

AI-rozšířené robustní řízení nelineárních systémů s využitím neceločíselného řádu a datově založené kvantifikace nejistot

AI-Enhanced Robust Control of Nonlinear Systems Using Fractional-Order Methods and Data-Driven Uncertainty Quantification

(Pozn: povinně uvést název i v angličtině)

Studijní program: Automatické řízení a informatika

Ústav fakulty: CEBlA-Tech / Ústav automatizace a řídicí techniky

Školitel: doc. Ing. Radek Matušů, Ph.D.

Konzultant: ---

Anotace:

Disertační práce bude zaměřena na vývoj nových metod inteligentního robustního řízení nelineárních dynamických systémů kombinujících metody umělé inteligence, přístupy s neceločíselným řádem a moderní metody robustního řízení. Motivací je skutečnost, že matematické modely reálných technických systémů často obsahují významné nejistoty, jejichž přesná parametrizace je obtížná, zatímco klasické modelové metody řízení mohou být za těchto podmínek citlivé na změny parametrů, nemodelovanou dynamiku a vnější poruchy. Současně mohou přístupy s neceločíselným řádem nabídnout vhodný nástroj pro popis a predikci dynamických jevů s paměťovým charakterem i pro syntézu řídicích algoritmů, a tím poskytnout dodatečné možnosti při návrhu celého řídicího systému.

Cílem práce bude vytvořit metodiku, v níž budou metody umělé inteligence využity především pro datově založenou identifikaci neznámých nebo obtížně modelovatelných částí dynamiky systému, odhad jejich změn a kvantifikaci nejistoty predikce. Součástí metodiky bude také zkoumání vhodného využití modelů a metod s neceločíselným řádem v jednotlivých částech procesu modelování, identifikace, predikce a řízení. Získaná informace bude následně integrována do návrhu robustního řídicího systému. Zásadním principem bude oddělení adaptační a učící složky od mechanismů zajišťujících robustnost a stabilitu uzavřené regulační smyčky. AI model tedy nebude představovat nekontrolovaný náhradní regulátor, ale prostředek pro získání dodatečné informace o dynamice systému a jeho nejistotách.

Výzkum se zaměří na návrh a analýzu metod robustního řízení založených například na fractional-order PI/PID regulaci, stavovém robustním řízení, H_∞ metodách, LMI formulacích nebo robustním modelově prediktivním řízením, přičemž neceločíselný řád může být využit jak přímo v řídicím algoritmu, tak v modelu či predikčním mechanismu. Pozornost bude věnována také možnostem adaptivního nastavování parametrů řídicích algoritmů na základě provozních dat a aktuálního odhadu nejistot. Součástí práce může být využití moderních metod statistické kvantifikace predikční nejistoty, například conformal prediction, a jejich propojení s podmínkami robustní stability a sledování požadované trajektorie.

Teoretická část bude zaměřena zejména na formulaci podmínek stability, robustního výkonu a omezené citlivosti vůči chybám AI modelu a nejistotám dynamického systému. Zkoumán bude také vztah mezi přesností datově získaného modelu, charakterem a velikostí odhadované nejistoty a výslednými vlastnostmi uzavřené regulační smyčky. Pozornost bude

věnována rovněž vlivu volby řádu a způsobu využití neceločíselných operátorů na vlastnosti modelu, predikce a výsledného řízení. Důležitou součástí bude návrh postupů umožňujících zohlednit nejistotu modelu přímo při návrhu robustního řídicího systému a současně zachovat praktickou realizovatelnost výsledné metody.

Navržené metody budou nejprve ověřeny na vybraných nelineárních modelech a následně experimentálně validovány na vhodném reálném mechatronickém systému. Hodnocena bude kvalita řízení, robustnost vůči parametrickým změnám, nemodelované dynamice, vnějším poruchám a šumu měření, stejně jako výpočetní náročnost a možnosti implementace v reálném čase. Očekávaným výsledkem práce je obecná metodika pro propojení datového učení s robustním řízením nelineárních systémů s využitím přístupů s neceločíselným řádem v modelování, predikci a/nebo řízení, která využije adaptabilitu metod umělé inteligence a současně zachová analyticky zdůvodnitelné vlastnosti uzavřeného řídicího systému.

Literatura:

- [1] I. R. Manchester, R. Wang, and N. H. Barbara, "Neural Networks in the Loop: Learning with Stability and Robustness Guarantees," *Annual Review of Control, Robotics, and Autonomous Systems*, vol. 9, pp. 181–214, 2026. <https://doi.org/10.1146/annurev-control-022624-032459>
- [2] T. K. Bashishtha, V. P. Singh, U. K. Yadav, and U. K. Sahu, "Fractional-order PID controllers and applications: A comprehensive survey," *Annual Reviews in Control*, vol. 60, Art. 101013, 2025. <https://doi.org/10.1016/j.arcontrol.2025.101013>
- [3] M. C. Martins-Gomes, F. A. de C. Ayres Junior, C. T. da Costa Junior, I. V. de Bessa, N. J. da S. Farias, R. L. P. de Medeiros, L. E. S. Silva, and V. F. de Lucena Júnior, "Fractional-Order Robust Control Design under parametric uncertain approach," *ISA Transactions*, vol. 153, pp. 420–432, 2024. <https://doi.org/10.1016/j.isatra.2024.07.023>
- [4] A. Veisi and H. Delavari, "Deep reinforcement learning optimizer based novel Caputo fractional order sliding mode data driven controller," *Engineering Applications of Artificial Intelligence*, vol. 140, Art. 109725, 2025. <https://doi.org/10.1016/j.engappai.2024.109725>
- [5] T. A. Mahmoud, M. El-Hossainy, B. Abo-Zalam, and R. Shalaby, "Event-triggered fractional-order fuzzy sliding mode control using online reinforcement learning for uncertain nonlinear systems: Practical validation," *Engineering Applications of Artificial Intelligence*, vol. 151, Art. 110653, 2025. <https://doi.org/10.1016/j.engappai.2025.110653>
- [6] T.-W. Hsu and H. Tsukamoto, "Statistical Guarantees in Data-Driven Nonlinear Control: Conformal Robustness for Stability and Safety," *IEEE Control Systems Letters*, vol. 9, pp. 997–1002, 2025. <https://doi.org/10.1109/LCSYS.2025.3578062>
- [7] S. Wei, M. Ornik, and H. Tsukamoto, "Conformal Contraction for Robust Nonlinear Control with Distribution-Free Uncertainty Quantification," in *2025 IEEE 64th Conference on Decision and Control (CDC)*, pp. 3502–3507, 2025. <https://doi.org/10.1109/CDC57313.2025.11312813>
- [8] M. M. Morato and M. S. Felix, "Data Science and Model Predictive Control: A survey of recent advances on data-driven MPC algorithms," *Journal of Process Control*, vol. 144, Art. 103327, 2024. <https://doi.org/10.1016/j.jprocont.2024.103327>