

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat D8.1:

Izvedba in testiranje napovedovanja porabe energije

Projekt/RRP	DIGITOP/RRP 8 - Aktivnost 8.2 Identifikacija in integracija modela za napovedovanje energije
Vrsta dokumenta	Poročilo o rezultatu D8.1
Verzija dokumenta	v1
Sodelujoči partnerji	IJS-E2, ULFE-LAK, KOLEKTOR
Avtorji	Dejan Gradišar, Miha Glavan, Gregor Černe, Grega Kmet
Datum priprave	31. 07. 2025

Kazalo

1	UVOD	3
2	DEMONSTRACIJSKI PROCES KOSOVNE PROIZVODNJE	3
2.1	OPIS PROIZVODNEGA PROCESA.....	3
2.2	SEGMENTACIJA PODATKOV	3
2.3	RAZVOJ NAPOVEDNEGA MODELA	4
3	DEMONSTRACIJSKI PROCES ZVEZNE PROIZVODNJE.....	7
3.1	OPIS PROCESA MLETJA.....	7
3.2	OSNOVNI NAPOVEDNI MODEL.....	8
3.3	ANALIZA VPLIVOV NA PROFIL PORABE PROIZVODNJE	8
3.4	REGRESIJSKI MODELI	11
3.5	NELINEARNI MODELI	13
3.6	ANALIZA REZULTATOV	15
	BIBLIOGRAFIJA	17

1 Uvod

V okviru aktivnosti za razvoj sistema za napovedovanje električne energije proizvodnih sistemov sta bila izbrana dva demonstracijska primera. Prvi demonstracijski primer predstavlja diskretni proizvodni proces, ki je implementiran pri projektnem partnerju Rudolfovo. Drugi demonstracijski primer pa je zvezni proizvodni proces večjih moči, ki pa gostuje pri zunanjem industrijskem partnerju.

Dva demonstracijska proizvodna procesa sta bila izbrana z namenom zagotavljanja raznolikosti pristopov in celovite demonstracije različnih pristopov k napovedovanju porabe. Lastnosti procesa namreč vplivajo na to kakšen pristop pri modeliranju procesa je potrebno uporabiti. Več o samih pristopih za napovedovanje porabe proizvodne porabe pa je bilo podano v poročilu D4.5. V tem dokumentu pa so predstavljeni prvi rezultati napovedovanja, ki bodo tekom izvajanja RDp8 nadgrajeni v končni demonstrator pristopa.

2 Demonstracijski proces kosovne proizvodnje


2.1 Opis proizvodnega procesa

Demonstracijski industrijski proizvodni proces v Rudolfovem predstavlja primer kosovne linije na kateri se izdelujejo posamezni izdelki. Proizvodna linija je namenjena demonstraciji in izobraževanju o novih tehnologijah ter konceptih Industrije 4.0. Proizvodna linija je sestavljena iz večih podajalnih robotov, CNC obdelovalnih enot, ročne postaje ter optične kontrole izdelka. Vsako izmed postaj povezuje tekoči trak, RFID zaznava nosilnih palet ter avtonomnim vozičkom za interno logistiko. Na proizvodni liniji se lahko izdeluje več izdelkov, ki se med seboj razlikujejo po obliki izdelka kakor tudi personalizaciji končnih izdelkov (prilagojeno graviranje).

2.2 Segmentacija podatkov

Opazovani proizvodni proces je tipičen primer kosovne obdelovalne linije. Ker pa je primarni namen tega proizvodnega procesa demonstracija tehnologij nimamo na voljo velikih ponovitev proizvodnih potekov. Za namene demonstracije pristopa in testiranja so v Rudolfovem izvedli testne seje, kjer so izdelali nekaj končnih izdelkov, hkrati pa je njihov nadgrajen informacijski sistem beležil moč posamezne delovne postaje s frekvenco vzorčenja 2s in zapisoval stanja delovanja posameznih proizvodnih postaj. Zbrani podatki so bili osnova za nadaljnje analize in razvoj pristopa za napovedovanje porabe proizvodnje. Proizvodna linija vsebuje sledeče operative proizvodne operacije na katere smo se osredotočili: skladišče, lasersko obdelovanje, posluževalni robot CNC obdelave, CNC obdelava, ročna obdelovalna postaja, sistem optične kontrole (vision) ter etiketiranje izdelkov.

V prvem koraku smo iz proizvodne baze podatkov identificirali ustrezne dogodke, ki označujejo začetek in konec posameznih proizvodnih operacij. Nato smo za vsako proizvodno operacijo določili ustrezne indikatorje proizvodne aktivnosti med vsemi razpoložljivimi proizvodnimi dogodki. Primeri aktivnosti posameznih proizvodnih faz in njihovo sosledje izvajanja so prikazani na Slika 1.




Slika 1: Proizvodni dogodki vseh opazovanih proizvodnih postaj

V naslednjem koraku smo vse časovne profile porabe posameznih obdelovalnih postaj segmentirali na profile porabe operativnih proizvodnih faz (»production operation mode«) in profile porabe posameznih proizvodnih enot v ustaljenem stanju (»steady state mode«). Tako pripravljeni segmenti in dogodki proizvodnih operacij so bili osnova za razvoj napovednega modela porabe proizvodnega procesa.


2.3 Razvoj napovednega modela

Segmentirani profili moči aktivnih faz vsebujejo karakteristične profile, ki nakazujejo operativne aktivnosti. Seveda pa njihovi profili v osnovi niso čisto časovno poravnani saj prihaja do določenih zamikov začetkov operacij glede na identificirane indikatorje proizvodne aktivnosti. V prvi fazi razvoja modela smo uporabili metodo ERAL [1] za poravnavo segmentov. Primer poravnanih segmentov operativne proizvodne operacije CNC obdelovalnega stroja je prikazan na Slika 2. Poravnani segmenti imajo usklajene karakteristične vrhove porabe kar omogoča nadaljnjo združevanje in identifikacijo prototipov porabe za posamezne proizvodne faze. Podobno poravnavo smo izvedli za vse proizvodne operacije.

V naslednjem koraku smo na podlagi poravnanih proizvodnih segmentov identificirali prototipe porabe. Vsak prototip je zaobjel statistiko proizvodnih operacij v danem trenutku. Z agregacijo smo identificirali povprečno porabo in ovrednotili standardno deviacijo meritev s katero je mogoče ovrednotiti tudi interval zaupanja napovedi glede na statistiko. Identificirani prototipi za vse proizvodne operacije in poravnani segmenti so prikazani na Slika 3. Vidimo lahko, da so bile proizvodne operacije kljub dolgemu vzorčnemu času (2s) ustrezno poravnane glede na karakteristike proizvodnih operacij. Identificirani prototipi pa tudi ustrezno agregirajo karakteristiko delovnih operacij.




Slika 2: Poravnani segmenti operativne proizvodne porabe za aktivno fazo proizvodnega obratovanja – primer operacije CNC obdelovalnega stroja



Slika 3: Identifikacija prototipov porabe proizvodnih operacij

Identificirani prototipi proizvodnih operacij omogočajo natančno predvidevanje porabe posamezne operacije. Zaradi narave procesa, ki zagotavlja dobro ponovljivost proizvodnih operacij lahko pričakujemo, da so te napovedi zadosti natančne in brez večjih deviacij. Da pa bi lahko napovedali časovno sosledje dogodkov in napovedali kdaj bo določena proizvodna operacija aktivna, je bilo potrebno razviti še model, ki opisuje stanja proizvodnega procesa. V ta namen smo na podlagi indikatorjev proizvodnih aktivnosti in zgodovinskih primerov

(npr. Slika 1) identificirali diskretno dogodkovni model prehajanja stanj proizvodnega procesa. Slika 4 prikazuje strukturo identificiranega modela predstavljenega s stohastičnimi Petrijevimi mrežami. Struktura modela opisuje možne prehode stanj, ki so bili prisotni v podatkih. Razvidno je, da si proizvodne operacije sledijo v sosledju izvajanja posameznih obdelovalnih postaj od POS0 do POS6. Tri izmed operacij (POS2, POS3 in POS4) pa tečejo vzporedno. Na podlagi zbranih proizvodnih podatkov smo za vsako izmed stanj identificirali čase prehodov in deviacijo prehodov. To nam omogoča, da lahko simuliramo izvajanje proizvodnih operacij. Z združenimi modeli prototipov proizvodnih moči lahko dobimo simulirane pričakovane profile moči in s tem tudi napoved moči za poljubni proizvodni plan.



Slika 4: Diskretno dogodkovni model demonstracijskega proizvodnega procesa.

V času priprave poročila je bilo za ta demonstracijski proces relativno malo vzorčnih primerov. Tekom izvajanja programa je bil namreč nadgrajen informacijski sistem proizvodnega procesa, pri čemer so bili integrirani novi senzorji moči ter nadgrajeni identifikatorji proizvodnih operacij. Prav tako pa primarna demonstracijska narava procesa ne zagotavlja veliko operativnih podatkov, saj se na liniji ne izdeluje večjega števila izdelkov. Tekom obdobja zbrani podatki tako niso bili povsem primerljivi, zato smo se osredotočili zgolj na zadnjo serijo podatkov. Tekom izvedbe demonstriranja pa se pričakuje, da se bo model še nadgradil na podlagi na novo zbranih podatkov.

3 Demonstracijski proces zvezne proizvodnje

V tem poglavju predstavljamo demonstracijski primer napovedovanja porabe električne energije v zveznem proizvodnem procesu, in sicer v industrijskem mletju mineralnih surovin v slovenskem podjetju. Glavni cilj je bil razviti napovedni model, ki omogoča oceno porabe energije na osnovi dostopnih vhodnih spremenljivk v realnem času. V ta namen smo razvili in primerjali več podatkovnih modelov ter analizirali vpliv posameznih vhodnih značilk.


3.1 Opis procesa mletja

Proces, ki ga obravnavamo v sklopu projekta vključuje mletje različnih mineralnih materialov in je shematsko predstavljen s Sliko 5. Poraba električne energije predstavlja pomemben strošek, zato podjetje išče načine za boljše razumevanje in napovedovanje porabe, z namenom izboljšanja planiranja proizvodnje tako, da upoštevajo tudi energetska učinkovitost.

Za namene analize smo pridobili omejen nabor proizvodnih podatkov za eno obratovalno leto. Razpoložljive vrednosti so:

- hitrost vrtenja (na cca 1 minuto),
- pretok vhodnega materiala (FIC) (na cca 1 minuto),
- tip izdelka (na cca 1 uro) in
- merjena odjemna moč (na 2-5 sekund).

Poleg tega smo iz javnih virov pridobili še meteorološke podatke (temperatura in vlaga) za geografsko področje, kjer se nahaja obravnavan proces. Cilj je napovedati kakšno moč bi morali zagotavljati za izvedbo določenega plana, ki je določen z želenim tipom izdelka in časom izvedbe.




Slika 5: Predstavitev procesa.

Vsaka meritev je merjena s svojim časom vzorčenja. Tako je bila naša prva naloga, da podatke ustrezno združimo obdelamo. Podatke smo standardizirali, agregirali in odpravili manjkajoče vrednosti. Časovne serije smo poravnali na skupno frekvenco vzorčenja. Kjer je potrebno določiti nove vrednosti, te določimo z linearno interpolacijo. Pri smo uporabili pristope predstavljene v poročilu [7]. Da omogočimo lažji izračun, oziroma, da se izognemo slabo definiranim stanjem procesa, smo se že na začetku odločili, da bomo upoštevali le meritve, ko

stroj deluje v normalnem obratovalnem režimu. V vseh primerih smo podatkovni set razdelili na učno in validacijsko množico v razmerju (80:20).

3.2 Osnovni napovedni model

Začetno modeliranje smo izvedli zgolj na osnovi proizvodnega plana, t.j. kdaj se izvaja kak tip izdelka (material). In tako preverili ali ima že tip proizvajanega izdelka odločilen vpliv na porabo električne energije. Uporabili smo linearno regresijo in identificirali model razmerja med materialom, ki se trenutno in porabljenega energijo.



Slika 6: Napoved na osnovi izdelka, ki se proizvaja.

Kot že lahko opazimo iz Slika 6, rezultati niso zadovoljivi. Sicer lahko vidimo, da se ob trenutkih menjave materiala spremeni tudi poraba, vendar vrednosti na osnovi tega ne moremo napovedati. Rezultate smo ovrednotili s tremi glavnimi metrikami: MAE: 156.65, MSE: 35074, R^2 : -0.208. Očitno na porabo ne vpliva zgolj tip izdelka, temveč je potrebno za napoved vključiti več dodatnih informacij o proizvodnih razmerah.

3.3 Analiza vplivov na profil porabe proizvodnje


Za izboljšanje natančnosti modela smo vključili še več razpoložljivih podatkov. Poleg tipa izdelka smo upoštevali tudi parametre, kot so hitrost vrtenja mlina, hitrost prenosa dovodnega materiala (FIC), ter dodatne zunanje dejavnike, kot so časovne spremenljivke (dan v tednu, mesec v letu) in meteorološke podatke (temperatura zraka, relativna vlaga) iz okoljske meteorološke merilne postaje.

Ker želimo preveriti upoštevanje dinamike procesa, smo iz obstoječih podatkov ustvarili zakasnjene regresorje. Preverili smo tudi vpliv različnih izpeljanih regresorjev, med katerimi so: (i) odvod hitrosti, (ii) integral odvoda hitrosti, kjer smo odstranili dele s preveliki skoki v hitrosti, (iii) razlika med hitrostjo materiala in hitrostjo vrtenja mlina.

Ker smo s tem kreirali veliko število možnih značilk, smo izvedli postopek selekcije, da smo ohranili le tiste, ki najbolj vplivajo na izhodno vrednost – odjemno moč [1]. Postopek filtriranja smo izvedli v treh korakih.


V prvem koraku smo odstranili močno korelirane značilke s pomočjo **korelacijske analize**, ki omogoča hitro prepoznavanje redundantnih spremenljivk [3]. Za vse neodvisne spremenljivke smo izračunali Pearsonove korelacijske koeficiente in jih prikazali v simetrični korelacijski matriki, kjer vsak element predstavlja korelacijo

med spremenljivkama in (Slika 7, zgoraj). Analizo smo izvedli na absolutnih vrednostih korelacij, pri čemer smo močno korelirane značilke odstranili, saj ne prinašajo dodatnih informacij in lahko povzročijo težave zaradi kolinearnosti (Slika 7, spodaj).



Slika 7: Korelacijska matrika.

V drugem koraku smo preverili nelinearne povezave in ocenili informacijsko vrednost izbranih značilk z izračunom **skupne informacije** (*MI - mutual information*). Ta analiza nam pove, v kolikšni meri posamezna značilka vpliva na ciljno spremenljivko. Vrednosti smo normalizirali in odstranili značilke z nizko informativno vrednostjo ($prag = 0.01$), kar je prikazano na Slika 8. Ker je analiza MI računsko zahtevnejša, smo jo izvedli šele po korelacijski analizi.



Slika 8: Skupna informacija (MI) z odvisno spremenljivko.

V tretjem koraku smo preverili, ali so po predhodnih filtriranjih med preostalimi značilkami še vedno prisotne odvečne povezave med spremenljivkami, ki bi lahko povzročale težave v modelu. Zato smo uporabili **parcialno korelacijo**, ki meri korelacijo med dvema spremenljivkama ob upoštevanju vpliva vseh ostalih značilk. Tako smo lahko ugotovili, ali sta dve značilki še vedno močno povezani, tudi ko odstranimo vpliv drugih značilk. Za vsako značilko smo izračunali parcialno korelacijo ter uporabili dva kriterija za filtriranje: absolutno korelacijo ($> 0,1$) in p -vrednost ($< 0,05$). Absolutna korelacija nam pove, ali ima značilka zadostno linearno povezavo s ciljno spremenljivko, medtem ko p -vrednost določa, ali je ta povezava statistično značilna. Značilke so bile ohranjene le, če sta bila izpolnjena oba pogoja. Rezultati so prikazani v Tabela 1. Ta korak je pomemben predvsem, kadar imamo opravka z večjih številom značilk.


ZNAČILKA	KORELACIJA	p-VALUE
<i>Velocity</i>	0.729344	0
<i>Material</i>	0.365976	0
<i>Temperature</i>	0.314804	0
<i>Humidity</i>	0.0528771	1.487e-281
<i>FIC</i>	0.0492984	5.724e-245
<i>DayOfWeek</i>	-0.191759	0
<i>Month</i>	-0.430725	0

Tabela 1: Analiza parcialne korelacije.

Izmed začetnih 30 značilk smo na koncu izbrali 5 ključnih, ki jih uporabimo za identifikacijo napovednega modela. Pred učenjem modela smo podatke normalizirali s standardizacijo, kar zagotavlja enakovredno obravnavo vseh značilk in preprečuje vpliv različnih merilnih enot. To je predvsem pomembno v primerih, ko uporabljamo algoritme modeliranja, ki so občutljivi na velikost vhodnih podatkov. Na koncu smo podatke razdelili na učno in testno množico, kar omogoča neodvisno validacijo modela.


3.4 Regresijski modeli

V nadaljevanju smo za napovedovanje ciljne spremenljivke uporabili linearno regresijo, eno najosnovnejših metod za modeliranje odvisnosti med več neodvisnimi spremenljivkami (regresorji) in odvisno spremenljivko. Model je bil naučen na učnem naboru podatkov in nato preizkušen na testnem naboru. Primerjava merjenih in izračunanih vrednosti je predstavljena na Slika 9. Dobljene vrednosti metrik na testnem naboru so: MAE: 102.23, MSE: 15292.8, R^2 : 0.4788. Vrednosti kažejo, da model razloži približno 47.88% variance ciljne spremenljivke, kar pomeni, da ima le delno napovedno moč.



Slika 9: Primerjava merjenih in izračunanih vrednosti ob uporabi regresijskega modela.

Opazimo, da napovedi niso vedno natančne in prihaja do večjih odstopanj za določene faze obratovanja procesa. V nadaljevanju smo preverili, ali so odvisnosti regresorjev od ciljne spremenljivke nelinearne. To smo storili s pomočjo razpršenih diagramov in LOWESS regresije [5]. V primeru, ko točke na grafu ne sledijo ravni črti, je to lahko znak nelinearnosti. Kot vidimo na Slika 10, se v vseh izbranih značilkah kažejo nelinearne povezave, kar indicira, da bi bilo potrebno uporabiti za modeliranje bolj kompleksno modelno strukturo.




Slika 10: Analiza nelinearnosti

3.5 Nelinearni modeli


Za izboljšanje napovedne natančnosti smo uporabili nevronske mreže, ki omogoča zajemanje kompleksnejših, nelinearnih povezav med regresorji in ciljno spremenljivko.

Model smo zasnovali z večplastno arhitekturo, sestavljeno iz vhodne plasti, dveh skritih plasti in izhodne plasti. Skriti plasti vsebujeta različne število nevronov, pri čemer se uporabljajo različne aktivacijske funkcije, kot sta ReLU in LeakyReLU, ki omogočata učinkovitejšo propagacijo signalov skozi omrežje ter zmanjšujejo težave, povezane z izginjanjem gradientov pri globljih modelih.



Slika 11: Primerjava merjenih in izračunanih vrednosti z uporabo nevronske mreže z izbranimi regresorji.

Nevronska mreža je bila učena na učnem naboru podatkov, pri čemer so se uteži optimizirale glede na kriterij minimalne kvadratne napake. Model je bil nato preizkušen na testnem naboru podatkov. V prvotni konfiguraciji model ni bistveno presegel zmogljivosti linearne regresije ($MAE = 105.94$, $MSE = 16599.7$, $R^2 = 0.4342$, Slika 11), zato smo preizkusili še drugačne nabore regresorjev. Z naborom 18ih regresorjev dobimo nekoliko bolj obetavne rezultate: $MAE: 60.76$, $MSE: 7206.6$, $R^2: 0.752$ (Slika 12).



Slika 12: Primerjava merjenih in izračunanih vrednosti z uporabo nevronske mreže z večjim naborom regresorjev.


3.6 Analiza rezultatov

V raziskavi smo proučevali možnosti napovedovanja odjemne moči v proizvodnem procesu s pomočjo podatkovnega modeliranja. Take modele lahko podjetju služijo kot osnova za nadaljnji razvoj orodij za optimizacijo stroškov, ki jih imajo z uporabo električne energije. Uporabili smo različne metode za izbiro najvplivnejših veličin. Te smo potem uporabili za podatkovno modeliranje, kjer smo preskusili tako linearno regresijo, kot tudi nevronske mreže. Izkaže se, da so končne napovedi pod pričakovanji, kar nakazuje na pomanjkanje ključnih informacij v razpoložljivih učnih podatkih.

Robustnost in generalizacijske sposobnosti modela smo na koncu preverili tudi s k -kratno navzkrižno validacijo (ang. -fold cross validation), ki omogoča natančnejšo oceno napovedne zmogljivosti modela in zmanjšuje vpliv naključne razdelitve podatkov na rezultate. Pri tej metodi so podatki razdeljeni v več (v našem primeru pet) enakovrednih skupin, pri čemer model učimo večkrat na različnih kombinacijah učnih in testnih podatkov. Vsakič

model treniramo na večini podatkov, medtem ko preostali del služi kot validacijski nabor. Na koncu se izračunajo povprečne vrednosti napovednih metrik ($R^2: 0.9836 \pm 0.0010$).

Rezultati so pokazali izjemno ugodne vrednosti metrik, kar je lahko znak prenaučnosti modela na podatke, saj se model preveč prilagodi posameznim skupinam podatkov in ne generalizira dobro na nove primere. To smo preverili z analizo poteka konvergence modela, kjer smo spremljali spremembo vrednosti učne in validacijske napake skozi proces učenja (Slika 13). Pri tem smo ugotovili, da se učna napaka hitro zmanjša, validacijska napaka pa se povečuje. Tak vzorec je značilen za prenaučene modele, saj kaže, da model dobro opisuje učne podatke, vendar se ne posploši na nove primere.



Slika 13: k-kratna navzkrižna validacija.

Za boljšo napoved bi torej potrebovali več podatkov iz proizvodnje. Tako je prihodnje delo usmerjeno na obravnavo širše slike proizvodnje in upoštevanje več meritev ter informacij o poteku proizvodnje. Dodatno bomo raziskali vpliv naprednejših modelov in prilagoditev strukture nevronske mreže, kar bi lahko pripomoglo k izboljšanju natančnosti napovedi.

Bibliografija

- [1] Ž. Stržinar, B. Pregelj, I. Škrjanc: Non-elastic time series fuzzy clustering for efficient analysis of industrial data sets. *Applied Soft Computing* 167, 112398 (2024)
- [2] M. Glavan, D. Gradišar, M. Atanasijević-Kunc, S. Strmčnik, G. Mušič. Input variable selection for model-based production control and optimisation. *International journal of advanced manufacturing technology*. 2013, vol. 68, no. 9/12, str. 2743-2759. DOI: [10.1007/s00170-013-4840-1](https://doi.org/10.1007/s00170-013-4840-1).
- [3] S.-J. Shin, J. Woo, S. Rachuri, Predictive Analytics Model for Power Consumption in Manufacturing, *Procedia CIRP*, 15: 153-158, 2014. <https://doi.org/10.1016/j.procir.2014.06.036>.
- [4] A. Osojnik, M. Žnidaršič, B. Ženko, M. Bošnjak, S. Tomažič, M. G., Ž. Stržinar, Rezultat D1.1: Metodološke osnove za napovedovanje in upravljanje porabe energije. Digitop. Jul 2024.
- [5] https://en.wikipedia.org/wiki/Local_regression
- [6] G. Černe, M. Glavan, D. Gradišar, V. Govže, Rezultat D4.1: Stanje raziskav na področju napovedovanja porabe energije. Digitop. Jan 2024.
- [7] D. Gradišar, M. Glavan, G. Kmet. Rezultat D4.5: Analiza za napovedovanje porabe energije, DIGITOP, 2025.