdots \quad \mathbf{u}(m-1)], \quad (13)$$

and both  $\mathbf{A}$  and  $\mathbf{B}$  are identified by solving a least-squares problem using an augmented matrix of states and inputs.

Finally, Augmented DMD with control (AugDMDc) combines delay embeddings and control inputs into a single framework. It improves robustness and accuracy in modelling noisy systems influenced by external actions by extending the augmented state matrix with control inputs appended as additional rows.

### 2.1.1 Modelling and predictions of vibrations using DMD

We employed DMD and AugDMD to analyse the vibrations transmitted to the surroundings during the vibrodriving process. The data and results presented in this section correspond to a measurement campaign described in [30]. Geophone measurements of vertical ground velocities at multiple radial distances from the pile served as input data for the DMD algorithm. This method decomposes the time-synchronised signals into dynamic modes that represent the dominant wave propagation patterns in the soil, reducing the dependence on detailed soil investigations prior to the installation. Fig. 5 and 6 show the results of DMD and AugDMD for the time-ahead prediction of the soil vibrations during a pile installation.

Building on the DMD framework, a real-time monitoring system was conceptualised to predict ground vibrations during the vibrodriving process. This system updates the DMD-based model continuously as new geophone data becomes available. Field tests revealed that while the standard DMD algorithm can effectively identify the primary vibration patterns, it is susceptible to noise in the measurement data. To improve robustness, an augmented version of DMD incorporating time-delay coordinates (AugDMD) was implemented, significantly enhancing prediction accuracy even in noisy environments. This capability enables the reliable prediction of short-term soil vibrations, which can be integrated into the control loop of the vibrodriver to adjust feed parameters and mitigate potentially harmful vibrations. Initial outcomes suggest that incorporating these data-driven models into the control strategy of the vibrodriver can optimise the installation process, improving efficiency and reducing environmental damage. Future work will explore the integration of additional sensor data, such as torque and rotational speed measurements, and extend the framework to Dynamic Mode Decomposition with control (DMDc). The ultimate goal is to develop a fully adaptive and data-informed operational strategy tailored to real-time soil conditions.

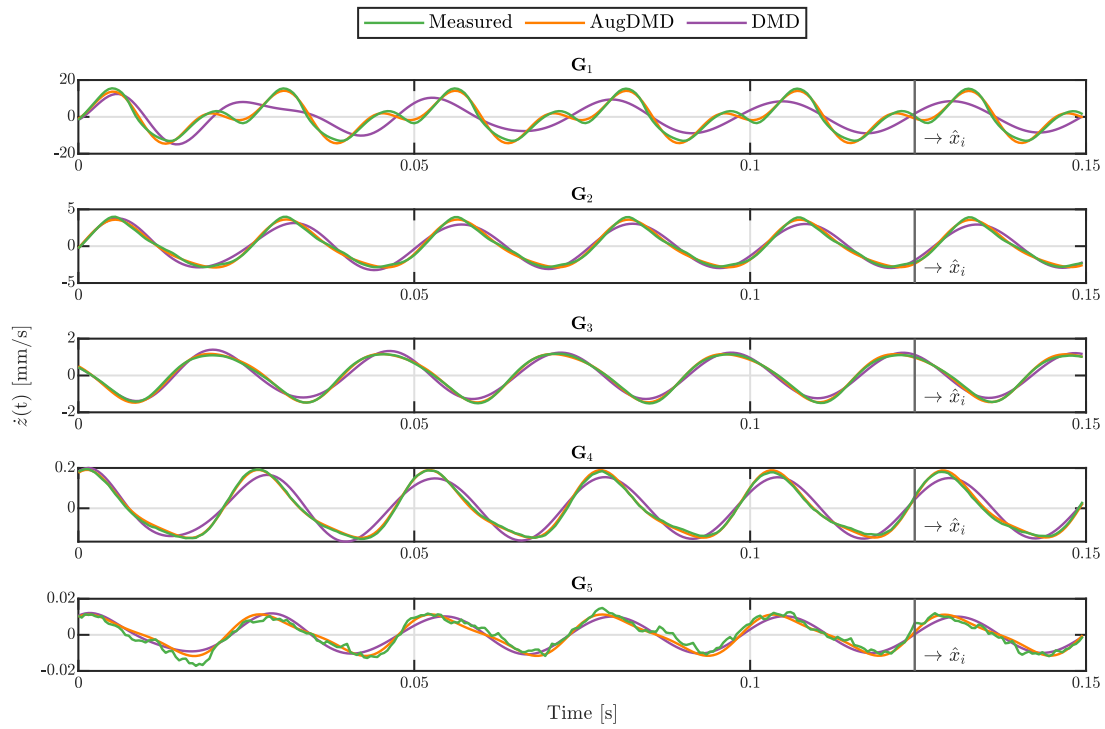


Figure 5: Approximation and prediction results of the standard and augmented DMD for a short time horizon [30].




Figure 6: Approximation and prediction results of the standard and augmented for a longer time horizon [30].

## 2.2 Construction of miniaturised vibrodriver

To conduct controlled testing in laboratory conditions or predefined field measurements, a small-scale vibrodriver was developed to study the installation of piles into the ground. The device, shown in Fig. 7, has four rotating weights (eccentric masses) that generate vibrations to assist in pushing the pile into the soil. These are powered by electric motors and held in place in an aluminium housing. The entire setup is designed to be portable (battery-powered) and can be used in both the lab and the field. It includes a vertical guide to keep the pile straight during installation. A counterweight stabilises the system, and a pulley facilitates the removal of the pile after each test. The pile is firmly clamped to the vibrodriver to ensure good transfer of the vibrations. Fig. 7 shows a technical drawing of the gearless electrical vibrodriver. The vibrodriver is equipped with several sensors to measure different aspects of the installation process. These include a six-axis force-torque sensor to capture the reaction forces at the pile head, a triaxial accelerometer to measure vibrations, and a linear encoder to track the pile's penetration depth.




Figure 7: Technical drawings of constructed vibrodriver

Additionally, pressure sensors can be placed at the pile tip to monitor soil conditions during installation. All sensor data is collected and processed by the system. Furthermore, during field testing, geophones can be connected and synchronised with the rest of the system to measure the vibrations transmitted to the surroundings. The electric motors driving the rotating weights are controlled by a programmable logic controller (PLC). This controller keeps the four motors perfectly synchronised, without using any mechanical gears, to ensure smooth and steady vibrations. The control system employs a method in which the PLC continuously adjusts the

position of each motor to keep them in sync. The motors themselves have built-in encoders to track their positions precisely, and everything is connected with fast data lines to minimise delay. This setup enables precise control of the vibrations.

### 3 Conclusion

This work highlights how automation and data-driven modelling can be advanced in geotechnical engineering applications by combining numerical and data-centric approaches. Through the SPH-based simulation of a tracked vehicle with trajectory tracking control, it was demonstrated that complex soil–structure interactions can be indirectly incorporated into the control design process. In parallel, the application of Dynamic Mode Decomposition to vibrodriving showed the potential of data-driven, equation-free methods to capture local soil behaviour without relying on predefined constitutive formulations. Together, these case studies illustrate complementary pathways—simulation-based automation and data-driven analysis—that can address the uncertainties inherent in soil systems. The integration of such approaches paves the way for more robust, adaptive, and reliable solutions in automation for geotechnical engineering.

### References

- [1] Bekker, M. G.. *Introduction to terrain-vehicle systems*. University of Michigan Press Ann Arbor, Ann Arbor, 1969.
- [2] Bekker, M. G.. *Theory of land locomotion; the mechanics of vehicle mobility*. University of Michigan Press Ann Arbor, Ann Arbor, 1956.
- [3] Andreas Gibbesch, Bernd SchMultibody System Modelling and Simulation of Planetary Rover Mobility on Soft Terrain. *IEEE Transactions on Robotics*, 20(5), 921-927, 2005.
- [4] Kazuya Yoshida, Hiroshi Hamano. Motion dynamics and control of a planetary rover with slip-based traction model. *Proceedings of SPIE - The International Society for Optical Engineering*, 4715(), 275–286, 2002.
- [5] Ishigami, Genya, Miwa, Akiko, Nagatani, Keiji, Yoshida, Kazuya. Terramechanics-based model for steering maneuver of planetary exploration rovers on loose soil. *Journal of Field Robotics*, 24(3), 233-250, 2007.
- [6] Hambleton, James, Drescher, A.. Modeling wheel-induced rutting in soils: Rolling. *Journal of Terramechanics*, 46(), 35-47, 2009.
- [7] Khot, Lav, Salokhe, Vilas, Jayasuriya, Hemantha, Nakashima, H.. Experimental Validation of Distinct Element Simulation for Dynamic Wheel-Soil Interaction. *Journal of Terramechanics*, 44(), 429–437, 2007.

- [8] Hu, Cheng, Gao, Jingwei, Song, Xiaobo, Zhang, Min, Tan, Xuhong. Analytical modeling and DEM analysis of soil–wheel interaction under cornering and skidding conditions in off-road vehicles. *AIP Advances*, 11(), 085122, 2021.
- [9] Xu, Xiaorong, Yerro, Alba, Soga, Kenichi, Li, Mo, Jin, Feng. Numerical Modelling and Simulation of the Wheel Rotation Problems by the Material Point Method. 2021.
- [10] Hu, Wei and Zhou, Zhenhao and Chandler, Samuel and Apostolopoulos, Dimitrios and Kamrin, Ken and Serban, Radu and Negrut, Dan. Traction control design for off-road mobility using an SPH-DAE cosimulation framework. *Multibody System Dynamics*, 55(1), 165-188, 2022.
- [11] Somasundaram, R., Williams-Riquer, F., and Grabe, J. (2024). Multi-body simulation of a tracked rover on granular soil using SPH framework. In: *Proceedings of the 18th International SPHERIC Workshop*, Berlin, Germany, pp. 48–53.
- [12] Nakashima. Algorithm and implementation of soil-tire contact analysis code based on dynamic FE-DE method. *Journal of Terramechanics*, 41(2), 127-137, .
- [13] Gingold, R. A., Monaghan, J. J.. Smoothed particle hydrodynamics: theory and application to non-spherical stars. *Monthly Notices of the Royal Astronomical Society*, 181(3), 375-389, 1977.
- [14] Lucy. A numerical approach to the testing of the fission hypothesis.. , 82(), 1013-1024, .
- [15] Kocak, B. (2017). *Zur numerischen Modellierung von hydraulisch-mechanisch gekoppelten Prozessen in gesättigten granularen Böden mittels Smoothed Particle Hydrodynamics* (PhD thesis). Technische Universität Hamburg.
- [16] Springel, V. (2005). The cosmological simulation code GADGET-2. *Monthly Notices of the Royal Astronomical Society*, 364(4), 1105–1134. <https://doi.org/10.1111/j.1365-2966.2005.09655.x> DOI:10.1111/j.1365-2966.2005.09655.x.
- [17] Springel, V., Yoshida, N., and White, S. D. M. (2001). GADGET: a code for collisionless and gasdynamical cosmological simulations. *New Astronomy*, 6(2), 79–117. [https://doi.org/10.1016/S1384-1076\(01\)00042-2](https://doi.org/10.1016/S1384-1076(01)00042-2) DOI:10.1016/S1384-1076(01)00042-2.
- [18] Ulrich, C. (2013). *Smoothed-Particle-Hydrodynamics simulation of port hydrodynamics problems* (PhD Dissertation). Technische Universität Hamburg, Schriftenreihe Schiffbau.
- [19] Brunton S. und Kutz J. (2022): *Data-driven science and engineering: machine learning, dynamical systems, and control*. Cambridge University Press, Cambridge
- [20] Chrisopoulos S. und Triantafyllidis T. (2019): Zur numerischen Modellierung von Vibrationsrammung im gesättigten Boden. *Bautechnik*, 96:176–194
- [21] Dawson S. T. M., Hemati M. S., Williams M. O. und Rowley C. W. (2016): Characterizing and Correcting for the Effect of Sensor Noise in the Dynamic Mode Decomposition. *Experiments in Fluids*, 57(3)

- [22] Jongmans D. (1996): Prediction of ground vibrations caused by pile driving: A new methodology. *Engineering Geology*, 42:25–36
- [23] Proctor J. L., Brunton S. L. und Kutz J. N. (2016): Dynamic Mode Decomposition with Control. *SIAM Journal on Applied Dynamical Systems*, 15(1):142–161
- [24] Ramshaw C. L. und Selby A. R. (2003): Computational modelling of ground waves due to pile driving. In: Bull J. (Hrsg.): *Computational Modelling in Hydraulic and Coastal Engineering*, Kapitel 5, Spon Press, 132–167
- [25] Reusch D. (2000): Automatic Controlled Vibratory Pile Driving with Shock-Stress Limitation. In: *Proceedings of the 17th International Symposium on Automation and Robotics in Construction (Taipei)*, 1–6
- [26] Rodger A. und Littlejohn (1980): A study of vibratory driving in granular soils. *Géotechnique*, 30:269–293
- [27] Schmid P. J. (2010): Dynamic Mode Decomposition of Numerical and Experimental Data. *Journal of Fluid Mechanics*, 656:5–28
- [28] Sun Z., Yu C., Li C., Liu R., Li Q. und Su C. (2023): Ground and Pile Vibrations Induced by Pile Driving. *Buildings*, 13:1884
- [29] Tu J. H., Rowley C. W., Luchtenburg D. M., Brunton S. L. und Kutz J. N. (2014): On Dynamic Mode Decomposition: Theory and Applications. *Journal of Computational Dynamics*, 1(2):391–421
- [30] Williams-Riquer F., Chmelnizkij A., Alkateeb D., Alkateeb D. und Grabe J. (2024): Prediction of induced soil vibration during pile vibrodriving using Dynamic Mode Decomposition (DMD). *Journal of Physics: Conference Series*, 2909(1):012002
- [31] Williams-Riquer F., Abdennadher M. A., Chmelnizkij A. und Smarsly K. (2025): Modeling and Predicting Soil Vibrations During Vibrodriving Installation Using Noisy Data and Dynamic Mode Decomposition. In: *Proceedings of the 11th International Conference on Experimental Vibration Analysis for Civil Engineering Structures (Porto, Portugal, July 2025)*

## Authors

### **Rahul Somasundaram**

Institute of Geotechnical Engineering and  
Construction Management  
rahul.somasundaram@tuhh.de  
Schellerdamm 22  
21079 Hamburg  
Tel.: +49(0)40/42878-3762

### **Francisco Williams-Riquer**

Institute of Geotechnical Engineering and  
Construction Management  
francisco.williams@tuhh.de  
Schellerdamm 22  
21079 Hamburg  
Tel.: +49(0)40/42878-3762



# Artificial Intelligence Applications in Computational Geomechanics

Raul Fuentes

**Abstract:** This contribution highlights recent advances in applying artificial intelligence—particularly neural networks—to computational geomechanics. After a brief introduction to the methodology, three case studies are presented, each showcasing a different approach to solving geotechnical problems using neural networks. These examples demonstrate the potential of data-driven and physics-informed strategies to enhance accuracy, efficiency, and interpretability in geotechnical modelling.

## 1 Introduction

The use of neural networks in computational mechanics has grown rapidly, with geotechnical applications gaining increasing attention. In their traditional form, neural networks are trained on labeled datasets to model specific processes or phenomena. While straightforward, such purely data-driven approaches require substantial training data and often struggle with extrapolation (Eghbalian et al., 2023). This limitation is often attributed to the lack of physical constraints embedded in the network output (Eghbalian et al., 2023; Haghighat et al., 2023).

To address this, recent methods integrate domain knowledge by incorporating governing equations—such as partial differential equations (PDEs)—into the learning process. These models, known as Physics-Informed Neural Networks (PINNs), enforce physical laws within the loss function of the network (Raissi et al., 2019). This not only improves prediction accuracy but also enhances the generalization capability of models (Meng and Karniadakis, 2020; Vahab et al., 2022).

In essence, PINNs allow for the solution of boundary value problems (BVPs) by embedding physical laws directly into the training process. This can lead to highly efficient solvers capable of producing results in seconds or even real time, depending on model complexity. Variations of this approach exist, such as Thermodynamics-Informed Neural Networks (TINNs), which apply similar principles but emphasize thermodynamic consistency (Masi and Stefanou, 2022).

## 2 Background and Methodology

A detailed review of neural network architectures, training procedures, and optimization algorithms is beyond the scope of this contribution. However, to illustrate the PINNs concept, a typical feed-forward neural network is shown in Figure 1. The network inputs represent the variables that define the boundary value problem—such as spatial coordinates, time, or material properties—while the output corresponds to the target physical quantity, often the dependent variable in the governing PDE or ODE.

For example, consider the one-dimensional consolidation problem, governed Equation 1:

$$\frac{\partial u}{\partial t} = c_v \frac{\partial^2 u}{\partial z^2} \quad (1)$$

Where  $u$  is the excess porewater pressure,  $t$  is the time,  $z$  the depth and  $C_v$  is the coefficient of consolidation. In the PINN framework,  $t$ ,  $z$  and  $C_v$  serve as inputs, and the network is trained to predict  $u$  as output.

The PDE becomes part of the loss function, which is minimized during training. To avoid ill-posed problems, initial and boundary conditions must also be included in the loss function, and may also serve as input features. For example, in the case of the 1D consolidation PDE, an input variable should be the initial porewater pressure,  $u$  at  $t = 0$ .

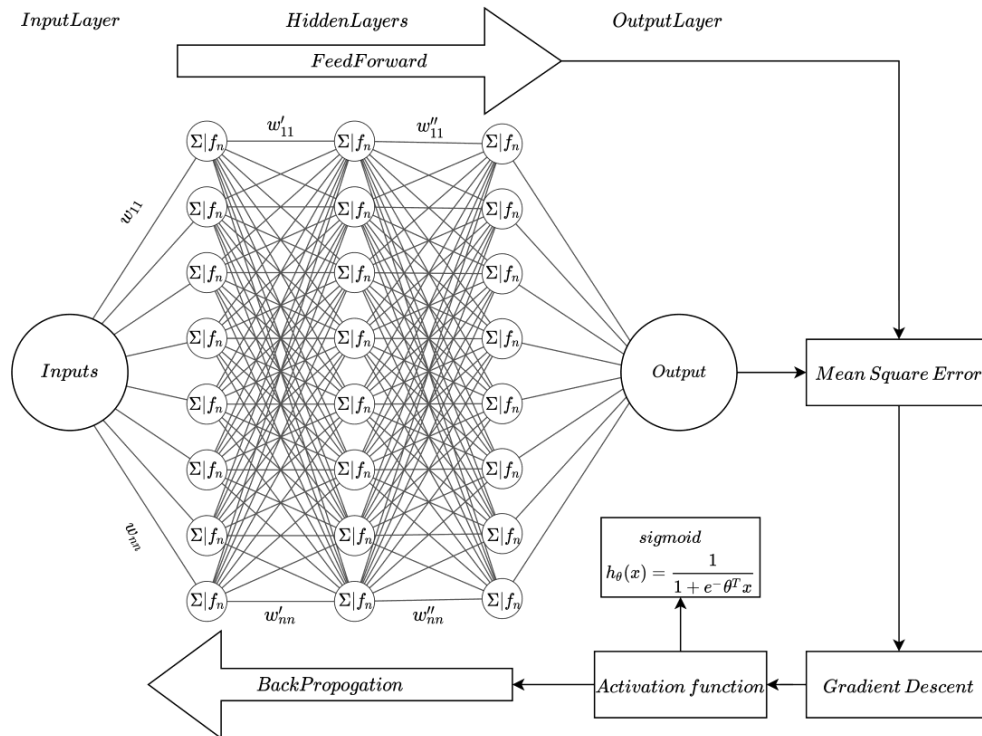


Figure 1: Standard schematic of NN and PINNs using a Feed Forward neural network.

In PINNs terminology, solving the PDE without any data is referred to as a forward problem, providing a physics-consistent solution. This is sometimes called direct PINNs. However, in

many cases, PDEs alone do not yield unique solutions. In such instances, incorporating observed data can improve model fidelity, particularly for cases included in the training set. The total loss function  $\mathcal{L}$  commonly takes the form shown in Equation 2.

$$\mathcal{L} = \mathcal{L}_{PDE} + \mathcal{L}_{bc/s} + \mathcal{L}_{data} \quad (2)$$

An additional strength of PINNs using data is their ability to solve inverse problems, such as estimating the consolidation coefficient  $C_v$  from observed pore pressure data. The structure of the neural network remains the same, but the loss function must include the data term in order to find the sought parameter.

### 3 Case Studies

To illustrate the versatility of neural networks in geotechnical applications, three case studies are presented. A summary is provided in Table 1, and the results are shown in Figures 2–4.

Table 1: Case studies description

	Application	Approach	Reference
1	Virtual calibration chamber for cone penetration test	Traditional NN using data	Liu <i>et al</i> (2024a)
2	Catastrophic creeping landslides	Traditional PINNs solving a complex PDE	Moeineddin <i>et al</i> (2023)
3	Modelling elastoplastic soil behaviour in boundary value problems	FEM-PINN combined boundary value problem (BVP) prediction	Liu <i>et al</i> (2024b)

Figure 2 shows the results of training a neural network in a traditional way using experimental data to develop a virtual calibration chamber for CPT. As observed, the model is capable of predicting penetration results very accurately.




Figure 2. Comparison of simulated vs experimental cone penetration resistance tests. Source: [1].

Figure 3 shows the predicted temperature as a fundamental factor to understand the stability of creeping landslides in the presence of a thin clay (fine grained) soil layer. The PINNs accurately predict normalized temperature over time, based solely on synthetic data. Real landslide events—such as Vaiont, Shuping, and Mud Creek—are effectively captured by the model, showcasing its real-time early warning potential.

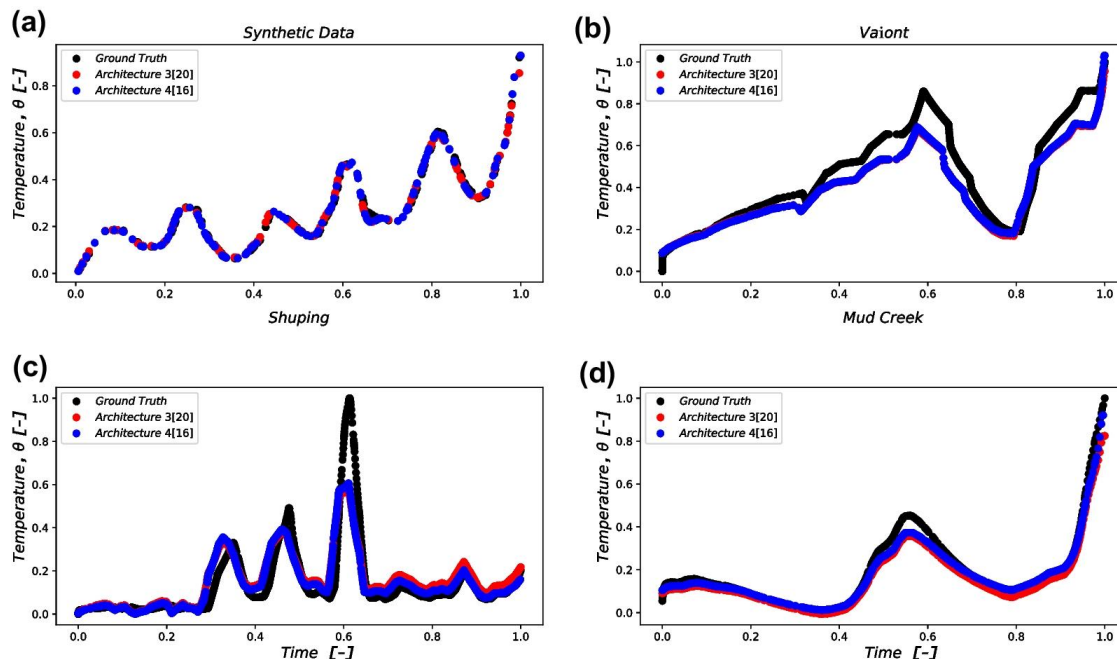


Figure 3. Normalized temperature in time calculated by the network for the three case studies. This normalized temperature has been calculated by training the synthetic data for two different network architectures 3[20] and 4[16] – 3 and 4 are the number of layers and 20 and 16, the number of neurons per layer, optimised as presented in [8]. Note that the ground truth data is from Segui et al. (2020) and Seguí and Veveakis (2022). **a** Fit of the ground truth (generated data) and calculated by the network synthetic data. **b** Fit of the ground truth data of the Vaiont landslide and the calculated data by the network. **c** Fit of the ground truth data of the Shuping landslide and the calculated data by the network. **d** Fit of the ground truth data of the Mud Creek landslide and the calculated data by the network. Source [8].

Figure 4 presents the results for a cavity expansion problem where PINNs have been used to substitute the constitutive model successfully and integrated into an FEM framework to make predictions of BVPs. In this case the comparisons are made against state-of-the-art computational results using the Bounding Surface Model (BSM), revealing good agreement in terms of total displacement  $u$ , deviatoric stress  $q$ , and plastic shear strain  $\gamma_p$ .




Fig. 4. Contours of FEM results for cavity expansion using (a) BSM and (b) PINN in the fields of total displacement  $u$ , deviatoric stress  $q$ , and plastic shear strain  $\gamma^p$ , as well as (c) their relative error. Source [9].

## Conclusions and Outlook

AI, and in particular PINNs approaches are increasingly being applied to computational geomechanics problems. Some of the advantages, compared to traditional numerical modelling techniques, are: PINNs don't need meshing, which is a huge benefit in geotechnics where irregular domains (tunnels, slopes, foundations, faults) and evolving geometries (large deformations, failure, fluidization) make mesh generation costly or unstable; Geotechnical problems often suffer from *sparse and noisy measurements* (e.g., piezometers, inclinometers, lab tests). Inverse PINNs allow simultaneous assimilation of these sparse data with governing equations — useful for parameter identification (e.g., stiffness, permeability, strength degradation) and model updating during construction; they can solve BVPs almost in real-time allowing with application to early-warning systems or integration into machines' control strategies; the constitutive model can be replaced completely, removing some of the problematic

numerical challenges that arise from this; can theoretically cover multi-physics coupled problems where governing equations are defined; to name but a few.

A challenge remains to come up though with surrogate models using PINNs that can extrapolate more universally to three-dimensional problems as the high dimensionality of the input variables, where training times grow significantly. In these case, FEM remains faster. PINNs rely on differentiable residuals of PDEs and therefore, capturing yield surfaces, plastic flow rules, and irreversibility is non-trivial, eventhough new approaches are appearing; PINNs use smooth neural network approximations and hence, struggle with discontinuous solutions (sharp settlement troughs, fracture propagation). Recent work on adaptive sampling, domain decomposition, or enriched NN basis functions helps, but it's early; No standardized "best practices" yet that results in inconsistent approaches across problem setups, which makes comparisons difficult; to also name some examples.

## References

- [1] Eghbalian, M., Pouragha, M., Wan, R. (2023). A physics-informed deep neural network for surrogate modeling in classical elasto-plasticity. *Computers and Geotechnics*, **159**:105472.
- [2] Haghghat, E., Abouali, S., Vaziri, R., 2023. Constitutive model characterization and discovery using physics-informed deep learning. *Engineering Applications of Artificial Intelligence*, **120**:105828.
- [3] Raissi, M., Perdikaris, P., Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, **378**:686-707.
- [4] Meng, X., Karniadakis, G. E., 2020. A composite neural network that learns from multi-fidelity data: Application to function approximation and inverse PDE problems. *Journal of Computational Physics*, **401**:109020.
- [5] Vahab, M., Haghghat, E., Khaleghi, M., Khalili, N. (2022). A Physics-Informed Neural Network Approach to Solution and Identification of Biharmonic Equations of Elasticity. *Journal of Engineering Mechanics*, **148**(2):04021154.
- [6] Masi, F., Stefanou, I. (2022). Multiscale modeling of inelastic materials with Thermodynamics-based Artificial Neural Networks (TANN). *Computer Methods in Applied Mechanics and Engineering*, **398**:115190.
- [7] Liu, M., Sun, E., Zhang, N., Lai, F., Fuentes, R., (2024a). A virtual calibration chamber for cone penetration test based on deep-learning approaches. *Journal of Rock Mechanics and Geotechnical Engineering*.
- [8] Moeineddin, A., Seguí, C., Dueber, S., Fuentes, R. (2023). Physics-informed neural networks applied to catastrophic creeping landslides. *Landslides* **20**, 1853–1863.
- [9] Liu, M., and Zhang, Q., and Fuentes, R. (2024b). A FEM-PINN Approach to Modelling

Elastoplastic Soil Behaviour in Boundary Value Problems. Available at SSRN: <https://ssrn.com/abstract=5010906> or <http://dx.doi.org/10.2139/ssrn.5010906>

- [10] Seguí C, Rattetz H, Veveakis M (2020). On the stability of deep-seated landslides. The cases of Vaiont (Italy) and Shuping (Three Gorges Dam, China). *Joiurnal of Geophysical Research - Earth Surface* **125**(7):e2019JF005203
- [11] Seguí C, Veveakis M (2022). Fusing physics-based and data-driven models to forecast and mitigate landslide collapse. California Digital Library (CDL). <https://doi.org/10.31223/X5W642>

## **Author**

Univ.-Prof. Dr.-Ing. Raul Fuentes  
RWTH Aachen  
Institut für Geomechanik und Untergrundtechnik.  
Mies van der Rohe Strasse 1,  
52074, Aachen.

Technische Universität Hamburg  
Institut für Geotechnik und Baubetrieb  
Harburger Schloßstraße 36  
21079 Hamburg  
Tel.: +49 (0) 241 80 25247  
e-mail: [raul.fuentes@gut.rwth-aachen.de](mailto:raul.fuentes@gut.rwth-aachen.de)  
Web: [www.gut.rwth-aachen.de](http://www.gut.rwth-aachen.de)



# Anwendung von KI zur Programmierung von Python-Scripten am Beispiel der Visualisierung von Dispersion

Abdulsalam Abdulrahman, Eugen Perau

**Abstract:** Der Einsatz von Künstlicher Intelligenz (KI) im geotechnischen Bereich nimmt stetig zu. Diese Arbeit präsentiert eine Fallstudie darüber, wie KI – konkret ChatGPT – zur Unterstützung der Programmierung einer Python-basierten Simulation für die Visualisierung der Partikeldispersion in porösen Medien eingesetzt wurde. Die Studie beschreibt die praktischen Schritte, die Einschränkungen sowie das Potenzial einer KI-gestützten Softwareentwicklung in geotechnischen Anwendungen. Die Simulationsergebnisse und der Interaktionsprozess mit der KI werden kritisch erörtert.

## 1 Einleitung

Künstliche Intelligenz (KI) wird zunehmend auch im Ingenieurwesen diskutiert und angewendet – so auch in der Geotechnik. In diesem Beitrag wird anhand einer konkreten Aufgabenstellung, der Visualisierung geotechnischer Dispersionsprozesse, der praktische Einsatz von KI zur Programmierung eines ingenieurwissenschaftlichen Tools dokumentiert.

Im Mittelpunkt des vorliegenden Beitrags steht dabei nicht die physikalische Modellierung von Dispersion selbst, sondern die KI-gestützte Erstellung eines Python-Programms zur Simulation und grafischen Darstellung entsprechender Prozesse. Der Bericht zeigt, wie durch den gezielten Einsatz von ChatGPT ein komplexer Programmierprozess iterativ unterstützt und umgesetzt werden kann. Weitere Details sind dem Beitrag (Perau und Abdulrahman, 2025) zu entnehmen.

Zur Einordnung wird zunächst kurz der Begriff „Dispersion“ veranschaulicht, der dem beschriebenen Anwendungsbeispiel zugrunde liegt:

**Dispersion** wird in der geotechnischen Literatur (z. B. Kinzelbach und Rausch, 1995; Bear und Verruijt, 1998) in aller Regel im Zusammenhang mit dem Transport von Schadstoffen im Grundwasser behandelt. Sie beschreibt die ausbreitende Bewegung gelöster Partikel infolge mikroskopischer Umwegpfade in porösen Medien. Dabei überlagert sich der advective Transport mit diffusionsartigen Mechanismen, wobei der Proportionalitätsfaktor zwischen Konzentrationsgradient und Schadstofffluss nicht konstant, sondern abhängig von Betrag und Richtung der Strömungsgeschwindigkeit ist.




Abb. 1: Ausbreitung (Dispersion) feiner Partikel durch zufällige Ablenkungen durch Störkörper, die entlang ihrer Bewegungsrichtung angeordnet werden

Als kleiner Ausblick auf die Einsatzmöglichkeit von KI diene bereits die Antwort von GPT-4o (ChatGPT, 2024) auf die folgende Abfrage:

**Frage:** „Erkläre mir anhand dieser Abbildung den Begriff Dispersion feiner Partikel in nicht-bindigen Böden!“

Dazu wurde der KI die Abbildung 1 in Form einer jpg-Datei gereicht.

**ChatGPT:** „Die Dispersion feiner Partikel erfolgt durch zufällige Ablenkungen entlang ihres Bewegungswegs, was zu einer Streuung der Partikelpositionen führt. Jede Ablenkung vergrößert die Breite der Verteilung, sodass die Partikel sich zunehmend über den Raum verteilen. Am Ende des Prozesses ergibt sich eine Konzentrationsverteilung. Die folgende Abbildung veranschaulicht die Konzentrationsverteilung der feinen Partikel entlang ihres Bewegungswegs (hier von oben nach unten).“

Die Antwort von ChatGPT liefert eine anschauliche, wenn auch vereinfachte Beschreibung des Dispersionsprozesses und verdeutlicht damit das Potenzial, aber auch die Grenzen KI-basierter Erklärungen in geotechnischen Anwendungen.

## 2 Ausgangssituation

Im Fachgebiet Geotechnik der Universität Duisburg-Essen bestand die Aufgabe darin, theoretische Ansätze zur Dispersion – insbesondere auf Grundlage der Theorie poröser Medien – durch geeignete Visualisierung darstellbar zu machen. Dabei sollten neben advektiven Transportmechanismen auch weitere physikalische Einflüsse, wie Gravitation sowie Wechselwirkungen zwischen Korngefüge, Wasser und Partikeln, berücksichtigt werden.

Die zugrunde liegenden Berechnungsansätze wurden zuvor im Rahmen einer Masterarbeit (Abdulrahman, 2023) entwickelt bzw. ausbreitet. Sie basieren auf einem Satz vektorwertiger Differentialgleichungen zur Beschreibung des Partikeltransports in einem porösen Medium. Eine exemplarische Form dieser Gleichungen lautet:

$$\operatorname{div} \mathbf{T}_k + \rho_k \cdot (\mathbf{b} - \ddot{\mathbf{x}}_k) + \mathbf{s}_k = m_k \cdot \dot{\mathbf{x}}_k. \quad (1)$$

In dieser Gleichung werden für jede Konstituente (Index  $k$ ) der Spannungstensor  $\mathbf{T}_k$ , die Dichte  $\rho_k$ , die Gravitationskraft  $\rho_k \cdot \mathbf{b}$  sowie Austauschsterme für Masse  $m_k$  und Impuls  $\mathbf{s}_k$  berücksichtigt. Der Spannungstensor für die Partikelkomponente  $\mathbf{T}_p$  enthält zusätzlich Terme zur Beschreibung der Ausbreitung durch Advektion und Dispersion. Die Massenträgheitskräfte  $\rho_k \cdot \ddot{\mathbf{x}}_k$  in dieser Gleichung werden in der Regel vernachlässigt.

Eine numerische Lösung dieser Gleichungen ist – abgesehen von Sonderfällen – nur mit entsprechender Softwareunterstützung möglich. Die Nutzung bestehender kommerzieller Programme wurde ausgeschlossen, da diese häufig kostenintensiv, unflexibel oder nicht quelloffen sind.

Zur Realisierung eines geeigneten Visualisierungstools unter diesen Rahmenbedingungen bot sich der Einsatz von Künstlicher Intelligenz zur Unterstützung der Softwareentwicklung an – insbesondere in Form eines dialogbasierten Assistenzsystems zur Codeerstellung.

## 3 Phasen der Bearbeitung

### 3.1 Entscheidung für den Einsatz Künstlicher Intelligenz

Zur Umsetzung der geforderten Visualisierung war die Entwicklung einer maßgeschneiderten Softwarelösung erforderlich. Aufgrund begrenzter Programmierkenntnisse wurde die Nutzung eines KI-basierten Assistenzsystems zur Codegenerierung favorisiert.

Nach ersten Tests mit der frei zugänglichen Version GPT-3.5, deren Funktionen für komplexe Programmieraufgaben nicht ausreichten, wurde die erweiterte Version GPT-4o eingesetzt. Diese ermöglichte nicht nur die Verarbeitung längerer Texte und Programmiersequenzen, sondern auch die Analyse von Gleichungen und Fehlermeldungen anhand von Screenshots.

Für die spezifischen Anforderungen im geotechnischen Kontext wurde das Tool „Python Code Expert“ verwendet, das auf die Unterstützung bei der Erstellung und Optimierung von Python-Code spezialisiert ist. Alle notwendigen Informationen zur Aufgabenstellung mussten strukturiert in das System eingegeben werden, um eine zielgerichtete Programmierung zu ermöglichen.

### 3.2 Umsetzung der Programmierung mit KI-Unterstützung

Zu Beginn der Bearbeitung wurden auf Empfehlung von ChatGPT die Programme Python 3.12 (64-bit) sowie Visual Studio Code installiert. Anschließend erfolgte die Interaktion über das Tool „Python Code Expert“, mit dem ein Python-Skript zur Simulation des Partikeltransports entwickelt werden sollte.

Die zugrunde liegenden Differentialgleichungen wurden der KI als Screenshots zur Verfügung gestellt. Diese wurden von ChatGPT analysiert und in einen ersten lauffähigen Code umgesetzt. Aufgrund unpräziser Eingaben wurden Feldgrößen dabei zunächst fälschlich als Konstanten interpretiert, wodurch es zu einer nicht sachgerechten Vereinfachung kam. Die erste Version des Programmcodes beschränkte sich auf eine eindimensionale Berechnung und war für die geplante Visualisierung der transversalen Dispersion ungeeignet. Sie bildete jedoch die Ausgangsbasis für eine schrittweise Weiterentwicklung.

Zur verwendeten numerischen Methode wurde seitens ChatGPT erläutert, dass der Code auf der Finite-Volumen-Methode (FVM) basiert. Die Implementierung erfolgt unter Nutzung der Python-Bibliothek fipy, die speziell für FVM-Anwendungen entwickelt wurde. Das zugrunde liegende Rechengitter ist ein regelmäßiges, kartesisches Grid2D, das durch die Parameter  $dx$ ,  $dy$ ,  $nx$  und  $ny$  definiert ist. Dieses Gitter eignet sich besonders als Grundlage für die Modellierung von Strömungs- und Transportprozessen in rechteckigen Gebieten.

### 3.3 Benutzeroberfläche zur Parametereingabe

Im Rahmen der Programmstruktur wurde mit Unterstützung von ChatGPT (GPT-4o, Python Code Expert) eine grafische Benutzeroberfläche (GUI) entwickelt, die es ermöglicht, alle für die Simulation relevanten Parameter komfortabel einzugeben (siehe Abb. 2). Diese beinhalten unter anderem die geometrischen Abmessungen des Untersuchungsgebiets, Anfangs- und Randbedingungen, Strömungsgeschwindigkeit, physikalische Stoffeigenschaften sowie die Positionen, an denen Konzentrationen ausgewertet werden sollen.

Transport der feinen Partikel infolge Grundwasserströmung			
Eingaben:			
Abmessung des Untersuchungsfeldes	Länge des Untersuchungsfeldes (L):	4,00	[m]
	Breite des Untersuchungsfeldes (B):	4,00	[m]
	Länge des FE-Elements (l):	0,01	[m]
Lage der feinen Partikel am Versuchsanfang	X-Koordinate der Anfangslage:	1	[m]
	Y-Koordinate der Anfangslage:	2	[m]
	Durchmesser des Partikelbereichs (d):	0,4	[m]
Berechnungszeit der Untersuchung	Maximale Berechnungsdauer (t_max):	600	[s]
	Berechnungsschritte (delta_t):	5	[s]
Dichten von F und P	Reindichte Fluid ( $\rho_{FR}$ ):	1000	[kg/m <sup>3</sup> ]
	Reindichte Partikel ( $\rho_{PR}$ ):	2000	[kg/m <sup>3</sup> ]
Abstandsgeschwindigkeit vom Wasser	Abstandsgeschwindigkeit X ( $v_{a1}$ ):	0,008	[kg/(m <sup>2</sup> s)]
	Abstandsgeschwindigkeit Y ( $v_{a2}$ ):	0	[kg/(m <sup>2</sup> s)]
Dispersionskoeffizienten	Longitudinale Dispersionskoeff. ( $\alpha_L$ ):	0,03	
	Transversale Dispersionskoeff. ( $\alpha_T$ ):	0,01	
Konzentration an der gewünschten Stelle	X-Koordinate Messstelle	2	[m]
	Y-Koordinate Messstelle	2	[m]

Abb. 2: Importmaske für Excel-Tabelle mit Simulationsparametern (links), und Benutzeroberfläche mit manuellen Eingabefeldern und Simulationseinstellungen (rechts)

Die Parametereingabe erfolgt wahlweise manuell über Eingabefelder oder automatisiert über eine vorbereitete Excel-Datei. Beide Varianten wurden in die Benutzeroberfläche integriert und sind funktional mit dem Simulationscode verbunden. Auch diese Bestandteile des Python-Programmes wurden durch die KI auf Grundlage konkreter Vorgaben generiert.

Im weiteren Verlauf wurde das Python-Programm schrittweise erweitert, indem ChatGPT zusätzliche Vorgaben zur Funktionalität erhielt. Ziel war die Berechnung und grafische Darstellung von Konzentrationsverteilungen bzw. Volumenanteilen feiner Partikel in Raum und Zeit, basierend auf benutzerdefinierten Eingaben.

Fehlermeldungen während der Ausführung wurden über Text oder Screenshots zurückgemeldet und durch gezielte Korrekturvorschläge der KI im Code behoben. Aufgrund des steigenden Umfangs wurde der Code in mehrere Module unterteilt, um eine strukturierte Weiterentwicklung zu ermöglichen.

Das Programm gliedert sich in vier funktionale Hauptbestandteile:

1. **Transport.py:** Steuerung der Programmausführung
2. **Hauptfenster.py:** Umsetzung der grafischen Benutzeroberfläche
3. **Excel\_import.py:** Importfunktion vorbereiteter Parameterdateien
4. **Berechnen.py:** Numerische Berechnung und grafische Ausgabe der Ergebnisse

Zur Vereinfachung der Bearbeitung kann ChatGPT bei Bedarf den modularen Code neu zusammenführen, sodass Anpassungen gezielt erfolgen können, ohne manuell an verschiedenen Stellen nachzuarbeiten.

## 4 Exemplarische Darstellung von Berechnungsergebnissen

Zur Überprüfung der Funktionalität des mit Hilfe von KI entwickelten Python-Programms wurden exemplarische Berechnungen durchgeführt. Im folgenden Beispiel wird die zeitliche Entwicklung der Partikelkonzentration an zwei Messpunkten entlang der Strömungsrichtung analysiert.

Das betrachtete Simulationsgebiet ist  $4,0 \text{ m} \times 4,0 \text{ m}$  groß und wurde in quadratische Elemente mit einer Kantenlänge von  $0,01 \text{ m}$  unterteilt. Die Partikel wurden zu Beginn in einem kreisförmigen Bereich mit einem Durchmesser von  $0,40 \text{ m}$  in der Position:  $x = 1,0 \text{ m}$ ,  $y = 2,0 \text{ m}$  mit einer maximalen Konzentration von  $c_p = 1,0$  eingebracht.

Die Berechnungen erfolgten über einen Zeitraum von  $600 \text{ s}$  mit Zeitschritten von  $5 \text{ s}$ . Als Strömungsbedingung wurde eine konstante Abstandsgeschwindigkeit von  $v_{al} = 0,008 \text{ m/s}$  in  $x$ -Richtung angenommen. Die physikalischen Parameter wurden wie folgt gesetzt: Fluidichte  $1000 \text{ kg/m}^3$ , Partikeldichte  $2000 \text{ kg/m}^3$ , longitudinaler Dispersionskoeffizient  $\alpha_L = 0,03$  und transversaler Dispersionskoeffizient  $\alpha_T = 0,01$ .

Die Konzentrationsentwicklung wurde an zwei Stellen im Strömungsfeld ausgewertet:

1. **Fall a:**  $x = 2,5 \text{ m}$ ,  $y = 2,0 \text{ m}$
2. **Fall b:**  $x = 3,0 \text{ m}$ ,  $y = 2,0 \text{ m}$

Abb. 3 zeigt die Ausgangssituation der Simulation zu Beginn ( $t = 0$  s) mit der Lage der Messpunkte. Der zentrale schwarze Kreis stellt den Bereich der Anfangskonzentration dar. Die roten Punkte markieren die Stellen, an denen die zeitabhängige Konzentration ermittelt wurde.




Abb. 3: Ausgangszustand der Beispielberechnung für die Simulation, links: Fall a Messpunkt bei  $x = 2,5$  m, rechts: Fall b Messpunkt bei  $x = 3,0$  m.

Die grafische Auswertung der berechneten Konzentrationen über die Zeit ist in Abb. 4 dargestellt. Die schwarze Linie zeigt den Verlauf im Zentrum der Ausgangsstelle, während die rote Linie die Entwicklung an den jeweiligen Messpunkten (Fall a und b) wiedergibt. Dabei ist gut zu erkennen, wie sich die Partikelkonzentration infolge von Advektion und Dispersion zunächst vom Zentrum aus verringert und sich zeitlich verzögert an den Messpunkten aufbaut und wieder abnimmt.




Abb. 4: Zeitlicher Verlauf der Partikelkonzentration, links Fall a und rechts Fall b.

Die dargestellten Grafiken wurden automatisch von dem mit Hilfe der KI erstellten Programm generiert. Die Auswahl der Messpunkte, der Zeitschritte und der grafischen Darstellung erfolgte über einfache Vorgaben an die KI und wurde in den Python-Code integriert.

Ergänzend zur punktuellen Auswertung wurde im gleichen Simulationsbeispiel eine alternative Darstellung der Ergebnisse gewählt. Die geometrischen Bedingungen, physikalischen Parameter und Anfangskonzentration entsprechen dabei exakt dem zuvor beschriebenen Fall.

Im Fokus steht hier jedoch die flächige Visualisierung der Konzentrationsverteilung über den gesamten Simulationsraum hinweg. Die Darstellung erfolgte für mehrere Zeitschritte (Schritte 0 bis 50), wobei die Konzentration  $c_p$  durch abgestufte Grautöne und ergänzend durch Isolinien repräsentiert wurde.

Zu Beginn der Simulation ( $t = 0$  s, Schritt 0) sind die Partikel ausschließlich in ihrem Startbereich konzentriert. Mit zunehmender Zeit erfolgt ein advektiver Transport sowie eine dispersive Ausbreitung, wobei sich – infolge der gerichteten Strömung in  $x$ -Richtung – eine deutlich stärkere Ausdehnung in Längsrichtung gegenüber der Transversalrichtung ergibt. Dieses Verhalten reflektiert die eingestellten Dispersionskoeffizienten  $\alpha_L$  und  $\alpha_T$ .

Die grafische Umsetzung wurde durch den programmierten Code automatisiert erstellt. Vorgaben zur Darstellungsart (z. B. Isolinien, Graustufen) konnten dabei flexibel über Textanweisungen an die KI definiert und direkt im Code umgesetzt werden.




Abb. 5: Entwicklung der Partikelkonzentration über die Zeit und den Ort – Darstellung mit Isolinien und Graustufen

Die erzeugte Bildsequenz kann darüber hinaus als animierte GIF-Datei ausgegeben werden, wodurch die Dynamik der Ausbreitung visuell besonders anschaulich dargestellt werden kann.

## 5 Fragestellungen als Diskussionsgrundlage

Der Einsatz von KI zur Programmierung technischer Modelle wirft zentrale Fragen auf, die sowohl für wissenschaftliches Arbeiten als auch für die praktische Anwendung von Rechner-Systemen im Ingenieurwesen relevant sind. Insbesondere betreffen diese Fragen die Brauchbarkeit und Nachvollziehbarkeit der Ergebnisse, die Zitierfähigkeit und Urheberchaft, sowie den Umgang mit sensiblen Informationen und die potenzielle Weitergabe von Nutzerwissen durch die KI. Weitere Einzelheiten sind dem Beitrag (Perau und Abdulrahman, 2025) zu entnehmen.

Die Simulationsergebnisse wurden anhand eines Vergleichs mit analytischen Lösungen einfacher Transportprobleme sowie mit numerischen Referenzrechnungen aus Abdulrahman (2023) verifiziert. Die Vergleiche zeigten eine gute Übereinstimmung, sodass die Korrektheit der Implementierung und die Eignung des Modells für den vorgesehenen Anwendungsbereich bestätigt werden konnten.

## 5.1 Brauchbarkeit und Transparenz

Die mit Hilfe von ChatGPT erstellte Software erwies sich im praktischen Einsatz als funktional und zielführend. Die Entwicklung erfolgte iterativ, wobei der Code schrittweise erweitert und durch Rückmeldungen der KI verfeinert wurde. Diese Vorgehensweise hat sich gegenüber einer vollständigen Initialbeschreibung als vorteilhaft erwiesen, insbesondere im Hinblick auf die Verständlichkeit des generierten Codes.

Aus technischer Sicht basiert das Programm auf der Finite-Volumen-Methode (FVM) und bildet den Transport feiner Partikel durch Advektion und Dispersion in porösen Medien ab. Die KI konnte die mathematisch-physikalischen Grundlagen korrekt wiedergeben, wobei der Lösungsweg über diskretisierte Kontrollvolumina erfolgt.

Die Nachvollziehbarkeit des Codes hängt jedoch stark vom Verständnis des Nutzers und der Klarheit der Eingaben ab. Die KI bietet funktionale Unterstützung, ersetzt jedoch nicht die kritische Kontrolle oder das ingenieurwissenschaftliche Verständnis.

## 5.2 Risiken und Limitationen

Die durch ChatGPT aufgezeigten Risiken umfassen unter anderem:

- Fehlinterpretationen durch ungenaue Eingaben
- begrenzte Transparenz der Entscheidungsprozesse
- Schwierigkeiten bei manueller Weiterbearbeitung aufgrund fehlender Detailkenntnisse
- Datenschutzprobleme bei sensiblen Inhalten
- ethische Risiken, etwa durch ungewollte Verzerrungen (Bias).

Diese Aspekte sind im Umgang mit KI-Systemen stets zu berücksichtigen und erfordern eine reflektierte Anwendung, insbesondere bei sicherheitsrelevanten oder publikationsbezogenen Vorhaben.

## 5.3 Zitierfähigkeit und wissenschaftlicher Umgang

Die Zitierfähigkeit KI-generierter Inhalte ist eingeschränkt. Da ChatGPT auf einem algorithmischen Prozess basiert, der keine überprüfbaren Primärquellen nennt, gelten seine Ausgaben nicht als wissenschaftliche Quellen. Inhalte sollten daher nicht direkt zitiert, sondern als Hilfsmittel zur Strukturierung oder Ideengewinnung verstanden und entsprechend transparent in der Arbeit offengelegt werden.

Die KI liefert keine Quellen als Beleg im wissenschaftlichen Sinne, daher liegt die Verantwortung zur Überprüfung und fundierten Begründung beim Nutzer.

## 5.4 Urheberrecht und Weitergabe von Nutzerwissen

Ein weiterer kritischer Aspekt ist die Verarbeitung und potenzielle Wiederverwendung von Benutzereingaben. Laut KI erfolgt die Verarbeitung temporär und das Wissen wird nicht gezielt

weitergegeben an andere Nutzer. Dennoch besteht keine vollständige Garantie dafür, dass Inhalte nicht im Training oder in ähnlichen Ausgaben erneut erscheinen. Dies betrifft insbesondere Texte, Code-Fragmente und fachspezifisches Wissen, das in die KI eingebracht wurde.

Die Empfehlung der KI, sensible oder schutzwürdige Inhalte nur mit Vorsicht einzugeben, sollte ernst genommen werden – insbesondere im Kontext urheberrechtlich geschützter oder vertraulicher Informationen.

ChatGPT selbst erkennt an, dass ähnliche Eingaben von unterschiedlichen Nutzern zu vergleichbaren Ergebnissen führen können, auch wenn keine direkte Weitergabe erfolgt. Dies kann problematisch sein, wenn komplexe fachliche Lösungen durch die KI unbeabsichtigt Dritten zugänglich gemacht werden.

## 6 Fazit und Ausblick

Die vorliegende Arbeit demonstriert das Potenzial des gezielten Einsatzes Künstlicher Intelligenz – im konkreten Fall ChatGPT – zur Unterstützung bei der Entwicklung technischer Simulationsprogramme. Am Beispiel eines numerischen Modells zur Visualisierung der Dispersion feiner Partikel in porösen Medien konnte aufgezeigt werden, dass KI-gestützte Systeme in der Lage sind, auch komplexe Programmieraufgaben in einem iterativen, dialogbasierten Prozess effizient umzusetzen.

Besonders hervorzuheben ist die effektive Verknüpfung ingenieurwissenschaftlicher Problemstellungen mit der KI-gestützten Codegenerierung. Die Fähigkeit der KI, mathematische Gleichungen zu analysieren, Fehlermeldungen zu interpretieren, grafische Benutzeroberflächen zu erstellen sowie Ergebnisse visuell darzustellen, bietet einen signifikanten Mehrwert – vorausgesetzt, die Kommunikation mit dem System erfolgt strukturiert und fachlich präzise. Gleichzeitig bleibt die Verantwortung für Plausibilitätsprüfung, Validierung und wissenschaftliche Nachvollziehbarkeit vollständig beim Anwender.

Ein Vorteil, einen eigenen Programmcode in Python zu entwickeln, liegt in ihrer hohen Zugänglichkeit für Studierende und Lehrende, da die Software ausschließlich auf frei verfügbaren, quelloffenen Bibliotheken basiert, kann sie ohne zusätzliche Lizenzkosten genutzt und auf handelsüblichen Rechnern installiert werden. Da Studierende des Bauingenieurwesens der Universität Duisburg-Essen im Bachelor-Studiengang Python als Programmiersprache erlernen müssen, ergeben sich in der Geotechnik Anwendungsmöglichkeiten, die die Motivation zum Erlernen der Programmiersprache steigern wird.

Am Fachgebiet Geotechnik der Universität Duisburg-Essen wird der Ansatz, Programmierung mit Unterstützung durch KI durchzuführen, derzeit systematisch in Forschung und Lehre implementiert. Vor allem in Bachelor- und Masterarbeiten werden dabei die Möglichkeiten des KI-gestützten Programmierens in Python genutzt. Der vorliegende Beitrag liefert damit nicht nur ein praxisorientiertes Fallbeispiel, sondern zugleich eine Grundlage für künftige Arbeiten, in denen die Synergien zwischen domänenspezifischem Fachwissen und KI-gestützten Entwicklungsprozessen vertieft analysiert und weiterentwickelt werden.

## Literatur

- [1] Abdulrahman, A. (2023): Analytische und numerische Auswertung eines Modells zur Simulation von Dispersion von Partikeln in nichtbindigen Böden. Masterarbeit an der Universität Duisburg-Essen, Fachgebiet Geotechnik, Hrsg.: E. Perau (unveröffentlicht)
- [2] Askamp, T. (2024): Ein Modell zur Beschreibung innerer Erosion, Grundzüge des mechanischen Modells und Ansätze zum Massenproduktionsterm. *Report Geotechnik*, Heft 49, Universität Duisburg-Essen. <https://doi.org/10.17185/dupublico/81891>
- [3] Bear, J. und Verruijt, A. (1998): *Modeling Groundwater Flow and Pollution. Theory and Applications of Transport in Porous Media*, 2nd Edition. Dordrecht u.a.O., D. Reidel Publishing Company
- [4] Kinzelbach, W. und Rausch R. (1995): *Grundwassermodellierung – Eine Einführung mit Übungen*. Berlin, Stuttgart, Gebrüder Borntraeger
- [5] Microsoft (2023): Visual Studio Code (Version 2023). [Online] Verfügbar unter: <https://code.visualstudio.com/> [Abrufdatum: 12.07.2024]
- [6] OpenAI (2024): ChatGPT (GPT-3.5 und GPT-4o). [Online] Verfügbar unter: <https://openai.com/> [Abrufzeitraum: 04.07.2024–20.12.2024]
- [8] Perau, E. und Abdulrahman, A. (2025): *Szenario zur Anwendung von KI zur Visualisierung von Ansätzen zur Dispersion – Erfahrungen und Fragen*. Digitalisierung in der Geotechnik – wohin geht die Reise? Tagungsband zum 14. RuhrGeo-Tag am 27.03.2025 in Essen, Report Geotechnik, Heft 50, Universität Duisburg-Essen, Fachgebiet Geotechnik, S. 79-96. <https://doi.org/10.17185/dupublico/82728>
- [7] Python Software Foundation (2023): Python 3.12. [Online] Verfügbar unter: <https://www.python.org/downloads/release/python-312/> [Abrufdatum: 12.07.2024]

## Autoren

Abdulsalam Abdulrahman, M.Sc.  
Universität Duisburg-Essen  
Fakultät für Ingenieurwissenschaften  
Abteilung Bauwissenschaften  
Fachgebiet Geotechnik  
Universitätsstraße 2  
45141 Essen  
Tel.: +49 (0) 201 – 1833117  
E-Mail: [abdulsalam.abdulrahman@uni-due.de](mailto:abdulsalam.abdulrahman@uni-due.de)  
Web: [www.uni-due.de/geotechnik](http://www.uni-due.de/geotechnik)

Prof. Dr.-Ing. Eugen Perau  
Universität Duisburg-Essen  
Fakultät für Ingenieurwissenschaften  
Abteilung Bauwissenschaften  
Fachgebiet Geotechnik  
Universitätsstraße 2  
45141 Essen  
Tel.: +49 (0) 201 – 1832858  
E-Mail: [eugen.perau@uni-due.de](mailto:eugen.perau@uni-due.de)  
Web: [www.uni-due.de/geotechnik](http://www.uni-due.de/geotechnik)

# Automated parameter determination: From in-situ measurements to constitutive models

Islam Marzouk, Haris Felić, Franz Tschuchnigg, Ronald Brinkgreve

**Abstract:** Site characterization relies on both in-situ and laboratory testing. In the early stages of a project, in-situ tests are often performed before launching a full laboratory testing program. At this stage—when soil data is limited—in-situ tests can provide valuable insights for preliminary characterization. To enhance the interpretation of these tests, an automated parameter determination framework has been developed, employing a graph-based approach to derive soil and constitutive model parameters from in-situ measurements. Several studies have been conducted to validate the framework’s output in terms of both soil properties and model parameters. The framework is designed to be transparent and adaptable, allowing users to trace the computed values for different parameters and incorporate their experience, knowledge and expertise. In this study, the tool was applied to a well-documented test site in Australia. Additionally, the integration of machine learning models for predicting soil parameters is explored as part of ongoing efforts to incorporate data-driven techniques into the framework.

## 1 Introduction

In-situ testing offers an alternative approach for determining soil parameters. Compared to laboratory tests, in-situ methods are more economical, faster, capable of assessing larger soil volumes, and cause less disturbance to the in-situ soil conditions. However, parameters cannot be directly obtained from in-situ measurements; their determination depends on interpretation through empirical correlations. These correlations are often limited in applicability, typically developed for specific soil types or conditions—such as a specific overconsolidation ratio (Kulhawy and Mayne 1990). As a result, multiple correlations may exist for the same parameter, introducing (additional) uncertainty in the derived values.

An Automated Parameter Determination (APD) framework has been developed as part of a research project to enable the automated interpretation of in-situ test results. The framework determines parameters using a graph-based approach (Van Berkom et al., 2022). Various publications have addressed different aspects of the tool, ranging from the general structure and implementation of the framework (Marzouk et al., 2024) to the integration of additional in-situ tests (Marzouk et al., 2023). Several studies have focused on validating the tool’s output in

terms of soil parameters (Marzouk et al., 2024; Marzouk and Tschuchnigg, 2024). An attempt to validate the output with respect to constitutive model parameters was made by Marzouk et al. (2025a), where parameters for the Clay and Sand Model (CASM) (Yu, 1998) were derived and used to numerically simulate a cone penetration test (CPT), with the results compared against the CPT used for interpretation. The automated connection between APD and a finite element (FE) software was demonstrated by Marzouk and Tschuchnigg (2025b), in which a synthetic shallow footing was modelled.

The framework consists of three main workflows, each dedicated to a specific in-situ test method for parameter determination: the cone penetration test (CPT), the dilatometer test (DMT), and shear wave velocity ( $V_s$ ) measurements. This study explores additionally the integration of data-driven methods as a fourth, complementary approach for parameter estimation. All four approaches—the three conventional workflows and the data-driven method—are applied to a well-instrumented test site in Australia, where the derived soil parameters are compared against reference values interpreted at the site.

## **2 Automated parameter determination framework**

The various components of the framework are described in detail in Marzouk et al. (2024). To avoid redundancy, only the key aspects are outlined in this section; interested readers are referred to Marzouk et al. (2024) for a comprehensive description.

The framework follows a modular architecture that links raw in-situ measurements to finite element (FE) software. In the CPT-based workflow, Module 1 imports raw data and computes some CPT parameters (e.g., normalized cone resistance  $Q_t$ ). Module 2 performs stratification of the measurements into soil layers. Module 3 evaluates the stress state within each layer, including the overconsolidation ratio (OCR) and the coefficient of earth pressure at rest ( $K_0$ ). Modules 4 and 5 implement the graph-based approach to derive both soil and constitutive model parameters. The final step involves transferring the output to the FE software.

The graphs are generated using two CSV files: one describing the methods (i.e., correlations) and the other specifying the parameters. The framework is developed in Python, and graph visualization is done using the Graphviz library (Gansner, 2011). The current version of the tool includes a validated database of more than 200 methods, covering both soil and constitutive model parameters.

### **2.1 Data-driven Site Characterization for Soil Parameter Determination**

Within the framework of APD, machine learning can be used as an additional source of information that supports conventional methodologies based on laboratory and in-situ data. Rather than replacing established empirical correlations, ML techniques augment them by data-driven

estimations of soil parameters, particularly in contexts characterized by limited availability of correlations. Validation against independent dataset (i.e. Ballina test site) has demonstrated the robustness of ML-based soil parameter predictions.

### 2.1.1 Databases used for machine learning

Two independent databases were compiled for ML model development. First, the laboratory database consists of paired records of CPT measurements and soil parameters derived from laboratory testing on borehole samples collected in close proximity to the CPT locations. This database contains 622 data pairs for saturated unit weight  $\gamma_t$  and 193 for undrained shear strength  $s_u$ . Data sources include publicly accessible datasets from Ballina and NGTS ([geocalcs.com/datamap](https://geocalcs.com/datamap)), a Dutch dataset (Lengkeek and Breedevelde 2022), as well as confidential datasets from Norwegian and Austrian projects. To ensure an unbiased ML performance assessment, the Ballina dataset was excluded from model training. Second, the in-situ database consists of 46 seismic CPT and 254 seismic CPTu tests, resulting in a total of 21,760 individual records. Data sources include the New Zealand Geotechnical Database (Scott et al., 2015), project data from Premstaller Geotechnik (Oberhollenzer et al., 2021), the Dutch dataset repository ([github.com/snakesonabrain/isc7\\_datasets](https://github.com/snakesonabrain/isc7_datasets)), and site data from Taiwan ([data.mendeley.com/datasets/v7frv3k2d3/1](https://data.mendeley.com/datasets/v7frv3k2d3/1)).

### 2.1.2 Machine learning algorithm and feature selection

All models developed in this study utilize the XGBoost algorithm (eXtreme Gradient Boosting Decision Tree), which represents an advanced variant of the Gradient Boosting Decision Tree (GBDT) technique. XGBoost improves predictive performance and computational efficiency by incorporating more regularization terms and parallelized tree building.

In supervised ML, a model creates a function between selected input features and the target variable (Deisenroth et al., 2021). The input feature matrix used here comprises depth, cone resistance  $q_c$ , sleeve friction  $f_s$ , and friction ratio  $R_f$ , similar to Felić et al. (2024). Preliminary analyses showed that this feature set is suitable for robust predictions. Due to the use of tree-based models, no feature transformation or normalization (i.e. feature engineering) was required. Separate models were trained for each target variable in this study:  $\gamma_t$ ,  $s_u$ ,  $V_s$ .

### 2.1.3 Training workflow

The model training and evaluation protocol follows standard ML practices, as outlined by Deisenroth et al. (2021). Initially, the data are randomly split into a training set (80 %) and a test set (20 %). The training data are further subdivided to create a validation set for hyperparameter tuning and performance monitoring. The initial training phase is conducted with default

hyperparameters. Model performance is assessed on the validation set using the coefficient of determination  $R^2$  as the objective function. To reduce overfitting, ten-fold cross-validation is employed. In addition, early stopping is employed to stop the training process if the validation error does not improve for ten consecutive iterations. Hyperparameter optimization is carried out using the Differential Evolution algorithm implemented via the `pymoo` library, with a population size of 25. The optimization goal is to maximize  $R^2$ . The process terminates after 1,000 iterations or when a relative error threshold of  $10^{-4}$  is reached. The best-performing hyperparameter set is then used to retrain the model on the combined training and validation datasets. Final model performance is evaluated on the test dataset. If acceptable performance is achieved, the final model is retrained using the full dataset.

### 2.1.4 Results of model performance

Figure 1 shows scatter plots comparing predicted and observed values for  $\gamma_t$ ,  $s_u$ , and  $V_s$  of the ML model after hyperparameter optimization. The dashed 45° line indicates perfect agreement. The scatter patterns show good predictive accuracy overall, with  $R^2$  values ranging from 0.58 to 0.83. Some deviations, particularly in  $V_s$  predictions in the lower range (0–350 m/s), are observed. These deviations of the ML model is part of ongoing research.




Figure 1: Evaluation of ML model performance after optimization via ten-fold cross-validation and early-stopping criteria.

## 3 Case study

### 3.1 Test site

This study focuses on the Ballina Soft Soil National Field Testing Facility (NFTF), located near the town of Ballina in New South Wales, Australia. The facility was established by the ARC Centre of Excellence for Geotechnical Science and Engineering (CGSE). Comprehensive characterization of the site is provided in Pineda et al. (2016) and Kelly et al. (2017). Interpreted

values used in this study were obtained from Datamap (Doherty et al., 2018), a web-based platform for managing and accessing geotechnical data.

### 3.2 Soil parameters

As in Section 2, three parameters are considered in this study: unit weight ( $\gamma_t$ ), undrained shear strength ( $s_u$ ), and small-strain stiffness ( $G_0$ ). For the determination of  $\gamma_t$ , a total of 13 methods were employed. 4 methods were used in the CPT-based workflow, 5 in the DMT-based workflow, and 4 in the  $V_s$ -based workflow. For  $s_u$ , 14 methods were utilized—6 from the CPT-based workflow, 5 from the DMT-based workflow, and 3 from the  $V_s$ -based workflow. Regarding  $G_0$ , 13 methods were applied: 10 from CPT, 2 from DMT, and 1 from  $V_s$  measurements. The details of all applied methods are presented in Tables 1 and 3–5 of Marzouk and Tschuchnigg (2025b).

Estimating the unit weight early in module 1 is essential, as it is required for calculating intermediate CPT and DMT parameters that rely on stress-dependent inputs. Consequently, an initial unit weight must be defined at this stage. This value can be specified using either empirical correlations or reference data. In this study, the initial unit weight for both the CPT- and  $V_s$ -based workflows was estimated using the method proposed by Mayne et al. (2023), whereas for the DMT-based workflow, it was derived from Marchetti’s chart (Marchetti and Crapps, 1981).

### 3.3 Results

The in-situ tests considered in this study are illustrated in Figure 2. Three piezocone penetration tests (CPTu) (Figures 2(a–c)), one dilatometer test (DMT) (Figure 2(d)), and shear wave velocity ( $V_s$ ) measurements (Figure 2(e)) were used as input for the APD framework. For improved visualization of the soft Ballina clay layers, Figure 2(a) has been clipped at 3 MPa. Soil parameters were evaluated using the methods described in the previous subsection. Additionally, the three CPTu soundings served as input for the ML models developed to predict the soil parameters (see Section 2).

APD computes soil parameters generally based on layers and supports various stratification approaches. These include built-in stratification algorithms, external sources (e.g., CPT interpretation software), machine learning (ML) models, and manual layering. In this study, manual layering was adopted: the in-situ measurements were averaged every 40 cm to generate thin layers, facilitating a detailed comparison with the reference values.

Figure 3 presents the comparison between ML and the APD-derived parameters—computed using the methods described in the previous subsection and the benchmark values interpreted at the Ballina clay site. The shaded bands in blue, green, red, and grey represent the value ranges obtained from the CPT, DMT, shear wave velocity ( $V_s$ ) workflows, and ML predictions, respectively. For the blue ranges (representing the output of the CPT-based workflow), the shaded bandwidth reflects not only the variation among different methods but also the variability

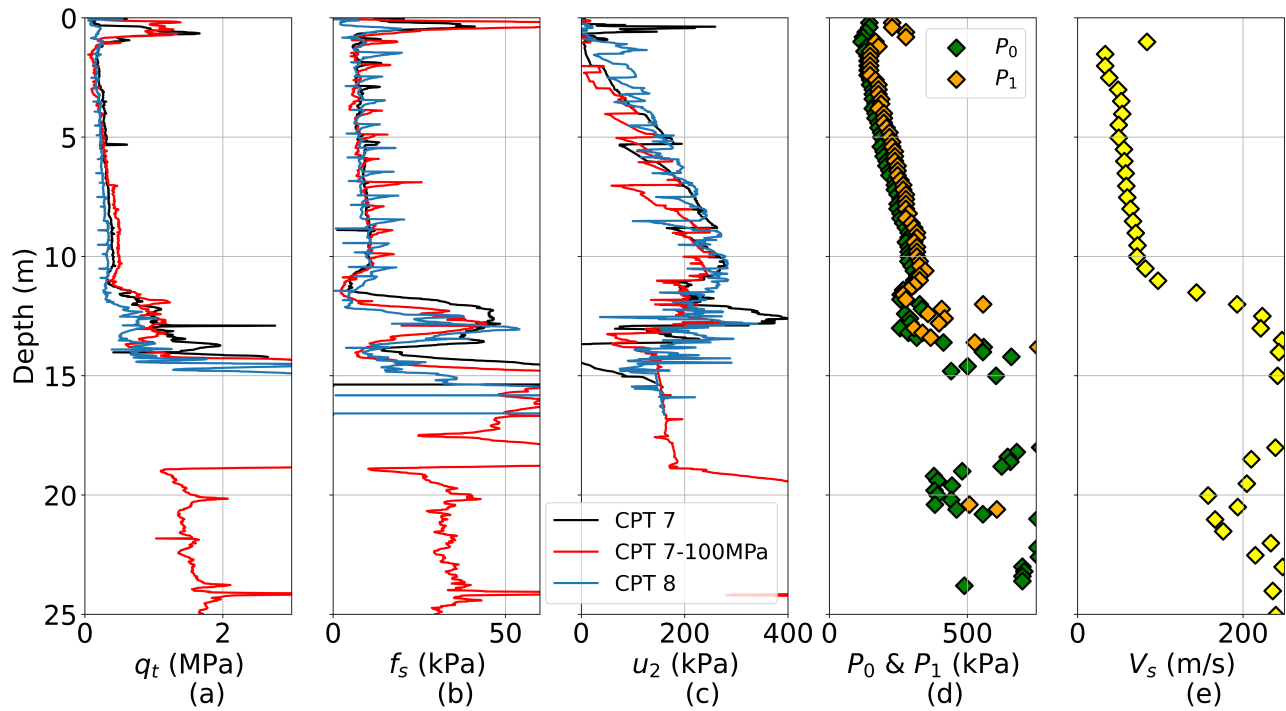


Figure 2: In-situ tests considered in this study, (a–c): CPTu results (profiles of  $q_t$ ,  $f_s$  and  $u_2$ ); (d): DMT results ( $P_0$  and  $P_1$ ); (e):  $V_s$ .

between the three CPT soundings used as input (see Figure 2). The same applies to the grey ranges (output of the ML model), as the same three soundings were used as input. The solid lines with circular markers denote the corresponding mean values, plotted at the mid-depths of the respective thin layers.

Figure 3a presents the results for the unit weight. The reference values were obtained from two continuous boreholes (Inclo 2 and Mex 9). At the top and bottom of the profile, the average values derived from the CPT, DMT,  $V_s$ , and ML workflows tend to underestimate the reference values. Between depths of approximately 2.5 and 10 m, the average values generally provide reasonable agreement with the reference data. However, the ML-based values slightly overestimate the reference unit weights in the depth range of 7 to 10 m.

Figure 3b shows the results for the undrained shear strength ( $s_u$ ). Reference values are obtained from triaxial compression tests (Inclo 2 and Mex 9) and triaxial extension tests (Mex 9 Ext). The average values from the  $V_s$ -based workflow closely match the reference values from the extension tests. Meanwhile, the CPT and DMT-based workflows align reasonably well with the compression test data. The ML-based values tend to overestimate  $s_u$  at the top of the profile, but show improved agreement with depth, particularly aligning with the compression test results.

Figure 3c presents the results for  $G_0$ . The reference values were derived from the seismic dilatometer test (SDMT 8) conducted at the site, which also provided the shear wave velocity profile used as input for the  $V_s$ -based workflow. As a result, the  $V_s$ -based workflow aligns

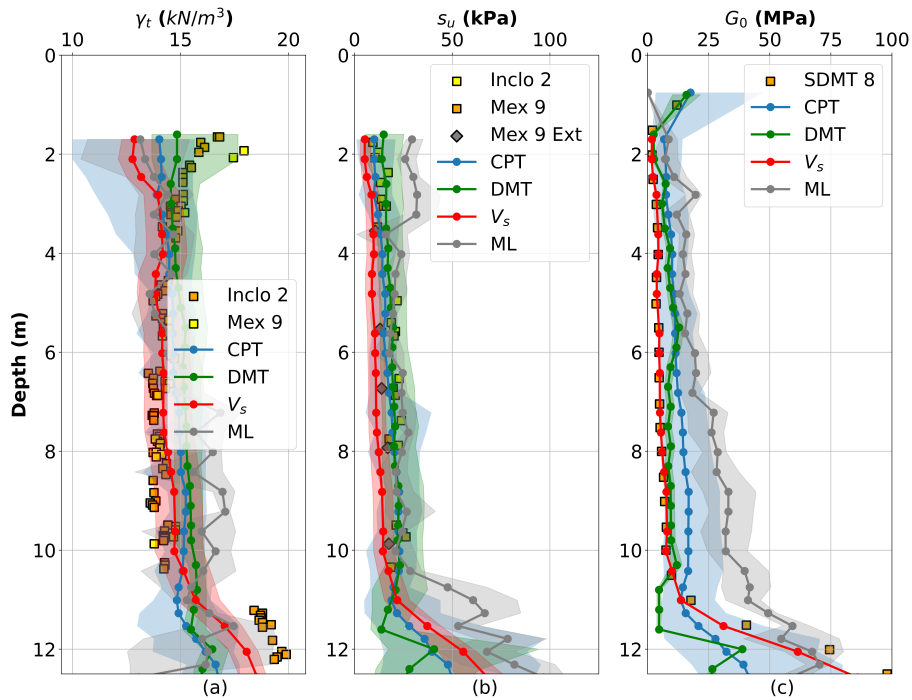


Figure 3: Comparison between APD and interpreted values at Ballina clay test site (the blue, green, red, and grey shaded areas represent the range of values obtained from the CPT, DMT,  $V_s$  workflows and ML, respectively): (a) unit weight, (b) undrained shear strength, (c) small-strain stiffness.

of course perfectly with the reference profile. Due to the use of ten different methods, the CPT-based workflow exhibits the largest spread, as reflected by the wide shaded band. The average value of this distribution tends to overestimate the reference values in the upper layers, while underestimating them toward the bottom. A similar trend is observed for the DMT-based workflow. The ML predictions, on the other hand, significantly overestimate the reference values throughout most of the profile, but show improved agreement at the bottom of the layer. A comparable overestimation by the ML approach for clays is also reported in Felić et al. (2025), which might be attributed to the under-representation of clay sites in the training database.

## 4 Conclusion and Outlook

APD is a parameter determination tool that utilizes a graph-based approach to derive soil and constitutive model parameters from in-situ test data. At the early stages of geotechnical projects—when soil data is limited—the tool supports early site characterization by providing detailed insights. Its purpose is not to replace laboratory testing, but rather to complement it, as laboratory results remain essential for the final design.

In this study, APD was applied using its three core workflows—CPT, DMT, and  $V_s$  measu-

rements—at a testing facility in Australia. Additionally, the study explored the potential of incorporating data-driven approaches as an alternative source for parameter estimation. The findings indicate that key soil parameters can be reasonably estimated using all four approaches, although some methods tend to under- or overestimate the reference values which might indicate that both, the validity of implemented correlations and the structure of the database for the ML approach requires some refinement.

Ongoing research aims to enhance the accuracy of the framework through statistical evaluation of the computed values and the inclusion of additional in-situ tests. Furthermore, efforts are underway to improve the machine learning models by expanding the training database to cover a broader range of parameters and soil types.

## Data repository

The GitHub repository for the machine learning approach is available here: <https://github.com/harifel/SmartGeotec2025>

## References

- [1] Deisenroth M. P., Ong C. S., and Faisal A. A. (2021): *Mathematics for machine learning*. Cambridge University Press.
- [2] Doherty J. P., Gourvenec S., Gaone F. M., Pineda J. A., Kelly R., O’Loughlin C. D., Cassidy M. J., Sloan S. W. (2018): A novel web-based application for storing, managing and sharing geotechnical data, illustrated using the national soft soil field testing facility in Ballina, Australia. *Computers and Geotechnics*, 93, 3–8. <https://doi.org/10.1080/17499518.2021.1896005>
- [3] Felić H., Marzouk I., Peterstorfer T., Tschuchnigg F. (2024): Data-driven site characterization – Focus on small-strain stiffness. In: Arroyo M., Gens A. (Eds.), *7th ISC – Ground models, from big data to engineering judgment*. <https://doi.org/10.23967/isc.2024.148>
- [4] Felić H., Marzouk I., Tschuchnigg F. (2025): A data-driven approach for soil parameter determination using supervised machine learning. *Proceedings of the 9th International Symposium on Geotechnical Safety and Risk (ISGSR 2025)*, accepted, not yet published.
- [5] Gansner E. R. (2011): Drawing graphs with Graphviz. *AT&T Bell Laboratories*.
- [6] Kelly R. B., Pineda J. A., Bates L., Suwal L. P., Fitzallen A. (2017): Site characterisation for the Ballina field testing facility. *Géotechnique*, 67(4), 279–300. <https://doi.org/10.1016/j.compgeo.2017.05.007>

- [7] Kulhawy F. H., Mayne P. W. (1990): *Manual on Estimating Soil Properties for Foundation Design*. Electric Power Research Inst., Palo Alto, CA (USA); Cornell Univ., Ithaca, NY (USA).
- [8] Lengkeek H. J., Breedevelde J. (2022): Eemdijk full-scale test on dike reinforced by sheet pile. *Dataset*, <https://doi.org/10.4121/19213890.v1>
- [9] Marchetti S., Crapps D. K. (1981): *Flat Dilatometer Manual*.
- [10] Marzouk I., Tschuchnigg F. (2025b): Bridging in situ testing and constitutive modelling: An automated approach to soil parameter identification. *Applied Sciences*, 15(13), Article 7224. DOI:10.3390/app15137224
- [11] Marzouk I., Oberhollenzer S., Tschuchnigg F. (2023b): An automated system for determining soil parameters: Case study. In: *Proc. 8th Int. Symp. on Deformation Characteristics of Geomaterials, Porto*. <https://doi.org/10.1051/e3sconf/202454404002>
- [12] Marzouk I., Tschuchnigg F., Brinkgreve R. B. J. (2023a): Expansion of an automated system for determining soil parameters using in-situ tests. In: *Proc. 10th European Conf. on Numerical Methods in Geotechnical Engineering (NUMGE 2023), London*. <https://doi.org/10.53243/NUMGE2023-70>
- [13] Marzouk I., Brinkgreve R. B. J., Lengkeek H. J., Tschuchnigg F. (2024): APD: An automated parameter determination system based on in-situ tests. *Computers and Geotechnics*, 176, 106799. <https://doi.org/10.1016/j.compgeo.2024.106799>
- [14] Marzouk I., Wijaya A. E., Schweiger H. F., Tschuchnigg F. (2025a): An automated system for determining soil parameters from in situ tests: Application to a sand site. *AIMS Geosciences*, 11(2), 489–516. <https://doi.org/10.3934/geosci.2025020>
- [15] Mayne P. W., Cargil E., Greig J. (2023): *A CPT Design Parameter Manual*. ConeTec Group.
- [16] Oberhollenzer S., Premstaller M., Marte R., Tschuchnigg F., Erharter G. H., Marcher T. (2021): Cone penetration test dataset Premstaller Geotechnik. *Data in Brief*, 34. <https://doi.org/10.1016/j.dib.2020.106618>
- [17] Pineda J. A., Suwal L. P., Kelly R. B., Bates L., Sloan S. W. (2016): Characterisation of Ballina clay. *Géotechnique*, 66(7), 556–577. <https://doi.org/10.1680/jgeot.15.P.181>
- [18] Scott J. W., van Ballegooy S., Stannard M., Lacrosse V., et al. (2015): The Benefits and Opportunities of a Shared Geotechnical Database. In: Cubrinovski M. (Ed.), *6th International Conference on Earthquake Geotechnical Engineering*.
- [19] Van Berkom I. E., Brinkgreve R. B. J., Lengkeek H. J., de Jong A. K. (2022): An automated system to determine constitutive model parameters from in situ tests. In: *Proc. 20th Int. Conf. on Soil Mechanics and Geotechnical Engineering, Sydney 2021*.

- [20] Yu H. S. (1998): CASM: A unified state parameter model for clay and sand. *International Journal for Numerical and Analytical Methods in Geomechanics*, 22(8), 621–653. [https://doi.org/10.1002/\(SICI\)1096-9853\(199808\)22:8<1t;621::AID-NAG937>3.0.CO;2-8](https://doi.org/10.1002/(SICI)1096-9853(199808)22:8<1t;621::AID-NAG937>3.0.CO;2-8)

## Author

Dipl.-Ing. Islam Marzouk  
Graz University of Technology  
Institute of Soil Mechanics, Foundation Engineering and Computational Geotechnics  
Rechbauerstraße 12  
8010 Graz, Austria  
Tel.: +43 316 873-6728  
e-mail: islam.marzouk@tugraz.at

Dipl.-Ing. Dipl.-Ing. Haris Felić  
Graz University of Technology  
Institute of Soil Mechanics, Foundation Engineering and Computational Geotechnics  
Rechbauerstraße 12  
8010 Graz, Austria  
Tel.: +43 316 873-6229  
e-mail: h.felic@tugraz.at

Univ.-Prof. Dipl.-Ing. Dr.techn. Franz Tschuchnigg  
Head of Institute  
Graz University of Technology  
Institute of Soil Mechanics, Foundation Engineering and Computational Geotechnics  
Rechbauerstraße 12  
8010 Graz, Austria  
Tel.: +43 316 873-6729  
e-mail: franz.tschuchnigg@tugraz.at

Assoc.-Prof. Dr.ir. Ronald Brinkgreve  
Delft University of Technology  
Department of Geo-Sciences & Engineering, Geo-engineering Section  
Stevinweg 1  
2628 CN Delft, The Netherlands  
Tel.: +31 15 27 83327  
e-mail: R.B.J.Brinkgreve@tudelft.nl

# **AI watches us build – tracking the construction process with smart algorithms**

**Dipl.-Ing. Marcus Daubner**

**Abstract:** The optimization of processes is a main focus of every industry and a guarantee for economic work. In the construction industry, the analysis of the construction process is mainly based on manual and usually time-limited recording.

This article describes the automated recording of construction processes by evaluating machine sensor data and AI interpreted image information.

## **1 Situation of process recording in the construction environment**

In recent years, construction sites have largely been executed in offline mode. This era was characterized by a lack of sensor technology and predominantly manual process time recording. The recording of data was generally limited to short time windows of one to three weeks and mainly took place when major disruptions occurred or for documentation purposes for claims.

Normally, trainees and students were used to collect data. Today, however, digital methods make it possible to automate this data collection to a greater extent.

By connecting construction sites to the IT infrastructure, the fundamentals of construction projects are changing deeply. The consideration of construction sites - similar to stationary plant facilities - allows the adoption of proven methods of process optimization from other industries. Concepts that have been successfully applied in the manufacturing industry can now be adapted to construction projects with a manageable amount of effort.

Construction sites are no longer isolated units, but an integral part of a digital ecosystem. This not only opens up the possibility of monitoring the construction process in real time, but also allows precise analysis and subsequent optimization of processes.

## **2 A question of perspective**

The fundamental question is which process should be recorded.

The perspective of mechanical engineers tends to limit process analysis to the manufacturing process of the device unit and thus focus solely on the machine production process.

In contrast, the specialist civil engineering perspective is characterized by a broader perspective. Here, the main focus is on the holistic recording of all sub-processes that are required to construct a specific component, a structure or the entire building.

Within this context, we differentiate between four process views:

- **Equipment production process:** This perspective focuses on the processes that are directly linked to the operation and functionality of the rig itself. Of course there is a connection to the constructed element, but the equipment production process is in the focus.
- **Individual element production process:** This focuses on the construction process of an individual structural element. Its creation usually requires several construction machines and various manual process steps that run in parallel.
- **Trade production process:** This perspective highlights the processes required for the production of a trade, i.e. the sum of the individual elements of a trade.
- **Overall building construction process:** The holistic view of the overall process of building construction requires comprehensive documentation of all sub-steps in order to enable precise analysis at the highest level.

Although this distinction may seem obvious, this understanding is of central importance. Both for the recording process and for the subsequent analysis objectives based on it.

## **3 Approach to digitally supported process recording in the context of specialist foundation engineering**

The construction process in specialist civil engineering is characterized by an extremely high degree of use of construction equipment. These rigs are equipped with a large number of sensors and allow for the current status of the devices to be mapped. These include sensors for

measuring depth, speed and position. The combination of this specific sensor information enables the identification of certain operating states of a device and derived from this, the executed process step. These operating states can be analyzed in different ways. On the one hand, rule-based analytical methods can be used, while the use of AI systems is also a promising approach [1,2].

Despite the use of drilling rig sensor technology, however, the clear mapping of each process step remains a challenge, as waiting times due to missing accompanying equipment or planned idle times, for example, cannot be differentiated by the sensor technology installed in the rig.

In order to eliminate this imprecision in the process recording, a combination of different information sources and recording methods is a good solution. This combination enables the generation of a more precise picture of the construction process than would be possible by using a single source of information alone.

- Use of additional sensor technology: The integration of additional sensors can help to document aspects of the construction process that have not yet been recorded and thus increase the completeness of the recorded information.
- Use of the documentation required for the quality process of a construction site: Information that is relevant to the quality process often also contains information that describes the process and thus supplements the process picture.
- Manual recording of work steps: Manual recording of individual work steps through targeted observation is a valuable source of information for comprehensive documentation of the construction process and should always be considered as a supplement.

Use of image analysis with AI: In cases where sensory recording cannot be implemented or only with great effort, the use of image-supported AI systems now represents another recording method.

## **4 Digital process recording using the example of Vienna Metro**

Various data collection systems were used on the Vienna Metro construction site for process recording. Bauer Spezialtiefbau worked together with two start-ups. Fielddata.io (now Bauer Maschinen GmbH) for device sensor evaluation of the rigs and about GmbH for image recognition.

Specifically, the sensor data from the drilling rig [Fig. 1] was sent to the startup fielddata.io every second and evaluated and graphically processed on its platform.



Figure1: Bauer drilling rig with data logger and DTR telematics system

The startup about GmbH provided two camera systems, among other things. One was a camera with a data logger and its own sensors. This unit was installed in the driver's cab, facing the operator's line of sight [2]. On the other hand, stationary, commercially available construction monitoring cameras were used for the higher-level observation of the construction processes Figure [3]. These surveillance cameras depicted the construction site, which was not in the field of vision of the rig operator.



Figure 2 left: Camera with data logger and sensors in the driver's cab of the drilling rig  
Figure 3 right: Stationary construction site monitoring camera

The cameras sent an image every minute, which was then analyzed on the about GmbH platform by using image recognition algorithms and evaluated according to the relevant process steps of specialist civil engineering.

This image analysis is carried out in accordance with the General Data Protection Regulation. The people in the image are grayed out by the camera before the image is sent and thus made unrecognizable. See image [4]. It is no longer possible to subsequently identify the persons.



Figure 4: Evaluated image material after processing by the AI

The list of activities determined in this way was transferred by about GmbH to fielddata.io, which merged these activities and visualized them uniformly for the construction site personnel on their portal Figure [5].

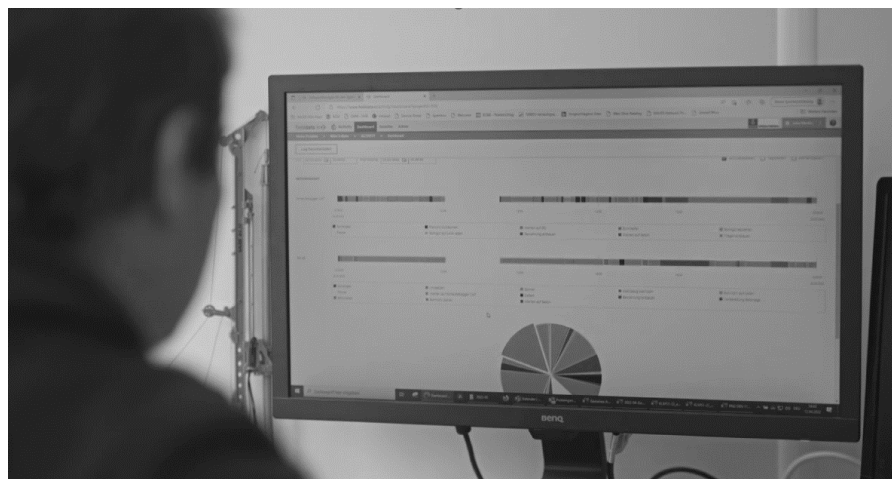


Figure 5: Portal of fielddata.io with the graphical preparation of the process steps

At the same time, the activities were recorded manually by a master student using the "Activity" software from [fielddata.io](https://fielddata.io) to validate the automatically recorded processes. This data was also visualized as a timeline on the [fielddata.io](https://fielddata.io) portal. This reference timeline made it possible to check the automated recording and identify inadequate interpretations of the algorithms.

## 5 Conclusion

The bundling of the various recording sources in one portal gives the site management the opportunity to have process steps made available immediately in processed form. The evaluation takes place both as a timeline in which the activity sequences are visualized. Alternatively, the data can also be displayed as a pie chart or as a list for subsequent, project-specific evaluations. The process figures prepared in this way show the influence of the disturbance variables and visualize the need for action for site management.

It has been demonstrated that frequently recurring construction processes can be recorded with a good hit rate. Disturbed construction processes, on the other hand, represent an effort for AI training that should not be underestimated, and which significantly influences the accuracy of the results.

This raises the question of which accuracies the automated detection must realistically map. Can an incorrect detection of a few minutes be tolerated in a 24-hour observation period or do these outliers lead to misinterpretations and thus to incorrect decisions? Or do the advantages of permanent process recording from the first minute of construction, which makes it possible to provide retrospective evaluations, outweigh the disadvantages?

In the course of the projects, the automated recording of the manufacturing process of an element or a trade turned out to be too complex for our initial implementation steps. The local assignment of a process recorded at multiple locations was a major challenge, especially when individual cameras could only capture sub-processes due to a limited field of view.

The granular recording of the rig process, on the other hand, showed sufficiently reliable results in process recording.

## 6 Outlook

Up to now, decisions in the event of disruptions to the construction process have been based on the experience of the responsible personnel. Due to the shortage of skilled workers, there are already gaps and a need for action. The automated recording of all process steps required for the production of a specialist civil engineering element will make it possible in future to digitally document more than just the production process. It will also be possible to automatically identify the causes of inefficiencies and anticipate delays in the construction process.

If, in addition to professional experience, a well-founded and defined database can also be used, then the decision-making process is no longer based solely on the gut feeling of employees but can be qualitatively substantiated.

A long-term vision is a data-driven system that is able to make forecasts and optimization recommendations for those involved in the project. Similar to a navigation system for the right route, a navigation system for the construction site could provide decision-making aids for the optimal construction site processes. Such a simplified decision-making process would not only benefit the site manager and site personnel, but also the customer thanks to the efficient handling of the construction task.

## References

- [1] Young-Jun Park und Chang-Yong Yi (2024): Time of Flight Distance Sensor–Based Construction Equipment Activity Detection Method. Kyungpook National University, Republic of Korea, <https://doi.org/10.3390/app14072859>
- [2] Xander Kupers, Jeroen Klein Brinke , Rob Bemthuis (2025): Towards Edge-Based Idle State Detection in Construction Machinery Using Surveillance Cameras. *University of Twente, Enschede, Netherlands*, <https://arxiv.org/pdf/2506.00904>

## Author

Dipl.-Ing. Marcus Daubner  
BAUER Spezialtiefbau GmbH  
Bauerstr.1  
86529 Schrobenhausen  
email: [marcus.daubner@bauer.de](mailto:marcus.daubner@bauer.de)  
Web: [www.bauer.de](http://www.bauer.de)



# Automatisierung und KI im maschinellen Tunnelbau: Entwicklungen und Perspektiven

Frederic Seng, Lasse Klein, Herrenknecht AG, Schwanau

**Abstract:** Der mechanisierte Tunnelbau spielt eine entscheidende Rolle bei der Realisierung moderner, nachhaltiger Infrastrukturen in urbanen und interregionalen Gebieten. Großprojekte wie der Brenner-Basistunnel verdeutlichen die strategische Bedeutung unterirdischer Verkehrswege. Gleichzeitig steht die Branche vor Herausforderungen wie Fachkräftemangel, steigenden Sicherheitsanforderungen und komplexen geologischen Bedingungen. Neue technologische Ansätze, insbesondere Automatisierung und künstliche Intelligenz (KI), gewinnen daher zunehmend an Bedeutung. KI-gestützte Systeme ermöglichen genauere Vorhersagen, optimierte Bohrprozesse und vorausschauende Wartung. Automatisierung erhöht die Effizienz, Sicherheit und Reproduzierbarkeit. Diese Entwicklungen markieren einen Paradigmenwechsel im Tunnelbau. Der Artikel beleuchtet aktuelle Fortschritte, Potenziale und Herausforderungen.

## 1 Einleitung

Der Tunnelbau spielt eine zentrale Rolle in der Entwicklung moderner Infrastrukturen. Ob im urbanen Nahverkehr, bei Hochgeschwindigkeitsbahnstrecken oder im Bereich der Energieversorgung – unterirdische Bauwerke ermöglichen effiziente, platzsparende und nachhaltige Lösungen für wachsende Mobilitäts- und Versorgungsbedarfe. Angesichts zunehmender Urbanisierung, steigender Anforderungen an Umwelt- und Ressourcenschutz sowie wachsender Komplexität der Projekte gewinnt der maschinelle Tunnelbau zunehmend an Bedeutung.

Großprojekte wie beispielsweise der Brenner Basistunnel oder die Hochgeschwindigkeit-Eisenbahnverbindung Lyon-Turin verdeutlichen die strategische Bedeutung unterirdischer Verkehrswege für Europa; vgl. European Climate, Infrastructure and Environment Executive Agency (2024) und European Climate, Infrastructure and Environment Executive Agency (2021).

Gleichzeitig steht die Branche vor tiefgreifenden Herausforderungen: Fachkräftemangel, steigende Sicherheitsanforderungen, komplexe geologische Bedingungen und wachsender Kostendruck erfordern neue technologische Ansätze. In diesem Kontext gewinnt die Automatisierung und die Datenwissenschaften mit u. A. der künstlichen Intelligenz (KI) zunehmend an Bedeutung. Neue Automatisierungs-Entwicklungen ermöglichen es, Prozesse im Tunnelbau nicht nur effizienter, sondern auch sicherer und nachhaltiger zu gestalten. KI-gestützte Systeme können geologische Bedingungen besser vorhersagen, Bohrparameter in Echtzeit optimieren und Wartungsbedarfe frühzeitig erkennen. Automatisierung wiederum reduziert manuelle Eingriffe und erhöht die Reproduzierbarkeit komplexer Abläufe.

Diese Entwicklungen markieren jedoch auch einen Paradigmenwechsel im maschinellen Tunnelbau.

Der vorliegende Beitrag basiert größtenteils auf einer Zusammenstellung aus bestehenden Veröffentlichungen zum Thema Automatisierung und Data Science im Tunnelbau. Deshalb ist es Ziel dieses Artikels aus Maschinenherstellerperspektive einen kurzen Einblick in ausgewählte Entwicklungen im Bereich der Automatisierung und KI im maschinellen Tunnelbau zu geben, Potenziale und Herausforderungen zu beleuchten und einen Ausblick auf Chancen und zukünftige Perspektiven zu geben.

## 2 Grundlagen

### 2.1 Automatisierung

Im Bereich von Tunnelvortriebsmaschinen (TVM) bezeichnet Automatisierung die Integration von Technologien und Systemen, die manuelle Eingriffe reduzieren oder vollständig ersetzen, um den Vortrieb effizienter, sicherer und in höherer, konstanter Qualität zu gestalten. Als industrieller Prozess bietet der maschinelle Tunnelvortrieb grundsätzlich gute Voraussetzungen für eine Automatisierung wie von Wehrmeyer et al. (2024) beschrieben. Für die Arbeitsabläufe im Bereich der TBM werden darin derzeit zwei Entwicklungsschwerpunkte unterschieden:

1. Bedienerunterstützende Systeme, oder sogenannte Assistenzsysteme
2. Automatisierte (Teil-)Systeme

Bedienerunterstützende Systeme zielen darauf ab, wiederkehrende Arbeitsabläufe teilweise zu automatisieren. Damit wird zum einen der Bediener entlastet. Zum anderen bietet sich die Chance, Fehlbedienungen zu vermeiden und eine Interpretationshilfe für den jeweiligen Betriebszustand des Teilsystems zu integrieren. Einige exemplarische von Herrenknecht entwickelte Beispiele sind:

- Die Steuerung der Vortriebsmaschine mit Darstellung des Druckschwerpunkts der Vortriebszylinder als Center of Thrust (CoT) und Nutzung desselben als Steuergröße
- Die bedarfsgerechte Befüllung der Dichtkammern der Schildschwanzdichtung (Adaptive Tailskin Sealing System)
- Die systematische Konvergenz- oder Überschmittmessung mit aus dem Schild ausfahrbaren Hydraulikzylindern, die mit fortschreitendem Vortrieb mehrfach den gleichen Punkt der Tunnellaibung messen und so eine mögliche Veränderung des gebohrten Tunneldurchmessers ermitteln
- Die automatische Steuerung der Staffelpumpen im hydraulischen Förderkreislauf sowie die automatische Richtungssteuerung der Nachläuferfahrwerke.

Der Einsatz automatisierter (Teil-)Systeme bietet insbesondere bei wiederkehrenden Tätigkeiten im TBM-Vortrieb große Potenziale. Beispiele sind der Einbau der Tübbinge, die Versorgung mit Tübbingen und Verbrauchsmaterialien, der Abtransport des Ausbruchsmaterials und die Wartung der Geräte.

- Historische Entwicklung
- Aktuelle Technologien (z. B. automatische Steuerung, Sensorik, Robotik)
- Beispiele aus der Praxis

## 2.2 Data Science und Künstliche Intelligenz (KI)

Di Benedetto et al. (2024) beschreibt die Data Science (DS) als einen Sammelbegriff, der Aspekte verschiedener Disziplinen wie ML, KI, Datenanalyse, Statistik, Informatik, Programmierung, Cloud Computing, Mathematik und deren Varianten umfasst. Im weitesten Sinne zielt die Data Science darauf ab, aus typischerweise großen Datensätzen Wissen zu generieren. Für zahlreiche Unternehmen ist es aufgrund des rasanten technologischen Fortschritts im 21. Jahrhundert unerlässlich geworden, zunächst in die Beschaffung von Daten zu investieren, um anschließend mithilfe von DS aus den gesammelten Informationen Wert zu generieren. Dieser Wert kann sich auf eine Vielzahl von Lösungen beziehen, beispielsweise auf digitale Dienste und Produkte bis hin zur Bereitstellung von Einblicken in Prozesse und Abläufe. Die Qualität der Daten hat jedoch einen entscheidenden Einfluss auf die Ergebnisse eines DS-Algorithmus. Daher ist die Schaffung einer robusten und zuverlässigen Informationsbasis ein wesentlicher Aspekt, um die Vorteile dieser Technologie nutzen zu können.

Im Tunnelbau muss die Dateninfrastruktur die riesigen Informationsmengen, die während eines Bauprojekts anfallen, erfolgreich verarbeiten. Nehmen wir als Beispiel eine TBM mit 2000 Sensoren, die jede Sekunde Daten in eine Datenbank schreiben. Über ein Jahr hinweg fallen so Zeitreihendaten mit einem Gesamtvolumen von mehr als 200 GB an.

Da die Informationsmenge zu groß ist, um von Statistikern einzeln analysiert zu werden, kommt DS ins Spiel.

Von Datenwissenschaftlern implementierte KI-Algorithmen können riesige Datenmengen – sogar in Echtzeit – verarbeiten, um Lösungen zur Verbesserung der Geschäftsleistung zu entwickeln. Die Stärke dieser Algorithmen liegt darin, dass sie Muster in hochdimensionalen Daten erkennen, die für den Menschen nicht wahrnehmbar sind. Prominente branchenübergreifende Anwendungsbereiche sind „Anomalieerkennung“, „vorausschauende Wartung“ und „Restlebensdauer“. Diese Lösungen helfen der Tunnelbauindustrie, Betriebskosten und den Energieverbrauch zu senken, ihre Leistung zu verbessern, intelligentere Entscheidungen zu treffen, ihr Geschäftswachstum zu steigern und vieles mehr.

Obwohl noch nicht vollständig verbreitet, nimmt der Einsatz von DS-Anwendungen in TBMs aufgrund der oben genannten Vorteile stetig zu.

## 3 Aktuelle Entwicklungsbeispiele

### 3.1 Automatisierung in Tunnelbohrmaschinen (TBMs)

#### 3.1.1 Tübbinghandling

Gemäß Wehrmeyer et al. (2024) ist der am häufigsten wiederkehrende Vorgang im maschinellen Schildvortrieb der Transport und Einbau der Tübbinge. Daher ist der Ansatz zur Automatisierung dieser Prozessschritte sowohl aus wirtschaftlichen wie auch aus Sicherheitsgründen in den Fokus gerückt. Gerade bei langen Tunneln mit entsprechend vielen Tübbingen kann sich eine Investition in vollautomatische oder bedienerunterstützende Systeme lohnen.

Vollautomatische Teilsysteme können alle Vorgänge des Tübbinghandlings, vom Entladen des Transportfahrzeugs bis zum Aufnehmen des Tübbings durch den Erektor und den Ringbau selbst, umfassen (Abbildung 1). Für die Einführung automatisierter Umschlagsysteme

müssen die Tübbinge, die Ladekonfiguration und der Tübbingstapel auf dem Lieferfahrzeug für die Automatisierung geeignet sein.




Abbildung 1: Automatisierter Tübbingumschlag im Nachläufer; Quelle: Herrenknecht AG

Während es sich bei den Tübbingen um hochpräzise Bauteile handelt, die bereits mit Hilfsmitteln wie Barcodes zur automatischen Identifizierung ausgestattet sind, erhöhen sich durch die Automatisierung die Anforderungen an die geometrische Genauigkeit der Stapel, der Stapelhölzer und der Stapelposition auf dem Versorgungsfahrzeug. Das Greifsystem für die Tübbingaufnahme durch einen Übergabekran oder Erektor kann kein manuelles Einschrauben von Tübbingspindeln mehr beinhalten und wird daher durch Vakuumheber oder andere Greifvorrichtungen realisiert. Unabhängig vom Tübbinghandling vor dem Tunnelportal hilft eine Sichtkontrolle der einzelnen Tübbinge auf der TBM beim Entladen und vor der Übergabe an den Erektor, die Effizienz der Prozesse zu optimieren. Die visuelle Kontrolle umfasst im Einzelnen die Prüfung auf Transportschäden, eine korrekte Positionierung der Tübbingdichtungen und anderer Einbauten sowie die Prüfung auf mögliche Verunreinigung der Oberfläche (durch Schmutz oder Eis/Schnee), die zu einer Fehlfunktion der Vakuumaufnahme führen können. Das Gesamtsystem eines automatisierten Tübbingumschlags umfasst ebenfalls automatisierte kameragestützte Inspektionssysteme, die sich für die Bildanalyse künstlicher Intelligenz bedienen, sowie eine präventive Reinigung der Tübbinginnenkontur. Je nach Tübbingdesign und den Vorbereitungsprozessen kann ein automatisierter Tübbingumschlag zudem eine automatische Dübelmontage umfassen. Auch bei einem vollautomatischen System muss es möglich sein, die Tübbinge sicher von Hand zu transportieren. Dazu gehört die Option, sie von ihrer Einbauposition im Schildschwanz zurück auf das Transportfahrzeug und schließlich aus dem Tunnel zu bringen. Mehrere TBM mit Durchmessern von 10 m wurden in den vergangenen Jahren mit automatisiertem Tübbinghandling im Nachläufer ausgeliefert und in Betrieb genommen.

### 3.1.2 Unterstützter und automatisierter Ringbau

#### Ringbauunterstützung

Für den Ringbauprozess können Sensortechnologien zusätzliche Informationen generieren, die entweder mit Signalsäulen nach dem Ampelprinzip direkt an der Erektorausgabplatte visua-

lisiert oder auf dem mobilen Erektortableau angezeigt werden, wie z. B. die Ringbauluft oder die relative Position des Segments zu seinen Nachbarsegmenten. Mit der Bereitstellung solcher Daten für den Erektorfahrer müssen keine manuellen Messungen von den Plattformen des Erektors mehr durchgeführt werden. Auf diese Weise können Sicherheitsrisiken beseitigt und die Anzahl der Mitarbeiter für den Ringbau reduziert werden.

### Automatischer Ringbau

Der nächste Schritt, der über die Bereitstellung von Informationen hinausgeht, ist der vollautomatische Ringbau. Der Ringbau beinhaltet die Handhabung schwerer Betonfertigteile in einem Bereich, der insbesondere bei kleinen TBM als beengter Arbeitsraum angesehen werden kann. Schwieriger Zugang und eingeschränkte Sicht sind typische Herausforderungen. Daher sind Sicherheitsaspekte neben Qualität und Wirtschaftlichkeit die wichtigsten Argumente für den automatisierten Ringbau, da dieser kein Personal erfordert. Die Hauptkomponente des zu automatisierenden Ringbausystems ist der Erektor. Wie bei allen Automatisierungsprozessen muss die genaue Position aller beteiligten Komponenten bekannt sein. Alle beweglichen Teile des Erektors, die Vortriebszylinder und der Tübbingzuführer sind deshalb mit Positionsmesssystemen auszurüsten. Für einen automatisierten Ringbauprozess ist nicht nur die exakte Position aller Erektorfunktionen und anderer beweglicher Teile, sondern auch die exakte Position und Ausrichtung der Segmente auf dem Tübbingzuführer erforderlich. Bei Verwendung von optischen Sensoren ist eine ungehinderte Sicht der Sensoren unerlässlich. Deshalb ist z. B. bei Reinigungs- und Wartungsarbeiten an den Verpressleitungen im Schildschwanz eine unnötige Verschmutzung der Sensoren zu vermeiden. Bei Herrenknecht in Schwanau wurden erste automatische Ringmontagesysteme für eine 3-Meter- und eine 8-Meter-Durchmesser-TBM entwickelt und mit Versuchsanordnungen in realer Größe getestet. Sobald automatisierte Systeme installiert werden, müssen physische Barrieren mit verriegelten Zugangstüren installiert werden, um den Zugang zum Bereich mit automatisierten Bewegungs- und/oder Handhabungsvorgängen auszuschließen. Solche Bereiche innerhalb des Nachläufers oder des Ringbaubereichs sind dann nur während des manuellen Betriebs oder zu Wartungszwecken zugänglich. Automatisierte Systeme haben somit Auswirkungen auf das Arbeitsumfeld und die Arbeitsabläufe. Automatisierte Systeme erfordern mehr Sensorik und computergesteuerte Kontrollsysteme. Insbesondere die rauen Umgebungsbedingungen in einem Tunnelvortrieb müssen bei der Auswahl und Auslegung der Komponenten berücksichtigt werden. Ebenso muss das Wartungspersonal vor Ort entsprechend qualifiziert werden.

## **3.2 Künstliche Intelligenz (KI)**

### **3.2.1 Geologieerkennung anhand von Maschinendaten und geotechnische Parameter**

Da die Geologie wesentlich die Parameter während des TBM-Vortriebs beeinflusst, ist gerade die Kenntnis der Untergrund-Veränderungen ein wesentlicher Optimierungsansatz im Zusammenhang mit dem Maschinenbetrieb.

Im Folgenden wird auf ein Anwendungsbeispiel eingegangen, das von Klein et al. (2024) im Rahmen der 1st International Rock Mass Classification Conference beschrieben wird.

Die Analyse von Maschinendaten in Verbindung mit geotechnischen Parametern ist in verschiedenen Anwendungsbereichen von entscheidender Bedeutung, unter anderem im Bauwesen, Bergbau und Tunnelbau. Beide werden im Folgenden näher beleuchtet:

#### Maschinendaten:

Maschinendaten sind aus der modernen Bau- und Bergbauindustrie nicht mehr wegzudenken. Sie beinhalten eine Vielzahl wichtiger Informationen, die von verschiedenen Geräten und

Maschinen erfasst werden. Diese Daten reichen von grundlegenden Messwerten wie Position und Geschwindigkeit bis hin zu komplexeren Details wie Vibrationen, Stromverbrauch und Hydraulikdruck und bieten einen umfassenden Überblick über die Leistung und Zustand verschiedenster Maschinen-Komponenten. Mit der Einführung fortschrittlicher TBMs, die mit Sensoren und Echtzeit-Datenerfassungsfunktionen ausgestattet sind, ist die Überwachung der Betriebsbedingungen immer effizienter geworden. Die Analyse von Maschinendaten liefert wertvolle Erkenntnisse über den Zustand, die Leistungseffizienz und die Produktivität der Maschine und ermöglicht es die Prozesse im laufenden Betrieb zu optimieren, Wartungsarbeiten proaktiv zu planen und die Sicherheitsmaßnahmen auf Baustellen zu verbessern.

#### Geotechnische Parameter:

Geotechnische Parameter sind die Grundlage, um den Untergrund, der für Bau- und Tunnelbauprojekte genutzt wird, einzuschätzen. Sie versuchen die vielfältigen physikalischen und mechanischen Eigenschaften von Locker- und Hartgestein zu beschreiben und in Form von Zahlen zu definieren. Diese Parameter, die von der Gesteinsart und -festigkeit bis hin zu den Grundwasserverhältnissen und Bruchereigenschaften reichen, spielen eine entscheidende Rolle bei der Beurteilung der Machbarkeit und Sicherheit von Ingenieurleistungen. Geotechnische Untersuchungen, die eine umfassende Reihe von Feldversuchen, Laboranalysen und numerischen Modellierungstechniken umfassen, sind für die Beurteilung des Boden- und Felsverhaltens von entscheidender Bedeutung. Darüber hinaus erleichtert der Einsatz von TBMs die Erfassung von Daten zur Gesteinserkennung und -klassifizierung und hilft so bei der Charakterisierung der während des Vortriebs angetroffenen Gesteinsmassen. Letztendlich ist ein tiefgreifendes Verständnis der geotechnischen Parameter unverzichtbar, um standfeste Bauwerke zu entwerfen, geeignete Vortriebsmethoden auszuwählen und Bodenbewegungen und Verformungen präzise vorherzusagen.

#### Vergleich und Integration:

Die Integration von Maschinendaten und geotechnischen Parametern stellt einen entscheidenden Fortschritt in der Bau- und Bergbaupraxis dar und bietet synergetische Vorteile für die Projektplanung, -ausführung und -überwachung. Durch die Kombination von Erkenntnissen aus der Überwachung von Vibrationsdaten und Hydraulikdrücken mit geotechnischen Parametern wie Gesteinsfestigkeit und -dichte können Bauteams in Echtzeit fundierte Entscheidungen treffen und so die Betriebseffizienz und -sicherheit verbessern. Darüber hinaus ermöglicht die Nutzung geotechnischer Daten für die Auswahl von Geräten, Betriebstechniken und Sicherheitsmaßnahmen proaktive Strategien zur Risikominderung bei instabilen Bodenverhältnissen. Des Weiteren erleichtert der Einsatz fortschrittlicher Technologien wie Geodatenkartierung, Fernerkundung und Algorithmen für maschinelles Lernen die nahtlose Korrelation und Analyse von Maschinendaten mit geotechnischen Parametern und ermöglicht so die prädiktive Modellierung und Optimierung von Bauprozessen für bessere Projektergebnisse. Veränderungen der Untergrundbedingungen können durch In-situ-Bodenüberwachung und Maschinendaten und deren Auswertung durch KI identifiziert werden (Abbildung 2).



Abbildung 2: Dargestellt ist der Übergang von weichem zu hartem Gestein von rechts nach links. Der Übergang markiert einen Wechsel der Gesteinseigenschaften und damit einhergehend eine Veränderung der Maschinendaten; Quelle: Herrenknecht AG

Abbildung 3 zeigt einen Übergang von weichem zu hartem Gestein (lila) und umgekehrt. Diese Übergänge spiegeln sich in den Maschinendaten wider und können mithilfe von KI erkannt werden. Das harte Gestein befindet sich zwischen den Ringnummern 120 und 235. Aufgrund der sich ändernden geotechnischen Parameter nimmt der Parameter „Eindringgeschwindigkeit“ beim Übergang von weichem zu hartem Gestein (Ringnummer 130) ab. Der Parameter „Vorschubkraft“ verhält sich genau umgekehrt. Nicht nur die Zahlen, sondern auch das Bild zeigen, dass es eine Verschiebung zwischen der Änderung der Maschinenparameter und der Änderung der prognostizierten Geologie gibt. Die mit solchen geotechnischen Informationen verbundenen Fehler können durch KI-basierte Maschinenparametererkennung und -interpretation weiter minimiert und aktualisiert werden.




Abbildung 3: Zustandsüberwachung und Vergleich mit Maschinendaten als Anwendungsbeispiel für die optimale Fortsetzung des Vortriebs unter sich verändernden Untergrundbedingungen; oberes Diagramm: Vortriebsgeschwindigkeit [mm/U]; unteres Diagramm: Vorschubkraft [kN]; Quelle: Herrenknecht AG

Zusammenfassend lässt sich sagen, dass das digitale Zeitalter einen Paradigmenwechsel in der Klassifizierung von Gebirgsmassen mit sich gebracht hat und eine neue Ära der Präzision, Effizienz und Sicherheit bei Tunnelbauprojekten in hartem Gestein eingeläutet hat. Durch die Nutzung der Leistungsfähigkeit digitaler Kartierungstechnologien, GIS-Integration, Algo-

rhythmen für maschinelles Lernen und Echtzeit-Überwachungssystemen können Ingenieure und Geologen nun genauere Bewertungen der Gebirgsbedingungen vornehmen, Risiken effektiv mindern und Bauprozesse optimieren, um den Anforderungen immer komplexerer Tunnelbauprojekte gerecht zu werden.

Insgesamt zeigen die Fortschritte bei den ML-Methoden zur Vorhersage und Optimierung der Leistungen im Tunnelbau die Machbarkeit datengesteuerter gemäß Di Benedetto et al. (2024) Ansätze für die Entwicklung intelligenterer TBMs. Es gibt jedoch noch Einschränkungen, die es zu überwinden gilt. Tatsächlich berücksichtigen die berichteten Beiträge in ihren Arbeiten nie die geologischen Bedingungen für die im vorangegangenen Abschnitt („Geologische Vorhersagen“) genannten Herausforderungen, und das entworfene Ziel berücksichtigt nur einige der im mechanisierten Tunnelbau verwendeten Parameter, wodurch die Komplexität der Vorgänge unterschätzt wird. Da die Modelle hauptsächlich an einem einzigen Tunnel getestet werden, ist es schließlich schwierig, die Eignung dieser Methoden für eine allgemeine Anwendung in mehreren Projekten abzuschätzen.

## 4 Herausforderungen und Chancen

### Domänenwissen

Für die Entwicklung datengesteuerter Lösungen ist ein tiefgreifendes Verständnis der komplexen Vorgänge im maschinellen Tunnelvortrieb von entscheidender Bedeutung. Ein übergreifendes Domänenwissen, mit fundierten Kenntnissen im mechanisierten Tunnelbau, geologischem Hintergrundwissen, umfassenden DS-Fähigkeiten und praktischer Einsatz Erfahrung ist besonders selten. So ist es nach Di Benedetto et al. (2014) vorteilhaft, wenn datengesteuerte Lösungen in der Regel in einem interdisziplinären Team aus mehreren Experten mit unterschiedlichen Hintergründen agil entwickelt werden. Datenwissenschaftler müssen eng mit den Fachleuten für die TBM-Komponenten zusammenarbeiten, die in der entwickelten Anwendung zum Einsatz kommen, und umgekehrt.

Galler et al. (2024) sieht dies auch im konventionellen Tunnelbau, wo die zukünftige Entwicklung an den Schnittstellen zwischen Informatik und den klassischen Disziplinen des Bau- und Umweltingenieurwesens stattfindet und damit Ingenieure mit einer starken interdisziplinären Ausbildung erfordert.

Eine Herausforderung dabei ist nach Di Benedetto et al. (2014) die Kommunikation zwischen den verschiedenen „Sprachen“, die Datenwissenschaftler, Ingenieure und Entwickler verwenden. Um dieses Problem zu mindern, ist eine intensive Vermittlung zwischen den Parteien empfehlenswert.

Um dem globalen Mangel an qualifizierten Wissenschaftlern, Ingenieuren und Fachkräften im Bereich des Tunnelbaus wirksam zu begegnen, ist der gezielte Ausbau von Kooperationen mit externen Partnern – etwa spezialisierten Forschungseinrichtungen, innovativen Start-ups oder Technologie- und Serviceanbietern – von zentraler Bedeutung. Solche Partnerschaften ermöglichen nicht nur den Zugang z.B. zu zusätzlicher datenanalytischer Expertise, sondern fördern auch den Transfer von branchenspezifischem Domänenwissen, das für die Entwicklung praxisnaher, digital gestützter Lösungen in komplexen Bauprojekten unerlässlich ist.

### Datengrundlage

Im Allgemeinen hängt die Leistungsfähigkeit von KI von der Qualität der Daten ab. Der Tunnelbau hat in Bezug auf diese Ressource ganz eigene Herausforderungen.

In Di Benedetto et al. (2024) wird grob zwischen drei Arten von Daten unterschieden:

i) Betriebsdaten – Dazu gehört das gesamte Sensorsystem, wie z. B. Hübe, Drücke, Spannungen, Geschwindigkeiten, Füllstände, Navigation und sogar Videos. Diese Daten lassen sich vergleichsweise gut verarbeiten, da die meisten Datensätze strukturiert gespeichert sind. In der Regel wird ein Zeitstempel für die Indizierung verwendet, und Zeitreihenanalysen können wertvolle Erkenntnisse über die Muster liefern, die während des Maschinenbetriebs auftreten. Der Wunsch einer maximalen (Kunden-)Individualisierung bringt jedoch auch Herausforderungen mit sich z.B. bei uneinheitlichen, nicht standardisierten Formaten und Benennungen bis hin zu einfachen Tippfehlern bei manueller Informationseingabe.

ii) Meta – Ohne zusätzliche Informationen können die reinen Betriebsdaten oft nicht ausgewertet werden. Zu diesen Metadaten gehören beispielsweise technische Unterlagen wie Zeichnungen oder Datenblätter. Diese Informationen werden in der Regel vom jeweiligen Hersteller zur Verfügung gestellt. Diese Daten werden noch sehr häufig in für Menschen lesbaren Formaten ausgetauscht und sind nicht maschinenlesbar. Folglich verwaltet jede DS-Anwendung die Parameter individuell, was zu einer Vielzahl von Daten und Redundanzen führt.

iii) Sekundär – Daten, die außerhalb des Anbieter-Einflussbereichs liegen, stellen die größte Herausforderung dar. Dies ist ein sehr breites Spektrum, das geotechnische Informationen, die DTA, Verträge, aber auch Baustellenberichte umfasst. Diese Daten werden strukturiert und/oder unstrukturiert gespeichert, und es gibt keine Kontrolle über Sprache, Form, Format, Einheiten, Koordinatensysteme usw..

Die oben genannten Herausforderungen lassen sich durch die Einführung eines Standards für eine einheitliche Datenerfassung mindern. Darüber hinaus sind zusätzliche Anstrengungen bei der Datensammlung – unter Einbeziehung des Personals vor Ort – erforderlich, um datenbasierte Lösungen im Tunnelbau flächendeckend einzusetzen.

Weitere Herausforderungen insbesondere für den Bereich der Datenwissenschaften sind im Folgenden nur stichpunktartig angeführt und können in Di Benedetto et al. (2024) nachgelesen werden:

- Daten-Vorverarbeitung
- Verallgemeinerung
- Bereitstellung

Daten bilden auch für Automatisierungslösungen die wesentliche Basis. So ist beispielsweise in Maidl & Maidl (2022) beschrieben: „Die Digitalisierung der Prozessdaten bildet die Grundlage für eine weitergehende Automatisierung der Abläufe im maschinellen Tunnelbau. Ziel ist es, durch kontinuierliche Datenerfassung und -auswertung die Steuerung der Vortriebsmaschine zu optimieren und perspektivisch autonome Vortriebsprozesse zu ermöglichen.“

Mostafa et al. (2024) stellt fest, dass die Automatisierung im Tunnelbau noch hinterherhinkt. Der Automatisierung des mechanisierten Tunnelbaus wird auch darin für die Zukunft eine entscheidende Bedeutung zugemessen, da die derzeitige Praxis noch stark von der Erfahrung und dem menschlichen Urteilsvermögen des Maschinenführers abhängt, der die TBM steuert, was zu unerwünschten Ereignissen führen kann. Dank der Fülle an Maschinendaten, die heute von TBMs zur Verfügung stehen, und den Fortschritten in den Bereichen Datenanalyse und

maschinelles Lernen (ML) wächst das Potenzial, den Tunnelbau zu revolutionieren, indem sie eine bessere Entscheidungsunterstützung bieten, einschließlich geologischer Vorhersagen und Anomalieerkennung. Durch die Hervorhebung dieser Herausforderungen will der Artikel von Mostafa et al. (2024) nicht nur kritisieren, sondern auch Orientierung bieten und Empfehlungen für zukünftige Forschungsarbeiten geben, die versprechen, die Lücken zu schließen und möglicherweise eine Ära vollautomatischer TBMs einzuläuten.

In der Publikation von Zhe Zheng et al. (2024) wird vor dem Hintergrund der Anforderungen an eine hohe Baueffizienz und -qualität von Tunneln eine systematische Untersuchung durchgeführt, um die autonome Lenksteuerung von TBM zu erörtern, die in der Praxis den Fahrer unterstützen oder ersetzen kann. Insgesamt bilden darin die umfangreichen multidimensionalen Felddaten eine gute Grundlage, sodass KI-basierte Methoden eine gängige Lösung darstellen. Dennoch behindert ihre Undurchsichtigkeit das Vertrauen in Vorhersagen und Entscheidungen in der praktischen Anwendung.

Zhe Zheng et al. (2024) geht von einer langen Übergangsphase aus, bis der Schildtunnelbau vollständig unbemannt erfolgen kann. Auch in dieser Arbeit wird den Fahrern eine wichtige Rolle, nicht nur als Aufseher zugesprochen, sondern als Kooperationspartner, um ihr globales Bewusstsein und ihr Vorwissen optimal zu nutzen. Offensichtlich ist die Kombination der Fähigkeiten von Menschen und autonomen Systemen entscheidend für die Bildung einer sicheren, stabilen, effizienten und harmonischen Mensch-Maschine-Zusammenarbeit in komplexen Szenarien. Folglich sind nicht nur intensive Forschung und Entwicklung für technologische Innovationen, sondern auch industrielle Erfahrungen für die autonome Lenksteuerung von TBM erforderlich.

Smith Kristina (2024) setzt sich in Ihrem Artikel mit der Keynote-Präsentation von Professor Mike Mooney der Colorado School of Mines im Rahmen der BTS Konferenz vom Oktober 2024 auseinander. Er sieht die Notwendigkeit für systematische oder strukturelle Veränderungen in der Arbeitsweise der Bauunternehmen hin zu datengetriebenen Entscheidungen.

Die Frage von Professor Colin Eddie, Geschäftsführer von CECL Global, ob TBM Operatoren Karriereberatung in Anspruch nehmen sollten beantwortet Mooney im Prinzip mit „Ja“. Mooney sieht zwei Trends, die diesen Wandel bereits vorantreiben: „Mit der Verbesserung der Informationsqualität und -quantität und der zunehmenden Automatisierung von TBM-Teilprozessen, beispielsweise Ringraumverpressung, Bodenaufbereitung, Segmentmontage und Steuerung, ist es an der Zeit, die nächste Generation datengesteuerter Ingenieure mit dem TBM-Betrieb zusammenzuführen, um eine Art TBM-Coach zu werden. Dies sei in anderen Branchen bereits gang und gäbe. Mit Blick auf die nicht allzu ferne Zukunft ist es seiner Ansicht nach möglich, eine Zeit zu sehen, in der die Automatisierung von Groß-TBMs weiterentwickelt wird und in Kombination mit maschinellem Lernen jene optimalen Betriebspunkte erreicht, die die Produktivität optimieren und Risiken reduzieren.“

## **5 Danksagung**

Die Autoren bedanken sich herzlich bei den Kolleginnen und Kollegen der Herrenknecht AG, die durch ihre wertvollen Beiträge in den angeführten Quellen einen wesentlichen Beitrag geleistet haben. Unser besonderer Dank gilt hierbei Herrn Stefan Mauerberger sowie Diego Di Benedetto, deren indirekte Mitarbeit wir sehr zu schätzen wissen.

## Literatur

- [1] Di Benedetto Diego, Mauerberger Stefan, Glueck Katharina, (2024): Data science in mechanised tunnelling, *Tunnels & Tunnelling International*, August 2024, page 19-29
- [2] European Climate, Infrastructure and Environment Executive Agency (2021): *Lyon-Turin rail link invests more than €3 billion*, European Commission, online verfügbar unter: [https://cinea.ec.europa.eu/news-events/news/lyon-turin-rail-link-invests-more-eu3-billion-2021-07-07\\_en](https://cinea.ec.europa.eu/news-events/news/lyon-turin-rail-link-invests-more-eu3-billion-2021-07-07_en) (Zugriff am 21.08.2025)
- [3] European Climate, Infrastructure and Environment Executive Agency (2024): *The Brenner Base Tunnel: shifting Alpine traffic from road to rail*, European Commission, online verfügbar unter: [https://cinea.ec.europa.eu/news-events/news/brenner-base-tunnel-shifting-alpine-traffic-road-rail-2024-09-18\\_en](https://cinea.ec.europa.eu/news-events/news/brenner-base-tunnel-shifting-alpine-traffic-road-rail-2024-09-18_en) (Zugriff am 21.08.2025)
- [4] Galler et al. (2023): Aktuelle Forschung im Bereich der Digitalisierung des konventionellen Tunnelbaus, SpringerLink.
- [5] Klein Lasse, Lehmann Gabriel, Tröndle Johannes, di Benedetto Diego, (2024) Rock Mass Classification in the Digital Era: A transformation in Hard Rock Tunnelling, 1st International Rock Mass Classification Conference, IOP Publishing, doi:10.1088/1755-1315/1435/1/012005
- [6] Maidl & Maidl (2022): Maschinelles Tunnelbau mit Tunnelvortriebsmaschinen und Rohrvortrieb, SpringerLink.
- [7] Mostafa Saadeldin, Sousa Rita L., Einstein Herbert H. (2024): Toward the automation of mechanized tunneling “exploring the use of big data analytics for ground forecast in TBM tunnels”, *Tunnelling and Underground Space Technology*, Volume 146
- [8] Smith Kristina (2024) Death of the TBM operator? *Tunnelling Journal* October/November 2024, page 18-21
- [9] Wehrmeyer Gerhard, Fenrich Nadine, Tröndle Johannes, Vogt Gino, Kiesele Charlotte (2024): Automatisierung, Digitalisierung und kontinuierlicher Vortrieb von Tunnelbohrmaschinen, *Tunnel 03-2024*. Internationale Fachzeitschrift für unterirdisches Bauen, STUVA (Hg.)
- [10] Zhe Zheng, Kaidi Luo, Xianzhong Tan, Lianhui Jia, Mingrui Xie, Haibo Xie, Lijie Jiang, Guofang Gong, Huayong Yang, Dong Han (2024): Autonomous steering control for tunnel boring machines, *Automation in Construction*, Volume 159

## **Autoren:**

Dipl.-Ing. Frederic Seng  
Herrenknecht AG  
Schlehenweg 2, 77963 Schwanau  
[seng.frederic@herrenknecht.de](mailto:seng.frederic@herrenknecht.de)

M.Sc. Lasse Klein  
Herrenknecht AG  
Schlehenweg 2, 77963 Schwanau  
[klein.lasse@herrenknecht.de](mailto:klein.lasse@herrenknecht.de)

# Digitalisierung in der Geotechnik – Wohin führt der Weg?

Sascha Henke, Johannes Beck

**Kurzfassung:** In diesem Beitrag wird zunächst der aktuelle Stand der Nutzung des Fachmodells Baugrund im praktischen Kontext diskutiert. Hierbei werden sowohl die Chancen und Möglichkeiten für die Praxis herausgestellt, als auch die aktuell weiterhin erkennbaren großen Herausforderungen diskutiert. Im zweiten Teil des Beitrags werden am Beispiel aktueller Forschungsthemen die großen Potenziale einer stärkeren Nutzung digitaler Methoden im geotechnischen Begutachtungs-, Entwurfs- und Planungsprozess diskutiert. Der Fokus liegt auf komplexen Themen, wie eine automatisierte Kopplung von Bauwerksinformationsmodellen und numerischen Modellen oder aber die Potenziale der Nutzung von Methoden der künstlichen Intelligenz, insbesondere des maschinellen Lernens. Hierfür werden Beispiele aus aktuellen Forschungsprojekten kurz aufgezeigt, um somit die Motivation für eine weitere verstärkte Nutzung digitaler Methoden in der Geotechnik zu geben.

## 1 Einleitung

Mit Einführung des Stufenplans des ehemaligen Bundesministeriums für Verkehr und digitale Infrastruktur aus dem Jahr 2015 wurde die Digitalisierung im Bauwesen durch eine notwendige Einführung der Methoden des Building Information Modeling (BIM) quasi adhoc für alle Ingenieurinnen und Ingenieure verpflichtend [1]. Dies schließt natürlich die Geotechnik entsprechend mit ein. Geplant war hierbei, dass bis 2020 eine Übergangsphase zur Etablierung erfolgt, sodass ab 2020 alle Verkehrs- und Infrastrukturprojekte mit entsprechender Komplexität mit den Methoden des BIM durchgeführt werden sollen. Es zeigt sich, dass dieser Zeitplan nicht vollumfänglich gehalten werden konnte. Dennoch ist die BIM-Methodik mittlerweile in der Baupraxis in zahlreichen Projekten in unterschiedlicher Tiefe präsent.

Die Ziele, die durch diese politisch motivierte Einführung erreicht werden sollten, umfassen bspw. (I) die Erhöhung von Planungsgenauigkeit, (II) von Termin- und Kostensicherheit sowie (III) die Transparenz und Kontrolle über den gesamten Lebenszyklus.

Es zeigte sich aber schnell, dass eine „von oben verordnete“ Einführung einer bis dato im deutschen Bauwesen kaum genutzten digitalen Methode nicht einfach und problemlos verläuft. Zwar werden in mittlerweile den vielen Projekten digitale Modelle erstellt, aber gerade die weitergehende Nutzung des Fachmodells Baugrund ist nach Ansicht der Autoren noch nicht sehr umfangreich.

An diese Stelle setzt der gegenständliche Beitrag an: Zunächst wird der aktuelle Stand des BIM in der Geotechnik aus Sicht der Autoren dargestellt und es werden Chancen, Möglichkeiten und Herausforderungen aufgezeigt. Im zweiten Teil des Beitrags werden dann die Möglichkeiten

der Digitalisierung in der Geotechnik aus Sicht der Forschung beleuchtet, um hierdurch die umfangreichen Möglichkeiten, die moderne IT-Methoden mit sich bringen, beispielhaft herauszuarbeiten.

## 2 Building-Information-Modeling (BIM) in der Geotechnik

### 2.1 Was ist der aktuelle Stand in der Praxis?

Die Methodik des BIM ist in der Praxis mittlerweile angekommen und wird in neu ausgeschriebenen Projekten regelmäßig gefordert. Hierbei wird auch das Fachmodell Baugrund erstellt, siehe beispielsweise [2] und [3]. Gemäß den Empfehlungen des AK 2.16 „Digitalisierung in der Geotechnik“ der DGGT [4] besteht dieses Fachmodell Baugrund aus mehreren Sub-Fachmodellen (Bohrsäulenmodell, Baugrundsichtenmodell, Homogenbereichsschichtenmodell, Grundwassermodell, ggf. Hydrogeologisches Modell etc.), wobei das Baugrundsichtenmodell aktuell das am weitesten verbreitete Sub-Fachmodell darstellt. Ein Beispiel eines großräumigen Baugrundsichtenmodells inkl. Bohr Säulen sowie ein spezielles Hydrogeologisches Modell zur Differenzierung zwischen Grundwasserleitern und -nichtleitern sind exemplarisch in Abbildung 1 dargestellt.




Abbildung 1: Beispieldarstellung eines großräumigen Baugrundsichtenmodells inkl. Bohr säulendarstellung (oben) sowie eines hydrogeologischen Modells zur Differenzierung von Grundwasserleitern und -nichtleitern (unten)

Somit kann festgehalten werden, dass die 3D-Baugrundmodellierung mittlerweile technisch möglich ist und regelhaft Baugrundmodelle im Rahmen von Infrastrukturprojekten erstellt werden. Hierfür sind verschiedene Software-Tools verfügbar, die unterschiedliche Stärken und Schwächen bezogen auf den BIM-Prozess haben, siehe hierzu [5].

Neben der reinen Visualisierung als Anwendungsfall sollte das Fachmodell Baugrund aber auch einen expliziten Nutzen im Begutachtungs-, Entwurfs- und Planungsprozess einnehmen. Aus diesem Grund wurden durch den AK 2.16 der DGGT Empfehlungen formuliert, welche sich u. a. mit den Entwicklungsstufen und der Attribuierung des Fachmodells [6] sowie verschiedenen denkbaren Anwendungsfällen [7] befassen. Hier bestehen aktuell aus Sicht der Autoren noch Herausforderungen vorhanden, die in Abschnitt 2.3 diskutiert werden. Zunächst werden jedoch die Chancen und Möglichkeiten dargestellt, die sich bereits jetzt ohne viel Aufwand aus Fachmodell in üblicherweise vorliegender Form ergeben.

## 2.2 Was sind die Chancen und Möglichkeiten für die Praxis?

In diesem Abschnitt werden verschiedene Chancen sowie Möglichkeiten dargestellt, die sich direkt ohne signifikanten zusätzlichen Aufwand aus dem Fachmodell Baugrund ergeben. Teilweise sind diese trivial und resultieren direkt aus dem Vorhandensein einer dreidimensionalen Repräsentation der wahrscheinlichen Baugrundgeometrie. Teilweise ergibt sich der Nutzen aber erst durch ein Zusammenspiel mit anderen Fachmodellen, wie es im klassischen BIM-Planungsprozess grundsätzlich angestrebt ist.

Nachfolgende exemplarisch genannte Anwendungsfälle mit ihren Vorteilen ergeben sich entsprechend direkt und bedürfen in der Regel mit Blick auf die aktuell verfügbaren Modellierungstechniken kaum Ergänzungen oder Anpassungen an dem Fachmodell Baugrund:

- Digitaler Bohrplan vs. analoger Bohrplan: Bohrpläne im klassischen geotechnischen Begutachtungsprozess wurden bisher in der Form eines 2D-CAD-basierten Plans mit Darstellung der Lage der Aufschlusspunkte im Lageplan erstellt, siehe Abbildung 2, links.




Abbildung 2: Beispiel eines „analogen“ (links) und vergleichend hierzu eines digitalen Bohrplans in 3D (rechts)

Aus dieser „analogen“, zweidimensionalen Darstellung kann außer der Lage und ggf. der Art des gewünschten Aufschlusses (wenn die gewählte Nomenklatur den Nutzenden bekannt ist), keine weitere Information, wie beispielsweise die angestrebte Aufschlusstiefe erkannt werden.

Die Aufschlusstiefe ist im digitalen Bohrplan (3D) hingegen direkt erkennbar. Somit kann dieser Bohrplan im Rahmen der Projektkoordination bspw. direkt für eine Kollisionskontrolle mit vorhandenen Leitungen und anderen Hindernissen genutzt werden. Weiterhin kann ein vorläufiges Planungsmodell des Bauwerkes den Aufschlüssen direkt gegenübergestellt werden, sodass frühzeitig erkennbar wird, inwieweit die gewählten Aufschlusstiefen sowie die Aufschlusslage zu dem geplanten Bauwerk passen. Auch im fortschreitenden Planungsprozess besteht so die Möglichkeit, dass bei Planungsänderungen durch den Planer direkt ein Abgleich erfolgen kann, inwieweit das Aufschlussprogramm zum geänderten Bauwerk passt. Zudem können den Objekten Eigenschaften zugewiesen werden, mit denen beispielsweise Bohrverfahren, Ausführungszeitpunkte, Protokolle und Fotos beschrieben oder verknüpft werden können.

Weiterhin kann dieser Bohrplan im Zuge der Ausführung der Baugrundaufschlüsse auch fortgeschrieben werden, sodass z. B. Fehlbohrungen, die tatsächliche Aufschlusstiefe etc. zeitnah für alle Beteiligten im digitalen Modell verfügbar werden.

- Ableitung von geologischen Schnitten: Im klassischen Planungsprozess werden geologische Schnitte oftmals so abgeleitet, dass „nahegelegene“ Aufschlüsse manuell in die Achse des gewünschten Schnittes projiziert werden, sodass Aufschlüsse unterschiedlicher Distanz zur Schnittachse als mehr oder weniger gleichwertige Basis des

geologischen Schnittes dienen. Gerade bei komplexen Baugrundsichtungen mit vielen wechselhaften Schichten kann dies zu Fehlinterpretationen führen. Wird der Schnitt hingegen direkt aus dem Baugrundsichtenmodell abgeleitet, welches durch geeignete Interpolation ein möglichst realitätsnahes räumliches Abbild der Baugrundsituation darstellt, werden die Fehler bei der Schnitterstellung deutlich reduziert.

Exemplarisch ist in Abbildung 3 ein Vergleich zwischen den geologischen Längsschnitten für ein reales Projekt dargestellt, welche mit den vorgenannten unterschiedlichen Methoden abgeleitet wurden. Es sind deutliche Unterschiede zwischen diesen beiden abgeleiteten Modellen erkennbar, die ohne Nutzung des 3D-Baugrundmodells nie erkannt würden.




Abbildung 3: Geologischer Längsschnitt entlang einer Achse. Oben: direkt aus dem Baugrundsichtenmodell abgeleitet, unten: durch Projektion von Bohrsäulen in die Schnittachse erstellt

- **Massenermittlung:** Bauteile und Bauwerke können mit geringem Aufwand mit dem räumlichen Baugrundsichtenmodell verschnitten werden, um hiermit eine effiziente, genaue und wenig fehleranfällige Massenermittlung zu ermöglichen.

Somit ist bereits an diesen Beispielen erkennbar, dass einfache Anwendungen des Fachmodells Baugrund, die aber einen großen erkennbaren Nutzen haben, ohne viel Aufwand bereits jetzt möglich sein sollten.

Dennoch sollte dies aus Sicht der Autoren nur der Anfang sein, da deutlich größere Potenziale in dem Fachmodell Baugrund vorhanden sind, die aktuell aber aufgrund verschiedener Aspekte, von denen nachfolgend einige kurz andiskutiert werden, nicht einfach umsetzbar sind und deshalb in der Praxis bisher kaum genutzt werden.

### 2.3 Was sind die aktuellen Herausforderungen in der Praxis?

Die großen Herausforderungen im Kontext der Digitalisierung im Bauwesen folgen nach Ansicht der Autoren u. a. daraus, dass die Einführung der bis dato im Bauwesen wenig etablierten digitalen Methoden aufgrund der in [1] politisch formulierten Erfordernisse plötzlich erfolgen musste und nicht aus sich selbst gewachsen ist.

Als Folge sind verschiedene Probleme oder Herausforderungen zu nennen:

- Die Ingenieurinnen und Ingenieure hatten bis dato keine oder wenig Erfahrungen mit den digitalen Methoden im nun geforderten Umfang. Sie wurden also quasi „ins kalte Wasser geworfen“. Zudem waren bis dato auch in der universitären Ausbildung des Nachwuchses das digitale Planen und Bauen kaum bis gar nicht verankert.
- Es war und ist teilweise auch heute vielen Beteiligten nicht in vollem Umfang bewusst, für welchen Zweck die Methode des Building Information Modeling in den jeweiligen Projekten genutzt werden soll. Oft herrscht noch die Meinung vor, dass es „ja auch immer ohne ging“. Dies hat zur Folge, dass im BIM-Prozess die notwendigen Zielstellungen oft unklar formuliert sind und oftmals nur in der jeweiligen Projektphase gedacht

wird, sodass eine zielgerichtete Nutzung der Fachmodelle über den gesamten Lebenszyklus mit den je Projektphase unterschiedlichen Anforderungen deutlich erschwert ist.

- Es wird in der Praxis (auch aufgrund der vergaberechtlichen Vorgaben) weiterhin der klassische Workflow bei einer Entwurfs-, Planungs- und Bauaufgabe verfolgt, der aber oftmals nicht uneingeschränkt kompatibel ist mit digitalen Prozessen. Oftmals wurden bzw. werden diese analogen Prozesse in den digitalen Workflow „gepresst“, was problematisch sein kann. Auch sind die Schnittstellen zwischen den verschiedenen Fachmodellen oftmals unzureichend definiert.
- Notwendige Grundlagen insbesondere aus datentechnischer Sicht (z. B. semantische Objektkataloge, Schnittstellendefinitionen etc.) sind bisher nicht allgemeingültig festgelegt oder geregelt, was einem durchgehenden digitalen Prozess abträglich ist. Ergänzend ist festzustellen, dass der „klassische“ BIM-Ansatz, der auf der Produktmodellierung mit zugeordneten geometrischen und nicht-geometrischen Eigenschaften besteht, bei geotechnischen Fragestellungen schnell an seine Grenzen stößt. Herausforderungen sind hier beispielsweise die quantifizierende Beschreibung von Unsicherheiten, auch in der geometrischen Repräsentation, die Beschreibung von spannungs- und zeitabhängigen Eigenschaften sowie Gültigkeitsbereiche von interaktionsbasierten Eigenschaften (z.B. Bettungsmodul), räumlich und systemisch.

Konkret werden nachfolgend drei Punkte besonders herausgestellt, die dringend angepasst werden müssen, damit digitale Methoden in der Geotechnik zunehmend Mehrwerte generieren:

1. In der Praxis ist es häufig der Fall, dass Baugrunderkundungen erst parallel zur laufenden Planung erfolgen. Dieses planungsbegleitende Erschließen des Baugrunds führt aber dazu, dass das Fachmodell Baugrund, welches ja per Definition ein *Grundlagenmodell* ist, das entsprechend als Planungsgrundlage vor Beginn der Planung in ausreichendem Umfang verfügbar sein sollte, erst entsteht, wenn die Planung schon so weit fortgeschritten ist, dass dieses Fachmodell kaum mehr sinnvoll im digitalen Planungsprozess genutzt werden kann. Dies führt dazu, dass oftmals maximal noch eine Massenermittlung erfolgt, weitergehende Anwendungen im Kontext der Bemessung und des Entwurfs entfallen hingegen fast vollständig. Hierfür fehlen beispielsweise Workflows zur semi-automatisierten Anpassung von Planungsmodellen bei sich ändernden Grundlagenmodellen.  
Hier zeigt sich aber auch eindrücklich, dass dieses Vorgehen nicht nur im digitalen Prozess unglücklich ist. Es verdeutlicht gleichzeitig, dass auch im analogen Planungsprozess bei einem derartigen Vorgehen die notwendigen Grundlageninformationen erst mit fortgeschrittenem Planungsprozess valide vorliegen, was dazu führt, dass die Planung ggf. mehrmals angepasst werden muss oder aber auf sehr konservativen Prämissen erfolgt, sodass der Entwurf unwirtschaftlich und wenig nachhaltig werden kann. Somit ist herauszustellen, dass die Ziele der Einführung des BIM, nämlich eine Effizienzsteigerung und Kostenreduktion nicht allein durch die Methode selbst, sondern insbesondere durch eine Verbesserung der alten Prozesse überhaupt erreichbar sind.
2. Oft entsteht der Eindruck, dass BIM in der Geotechnik mit einer 3D-Modellierung der Baugrundsichten gleichzusetzen ist. Hierbei wird aber vergessen, dass neben der räumlichen geometrischen Repräsentation v. a. die semantische Modellierung essentiell ist. Dies bedeutet, dass die erstellten Modelle mit zahlreichen Informationen angereichert werden müssen, die für die Erreichung der Ziele (Anwendungsfälle) notwendig sind. Dies wird als Attribuierung bezeichnet.

Im digitalen Prozess ist es erforderlich, dass die Attribute nach einem klar definierten und v. a. auch informationstechnologisch korrekten Schema (genannt bspw. Semantisches Objektmodell [SOM]) im Modell integriert werden. Dies beinhaltet neben einer korrekten Bezeichnung und Platzierung und einer Eindeutigkeit auch eine klare Vorgabe zu Format, Einheiten etc. Zudem sind Dopplungen in der Attribuierung zwingend zu vermeiden (*single-source-of-truth*).

Da in einem durchgehenden digitalen Prozess immer wieder auf ausgewählte Eigenschaften direkt zugegriffen werden muss und teilweise auch neue Attribute generiert werden, ist es offensichtlich, dass ein durchgehender digitaler Prozess nur umsetzbar ist, wenn allgemeingültige und eindeutige Objektmodelle genutzt werden.

Aktuell ist diesbezüglich der Stand, dass derartige abgestimmte und allgemeingültige Kataloge nicht vorliegen. Vielmehr werden in der Praxis aktuell „Insellösungen“ generiert, die für ein spezifisches Projekt genutzt werden. Bei anderen Projekten sind dann ggf. andere Objektkataloge zu nutzen, sodass offensichtlich erkennbar ist, dass dies die Entwicklung von Programmen zur Unterstützung digitaler Workflows behindert bzw. sehr aufwändig oder nahezu unmöglich macht, da in jedem Fall individuelle Schnittstellenlösungen erarbeitet werden müssen.

3. Im Rahmen der Ausschreibung werden sogenannte Auftraggeberinformationsanforderungen (AIA) verfasst, aus denen die Ziele der Anwendung des BIM im Projekt eindeutig hervorgehen sollen. Hier hat sich in den letzten Jahren eine grundsätzlich positive Entwicklung gezeigt, so wurden vielfach Muster-AIA entwickelt und die Aufgaben werden mittlerweile besser als mit Einführung des BIM definiert.

Dennoch ist gerade die Nutzung des Fachmodells Baugrund oftmals auf grundlegende Anwendungsfälle wie Bestandserfassung und Visualisierung beschränkt. Es fehlt somit zu Beginn eines Projekts die Vorstellung einer weitergehenden Nutzung des Fachmodells Baugrund z. B. im Zuge der Bemessung oder aber auch für die Abrechnung und Bauausführung.

Entsprechend wäre es im Hinblick auf das Ziel einer Nutzung des Fachmodells Baugrund über den gesamten Lebenszyklus von großer Bedeutung, dass bereits in der Ausschreibung alle potentiell zukünftig angestrebten Anwendungsfälle des Fachmodells klar definiert werden, damit dem Modell die notwendigen Funktionalitäten entsprechend eingepflegt werden können.

### **3 Digitalisierung – Anwendungspotenziale aus Sicht der Forschung**

Die nachfolgenden Themen sind exemplarische Beispiele für eine weitergehende Nutzung digitaler Methoden im geotechnischen Begutachtungs-, Entwurfs- und Planungsprozess, die aktuell dem Stand der Forschung zuzuordnen sind. Es ist aber zu erwarten, dass aus diesen Anwendungsbeispielen große Chancen für eine schnellere, fehlerreduzierte und auch nachhaltigere Planung geotechnischer Konstruktionen entstehen, was nachfolgend kurz diskutiert wird.

#### **3.1 BIM2FEM-Kopplung**

Da im Rahmen des BIM-getriebenen Planungsprozesses ein räumliches Fachmodell Baugrund erstellt wird, liegt es nahe, geotechnische Schnitte, die für FE-Berechnungen weitergenutzt werden können, direkt aus dem Fachmodell abzuleiten. Hierbei sind aber einige Aspekte hervorzuheben, die diesen Vorgang erschweren:

- Das Baugrundmodell ist in der Regel deutlich detaillierter modelliert als es für eine FE-Modellierung erforderlich ist. D. h., es ist u. a. geprägt durch Linsen, auslaufende Schichten sowie vergleichsweise dünne Schichtpakete, die bei direkter Übertragung eines Schnittes in einen FE-Preprocessor bei der Netzgenerierung zu Problemen infolge sehr kleiner oder stark verzerrter Elemente mit teilweise schlechter Qualität führen. [8], [9]
- Im FE-Modell müssen zusätzlich Strukturelemente modelliert werden, die je nach Entwurf Schichtgrenzen schneiden, sodass in diese Schnittbereichen ebenfalls Regionen resultieren, die im Rahmen der Netzgenerierung durch vergleichsweise kleine und verzerrte Elemente mit schlechter Qualität geprägt sind. [8], [9]

Diese Probleme führen dazu, dass das numerische Modell (I) aus vergleichsweise vielen Elementen besteht, sodass lange Rechenzeiten resultieren, (II) die Elemente unzureichender Qualität ggf. keine adäquaten Ergebnisse liefern und (III) ggf. eine Vernetzung überhaupt nicht möglich ist. Dies führt dazu, dass in der praktischen Umsetzung umfangreiche händische Nacharbeiten am FE-Netz erforderlich werden, die den Prozess der automatischen BIM2FEM-Integration unwirtschaftlich machen.

Um eine automatisierte BIM2FEM-Kopplung zu ermöglichen und eine Vernetzung zu ermöglichen, die mit Netzen vergleichsweise geringer Netzdichte bei gleichzeitig hoher Netzqualität einhergehen, ist es erforderlich, dass die aus dem Fachmodell Baugrund abgeleiteten Schnitte vor einem Transfer in die FE-Software mit Methoden der Geometrievereinfachung „aufgeräumt“ werden. Dieser Ansatz ist beispielsweise in [8] und [9] beschrieben, ein exemplarisches Beispiel zur Geometriesimplifikation im Bereich auslaufender Schichten ist in Abbildung 4 beigefügt. Dort ist neben der Referenzgeometrie und der vereinfachten Geometrie jeweils das resultierende FE-Netz dargestellt. Weiterhin wird die Netzqualität farblich dargestellt, wobei das Netz umso „besser“ ist, je näher der Netzqualitätsfaktor gegen 1,0 strebt.

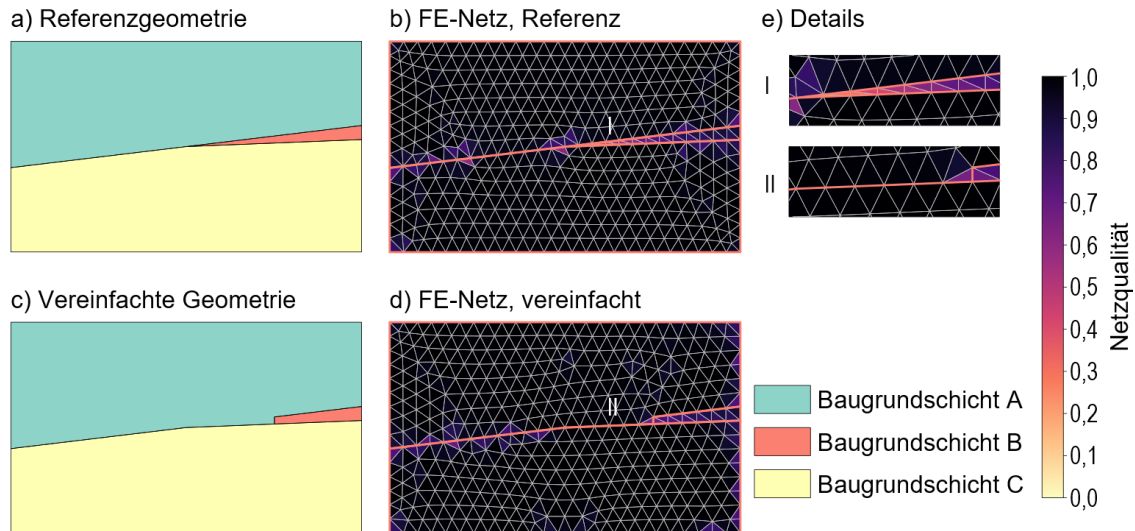


Abbildung 4: Exemplarisches Beispiel einer Geometrievereinfachung im Bereich von auslaufenden Schichten

Es wird deutlich, dass im Bereich der spitzen Ecke einer auslaufenden Baugrundsicht durch gezielte Vereinfachung der Geometrie (hier Auflösung des spitzen Winkels durch gezielte

Begrenzung der auslaufenden Schicht) ein deutlich verbessertes FE-Netz im kritischen Bereich resultiert.

Der grundsätzliche Prozess vom Fachmodell Baugrund und der daraus erfolgten Ableitung eines Schnittes hin zum FE-Modell mit hochqualitativem Netz mit minimaler Elementanzahl ist in Abbildung 5 in überakzentuierter Vereinfachung zusammengefasst. Für die Modellierung der Strukturelemente sind nicht-geometrische Daten von besonderer Bedeutung, da über diese die Ausprägung im numerischen Modell maßgeblich beschrieben werden kann. Im Beispiel aus Abbildung 5 wird lediglich die Lage und der Abstand der Steifen indirekt aus geometrischen Daten abgeleitet. Durchgängige Prozesse ermöglichen die vereinfachte Weiternutzung von Simulationsergebnissen in Entwurf und Planung, eine Versionierung von Berechnungsmodellen und eine (semi-)automatische Dokumentation.

Eine detaillierte Darstellung verschiedener möglicher Geometriesimplifizierungsalgorithmen wird zeitnah in [10] publiziert.

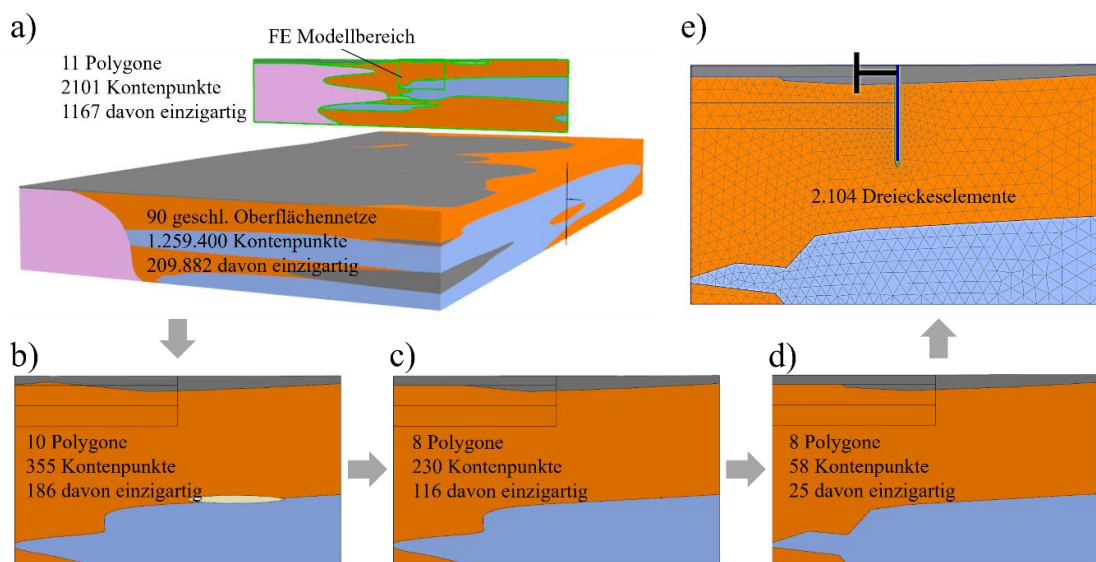


Abbildung 5: a) Fachmodell Baugrund mit b) extrahiertem Schnitt und definierten Aushubbereichen, c) Elimination nicht relevanter Linsen, d) Geometriesimplifizierung und e) resultierendem Berechnungsnetz, entnommen aus [8]

### 3.2 Nutzung von Methoden der künstlichen Intelligenz in der Geotechnik

In jüngerer Zeit werden vermehrt Arbeiten zur Nutzung von Methoden der künstlichen Intelligenz in der Geotechnik publiziert. Beispiele, die sich vorrangig auf die Nutzung der genannten Methoden in der Bauausführung beziehen, sind bspw. in [11] dokumentiert. Einen breiteren Überblick über verschiedene Anwendungsgebiete der künstlichen Intelligenz für geotechnische Fragestellungen liefert darüber hinaus [12]. Somit zeigt sich, dass im Zuge der wachsenden Digitalisierung, steigender Rechnerkapazitäten und fortschreitender Entwicklung der Methoden der künstlichen Intelligenz auch in der Geotechnik vielfältige Anwendungsmöglichkeiten vorhanden sind.

Im Rahmen dieses Beitrags werden als Beispiel zur Verdeutlichung der Potenziale der Anwendung der künstlichen Intelligenz bereits in der frühen Projektphase der klassischen Baugrunderkundung (Bodenansprache/-klassifikation) erste Ergebnisse von Untersuchungen zur Möglichkeit einer Bodenklassifikation auf Basis von Bilddaten vorgestellt.

Ziel dieser Untersuchungen war es, zu prüfen, inwieweit die Bodenarten einer Bodenprobe auf Basis eines Bildes mittels künstlicher Intelligenz vorhergesagt werden kann.

Hierfür wurden Fotos von Bohrkernen aus einem Projekt der Bundesanstalt für Wasserbau (BAW) zusammen mit den Ergebnissen der Bodenansprache (Haupt- und Nebenbodenarten) zur Verfügung gestellt. Bei diesem Projekt handelt es sich um einen geplanten Schleusenneubau im norddeutschen Raum, sodass der Boden wesentlich von rolligen Böden sowie bereichsweise von Beckensedimenten geprägt ist.

In Abbildung 6, links ist ein exemplarisches Foto einer Linerbohrung dargestellt.




Abbildung 6: Links: Beispiel einer Liner-Bohrung, an der die Hauptbodenart der einzelnen Schichten mit Methoden der künstlichen Intelligenz abgeschätzt werden soll, Rechts: Beispiel eines händisch entnommenen Bildausschnitts (330x330 Pixel)

Im Rahmen der vorbereitenden Datenaufbereitung wurden in einem ersten Schnitt händisch aus den Linerfotos Abschnitte der Größe 330x330 Pixel ausgeschnitten (Abbildung 6, rechts) und mit den wesentlichen Informationen zu Haupt- und Nebenbodenarten nach DIN 4022 gelabelt. Hierbei wurden insgesamt vier unterschiedliche Hauptbodenarten im Projekt identifiziert, nämlich fS, mS, gS und U. Wobei der Anteil an gS und U mit je etwas über 200 Datensätzen den geringsten Umfang aufweist.

Es wurden aus den verfügbaren Linerbildern insgesamt 2.464 Bilder extrahiert und gelabelt, die nachlaufend als Trainingsdatensatz genutzt wurden. Zusätzlich wurden insgesamt bis zu 656 weitere Bilder der vier differenzierten Klassen als Testdatensatz zurückgehalten.

Im Rahmen dieser Vorstudie wurde ein vortrainiertes KI-Modell (hier: VGG16, siehe [13]) genutzt. Hinsichtlich der genauen Beschreibung wird auf [13] verwiesen. Mit dieser Methode erfolgte dann für den Testdatensatz eine Vorhersage der potentiellen Hauptbodenart allein auf Basis der in den Bildern enthaltenen Informationen. Als Ergebnis dieser ersten Studie ist Tabelle 1 dargestellt.

Tabelle 1: Ergebnis der Klassifikation der Hauptbodenart mittels VGG16

Hauptbodenart	Precision	Recall	F1-value	Anzahl Trainingsdatensätze	Accuracy
fS	82 %	78 %	80 %	41	
gS	94 %	91 %	93 %	34	
mS	73 %	71 %	72 %	34	
U	80 %	100 %	89 %	16	
<b>Gesamt: 125</b>					82 %

In dieser Beispieluntersuchung wurden insgesamt 125 Testdatensätze zur Überprüfung des Modells genutzt, um bei den ausgewählten Bildern eine ungefähre Gleichgewichtung zwischen den verschiedenen Bodenarten zu gewährleisten.

Die in Tabelle 1 angegebenen Kennwerte „Precision“, „Recall“ und „F1-value“ sind übliche Kennwerte, um die Genauigkeit einer KI-gestützten Prognose bewerten zu können. Für eine detaillierte Beschreibung dieser Kenngrößen wird auf die gängige Literatur verwiesen [14]. An dieser Stelle ist hierzu festzuhalten, dass je näher ein Wert von 100 % erreicht wird, umso besser ist die Prognose. Somit kann unter Berücksichtigung dieser Ergebnisse festgehalten werden, dass mit dieser relativ einfachen Bildanalyse und der überschaubaren Datengrundlage mit nur wenigen unterschiedlichen und zudem sehr ähnlichen Bodenarten bereits eine Erfolgsquote von in der Regel > 80 % erzielt werden konnte, was die Potenziale der KI-basierten Bilderkennung zur Bodenklassifikation unterstreicht. Es ist zu erwarten, dass die Ergebnisse durch gezieltes Anlernen der künstlichen Intelligenz und das Einpflegen weiterer Datensätze weiter verbessert werden können. Zudem ist an dieser Stelle auch anzumerken, dass auch die Eingangsdaten, d. h. das Ergebnis der manuellen Bodenklassifikation infolge einer Bodenansprache durch das Laborpersonal eine gewisse Unschärfe hat, sodass auch hier ein Grund für die teilweise festgestellten Abweichungen vorliegen kann. Es wäre entsprechend zukünftig anzustreben, dass nicht das Ergebnis einer händischen Bodenansprache, sondern bspw. die Ergebnisse von Klassifikationsversuchen, wie z. B. die Korngrößenverteilung, als Information an die Bilder angehängt wird, sodass die Bilderkennung auf Basis dieser zuverlässigeren Daten erfolgen kann.

Aus dieser ersten Untersuchung ergab sich aber, dass die händische Aufbereitung der Bilddaten unverhältnismäßig aufwändig war, sodass in einem weiteren Schritt ein alternativer Weg beschritten wurde. Hierfür wurden die zur Verfügung gestellten Bilddaten direkt mittels Bilderkennung analysiert, um somit automatisiert eine Differenzierung der verschiedenen Bodenarten sowie eine Erkennung von Kernverlusten und Schichtgrenzen zu testen.

Genutzt wurde hierfür die gleiche Datenbasis (Linerfotos, zur Verfügung gestellt durch die BAW) wie in den vorhergehenden Untersuchungen verwendet. Als Bildsegmentierungsmodell wurde das sogenannte YOLOv8-Modell genutzt, welches von Ultralytics 2023 bereitgestellt wurde [15]. Hierbei handelt es sich um ein Deep Learning-basiertes Modell, welches speziell für Erkennung und Segmentierung von Objekten entwickelt wurde. Bezüglich des Aufbaus dieses Modells und seiner konkreten Anwendungsbreite wird auf [16] verwiesen.

Im Rahmen der Studie wurden insgesamt 232 Linerfotos (siehe exemplarisch Abbildung 6, links) genutzt, wobei diese in Trainings-, Validierungs- und Testdatensätze unterteilt werden mussten (60 % Training, 25 % Validierung, 15 % Test).

Im dargestellten Beispiel wurden die unterschiedlichen in den Linern enthaltenen Böden entsprechend ihrer Hauptbodenarten wie folgt unterteilt: (I) Sand (oberhalb Grundwasserspiegel), (II) Sand (unterhalb Grundwasserlevel), (III) Ton (unter Grundwasserlevel), (IV) Schluff (unter Grundwasserlevel) und (V) Grobsand (unter Grundwasserlevel). Hierbei wurde die Gruppe Sand aus Proben mit vorrangig Mittel- und Feinsand gebildet, während der Grobsand als separate, durch deutlich gröbere Fraktionen geprägte Gruppe berücksichtigt wurde. Die Unterscheidung zwischen ober- und unterhalb Grundwasserlevel für die Sande wurde bewusst gewählt, da teilweise Sande vor Ort oberhalb des Grundwassers anstehen und demnach gesondert betrachtet werden sollten, da dies ggf. Einfluss auf bspw. die Farbe hat und somit in der Bildsegmentierung berücksichtigt werden sollte.

Zusätzlich wurden noch die Gruppen Kernverlust (KV) und Hintergrund (background) definiert, da auf den Fotos immer auch Bereiche mit Kernverlusten im Liner vorhanden waren. Zudem war der Hintergrund ebenfalls im Bild enthalten und musste entsprechend heraussegmentiert werden.

In Abbildung 7 ist als Ergebnis der Untersuchung die sogenannte *Confusion Matrix* dargestellt. Diese gibt an, mit welchem Prozentsatz ein Trainingsdatensatz korrekt erkannt wurde und wie sich die „Falschprognosen“ auf die unterschiedlichen anderen Gruppen aufteilen. Dies bedeutet, je näher der Wert in der Matrixdiagonalen gegen 1,0 strebt, umso besser ist die Erkennungsrate.

Anhand dieses Ergebnisses kann erkannt werden, dass eine nahezu optimale Erkennung für die Sande, den Ton und den Kernverlust erreicht wurde. Auch der Grobsand wurde mit einer Erkennungsquote von 70 % zufriedenstellend identifiziert. Problematisch war die Erkennung des Schluffes, was voraussichtlich dadurch zu begründen ist, dass dieser in den vorliegenden Datensätzen nur sehr untergeordnet vorhanden ist, sodass kein ausreichender Trainingsdatensatz erstellt werden konnte. Hier wäre es entsprechend erforderlich, weitere Schluffdatensätze zum Anlernen des Modells zu ergänzen.




Abbildung 7: *Confusion Matrix* als Ergebnis der Bildsegmentierung durch YOLOv8-Modell

Eine visuelle Veranschaulichung eines Ergebnisses der Bildsegmentierung ist Abbildung 8 dargestellt. In dieser Darstellung ist zum einen das originale Linerfoto dargestellt (links). Weiterhin wird das Ergebnis der Bildsegmentierung mit Prognosewahrscheinlichkeit dargestellt (Mitte), um dieses mit der händischen Segmentierung / Ansprache (*ground truth*) zu vergleichen.

Es ist gut zu erkennen, dass die KI-basierte Segmentierung des Liners im dargestellten Fall offensichtlich sehr gute Ergebnisse liefert. Neben einer guten Prognose der jeweiligen Bodenart bzw. der Identifikation von Bereichen mit Kernverlust fällt auf, dass auch Schichtgrenzen gut vorhergesagt werden.

Es ist an dieser Stelle anzumerken, dass die hier präsentierten Ergebnisse erste Untersuchungen darstellen, die im Rahmen weiterer Forschungsarbeiten zu vertiefen sind. Dennoch ist hervorzuheben, dass große Potenziale in den gezeigten KI-Methoden vorhanden sind, wie bspw. Effizienzsteigerung, Reproduzierbarkeit und Reduktion der Subjektivität des Laborpersonals, die es zu vertiefen gilt.




Abbildung 8: Exemplarisches Ergebnis der Bildsegmentierung mittels YOLOv8-Modell, links: Originalbild, Mitte: Prognose, rechts: *ground truth*

## 4 Zusammenfassung und Ausblick

Im Rahmen dieses Beitrages wurde auf den aktuellen Stand der Umsetzung bzw. Einführung der Digitalisierung in der Geotechnik eingegangen. Wesentlich getrieben ist die Forcierung der Digitalisierung im Bauwesen durch die verpflichtende Nutzung des Building-Information-Modelling (BIM) bei größeren Infrastrukturprojekten. Es wird diskutiert, dass das Fachmodell Baugrund als ein Datenliefergegenstand der Geotechnik im BIM-Prozess mittlerweile regelhaft erstellt und bereitgestellt wird. Es zeigt sich aber auch, dass die Nutzung dieses Fachmodells bislang eher selektiv ist und nur wenige Chancen, die sich aus diesem Modell heraus für den Planungs- und Bauprozess ergeben, wirklich genutzt werden.

Die Gründe hierfür sind vielfältig und müssen im Rahmen der weiteren Etablierung des BIM gelöst werden. Insbesondere ist es essentiell, dass die Prozesse grundlegend an einen digitalen

Planungs- und Bauprozess angepasst werden und dass notwendige semantische Objektkataloge sowie Schnittstellen erstellt und allgemeingültig festgeschrieben werden.

Im zweiten Teil dieses Beitrages werden dann verschiedene Potenziale der Digitalisierung über den reinen BIM-Planungsprozess hinaus exemplarisch diskutiert. Fokussiert wird hierbei auf eine automatisierte BIM2FEM-Kopplung, um automatisiert und fehlerreduziert Finite-Elemente-Modelle direkt aus einem digitalen Bauwerks- und Baugrundmodell zu generieren. Als weiteres Beispiel wird auf die Potenziale der künstlichen Intelligenz am Beispiel der Bodenklassifikation mittels Bilderkennungstools eingegangen. Beide Beispiele zeigen deutlich die hohen Potenziale, die in einer vermehrten Nutzung der hochwertigen digitalen Methoden liegen. Natürlich ist hier aber noch Forschungsbedarf erforderlich, um diese Methoden in der Praxis zu etablieren.

## Danksagung

Die Autoren danken der Bundesanstalt für Wasserbau (BAW) für die Bereitstellung der Linerfotos sowie der Bodenanspracheprotokolle, die im Rahmen der Untersuchungen zur Bodenklassifikation mittels KI-Tools Verwendung fanden.

## Literatur

- [1] Bundesministerium für Verkehr und digitale Infrastruktur (2015): Stufenplan Digitales Planen und Bauen, Einführung moderner, IT-gestützter Prozesse und Technologien bei Planung, Bau und Betrieb von Bauwerken, Dezember 2015.
- [2] Stille, B.; Sanchez C.C.; Schreiner, A. (2025): 3D-Baugrundmodellierung im BIM-Prozess am Beispiel der Kläranlage Leverkusen, Report Geotechnik Universität Duisburg-Essen, Heft 50, S. 19-31.
- [3] Wilfing, L. and Boley, C. (2022), Digitalisierung und BIM in der Geotechnik – Möglichkeiten und Herausforderungen. *Bautechnik*, 99: 698-705. <https://doi.org/10.1002/bate.202200060>
- [4] Molzahn, M.; Bauer, J.; Henke, S.; Tilger, K. (2020): Das Fachmodell Baugrund – Empfehlungen des Arbeitskreises 2.14 der DGGT „Digitalisierung in der Geotechnik“. *Geotechnik* 44 (2021), Heft 1, 41-51. DOI: 10.1002/gete.202000040
- [5] Bauer, J.; Beck, J.; Clostermann, D.; Henke, S.; Schwabe, K.; Tilger, K. (2023): Vergleichende Untersuchung von Software zur Erstellung des Fachmodells Baugrund. *Bautechnik* 100 (2023), Heft 9, 552-564. <https://doi.org/10.1002/bate.202300076>
- [6] Molzahn, M.; Bauer, J.; Henke, S.; Tilger, K. (2021): Entwicklungsstufen und Attribuierung des Fachmodells Baugrund – Empfehlungen Nr. 2 des Arbeitskreises 2.14 der DGGT „Digitalisierung in der Geotechnik“. *Geotechnik* 44, Heft 3, S. 209-218
- [7] Molzahn, M.; Bauer, J.; Henke, S.; Tilger, K. (2021): Anwendungsfälle des Fachmodells Baugrund – Empfehlungen Nr. 3 des Arbeitskreises 2.14 der DGGT „Digitalisierung in der Geotechnik“. *Geotechnik* 45, Heft 2, S. 111-116. DOI: 10.1002/gete.202100026

- [8] Beck, J.; Henke, S. (2023): A novel approach towards automated derivation of two-dimensional, numerical models from geotechnical building information models (BIM). Proceedings 10th NUMGE 2023. 10th European Conference on Numerical Methods in Geotechnical Engineering. Zdravkovic L, Kontoe S., Taborda DMG, Tsiamposi A (eds). <https://doi.org/10.53243/NUMGE2023-28>
- [9] Beck, J.; Henke, S. (2024): Untersuchungen zur wissensbasierten BIM-FEM-Integration an einer innerstädtischen Baugrube. Fachsektionstage Geotechnik – Interdisziplinäres Forum. Tagungsband. S. 118-123. ISBN 978-3-946039-10-5
- [10] Beck, J.; Henke, S. (2025): Subsoil geometry simplification for deriving 2D-FE-Models from Building Information Models. *Journal of Information Technology in Construction*. [submitted]
- [11] Thienert, C.; Gutberlet, L.; Klaproth, C.; Otterbein, R.; Ludwig, F.; Könemann, F.; Heim, A.; Budach, C. (2025): Methoden Künstlicher Intelligenz in der Geotechnik – Ausgewählte Beispiele. In: Report Geotechnik Universität Duisburg-Essen, Hrsg. E. Perau, Heft 50, S. 67-77.
- [12] Baghbani, A.; Choudhury, T.; Costa, S.; Reiner, J. (2022): Application of artificial intelligence in geotechnical engineering: A state-of-the-art-review. *Earth-Science Reviews*, Vol. 228, 2022, 103991. <https://doi.org/10.1016/j.earscirev.2022.103991>
- [13] Simonyan, K.; Zisserman, A. (2014): Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv e-prints, Art. no. arXiv:1409.1556. doi:10.48550/arXiv.1409.1556.
- [14] Kanstrén, T. (2022): A Look at Precision, Recall, and F1-Score - Towards Data Science, Medium, [online] <https://towardsdatascience.com/a-look-at-precision-recall-and-f1-score-36b5fd0dd3ec>
- [15] Hussain, M. (2024): YOLOv1 to v8: Unveiling Each Variant–A Comprehensive Review of YOLO in *IEEE Access*, vol. 12, pp. 42816-42833. Doi: 10.1109/ACCESS.2024.3378568
- [15] Solawetz, J.F. (2023): What is YOLOv8? The Ultimate Guide. January 11 2023. – URL <https://blog.roboflow.com/whats-new-in-yolov8/>

## Autoren

Univ.-Prof. Dr.-Ing. habil. Sascha Henke  
 Helmut-Schmidt-Universität / UniBw H  
 Professur für Geotechnik  
 Holstenhofweg 85  
 22043 Hamburg  
 Tel.: +49 (0) 40 - 6541 / 3351  
 E-Mail: [sascha.henke@hsu-hh.de](mailto:sascha.henke@hsu-hh.de)  
 Web: [www.hsu-hh.de/geot](http://www.hsu-hh.de/geot)

M.Eng. Johannes Beck  
Helmut-Schmidt-Universität / UniBw H  
Professur für Geotechnik  
Holstenhofweg 85  
22043 Hamburg  
E-Mail: [beckjo@hsu-hh.de](mailto:beckjo@hsu-hh.de)



# KI gestützte Überwachung von Ufereinfassungen

K. Cerek

**Kurzfassung:** Die langfristige Leistungsfähigkeit und Sicherheit von Kaimauern hängt von komplexen Boden-Bauwerks-Interaktionen ab, die mit herkömmlichen Inspektions- und Messmethoden allein schwer zu überwachen und vorherzusagen sind. In diesem Beitrag wird ein hybrider Ansatz für die KI-gestützte Überwachung von Kaimauern vorgestellt, der numerische Simulationen mit auf maschinellem Lernen basierenden Surrogate-Modellen (dt.: Ersatzmodellen) kombiniert. Mit diesem Ansatz soll die geotechnische Interpretation von Sensordaten verbessert und eine Echtzeitbewertung des Strukturverhaltens unter variablen Belastungs- und Umweltbedingungen ermöglicht werden. Die Hauptkomponente des Systems ist ein digitaler Zwilling, der Messdaten (z. B. von Neigungsmessern, Piezometern und Ankerkraftsensoren) mit FE-Simulationen verbindet, die das physikalische Verhalten des Kaimauersystems darstellen. Diese Simulationen werden verwendet, um Trainingsdaten für Surrogate-Modelle zu generieren, welche die Ergebnisse des numerischen Modells zu einem Bruchteil der Rechenkosten nachbilden. In diesem Beitrag werden die wichtigsten Herausforderungen hinsichtlich der Datenverfügbarkeit und der Modellverallgemeinerung von KI-Modellen in geotechnischen Zusammenhängen erläutert.

## 1 Motivation

Kaimauern sind als wichtige Bestandteile der maritimen Infrastruktur komplexen geotechnischen Belastungsbedingungen ausgesetzt. So erfahren sie neben Erd- und Wasserdrücken, auch zyklische Belastungen durch Anlegevorgänge und langfristige Konsolidierungs- oder Kolkprozesse. Die Aufrechterhaltung ihrer strukturellen und geotechnischen Integrität über Jahrzehnte hinweg ist von entscheidender Bedeutung, aber auch eine Herausforderung.

Herkömmliche Zustandsbewertungsansätze beruhen auf regelmäßigen visuellen Inspektionen und der manuellen Auswertung von Sensordaten. Die zunehmend alternde Infrastruktur und die steigenden Anforderungen an die Häfen erfordern jedoch proaktivere und automatisierte Überwachungsstrategien. In der Geotechnik hat die Integration numerischer Simulationen, z. B. mit Finite-Elemente-Modellen (FE-Modellen), unsere Möglichkeiten zum Verständnis der Boden-Bauwerk-Interaktion unter verschiedenen Belastungsszenarien erheblich verbessert [44, 43, 21, 36, 40, 6, 1, 41, 20, 19]. Ihr Einsatz in der täglichen Überwachung ist jedoch durch die Rechenkosten begrenzt. Hier bietet die KI-gestützte Überwachung ein neues Potenzial nicht als Ersatz

für physikalische oder numerische Modelle, sondern als Ermöglichung einer datengesteuerten Entscheidungsfindung in Echtzeit durch hybride digitale Zwillinge. In einem solchen Rahmen simulieren numerische Modelle das physikalische Verhalten der Kaimauer unter verschiedenen Bedingungen, und KI-Modelle insbesondere Surrogate-Modelle lernen, deren Ergebnisse zu approximieren. Diese trainierten Modelle können dann verwendet werden, um strukturelle Reaktionen schnell zu bewerten, Abweichungen vom erwarteten Verhalten zu erkennen oder wahrscheinliche Ursachen aus beobachteten Daten rückzurechnen.

In diesem Beitrag wird untersucht, wie KI-Methoden zur Unterstützung der geotechnischen Überwachung von Kaimauern durch die Entwicklung von Surrogate-Modellen auf der Grundlage numerischer Simulationen eingesetzt werden können. Er skizziert die Schlüsselkomponenten eines hybriden digitalen Zwillings, beschreibt geeignete Techniken des maschinellen Lernens für die Surrogate-Modellierung und erörtert die Herausforderungen der Integration von Simulationsergebnissen mit Echtzeit-Überwachungsdaten.

## **2 KI und Digitale Zwillinge in der Geotechnik**

Das Konzept des digitalen Zwillings, ein virtuelles Abbild eines physischen Objekts, das kontinuierlich mit realen Daten aktualisiert wird, hat in den letzten Jahren im Bauwesen an Bedeutung gewonnen. Vor allem in der Geotechnik befindet sich der digitale Zwilling aufgrund mehrerer bereichsspezifischer Herausforderungen noch im Anfangsstadium [22, 42]. Dazu gehören eine begrenzte Sensorabdeckung innerhalb des Bodenkörpers, Heterogenität und komplexe Boden-Bauwerk-Interaktionen, die sich nur schwer in einem allgemeinen Modell erfassen lassen.

Dennoch haben die Fortschritte in der Sensortechnologie, der Echtzeit-Datenerfassung und der numerischen Modellierung eine Grundlage geschaffen, auf der digitale Zwillinge für geotechnische Systeme aufgebaut werden können. Im Zusammenhang mit Kaimauern beinhaltet dies die Integration von geotechnischen Instrumenten (z. B. Neigungsmesser, Porendruckaufnehmer, Dehnungsmessstreifen) mit FE-Simulationen, die das Struktur- und Bodenverhalten unter verschiedenen Belastungs- und Randbedingungen darstellen [27]. Hochauflösende Simulationen sind jedoch sehr rechenintensiv und nicht für den Echtzeitbetrieb geeignet. An dieser Stelle kommen KI-Techniken, insbesondere Surrogate-Modelle mit maschinellem Lernen, ins Spiel [26, 7].

Bisher fokussierte sich die Geotechnik auf KI und digitale Zwillinge in folgenden Anwendungsfeldern:

- Modellierung reduzierter Ordnung und Surrogate-Modellierungstechniken (z. B. Kriging, künstliche neuronale Netze, Gauß-Prozesse), die das Ergebnis numerischer Modelle zu einem Bruchteil der Rechenkosten annähern [26, 7, 24, 38].
- KI-gestützte inverse Analyse zur Abschätzung von Bodenparametern oder Randbedin-

gungen anhand weniger Sensordaten [39, 50].

- Erkennung von Anomalien anhand von Zeitreihendaten von geotechnischen Sensoren, häufig auf der Grundlage von unüberwachtem Lernen (z. B. Autocoder oder Clustering-Algorithmen) [31].
- Probabilistische und hybride Ansätze, die physikbasierte Modellierung mit datengesteuertem Lernen kombinieren, um die Vorhersagegenauigkeit und Robustheit unter Unsicherheit zu verbessern [5].

Trotz vielversprechender Fortschritte bleiben die meisten Anwendungen experimentell oder auf den Forschungskontext beschränkt. Der Übergang zu praktischen, operativen Systemen erfordert eine tiefere Integration von physikalischem Verständnis, numerischer Modellierung und maschinellen Lernmethoden. Die vorliegende Arbeit baut auf diesen Entwicklungen auf, indem sie ein KI-gestütztes Überwachungssystem für Kaimauern vorschlägt, das die Ergebnisse numerischer Simulationen nutzt, um Surrogate-Modelle zu trainieren. Diese Modelle ermöglichen eine Echtzeitinterpretation von Sensordaten und prädiktive Einblicke in das geotechnische Verhalten des Bauwerks.

### 3 Hybrides Überwachungssystem für Kaimauern

Der vorgeschlagene Ansatz integriert konventionelle geotechnische Überwachung, numerische Simulationen und KI-basierte Surrogate-Modellierung, um ein reaktionsschnelles und skalierbares Zustandsbewertungssystem für Kaimauern zu ermöglichen. Ziel ist es, von der statischen, beobachtungs-basierten Bewertung zu einem kontinuierlichen, prognostischen und interpretierbaren Überwachungsprozess überzugehen, der auf geotechnischen Prinzipien beruht. Die Funktionsweise eines solchen Überwachungssystems ist in Abbildung 1 skizziert.




Abbildung 1: Hybrides KI-basiertes Überwachungssystem

### 3.1 Überwachungsinputs und relevante Parameter

Die Überwachung von Kaimauern umfasst beispielsweise eine Mischung aus strukturellen und geotechnischen Sensoren:

- Geotechnische Sensoren: Neigungsmesser (seitliche Verschiebung), Piezometer (Porenwasserdruck), Setzungsplatten, Dehnungsmessstreifen in Ankern, Erddruckzellen.
- Umweltsensoren: Gezeitenpegel, Wasserdruck, Wellenschlag, Temperatur.
- Belastungsbezogene Daten: Liegeplatzbelastungen, Verkehr, Auflaständerungen, Betriebsergebnisse.

Spundwandssysteme mit umfangreicher Sensorik für die Echtzeitdatenerfassung werden in der Industrie bereits erprobt [4]. Abbildung 2 zeigt schematisch eine Kaimauer mit einer möglichen Messinstrumentierung. Die aus der Sensorik gewonnenen Datenströme werden in Echtzeit verarbeitet und dienen als Input für das System. Die räumliche Auflösung ist meist begrenzt, sodass die Integration mit Simulationsdaten für die Interpretation des Verhaltens des Gesamtsystems unerlässlich wird.




Abbildung 2: Schematischer Querschnitt einer Kaimauer mit Instrumentierung an der Spundwand

### 3.2 Rolle der numerischen Simulationen

FE-Modelle (z.B. unter Verwendung elastoplastischer oder hypoplastischer Bodenmodelle [17, 18]) simulieren das geotechnische Verhalten der Kaimauer unter verschiedenen Randbedingungen. Diese Modelle dienen als Plattform zur Erzeugung synthetischer Daten für das Training überwachter maschineller Lernalgorithmen [26, 33, 12]. So können beispielsweise Verschiebungsfelder und Spannungsantworten unter verschiedenen Belastungsbedingungen extrahiert werden, um einen weiten Betriebsbereich abzudecken [28, 22]. Die Einbindung von FE-Simulationen zur Erstellung des Surrogate-Modells umfasst folgende Schritte:

- Entwurfsphase: Erstellen eines hochgenauen numerischen Modells der Struktur.
- Szenario-Simulationen: Variation von Parametern wie Auflast, Porendruck und Steifigkeit, um eine Bibliothek von Systemreaktionen zu erstellen.
- Datengenerierung: Simulationsergebnisse (z.B. Verschiebung, Spannungsverteilung, Porenüberdruck) werden als synthetische Daten verwendet, um KI-Modelle zu trainieren [26].

Dabei ist eine Vereinfachung und damit einhergehend mit einem Qualitätsverlust zwingend erforderlich, um die Geschwindigkeit für Echtzeitanwendungen zu erhöhen. Die Überführung von Numerik zum Surrogate-Modell wird in Abbildung 3 aufgegriffen.

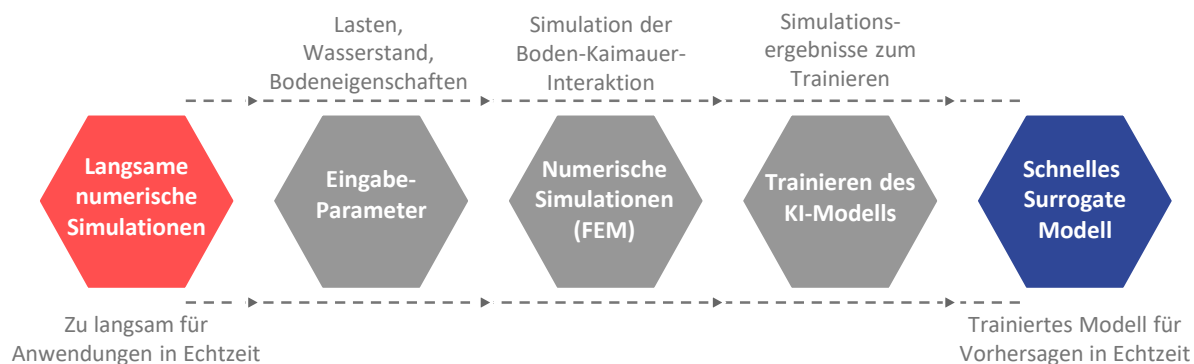


Abbildung 3: Überführung vom numerischen Modell zum digitalen Zwilling

### 3.3 Surrogate-Modellierung und KI-Integration

Surrogate-Modelle (auch bekannt als Emulatoren oder Modelle reduzierter Ordnung) werden anhand der Ergebnisse numerischer Simulationen trainiert. Sie approximieren die Systemantwort mit deutlich geringerem Rechenaufwand [7, 30]. Bei Kaimaueranwendungen haben jüngste Studien gezeigt, wie künstliche neuronale Netze auf FE-Simulationen trainiert werden können, um strukturelle Reaktionsvorhersagen in Echtzeit zu ermöglichen [27]. Andere Arbeiten integrieren Surrogate-Modellierung in hybride Ansätze, um dateneffiziente digitale Zwillinge zu ermöglichen [42, 23, 47]. Mögliche Ansätze sind:

- Vorwärtsgerichtete neuronale Netze zur Abbildung von Eingaben (z. B. Belastung, Wasserstand, Bodenparameter) auf Ausgaben (z. B. Wanddurchbiegung, Ankerkraft) [27].
- Gaußsche Prozessregression (GPR) für Vorhersagen unter Berücksichtigung von Rauschen [49].

- Autoencoder für Dimensionalitätsreduktion und Anomalieerkennung in multivariaten Zeitreihen [31].
- Rekurrente Modelle (z.B. LSTM) für die zeitliche Vorhersage von Verschiebungen oder Porendrücken [39, 10, 8, 11].

Diese Modelle ermöglichen schnelle Vorhersagen (Was passiert bei einer bestimmten Belastung?) und inverse Analysen (Welche Randbedingung oder Steifigkeit erklärt die beobachtete Reaktion?).

### 3.4 Architektur des Hybridsystems

Das Überwachungssystem ist in Abbildung 4 dargestellt und besteht aus den folgenden Ebenen:

- Datenerfassung: Sensorsignale und externe Datenströme.
- Preprocessing: Filterung, Normalisierung, Ausreißererkenkung.
- Modellbasierte Vorhersage: Echtzeit-Surrogate-Modell-Inferenz auf der Grundlage der aktuellen Eingaben.
- Abweichungserkennung: Vergleich zwischen vorhergesagten und gemessenen Werten zur Erkennung von Anomalien oder strukturellen Veränderungen [31].
- Visualisierung und Entscheidungshilfe: Dashboard für Ingenieure mit Zeitreihen, Heatmaps [28], und Alarmschwellen.

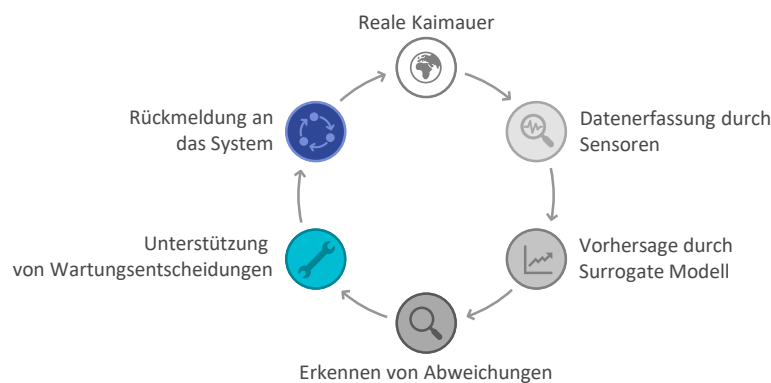


Abbildung 4: Ablauf des Überwachungsprozesses mit Hilfe des Surrogate-Modells

Diese Systemarchitektur unterstützt sowohl die kontinuierliche Zustandsverfolgung als auch ereignisbasierte Alarmer. Sie ist skalierbar und lässt sich an unterschiedliche Kaimauerdesigns und Überwachungseinrichtungen anpassen.

## 4 Herausforderungen und Beschränkungen

Während die Integration von KI und numerischer Modellierung in die Kaimauerüberwachung vielversprechende Möglichkeiten bietet, müssen mehrere Herausforderungen bewältigt werden, bevor solche Systeme zuverlässig in die Praxis umgesetzt werden können.

### 4.1 Datenqualität und Verfügbarkeit

Eine der größten Herausforderungen bei geotechnischen Anwendungen ist die begrenzte Verfügbarkeit und Qualität von Überwachungsdaten. Im Gegensatz zu Strukturelementen, die leicht instrumentiert und beobachtet werden können, ist es von Natur aus schwierig, Bodenbedingungen direkt und kontinuierlich zu messen. Sensoren können unter Drift, Rauschen oder Ausfällen leiden, und die räumliche Auflösung ist oft grob [46, 45, 2]. Zwar gibt es den steigenden Trend, Datensätze öffentlich frei zugänglich zu machen [9, 15], jedoch stellt die Datenknappheit nach wie vor eine große Herausforderung für das Training von datenintensiven maschinellen Lernmodellen dar, insbesondere für solche, die auf überwachtem Lernen beruhen[31].

Qualitativ hochwertige Sensordaten sind für das Modelltraining und die Inferenz entscheidend. Geotechnische Sensoren leiden jedoch häufig unter geringer räumlicher Auflösung, Rauschen oder Datenlücken aufgrund rauer Umgebungen [5, 37]. Diese Einschränkungen können sich auf Surrogate-Modelle auswirken und die Zuverlässigkeit der Vorhersage verringern. Fortschrittliche Strategien zur Datenimputation und Fusion mit simulierten Daten können helfen, diese Lücken zu schließen [34].

### 4.2 Kalibrierung und Gültigkeit numerischer Modelle

Die Leistung des Surrogate-Modells hängt stark von der Qualität der zugrunde liegenden numerischen Simulationen ab. Diese Simulationen müssen anhand verfügbarer Feld- oder Labordaten kalibriert werden, und Vereinfachungen bei der Modellierung der Bodenbeschaffenheit, der Randbedingungen oder der Netzauflösung können zu Verzerrungen führen [16, 14]. Wenn das FE-Modell das tatsächliche Verhalten der Kaimauer nicht hinreichend wiedergibt, werden diese Ungenauigkeiten durch das Surrogate-Modell, das anhand seiner Ergebnisse trainiert wird, weitergegeben [26].

### 4.3 Verallgemeinerung und Übertragbarkeit

Surrogate-Modelle sind systemspezifisch. Ihre Fähigkeit zur Verallgemeinerung auf unterschiedliche Kaimauergeometrien, Bodenprofile oder Belastungsszenarien ist begrenzt, es sei denn, sie werden explizit für solche Variabilitäten trainiert. Die Entwicklung robuster und verallgemeinerungsfähiger KI-Modelle würde ein Training mit einem großen und vielfältigen Datensatz von

Simulationsergebnissen und Überwachungsszenarien erfordern, was in der Geotechnik oft nicht möglich ist. Robustes Training erfordert eine sorgfältige Auswahl des Eingaberaums [35, 25] und kann von Ensemble-Modellierung [32] oder aktiven Lernstrategien [29] profitieren.

#### **4.4 Interpretierbarkeit und Vertrauen**

Viele Modelle des maschinellen Lernens, insbesondere tiefe neuronale Netze, werden als Black-boxen betrachtet und bieten nur einen begrenzten Einblick, warum eine bestimmte Vorhersage getroffen wurde. Dieser Mangel an Interpretierbarkeit ist ein entscheidendes Hindernis für die Akzeptanz. Bemühungen wie erklärbare KI (Explainable Artificial Intelligence - XAI) oder die Kombination datengesteuerter Methoden mit physikalisch interpretierbaren Surrogate-Modellen (z. B. basierend auf dimensional reduzierten FEM-Ergebnissen) sind notwendig, um Vertrauen aufzubauen [39]. Bei sicherheitskritischen geotechnischen Anwendungen ist die Erklärbarkeit von Vorhersagen entscheidend für die Akzeptanz durch die Ingenieure. Abbildung 5 zeigt eine Möglichkeit der Ergebnisdarstellung. Techniken wie Shapley-Werte, Sensitivitätsanalysen oder interpretierbare Surrogate-strukturen wie polynomiale Chaos-Expansionen oder Kriging werden zunehmend erforscht [3, 48, 13].

#### **4.5 Integration in bestehende Arbeitsabläufe**

Schließlich ist die praktische Integration von KI-basierten Überwachungssystemen in den realen Hafetrieb nicht trivial. Sie erfordert:

- die Einbindung in bestehende Sensornetzwerke und Kontrollsysteme,
- die Gewährleistung der Datensicherheit und Langzeitspeicherung,
- die Entwicklung intuitiver Benutzeroberflächen und
- die Erstellung von Protokollen für die Alarmbearbeitung und Reaktion.

Diese Implementierungsaspekte sind ebenso wichtig wie die Modellierungsarbeit und werden in der Frühphase der Forschung oft unterschätzt [28].

### **5 Fazit und Ausblick**

In diesem Beitrag wurde ein hybrider Ansatz für die KI-gestützte Überwachung von Kaimauern skizziert, der die Synergie zwischen hochgenauen numerischen Simulationen und datengesteuerten Surrogate-Modellen hervorhebt. Durch die Nutzung von Simulationsergebnissen zum




Abbildung 5: Vorhersage im Vergleich zu Messungen: Verlauf der Verlustfunktion (links), Vergleich Vorhersage gegenüber echte Werte (rechts)

Trainieren von KI-Modellen können Ingenieure reaktionsschnelle Echtzeit-Überwachungssysteme aufbauen, die eine enge Verbindung zum physikalischen Verständnis aufrechterhalten und gleichzeitig die rechnerischen Beschränkungen von numerischen Analysen in großem Maßstab überwinden. Der vorgeschlagene Ansatz unterstützt sowohl die Vorwärtsprognose (z. B. die Abschätzung von Verformungen unter zukünftigen Belastungsbedingungen) als auch die inverse Analyse (z. B. die Identifizierung von abnormalem Verhalten auf der Grundlage beobachteter Reaktionen). Dieser Ansatz bildet die Grundlage für einen geotechnisch informierten digitalen Zwilling, der eine effizientere Instandhaltungsplanung, eine frühzeitige Warnung vor geotechnischen Versagensmechanismen und eine kontinuierliche Zustandsbewertung der maritimen Infrastruktur ermöglicht. Die Umsetzung dieses Ansatzes in die Praxis erfordert jedoch die Bewältigung von Herausforderungen bei der Datenqualität, der Modellverallgemeinerung und dem Vertrauen.

Insgesamt bietet die verantwortungsvolle Anwendung von KI in der Geotechnik die Möglichkeit, die Lebensdauer kritischer Infrastrukturen zu verlängern, die Inspektionskosten zu senken und die Sicherheit zu verbessern - vorausgesetzt, sie basiert auf einem soliden Verständnis der Boden-Bauwerk-Interaktion und wird mit fundiertem ingenieurtechnischem Urteilsvermögen kombiniert.

## Literatur

- [1] M. A. Abdennadher. Virtual experiments on coarse-grained soil using x-ray ct and finite element analysis. In *Proceedings of The Rocscience International Conference 2025 (RIC2025)*, Sydney, Australia, 2025.
- [2] M. A. Abdennadher, F. Williams Riquer, D. A. Dao, and J. Grabe. Data-driven modeling of structural dynamics: Improving measurement noise robustness with augmented dynamic mode decomposition. In *Proceedings of the 10th International Conference on Computational Methods in Structural Dynamics and Earthquake Engineering (COMPdyn 2025)*, Rhodes Island, Greece, 2025. Paper No. 24480.

- [3] T. Al-Bittar and A.H. Soubra. Bearing capacity of strip footings on spatially random soils using sparse polynomial chaos expansion. In *Geo-Risk 2011: Risk Assessment and Management*, pages 279–286, 2011.
- [4] ArcelorMittal Spundwand. Smartsheetpile: Intelligente lösungen aus stahl für innovative infrastrukturen. Broschüre, 2025. Abgerufen im März 2025.
- [5] A. Baghbani, T. Choudhury, S. Costa, and J. Reiner. Application of artificial intelligence in geotechnical engineering: A state-of-the-art review. *Earth-Science Reviews*, 228:103991, 2022.
- [6] B. Bienen, S. Fan, M. Schröder, and M. F. Randolph. Effect of the installation process on monopile lateral response. In *Proceedings of the Institution of Civil Engineers – Geotechnical Engineering*, 2021.
- [7] Á. Bárkányi, T. Chován, S. Németh, and J. Abonyi. Modelling for digital twins—potential role of surrogate models. *Processes*, 9(3):476, 2021. A review outlining how data-driven surrogate models (e.g. neural networks, Gaussian processes) can support digital twin development for engineering systems.
- [8] K. Cerek, D. A. Dao, E. Hadjiloo, and J. Grabe. Application of lstm time series forecasting method for predicting compression curves of soil. In *Proceedings of the 17th Pan-American Conference on Soil Mechanics and Geotechnical Engineering*, La Serena, Chile, 2024.
- [9] K. Cerek, D. A. Dao, E. Hadjiloo, and J. Grabe. Dataset of simulated crs tests for advanced soil parameter identification. Datensatz, 2024.
- [10] K. Cerek, A. Gupta, D. A. Dao, E. Hadjiloo, and J. Grabe. Python implementation of bidirectional lstm for sequential data processing. Source Code, 2024.
- [11] K. Cerek, A. Gupta, D. A. Dao, E. Hadjiloo, and J. Grabe. Predicting soil stress–strain behaviour with bidirectional long short-term memory networks. *Machine Learning and Data Science in Geotechnics*, 1(1):59–76, 2025.
- [12] K. Cerek, E. Hadjiloo, J. Grabe, and D.A. Dao. Optimization of drag embedment anchors applying multi-objective evolutionary algorithm nsga-ii. *Journal of Ocean Engineering and Science*, 2025.
- [13] D. Chicco, M.J. Warrens, and G. Jurman. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. *PeerJ Computer Science*, 7:e623, 2021.
- [14] D. A. Dao, D. Alkateeb, and M. Schröder. Discrepancies between element tests and large-scale ldf simulations: a case study on anchor kinematics during installation in clay. *Computers and Geotechnics*, 163:105698, 2023.
- [15] D. A. Dao and M. Banduch. Geotechnical laboratory investigation on the baltic sea sand sample z\_vc\_011. Datensatz, 2023.
- [16] D. A. Dao and K. Dicke. Numerical investigation of drag embedment anchor model reduction for fowts in coarse and fine-grained baltic sea soil. In *Proceedings of the 5th International Conference on Geotechnics for Sustainable Infrastructure Development (GEOTEC 2023)*, Hanoi, Vietnam, 2023. Vietnamese Society for Soil Mechanics and Geotechnical Engineering.

- [17] D. A. Dao, K. Dicke, and J. Grabe. Investigation of anchor installation for floating offshore wind turbines. In M. et al. Chung, editor, *Proceedings of the 10th International Conference on Physical Modelling in Geotechnics (ICPMG 2022)*, pages 482–485, Daejeon, Korea, 2022. Korea Geotechnical Society.
- [18] D. A. Dao and J. Grabe. Numerical investigation of ship anchor kinematics: Implication on subsea cable burial. *Ocean Engineering*, 314:119674, 2024.
- [19] D. A. Dao, A. Struve, and J. Grabe. Numerical investigation on the effect of anchor modelling on anchor chain-soil interaction for floating offshore wind turbines. In *Proceedings of the 15th International Symposium on Practical Design of Ships and other Floating Structures (PRADS 2022)*, pages 1673–1684, Dubrovnik, Croatia, 2022.
- [20] D. A. Dao, M. Tafili, J. Grabe, and T. Wichtmann. Simulation of large displacements during pile installation in anisotropic cohesive soil. In *Proceedings of the 77th Canadian Geotechnical Conference (GeoMontréal 2024)*, Montréal, Canada, 2024.
- [21] D. A. Dao, M. Tafili, F. Williams-Riquer, J. Grabe, and T. Wichtmann. Large deformation simulations of structure-soil-interaction in anisotropic fine-grained soils. *Computers and Geotechnics*, 2025.
- [22] Shao-Lin Ding, Jia-Jun Pan, Yanli Wang, Han Xu, Dian-Qing Li, and Xin Liu. Developing a digital twin for dam safety management. *Computers and Geotechnics*, 180:107120, 2025.
- [23] Armin Dadras Eslamlou and Shiping Huang. Reinforcement learning for multi-objective automl in vision-based structural health monitoring. *Automation in Construction*, 166:105593, 2024.
- [24] A.I.J. Forrester, A. Sóbester, and A.J. Keane. *Engineering design via surrogate modelling: A practical guide*. Wiley, 2008.
- [25] J.H. Halton. On the efficiency of certain quasi-random sequences of points in evaluating multi-dimensional integrals. *Numerische Mathematik*, 2(1):84–90, 1960.
- [26] X. He, F. Wang, W. Li, and D. Sheng. Efficient reliability analysis considering uncertainty in random field parameters: Trained neural networks as surrogate models. *Computers and Geotechnics*, 136:104212, 2021. Uses artificial neural network surrogates to replace expensive FE analyses in geotechnical reliability computations, improving efficiency under soil variability.
- [27] S. C. Jayasinghe et al. Innovative digital twin with artificial neural networks for real-time monitoring of structural response: A port structure case study. *Ocean Engineering*, 312:119187, 2024. Demonstrates a port quay wall digital twin using ANN surrogates for real-time structural response monitoring.
- [28] C. H. Jeon, C. S. Shim, Y. H. Lee, and J. Schooling. Prescriptive maintenance of prestressed concrete bridges considering digital twin and key performance indicator. *Engineering Structures*, 302:117383, 2024. Introduces a digital twin-driven approach to bridge maintenance, using real-time monitoring data and KPIs to schedule proactive maintenance interventions.
- [29] C. Kamath. Intelligent sampling for surrogate modeling, hyperparameter optimization, and data analysis. *Machine Learning with Applications*, 9:100373, 2022.

- [30] K Khaledi, S Miro, M König, and T Schanz. Robust and reliable metamodels for mechanized tunnel simulations. *Computers and Geotechnics*, 61:1–12, 2014.
- [31] T. Lee, S.-S. Jin, S. T. Kim, and J. Min. Online anomaly detection for long-term structural health monitoring of caisson quay walls. *Engineering Structures*, 323:119197, 2025. Develops an online algorithm to detect abnormal behavior in time-series data from quay wall sensors, enabling early identification of structural anomalies in a port environment.
- [32] Y. Liu, X. Li, X. Liu, and Z. Yang. A combined shear strength reduction and surrogate model method for efficient reliability analysis of slopes. *Computers and Geotechnics*, 152:105021, 2022.
- [33] Zihao Liu, Qian Fang, Yi Shen, Qing Ai, Hui Wang, Xingchun Huang, and Yong Yuan. Two-stage surrogate modeling strategy for predicting foundation pit excavation-induced strata and tunnel deformation. *Tunnelling and Underground Space Technology*, 151:105845, 2024.
- [34] M.K. Lo and Y.F. Leung. Bayesian updating of subsurface spatial variability for improved prediction of braced excavation response. *Canadian Geotechnical Journal*, 56(8):1169–1183, 2019.
- [35] M. McKay, R. Beckman, and W. Conover. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2):239–245, 1979.
- [36] Michael Niebler, Stylianos Chrisopoulos, Roberto Cudmani, and Daniel Rebstock. A general framework to simulate soil–structure interface behaviour using advanced constitutive models. *Modelling*, 6(1):11, 2025.
- [37] K.-K. Phoon and W. Zhang. Future of machine learning in geotechnics. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 17(1):7–22, 2022.
- [38] Nestor V Queipo, Raphael T Haftka, Wei Shyy, Tushar Goel, Rajkumar Vaidyanathan, and P Kevin Tucker. Surrogate-based analysis and optimization. *Progress in aerospace sciences*, 41(1):1–28, 2005.
- [39] B. B. Sheil. Hybrid framework for forecasting circular excavation collapse: Combining physics-based and data-driven modeling. *Journal of Geotechnical and Geoenvironmental Engineering (ASCE)*, 147(12):04021157, 2021. Presents a hybrid modeling approach where machine-learning models are coupled with conventional soil mechanics simulations to predict retaining wall (excavation) stability, exemplifying the observational method in geotechnics.
- [40] M. Stapelfeldt, D. Alkateeb, J. Grabe, and B. Bienen. Numerical simulation of cone penetration tests inside suction caisson foundations in sand. In *Proceedings of the ASME 2020 39th International Conference on Ocean, Offshore and Arctic Engineering, Volume 10: Offshore Geotechnics*, aug 2020.
- [41] M. Tafili, D. A. Dao, J. Grabe, and T. Wichtmann. Simulation of large displacements during lateral pile loading in anisotropic, overconsolidated fine-grained soils. In *Proceedings of the 5th International Symposium on Frontiers in Offshore Geotechnics (ISFOG 2025)*, number 61, Nantes, France, 2025. International Society for Soil Mechanics and Geotechnical Engineering.
- [42] Xiong Wang, Yue Pan, and Jinjian Chen. Digital twin with data-mechanism-fused model for smart excavation management. *Automation in Construction*, 168:105749, 2024.

- [43] P Wiesenthal and S Henke. Numerical investigation of soil plugging in clay with the cel method and effective contact stresses. 2025.
- [44] Philipp Wiesenthal and Sascha Henke. Concept on plug development in jacked open-ended piles in clay considering total stresses. *Acta Geotechnica*, 20(3):1019–1033, 2025.
- [45] F. Williams Riquer, M. A. Abdennadher, A. Chmelnizkij, J. Grabe, and K. Smarsly. Modeling and predicting soil vibrations during vibrodriving installation using noisy data and dynamic mode decomposition. In *Proceedings of the 11th International Conference on Experimental Vibration Analysis of Civil Engineering Structures (EVACES 2025)*, Porto, Portugal, 2025.
- [46] F. Williams-Riquer, A. Chmelnizkij, D. Alkateeb, and J. Grabe. Prediction of induced soil vibration during pile vibrodriving using dynamic mode decomposition (dmd). *Journal of Physics: Conference Series*, 2909(1):012002, 2024.
- [47] F. Williams Riquer, D. A. Dao, and J. Grabe. Towards the development of a digital twin for subsoil monitoring and stability against overturning of a mobile drilling rig. In *Proceedings of the International Symposium on Automation and Robotics in Construction (ISARC 2022)*, pages 207–214, Bogota, Colombia, 2022.
- [48] J. Zhang, H.W. Huang, and K.K. Phoon. Efficient response surface method for practical geotechnical reliability analysis. *Computers and Geotechnics*, 69:496–505, 2015.
- [49] JHHW Zhang, HW Huang, and KK Phoon. Application of the kriging-based response surface method to the system reliability of soil slopes. *Journal of Geotechnical and Geoenvironmental Engineering*, 139(4):651–655, 2013.
- [50] H. Zheng, M. Mooney, and M. Gutierrez. Updating model parameters and predictions in sem tunnelling using a surrogate-based bayesian approach. *Géotechnique*, 74(13):1855–1867, 2024.

## Author

Kacper Cerek  
 Technische Universität Hamburg  
 Institut für Geotechnik und Baubetrieb  
 Schellerdamm 22-24  
 21079 Hamburg  
 e-mail: kacper.cerek@tuhh.de



# **Intelligente Zukunft: KI-gestützte Innovationen im Bauwesen am Beispiel des STRABAG-Konzerns**

**Marina Ivanova, Jörg Schreiber**

**Abstract:** Technologieführerschaft ist ein zentraler Bestandteil der Strategie 2030 der STRABAG SE. Neben dem Einsatz von KI-Technologien initiiert der Konzern zukunftsweisende Projekte und bringt seine internen KI-Innovationen zur Marktreife. Das erste Beispiel für den gezielten Einsatz von KI bei STRABAG ist DARIA, die datengestützte Risikoanalyse, eine digitale Lösung für laufende Straßenbauprojekte. DARIA ermöglicht es Controllern, finanzielle Risiken frühzeitig zu erkennen und objektive Prognosen für Bauprojekte zu erhalten. Damit leistet das Tool einen wesentlichen Beitrag zur Qualitätskontrolle und macht die finanziellen Risiken von Bauprojekten transparenter. Der Abschnitt enthält auch einen Ausblick auf die Ausweitung von DARIA auf andere Geschäftsbereiche und Projektphasen. Abschließend wird das Tool GD Excavation Pit beschrieben. Dabei handelt es sich um ein Programm, das mit Hilfe von generativem Design automatisch einen Entwurf für eine Baugrube optimieren kann. Zu diesem Zweck wird die Berechnungsdatei einer Statiksoftware importiert und anschließend werden auf dieser Grundlage zahlreiche Varianten des Verbau-Systems unter Einsatz eines Partikelschwarmoptimierers generiert und bewertet.

## **Autoren**

M. Sc. Marina Ivanova  
STRABAG Innovation & Digitalisation  
Donau-City-Str. 9  
1220 Vienna, Austria

Dr.-Ing. Jörg Schreiber  
Ed. Züblin AG  
Zentrale Technik  
Albstadtweg 3  
70567 Stuttgart



# **Die Zukunft des digitalen Lean bei Drees & Sommer SE – Der Weg von analog über digital, smart und autonom bis zum ultraeffizienten Bauprojekt**

**Jan Onne Backhaus**

**Kurzfassung:** Getragen von dem Erfolg in der Automobilindustrie etablierte sich Lean rasch in der stationären Industrie und legte damit den Grundstein für seinen späteren Einzug in die instationären Branchen, allen voran die Bauwirtschaft. Dieser Artikel resümiert nach zwei Jahrzehnten Lean Construction Management (LCM®) den aktuellen Stand und versucht eine Antwort auf die Frage zu finden, was Lean Construction ist und wie das Lean der Zukunft aussehen wird.

Diese Prognose nimmt Bezug zu den aktuellen, technischen Entwicklungen in der Bauindustrie. Der Grad der Digitalisierung, Automatisierung und Autonomisierung verändert den Alltag auf unseren Baustellen und damit auch die Art und Weise, in der Lean Project Delivery Wert erzeugt. Das Ziel ist das ultraeffiziente Projekt – eine Nordsternvision, deren Erreichung vielleicht näher liegt, als vermutet. Bevor diese Vision erreicht werden kann, müssen Unternehmen fünf Lean-Zeitalter durchleben. Unabhängig davon, in welchem Zeitalter sich ein Unternehmen gerade befindet, wird der Schlüssel zum Erfolg die Verankerung der Lean-Kultur auf der Strategieebene sein. Erst wenn Lean seine Rolle als reines Service- und Dienstleistungsprodukt verliert und zentraler Teil der Strategie und Kultur eines Unternehmens wird, wird es diesem gelingen, alle Mitarbeitenden der Organisation zu erreichen und das enorme Skalierungspotential zu entfalten, dass für die anstehende Transformation notwendig ist.

Dieser Artikel baut auf der Zukunftsvision für Lean Project Delivery von Drees und Sommer auf (Drees und Sommer SE, 2022) und beleuchtet die Evolution von Lean – von analogen Anfängen über digitale und smarte Ansätze bis hin zur autonomen Phase und dem Ziel des ultraeffizienten Bauprojekts.

## **1 Eine kurze Geschichte von Lean Construction**

Die Geschichte von Lean beginnt mit den Anfängen der Massenproduktion in der Automobilindustrie. Fords System basierte auf dem Fließband und folgte den Prinzipien der Standardisierung und Spezialisierung der Arbeiter, um die Effizienz zu maximieren. Die Möglichkeit, die Kosten für komplexe Konsumgüter (wie Autos) erheblich zu senken, führte zum enormen Erfolg von Fords Massenproduktionssystem: Nur zwei Jahrzehnte nach der Einführung des Fließbands im Jahr 1913 besaß über die Hälfte aller amerikanischen Haushalte ein Auto. (Ford, 2008)

Nach dem Ende des Zweiten Weltkriegs führten die Einschränkungen des japanischen Marktes – kleine Stückzahlen verschiedener Modelle bei geringer Nachfrage zu produzieren – dazu, dass japanische Unternehmen eine angepasste Version von Fords Massenproduktion entwickelten: Das Toyota-Produktionssystem (TPS). Der wichtigste Beitragende zum TPS war Taiichi Ōno, ein Maschinenbauingenieur, der 1943 ohne Vorerfahrung in der Automobilproduktion zu Toyota kam. Im Gegensatz zur Massenproduktion bei Ford konzentrierte sich TPS auf kleine Losgrößen und kurze Rüstzeiten der Maschinen, um genau die richtige Menge des richtigen Produkts zur richtigen Zeit herzustellen – also Just-in-Time (JIT). Das übergeordnete Ziel war die Kostensenkung durch die Beseitigung von Verschwendung mithilfe der zwei Prinzipien: Autonome Automatisierung und Just-in-Time. (Ōno, 1978/2013)

Trotz des großen Erfolgs des TPS und der Verfügbarkeit begleitender Handbücher ab den frühen 1970er Jahren war das Interesse der westlichen Forschungsgemeinschaft an TPS zunächst gering. Dies änderte sich 1979, als der Leistungsunterschied zwischen TPS-gesteuerten japanischen Unternehmen und US-Firmen im Ford-Stil deutlich wurde. Dies führte zur Gründung des „International Motor Vehicle Program“ am MIT. 1990 veröffentlichten drei Forscher dieses Programms, James Womack, Daniel Jones und Daniel Roos, ein Buch basierend auf ihren Erkenntnissen: „The Machine that Changed the World.“ Dieses Buch prägte den Begriff „Lean“. (Womack, Jones and Ross, 1990/2007)

Zwei Jahre nach der Veröffentlichung von „The Machine That Changed the World“ wurde das Lean-Konzept von Wissenschaftler:innen der Bauindustrie übernommen. Der Begriff „Lean Construction“ wurde 1992 erstmals von Lauri Koskela in seinem Technical Report No. 72 verwendet (Koskela, 1992). Dieser beschrieb die Anwendung der neuen Produktionsphilosophie auf den Bausektor. Während der 25 Jahre, die seit Koskelas Veröffentlichung vergangen sind, hat sich Lean Construction immer weiter den tatsächlichen Bedürfnissen der Bauindustrie angepasst. Ganz vorne mit dabei waren Firmen wie Drees und Sommer und Porsche Consult. Diese trugen wesentlich dazu bei, Lean in Deutschland auf die Baustellen zu bringen.

Der Artikel beleuchtet die Evolution von Lean – von analogen Anfängen über digitale und smarte Ansätze bis hin zur autonomen Phase und dem Ziel des ultraeffizienten Bauprojekts. (Drees und Sommer SE, 2022)

## **2 Analoges Lean**

Die Adaption von Lean aus der stationären auf die instationäre Industrie begann bei Drees und Sommer ab 2006. Lean war zunächst ein Dienstleistungsprodukt für die Ausführungsphase, das geeignet war, die Effizienz in den Bauprojekten zu steigern. Das Ziel der adaptierten Lean Methoden war es, die Transparenz im Projekt zu verbessern, die Bauzeit zu verkürzen, Terminstabilität als auch -treue zu erhöhen und die Kollaboration im Projekt im Allgemeinen zu verbessern. Während die Zielkunden zunächst vor allem Bauherren waren, erkannten bald auch andere Baubeteiligte die Vorteile der Denk- und Arbeitsweise von Lean Construction Management (LCM<sup>®</sup>). LCM<sup>®</sup> fand sich bald auch in Methodenbaukästen vieler Bauunternehmen, Anlagen-

bauer, Nachunternehmern und Bauzulieferern. Die drei grundsätzlichen Methoden von LCM<sup>®</sup> – Gesamtprozessanalyse, Prozessplanung und Feinplanung – sind seitdem fester Bestandteil vieler Lean-Workshops. (Backhaus, 2022)

Während der *Gesamtprozessanalyse* wird die Geometrie des Bauwerks analysiert und in leicht verständliche Gleich- und Taktbereiche unterteilt. Anhand dieser wird dann die Reihenfolge der Tätigkeiten – die Prozesssequenz – kollaborativ mit Haftnotizen auf einem Brownpaper ermittelt.

Im Zuge der *Prozessplanung* wird die Prozesssequenz auf die Zeitebene gehoben. Aus taktbaren und nicht taktbaren Bereichen entsteht ein mit allen abgestimmter Terminplan für die Bauausführung.

Die Terminsteuerung findet in der *Feinplanung* mit der Plantafel auf der Baustelle statt (Abbildung 1). Die Baubeteiligten treffen sich in täglichen und wöchentlichen Besprechungen, um den SOLL-IST-Abgleich durchzuführen und drohende Planabweichungen früh genug zu erkennen, um effektiv gegensteuern zu können. Als Resultat findet eine kontinuierliche Auseinandersetzung aller Beteiligten mit der Ablaufoptimierung des Projektes statt.



Abbildung 1: Die Plantafel ist ein Kanban-Steckkartensystem und bildet das Zentrum der Wochen- und Detailplanung. Kanban-Systeme wurden von Drees und Sommer, als eines der ersten Unternehmen weltweit auf den Baustellen eingesetzt. (Bildquelle: Lingg, 2025)

Mit der Entwicklung von *Lean Design* wurden die bewährten Methoden des LCM<sup>®</sup> auf die frühen Leistungsphasen angepasst. Ziel ist eine Optimierung der Planung der Planung durch Methoden wie beispielsweise dem Target Value Design, Agile Design Management und dem Last Planner System für die Planung. Zudem wird das Gebäude an sich optimiert, indem beispielsweise modular geplant wird.

Fast zeitgleich zu LCM<sup>®</sup> entstand das *Last Planner System* (LPS<sup>®</sup>), siehe Ballard (2000), und die *Taktplanung und Taktsteuerung* (TPTS), siehe VDI (2553). Kollaboration und Kooperation sind das Ziel des LPS. Die Letzten Planer sind die letzten an der Bauausführungsplanung beteiligten

Personen – häufig Poliere, Meister oder Bauleiter. Diese kommen zusammen, um gemeinsam den Bauablauf zu entwerfen. Das LPS sorgt im allgemeinen für ein sehr positives Erleben des Planungsprozesses durch die Letzten Planer und ein qualitativ gutes, aber schwer messbares Ergebnis. Die Taktplanung wird meist von der Arbeitsvorbereitung durchgeführt und kann je nach Vorgehensweise unterschiedlich strikt oder kollaborativ umgesetzt werden. Sie liefert direkt messbare Ergebnisse, erfordert jedoch im Projektverlauf mehrere Anpassungen. Durch die Einbindung der Firmen während der Bauausführung ermöglicht die Taktsteuerung ein agiles Reagieren auf Entwicklungen im Projekt.

LCM<sup>®</sup> ist im Vergleich zu LPS und TPTS eine hybride Methode, bei der zu Projektbeginn ein Taktplan erstellt und das Bauvorhaben mit einem Steckkartensystem direkt auf der Baustelle umgesetzt wird. Die Firmen sind kontinuierlich in die Planung eingebunden, was besonders bei großen, komplexen Projekten Vorteile bringt. Die Wahl der passenden Methode sollte abhängig von Projektgröße, Komplexität und Beteiligten erfolgen. Ziel aller Lean-Methoden ist es, Arbeit sichtbar zu machen, um Risiken früh zu erkennen und stabile, verlässliche Prozesse zu schaffen. So lassen sich insbesondere Terminabweichungen – die größte Verschwendung im Bau – deutlich verringern.

### 3 Digitales Lean

Im digitalen Lean geht es vor allem um das Sammeln und Verfügbarmachen echter Projektdaten, wie beispielsweise Aufwandswerte, Besprechungsprotokolle und Aktionslisten oder Prozesssequenzen und -dauern. Der Fokus liegt auf einer optimierten Kommunikation und der Möglichkeit in Echtzeit mit aktuellen Daten virtuell zusammenzuarbeiten. Die Lean Berater:innen versuchen alles, was zuvor im physischen Raum geschah, im digitalen Raum nachzubilden – das schließt das emotionale Erleben der Lean-Workshops mit ein. Die Voraussetzung hierfür ist, dass die Lean Methoden selbst – insbesondere das LPS – vollständig digitalisiert ist.

Das digitale Lean-Zeitalter begann bei Drees und Sommer um 2015 herum und markiert den Zeitpunkt der ersten Versuche, Gesamtprozessanalyse, Prozessplanung und Feinplanung digital abzubilden. Zu diesem Zeitpunkt gab es bereits anfängliche, digitale Einzellösungen. Die *Taktplanung* wurde von Anwender:innen der Methode bereits in Tabellenkalkulationsprogrammen, zum Beispiel MS Excel, modelliert. Parallel entstanden die ersten Softwarelösungen, die das Erstellen einer Taktplanung unterstützten oder vereinfachen sollten. Für die *Taktsteuerung* bietet der Markt bereits vielversprechende Lösungen, die hybride Arbeiten ermöglichen. Der IST-Zustand der Baustelle wird über digitale Werkzeuge in-situ erhoben und über die Softwarelösung allen Baubeteiligten in den Taktsteuerungsbesprechungen live zur Verfügung gestellt.

Während erste Versuche bei Drees und Sommer sich noch work-arounds mit sperrig zu bedienenden Makros für MS Visio bedienten, wurde um 2019 die Firma LCM Digital (LCMD, 2025a) aus dem Drees und Sommer Innovation Center heraus gegründet. Die cloudbasierte Software LCM Digital verbindet die Baubeteiligten von der Planung bis zur Ausführung mit Hilfe der Lean-Prinzipien miteinander. Sie bildet LCM<sup>®</sup> nach und verbessert so die Kommunikation,

Zusammenarbeit und Feedback-Zyklen. Damit ist LCM Digital eine der wenigen Lösungen weltweit, der es gelungen ist, sowohl Taktplanungen zu erstellen, als auch live Kollaboration in der digitalen Taktsteuerung zu ermöglichen. (Abbildung 2)



Abbildung 2: Digitale Taktplanung mit LCMD. Das Bild zeigt die Vorschau einer prozessoptimierten Taktplanung mit der dazugehörigen Kapazitätskurve. (Bildquelle: LCMD, 2025b)

Wie auch in der physischen Bauwelt lag der Fokus des digitalen Lean zunächst auf der Ausführungsphase. Seit 2020 nimmt die Anzahl der Lösungen für die früheren Leistungsphasen sichtbar zu. Vorhandene Softwarelösungen, wie beispielsweise LCM Digital, adaptierten ihre existierenden Lösungen auf die frühen Phasen. Newcomer im Lean Markt adaptieren zudem für die Planungsphasen erprobte Werkzeuge auf den digitalen Raum. So erprobte das Start-Up Anchor Decisions die Methode *Choosing by Advantages* als digitale Lösung zur Vereinfachung von Entscheidungsprozessen im Projektmanagement. Beeboard ist eine Lösung, die die Transparenz des Projektes über alle Leistungsphasen auf der Basis der Lean-Prinzipien erhöht (Dunker, 2022).

Die große Schwierigkeit bei der Digitalisierung der Planungsphase besteht in der richtigen Adaption des Last-Planner-Systems oder Agiler Methoden. Besprechungsergebnisse, Protokolle, Planungsentscheidungen und Termine müssen mit konkreten Aktivitäten und Prozessschritten verknüpft werden. Dabei soll die entstehende Information eine hohe Qualität haben, dass heißt sie soll aktuell, leicht verständlich, widerspruchsfrei, zugänglich und kontextbezogen sein. Da die Komplexität von Planungsaufgaben häufig erst während der Planung selbst klar wird, stellt die Abschätzung der Dauer einzelner Planungsschritte eine besondere Herausforderung dar.

Im Vergleich zur stationären Industrie ist die Bauindustrie mit der Digitalisierung analoger Shopfloor-Prozesse recht weit. Während erstere weiterhin an der Digitalisierung des Shopfloor-Managements arbeitet, finden sich in der Bauindustrie gute Lösungen für leane Prozesssysteme, wie dem Last-Planner-System, der Taktplanung und Taktsteuerung. Projektdaten werden in-situ erfasst und können weltweit zeitgleich in hybriden Workshops und Besprechungen bearbeitet werden. Aktuell wird häufig ein hybrider Ansatz aus vor Ort und virtuellen Workshops und Regelbesprechungen gelebt. Die Corona-Pandemie wirkte als Beschleuniger für die digitalen Lösungen – sowohl technisch als auch auf der Seite der Anwender:innen, deren Bereitschaft, sich

auf digitale Formate einzulassen, nach der Pandemie stark gestiegen ist. LCM<sup>®</sup> geht davon aus, dass kollaborative Zusammenarbeit und eine hohe Transparenz bei Prozessen und Aufgaben, die treibenden Erfolgselemente von Bauprojekten sind. Da es am Ende immer Menschen sind, die mit den Methoden zur Kollaboration gebracht werden, empfiehlt Drees und Sommer weiterhin den Einstieg mit haptischen Formaten – denn in Präsenz und im Kontakt zu anderen Menschen lassen sich die Lean-Methoden am besten erleben und verinnerlichen.

In der Summe wird die Terminplanung im digitalen Lean-Zeitalter verlässlicher. Die existierenden Werkzeuge sind leicht zu bedienen, schnell auswertbar und erlauben es Entscheidungen auf der Basis von hochwertigen Informationen zu treffen. Wie auch in anderen Industrien gilt im Bau: "Daten sind das neue Öl".

## 4 Smartes Lean

Laut einer Studie des Softwareherstellers Autodesk in Zusammenarbeit mit dem Beratungshaus Deloitte erzeugt die Bauindustrie täglich eine Datenmenge von über 2.5 Millionen Terabytes (Peccolo, 2024). Die aus diesen Datenschätzen erwachsenden Möglichkeiten sind enorm. Die Bauindustrie steht nun vor der Herausforderung, diese Daten systematisch zu sammeln und auszuwerten. Smartes Lean Construction ist bereits Teil der Visionen der meisten Hersteller leaner Softwareprodukte. Während bei dem digitalen Lean das Sammeln und Strukturieren von händisch eingepflegten Daten im Vordergrund stand, geschieht die Dateneingabe und die Vernetzung im smarten Lean automatisch. Im Smart Project Delivery werden Menschen, Maschinen und Materialien automatisch miteinander vernetzt. Zukünftig werden deshalb Data Scientists – heute noch eine Koryphäe im Bau – eine immer wichtigere Rolle in Bauprojekten spielen. Es geht darum, die riesigen Mengen an Echtzeitdaten nutzbar zu machen, um verlässliche Aussagen über die Zukunft ermitteln zu können. Ist dies erst einmal möglich, lassen sich bereits heute optimierte Zukunftsszenarien berechnen (Backhaus, 2021).

Dies ist der Zeitpunkt, an dem Lean final aus dem Schatten des verbreiteten Missverständnisses als Methodenbaukasten heraustritt. Denn Lean ist weder Werkzeug noch Werkzeugsammlung, sondern „[...] ein kultureller Änderungsprozess, der den Kundenwert in den Mittelpunkt stellt“ (Drees und Sommer SE, 2025). Um von einem herkömmlichen in ein leanes Produktionssystem zu wechseln, ist es nötig, dass sich das Verhalten der Akteure im Projekt verändert – neue Arbeitsroutinen sind genauso nötig wie die individuelle Akzeptanz, dass zuvor lieb gewonnene Zielbilder obsolet geworden sind. Dem neuen Zielbild – maximiere den Kundenwert – steht nun die Mutter der Verschwendung im Bau gegenüber: Die Zielabweichung. Bei Drees und Sommer haben wir diesem Wandel einen Namen gegeben: Unser smartes Lean-Produktionssystem heißt *Time- and Process Management (TPM)* – der Schlüssel zur erfolgreichen Transformation auf der Baustelle.

Die größte Hürde ist der zusätzliche Aufwand, den die Transformation hin zu einem leanen Produktionssystem mit sich bringt (John et al., 2025). Oftmals fehlt es an dem Know-How, die Veränderung nachhaltig in der Organisation zu verankern. Nach anfänglichen Erfolgen ruht sich

die Organisation auf den frühen Erfolgen der Transformation aus, herkömmliche Prozesse laufen parallel zu funktionierenden Lean-Strukturen weiter, der Aufwand der manuellen Datenaufnahme über Haftnotizen begegnet einer wachsenden Unzufriedenheit, diese führt zur Nachlässigkeit und damit einem Degenerieren der Datenqualität.

Durch die passive Datenaufnahme im Smarten Lean wird sich der Aufwand beim Sammeln der Daten verringern. Es wird eine verlässlich hohe Datenqualität erzeugt, die schnelle Entscheidungen im laufenden Projektbetrieb ermöglicht.

Beispiele sind die automatisierte IST-Zustandsaufnahme durch Helmkameras, Drohnen, Roboter oder eine direkte Werkzeug-Taktplan-Schnittstelle (Backhaus und Lauble, 2022). Diese erlauben eine kontinuierliche Aktualisierung des Taktplans mit hochqualitativen Echtzeitdaten direkt aus dem Bauprozess heraus. In Kombination mit Building Information Management (BIM) lässt sich so der IST-Zustand in Echtzeit visualisieren. Schon heute können Smartphones genutzt werden, um beispielsweise Fotos von Mängeln direkt im LCM Digital Prozessplan zu hinterlegen. Eine KI analysiert die Fotos und formuliert einen Mängeltext, der bei Bedarf durch eine simple Spracheingabe korrigiert werden kann (Abbildung 3).

In Kombination mit BIM und performanter Gamification lassen sich intuitive Nutzeroberflächen bauen, die den Baubeteiligten die schnelle Visualisierung von Problemen im Prozesssystem erlaubt. Systeme, die es erlauben die identifizierten Herausforderungen im kollaborativen Spiel zu lösen, könnten eine neue Nische zukünftiger Softwarelösungen bilden.

Unternehmen, die in der Lage sind diese Daten über den Projektverlauf zu sammeln, auszuwerten und so aufzubereiten, dass sie als leicht verständliche Entscheidungsgrundlage verwendet werden können, werden klar im Vorteil sein. Dabei wird es sich bald nicht mehr um einen USP handeln. Wer heute nicht bereits mit dem strukturierten Sammeln und Auswerten von live Projektdaten begonnen hat, der hat sich entschieden, zukünftig keine Rolle mehr im Projektgeschäft zu spielen. Wem es gelingt, digitale Kollaboration auch von seinen Baupartnern einzufordern und vernetzte Datensysteme erschafft, der wird bei dem ewigen Effizienzrennen der Branche vorne mit dabei sein.

Trotz wachsender digitaler Kompetenz werden die meisten Bauwerke auch weiterhin durch das menschliche Stapeln von Steinen erzeugt. Dies ändert sich in dem folgenden Zeitalter: Der autonomen Lean-Ära.




Abbildung 3: Screenshot Lehrvideo: KI Bildanalyse in der LCM Digital App. Die App erzeugt automatisierte Bildbeschreibungen. (Bildquelle: LCMD, 2025b)


## 5 Autonomes Lean

Firmen in der Bauindustrie haben in der Vergangenheit meist rein horizontales Wachstum erfahren: Baufirmen kauften Baufirmen und Planungsbüros kauften Planungsbüros – man blieb in seiner Sparte. Dieser Trend verändert sich zunehmend. Immer mehr Firmen streben nach der vertikalen Integration vor- und nachgeschalteter Wertschöpfungsketten. Immer mehr Unternehmen wagen dabei den Sprung in andere Industrien, um aus diesen Wert für die Bauindustrie zu erzeugen. Ein Beispiel solcher cross-industriellen Merger sind Automotive-Zulieferer, die sich im Zuge wachsender Elektromobilität als TGA-Bauzulieferer im Markt positionieren. Drees und Sommer hat ein eigenes Innovationszentrum aufgebaut (Drees und Sommer, 2025). Dieses hat sich zum Ziel gesetzt, die bestehenden Geschäftsbereiche zu digitalisieren, neue Geschäftsmodelle zu entwickeln und erfolgreich an den Markt zu bringen. Auf dem Weg dorthin werden Start-Ups identifiziert, gegründet und gemerged.

Die Art, wie gebaut wird, befindet sich im technologischen Umbruch. Viele sehen vor allem die Vorfertigung oder modulare Bauweise als das Ziel dieser Entwicklung. Tatsächlich bewegt sich die Industrie jedoch auf die autonome Bauprojektentwicklung zu. Autonome Projektentwicklung meint hier Technologien wie Contour Crafting und den 3D-Druck von Gebäuden (Abbildung 4). Wert wird am Bauort durch voll-autonome Systeme erzeugt werden. Zu Beginn werden die herkömmlichen Konstruktionssysteme durch neue autonome Systeme ersetzt. Schon heute zeichnet sich der positive Einfluss von Robotern auf Baustellen ab (Hu et.al, 2025). Im nächsten Schritt werden diese dann durch komplett neue und an die autonome Bauweise angepasste Konstruktionssysteme ersetzt zu werden. Diese Entwicklung lässt sich als Fortsetzung des Computer Aided Design (CAD) lesen, dass in den 1990ern die Bauindustrie disruptiert. BIM ist eine ähnliche Distribution bisher nicht gelungen. Im Zeitalter des Smarten und Autonomen Lean Design und Lean Construction wird sich dies ändern. Wie auch in der stationären Industrie wird CAD zu Computer Aided Construction (CAC).

Im Zeitalter des Autonomen Lean Construction wird der Markt disruptiert. Viele der alteingesessenen Marktteilnehmer werden ausscheiden und neue, bisher unsichtbare, hinzukommen. Insbesondere die vielen gewerblichen Mitarbeitenden werden dem technologischen Fortschritt weichen. Die Planung wird die Daten künftig direkt in ein CAC-System überführen, dass mit Hilfe von Robotern, Maschinen und 3D-Druckern die Ausführungsphase beherrscht. Ausführende Unternehmen werden zunehmend von Zulieferern ersetzt werden. Der Bedarf an Maschinenbauingenieur:innen wird steigen. Die Entwicklung von Lean Construction wird analog zu jener im Lean Production der stationären Industrie verlaufen. Damit wird der Fokus der Optimierung von den Menschen, Gewerkekettens und ausführenden Unternehmen auf die Optimierung des Kundentaktes, die Maschinen und die Schnittstelle zu den Zulieferern verlagert. Diese Veränderung wird den Arbeitsmarkt in der Bauindustrie radikal verändern (Okemwa, 2025). In einer Welt, in der immer mehr Standardaufgaben durch Maschinen übernommen werden und nur noch die erfahrenen Entscheider im Projekt tätig sind, werden es Berufsanfänger:innen – egal ob in der Planung oder Ausführung – schwer haben, ihre Nische zu finden. Sie stehen in direkter Konkurrenz zur KI, der es zunehmend gelingen wird, pseudo-kreative Lösungen für pseudo-individuelle Probleme zu präsentieren.

Um als Disziplin weiterhin zu bestehen, wird das Projektmanagement neue Werkzeuge entwickeln, die es den Handelnden erlauben, Investoren und Bauherren in ihren Entscheidungen zu unterstützen. Es ist abzusehen, dass die Modularität in der Planung zwar zunimmt, dies jedoch nicht auf Kosten der gestalterischen Freiheit geschieht.



Im autonomen Lean wird die Shopfloor-Kaskade auf der Baustelle mit einem Zielentfaltungsprozess auf der Unternehmensstrategie gekoppelt sein. Die aktuelle Schnittstelle zwischen dem Lean-Unternehmen und dem Lean-Projekt wird sich auflösen. Prozessdaten werden direkt aus den Maschinen, Werkzeugen und Materialien in das leane Produktionssystem übertragen und in die Planung des nächsten Prozessschrittes übernommen. Die punktuelle, kontinuierliche Verbesserung dieses Systems wird die Leane Denk- und Arbeitsweise im Alltag bestimmen.

Abbildung 4: 3D-Betondruck. Schon heute lassen sich dreidimensionale Strukturen in Beton drucken. Die Potentiale der Technologie zeigen, in welche Richtung sich die Autonome Baustelle entwickeln könnte. (Bildquelle: Kauppila, 2023)

## 6 Ultraeffiziente Projekte

Was die ultraeffiziente Baustelle ist und wie sie aussieht, ist nicht bekannt. Wie auch Lean Construction könnte sie den Fußstapfen der stationären Industrie folgen. Die Vision der Lean-Fabrik der stationären Industrie ist die Synchron Fabrik – ein Produktionssystem, in dem bedarfsgerechte Produktion ohne Lagerhaltung geschieht und die das Erkennen und Reduzieren der sieben Verschwendungsarten erlaubt. Eine Synchron Baustelle scheint mit Blick auf die stetig wachsenden Anforderungen an Bauprojekte in weiter Ferne. Der anhaltende Kostendruck, sich verändernde Anforderungen beispielsweise zur Nachhaltigkeit und die immer kürzeren Bauzyklen erzeugen einen enormen Innovationsdruck in den Projekten. Die Synchron Baustelle bedarf einer Steuerung über die Grenze des herkömmlichen Planungsrahmens hinaus. Lean Construction wird sich dieser Veränderung anpassen, um als das ganzheitliche Prozesssystem wirken zu können, das die Synchron Baustelle benötigt.

Durch den Einsatz echter Künstlicher Intelligenz werden Systeme auf den Markt kommen, die sich nicht nur an veränderte Projektbedingungen anpassen, sondern aktiv aus diesen lernen. Der Mensch könnte Teil dieses Systems als Entscheider sein. Um aber entscheiden zu können, müssen die Projektdatenströme in für Menschen verständliche Informationen umgewandelt werden. Auch hier wird eine echte KI lernen, was dem menschlichen Geist noch zugemutet werden kann und im Zweifel Nudges geben, gleich selbst entscheiden oder zumindest Empfehlungen aussprechen. Generatives Design (für die autonome Planung) und Computer Aided Construction (für das autonome Bauen) könnten mit einer starken KI (für autonomes Lernen) verknüpft werden. In

Kombination mit (KI-)moderierten Kollaborationsplattformen (als Soziales Management-System) würde das Lean, wie es heute existiert, durch das Ultraeffiziente Bauprojekt disruptiert und ersetzt werden.

## 7 Zusammenfassung

Lean Construction hat sich in den letzten zwei Jahrzehnten von einem analogen Methodenbaukasten hin zu einem strategischen Gesamtsystem entwickelt (Abbildung 5). Ursprünglich aus der Automobilindustrie abgeleitet, wurden zunächst Werkzeuge wie Taktplanung und Last Planner System auf den Bau übertragen. In der digitalen Phase kamen softwaregestützte Tools hinzu, die kollaboratives Arbeiten, Echtzeitdatenverfügbarkeit und hybride Workflows ermöglichten. Heute transformiert smartes Lean den Baualltag durch automatisierte Datenerhebung, KI-gestützte Auswertungen und datenbasierte Entscheidungen. Der Wandel hin zum autonomen Lean bringt disruptive Technologien wie 3D-Druck, Robotik und Computer Aided Construction auf die Baustelle. Künftig könnten ultraeffiziente Bauprojekte durch die Verbindung von generativem Design, autonomer Planung, vernetzten Datenströmen und echter künstlicher Intelligenz entstehen. Entscheidend für den Erfolg ist jedoch die kulturelle Verankerung von Lean auf strategischer Ebene – nur so lässt sich das volle Potenzial dieser Entwicklung ausschöpfen.

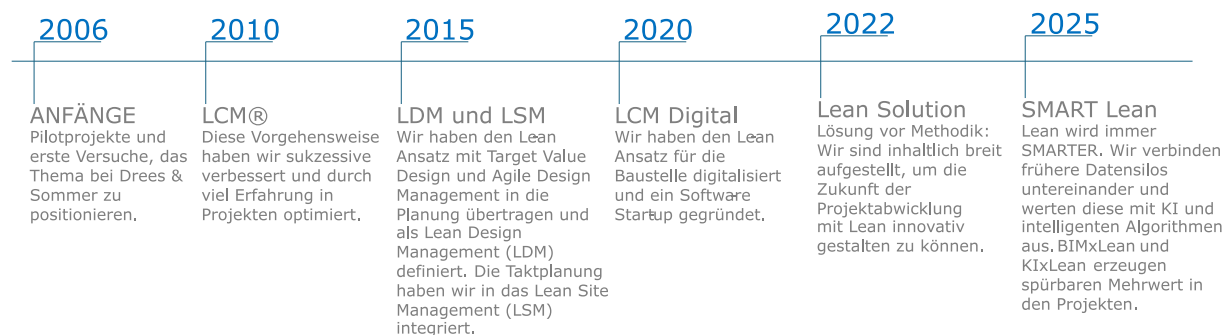


Abbildung 5: Eine kurze Geschichte des Lean bei Drees und Sommer SE. (Bildquelle: adaptiert von Drees und Sommer SE, 2022)

## Literatur

- [1] Backhaus, J. O. (2022): Lean Construction: Bauprojekte verschwendungsarm koordinieren. YOKOTEN Magazin, No. 2, S. 28-31.
- [2] Backhaus, J. O. (2021): A Methodology for the Numeric Time-Cost Forecast and Pareto Optimization of Large Injection Projects in Tunneling. In: Veröffentlichungen des Instituts für Geotechnik und Baubetrieb der TU Hamburg, No. 49, Dissertation.

- [3] Backhaus, J. O. und Lauble S. (2022): KI in der Bauwirtschaft. In: Markus Dahm (Hrsg.), Wie Künstliche Intelligenz unser Leben prägt, Haufe-Lexware. ISBN: 978-3-648-16204-0.
- [4] Ballard, G. (2000): The Last Planner System of Production Control. PhD thesis. Birmingham. UK: University of Birmingham.
- [5] Dunker, S. (2022): Innovatives Startup "beeboard" hebt die digitale Projektentwicklung auf ein neues Level. Drees und Sommer Pressemitteilung. <https://www.dreso.com/de/unternehmen/presse/presseinformationen/details/innovative-s-startup-beeboard-hebt-die-digitale-projektentwicklung-auf-ein-neues-level>, zugegriffen am 12.07.2025.
- [6] Drees und Sommer (2025): The Drees & Sommer Innovation Center. Website: Drees und Sommer. <https://www.dreso.com/de/en/company/innovation-center>, zugegriffen am 13.07.2025.
- [7] Drees und Sommer SE (2022): Lean Project delivery – A vision of the future. In: Drees und Sommer SE, Thinking Ahead, [www.dreso.com/de/en/thinking-ahead-lean-project-delivery](http://www.dreso.com/de/en/thinking-ahead-lean-project-delivery), zugegriffen am 13.07.2025.
- [8] Ford, H. (2008): My Life and Work – An Autobiography of Henry Ford. Barnes & Nobles Publishing. Hawthorne, CA, USA.
- [9] Hu, R., Mao, J., Chae, S., und Yeoh, J.K.W. (2025): Implications of construction robots for on-site lean construction: An in-depth case study. In Seppänen O., Koskela, L. und Murata, K. (Eds.), Proceedings of the 33rd Annual Conference of the International Group for Lean Construction (IGLC33) (pp. 999-1010). <https://doi.org/10.24928/2025/0207>.
- [10] John C., Niederprüm, K., Maier, E. und Haghsheno, S. (2025). Lean Construction in Germany – Empirical Findings on the Current State of Practice. In Seppänen O., Koskela, L. und Murata, K. (Eds.), Proceedings of the 33rd Annual Conference of the International Group for Lean Construction (IGLC33) (pp. 1368-1379). <https://doi.org/10.24928/2025/0167>.
- [11] Kauppila, I. (2023): 3D Concrete Printing – The Ultimate Guide. Website. <https://all3dp.com/1/3d-concrete-printing-guide>, zugegriffen am 12.07.2025.
- [12] Koskela, L. (1992): Application of the new production philosophy to construction. Technical Report 72. Stanford, CA: Center for integrated facility engineering (CIFE), Stanford University.
- [13] LCMD (2025a): Website: LCMDigital, [www.lcmd.io](http://www.lcmd.io), zugegriffen am 06.07.2025.
- [14] LCMD (2025b): Website: LCMDigital Helpcenter, <https://lcmdigital.zendesk.com>, zugegriffen am 12.07.2025.
- [15] Lemke, N. und Khidoyatova M. (2018): LCM Digital: Innovative Plattform für digitale Termin- und Prozessplanung. Drees und Sommer Pressemitteilung. [https://cdn.dreso.com/fileadmin/media/06\\_Presse/Presseinformationen/LCM\\_D](https://cdn.dreso.com/fileadmin/media/06_Presse/Presseinformationen/LCM_D)

igital\_\_Innovative\_Plattform\_fuer\_digitale\_Termin-\_und\_Prozessplanung/20181008\_\_Presseinformation\_LCM\_Digital\_Innovative\_Plattform\_fuer\_digitale\_Termin-\_und\_Prozessplanung.pdf, zugegriffen am 12.07.2025.

- [16] Lingg, S. (2025): Agile und schlanke Bauprojekte mit Lean Construction. Website: Drees und Sommer, <https://www.dreso.com/ch/top-themen/lean-construction-management-lcm>, zugegriffen am 06.07.2025.
- [17] Okemwa, K. (2025): “Stop sugar-coating it”: Anthropic CEO says AI will slash 50% of entry-level white collar jobs – leaving Gen Z out of work. Website: Windows Central. <https://www.windowscentral.com/software-apps/work-productivity/anthropic-ceo-ai-slash-50-percent-entry-level-jobs>, zugegriffen am 13.07.2025.
- [18] Ōno T. (1978/2013): Das Toyota-Produktionssystem. German. 3rd edition. (Original Japanese language version published 1978 by Diamond Inc., Tokyo, Japan). Frankfurt/Main, Germany: Campus.
- [19] Peccolo, G. (2024): New Report: The State of Data Capabilities in Construction, Website: Autodesk. <https://www.autodesk.com/blogs/construction/state-of-data-capabilities-in-construction/>, zugegriffen am 06.07.2025.
- [20] VDI (2019): VDI2553 Lean Construction, VDI-Gesellschaft Bauen und Gebäudetechnik.
- [21] Womack J.P., Jones D.T., und Ross D. (1990/2007): The machine that changed the world. How Lean Production Revolutionized the global Car Wars. New Ed. (Originally published in 1990 by Rawson Associates, New York, NY). London, UK: Simon & Schuster.

## Author

Dr.-Ing. Jan Onne Backhaus, MBA  
Drees und Sommer SE  
Ludwig-Erhard-Straße 1  
20459 Hamburg  
E-Mail: [jan-onne.backhaus@dreso.com](mailto:jan-onne.backhaus@dreso.com)  
Web: [www.dreso.com](http://www.dreso.com)

## **KI-Anwendungen bei geotechnischen Bauverfahren**

**Dr.-Ing. Christian Thienert, Lara Gutberlet, Christoph Klaproth, STUVA e. V., Köln**  
**Dipl.-Ing. Reiner Otterbein, Dipl.-Ing. Frank Ludwig, Keller Grundbau GmbH,**  
**Bochum**  
**Prof. Dr.-Ing. Frank Könemann, Technische Universität Dortmund**  
**Dipl.-Geol. André Heim, Herrenknecht AG, Schwanau**  
**Prof. Dr.-Ing. Christoph Budach, Technische Hochschule Köln**

### **Zusammenfassung:**

Künstliche Intelligenz (KI) gewinnt in der Geotechnik zunehmend an Bedeutung und bietet neue Perspektiven für Prozessoptimierung und Nachhaltigkeit. Dieser Beitrag stellt drei Anwendungen von KI unter Einsatz künstlicher neuronaler Netze vor. Dazu gehören: (1) die Bewertung der Wiederverwendbarkeit des Rückflusses beim Düsenstrahlverfahren mithilfe eines vor Ort eingesetzten Online-Messsystems, (2) die Vorhersage von Injektionsvolumina bei Felsinjektionen auf Basis von Druck-Mengen-Schrieben aus Tausenden von Felddatensätzen und (3) die Klassifizierung von Tunnelausbruchmaterial auf dem Förderband einer Tunnelbohrmaschine (TBM).

Alle Anwendungen zeigen, dass KI zuverlässige Vorhersagen wichtiger geotechnischer Parameter ermöglicht, den Materialverbrauch reduziert und eine dynamische Prozesssteuerung unterstützt. Die Ergebnisse unterstreichen das Potenzial der KI, die Effizienz zu steigern, die Umweltbelastung zu verringern und die Entscheidungsfindung im Tunnel- und Untertagebau zu verbessern.

## **1 Einführung**

Künstliche Intelligenz (KI) ist eine der am schnellsten an Bedeutung gewinnenden Technologien unserer Zeit. So haben zum Beispiel bereits sogenannte Chatbots zur „vereinfachten“ Kommunikation zwischen großen Online-Händlern und Kunden oder Softwaretools zur Zusammenfassung von Texten ihren breiten Eingang in unseren Alltag gefunden. Auch aus dem industriellen Bereich wird kontinuierlich über neue Entwicklungen und Einsatzmöglichkeiten berichtet. Es ist also nur eine Frage der Zeit, bis auch in der Geotechnik konkrete Praxisanwendungen zu verzeichnen sein werden.

Im Rahmen dieses Beitrags werden drei ausgewählte Beispiele vorgestellt, für die bereits konkrete Perspektiven zum Einsatz von Künstlicher Intelligenz in der Geotechnik vorliegen:

- Bewertung des Rücklaufs beim Düsenstrahlverfahren
- Prognose von Injektionsverläufen im Festgestein
- Klassifizierung von Tunnelausbruchmaterial

Nachfolgend werden zunächst einige gemeinsame Grundlagen erläutert; die konkreten Beispiele folgen anschließend in den Abschnitten 3. bis 5.

## 2 Grundlagen Künstliche Intelligenz

### 2.1 Lernmethoden und Künstliche Neuronale Netze

Methoden Künstlicher Intelligenz werden häufig nach Methoden des Überwachten Lernens und des Unüberwachten Lernens unterschieden. Beim Überwachten Lernen (engl. „supervised learning“) wird auf bekannte „wahre“ Kombinationen von Eingangsdaten (Input) und Ausgangsdaten (Output) zurückgegriffen; beim Unüberwachten Lernen (engl. „unsupervised learning“) erfolgt im Vorfeld keine derartige Unterscheidung bzw. ist diese mitunter gar nicht bekannt.

Für die Ermittlung einer entsprechenden Korrelationsfunktion bzw. Prognose werden häufig sogenannte Künstliche Neuronale Netze (KNN) verwendet. Die Bezeichnung lehnt sich an das biologische Modell des menschlichen Gehirns an, wobei die Neuronen mit den Axonen miteinander verknüpft werden.

Ein solches KNN besteht aus Neuronen (Units), Verbindungen (Links) und Schichten (Layers), siehe Abbildung 1. Die erste Schicht enthält dabei die Input-Neuronen, welche die Eingangsdaten (z. B. Messwerte) enthalten. In der letzten Schicht befinden sich die Output-Neuronen (z. B. zu prognostizierende Index-Werte). Zwischen der Input- und Output-Schicht können beliebig viele Schichten, die Hidden-Schichten, mit beliebig vielen sogenannten Hidden-Neuronen liegen. Je nach gewähltem Aufbau sind die Neuronen untereinander durch die Verbindungen verknüpft. Das Gewicht der Verbindungen repräsentiert die jeweilige Stärke der Verbindung zwischen den einzelnen Neuronen, wobei die Stärke das „Wissen“ des Netzes darstellt, welches durch den Lernprozess erlangt wird. (Rey & Wender, 2011)

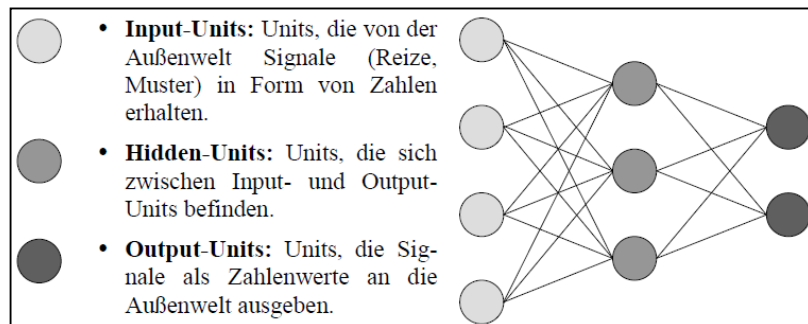


Abbildung 1: Schematische Darstellung eines KKN (Rey & Wender, 2011)

### 2.2 Training und Validierung

Die Grundgesamtheit aller zur Verfügung stehender Daten wird in einen Trainings- und einen Validierungsdatensatz aufgeteilt. Zunächst werden die Trainingsdaten dazu verwendet, das KNN anzulernen, bis eine zufriedenstellende Korrelation zwischen Input- und Output-Werten

erreicht wird. Die Beurteilung der Korrelationsgüte ist dabei dem jeweiligen Anwender überlassen und hängt im starken Maße von der Quantität und der Qualität der Trainingsdaten ab. (Rey & Wender, 2011)

Nach Abschluss des Trainings erfolgt unter Verwendung der Validierungsdaten eine Überprüfung, welche Prognosegüte erreicht wird. Häufig werden dabei „wahre“ und prognostizierte Output-Daten in einem Diagramm gegenübergestellt, wobei auf der x-Achse der „wahre“ Wert und auf der y-Achse der prognostizierte Wert aufgetragen wird und ein Qualitätsindex (z. B. der mittlere quadratische Fehler) ermittelt wird. Bei einer „perfekten Prognose“ lägen also alle Wertepaare auf der Winkelhalbierenden und die mittlere quadratische Abweichung würde null betragen.

Für die in den nachfolgenden Abschnitten 3. bis 5. behandelten Anwendungsbeispiele wird jeweils auf Methoden des überwachten Lernens unter Verwendung von KNN zurückgegriffen.

### **3 Bewertung des Rücklaufs beim Düsenstrahlverfahren**

#### **3.1 Ausgangssituation**

Beim Düsenstrahlverfahren (DSV) wird ein nicht unerheblicher Anteil der mit Bodenbestandteilen aufgeladenen Zementsuspension durch den Bohrlochringraum zum Bohrlochmund an die Geländeoberfläche gespült. Das Mischungsverhältnis (d. h. die Anteile an Zement, Boden und Wasser) dieser auch als Rücklauf bezeichneten Suspension ist nicht näher bekannt und variiert sowohl in Abhängigkeit der hydrogeologischen Randbedingungen als auch verfahrenstechnischer Parameter. Weil deshalb unklar ist, ob der Zementanteil des Rücklaufs im Vergleich zur Frischsuspension noch groß genug ist, um die erforderlichen Qualitätseigenschaften (v. a. Druckfestigkeit) nach dem Erhärten zu erreichen, wird der Rücklauf nach dem Stand der Technik auf einer Deponie beseitigt und kann nicht wiederverwendet werden.

#### **3.2 Messsystem und Datenanalyse**

Aus diesem Grund wurde von Keller Grundbau und STUVA ein modulares, auf Baustellen leicht integrierbares Online-Messsystem entwickelt (Abbildung 2), mit dem die Wiederverwendbarkeit von Zementsuspensionen beim Düsenstrahlverfahren bewertet werden kann.



Abbildung 2: Messsystem als Demonstrator

Wesentliche Idee ist es, die Zementsuspensionen im noch fließfähigen Zustand anhand ihrer Reaktion bei stufenweiser Zugabe eines die Rheologie beeinflussenden Betonzusatzmittels zu beurteilen und damit Rückschlüsse auf die zu erwartende Druckfestigkeit nach Bindemittelerhärtung bzw. den Bindemittelanteil zu ermöglichen. Prinzipiell gilt, dass die Veränderung der maßgeblichen rheologischen Kenngrößen umso ausgeprägter ist, desto größer die Reaktivität und damit der Bindemittelgehalt ist. Als Parameter wurden unter anderem Drücke, Dichte und Temperatur sowie Leitfähigkeit und pH-Wert ermittelt. In Abbildung 3 sind exemplarische zeitliche Druckverläufe bei stufenweiser Betonzusatzmittel-Zugabe für verschiedene Suspensionen (Bindemittelanteil 25 %, 50 %, 75 % und 100 % des Gesamtfeststoffs) für eine einheitliche Dichte von  $1,60 \text{ t/m}^3$  dargestellt.




Abbildung 3: Exemplarische Druckverläufe

Eine Künstliche Intelligenz auf Basis eines Künstlichen Neuronalen Netzes (KNN) verknüpft die Daten der einzelnen Sensoren (Input) mit maßgeblichen bautechnischen Kenngrößen wie „Bindemittelanteil“ und „Druckfestigkeit“ (Output). Die KI wurde zunächst im Labor anhand einer größeren Anzahl von Suspensionen mit variierenden Zement-, Bodenkorn- und Wasseranteilen über einen Zeitraum von mehreren Monaten trainiert. Danach wurde das Messsystem erstmals in Form eines sogenannten Demonstrators auf einer Baustelle getestet. Erfreulicherweise lagen sowohl die mittlere Abweichung mit ca. 8 % als auch die maximale Abweichung mit ca. 13 % bezüglich des Bindemittelanteils nur unwesentlich über den 7 %, die im Rahmen der Validierung der KI im Labor ermittelt worden waren (siehe Abbildung 4).




Abbildung 4: Gegenüberstellung im Labor und in situ bestimmter Bindemittelanteile

### 3.3 Schlussfolgerungen

Basierend auf dem vorgestellten Online-Messsystem wird es in Zukunft nach derzeitigem Stand und unter annähernd gleichförmigen geologischen Bedingungen möglich sein, etwa 50 bis 70 % des Rücklaufs beim Düsenstrahlverfahren wiederzuverwenden.

### 3.4 Weiterführende Informationen

Die vorgestellten Ergebnisse wurden von Keller Grundbau GmbH und STUVA e. V. mit Förderung durch die Deutsche Bundesstiftung Umwelt (DBU) erarbeitet. Ein nachfolgender Entwicklungsschritt zur weiteren Untersuchung der Einflüsse aus unterschiedlichen Bindemittelarten wird in einer nachfolgenden Projektphase angestrebt.

## 4 Prognose von Injektionsverläufen im Festgestein

### 4.1 Ausgangssituation

Für Ausführung, Dokumentation und Abrechnung von Injektionsarbeiten im Festgestein haben die sogenannten Druck-Mengen-Schriebe nach wie vor eine große Bedeutung. Mittlerweile stehen hierfür spezielle digitale Datenmanagementsysteme (Ouschan, 2018) zur Verfügung, welche die Daten strukturiert und konsistent bereitstellen können, sodass diese auch für Ansätze von Künstlicher Intelligenz nutzbar werden. Es sollte untersucht werden, inwieweit die Verläufe von Druck-Mengen-Schrieben (Abbildung 5) bei Injektionsarbeiten mittels KI prognostiziert werden können.




Abbildung 5: Exemplarischer Druck-Mengen-Schrieb

Dafür wurden Baustellendaten von fast 3.000 Einzelinjektionen eines Tunnelprojekts in Skandinavien herangezogen, bei dem Injektionen als vorausseilende Abdichtungsinjektionen ausgeführt wurden. Die Injektionen wurden druckgesteuert mit einem Maximaldruck von 25 bar und einer Mengenbegrenzung von 1.200 l ausgeführt. Beim Injektionsgut handelt es sich um Zementsuspensionen, die sich im Wesentlichen im Wasser-Zement-Verhältnis ( $w/z$ -Wert) unterscheiden.

## 4.2 Datenanalyse

In Abbildung 6 ist die Verteilung des tatsächlich verpressten Injektionsgutvolumens für die betrachteten 416 Validierungsdatensätze dargestellt. Mit 45 Registrierungen ist 94 l der häufigste Einzelwert, innerhalb des Intervalls 80 bis 120 l liegen  $214/416 = 51,4\%$  aller Werte.





Abbildung 6: Häufigkeitsverteilung der tatsächlichen Injektionsgutvolumina

In Abbildung 7 sind die tatsächlich verpressten Injektionsgutvolumina ( $x$ -Achse) gegen die prognostizierten ( $y$ -Achse) für 416 Validierungsdatensätze aufgetragen. Hierfür wurden alle Einzelinjektionsverläufe (unabhängig von ihrer tatsächlichen Dauer bzw. Datenaufzeichnungsrate) einheitlich durch 400 Einzeldatenpunkte abgebildet, wodurch eine Art Normierung der Datensätze stattfindet. Auf dieser Basis kann dann für verschiedene relative Zeitpunkte (z. B.  $120/400 = 0,3$  [blaue Rauten in Abb. 7],  $240/400 = 0,6$  [rote Quadrate],  $360/400 = 0,9$  [grüne Dreiecke]) das jeweilige prognostizierte Volumen dem tatsächlich verpressten Volumen gegenübergestellt werden. Es ist zu erkennen, dass erwartungsgemäß die Prognosegüte umso besser ist, je weiter der Injektionsvorgang vorangeschritten ist, also alle Datenpaare nah der Winkelhalbierenden liegen. Des Weiteren zeichnet sich ab, dass jene Werte am besten prognostiziert werden, die besonders häufig vorliegen. Bezogen auf den häufigsten Einzelwert von 94 l (vgl. Abb. 6). liegt damit eine relative Abweichung vor in der Größenordnung von lediglich ca.  $8,13/13 = 8,6\%$  nach 240 von 400 Datenpunkten, also nachdem 60 % des Injektionsvorgangs abgeschlossen ist, vor. Für ein effizientes Lernen einer KI sind also repräsentative Datensätze erforderlich, die möglichst die gesamte Bandbreite gleichmäßig abdecken.



### 4.3 Schlussfolgerungen

Die Analyse von Injektionsdaten mit Hilfe von KI hat das Potenzial, Injektionsarbeiten im Festgestein zu einem dynamischen Prozess zu machen, d. h. Herstellparameter (Injektionsdruck, Durchflussrate) und Design (Bohrgeometrie, Injektionsmaterial, Injektionsvolumen) kontinuierlich zu optimieren. Wesentliche Vorteile in diesem Zusammenhang sind:

- Beschleunigung der Bohr- und Injektionsarbeiten
- Reduzierung der Massen (Bohrlängen, Injektionsvolumina)
- Reduzierung der Kosten bei gleichzeitiger Erhöhung der Qualität.

Der wesentliche baupraktische Nutzen liegt darin, dass Zeit- und Materialbedarfe frühzeitiger und zuverlässiger als bislang eingeschätzt bzw. prognostiziert werden können, was sich vor allem positiv auf das Zusammenspiel der Gewerke Spezialtiefbau (vorausseilende Injektionen) und eigentlicher Tunnelbau (Vortrieb) auswirken kann.

### 4.4 Weiterführende Informationen

Weitere Details zum Anwendungsbeispiel „Prognose von Injektionsverläufen im Festgestein“ sind in (Thienert et al., 2022) ausführlich dargestellt. Diese Ergebnisse wurden im Rahmen des Projekts „AVANT – Adaptive Planung von Injektionsmaßnahmen im Tunnelbau mittels Künstlicher Intelligenz“ im Rahmen einer deutsch-österreichischen Kooperation von STUVA e. V. und geoteam Ingenieurgesellschaft mbH sowie eguana GmbH, Montanuniversität Leoben und Züblin Spezialtiefbau Ges.m.b.H. (Wien) mit Förderung durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) bzw. die Österreichische Forschungsförderungsgesellschaft (FFG) erarbeitet.

## 5 Klassifizierung von Tunnelausbruchmaterial

### 5.1 Ausgangssituation

Fast die Hälfte aller Tunnel wird mit Tunnelbohrmaschinen (TBM) gebaut. Bei den sogenannten Erddruckschilden (engl. „Earth Pressure Balance Shield“, kurz EPB) wird der abgebaute Boden selbst als Stützmedium genutzt. Hierfür werden am Schneidrad der TBM Konditionierungsmittel in Form von Suspensionen oder Schäumen zugegeben, sodass üblicherweise ein pastöser Erdbrei vorliegt. Der typische Einsatzbereich einer EPB-TBM ist Lockergestein in Form von fein- und gemischtkörnigen aber auch grobkörnigen Böden.

Während Ausbruchmaterial aus Hartgesteinsvortrieben vergleichsweise einfach (z. B. als Gesteinskörnung in Beton) verwertet werden kann, ist dies bei fein- oder gemischtkörnigem Lockergestein ungleich schwieriger, denn der konditionierte Erdbrei weist im Vergleich zum anstehenden Boden andere geotechnische Kennwerte auf (Budach, 2024). Für eine Verwertung im Sinne der Kreislaufwirtschaft für andere bautechnische Zwecke (z. B. einen Erdwall oder eine Straßenunterkonstruktion) ist daher üblicherweise eine aufwendige Bodenaufbereitung oder -behandlung durch Zugabe von Kalk o. ä. erforderlich.

Wenn dies wirtschaftlich nicht möglich ist, wird das Ausbruchmaterial zumeist auf einer Deponie beseitigt. Zur Erhöhung der Ressourceneffizienz muss es daher Ziel sein, so wenig Konditionierungsmittel wie möglich einzusetzen und das Bodenmaterial frühzeitig – am besten bereits auf dem Förderband – hinsichtlich seiner geotechnischen Eigenschaften zu klassifizieren, so dass eine optimale Verwertung des Materials erfolgen kann.

## 5.2 Messsystem und Datenanalyse

Aus diesem Grund wurde ein innovatives Messsystem entwickelt, das eine Prognose geotechnischer (Index-)Parameter wie Setzmaß (sog. Slumpwert) und Flügelscherfestigkeit ermöglicht (Budach et al., 2023). Wie in Abbildung 8 dargestellt, übt das auf dem Förderband transportierte Ausbruchmaterial Impulse und damit Kräfte auf eine Stahlkugel und einen Pflug aus, die kontinuierlich registriert werden. In Abhängigkeit der rheologischen Eigenschaften des Materials sind die zeitlichen Kraftverläufe unterschiedlich.

Eine Künstliche Intelligenz verknüpft die Daten aus den Kraftverläufen (Input) mit maßgeblichen geotechnischen (Index-)Parametern wie dem Setzmaß und der Flügelscherfestigkeit (Output) und kann so zuverlässige Informationen über die Verarbeitbarkeit des Bodens liefern. Die KI wurde zunächst mittels im Labormaßstab registrierten Daten trainiert; die Validierung erfolgte ergänzend mit Daten einer auf einem Testförderband im Maßstab 1:1 installierten Messeinrichtung und zusätzlich durch Untersuchungen auf einer im Einsatz befindlichen TBM. Insbesondere im Hinblick auf die Slumpwerte und Flügelscherfestigkeiten konnten sehr gute Prognosegüten von ca. 96 % bzw. 97 % erzielt werden.

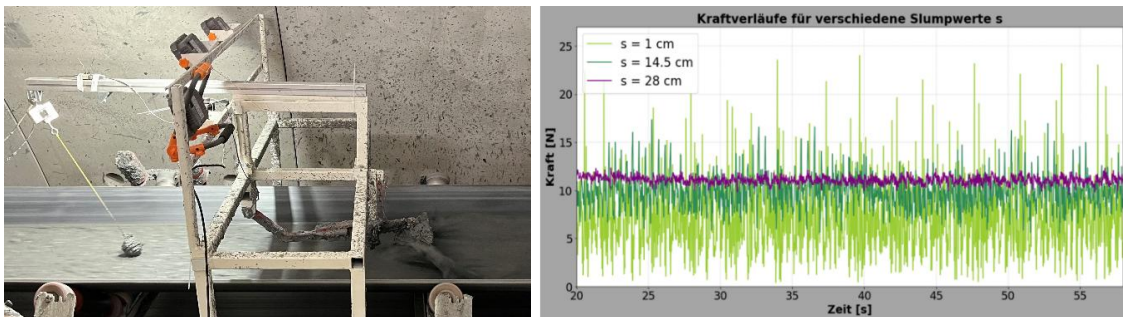


Abbildung 8: Neu entwickeltes Messsystem  
links: Installation auf einer TBM;  
rechts: Kraftverläufe für verschiedene Slumpwerte

## 5.3 Weiterführende Informationen

Detaillierte Ergebnisse zum Anwendungsbeispiel „Klassifizierung von Tunnelausbruchmaterial“ werden in Kürze veröffentlicht werden (Thienert et al., 2025) und wurden im Rahmen des Projekts „REMATCH – Ressourceneffizienter Tunnelbau auf Basis einer Echtzeit-Charakterisierung des Ausbruchmaterials“ im Rahmen einer deutsch-französischen Kooperation von STUVA e. V., Herrenknecht AG und Technische Hochschule Köln sowie LIRIS – Laboratoire d'InfoRmatique en Image et Systèmes d'information und Arcadis ESG mit Förderung durch das Bundesministerium für Bildung und Forschung (BMBF) bzw. die Agence Nationale de la Recherche (ANR) erarbeitet.

## 6 Zusammenfassung und Ausblick

Die obenstehenden Beispiele zeigen, dass auch im Bereich der Geotechnik bereits in absehbarer Zeit neue Entwicklungen ihren Eingang in die Praxis finden werden, die auf Ansätzen von Künstlicher Intelligenz beruhen. Dies ist nicht nur als Trend der Zeit anzusehen, vielmehr sind auf diese Weise durchaus innovative Ansätze, Methoden und Technologien zu erwarten, die den Grundbau schneller, kostengünstiger und ökologisch nachhaltiger machen könnten. Hierfür sind jedoch drei wesentliche Voraussetzungen zu erfüllen:

1. Die erfolgreiche Einführung von KI-Anwendungen erfordert zumindest grundlegendes Wissen bei allen am Bau Beteiligten darüber, was überhaupt möglich ist und umgesetzt werden könnte. Schließlich sind es die Bauherren und damit die Planer, die bereits in den Ausschreibungen den Weg für innovative Ansätze ebnen müssen. Die Bauunternehmen allein werden dies am Ende nicht sein können!
2. Für die erfolgreiche Umsetzung ist es dann auch erforderlich, dass neue vertragliche Lösungen gefunden werden. Warum sollte sonst zum Beispiel ein Injektionsunternehmen, das nach Injektionsstunden bezahlt wird, ein Interesse daran haben, Abläufe mittels KI zu beschleunigen? Einige konkrete diesbezügliche Lösungsvorschläge sind in (Thienert et al., 2022) aufgeführt.
3. Ein wesentlicher Vorteil von KI ist, dass diese durch immer mehr Daten immer besser werden kann, sich also zum Beispiel die Genauigkeit von Prognosemodellen durch zusätzliche Prozessdaten kontinuierlich steigern lässt. Hierfür ist es erforderlich, dass die Daten in einer maschinenlesbaren Form vorliegen, d. h. in Datenbanken abgelegt werden. Gescannte händische Protokolle sind keine digitalen Daten! Mittlerweile sind einige grundbauspezifische Anwendungen verfügbar, die auch für Überwachung und Abrechnung einen Mehrwert aufweisen; einen Überblick gibt u. a. (Ouschan et al., 2018).

### Hinweis

Dieser Beitrag basiert auf einer Veröffentlichung im Rahmen des „14. RuhrGeo-Tag 2025“ der Universität Duisburg-Essen, Fachgebiet Geotechnik: Perau, Eugen (Hg.) (2025): Digitalisierung in der Geotechnik - wohin geht die Reise? 14. RuhrGeo-Tag am 27.03.2025 in Essen. Tagungsband. Erschienen in Report Geotechnik Universität Duisburg-Essen, Heft 50. Open Access über DuEPublico, dem Dokumenten- und Publikationsserver der Universität Duisburg-Essen.

### Literatur

- Budach, C. (2024) Ausbruchmaterial beim Schildvortrieb – Teil 1: Geotechnische Eigenschaften und umwelttechnische Klassifizierung in Deutschland. *Geomechanics and Tunneling*, 4/24, S. 332 – 340
- Budach, C.; Chalak, C.; Heim, A.; Porthier, C.; Thienert, C.; Chaubeau, J. (2023): Improvement of the recycling process of excavated soil using tunnel boring machines– First results of the European research project REMATCH, Proceedings of the congress L'Association Française des Tunnels et de l'Espace Souterrain (AFTES), Paris

- Ouschan, M.; Maroschek, P.; Sabew, S.; Winkler, L. (2018): Digitales Dokumentations- und Datenmanagement bei Injektionsmaßnahmen. In: Vorträge zum Forum Injektionstechnik 2018 (Forschung + Praxis, U-Verkehr und unterirdisches Bauen; 52), Hrsg. STUVA e. V. Köln, ISBN 978-3-9819842-1-7, S. 32-40
- Rey, G. D.; Wender, K. F. (2011): Neuronale Netze: Eine Einführung in die Grundlagen, Anwendungen und Datenauswertung. 2. Aufl. Bern; Huber
- Thienert, C.; Ouschan, M. †.; Wenighofer, R.; Könemann, F.; Klaproth, C.; Gabriel, P.; Ville-neuve, M.; Pechhacker, R. (2022): Potenziale und Grenzen der Prognose von Injektionsparametern mittels Künstlicher Intelligenz – Ergebnisse einer Fallstudie bei einem Tunnelprojekt in Skandinavien. Geomechanik und Tunnelbau.  
<https://doi.org/10.1002/geot.202200050>
- Thienert, C.; Gutberlet, L.; Klaproth, C.; Budach, C.; Müller, P.; Heim, A.; Kassel, A. (2025): Real-time determination of EPB-TBM excavation material parameters using AI-based measurement data analyses, Proceedings of World Tunnel Congress 2025, in

## **Autoren**

Dr.-Ing. Christian Thienert, Lara Gutberlet, M. Sc., Dipl.-Ing. Christoph Klaproth  
Studiengesellschaft für Tunnel und Verkehrsanlagen – STUVA – e. V.  
Mathias-Brüggen-Straße 41, 50827 Köln  
[c.thienert@stuva.de](mailto:c.thienert@stuva.de), [l.gutberlet@stuva.de](mailto:l.gutberlet@stuva.de), [c.klaproth@stuva.de](mailto:c.klaproth@stuva.de)

Dipl.-Ing. Reiner Otterbein, Dipl.-Ing. Frank Ludwig  
Keller Grundbau GmbH  
Mausegatt 45, 44866 Bochum  
[reiner.otterbein@keller.com](mailto:reiner.otterbein@keller.com), [frank.ludwig@keller.com](mailto:frank.ludwig@keller.com)

Prof. Dr.-Ing. Frank Könemann  
Technische Universität Dortmund, Lehrstuhl Geotechnik  
August-Schmidt-Str. 8, 44227 Dortmund  
[frank.koenemann@tu-dortmund.de](mailto:frank.koenemann@tu-dortmund.de)

Dipl.-Geol. André Heim  
Herrenknecht AG  
Schlehenweg 2, 77963 Schwanau  
[Heim.Andre@herrenknecht.de](mailto:Heim.Andre@herrenknecht.de)

Prof. Dr.-Ing. Christoph Budach  
Technische Hochschule Köln, Lehr- und Forschungsgebiet Geotechnik und Tunnelbau  
Betzdorfer Straße 2, 50679 Köln  
[christoph.budach@th-koeln.de](mailto:christoph.budach@th-koeln.de)