

Umetna inteligenca in strojno učenje kot gonilo pametnih izdelovalnih sistemov

Denis Jankovič, Miha Pipan, Niko Herakovič
Univerza v Ljubljani, Fakulteta za strojništvo


POVZETEK

Umetna inteligenca in strojno učenje postajata osrednja gonila razvoja pametnih izdelovalnih sistemov, kjer je natančno razumevanje stanja strojev ključno za zanesljivo in učinkovito delovanje. Za ponazoritev praktične uporabnosti teh pristopov smo izbrali reprezentativen primer hidravlične stiskalnice v postopku upogibanja pločevine. Na tej osnovi smo razvili celovito orodje, ki z uporabo podatkovnega zajema in regresijskih modelov omogoča napredno spremljanje delovanja stiskalnice v različnih delovnih pogojih. Vzpostavili smo obsežen nabor eksperimentalnih scenarijev, ki zajemajo različne intenzitete obremenitev, hitrosti hidravličnega valja ter simulirane pogoje trenja v vodilih hidravličnega valja. Na osnovi petih ključnih vhodnih parametrov (Δp , F_C , X_V , v_C , ΔX_C) smo postavili in primerjali več modelov strojnega učenja ter ugotovili, da linearna regresija, SVM in Gaussian Process Regression dosegajo najvišjo predikcijsko natančnost (R^2 nad 0,99). Hkrati smo potrdili, da enostavnejši modeli omogočajo bistveno krajši čas učenja in hitrejšo napovedovanje. Razvito orodje nam omogoča sprotno zaznavanje odstopanj, do 95-odstotno zmanjšanje napake odziva valja ter vzpostavitev temeljev za adaptivno krmiljenje v realnem času. S tem prispevamo k razvoju inteligentnih, odzivnih in podatkovno podprtih izdelovalnih sistemov, skladnih s cilji Industrije 4.0 in 5.0.

1. UVOD

V zadnjem desetletju je mogoče opaziti premik industrije v smeri celostnega prehoda na podatkovno podprte, inteligentne in adaptivne sisteme. Medtem ko je paradigma Industrije 4.0 usmerjena predvsem v digitalizacijo, avtomatizacijo in integracijo IoT naprav, paradigmo Industrije 5.0 zaznamuje čedalje bolj tesno sodelovanje med človekom in strojem, visoka stopnja personalizacije ter trajnostni pristop k proizvodnim procesom. Poglavitna naloga sodobnih izdelovalnih sistemov postaja

spособnost natančnega razumevanja lastnega stanja, kar je ključnega pomena za kakovost izdelkov, robustno delovanje, prediktivno vzdrževanje in dolgoročno zanesljivost. To lahko dosežemo z integracijo ekspertnih sistemov (Slika 1). Hidravlične stiskalnice predstavljajo enega izmed tistih sistemov, ki združujejo nelinearne dinamike, kompleksne interakcije med komponentami ter občutljivost na zunanje motnje, kot so trenje, dinamične obremenitve in variabilnost procesa preoblikovanja. Predhodne raziskave opozarjajo, da tradicionalni regulacijski



Slika 1: Primer ekspertnega sistema za krmiljenje hidravlične stiskalnice [1].

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].

V tej raziskavi smo razvili celovit podatkovno-gnan pristop, ki združuje pridobivanje multivariatnih 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 natančno opisati odnos med petimi ključnimi vhodnimi veličinami (Δp , F_C , X_V , v_C , ΔX_C) ter odzivom hidravličnega sistema. Posebej nas zanima, v kolikšni meri so kompleksnejši modeli, kot je Gaussian Process Regression (GPR), boljši od enostavnejših pristopov, kot so linearna regresija ali SVM, ter kako se razmerje med natančnostjo in časom učenja odraža pri praktični uporabi v realnem času.

2. OPIS SISTEMA IN EKSPERIMENTALNEGA OKOLJA


Hidravlična stiskalnica, uporabljena v raziskavi, je bila zasnovana kot mehatronski sistem, ki združuje hidravlične, mehanske, senzorske in krmilne elemente. Sistem sestavljajo proporcionalni ventil MOOG D663, hidravlični valj z integriranim Servoseal vodilnim sistemom, merilniki tlaka v obeh valjnih komorah, merilnik sile, LVDT senzor ventilne odprtosti ter merilnik pomika valja. Vsi podatki so bili zajeti s frekvenco 100 Hz preko Beckhoff krmilnika, kar omogoča visoko ločljivost časovnih signalov.

Proces oblikovanja pločevine poteka skozi štiri faze, ki imajo različen vpliv na dinamiko hidravličnega pogona. Med hitrim približevalnim gibom valj doseže delovno območje z veliko hitrostjo. V fazi upogibanja pride do prehoda iz elastičnega v plastično območje deformacije, kar povzroči hiter porast sile ter izrazito spremembo tlakov v komorah A in B. Faza zadrževanja predstavlja bolj stabilno, kvazi-stationarno stanje, medtem ko hitri povratni gib ponovno obremeni ventil in povzroča hitre prehodne pojave. V

raziskavi smo sistematično spreminjali intenziteto sile preoblikovanja, hitrost valja ter pogoje trenja. Stopnjo obremenjenosti stiskalnice smo prilagajali z intenziteto preoblikovanja in sicer smo s širino preizkušancev (10–40 mm) tvorili preoblikovalne sile med 3,2 kN in 13 kN. Hitrost valja smo spreminjali med 5 in 90 mm/s. Stribeckovo trenje smo ponazorili z dodatnim uporom, generiranim prek sistema škripcev, ki omogoča natančno simulacijo trenja med vodili valja oziroma konstrukcijo stiskalnice, skladno z ugotovitvami v literaturi [2].

Na sliki 2 je prikazano preizkuševališče z naslednjimi vozlišči:

- **Vozlišče A:** Krmilna enota (PID-krmilnik, MOOG servo ojačevalnik G122-829A, krmilnik Beckhoff CX 9020, Beckhoff moduli, napajalnik ipd.).
- **Vozlišče B:** Hidravlični ventil MOOG D663 (pretok olja 5 l/min pri tlačnem padcu 70 bar, neposredno krmiljen z linearnim pogonskim motorjem s permanentnim magnetom).
- **Vozlišče C:** Hidravlični valj Hanchen (premer bate 30 mm, premer ohišja 45 mm, vodilni sistem Servoseal, nazivni delovni tlak 200 bar).
- **Vozlišče D:** Mehanski sistem (upogibno orodje ter konstrukcijski okvir hidravlične stiskalnice).



Slika 2: Hidravlična stiskalnica s štirimi vozlišči [2].

3. PODATKOVNA ANALITIKA IN PRIPRAVA PODATKOV

Za obdelavo podatkov smo uporabili holistični merilni sistem HSFS (Holistic Sensing Framework System), ki omogoča združevanje meritev različne narave v konsistentno podatkovno strukturo [1]. Podatki vključujejo hidravlični pomik, hitrost, tlak, odprtost ventila in silo potrebno za preoblikovanje, kar omogoča poglobljeno analizo vzrokov in posledic. 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 signali nosijo največ informacij o realnem stanju komponente.


Normalizacija podatkov med 0 in 1 je bila ključna za izenačitev vpliva posameznih veličin, saj imajo sile, tlaki in pomiki različno utež pomembnosti, kar bi sicer povzročilo neuravnoteženo učenje modelov. Celoten nabor podatkov obsega približno 300.000 vzorcev, razdeljenih med eksperimentalne in simulacijske signale. Simulacijski podatki so služili validaciji ujemanja med matematičnim modelom in realnim sistemom,

kar je skladno s pristopom simulacijsko-podprtega učenja, predstavljenega v članku Jankovič et al. (2024) [1] in prikazana na Sliki 3.

4. REGRESIJSKI MODELI IN METODOLOGIJA STROJNEGA UČENJA

Za napoved napake odziva valja ΔX_C smo razvili pet tipov regresijskih modelov: linearno regresijo, Support Vector Machine (SVM), Gaussian Process Regression (GPR), odločitvena drevesa in nevronske mreže. Vsak od modelov uporablja enake vhodne spremenljivke, razporejene v petnajst različnih kombinacij, kar omogoča analizo vpliva posameznih veličin na natančnost napovedi [3].

Modeli so bili učeni s pomočjo kombinacije mrežnega in naključnega iskanja hiperparametrov ter validirani s petkratno križno validacijo. Linearna regresija se je pokazala kot presenetljivo robustna, kar potrjujejo tudi ugotovitve drugih avtorjev, ki navajajo, da so enostavni modeli pogosto konkurenčni kompleksnejšim, če vsebujejo ustrezno izbrane vhodne veličine [3]. Pri modelih SVM je bila uspešnost odvisna predvsem



Slika 3: Priprava podatkov in njihova analiza [1].

od izbire jedra, zato smo uporabili radialno bazno funkcijo (RBF), ki omogoča nelinearno preslikavo vhodnega prostora.

Gaussova regresijska metoda se je izkazala za najučinkovitejšo, kar je skladno z literaturo, ki poudarja sposobnost GPR, da z visoko verjetnostjo opisuje negotovost napovedi in s tem zagotavlja interpretabilnost modela [1]. Njegove prednosti izhajajo iz fleksibilnosti jedrne funkcije ter zmogljivosti obvladovanja kompleksnih triboloških in dinamičnih pojavov v hidravličnem sistemu.

5. REZULTATI

Testiranje je bilo izvedeno na področju izvajanja preoblikovanja s hidravlično stiskalnico (Slika 4). Rezultati jasno kažejo, da so predstavljene metode linearna regresija, SVM in GPR dosegli koeficient determinacije R^2 nad 0,99. Gaussian Process Regression se je izkazal kot najboljši, saj je v vseh treh fazah postopka (upogibanje, zadrževanje, hitri gibi) dosegal R^2 med 0,998 in 0,999, kar je v celoti skladno z rezultati iz članka Jankovič, Šimic in Herakovič (2024) [3]. SVM je dosegal podobno visoke vrednosti, vendar je bil bolj občutljiv na hiperparametre. Linearna regresija se je izkazala za presenetljivo stabilno, saj je dosegala R^2 blizu 0,996, hkrati pa je bila časovno med najhitrejšimi.

Nevronske mreže in odločitvena drevesa so bili občutno počasnejši. Časi učenja so bili do 437-krat daljši v primerjavi z linearnimi modeli, kar bistveno omejuje njihovo uporabnost pri


realnočasovnih aplikacijah, kjer je prioriteta hitro odzivanje, kot je adaptivno krmiljenje [3].

Posebej pomembna ugotovitev je, da uporaba UI omogoča realno časovno zmanjšanje napake odziva hidravličnega valja. Pri integraciji v simulacijsko-krmilno zanko je bilo mogoče napako zmanjšati za do 95 %, kar dokazujejo rezultati faze upogibanja, faze zadrževanja in hitrega giba v eksperimentih [1].


6. RAZPRAVA

Rezultati potrjujejo, da lahko umetna inteligenca pomembno izboljša robustnost, odzivnost in natančnost hidravličnih stiskalnic (Slika 5). Podatkovno gnani pristopi omogočajo bistveno natančnejše zaznavanje subtilnih sprememb trenja, variabilnosti sile preoblikovanja ter ventilnih karakteristik, kar je na ravni klasičnega PID-krmiljenja težko izvedljivo, saj tradicionalni regulatorji temeljijo na linearnem odzivu in ne zaznajo zgodnjih odstopanj v nelinearnem obnašanju sistema. Uporaba naprednih regresijskih modelov omogoča, da so ti vplivi prepoznani že v začetnih fazah, ko so odstopanja še majhna in običajno neopazna.

Razvoj digitalnega dvojčka, ki temelji na GPR ali SVM modelu, dodatno razširi možnosti spremljanja, saj omogoča sprotno primerjavo



Slika 4: Področja opazovanja za verifikacijo ekspertnega.



Slika 5: Rezultati adaptivnega krmiljenja v realnem času.

referenčnih in dejanskih gibanj valja ter identifikacijo odstopanj, ki so lahko zgodnji znak degradacije komponent ali bližajoče se napake. Digitalni dvojček lahko z visoko stopnjo zanesljivosti oceni tudi verjetnost prihodnjih odstopanj, kar omogoča boljše odločanje pri prediktivnem vzdrževanju in zmanjša potrebo po reakcijskem, zamikajočem se popravljanju. S tem UI ne izboljšuje le trenutne regulacije, temveč vzpostavlja temelj za dolgoročno stabilnost in izboljšavo delovanja hidravličnih stiskalnic.

7. ZAKLJUČEK

Raziskava potrjuje, da umetna inteligenca in strojno učenje postajata 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 prilagodljivost procesa. Dosežene izboljšave, ki presegajo 90 % zmanjšanja napake odziva, potrjujejo, da UI ne deluje zgolj kot dopolnilo, temveč predstavlja ključno komponento pri dvigu natančnosti in stabilnosti hidravličnih procesov.

Integracija strojnega učenja z digitalnimi dvojčki, naprednimi senzorji in sodobnimi

komunikacijskimi tehnologijami odpira pot avtonomnim in samozaznavnim sistemom, ki so se sposobni učiti iz podatkov, predvidevati motnje ter izboljševati svoje delovanje v realnem času. Takšni sistemi predstavljajo jedro paradigme Industrije 4.0 in 5.0, kjer postajajo inteligentno odločanje, robustnost in trajnost ključni elementi konkurenčnosti.

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

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.