

Strojno učenje in umetna inteligenca v pametnih izdelovalnih sistemih

Denis Jankovič, Miha Pipan, Niko Herakovič

Izvleček:

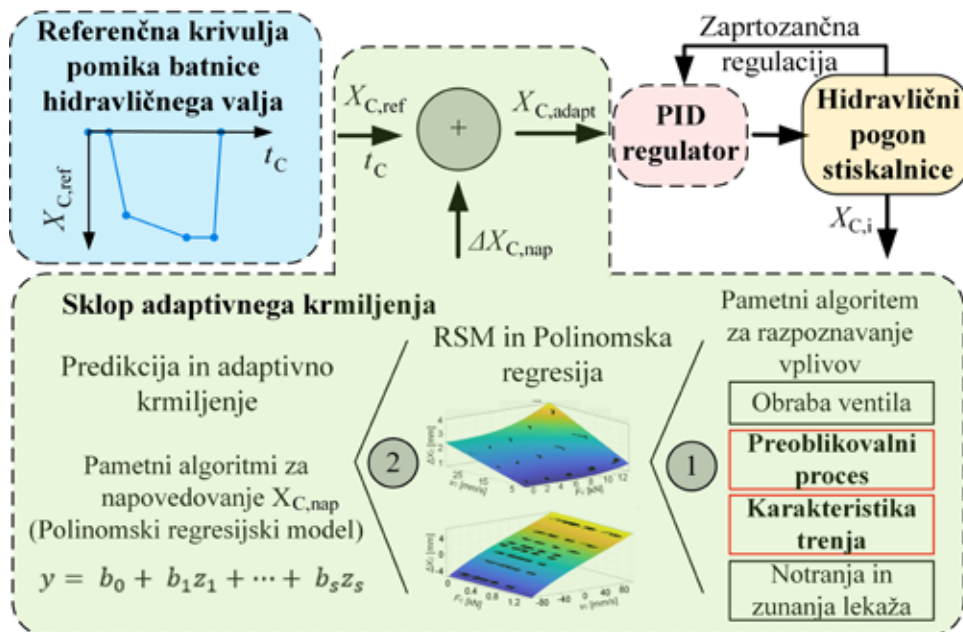
Umetna inteligenca (UI) in strojno učenje vse bolj poganjata razvoj sodobnih izdelovalnih sistemov, pri katerih je zanesljivo delovanje neposredno povezano z natančnim poznavanjem trenutnega stanja strojev. V prispevku je predstavljena praktična uporaba teh pristopov na primeru hidravlične stiskalnice pri upogibanja pločevine. Na osnovi tega primera je bil razvit napredni krmilni sistem, ki združuje zajem procesnih podatkov v realnem času in uporabo regresijskih modelov za spremljanje obratovalnih parametrov stiskalnice v različnih delovnih režimih. Eksperimentalni del je bil zasnovan tako, da obsega širok spekter scenarijev z variabilnimi obremenitvami, hitrostmi hidravličnega valja ter nadzorovano simulacijo trenja v vodilih valja. Z uporabo petih ključnih procesnih parametrov je bila izvedena primerjalna analiza več pristopov strojnega učenja, pri čemer so linearna regresija, metoda podpornih vektorjev in Gaussovo regresijsko modeliranje imeli najvišjo natančnost napovedi ($R^2 > 0,99$). Rezultati so pokazali, da enostavnejši modeli omogočajo hitrejšo učenje in učinkovitejše napovedovanje. Razviti pristop omogoča sprotno zaznavanje odstopanj v delovanju, zmanjšanje napake odziva hidravličnega valja do 95 % ter predstavlja osnovo za uvedbo adaptivnega krmiljenja v realnem času.

Ključne besede:

umetna inteligenca, strojno učenje, hidravlični sistem, ekspertni sistem, digitalni dvojček

1 Uvod

V zadnjem desetletju je mogoče opaziti premik industrije v smeri prehoda na podatkovno podprte, inteligentne in adaptivne sisteme. Medtem ko je koncept industrije 4.0 usmerjen predvsem v digitalizacijo, avtomatizacijo in integracijo naprav v internet stvari, koncept industrije 5.0 uveljavlja bolj tesno sodelovanje med človekom in strojem, visoko stopnjo personalizacije ter trajnostni pristop k proizvodnim procesom. Poglavitna naloga sodobnih izdelovalnih sistemov tako postaja sposobnost nadzornih sistemov po natančnem razumevanju stanja procesov in strojev, kar je ključnega pomena za robustno delovanje, prediktivno vzdrževanje, dolgoročno zanesljivost in nenazadnje čim višjo kvaliteto izdelkov. To lahko dosežemo z integracijo ekspertnih sistemov (slika 1). Hi-



Primer ekspertnega sistema za krmiljenje hidravlične stiskalnice [1]

1

dravlične stiskalnice predstavljajo enega izmed sistemov, ki združujejo nelinearne dinamike, kompleksne interakcije med komponentami ter občutljivost na zunanje motnje, kot so trenje, dinamične obremenitve in variabilnost procesa preoblikovanja. Raziskovalci so v predhodnih raziskavah ugotovili, da tradicionalni regulacijski pristopi, zasnovani na PID-krmiljenju, pogosto ne zmorejo kompenzirati hitrih prehodnih pojavov, materialnih nelinearnosti in sprememb triboloških lastnosti, kar vodi do opazne napake položaja oziroma odziva hidravličnega valja ΔX_c [1].

Dr. Denis Jankovič, mag., doc. dr. Miha Pipan, univ. dipl. inž., prof. dr. Niko Herakovič, univ. dipl. inž., vsi Univerza v Ljubljani, Fakulteta za strojništvo


© The Authors 2026. CC-BY 4.0
<https://doi.org/10.5545/Ventil-32-2026-2.21>

V sklopu naše raziskave smo razvili celovit podatkovno gnan pristop, ki združuje pridobivanje podatkov iz realnega sistema, njihovo časovno in statistično obdelavo ter uporabo regresijskih modelov strojnega učenja za napoved napake odziva valja v različnih delovnih pogojih. Osrednji cilj je bil natančno opisati odnos med petimi ključnimi vhodnimi veličinami (razlika tlakov v komori hidravličnega valja Δp , pritiski sili hidravličnega valja F_c , pomiku krmilnega drsnika hidravličnega venila X_v , hitrosti gibanja batnice hidravličnega valja v_c , odstopanje med referenčno in izmerjeno vrednostjo pomika batnice hidravličnega valja ΔX_c) ter odzivom hidravličnega sistema. Posebej nas je zanimalo, v kolikšni meri so kompleksnejši modeli (kot je Gaussovo regresijsko modeliranje) boljši od enostavnejših modelov, kot so linearna regresija ali metoda podpornih vektorjev, ter kako se razmerje med natančnostjo in časom učenja odraža pri praktični uporabi v realnem sistemu.

2 Eksperimentalno okolje

Hidravlična stiskalnica je kot mehatronski sistem, ki združuje hidravlične, mehanske, senzorske in krmilne elemente, kot je prikazano na *sliki 2*. Preizkuševališče je razdeljeno na štiri glavna vozlišča. Vozlišče A predstavlja krmilno enoto, ki vključuje PID-krmilnik, MOOG-servoojačevalnik G122-829A, krmilnik Beckhoff CX 9020, pripadajoče Beckhoff module ter napajalnik. Vozlišče B predstavlja proporcionalni hidravlični ventil MOOG D663, ki je neposredno krmiljen z linearnim pogonskim motorjem s permanentnim magnetom in omogoča pretok olja 5 l/min pri tlačnem padcu 70 bar. Vozlišče C obsega hidravlični valj Hanchen s premerom bata 30 mm in premerom ohišja 45 mm, opremljen z integriranim vodilnim sistemom Servoseal ter z nazivnim delovnim tlakom 200 bar. Vozlišče D predstavlja mehanski sistem, ki vključuje upogibno orodje in konstrukciji okvir hidravlične stiskalnice.

Sistem je opremljen z merilniki tlaka v obeh valjnih komorah, merilnikom sile, LVDT-senzorjem ventilske odprtosti ter merilnikom pomika valja. Vsi merilni podatki se zajemajo s frekven-



2 Hidravlična stiskalnica s štirimi vozlišči [2]

co 100 Hz preko Beckhoff krmilnika, kar omogoča visoko časovno ločljivost izmerjenih vrednosti.

Proces oblikovanja pločevine poteka v štirih fazah, ki imajo različen vpliv na dinamiko hidravličnega pogona. Najprej valj med hitrim približevalnim gibom doseže delovno območje z visoko hitrostjo. V fazi upogibanja pride do prehoda preoblikovanega preizkušanca iz elastičnega v plastično območje deformacije, kar povzroči hiter porast sile ter izrazito spremembo tlakov v zgornji in spodnji komori hidravličnega valja. Faza zadrževanja predstavlja stabilno, kvazistacionarno stanje, medtem ko zadnja faza (hitri povratni gib) ponovno obremeni ventil in povzroča hitre prehodne pojave. V raziskavi smo sistematično spreminjali intenziteto sile preoblikovanja, hitrost valja ter pogoje trenja preoblikovalnega procesa. Stopnjo obremenjenosti stiskalnice smo prilagajali z intenziteto preoblikovanja, in sicer smo s širino preizkušancev (10–40 mm) generirali preoblikovalne sile med 3,2 kN in 13 kN. Hitrost valja smo spreminjali med 5 in 90 mm/s. Stribeckovo trenje smo simulirali s sistemom škripčevja z dodatnim uporom, generiranim prek škripčnega mehanizma, ki omogoča natančno posnemanje trenja med vodili valja in konstrukcijo stiskalnice, skladno z ugotovitvami iz preteklih raziskav, objavljenih v prispisku [2].


3 Priprava in analiza podatkov

Za pripravo in kasnejšo obdelavo podatkov smo uporabili holistični merilni sistem HSFS (angl. *Holistic Sensing Framework System*), ki omogoča združevanje meritev različnih senzorjev in veličin v uniformno podatkovno strukturo [1]. Podatki vključujejo hidravlični pomik, hitrost, tlak, odprtost ventila in silo, potrebno za preoblikovanje, kar omogoča poglobljeno analizo vzrokov in posledic, kot je predstavljeno na *sliki 3*. Po zajemu podatkov smo izvedli okensko razdelitev časovnih nizov, kjer smo izločili nestabilne prehodne intervale, zlasti ob kontaktnem udarcu med orodjem in pločevino. S tem smo zagotovili, da regresijski modeli učijo predvsem stabilna območja, v katerih imajo za nas podatki največ informacij o realnem stanju komponente.

Normalizacija podatkov med vrednostjo 0 in 1 je bila ključna za izenačitev vpliva posameznih veličin, saj imajo sile, tlaki in pomiki različne velikostne faktorje in vplive, kar bi povzročilo neuravnoteženo učenje modelov. Celoten nabor baze podatkov obsega približno 300.000 podatkovnih točk, razdeljenih med eksperimentalne in simulacijske sete podatkov. Simulacijski podatkovni seti so namenjeni za validacijo podobnosti med matematičnim modelom in realnim sistemom, kar je skladno s pristopom simulacijsko podprtega učenja, predstavljenega v članku Jankovič et al. (2024) [1].

4 Regresijski modeli in metodologija strojnega učenja

Za napoved napake odziva valja ΔX_c smo uporabili pet tipov regresijskih modelov: linearna regresija, metoda podpornih vektorjev, Gaussovo regresijsko modeliranje, odločitvena drevesa in nevronske mreže. Vsak od modelov uporablja iste vhodne spremenljivke, razporejene v petnajst različnih kombi-



4 Področja opazovanja za verifikacijo ekspertnega sistema

Na *sliki 4* sta predstavljena preoblikovalna cikla 1 in 2, kjer so upoštevani različni pogoji (hitrosti gibanja hidravličnega valja, povečanje napake pomika hidravličnega valja ΔX_c in intenzitete preoblikovalnega procesa). Iz obeh ciklov je razvidno večje odstopanje med odzivom hidravličnega pogona z vključenim PID-krmiljenjem od referenčne (pričakovane) vrednosti v primerjavi z izboljšanim odzivom, kjer je odstopanje napake odziva hidravličnega valja ΔX_c znatno manjše. Predstavljeni rezultati izboljšane odziva prikazujejo učinkovitost uporabe ekspertnega sistema, v katerem je integriran model napovedovanja na konceptu linearne regresije sposoben adaptivno izboljšati napako odziva


Rezultati potrjujejo, da lahko uporaba umetne inteligence pomembno izboljša robustnost, odzivnost in natančnost hidravličnih stiskalnic. Na *sliki 5* je prikazan odziv hidravličnega pogona pri adaptivnem krmiljenju, ki temelji na regresijskem modelu po metodi linearne regresije, vključenem v ekspertni sistem. Model v realnem času napoveduje napako odziva hi-

dravličnega valja ΔX_c in na tej osnovi v zaprtostančni optimizaciji prilagaja krmilni signal hidravličnega ventila.

V fazi upogibanja se maksimalna napaka pomika hidravličnega valja ΔX_c zmanjša s 3,3 mm na manj kot 0,2 mm, kar predstavlja zmanjšanje napake v povprečju za 94 %. Podobno zmanjšanje napake je doseženo tudi v fazi zadrževanja in fazi hitrih gibov. *Slika 5* tako predstavlja eksperimentalno potrditev učinkovitosti linearne regresijskega modela v adaptivni krmilni zanki v realnem času trajanja eksperimenta.

6 Razprava

Podatkovno gnani pristopi in UI omogočajo natančnejše zaznavanje subtilnih sprememb trenja, variabilnosti sile preoblikovanja ter ventilnih karakteristik, kar je pri uporabi klasičnega PID-krmiljenja težko izvedljivo, saj tradicionalni regulatorji temeljijo na linearnem odzivu in ne zaznajo zgodnjih odsto-



5 Rezultati adaptivnega krmiljenja v realnem času

panj v nelinearnem obnašanju sistema. Uporaba naprednih regresijskih modelov omogoča, da so ti vplivi prepoznani in uspešno korigirani že v začetnih fazah, ko so odstopanja še majhna in običajno neopazna.

Posebej pomembna je tudi ugotovitev, da uporaba metod umetne inteligence in strojnega učenja omogoča bistveno zmanjšanje napake odziva hidravličnega valja v realnem času. Pri integraciji izbranih modelov v simulacijsko-krmilno zanko smo napako odziva hidravličnega pogona stiskalnice ΔX_c zmanjšali za do 95 %, kar potrjujejo rezultati v fazi upogibanja, fazi zadrževanja in fazi hitrih gibov [1].

Razvoj digitalnega dvojčka, ki temelji na Gaussovem regresijskem modeliranju ali metodi podpornih vektorjev, dodatno razširi možnosti spremljanja, saj omogoča sprotno primerjavo referenčnih in dejanskih gibov valja ter identifikacijo odstopanj, ki so lahko zgodnji znak degradacije komponent ali bližajoče se napake. Digitalni dvojček lahko z visoko stopnjo zanesljivosti nakaže verjetnost prihodnjih odstopanj, kar omogoča boljše odločanje pri prediktivnem vzdrževanju in zmanjša potrebo po reakcijskem popravljanju. S tem UI ne izboljšuje le trenutne regulacije, temveč vzpostavlja temelj za dolgoročno stabilnost in izboljšavo delovanja hidravličnih stiskalnic.

7 Zaključek

Z raziskavo smo potrdili, da sta umetna inteligenca in strojno učenje osrednja tehnološka temelja pametnih izdelovalnih sistemov. V kontekstu hidravličnih stiskalnic, kjer delujejo nelinearne dinamike, hitro spreminjajoče se obremenitve in izraziti tribološki vplivi, UI omogoča bistveno boljše razumevanje stanja sistema kot tradicionalne regulacijske metode. S pomočjo podatkovno gnanih regresijskih modelov je mogoče natančno napovedati odziv valja, zaznavati odstopanja in izboljšati pri-

lagodljivost procesa. Dosežene izboljšave, ki presegajo 90 % zmanjšanja napake odziva v primerjavi s klasičnimi krmilnimi pristopi, potrjujejo, da UI ne deluje zgolj kot dopolnilo, temveč se uporablja za zagotavljanje natančnega napovedovanja in stabilnosti hidravličnih procesov.

Integracija strojnega učenja z digitalnimi dvojčki, naprednimi senzorji in sodobnimi komunikacijskimi tehnologijami odpira pot avtonomnim sistemom, ki so se sposobni učiti iz podatkov, predvidevati motnje ter izboljševati svoje delovanje v realnem času. Takšni sistemi predstavljajo jedro koncepta industrije 4.0 in 5.0, kjer postajajo inteligentno odločanje, robustnost in trajnost ključni elementi konkurenčnosti.

Tako lahko zaključimo, da UI pospešuje razvoj pametnih izdelovalnih sistemov in tudi preoblikuje način, kako ti sistemi delujejo, se nadzirajo in odzivajo na spremembe. S tem postavlja temelje za nove generacije proizvodnje, kjer avtonomija, natančnost in podatkovna podprtost postanejo standard sodobnega industrijskega okolja.

Viri in literatura

- [1] Jankovič, D., Šimic, M., Herakovič, N. (2024). A data-driven simulation and Gaussian process regression model for hydraulic press condition diagnosis. *Advanced Engineering Informatics*.
- [2] Jankovič, D., Šimic, M., Herakovič, N. (2023). Cause-and-effect analysis and simulation-based learning in hydraulic systems. *Elsevier dataset excerpts*.
- [3] Jankovič, D., Šimic, M., Herakovič, N. (2024). A comparative study of machine learning regression models for production systems condition monitoring. *Advances in Production Engineering & Management* 19(1), 78–92.

Machine Learning and Artificial Intelligence in Smart Manufacturing Systems

Abstract:

Artificial intelligence and machine learning are increasingly shaping the development of modern smart manufacturing systems, where reliable and efficient operation is strongly dependent on accurate awareness of machine states and process conditions. In this paper, the practical applicability of data-driven methods is demonstrated through a representative case study of a hydraulic press used in sheet metal bending operations. Based on this system, a comprehensive monitoring and analysis framework was developed, combining systematic process data acquisition with regression-based machine learning models to enable advanced insight into press behavior under diverse operating regimes.

The experimental investigation covers a wide range of scenarios, including varying forming forces, hydraulic cylinder velocities, and controlled simulation of friction effects in the cylinder guide system. Five key process parameters were identified as dominant inputs and used for a comparative evaluation of several regression approaches. The results show that linear regression, Support Vector Machines, and Gaussian Process Regression achieve superior predictive performance, with coefficients of determination exceeding $R^2 = 0,99$ across all evaluated operating phases. At the same time, the analysis confirms that simpler models offer significant advantages in terms of training time and computational efficiency, which is particularly important for real-time industrial applications.

The proposed approach enables continuous detection of operational deviations, achieves up to a 95% reduction in hydraulic cylinder response error, and establishes a solid foundation for real-time adaptive control strategies. By integrating machine learning models into the control and monitoring architecture, the presented methodology contributes to increased robustness, responsiveness, and transparency of hydraulic forming systems. As such, it supports the development of intelligent, data-driven manufacturing solutions aligned with the principles and objectives of Industry 4.0 and Industry 5.0.

Keywords:

Artificial intelligence, Machine learning, Hydraulic systems, Expert systems, Digital twin