

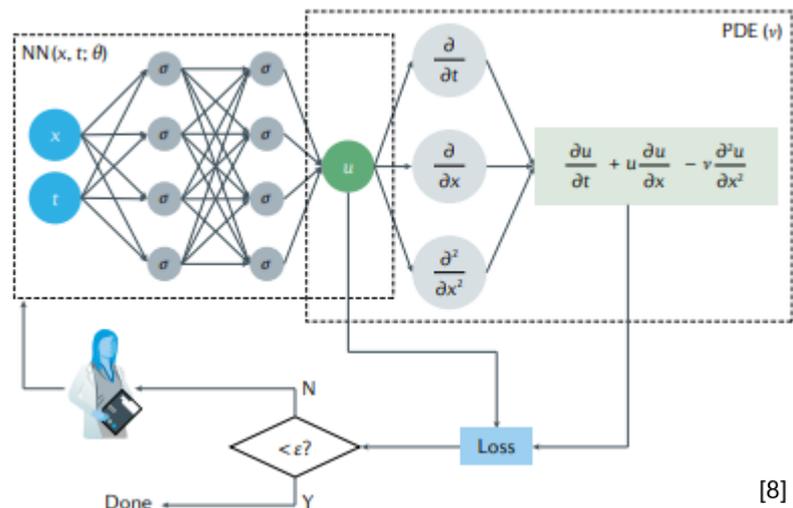
Projektarbeit (Master, 3CP) Informed Machine Learning (IML)

Ahmad Hoschang Noori

Im Forschungsprojekt EEp-Beton wird ein datengesteuertes Modell für die Echtzeitvorhersage von Betoneigenschaften in der Produktion und Qualitätssicherung entwickelt. Das Hauptproblem bei der Modellierung von Betonqualitätsvorhersagen ist die geringe Datenmenge für den Modellierungsprozess.

ML Algorithmen sind eine interessante Alternative, aber das Training von ML erfordert große Datenmengen, die bei wissenschaftlichen Problemen nicht immer verfügbar sind. Trotz ihrer vielversprechenden empirischen Ergebnisse und einiger erster Erfolge sind die meisten ML-Ansätze derzeit nicht in der Lage, interpretierbare Informationen und Wissen aus geringen Datenmengen zu extrahieren.

Um kleine Datenmengen bewältigen zu können, soll das Vorwissen (Prior-Knowledge) des Prozesses in den verwendeten Algorithmus integriert werden. IML ist definiert als der Prozess, bei dem Vorwissen, das aus unserem beobachteten, empirischen, physikalischen oder mathematischen Verständnis der Welt stammt, zur Verbesserung der Leistung eines Lernalgorithmus genutzt werden kann [8].



In der Arbeit sollen theoretische Kenntnisse und Fakten über IML erworben werden. Dabei werden alle möglichen Konzepte und Methoden von IML untersucht.

Folgende Teilaufgaben sind vorgesehen:

- Recherche und Einarbeitung in die Konzepte, Typen und Darstellung der Vor- und Nachteile der IML-Algorithmen.
- Methodischer Vergleich von IML-Algorithmen bei der Untersuchung ihrer Grenzen, Herausforderungen, Anwendungsbereiche und Entwurfsverfahren.
- Dokumentation der Arbeit und Kolloquiumsvortrag

Betreuer: F. Rezazadeh M.Sc., Univ.-Prof. Dr.-Ing. A. Kroll

Beginn: Erste Februar 2022

Geplantes Ende: Ende Mai 2022

Literaturhinweise:

- [1] Rueden, L.V.; Mayer, S.; Garcke, J.; Bauckhage, C; Schuecker, J: "Informed machine learning—towards a taxonomy of explicit integration of knowledge into machine learning." *learning* 18, 19-20 (2019).
- [2] Rueden, L.V.; Mayer, S.; Beckh, K. Georgiev, B.; Giesselbach, S.; Heese, R.; Kirsch, B.; Pfrommer, J.; Pick, A.; Ramamurthy, R.; Walczak, M.; Garcke, J.; Bauckhage, C.; Schuecker, J.: "Informed Machine Learning--A Taxonomy and Survey of Integrating Knowledge into Learning Systems." *arXiv preprint arXiv:1903.12394* (2021).
- [3] Muralidhar, N.; Islam, M.R.; Marwah, M.; Karpatne, A.; Ramakrishnan, N.: "Incorporating prior domain knowledge into deep neural networks." *2018 IEEE international conference on big data (big data)*. IEEE, (2018).
- [4] Karpatne, A.; Atluri, G.; Faghmous, J.H.; Steinbach, M.; Banerjee, A.; Ganguly, A.; Shekhar, S.; Samatova, N.; Kumar, V.: "Theory-guided data science: A new paradigm for scientific discovery from data." *IEEE Transactions on knowledge and data engineering* 29.10, 2318-2331 (2017).
- [5] Karniadakis, G.E.; G. Kevrekidis, I.G.; Lu, L.; Perdikaris, P.; Wang, S.; Yang, L: "Physics-informed machine learning". *Nat Rev Phys* 3, 422–440 (2021).
- [6] Raissi, M.; Perdikaris, P.; Karniadakis, G.E.: "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 (2019).
- [7] Viana AC, F.; Subramaniyan, A.K.: "A Survey of Bayesian Calibration and Physics-informed Neural Networks in Scientific Modeling." *Archives of Computational Methods in Engineering* 1-30 (2021).
- [8] Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., & Yang, L.: "Physics-informed machine learning." *Nature Reviews Physics* 3.6: 422-440, (2021).