

Povzetek dispozicije doktorske disertacije: Načrtovanje eksperimentov na podlagi samorazvijajočega se nevro-mehkega modela za identifikacijo nelinearnih dinamičnih sistemov

Miha Ožbot, Igor Škrjanc

Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana, Slovenija
miha.ozbot@fe.uni-lj.si, igor.skrjanc@fe.uni-lj.si

Povzetek. Dispozicija doktorske disertacije predstavlja načrtovanje eksperimentov na podlagi samorazvijajočega se nevro-mehkega modela za identifikacijo nelinearnih dinamičnih sistemov. Tradicionalno modelno osnovano spremljanje procesov in programski senzorji zahtevajo pogosto ponovno umerjanje zaradi lezenja sistema, nenadnih sprememb in kompleksnosti procesov. Z združevanjem samorazvijajočega se nevro-mehkega modela z adaptivnim načrtovanjem eksperimentov si doktorska raziskava prizadeva razviti metode za samodejno izbiro informativnih spremenljivk, optimizacijo signalov vzbujanja in zanesljivo identifikacijo v prisotnosti šuma, manjkajočih podatkov in nestacionarnih pogojev. Pričakovani rezultat je sistem za adaptivne programske senzorje, ki bo izboljšal natančnost napovedi, stroškovno učinkovitost in dolgoročno uporabnost v industrijskih okoljih ob minimalnem človeškem posredovanju.

Ključne besede: samorazvijajoči se sistemi, mehka logika, načrtovanje eksperimentov, nelinearni dinamični sistemi, identifikacija, programski senzorji

Summary of a Doctoral Dissertation Proposal: Evolving Neuro-Fuzzy Model-Based Design of Experiments for Identification of Nonlinear Dynamical Systems

This dissertation proposal introduces an *evolving neuro-fuzzy* model-based *design of experiments* for the identification of nonlinear dynamical systems. Traditional model-based *process monitoring* and *soft sensors* require frequent recalibration due to *system drift*, sudden shifts, and process complexity. The proposed research will investigate how evolving systems, capable of online learning from data streams, can adapt both their structure and parameters to improve robustness and reduce manual intervention. By integrating evolving neuro-fuzzy inference with adaptive design of experiments, the study aims to develop methods for automated selection of informative variables, optimization of excitation signals, and reliable identification under noisy, incomplete, and nonstationary conditions. The expected outcome is a framework for adaptive soft sensors that enhance prediction accuracy, cost efficiency, and long-term applicability in industrial environments with minimal human intervention.

1 UVOD

Modelno osnovane metode za spremljanje in nadzor procesov nudijo precejšnje prednosti pred tradicionalnimi pristopi, ki temeljijo na ročnih posegih in laboratorijskih preizkusih. Z namenom izboljšanja takih

sistemov algoritmični programski senzorji (*soft sensors*) uporabljajo matematične modele za oceno dragih ali težko merljivih stanj ali procesnih spremenljivk iz drugih enostavno merljivih spremenljivk, kar zagotavlja stroškovno učinkovitejšo in zanesljivo rešitev. Vendar pa sta izgradnja in vzdrževanje programskih opazovalnikov običajno zapletena, saj se razmere delovanja industrijskih naprav in procesov nenehno spreminjajo. Strojna oprema se obrablja in potrebuje vzdrževanje ali zamenjavo, spremembe procesnih pogojev pa lahko zmanjšajo zanesljivost modela.

S pomočjo metod identifikacije nelinearnih sistemov in mehkega računanja lahko ustvarimo podatkovno osnovane procesne modele ter spremljamo delovanje procesov in zagotavljamo optimalno delovanje z merjenjem ključnih spremenljivk. Nesprotne (*offline*) modele razvijemo na podlagi zgodovinskih podatkov, pri čemer predpostavljamo, da bodo lastnosti delovanja sistema v realnem času podobne. Kljub temu lahko lastnosti sistemov in njihovega okolja počasi lezejo (*drift*) ali se skočno pomaknejo (*shift*), npr. senzorji lahko doživijo termično lezenje ali staranje, zaradi česar postanejo modeli nezanesljivi. Ti dejavniki zahtevajo pogosto kalibracijo programskih senzorjev, kar vključuje prestrukturiranje in vzdrževalna dela strokovnjakov ter lahko povzročijo znatne stroške.

Uporaba samorazvijajočih se sistemov (*evolving systems*), ki so zmožni postopoma prilagoditi svoje parametre in strukturo z uporabo sprotnega učenja iz toka


Prejet 27. avgust, 2025

Odobren 10. november, 2025



Avtorske pravice: © 2025
Creative Commons Attribution 4.0
International License

podatkov (*data stream*), je učinkovita rešitev za razvoj modelov v spremenljivem okolju. Analiza podatkov v realnem času še dodatno olajša optimizacijo proizvodnih procesov, saj omogoča izbor optimalnih signalov vzburljenja in parametrov algoritma za kalibracijo mehkih senzorjev. Takšna programska orodja lahko pripomorejo tudi k izboljšanju kakovosti in količine proizvodnje ter interoperabilnosti senzorskih sistemov, kar prinaša velike koristi industrijskim aplikacijam. Shema idejne zasnove predlagane teme doktorske disertacije je predstavljena na sliki 1. V okviru doktorske disertacije se bomo osredotočili na identifikacijo samorazvijajočih se nevromehkih sistemov, ki se lahko gradijo sproti in nudijo neposredne in dolgotrajne prednosti pri učinkovitosti podatkovnih senzorjev.



Slika 1 Shema predlagane raziskovalne teme s samorazvijajočim se načrtovanjem eksperimentov, uporabljene pri nalogi programske senzorike v procesnem vodenju in nadzoru. Tradicionalni pristop (zgoraj) je nadgrajen z ogrodjem razvijajočega se sistema (spodaj), ki se sproti uči modela procesa na podlagi metodologije načrtovanja eksperimentov.

2 PREGLED LITERATURE

V zadnjih dveh desetletjih se je razpoložljivost podatkov v obliki toka podatkov iz različnih virov, kot so internet stvari (*Internet of Things* – IoT), industrijski senzorji (industrija 4.0), informacijsko-komunikacijska tehnologija, trgovanje na borzi, globalna oskrbna logistika, pametna energetska omrežja, mobilna robotika, zdravstveni nadzor itd. [1], [2], občutno povečala, kar je privedlo do povečanega zanimanja za rudarjenje podatkov (*data mining*) s sprotnim učenjem (*online learning*). Ti toki podatkov so sestavljeni iz neskončnega števila vzorcev, ki prihajajo drug za drugim, in jih pogosto ni mogoče shranjevati zaradi strojnih omejitev ali prevelike količine. Poleg tega se lahko lastnosti podatkov sčasoma

spreminjajo zaradi nenadnih nestacionarnih premikov in pojavov počasnega lezenja. Posledično morajo biti algoritmi, ki se uporabljajo za obdelavo teh podatkov, sposobni opisovati različne porazdelitve podatkov, se prilagajati konceptualnim spremembam, delovati v realnem času in se učinkovito prilagajati dimenzionalnosti problema (*curse of dimensionality*) [1], [3], [4].


2.1 Samorazvijajoči se inteligentni sistemi

Za obravnavo sprotnega učenja iz podatkovnih tokov so bili predlagani samorazvijajoči se inteligentni sistemi (*Evolving Intelligent Systems* – EIS) [5], ki imajo zmožnost posodabljanja svoje strukture in parametrov skozi čas (glej sliko 2). To pomeni, da se sistem lahko prilagaja na podlagi najnovejših razpoložljivih podatkov, zaradi česar je primeren za realnočasovne aplikacije, kjer se lastnosti sistema nenehno spreminjajo. Samorazvijajoči se nevromehki sistemi sklepanja (*Evolving Neuro-Fuzzy Inference Systems* ENFIS) so posebna vrsta EIS, ki združujejo mehko logiko s strukturo nevronskega omrežja [1].

Samorazvijajoči se nevromehki modeli so običajno sestavljeni iz predhodne pogojne strukture, ki temelji na večdimenzionalnih Gaussovih rojih [6], trapezoidnih informacijskih granulah [7], Cauchyjevih podatkovnih oblakih [8] ali drugih pristopih, ter posledičnega dela s polinomskimi in afinimi linearnimi funkcijami. To sistemu omogoča, da podatke pretvori v nelinearne dinamične strukture, medtem ko ohranja preglednost in razumljivost komponent [9], kar je pomembno v industrijskem okolju, kjer morajo biti rezultati ponovljivi in preverljivi.

Ker so samorazvijajoči se sistemi zasnovani za samodejno posodabljanje v realnem času, potrebujejo mehanizme za dodajanje novih pravil, ko postanejo na voljo novi podatki, ki jih obstoječa struktura ne predstavlja ustrezno. Poleg tega morajo biti takšni sistemi zmožni odstraniti odvečna ali neustrezna pravila, razcepiti pravila za povečanje natančnosti modela, ko se vzorci začnejo razhajati, in združiti pravila za poenostavitev strukture, ko se vzorci združujejo [1], [9]. Lastnosti ENFIS so obetavna možnost za identifikacijo procesov v realnem času in spremljanje stanja, kjer tradicionalni pristopi modeliranja v nesprotnem načinu delovanja ne zadostujejo [10].

Nekateri najbolj vplivni samorazvijajoči se mehki in nevromehki sistemi zadnjega desetletja so: eTS+ [5], FLEXFIS+ [11], AnYa [8], FBeM [7], PANFIS [12], eFuMo [13], GS-EFS [14] in eGauss+ [6]. Uporabljeni so bili pri klasifikaciji podatkov [6], identifikaciji sistemov [3], adaptivnem vodenju [15], diagnostiki napak [13], načrtovanju eksperimentov [16] in lokalizaciji [17]. Mehanizmi za združevanje in razcepljanje večdimenzionalnih Gaussovih rojev ostajajo odprto raziskovalno vprašanje zaradi računske zahtevnosti v sprotnem načinu delovanja [18], [6]. Večina ENFIS temelji na uteženi rekurzivni metodi najmanjših kvadratov,



Slika 2 Prikaz paradigme samorazvijajočih se sistemov na primeru nenadzorovanega učenja. Podatki prihajajo v obliki podatkovnega toka, katerega lastnosti se s časom spreminjajo. Sistem mora imeti sposobnost sprotnega prilagajanja svojih komponent ter dodajanja novih, njihovega združevanja in odstranjevanja skozi čas. Prikazan je časovni potek samorazvijajočega se učenja, kjer so roji predstavljeni z Gaussovimi elipsami (modra), ki zajemajo pretekle (sive) in nove (črne) podatke.

občutljivi za šum, osamelce in manjkajoče podatke [4], zato ostajajo glavni izzivi robustnost ter dolgoročna stabilnost in konvergenca. To pomanjkanje zagotovil omejuje njihovo uporabo v industriji [1].

2.2 Programski senzorji

Podatkovno osnovani programski senzorji (*Data-Driven Soft Sensors – DDSS*) [19] so programski algoritmi za ocenjevanje težko merljivih stanj sistema ali spremljanje spremenljivk kakovosti, ki imajo velik časovni zamik meritev, so drage za merjenje ali jih je težko meriti s pomočjo strojnih senzorjev. DDSS se uporabljajo za različne namene, kot so napovedovanje vrednosti signalov, kadar meritve niso na voljo [13], delovanje kot opazovalniki stanj [20], odkrivanje napak in degradacije senzorjev [18], modeliranje stroškovnih spremenljivk in spremenljivk kakovosti [21]. Na primer, v [20] je bil uporabljen opazovalec za merjenje stanj gorivne celice s polimerno elektrolitsko membrano, medtem ko je bil v [22] uporabljen programski senzor s kodirno-dekodirnim sistemom za spremljanje procesa proizvodnje.

Predlagani so bili tudi že samorazvijajoči se programski senzorji [13] za spremljanje čistilne naprave za odpadne vode, samorazvijajoči se sistem ogrevanja, prezračevanja in klimatizacije [21] ter ansambel samorazvijajočih se modelov za sprotno podatkovno osnovano spremljanje stanja in prediktivno vzdrževanje orodja (*Tool Condition Monitoring*) [18]. Ti sistemi še ne vključujejo metodologije načrtovanja eksperimentov, izbire vhodnih signalov, odstranjevanja zastarelih komponent, samovrednotenja, obravnave osamelcev ali uporabe intervalov zaupanja.

2.3 Adaptivno načrtovanje eksperimentov

Za identifikacijo nelinearnega dinamičnega sistema je pomembno zbrati informativne podatke, ki so frekvenčno bogati in vsebujejo odziv sistema v širokem obsegu obratovalnih pogojev. Pri izbiri vzbujalnega signala za merjenje odziva sistema je ključno upoštevati morebitne omejitve strojne opreme ali nestabilna območja vhodnega prostora, da zagotovimo kakovostne podatke za identifikacijo. Načrtovanje eksperimentov (*Design*

of Experiment DoE) se uporablja za izbiro optimalnih vrednosti neodvisnih spremenljivk in parametrov za identifikacijo modelov z minimalnim naporom. DoE je statistična metodologija, ki vključuje izbiro vplivnih dejavnikov, ustvarjanje načrta preizkusov in analizo pridobljenih podatkov s pomočjo statističnih tehnik.

Izbira metode DoE je odvisna od uporabe, na primer identifikacija dinamičnega ali statičnega modela, ali analize pomembnosti spremenljivk. Načrti, ki temeljijo na polnjenju prostora (*space-filling design*), kot so Minimax, Maximin in Latin Hypercube Sampling (LHS), izberejo spremenljivke v določenem vzorcu po prostoru. Medtem ko se lahko optimalni načrti (*optimal design*), ki temeljijo na Fisherjevi informacijski matriki, kot so D-optimalni, A-optimalni in G-optimalni načrt, uporabljajo za optimizacijo vhodnih signalov na podlagi obstoječega modela [16], [23]. Predstavljeni so bili tudi zaporedni načrti (*sequential design*), ki izbirajo nove meritve na podlagi prej identificiranega modela in postopoma prilagajajo njegovo strukturo [24], ter pristopi za postopno razširjanje dimenzije prostora modela [25].

Metode sprotnega načrtovanja eksperimentov imajo pomembno prednost pred nesprotnimi metodami in iterativnimi metodami, saj optimizirajo vhodni signal za ciljni sistem, kar vodi do vzorčno učinkovitega načrta, ki zmanjšuje število potrebnih vzorcev za identifikacijo [26]. Na primer, v [16] je bil predlagan pristop DoE z vrha navzdol, ki razdeli regije in izbira nove vzorce, vendar ne modelira dinamike sistema. Predlagana je bila metoda DoE za opazovalnik stanj sistema z izbiro najbolj informativnih spremenljivk [20]. Raziskovanje celotnega problemskega prostora je namreč težavno zaradi bodisi previsoke dimenzije ali pa je vzorčenje drago. Treba je pametno izbirati spremenljivke, značilke ali vzorce za zmanjšanje potrebnega števila meritev za visoko natančnost modela [3], [23], [20]. Čeprav sta bila sprotna izbira značilk [8], [12], [14], [25] in vzorcev [3] že predlagana za ENFIS, ta pristop še ni bil uporabljen pri načrtovanju eksperimentov za programski senzor. V dinamičnih okoljih se informativne spremenljivke s časom spreminjajo [4], zato model zahteva stalno spremljanje in prilagajanje.

3 RAZISKOVALNA VPRAŠANJA

Cilj modeliranja je uporaba podatkovno osnovanih modelov za naloge programskega zaznavanja. Načrtovanje eksperimentov ima v tem kontekstu ključno vlogo, saj pomaga pri izbiri ustreznih spremenljivk in signalov vzbujanja, s čimer izboljšuje kakovost podatkov in skrajšuje čas eksperimentiranja.

Pri raziskavah bo treba obravnavati več ključnih izzivov. Pomemben vidik je modifikacija klasičnih tehnik načrtovanja eksperimentov za sprotno učenje, ki odpravlja potrebo po shranjevanju preteklih vzorcev in upošteva načela samorazvijajočih se sistemov. Poleg tega je velik izziv oblikovanje algoritmov in mehanizmov, ki omogočajo učinkovito prilagajanje na postopno spreminjanje parametrov sistema skozi čas. Še en izziv je zagotavljanje robustnosti nevro-mehke samorazvijajoče se metode identifikacije tudi ob prisotnosti manjkajočih vzorcev, šuma ali napak senzorjev. Poleg tega med sprotno validacijo modela postane zahtevna naloga kvantitativno opredeliti, ali je lokalna napaka posledica pristranskosti ali variance parametrov.

Predlagani pristop vključuje uporabo samorazvijajočih se nevro-mehkih sistemov sklepanja v povezavi z načrtovanjem eksperimentov, kar omogoča samokalibracijo in samopotrjevanje samorazvijajočega se mehkega senzorja. To področje še ni bilo obsežno obravnavano v literaturi. Čeprav so bile že izvedene posamezne raziskave na področju načrtovanja eksperimentov [16] in programskih senzorjev [13] s samorazvijajočimi se sistemi, še ni bil raziskan celovit pristop, ki združuje načrtovanje in validacijo pri samorazvijajočih se sistemih. To je pomembna vrzel v znanju, ki jo nameravamo obravnavati v doktorski disertaciji.

Na podlagi pregleda literature in opravljenih študij so bila oblikovana naslednja raziskovalna vprašanja:

- R1 Ali lahko metoda identifikacije samorazvijajočih se nevro-mehkih modelov kompenzira lezenje parametrov sistema ter ostane odporna proti manjkajočim vzorcem, povečanemu šumu in osamelcem?
- R2 Ali je mogoče za samodejno nastavljanje programskega senzorja uporabiti identifikacijo samorazvijajočega se nevro-mehkega modela z načrtovanjem eksperimentov ter s tem poenostaviti razvoj in vzdrževanje v primerjavi z nesprotnimi pristopi?
- R3 Katere dodatne funkcije je smiselno vključiti v samorazvijajoči se programski senzor (npr. sistemi za podporo odločanju)?
- R4 Ali je mogoče razviti celovit postopek ter smernice za razvoj in validacijo samorazvijajočih se programskih senzorjev?

Samorazvijajoči se programski senzorji imajo več potencialnih aplikacij, vključno z izboljšanjem odzivnosti časovno kritičnih sistemov z minimalnim človeškim posredovanjem ter natančnosti identifikacije sistema ob zmanjšanju časovnih in surovinskih stroškov, z odkri-

vanjem in ponovnim umerjanjem senzorjev v primeru lezenja in pomikov parametrov ter s spremljanjem sistema, zaznavanjem in diagnostiko napak ter napovednim vzdrževanjem opreme. Uporabni so lahko tudi za opazovanje stanj sistema v primerih, ko se določena stanja redko merijo, ko manjkajo vzorci ali ob prisotnosti osamelcev.

4 ZAKLJUČEK

Predstavili smo dispozicijo doktorske disertacije samorazvijajočega se programskega senzorja, ki ga je mogoče uporabiti za industrijsko opremo in zajema načrtovanje eksperimentov na podlagi modelov, identifikacijo samorazvijajočih se nevro-mehkih dinamičnih modelov in njihovo validacijo. Cilj raziskav je razvoj novega pristopa k samorazvijajočemu se nevro-mehkemu sistemu za identifikacijo nelinearnih dinamičnih sistemov, odpornega proti šumu, lezenju in nenadnim pomikom. Metoda bo ovrednotena z vidika natančnosti napovedi, števila rojev in računske zahtevnosti, vključuje pa tudi samodejno izbiro informativnih spremenljivk in optimizacijo vhodnih signalov za pospešitev identifikacije ter zmanjšanje potrebe po ročnem posredovanju. Posebna pozornost je namenjena vmesnim raziskavam, ki obravnavajo adaptivno načrtovanje eksperimentov na ploščnem toplotnem izmenjevalniku [27], merjenje prekrivanja rojev [28], prediktivno vodenje z istočasno identifikacijo procesa [29], sprotno ocenjevanje intervalov zaupanja [30] ter distribuirano učenje na robnih napravah [31]. Ti prispevki skupaj tvorijo metodološki okvir, ki omogoča praktično uresničitev samorazvijajočih se programskih senzorjev v realnih pogojih.

ZAHVALA

Avtorji se zahvaljujejo za finančno podporo Javne agencije za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije (ARIS), številka projekta P2-0219.

LITERATURA

- [1] I. Škrjanc, J. Iglesias, A. Sanchis, D. Leite, E. Lughofer, and F. Gomide, "Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A Survey," *Information Sciences*, vol. 490, pp. 344–368, 7 2019.
- [2] G. Ditzler, M. Roveri, C. Alippi, and R. Polikar, "Learning in nonstationary environments: A survey," *IEEE Computational Intelligence Magazine*, vol. 10, no. 4, pp. 12–25, 2015.
- [3] E. Lughofer and M. Pratama, "Online Active Learning in Data Stream Regression Using Uncertainty Sampling Based on Evolving Generalized Fuzzy Models," *IEEE Transactions on Fuzzy Systems*, vol. 26, pp. 292–309, 2 2018.
- [4] E. Lughofer, "Improving the robustness of recursive consequent parameters learning in evolving neuro-fuzzy systems," *Information Sciences*, vol. 545, pp. 555–574, 2 2021.
- [5] P. Angelov, "Evolving Takagi-Sugeno Fuzzy Systems from Streaming Data (eTS+)," *Evolving Intelligent Systems: Methodology and Applications*, pp. 21–50, 4 2010.
- [6] I. Škrjanc, "Cluster-Volume-Based Merging Approach for Incrementally Evolving Fuzzy Gaussian Clustering-eGAUSS+," *IEEE Transactions on Fuzzy Systems*, vol. 28, pp. 2222–2231, 9 2020.

- [7] D. Leite, R. Ballini, P. Costa, and F. Gomide, "Evolving fuzzy granular modeling from nonstationary fuzzy data streams," *Evolving Systems*, vol. 3, pp. 65–79, 6 2012.
- [8] P. Angelov and R. Yager, "A new type of simplified fuzzy rule-based system," *International Journal of General Systems*, vol. 41, pp. 163–185, 2012.
- [9] E. Lughofer, "On-line assurance of interpretability criteria in evolving fuzzy systems – Achievements, new concepts and open issues," *Information Sciences*, vol. 251, pp. 22–46, 12 2013.
- [10] O. Nelles, "Nonlinear Dynamic System Identification," *Nonlinear System Identification*, pp. 831–891, 2020.
- [11] E. Lughofer, J. L. Bouchot, and A. Shaker, "On-line elimination of local redundancies in evolving fuzzy systems," *Evolving Systems*, vol. 2, pp. 165–177, 9 2011.
- [12] M. Pratama, S. G. Anavatti, P. P. Angelov, and E. Lughofer, "PANFIS: A novel incremental learning machine," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, pp. 55–68, 1 2014.
- [13] D. Dovžan, V. Logar, and I. Škrjanc, "Implementation of an Evolving Fuzzy Model (eFuMo) in a Monitoring System for a Waste-Water Treatment Process," *IEEE Transactions on Fuzzy Systems*, vol. 23, pp. 1761–1776, 10 2015.
- [14] E. Lughofer, C. Cernuda, S. Kindermann, and M. Pratama, "Generalized smart evolving fuzzy systems," *Evolving Systems*, vol. 6, pp. 269–292, 12 2015. Gen-Smart-EFS.
- [15] G. Andonovski, P. Angelov, S. Blažič, and I. Škrjanc, "A practical implementation of Robust Evolving Cloud-based Controller with normalized data space for heat-exchanger plant," *Applied Soft Computing*, vol. 48, pp. 29–38, 11 2016.
- [16] I. Škrjanc, "Evolving Fuzzy-Model-Based Design of Experiments with Supervised Hierarchical Clustering," *IEEE Transactions on Fuzzy Systems*, vol. 23, pp. 861–871, 8 2015.
- [17] G. Klančar and I. Škrjanc, "Evolving principal component clustering with a low run-time complexity for LRF data mapping," *Applied Soft Computing*, vol. 35, pp. 349–358, 10 2015.
- [18] M. Pratama, E. Dimla, T. Tjahjowidodo, W. Pedrycz, and E. Lughofer, "Online Tool Condition Monitoring Based on Parsimonious Ensemble+," *IEEE Transactions on Cybernetics*, vol. 50, pp. 664–677, 2 2020.
- [19] J. Mendes, F. Souza, R. Araújo, and N. Gonçalves, "Genetic fuzzy system for data-driven soft sensors design," *Applied Soft Computing*, vol. 12, pp. 3237–3245, 10 2012.
- [20] Z. P. Du, C. Steindl, S. Jakubek, and C. Hametner, "Concentration Estimation for Fuel Cells: Design of Experiments, Nonlinear Identification, and Observer Design With Experimental Validation," *IEEE Access*, vol. 11, pp. 10453–10470, 2023.
- [21] G. Andonovski, G. Mušič, S. Blažič, and I. Škrjanc, "Evolving model identification for process monitoring and prediction of non-linear systems," *Engineering Applications of Artificial Intelligence*, vol. 68, pp. 214–221, 2 2018.
- [22] L. Feng, C. Zhao, and Y. Sun, "Dual Attention-Based Encoder-Decoder: A Customized Sequence-to-Sequence Learning for Soft Sensor Development," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 32, pp. 3306–3317, 8 2021.
- [23] C. Hametner, M. Stadlbauer, M. Deregnaucourt, S. Jakubek, and T. Winsel, "Optimal experiment design based on local model networks and multilayer perceptron networks," *Engineering Applications of Artificial Intelligence*, vol. 26, pp. 251–261, 1 2013.
- [24] J. Bect, F. Bachoc, and D. Ginsbourger, "A supermartingale approach to Gaussian process based sequential design of experiments," <https://doi.org/10.3150/18-BEJ1074>, vol. 25, pp. 2883–2919, 11 2019.
- [25] T. Voigt, M. Kohlhase, and O. Nelles, "Incremental DoE and Modeling Methodology with Gaussian Process Regression: An Industrially Applicable Approach to Incorporate Expert Knowledge," *Mathematics* 2021, Vol. 9, Page 2479, vol. 9, p. 2479, 10 2021.
- [26] H. J. V. Waarde, "Beyond Persistent Excitation: Online Experiment Design for Data-Driven Modeling and Control," *IEEE Control Systems Letters*, vol. 6, pp. 319–324, 2022.
- [27] M. Ožbot, E. Lughofer, and I. Škrjanc, "Evolving neuro-fuzzy systems-based design of experiments in process identification," *IEEE Transactions on Fuzzy Systems*, vol. 31, no. 6, p. 1995–2005, 2023.
- [28] M. Ožbot and I. Škrjanc, "Mere prekrivanja večrazsežnih gaussovih rojev v nenadzorovanem sprotnem učenju," p. 226–230, Slovenska sekcija IEEE; Fakulteta za elektrotehniko, 2024.
- [29] M. Ožbot and I. Škrjanc, "Evolving fuzzy model predictive control based on optimization for nonlinear plate heat exchanger," in *PROCEEDINGS 34. WORKSHOP COMPUTATIONAL INTELLIGENCE*, vol. 21, p. 77, 2024.
- [30] M. Ožbot and I. Škrjanc, "Online design of experiments with fuzzy confidence interval for identification of nonlinear dynamical processes," in *2024 IEEE International Conference on Evolving and Adaptive Intelligent Systems (EAIS)*, p. 1–8, May 2024.
- [31] M. Ožbot, S. Ozawa, and I. Škrjanc, "efedgauss: A federated approach to fuzzy multivariate gaussian clustering," in *2024 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, p. 1–8, 2024.

Miha Ožbot je leta 2018 na Fakulteti za elektrotehniko Univerze v Ljubljani diplomiral iz elektrotehnike ter leta 2021 na isti fakulteti tudi magistriral. Trenutno opravlja doktorski študij elektrotehnike na tej fakulteti. Njegovo raziskovanje je usmerjeno na samorazvijajoče se sisteme, predvsem njihove uporabe v identifikaciji sistemov, programskih senzorjih, nevronskih mrežah, globalnih optimizacijskih tehnikah, načrtovanju eksperimentov, federativnem učenju in vodenju sistemov.

Igor Škrjanc je v letih 1988, 1991 in 1996 diplomiral, magistriral in doktoriral na Fakulteti za elektrotehniko Univerze v Ljubljani. Je redni profesor na tej fakulteti, vodja Laboratorija za avtomatiko in kibernetiko in predstojnik Katedre za avtomatiko in kibernetiko. Na dodiplomskem študiju predava predmet industrijski krmilni in regulacijski sistemi, na podiplomskem pa inteligentne metode za podporo odločanju. Njegova glavna raziskovalna področja so adaptivni, prediktivni, nevromehki in mehki adaptivni sistemi vodenja. Njegovo trenutno raziskovanje vključuje tudi področje avtonomnih mobilnih sistemov v smislu lokalizacije, neposrednega vizualnega nadzora in sledenja poti.