

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat 5.4:

Razvoj AI modulov za proizvodna okolja

Projekt/RRP	DIGITOP/ RRP5, Aktivnost 5.4
Vrsta dokumenta	Poročilo
Verzija dokumenta	1.0
Sodelujoči partnerji	Javni raziskovalni zavod Rudolfovo, Odsek za inteligentne sistem – E9, Odsek za sisteme in vodenje – E2 Institut Jožef Stefan
Avtorji	Primož Kocuvan, Vinko Longar, Rok Struna
Datum priprave	1.8.2025

Kazalo

1	UVOD	3
1.1	PREDIKTIVNO VZDRŽEVANJE STROJEV	3
1.2	NAPOVED DIMENZIJSKIH ODSTOPANJ IZDELKOV:	3
1.3	IZBOLJŠAVA ALGORITMA ZA OPTIMIZACIJO PORABE ELEKTRIČNE ENERGIJE:	3
2	PREDIKTIVNO VZDRŽEVANJE STROJEV V PROIZVODNJI LABTOP	4
3	NAPOVED DIMENZIJSKIH ODSTOPANJ - NAPAK NA IZDELKIH	6
4	IZBOLJŠAVA ALGORITMA ZA OPTIMIZACIJO PORABE ELEKTRIČNE ENERGIJE	8
5	BIBLIOGRAFIJA	9

1 UVOD

Razvoj umetne inteligence predstavlja del digitalne preobrazbe sodobnih proizvodnih okolij. Integracija modulov UI v proizvodne procese omogoča analizo podatkov, ki izhajajo iz senzorjev, strojev in informacijskih sistemov (MES in ERP), ter s tem podpira odločanje na podlagi podatkov.

V okviru aktivnosti 5.4 smo se osredotočili na razvoj in implementacijo treh AI modulov, namenjenih napovednemu vzdrževanju, nadzoru kakovosti ter optimizaciji porabe energije v proizvodnem sistemu LabTOP. Uporabljeni pristopi temeljijo na uporabi strojnega učenja in podatkovne analitike, pri čemer so bili uporabljeni podatki, zbrani s senzorji in informacijskimi sistemi v laboratoriju LabTOP.

1.1 PREDIKTIVNO VZDRŽEVANJE STROJEV

Na CNC-stroj in kompresor so člani Rudolfovega namestili dva iCOMOX senzorja, ki je 30 dni zajemal podatke o vibracijah, magnetnem polju, temperaturi in zvoku. Ker med tem obdobjem ni bilo zabeleženih okvar, so bili podatki obravnavani kot neoznačeni. Član E9 je z uporabo PCA metode zmanjšal dimenzionalnost podatkov in s pomočjo gručenja identificiral tri skupine (gruče) obratovalnih stanj, med katerimi sta pri obeh senzorjih izstopali po ena – potencialni indikatorji napak. Zaradi pomanjkanja informacij o dejanskih napakah trenutno ni možno izvajati nadzorovanega učenja, ki je predvideno v nadaljnjih fazah projekta.

1.2 NAPOVED DIMENZIJSKIH ODSTOPANJ IZDELKOV:

Analizirali smo vpliv proizvodnih parametrov (pomik, globina reza, vrtilna hitrost) na dimenzijske napake pri izdelavi lesenih podstavkov za slušalke. Zbrali smo 17 primerov, ki smo jih skenirali in nato s pomočjo knjižnice SMOGN sintetično razširili na 500 primerov. Najuspešnejši model za napoved odstopanj je bil MLP regresor. Modeli, ki temeljijo na drevesih, so bili izločeni zaradi pristranskosti SMOGN generacije. Kljub omejitvam je bil primer dovolj zanimiv za znanstveno objavo v reviji *Informatica* [1].

1.3 IZBOLJŠAVA ALGORITMA ZA OPTIMIZACIJO PORABE ELEKTRIČNE ENERGIJE:


V okviru izboljšave algoritma za optimizacijo porabe električne energije razvijamo dva medsebojno povezana napovedna modela. Prvi model napoveduje porabo energije v proizvodnji glede na tip izdelka, medtem ko drugi model napoveduje proizvodnjo električne energije iz sončne elektrarne. Z integracijo obeh napovedi želimo razviti sistem, ki bo omogočal optimalno odločanje o viru napajanja – kdaj uporabiti energijo iz sončnih celic in baterijskega sistema ter kdaj iz omrežja. Cilj aktivnosti je ustvariti sistem, ki bo zmanjšal stroške električne energije in povečal delež samooskrbe v laboratoriju LabTOP.

2 PREDIKTIVNO VZDRŽEVANJE STROJEV V PROIZVODNJI LABTOP


Rudolfovo je v okviru preventivnega vzdrževanja opremil kompresor in vreteno CNC-stroja z dvema iCOMOX senzorjema. Vsak iCOMOX modul integrira pet merilnih elementov, namenjenih zbiranju podatkov za kasnejšo obdelavo z metodami strojnega učenja. Merilni sklop zajema:

- **Vibracije:** tridimenzionalni MEMS pospeškomer Analog Devices ADXL356, občutljivost ± 20 g, pasovna širina do 2 kHz
- **Magnetno polje:** tridimenzionalni magnetometer Bosch BMM150, občutljivost $0,3 \mu\text{T}$
- **Temperaturo:** digitalni senzor Analog Devices ADT7410, natančnost $\pm 0,5^\circ\text{C}$
- **Zvok:** MEMS mikrofoni Infineon IM69D130, frekvenčni razpon 20 Hz–20 kHz

Merilni interval je znašal 5 minut, obdobje kontinuiranega zajema pa je trajalo 30 dni. Zaradi odsotnosti diagnostičnih oznak (ni bilo zabeleženih poškodb pogonskega sklopa, nenavadnih temperaturnih nihanj ali ležajnih okvar) so bili zbrani podatki obravnavani kot neoznačeni. Analizo je izvedel E9 z uporabo metod nenadzorovanega učenja (gručenje in PCA analiza), pri čemer je bil cilj odkriti vzorce in morebitna odstopanja v delovanju strojev. Podatki so bili sestavljeni iz 11 dimenzij, kjer vsaka dimenzija predstavlja en podatek, je E9 reduciral na 2 dimenziji z uporabo PCA (Principle component analysis) metode [2]. Ostale metode reduciranja dimenzij se niso izkazale kot uspešne, zato je E9 nadaljeval s PCA [1–3]. Kolenčna in silhueta metoda sta podali optimalno število gručk po katerih je E9 razdelil točke v 2D razpršenem grafu [3]. Slika 1. in Slika 2. prikazujeta razpršeni graf posameznega iCOMOX senzorja, kjer so točke razdeljene v 3 optimalne gruče [4]. Pri iCOMOX1 je gruča ki izstopa 1. označena z oranžno barvo. Pri iCOMOX2 je gruča ki izstopa označena z zeleno barvo (2.). Interpretacija razpršenih dobljenih grafov je, da gruče kjer so posamezne točke blizu skupaj predstavlja normalno obratovanje labTOP medtem ko izstopajoča gruča napake v merjenju ali napake na strojih. Zaradi odsotnosti podatka o zabeleženih napakah na vretenu ali kompresorju sedaj ni možno opraviti nadzorovanega učenja in bo opravljeno v prihodnosti v sklopu aktivnosti 9.4.



Slika 1: Razpršeni graf s tremi gručkami za iCOMOX1



Slika 2: Razpršeni graf s tremi gruči za iCOMOX2

Tabela 1 prikazuje tri gruče, ki predstavljajo značilna obratovalna stanja strojev v sistemu LabTOP. Gruči 0 in 2 imata nizke RMS vrednosti pospeškov in zvoka ter predstavljata normalno delovanje strojev, medtem ko gruča 1 izstopa z izrazito povišanimi RMS vrednostmi zvoka in pospeškov, kar lahko nakazuje na potencialne anomalije ali nestabilne obratovalne pogoje.

Tabela 1: Semantična – pomenska analiza gruč zbrana v skupni tabeli

Gruča	Število	Povprečni RMS	Ključne značilnosti
0	1.387	813,4	• Zelo nizka RMS vrednost pospeškomera ($\approx 0,02-0,05$) na ADXL356 v smereh X/Y • Visoke vrednosti magnetometra X/Z (BMM150) okoli 2.578/4.320 • Zmerna vrednost MEMS zvočnega senzorja IM69 ($\sim 257,0$)
1	30	11.054,7	• Izjemno visoka RMS vrednost MEMS zvoka IM69 (~ 124.527) • Povišan RMS pospeškomera ADXL356 v smereh X/Y ($\approx 0,66-1,12$) • Visoke vrednosti magnetometra Y/Z (BMM150) okoli 2.204/4.546
2	1.793	738,0	• Podobno kot gruča 0, a nekoliko višji RMS temperature na ADT7410 (33,0 proti 32,0) • Zmerno visoke vrednosti BMM150 Y/Z (1.863/4.258) in IM69 (~ 688)


3 NAPOVED DIMENZIJSKIH Odstopanj - NAPAK NA IZDELKIH

Rudolfovo je 2-krat obiskal član E9, ki se je seznanil z labTOP testno proizvodnjo linijo. Na sestanku so pogovori potekali tudi o napakah na izdelkih, v tem primeru gre za podstavek za slušalke izdelan iz brezove vezane plošče v katero sta narejena dva pravokotna žepa za pritrditev stojala. Pravokotna žepa je izdelal spiralni rezkar, ki je viden na Sliki 3. Iz raziskovalnega stališča nas je zanimalo pod katerimi parametri (pogoji) je izdelan pravokotni žep z minimalnimi odstopanji. Oziroma, če izberemo različne parametre (hitrost pomika, globina reza ter vrtilna hitrost vretena) ali lahko napovemo, kakšno bo dimenzijsko odstopanje pravokotnih žepov. Zaradi omejitev pri izvajanju meritev je bilo v laboratoriju LabTOP pridobljenih le 17 realnih primerov obdelovancev, ki so bili skenirani z 3D skenerjem. Član E9 je z uporabo Python knjižnice SMOGN sintetično razširil podatkovni nabor in tako zagotovil zadostno količino podatkov za učenje modelov strojnega učenja. Skupno število učnih primerov je na koncu znašalo 500. S podatki je naučil različne modele, kjer se je najbolje izkazal MLP regresor. Na koncu je bila opravljena tudi optimizacija hiperparametrov. Ugotovili smo, da so sicer nekateri modeli dobri, vendar smo imeli omejitve pri razpršenosti učnih primerov. Programski paket SMOGN ni bil zmožen ekstrapolirati učnih primerov, generiral je le podobne točke v okolici realnih primerov. Zaradi tega smo vse modele, ki temeljijo na drevesih izločili saj bi bil rezultat pristranski. Zaradi zanimivosti primera smo napisali članek, ki je bil poslan v revijo Informatica [1].



Slika 3: Spiralni rezkar 6mm CMT (desno) in Električno vreteno Hiteco S-13/18 24 ER25 DX BT (levo)


Slika 4 prikazuje rezultat 3D skeniranja lesenega podstavka za slušalke, izdelanega iz brezove vezane plošče. Skeniranje je bilo izvedeno z avtomatiziranim 3D-skenerskim sistemom Raptor 3DX, ki omogoča natančno digitalizacijo površin brez potrebe po referenčnih markerjih. Barvna lestvica na desni strani slike prikazuje dimenzijska odstopanja v milimetrih glede na idealni model (CAD model). Zelene površine predstavljajo območja znotraj tolerance ($\pm 0,1$ mm), rumena in rdeča barva označujeta pozitivna odstopanja oziroma previsoke točke, modra območja pa negativna odstopanja oziroma poglobitve.



Slika 4: 3D-sken brezove vezane plošče – podstavek za slušalke

4 IZBOLJŠAVA ALGORITMA ZA OPTIMIZACIJO PORABE ELEKTRIČNE ENERGIJE

V okviru aktivnosti je bil razvit napovedni model porabe in proizvodnje električne energije, namenjen optimizaciji rabe energije v laboratoriju LabTOP. Model temelji na uporabi rekurentnih nevronske mreže (LSTM in BiLSTM), ki so prilagojene za obdelavo časovnih vrst in omogočajo natančno napoved porabe in proizvodnje električne energije v 15-minutnih intervalih do treh dni vnaprej, kot to prikazuje Slika 5. Pri razvoju modela napovedi proizvodnje sončne energije je bilo uporabljenih 13 vhodnih vremenskih značilnosti (temperatura, sončno obsevanje, oblačnost, vlaga, hitrost vetra...). Doseženi rezultati so pokazali RMSE 2,3 kWh (LSTM) in 2,5 kWh (BiLSTM) ter $R^2 = 0,75$ in $0,70$, pri čemer se je ansambelski model izkazal kot najbolj natančen pri dnevni in tridnevni napovedi (napaka 1,5 % in 2,7 %).



Slika 5: Napoved proizvodnje sončne energije

Drugi del raziskave je bil usmerjen v napoved porabe energije v proizvodnji, kjer so vhodne spremenljivke zajemale tip izdelka, dolžino obdelave, delovni cikel stroja ter režim obratovanja. Model omogoča oceno pričakovane porabe energije za posamezen proizvodni nalog, kar bo v sklopu aktivnosti 5.5 povezano s podatki o napovedani proizvodnji sončne energije v digitalnem dvojčku. S tem pristopom bomo lahko vnaprej določili optimalno razmerje med uporabo energije iz omrežja in iz baterijskega sistema.

5 BIBLIOGRAFIJA

- [1] P. Kucovan, „Forecasting Rectangular Pocket Deviations in Birch Plywood for Milling Process Optimization“.
- [2] „PCA“, scikit-learn. Pridobljeno: 2. november 2025. [Na spletu]. Dostopno na: <https://scikit-learn/stable/modules/generated/sklearn.decomposition.PCA.html>
- [3] „Selecting the number of clusters with silhouette analysis on KMeans clustering“, scikit-learn. Pridobljeno: 2. november 2025. [Na spletu]. Dostopno na: https://scikit-learn/stable/auto_examples/cluster/plot_kmeans_silhouette_analysis.html
- [4] „KMeans“, scikit-learn. Pridobljeno: 2. november 2025. [Na spletu]. Dostopno na: <https://scikit-learn/stable/modules/generated/sklearn.cluster.KMeans.html>