

Masterarbeit

Gaußsche Prozessmodelle für nichtlineare Regression und Systemidentifikation: Potentialanalyse für spanende Fertigungsprozesse und verfahrenstechnische Prozesse

Lars Kistner

Gaußsche Prozessmodelle (GPM) gehören zur Klasse der kernelbasierten, nichtparametrischen Modelle. Sie stammen aus dem Bereich des maschinellen Lernens. Einen normalverteilten Zufallsprozess unterstellend, präzisieren Sie die Zielgröße und deren Unsicherheit. GPM stellen einen Standardansatz beim Vorliegen hochdimensionaler Räume und wenig Daten dar. Da die notwendige Berechnungszeitkomplexität $O(N^3)$ ist, müssen bei großen Datensätzen allerdings Approximationen vorgenommen werden.

Im Rahmen dieser Masterarbeit soll die Eignung von GPM für die Anwendung in zwei technischen Problemstellungen untersucht werden. Erstens sollen nichtlineare Regressionsaufgaben betrachtet werden, wie sie bei der Modellierung mechanischer Materialeigenschaften bei der spanenden Fertigung auftreten. Hier gibt es viele Einflussgrößen, die die Ausprägung der Randschichteigenschaften beeinflussen, allerdings aus Aufwands-/Kostengründen nur wenige vermessene Proben (hochdimensionaler, spärlich belegter Eingangsdatenraum). Zweitens soll die Eignung für die nichtlineare Systemidentifikation insb. beim Vorliegen großer Datensätze (Zeitreihen) untersucht werden. Es soll abschließend eine vergleichende Diskussion von GPM und Multi-Modellen vom Typ Takagi-Sugeno (TS) durchgeführt werden, die in anderen aktuellen Arbeiten am Fachgebiet MRT für die gleichen Anwendungen eingesetzt werden. Die Teilaufgaben der Masterarbeit sind:

- Einarbeitung in GPM und Prüfung verfügbarer Implementierungen (insb. Matlab, Python).
- Recherche über und Anwendung von GPM für die Prädiktion von Eigenspannungsprofilen bei Hartdrehprozessen auf Basis eines vorliegenden Messdatensatzes (nichtlineare Regression). Dabei Klärung geeigneter Festlegungsmethoden der Hyperparameter (wie Rauschvarianz oder Ausdehnung).
- Recherche über und Anwendung von GPM für die nichtlineare Systemidentifikation am Beispiel der Prozessinsel 2 der Modellfabrik μ Plant. Dazu Konzipierung und Durchführung geeigneter Experimente mit der Prozessinsel 2. Dabei Untersuchung von verfügbaren Approximationsverfahren beim Vorliegen großer Datensätze sowie der lokalen Nachlernbarkeit zum kontinuierlichen Anlernen digitaler Zwillinge im laufenden Betrieb.
- Vergleichende Bewertung der Eignung und Eigenschaften von GP- und TS-Modellen für die behandelten Problemstellungen sowie für die Nutzung bei Vorsteuerungs- und Regelungsaufgaben. Aufzeigen weiterführender Fragestellungen und Lösungsansätze.
- Dokumentation und Kolloquiumsvortrag.

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

Beginn: Mai 2019

Geplantes Ende: November 2019

Literaturhinweise:

- [1] Beckers, T.M Umlauf, J.; Hirche, S.: Mean square prediction error of misspecified Gaussian process models, Proc. IEEE Conf. on Decision and Control, Miami Beach, 1162-1167, 2018.
- [2] Decker, T.; Nelles, O.: Local Gaussian process model networks, Proc. 28. Workshop Computational Intelligence, Dortmund, 235-256, 2018.
- [3] Gregorčič, G.; Lightbody, G.: Nonlinear system identification: from multiple-model networks to Gaussian processes. Engineering Applications of Artificial intelligence 21, 1035-1055, 2008.
- [4] Kocijan, J.; Girad, A.; Banko, B.; Murray-Smith, R.: Dynamic systems identification with Gaussian processes, Mathematical and Computer Modelling of Dynamical Systems 11(4) 411-424, 2005.
- [5] Kocijan, J.; Murray-Smith, R.; Rasmussen, C.E.; Girad, A.: Gaussian process model based predictive control, Proc. American Control Conference, Boston, 2214-2219, 2004.
- [6] Rasmussen, C. E.; Williams, C. K. I.: Gaussian processes for machine learning. MIT Press, 2006. Online: www.gaussianprocess.org/gpml/chapters/RW.pdf
- [7] Svensson, A.: Machine learning with state-space models, Gaussian processes and Monte Carlo methods, Digital Comprehensive Summaries of Uppsala Dissertations from the Faculty of Science and Technology 1709, Uppsala: Acta Universitatis Upsaliensis, 2018.
- [8] Svensson, A.; Solin, A. Särkkä, S.; Schön, T. B.: Computationally efficient Bayesian learning of Gaussian process state space models, Proc. 19th Int. Conference on Artificial Intelligence and Statistics (AISTATS), Cadiz, 213-221, 2016.
- [9] Wittich, F.: Zur datengetriebenen Modellierung der Eigenspannungstiefenverteilung beim Hartdrehen, Bachelorarbeit, FG Mess- und Regelungstechnik, Universität Kassel, 2019.
- [10] Wittich, F.: Zur Identifikation nichtlinearer Takagi-Sugeno-Modelle für Randschicht-zustände metallischer Werkstücke bei beschränkten Störungen der Zielgrößen, Masterarbeit, FG Mess- und Regelungstechnik, Universität Kassel, 2019 (in Bearbeitung).