

Masterarbeit

Multi-Fidelity-Optimierung zur Lösung nichtlinearer Machine-Learning-Probleme

Mohamad Traiki

In vielen Problemen des Machine Learning wie Klassifikation oder Regression ist beim Lernen im Kern ein nichtlineares Optimierungsproblem zu lösen. Solche Optimierungsprobleme sind schwierig zu lösen: Gradientenbasierte Verfahren sind zwar effizient aber konvergieren lokal. Metaheuristiken wie Partikelschwarmverfahren suchen zwar global, sind aber sehr ineffizient. Zur Verbesserung der Exploration bei lokal konvergierenden Verfahren werden oft Multi-Start-Strategien eingesetzt, die eine Population von zufälligen Startwerten bis zum Ende optimieren. Bei begrenztem Rechenbudget ist die Populationsgröße entsprechend klein.

Im Rahmen dieser Arbeit sollen Multi-Start-Strategien untersucht werden, die in mehreren Stufen aus der Population solche Modellkandidaten aussortieren, die eine schlechte Ergebnisprognose haben. Da so nicht alle Kandidaten bis zum Ende optimiert werden, kann eine größere Startpopulation verwendet und damit besser exploriert werden. Man spricht auch von „Multi-Fidelity“-Optimierung. Die Hypothese ist, dass es bei iterativen Optimierungsverfahren möglich ist, nach den ersten Iterationen aus dem Zwischenergebnis die final erreichte Güte eines Lösungskandidaten ausreichend gut zu prognostizieren. Im Rahmen dieser Arbeit sollen verschiedene Strategien konzipiert, implementiert und evaluiert werden. Als Aufgabenstellung sollen nichtlineare Regressionsaufgaben und als Modellansatz Takagi-Sugeno- und Multi-Layer-Perceptron-Modelle untersucht werden.

Die Teilaufgaben sind:

- Literatur-Recherche zu Multi-Stufe-/„Multi-Fidelity“-Optimierungsverfahren
- Einarbeitung in das Lernen von Takagi-Sugeno- und Multi-Layer-Perceptron-Modellen und Konzeption und Umsetzung (Matlab oder Python) verschiedener Multi-Stufen-Optimierungsverfahren für Regressionsprobleme
- Festlegung von ca. 10 Beispielproblemen (Testfunktionen, Benchmarkdatensätze) und von Bewertungskriterien (Modellgüte, Robustheit der Verfahren)
- Konzeption und Durchführung von Simulationsstudien: Stufenanzahl, Stufenpopulationsgrößen, Selektionskriterien für die nächste Stufe (Modellgüte, Güteprognose mittels Surrogatmodell,...), Iterationen pro Stufe, Störungsgrad der Daten, Vergleich mit Mini-Batch-Methoden
- Analyse und Bewertung der Ergebnisse
- Dokumentation der Ergebnisse und Vortrag.

Matlab oder Python-Kenntnisse sind nützlich, können aber im Rahmen der Arbeit erworben werden. Der Arbeitsumfang wird an die Art der Studienleistung angepasst.

Betreuer: Prof. Dr.-Ing. A. Kroll, Dr. H.J. Sommer

Beginn: 01.06.2023

Geplantes Ende: 28.02.2024

Literaturhinweise:

- [1] Jaderbreg, M., Dalibard, V., Osindero, S., Czarnecki, W.M., Donahue, J., Razavi, A., Vinyals, O., Green, T., Dunning, I., Simonyan, K., Fernando, C., Kavukcuoglu, K. Population based training of neural networks, arXiv.1711.08946v2 [cs.LG] 28 Nov 2017.
- [2] Kostenko, V.A. Multi-start method with cutting for solving problems of unconditional optimization, *Optical Memory and Neural Networks* 29(1) 30-36, 2020.
- [3] Kroll, A. *Computational Intelligence*, 2. Auflage, Oldenbourg/de Gruyter, 2016.
- [4] Liu, C., Zoph, B., Neumann, M., Shlens, J., Hua, W., Li, L.-J., Yuille, A., Huang, J., Murphy, K. Progressive neural architecture search, *ECCV* 2018.
- [5] Marinov, D., Karapetyan, D. Hyperparameter optimisation with early termination of poor performers, *Proc. Computer Science and Electronic Engineering*, 2019.
- [6] Marti, R., Resende, M.G.C., Ribeiro, C.C. Multi-start methods for combinatorial optimization, *European Journal of Operational Research* 226, 1-8, 2013.