

Vergleich von Datenreduktionskriterien für Online-Gaußprozesse zur Systemidentifikation

Thore Wietzke, Knut Graichen

Lehrstuhl für Regelungstechnik, Friedrich-Alexander-Universität Erlangen-Nürnberg, Cauerstraße 7, 91058 Erlangen, Tel: +49(0)9131/85-27419, E-Mail: Thore.Wietzke@fau.de

Die Verwendung von Gaußprozessen (GP) erfreut sich großer Beliebtheit für die Systemidentifikation von dynamischen Systemen. Ihr Vorteil besteht in ihrer nativen stochastischen Modellierung, wodurch die Unsicherheiten während und nach der Systemidentifikation berücksichtigt werden können. Für große Datenmengen sind sie dagegen nicht geeignet, da durch eine Matrixinversion die Rechenzeit mit $\mathcal{O}(N^3)$ skaliert. Hierfür existieren dünn besetzte Approximationen, auch Sparse GP genannt, die durch die Verwendung von induzierten Datenpunkten die Rechenzeitskalierung auf $\mathcal{O}(NM^2)$ reduzieren können [1].

Für die Online-Systemidentifikation sind selbst Sparse GP nicht geeignet, da kontinuierlich neue Datenpunkte integriert werden müssen. Ein häufiger Ansatz definiert ein maximales Budget N_{max} an Datenpunkten, die die Rechenzeitanforderungen für die Anwendung des Gaußprozesses einhält [2]. Zunächst werden neue Datenpunkte anhand eines Hinzufügekriteriums ausgewählt. Danach werden alte Datenpunkte mit den neuen Datenpunkten nach gewissen Reduktionskriterien ersetzt.

In der Literatur existieren für die Reduktion diverse Kriterien, die bisher nicht systematisch miteinander verglichen wurden [2, 3, 4]. In diesem Vortrag wird daher ein Vergleich der Reduktionskriterien durchgeführt und ihre Eignung anhand von Benchmark-Funktionen und Datensätzen zur Systemidentifikation behandelt [5]. Die Evaluation findet im Rahmen der Offline-Datenreduktion bzw. -selektion und innerhalb eines Online GPs statt. Hieraus lassen sich Empfehlungen für die Wahl des Reduktionskriteriums ableiten.

Literatur

- [1] Quiñonero-Candela, J.; Rasmussen C.-E.: A Unifying View of Sparse Approximate Gaussian Process Regression, *Journal of Machine Learning Research*, vol. 6, pp. 1939-1959, 2005.
- [2] Nguyen-Tuong, D.; Peters, J.: Incremental online sparsification for model learning in real-time robot control, *Neurocomputing*, vol. 74, no. 11, pp. 1859-1867, 2011.
- [3] Petelin, D.; Grancharova, A.; Kocijan, J.: Evolving Gaussian Process Models for Prediction of Ozone Concentration in the Air, *Simulation Modelling Practice and Theory*, vol. 33, pp. 68-80, 2013.
- [4] Bergmann, D.; Buchholz, M.; Niemeyer, J.; Remele, J.; Graichen, K.: Gaussian Process Regression for Nonlinear Time-Varying System Identifikation, *IEEE Conference on Decision and Control*, pp. 3025-3031, 2018.
- [5] Wietzke, T.; Graichen, K.: Comparison of Data Reduction Criteria for Online Gaussian Processes, *arXiv preprint arXiv:2508.10815*, 2025.