

Uporaba Metode rojenja z lastnim odzivom v minimalno invazivnem nadzornem sistemu

Žiga Stržinar¹, Boštjan Pregelj¹ in Igor Škrjanc²

¹Institut Jožef Stefan, Jamova c. 39, 1000 Ljubljana, Slovenija

²Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška c. 25, 1000 Ljubljana, Slovenija

ziga.strzinar@ijs.si, bostjan.pregelj@ijs.si, igor.skrjanc@fe.uni-lj.si

Using Eigenresponse Fuzzy Clustering in a minimal-invasive supervisory system

Effective supervision of production processes is critical to ensuring product quality, maximizing production asset utilization, and improving overall performance metrics. However, the cost of implementing control systems can be prohibitively high, with such systems typically only being available on mass-produced machines. As a result, control systems are often unavailable on unique machines, which represent the majority of production assets. In order to promote wider use of control systems, our research focuses on utilizing minimally invasive or existing measuring equipment to enable control system implementation on unique machines. Specifically, we concentrate on repeatable industrial processes, with a particular emphasis on batch production. We propose a sequence of tasks that enable real-time detection of anomalies during operation. In this paper, we present a method for time series classification called Eigenresponse Fuzzy Clustering, which uses a condensed representation of each class with a limited number of prototypes known as Eigenresponses. We demonstrate the effectiveness of this method in detecting the actuation of various pneumatic actuators.

Kratek pregled prispevka

Nadzor proizvodnih procesov je ključen dejavnik za zagotavljanje kakovosti, maksimiziranje izrabe proizvodnih sredstev in izboljšanje drugih kazalnikov uspešnosti. Visoka cena uvedbe nadzornega sistema pa je pogosto ovira, zato so ti sistemi tipično na voljo le na masovno proizvedenih strojih, medtem ko so na unikatnih strojih na voljo le v omejenem obsegu. S ciljem spodbujanja širše uporabe nadzornih sistemov dajemo prednost uporabi minimalno invazivne ali že obstoječe merilne opreme, s čimer omogočamo uporabo nadzornega sistema tudi na unikatnih strojih, ki predstavljajo večino proizvodnih sredstev. V našem prispevku se osredotočamo na domeno ponovljivih se industrijskih procesov, s poudarkom na kosovni proizvodnji. Predstavljamo predlagano zaporedje opravil, ki omogočajo odkrivanje anomalij v realnem času. V prispevku predstavimo Metodo mehkega rojenja z lastnim odzivom, ki omogoča klasifikacijo časovnih vrst. Pristop temelji na zgoščeni predstavitvi vsakega razreda z omejenim številom prototipov. Metodo demonstriramo za zaznavanje aktiviranja različnih pnevmatskih aktuatorjev.

1 Uvod

Nadzorni sistemi so ključni za zagotavljanje visoke kakovosti izdelkov in maksimizacijo izkoriščenosti proizvodnih virov. Vendar pa je njihova implementacija draga, zato so redko prisotni na unikatnih strojih. Naš cilj je pomagati proizvodnim podjetjem doseči nadzor nad široko paleto proizvodnih strojev brez invazivnih posegov ali vplivov na osnovno delovanje stroja.

Spremljanje procesov je ključno za uspešno proizvodnjo, saj podjetjem omogoča, da zagotovijo učinkovito delovanje proizvodnih procesov. To vključuje zbiranje in analizo podatkov iz različnih stopenj proizvodnega procesa. S tem lahko podjetja hitro ugotovijo morebitna odstopanja ali nepravilnosti, ki lahko vplivajo na kakovost izdelka ali donosnost proizvodnje [1, 2].

S spremljanjem proizvodnih procesov lahko podjetja hitro ugotovijo težave in jih odpravijo, kar vodi k večji produktivnosti, nižjim stroškom in višji kakovosti izdelkov. Spremljanje procesov je ključni vidik sodobne proizvodnje, katerega pomen je izjemno pomemben [3].

Večina strojev, ki so na voljo na trgu, je zasnovanih za ponavljajoče se naloge in je opremljena z osnovnimi notranjimi alarmnimi sistemi. Ti alarmni sistemi so običajno vgrajeni v krmilni sistem stroja. Krmilni sistem stroja ustvari alarm, ko notranja spremenljivka preseže zgornjo ali spodnjo mejo.

Te rešitve imajo več pasti. Prvič, te rešitve niso zmožne zaznati šibkih začetnih napak, saj se običajno odzovejo, ko je napaka že v zreli fazi. Drugič, te rešitve ne upoštevajo medsebojne povezave med spremenljivkami procesa, zato ne morejo zanesljivo sklepati o osnovnem vzroku. Tretjič, proizvajalci pogosto omejujejo dostop končnega uporabnika do notranjih spremenljivk nadzornih sistemov, zaradi česar je izvajanje diagnostične funkcionalnosti težko brez sodelovanja ponudnika strojev, ki pa za to zahtevajo doplačilo. Prav tako je treba upoštevati, da še vedno obstaja veliko strojev brez vgrajenih diagnostičnih funkcij, na primer stroji starejše generacije [4].

V našem raziskovalnem delu si prizadevamo razviti nove splošne metode za nadzorovanje proizvodnih procesov v kosovni industriji ter drugih visoko-ponovljivih procesih. Naš cilj je zagotoviti široko uporabo nadzornega sistema, ki ne bo zahteval velikih posegov v obstoječe proizvodne sisteme ter bo omogočal uporabo minimalno invazivne ali že-prisotne merilne opreme. Poleg tega si želimo izkoristiti obstoječe signale na liniji, ne da bi bilo potrebno dodajanje dodatnih senzorjev ali pa uporabljati neinvazivne senzorje, ki ne bodo vplivali na delovanje opazovane naprave.

Naš cilj je razviti splošni nadzorni sistem, ki bo primeren za širok nabor cikličnih naprav v kosovni proizvodnji ter bo omogočal zanesljivo odkrivanje morebitnih napak v proizvodnem procesu. Pri tem želimo izkoristiti obstoječe podatke, ki jih pridobivamo iz proizvodnih procesov, ter jih analizirati na način, ki nam bo omogočal zaznavanje napak v zgodnji fazi ter njihovo odpravo, preden povzročijo večje težave.

Za doseg tega cilja se bomo osredotočili na razvoj in uporabo splošnih metod za nadzorovanje proizvodnih procesov ter na uporabo minimalno invazivne ali že-prisotne merilne opreme. S tem bomo omogočili široko uporabo našega nadzornega sistema na različnih napravah v kosovni industriji ter drugih visoko-ponovljivih procesih, hkrati pa zmanjšali stroške in čas za integracijo in prilagajanje sistema na posamezne proizvodne procese.

Predstavili bomo predlog zasnove minimalno invazivnega nadzornega sistema, ki je sestavljen iz različnih komponent, med drugim tudi metode za klasifikacijo časovnih vrst. V prispevku bomo prikazali uporabo te metode na primeru meritev pnevmatskega tlaka.

Klasifikacija časovnih vrst je pomemben korak v zastavljenem nadzornem sistemu. Klasifikacijo vršimo na segmentih časovne vrste, ki predstavljajo smiselne korake delovanja opazovanega stroja.

Klasifikacija časovnih vrst (TSC) je aktivno področje raziskav [5]. Njen naraščajoči pomen je posledica eksplozije virov podatkov, ki ustvarjajo

časovne vrste: internet stvari (IoT), industrija 4.0, finančni sektor [6], zdravstvene in medicinske naprave [7], vremenske postaje in monitorji kakovosti zraka, GPS loggerji itd. Aplikacije TSC vključujejo odkrivanje napak [8–10], prepoznavanje predmetov, analizo porabe energije [11], analizo prometnih vzorcev [12] in odkrivanje raztresenih voznikov [13]. V proizvodnji obstaja več primerov uporabe klasifikacije časovnih vrst: (1) odkrivanje napak na obdelovancih, (2) spremljanje strojev za preventivno in napovedno vzdrževanje, (3) odkrivanje nepričakovanih/nepripravilnih operacij strojev, (4) kategorizacija obdelovancev.

Metode TSC se delijo v več kategorij. Izbira kategorije metod je odvisna od lastnosti časovnih vrst, ki jih želimo klasificirati. Pregledi kategorij metod klasifikacije časovnih vrst so na voljo v [14]. Za potrebe nadzornega sistema, opisanega v 2, je relevantna kategorija metod, ki opazujejo obliko celotne časovne vrste. Na tem področju se največ pozornosti posveča alternativnim (elastičnim) meram razdalje [14, 15]. V našem delu se osredotočimo na drug del teh metod - na klasifikator. Predlagamo alternativen klasifikator: metodo rojenja z lastnim odzivom.

V prispevku predstavimo predlog zasnove minimalno invazivnega nadzornega sistema. V poglavju 2 predstavimo koncept minimalno invazivnega nadzornega sistema, ki ga nameravamo razviti. V poglavju 3 predstavimo metodo rojenja z lastnim odzivom, ki jo nameravamo uporabiti za klasifikacijo časovnih vrst, pridobljenih iz meritev pnevmatskega tlaka. Rezultati metode so prikazani v poglavju 4. V poglavju 5 predstavimo zaključek in povzetek prispevka.

2 Minimalno invaziven nadzorni sistem

Za zagotavljanje natančnega in učinkovitega nadzora cikličnih naprav v proizvodnji je bil razvit koncept minimalno invazivnega nadzornega sistema. V tem poglavju bomo predstavili osnovne elemente tega sistema ter njegove prednosti pri zagotavljanju visoke kakovosti izdelkov in zmanjševanju stroškov proizvodnje. Shema predlaganega nadzornega sistema prikazuje slika 1. V

fazi učenja (modri tok) se učijo modeli za identifikacijo elementarnih vzorcev, segmentacijo, DES model, model za klasifikacijo. Ena od posebnosti zastavljenega modela je zmožnost razvoja - evolucije končnih modelov tudi po začetni fazi učenja. S tem se zastavljen sistem lahko prilagaja spremembam v opazovanem procesu ter te spremembe uspešno obravnava.

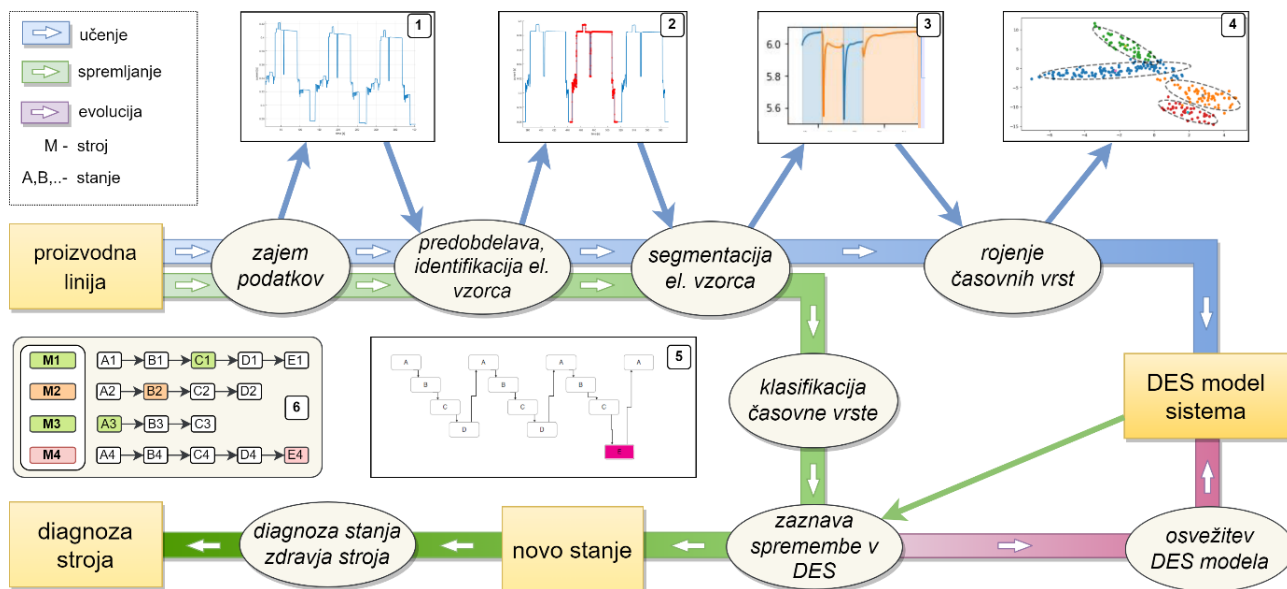
Z namenom čim širše uporabnosti sistema se osredotočamo na uporabo signalov, ki so vseprisotni v industrijskih okoljih, (npr. tlaki na pnevmatskih linijah) in katerih zajem ne vpliva na delovanje opazovanega sistema (npr. podatek o odmiku, lokaciji, hitrosti orodja).

V časovnih vrstah v kosovni industriji se pogosto pojavljajo ponavljajoči vzorci, ki predstavljajo cikle stroja. Ti vzorci niso strogo periodični, saj lahko že med obdelavo enega kosa ali skupine kosov pride do odstopanj zaradi variabilnosti v človeškem posegu, manjših nastavitvev ali ročnega polaganja kosov. Namen metode za identifikacijo elementarnega vzorca je označiti te ponavljajoče vzorce v kontinuiranih meritvah ter za vsako pojavitev določiti začetno in končno točko.

Po detekciji elementarnih vzorcev se ti lahko nadalje razdelijo na posamezne segmente, kjer vsak segment predstavlja neko akcijo opazovanega sistema oziroma stroja. Metodologija razdelitve na segmente (segmentacija) je težavno opravilo, ki nima splošne rešitve, saj je odvisna od narave procesa ter predpostavk o pomenu segmentov.

Po segmentaciji je potreben korak klasifikacije vsakega od zaznanih segmentov. Metoda za klasifikacijo razvršča časovne vrste v enega od možnih razredov. Tako lahko namesto zaporedja segmentov naprej obdelujemo zaporedje razredov. Vsak razred lahko interpretiramo kot stanje ali dogodek (prehod med stanji procesa), odvisno od narave opazovanega sistema.

Po klasifikaciji pridobljenih segmentov imamo na voljo zaporedje dogodkov. To zaporedje dogodkov lahko služi kot osnova za gradnjo DES (angl. *Discrete Event System*) modela v fazi učenja ali za nadzor delovanja opazovanega sistema v fazi spremljanja.



Slika 1: Shema minimalno invazivnega nadzornega sistema


Z analizo zaporedja dogodkov in časov med dogodki lahko nadzorujemo delovanje stroja ter zaznamo in diagnosticiramo odstopanja, ko do njih pride.

3 Metoda rojenja z lastnim odzivom

Metoda rojenja z lastnim odzivom (angl. *Eigenresponse fuzzy clustering*, EFC) [16] je metoda za klasifikacijo časovnih vrst. Spada v kategorijo metod za klasifikacijo, ki za razvrstitev časovne vrste upoštevajo celotno časovno vrsto (ne le podintervale ali statistične lastnosti), ter se osredotočajo na obliko časovne vrste (angl. *Whole-series classification* [14]). Za klasifikacijo v tej kategoriji se najpogosteje uporablja klasifikator najbližjega soseda (angl. *Nearest Neighbour 1NN*) z različnimi elastičnimi merami razdalje npr. metodo časovnega popačenja (DTW - *Dynamic Time Warping* [17]), ali njene izpeljanke [18–20]. Med pomanjkljivosti takega klasifikatorja so:

1. v pomnilniku hrani celotno učno množico,
2. 'naučenega' modela na moremo enostavno predstaviti uporabniku,
3. računski kompleksnost klasifikacije, sploh pri kompleksnih elastičnih merah, narašča z velikostjo učne množice.

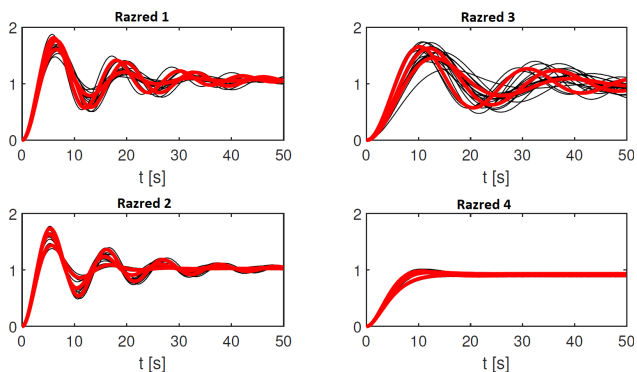
Da bi zaobšli te pomakljivosti predlagamo uporabo metode EFC predstavljene v nadaljevanju.



Slika 2: Faza učenja metode rojenja z lastnim odzivom

Slika 2 prikazuje fazo učenja te metode. V fazi učenja se učna množica $X = \{X_0 \cup X_1 \cup \dots \cup X_i \cup \dots \cup X_n\}$ razdeli na posamezne razrede X_i . Za vsak razred podatkov se z metodo mehkega rojenja (fuzzy c-means clustering - FCM [21, 22]) pridobijo ključni vzorci - prototipi, ki opisujejo razpon vzorcev znotraj razreda. Za vsakega od k razredov pridobimo c prototipov. Primer s $k = 4$ in $c = 4$ je prikazan na sliki 3. Nabor naučenih prototipov ter njihova razvrstitev med razrede predstavlja naučen model metode rojenja z lastnim odzivom. Prototipe razredov imenujemo lastni odzivi (angl. *eigenresponses*).

Potem ko je model naučen, ga lahko uporabimo



Slika 3: Časovne vrste štirih razredov (angl. class), za vsak razred določeni po trije ($c = 3$) prototipi - lastni odzivi.

za klasifikacijo novih časovnih vrst. V [16] je predlaganih več pristopov k klasifikaciji. Pri klasifikaciji uporabimo naučene lastne odzive. Klasifikacija se lahko izvede s pomočjo izračuna razdalje časovne vrste do prototipov, z rekonstrukcijo ali z izračunom mehke pripadnosti novega vzorca rojem, ki jih definirajo prototipi.

Pri klasifikaciji z rekonstrukcijo se lastni odzivi vsakega razreda uporabijo kot bazne funkcije za rekonstrukcijo iskane časovne vrste. Časovno vrsto se razvrsti v tisti razred, čigar lastni odzivi so pri rekonstrukciji dosegli najmanjši pogrešek (npr. MSE).

Za klasifikacijo lahko uporabimo tudi neposredno razdaljo do lastnih odzivov. Ta primer je podoben uporabi 1NN, le da se za vsak razred v učni množici ohranijo le ključne časovne vrste (lastni odzivi razreda).


Pri klasifikaciji z izračunom mehke pripadnosti vzorca rojem, ki jih definirajo lastni odzivi, (naučen EFC model), se uporabi pripadnost μ_{ij} :

$$\mu_{ij} = \left(\sum_{C_l \in C} \left(\frac{d(\mathbf{x}_j - \mathbf{v}_l)}{d(\mathbf{x}_j - \mathbf{v}_1)} \right)^{\frac{1}{\eta-1}} \right)^{-1} \quad (1)$$

C je množica rojev, l je indeks roja, i je indeks roja do katerega izračunavamo pripadnost, j je indeks vzorca, \mathbf{v}_l je prototip l -tega roja, η je parameter.

4 Rezultati in diskusija

Da demonstriramo delovanje metode, jo preizkusimo na podatkih z resničnega sistema. Gre za testno napravo na končni postaji v proizvodnjo motorjev e-koles, ki je opremljena z merilcem pnevmatskega tlaka. Naprava med testiranjem elektro motorjev proži več aktuatorjev, proženje le teh se pozna na tlačnih meritvah. En cikel naprave (test enega motorja) je prikazan na sliki 4.



Slika 4: Normirane tlačne meritve enega cikla naprave. Z izmenjajočo barvo ozadja označeni posamezni koraki delovanja naprave.

Za evalvacijo smo uporabili 280 časovnih vrst z označenimi 13 različnimi koraki, ki jih je izvedla testna naprava. Predstavljen klasifikator je pravilno razvrstil vse časovne vrste, medtem ko je referenčni klasifikator skupine 'whole series TSC' napačno razvrstil 7 časovnih vrst (2.5% napaka).

Poleg izboljšanja klasifikacijske natančnosti pa opisana metoda nudi še nekaj izboljšav:

- bolj kompaktna predstavitev učne množice - zmanjšana poraba spomina
- faza klasifikacije je neodvisna od velikosti izvirne učne množice, računaska kompleksnost ne narašča z večanjem količine učnih podatkov
- izboljšana možnost vizualizacije modela ter razložljivost rezultatov

Metodo smo preizkusili tudi večjem številu javno dostopnih podatkovnih setov. Uporabili smo UCR Archive [23]. Podatkovni seti v arhivu so razdeljeni v kategorije. Pričakovano metoda najboljše rezultate doseže v kategoriji obrisi (*shape outlines*), v kateri se časovne vrste razlikujejo po obliki celotne časovne vrste.

5 Zaključek

Predstavljena je zasnova minimalno invazivnega nadzornega sistema, ki je osredotočen na splošnost ter uporabo obstoječih signalov ali minimalno invazivnih senzorjev, ki ne vplivajo na proces. Zastavljeno zaporedje omogoča razdelitev časovne vrste v segmente, primerne za nadaljno obdelavo. Cilj nadzornega sistema je detekcija napaknih zaporedij akcij ter degradacije v časovnih parametrih prehodov stanj sistema. Predstavljen nadzorni sistem za delovanje potrebuje številne metode strojnega učenja, predvsem metode analize časovnih vrst - segmentacije, klasifikacije ter rojenja, ter metode za analizo diskretnih dogodkov.

Predstavljena je bila metoda za klasifikacijo časovnih vrst - metoda rojenja z lastnim odzivom, ki s pomočjo mehkega rojenja pridobi lastne odzive razredov časovnih vrst. Na podlagi lastnih odzivov lahko v fazi klasifikacije razvrščamo časovne vrste. Primer uporabe metode je razpoznavanje korakov testne naprave na podlagi meritev pnevmatskega tlaka.

Zahvala

Delo je bilo izvedeno v okviru raziskovalnega programa Sistemi in vodenje, P2-0001 in projekta L2-4454.

Literatura

- [1] S. Cavalieri in M. G. Salafia. A model for predictive maintenance based on asset administration shell. *Sensors*, zv. 20, št. 21, str. 6028, 2020.
- [2] H. Lasi, P. Fettke in sod. Industry 4.0. *Business & information systems engineering*, zv. 6, št. 4, str. 239–242, 2014.
- [3] A. V. Bogoviz, A. A. Kurilova in sod. Artificial intelligence as the core of production of the future: Machine learning and intellectual decision supports. V *Advances in Mathematics for Industry 4.0*, str. 235–256. Elsevier, 2021.
- [4] P. Burggräf, J. Wagner in sod. Performance assessment methodology for ai-supported decision-making in production management. *Procedia CIRP*, zv. 93, str. 891–896, 2020.
- [5] Ž. Stržinar, B. Pregelj in I. Škrjanc. Overview of some methods in the field of time series analysis. V *Proceedings of the 29. International Electrotechnical and Computer Science Conference ERK 2020, Portorož, Slovenia*. 2020. Original title: Pregled nekaterih metod na področju analize časovnih vrst.
- [6] T.-c. Fu, F.-l. Chung in sod. Representing financial time series based on data point importance. *Engineering Applications of Artificial Intelligence*, zv. 21, št. 2, str. 277–300, 2008.
- [7] E. J. d. S. Luz, W. R. Schwartz in sod. Ecg-based heart-beat classification for arrhythmia detection: A survey. *Computer methods and programs in biomedicine*, zv. 127, str. 144–164, 2016.
- [8] B. Pregelj, A. Debenjak in sod. Diagnostic system for end-of-line quality control of Pedalec electric bike drives. V *Proceedings of the 11. AIG conference, Maribor, Slovenia*. 2019.
- [9] Ž. Stržinar. *Modelling and fault detection in heating, ventilation, and air conditioning systems*. Magistrsko delo, University of Ljubljana, Faculty of Electrical Engineering, 2017. Original title: Modeliranje in zaznavanje napak v klimatskih sistemih.
- [10] G. Andonovski, S. Blažič in I. Škrjanc. Partial cloud-based evolving method for fault detection of HVAC system. V *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, str. 1–6. IEEE, 2018.
- [11] B. Ellert, S. Makonin in F. Popowich. Appliance water disaggregation via non-intrusive load monitoring (nilm). V *Smart City 360°*, str. 455–467. Springer, 2016.
- [12] V. Guralnik in J. Srivastava. Event detection from time series data. V *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining*, str. 33–42. 1999.
- [13] R. Mercer, S. Ucar in E. Keogh. Shape-based telemetry approach for distracted driving behavior detection. V *2021 IEEE Conference on Standards for Communications and Networking (CSCN)*, str. 118–123. IEEE, 2021.
- [14] A. Bagnall, J. Lines in sod. The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data Mining and Knowledge Discovery*, zv. 31, št. 3, str. 606–660, 2017.
- [15] J. Large, A. Bagnall in sod. On Time Series Classification with Dictionary-Based Classifiers. *Intelligent Data Analysis*, zv. 23, št. 5, str. 1073–1089, 2019.
- [16] Ž. Stržinar, B. Pregelj in I. Škrjanc. Soft sensor for non-invasive detection of process events based on eigenresponse fuzzy clustering. *Applied Soft Computing*, zv. 132, str. 109859, 2023.
- [17] M. Müller. Dynamic time warping. *Information retrieval*

eval for music and motion, str. 69–84, 2007.

- [18] Y.-S. Jeong, M. K. Jeong in O. A. Omitaomu. Weighted dynamic time warping for time series classification. *Pattern recognition*, zv. 44, št. 9, str. 2231–2240, 2011.
- [19] T. Górecki in M. Łuczak. Using derivatives in time series classification. *Data Mining and Knowledge Discovery*, zv. 26, št. 2, str. 310–331, 2013.
- [20] T. Górecki in M. Łuczak. Non-isometric transforms in time series classification using dtw. *Knowledge-Based Systems*, zv. 61, str. 98–108, 2014.
- [21] J. C. Dunn. A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. 1973.
- [22] J. C. Bezdek, R. Ehrlich in W. Full. Fcm: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, zv. 10, št. 2-3, str. 191–203, 1984.
- [23] H. A. Dau, E. Keogh in sod. The ucr time series classification archive, 2018. https://www.cs.ucr.edu/~eamonn/time_series_data_2018/.