

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat D8.3:

Integracija napovedovanja porabe energije v MES

Projekt/RRP	DIGITOP/RRP 8 - Aktivnost 8.2 Identifikacija in integracija modela za napovedovanje energije
Vrsta dokumenta	Poročilo o rezultatu D8.3
Verzija dokumenta	v1
Sodelujoči partnerji	KOLEKTOR, IJS-E2, ULFE-LAK, IJS-E6
Avtorji	Dejan Gradišar, Miha Glavan, Rok Cek, Gregor Grega, Kmet, Klemen Blokar, Marko Hudomalj, Miha Smolnikar, Andrej Čampa, Mihael Mohorčič
Datum priprave	30. 06. 2026

Kazalo

1.	UVOD	3
2.	OKOLJE ZA PRENOS MODELOV V PRODUKCIJSKO OKOLJE	3
3.	DEMONSTRACIJSKI PROCES KOSOVNE PROIZVODNJE	6
3.1.	LABTOP PROIZVODNA LINIJA	6
3.2.	MODEL ZA NAPOVEDOVANJE PORABE ELEKTRIČNE ENERGIJE	7
3.3.	PROTOTIPI PORABE PROIZVODNIH OPERACIJ	8
3.4.	DISKRETNO DOGODKOVNI MODEL PROIZVODNIH OPERACIJ	9
3.5.	IMPLEMENTACIJA DISKRETNO DOGODKOVNEGA MODELA PROIZVODNIH OPERACIJ	9
3.6.	VALIDACIJA MODELA	10
4.	DEMONSTRACIJSKI PROCES ZVEZNE PROIZVODNJE	11
4.1.	PROCES MLETJA	11
4.2.	PRIPRAVA NAPOVEDNEGA MODELA PORABE ENERGIJE	12
4.2.1.	KLASIFIKACIJSKI MODEL ZA IDENTIFIKACIJO MATERIALA	12
4.2.2.	REGRESIJSKI MODEL ZA NAPOVED PORABE ELEKTRIČNE ENERGIJE	13
4.2.3.	IMPLEMENTACIJA MODELOV ZA UPORABO V KONČNEM PRODUKCIJSKEM OKOLJU	14
4.3.	INTEGRACIJA REŠITVE V PROIZVODNI INFORMACIJSKI SISTEM MES V PROIZVODNEM OKOLJU	14
4.3.1.	PROCESNI PODATKI IN ZAJEM MERITEV	15
4.3.2.	PODATKOVNA PLAST	15
4.3.3.	IZVAJANJE MODELNIH NAPOVEDI	15
4.3.4.	PRIMERJAVA NAPOVEDI Z DEJANSKIMI MERITVAMI	16
4.3.5.	VIZUALIZACIJA IN UPORABNIŠKI PREGLEDI	16
4.3.6.	ORKESTRACIJA OBDELAV	17
4.3.7.	TEHNIČNA ARHITEKTURA	17
4.4.	UPORABNIŠKI VMESNIK	18
4.4.1.	PREGLED DASHBOARDOV	18
4.4.2.	PREGLED NAPOVEDI MODELA	19
4.4.3.	PRIMERJAVA TOČNOSTI MODELOV	20
4.4.4.	BELEŽENJE IN PRIKAZ VREDNOSTI VHODNIH (ZAJETIH) PODATKOV	21
5.	RAZVOJ SISTEMA ZA NEINVAZIVNO SPREMLJANJE PORABE KOMPRIMIRANEGA ZRAKA	22
5.1.	PROIZVODNJA IN PORABA KOMPRIMIRANEGA ZRAKA V INDUSTRIJSKEM OKOLJU	22
5.2.	SPREMLJANJE PRETOKA KOMPRIMIRANEGA ZRAKA	22
5.3.	OSNOVNI KONCEPT MERILNEGA SISTEMA	23
5.4.	PROTOTIP SENZORSKE NAPRAVE	23
5.5.	DEMONSTRACIJSKO OKOLJE ZA SPREMLJANJE PRETOKA KOMPRIMIRANEGA ZRAKA	24
	BIBLIOGRAFIJA	26

1. Uvod

Za razvoj sistema za napovedovanje porabe električne energije v proizvodnih sistemih sta bila vzpostavljena dva demonstracijska primera. Prvi demonstracijski primer temelji na diskretnem proizvodnem procesu LabTop, katerega upravlja projektni partner Rudolfovo. Drugi demonstracijski primer obravnava zvezni proizvodni proces mletja, ki je bil v sklopu aktivnosti Digitop implementiran pri zunanjem industrijskem partnerju iz Slovenije. Izbira dveh vzporednih primerov omogoča testiranje in demonstracijo različnih pristopov za napovedovanje porabe električne energije, saj lastnosti obravnavanih procesov vplivajo na izbor pristopa za razvoj napovednih modelov.

V okviru aktivnosti 8.1 je bil izveden izbor ustreznih proizvodnih procesov na podlagi trenutne stopnje digitalizacije procesov ter razpoložljivosti podatkov o porabi električne energije [1]. Razpoložljivi podatki so bili ustrezno pred-obdelani z namenom zagotavljanja njihove kakovosti in primernosti za razvoj napovednih modelov. V aktivnosti 8.2 so bili na podlagi pripravljenih podatkov razviti, validirani in integrirani končni modeli za napovedovanje porabe električne energije, ki so bili preizkušeni v povezavi z dejanskimi proizvodnimi procesi.

V tem projektnem poročilu so predstavljene podrobnosti priprave in implementacije obeh demonstracijskih primerov. V naslednjem poglavju je predstavljena implementacija enotnega okolja za prenos napovednih modelov iz razvojnega v produkcijsko okolje. Poglavje 3 podrobneje obravnava pripravo in implementacijo napovednega modela za proces LabTop. V poglavju 4 pa so predstavljene aktivnosti potrebne za implementacijo napovednih modelov v industrijski proizvodni proces mletja. Poglavje 5 povzema aktivnosti povezane z razvojem prototipa neinvazivne senzorske naprave za spremljanje pretoka komprimiranega zraka v industrijskem okolju ter ustreznega demonstracijskega okolja za njegovo testiranje in validacijo.

2. Okolje za prenos modelov v produkcijsko okolje

Z namenom poenotenja prenosa razvitih rešitev strojnega učenja je bilo razvito enovito podporno programsko okolje. Njegov namen je poenostavitev prenosa ter boljši nadzor nad pripravo okolja in izvajanjem modelov za napovedovanje časovnih vrst.

V praksi razvoj in implementacija modelov strojnega učenja poteka v več ciklih. Vsak izmed korakov, od razvoja do testiranja in končne implementacije, se ponavlja, dokler ni delovanje in robustnost razvitih rešitev na zadovoljivi ravni. Celoten življenjski cikel razvoja napovednih modelov tako tipično poteka v več medsebojno povezanih okoljih, in sicer v:

- razvojnem okolju, kjer poteka priprava podatkov, eksperimentiranje in učenje modelov,
- testnem oziroma laboratorijskem okolju, kjer se preverja delovanje modelov na novih podatkih,
- produkcijskem okolju, kjer so modeli vključeni v dejanske industrijske procese in podpirajo operativno odločanje.

V začetnih fazah razvoja se modeli praviloma gradijo na podlagi zgodovinskih podatkov v ne-sprotnem načinu delovanja. Tak pristop omogoča fleksibilno preizkušanje različnih metod modeliranja, optimizacijo parametrov

ter podrobno analizo podatkov. Po uspešni validaciji se model prenese v produkcijsko okolje, kjer se uporablja za sprotno napovedovanje, spremljanje procesov in podporo izboljševanju proizvodnega sistema.

V industrijski praksi modeli strojnega učenja običajno delujejo kot sestavni del širšega informacijskega sistema. Zato jih je treba povezati z bazami podatkov, poslovnimi aplikacijami in drugimi storitvami, ki omogočajo njihovo avtomatizirano in zanesljivo uporabo.


Izkušnje iz številnih razvojnih in industrijskih projektov kažejo, da je prehod modelov iz razvojnega oziroma testnega okolja v produkcijsko okolje pogosto zahteven in časovno potraten. Glavni izzivi se nanašajo na:

- upravljanje izvajalnega okolja modelov (knjižnice, odvisnosti in način izvajanja),
- upravljanje različic modelov (posodabljanje),
- obravnavo napak in izrednih dogodkov med izvajanjem,
- zagotavljanje ustrezne ravni varnosti in nadzora dostopa,
- spremljanje in vrednotenje uspešnosti modelov skozi celoten življenjski cikel.

Posodobitve modelov in njihove nadaljnje izboljšave pogosto zahtevajo ponovno vzpostavitev izvajalnega okolja ter dodatne aktivnosti pri integraciji in odpravljanju napak, kar povečuje stroške razvoja in njihovega dolgoročnega vzdrževanja.

Z namenom poenostavitve prenosa razvitih rešitev iz razvojnega okolja v testno in produkcijsko okolje je bila razvita namenska programska rešitev. Rešitev naslavlja navedene izzive z enotnim in splošno uporabnim pristopom za uvajanje, upravljanje in izvajanje modelov strojnega učenja. Zaradi svoje modularnosti in prilagodljivosti omogoča uporabo v različnih industrijskih okoljih in za različne modele za napovedovanje časovnih vrst.

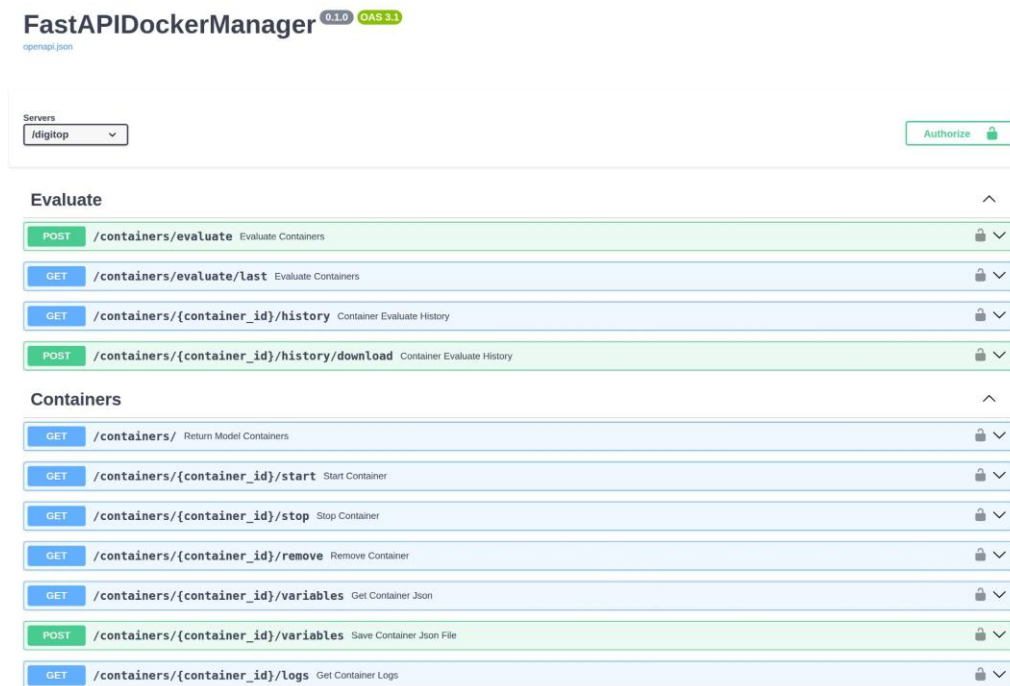
Arhitekturna zasnova predlagane tehnične izboljšave je predstavljena na Slika 1. Predlagana rešitev predstavlja skalabilno, varno in modularno arhitekturo, zasnovano na kontejnerski osnovi (Docker, [2]), ki omogoča enostavno uvajanje, upravljanje in nadzor modelov strojnega učenja, ki lahko izvirajo iz povsem različnih razvojnih okolij. Sistem je zasnovan kot posredniški sloj med razvojnimi okolji modelov in produkcijskimi informacijskimi sistemi.



Slika 1: Funkcionalnosti razvitega sistema za prenos napovednih modelov iz testnega v produkcijsko okolje


Konteinerizacija okolij je bila izbrana kot osnova za implementacijo modelov. Pri tem vsak model deluje v lastnem izoliranem okolju (kontejnerju), kar zagotavlja izolacijo, ponovljivost in enostavno prenašanje med okolji. Zasnova z ločenimi kontejnerji tako omogoča: (i) hitre posodobitve modelov, (ii) konsistentnost med napravami, (iii) minimalno odvisnost od infrastrukture ter (iv) varno izolacijo med modeli.

Celoten sistem komunicira z zunanjim svetom preko enotnega REST API vmesnika (Slika 2). Vmesnik je poenoten za vse vključene modele, kar poenoti komunikacijski pristop za vse modele, ne glede na njihovo implementacijo. Preko centralnega REST API vmesnika lahko zunanji sistemi: (i) pošiljajo vhodne podatke modelom, (ii) pridobijo rezultate napovedi, (iii) upravljajo modele (start/stop/update), (iii) dostopajo do zgodovine rezultatov, logov. REST API je standardiziran in dokumentiran (OpenAPI/Swagger), kar omogoča enostavno integracijo s spletnimi sistemi, IoT napravami, ERP/SCADA sistemi ipd. Dokumentacija REST API vmesnika je tudi dokumentirana v [3].



Slika 2: Programski vmesnik za upravljanje sistema z uporabo REST API vmesnika, ki je dokumentiran po standardu OpenAPI

Drug način za upravljanje z modeli pa predstavlja grafični uporabniški vmesnik. Preko vmesnika je mogoče na enostaven način naložiti nove različice modelov, pregledovati delovanje obstoječih modelov, izvoziti zgodovinske podatke ter na splošno nadzirati delovanje večih implementiranih modelov. Primer osnovnega preglednega okna uporabniškega vmesnika je prikazano na Slika 3.



Slika 3: Osnovno uporabniško okno za nadzor nad implementiranimi modeli strojnega učenja ter zadnjimi izhodnimi napovedmi modelov

3. Demonstracijski proces kosovne proizvodnje

Prvi demonstracijski primer temelji na diskretnem procesu LabTop, v katerem potekajo operacije obdelave in sestavljanja različnih kosovnih izdelkov (npr. ure, podstavki). V sklopu aktivnosti RRp8 je bil za izbran proces razvit napovedni model ter implementiran v enotno implementacijsko okolje (predstavljeno v prejšnjem poglavju). Razvit demonstrator je bila osnova za vzporedne aktivnosti, ki so tekle v RRp9, kjer je bil napovedni model implementiran v proizvodno-informacijski sistem procesa LabTop.

3.1. LabTop proizvodna linija

LabTOP proizvodna linija (Slika 4) predstavlja fleksibilno in avtomatizirano okolje za izdelavo osnovnih izdelkov v več variacijah, kar omogoča preučevanje različnih proizvodnih scenarijev. Linija je zasnovana kot sistem, ki podpira integracijo različnih industrijskih komponent ter prilagodljivo konfiguracijo procesov. Vgrajeni sistemi za zajem podatkov omogočajo spremljanje širokega nabora signalov in meritev, vključno z energetskimi, procesnimi in operativnimi parametri. Razvojno okolje omogoča testiranje in validacijo algoritmov ter digitalnih rešitev, saj zagotavlja realistično, a hkrati nadzorovano platformo za eksperimentiranje z različnimi pristopi upravljanja in optimizacije proizvodnje.




Slika 4: Proizvodna linija LabTop

V okviru demonstracije pristopa so bile opravljene meritve med izdelavo produkta namizne ure, sestavljene iz dveh polizdelkov, z možnostjo različnih variacij obdelave. Proizvodni proces je bil zasnovan kot zaporedje avtomatiziranih operacij, ki vključujejo skladiščenje (POS0 SKLADISCE), lasersko graviranje (POS1 LASER), CNC-obdelavo (POS2 ROBOT CNC, POS3 CNC), ročno sestavo (POS4 ROCNO), vizualno kontrolo (POS5 STROJNI VID) ter etiketiranje (POS6 ETIKETIRANJE). Polizdelki so bili najprej avtomatsko naloženi na transportne palete, nato pa so prehajali skozi posamezne obdelovalne celice, kjer so se izvajali prilagojeni programi glede na varianto izdelka. Po mehanski in laserski obdelavi sta bila oba polizdelka na ročnem delovnem mestu sestavljena v končni izdelek. Sledila je še kontrola kakovosti z uporabo sistema strojnega vida ter zaključna obdelava. Transport palet med celicami je potekal avtomatizirano, pri čemer je bila zagotovljena tudi krožna logistika praznih in polnih palet.

3.2. Model za napovedovanje porabe električne energije

Pristop razvoja napovednih modelov temelji na kombinaciji podatkovno gnanega modeliranja in formalnega diskretno dogodkovnega modeliranja, kot to prikazuje Slika 5. Podatkovni del se uči na zgodovinskih podatkih in opiše, kako posamezna operacija porablja energijo, diskretno-dogodkovni del pa opiše, kdaj se operacije zgodijo, koliko časa trajajo in kako se med seboj omejujejo.




Slika 5: Pristop za razvoj energetskega digitalnega dvojčka z združevanjem prototipov porabe operacij in diskretno-dogodkovnega modela proizvodnje

3.3. Prototipi porabe proizvodnih operacij

Prototip porabe predstavlja statistični opis tipične energijske sledi določene proizvodne operacije. Ker so operacije v kosovni proizvodnji ponovljive, je mogoče iz več merjenih ponovitev oceniti pričakovano obliko profila in njegovo časovno odvisno variabilnost. Postopek je sestavljen iz štirih glavnih korakov (Slika 6):

1. Zajem surovega profila porabe: iz meritev se pridobi časovna vrsta moči za posamezno proizvodno postajo.
2. Identifikacija aktivnih operacij: z uporabo indikatorjev začetka in konca se izločijo odseki, ki pripadajo dejanski proizvodni aktivnosti.
3. Poravnava ponovitev: profili se časovno poravnajo, ker lahko med ponovitvami pride do manjših zamikov značilnih dogodkov. Uporabljena je metoda ERAL za poravnavo časovnih vrst.
4. Statistični opis: za vsako časovno točko poravnane profila se oceni pričakovana vrednost in varianca porabe.




Slika 6: Identifikacija prototipov porabe proizvodnih operacij

3.4. Diskretno dogodkovni model proizvodnih operacij

Model delovnega toka določa, kdaj se posamezna operacija začne in konča, kateri viri so zasedeni, kje nastajajo čakalne vrste in katere operacije lahko potekajo sočasno. Za ta namen je uporabljen formalizem stohastičnih Petrijevih mrež. Stohastična Petrijeva mreža omogoča opis: (i) zaporednih in vzporednih proizvodnih operacij, (ii) omejitev proizvodnih virov, (iii) čakalnih vrst pred delovnimi postajami, (iv) naključnosti oziroma variabilnosti trajanja operacij ter (v) sinhronizacije med operacijami.

Za celotno proizvodno linijo je bil zgrajen SPN model, ki vključuje čakalne vrste pred celicami, omejitev obdelave enega izdelka naenkrat in posebno povezavo med robotsko in CNC operacijo. Celotna shema diskretno-dogodkovnega modela proizvodnega procesa LabTop je prikazana na Slika 7.




Slika 7: Diskretno dogodkovni model LabTop proizvodnih operacij

3.5. Implementacija diskretno dogodkovnega modela proizvodnih operacij

Razvit napovedni model je bil v celoti implementiran v okolju Python. Pri tem so bile uporabljene standardne metode za pred-procesiranje podatkov (scikit-learn) [4], ERAL metoda za poravnavo časovnih signalov prototipov [5] ter knjižnica PySPN [6] za opis diskretno-dogodkovnega modela procesa. Podrobnosti o razvitih Python skriptah, potrebnih za končno implementacijo, so predstavljene v tehničnem poročilu [7].

Končna različica napovednega modela je bila kontejnerizirana (angl. *dockerized*), na način, da omogoča vključitev v pripravljeno okolje za končno implementacijo modelov. V sklopu priprave kontejnerja je bilo pripravljeno branje in pisanje zahtevkov za napoved na podlagi centralnega MQTT strežnika sistema. Okolje za implementacijo modelov pa navzven komunicira z ostalimi deležniki sistema preko REST-API vmesnika. Pri tem sta za uporabo ključni dve spletni storitvi, prikazani na Slika 8. Prva omogoča pridobitev imena vseh aktivnih kontejnerjev, druga pa omogoča ovrednotenje poljubnega napovednega zahtevka.




Slika 8: REST-API vmesnik modela za napovedovanje porabe procesa LabTop

Parametri zahteve za preračun napovedi se podajo preko jedra REST-API zahtevka. Le-to pa mora biti strukturirano po naslednjem vzorcu: {"schedule": {"0": 1, "100": 1}, "N": {"0": 20}, "t_sim_end": {"0": 500}}. Pri tem je potrebno podati urnik (schedule) delovnega naloga (čas in število kosov), število ponovitev monte-carlo simulacije (N) ter končni simulacijski čas (t_sim_end). Zahtevnik vrne tri vrednosti v obliki časovne vrste, in sicer, pričakovano povprečno porabo (mean), ki se izračuna kot povprečje porabe vseh monte-carlo simulacij, spodnji simulacijski interval zaupanja (cis_low) ter zgornji simulacijski interval zaupanja (cis_high). Pri tem je čas simulacije zaveden v sekundah izvajanja procesa.

3.6. Validacija modela

Slika 9 prikazuje združen rezultat stotih simulacij za izvedbo enakega proizvodnega plana izdelave sedmih izdelkov. Rezultati kažejo, da se simulirana napoved dobro ujema z variabilnostjo, zajeto z razvitim napovednim modelom, kar potrjuje ustreznost predlaganega pristopa za modeliranje in napovedovanje energijskih potreb proizvodnega procesa. Z integracijo razvitega modela v proizvodno-informacijski sistem procesa LabTop (izvedba v RRP9) pa bo naknadno mogoča še bolj podrobna validacija za različne delovne naloge.



Slika 9: Primerjava simulacijske napovedi (100 simulacijskih tekov) z dejansko porabo procesa

4. Demonstracijski proces zvezne proizvodnje

V tem poglavju so predstavljene podrobnosti glede implementacije demonstracijskega primera napovedovanja porabe električne energije v zveznem proizvodnem procesu. Demonstrator je bil vzpostavljen v slovenskem podjetju, kjer poteka proces mletja mineralnih surovin.

Glavni cilj aktivnosti v projektu DIGITOP je bil razvoj napovednega modela, ki omogoča oceno porabe energije na osnovi dostopnih vhodnih procesnih spremenljivk v realnem času. Motivacija za natančno napoved porabe izhaja predvsem iz narave procesa mletja, kjer je zagotavljanje želene kakovosti produkta neposredno povezano s sposobnostjo upravljanja moči porabe procesa.

4.1. Proces mletja

Obravnavani proces predstavlja industrijsko linijo za mokro mletje kalcijevega karbonata oziroma proizvodnjo mokro mletega kalcijevega karbonata. V procesu se predhodno zdrobljeni kalcit zmeša z vodo, nato pa se zmes obdelava v mešalnem mlinu. V mlinu se mehanska energija z vrtečega mešala in mlevnih teles prenaša na mineralno suspenzijo. Namen mletja je zmanjšati velikost delcev kalcijevega karbonata ter pri tem zagotoviti stabilno goščo, primerno za nadaljnjo industrijsko uporabo.

Pri napovedovanju porabe električne energije procesa ni smiselno obravnavati zgolj kot časovne vrste pretekle porabe, temveč kot voden fizikalni proces. Trenutna poraba električne moči je odvisna od obratovalnega stanja mlina, količine doziranega materiala, mehanske obremenitve v mlevni komori in lastnosti suspenzije. Med pomembnejšimi procesnimi veličinami sta hitrost mletja in hitrost doziranja. Hitrost mletja vpliva na količino mehanske energije, ki se prenese na mlevna telesa, hitrost doziranja pa vpliva na obremenitev mlina z materialom in na čas zadrževanja materiala v mlevni komori. Spremembe teh nastavitev se zato lahko hitro odrazijo v spremenjeni porabi električne energije.

Proces ima tudi določeno časovno vztrajnost. Spremembe hitrosti mletja ali doziranja se v izmerjeni električni moči ne pokažejo nujno takoj, saj so v mlinu že prisotni suspenzija, mlevna telesa in material v obdelavi. Na porabo vplivajo tudi lastnosti gošče, predvsem koncentracija trdnih snovi, porazdelitev velikosti delcev in stanje disperzije. Zaradi tega so pri modeliranju koristne tudi značilke, izračunane iz preteklih vrednosti v drsečih časovnih oknih. Te značilke zajamejo nedavno zgodovino procesa in s tem posredno opisujejo trenutno stanje sistema.

Dodaten vir variabilnosti predstavljajo lastnosti vhodnega materiala. Tudi pri istem nominalnem tipu proizvoda lahko razlike v surovini vplivajo na zahtevnost mletja, obnašanje suspenzije in posledično na porabo električne energije.

4.2. Priprava napovednega modela porabe energije

Za razvoj napovednega modela porabe električne energije smo imeli na voljo procesne podatke za obdobje od leta 2022 do leta 2025. Podatki so vključevali informacije o električni moči, specifični porabi energije, hitrosti mletja, hitrosti doziranja ter lastnostih materiala. Ker so bili podatki zajeti z različnimi časovnimi ločljivostmi oziroma stopnjami vzorčenja, na primer 1 s, 2 s, 5 s, 10 s, 30 s, 60 s, 120 s in 600 s, smo jih pred uporabo v modelih prevzorčili na enominutne intervale.


Poleg procesnih podatkov smo v analizo vključili tudi vremenske podatke, in sicer podatke o padavinah, relativni vlažnosti in temperaturi. Ti podatki so bili pridobljeni iz vremenske postaje ARSO, ki se nahaja v bližini obravnavanega mlina. Vremenske podatke smo vključili zato, ker je material skladiščen na prostem, zaradi česar lahko vremenske razmere vplivajo na njegove lastnosti in posledično tudi na porabo energije med procesom mletja.

4.2.1. Klasifikacijski model za identifikacijo materiala

V začetni fazi smo razvili več modelov strojnega učenja. Pri tem smo ugotovili, da modeli, ki so bili razviti ločeno za posamezne materiale na podlagi obstoječih oznak v podatkih, pogosto niso dosegali pričakovanih rezultatov. Podatke o materialih smo zato dodatno pregledali skupaj z industrijskim partnerjem. Pri pregledu je bilo ugotovljeno, da oznake materialov v podatkovni bazi niso bile vedno pravilno oziroma dosledno zabeležene.

Zaradi tega smo preverili možnost identifikacije materiala na podlagi procesnih podatkov. Z uporabo dveh atributov, ki opisujeta lastnosti materiala, in metode gručenja K-means je bilo mogoče materiale večinoma razdeliti v tri večje gruče. Gruče se med seboj delno prekrivajo, vendar vseeno omogočajo bolj smiselno ločevanje različnih tipov materiala, kot je prikazano na Sliki 8.

Tako določene skupine materialov smo nato uporabili pri razvoju regresijskih modelov, specifičnih za posamezen tip materiala.



Slika 10: Identifikacija tipa izdelka na podlagi obratovalnih procesnih podatkov

4.2.2. Regresijski model za napoved porabe električne energije

Za napoved porabe električne energije smo razvili več regresijskih modelov strojnega učenja. Med uporabljenimi modeli so bili linearni modeli, drevesni modeli, modeli gradient boosting in drugi pristopi. Vsi modeli so bili implementirani v programskem jeziku Python.

Pred učenjem modelov smo izvedli dodatno pred obdelavo podatkov. Za procesne podatke smo izračunali agregirane značilke na podlagi 90-minutnega časovnega okna pred trenutkom napovedi. Za vremenske podatke smo uporabili tritedensko časovno okno, saj vremenske razmere na material ne vplivajo nujno le kratkoročno, temveč lahko zaradi zunanjega skladiščenja vplivajo na njegove lastnosti skozi daljše časovno obdobje.

Modele smo učili na podatkih iz obdobja 2022–2024, njihovo uspešnost pa smo ovrednotili na testnih podatkih iz leta 2025. Napovedi smo pripravljali za tri časovne horizonte: 15, 30 in 45 minut vnaprej.

Uspešnost modelov smo ocenjevali z metrikami R^2 , RMSE in MAPE. Med preizkušenimi modeli se je najbolje odrezal model Ridge, ki spada med linearne regresijske modele z regularizacijo. Predvidevamo, da je bil razlog za dobro delovanje tega modela predvsem v ustrezni pripravi vhodnih značilk. Z uporabo 90-minutnih agregacij procesnih podatkov in tritedenskih agregacij vremenskih podatkov smo zmanjšali vpliv šuma in kratkoročne volatilnosti v podatkih, zaradi česar je bil tudi linearni model sposoben dobro opisati odvisnost med vhodnimi spremenljivkami in porabo energije.

Primerjava rezultatov je pokazala, da so modeli, razviti ločeno za posamezne skupine materialov, v vseh primerih dosegli boljše rezultate kot globalni modeli, naučeni na vseh materialih hkrati. To je razvidno iz Tabele 1. Rezultati kažejo, da je uporaba gručenja za ločevanje materialov izboljšala kakovost napovedi, predvsem pri materialih, pri katerih globalni model ni uspel dobro zajeti značilnih obratovalnih vzorcev.

Tabela 1: Validacijski rezultati napovednih modelov za vse predvidene tipe materiala in časovne horizonte

		R2		RMSE		MAPE	
		Global Model	Specific Model	Global Model	Specific Model	Global Model	Specific Model
Target	Material						
15 min	Mat 1	0.9439	0.9566	39.0804	34.3588	1.3464	1.3417
	Mat 2	0.6832	0.6908	51.2892	50.6697	3.0461	3.0311
	Mat 3	-0.5506	0.1862	43.1341	31.2480	0.9510	1.1715
30 min	Mat 1	0.9023	0.9174	50.4210	46.3857	2.0256	1.9867
	Mat 2	0.6271	0.6523	55.5088	53.6011	3.2514	3.1927
	Mat 3	-0.8849	0.1011	54.0181	37.3026	1.3084	1.5169
45 min	Mat 1	0.8648	0.8789	58.5545	55.4090	2.5698	2.5020
	Mat 2	0.5800	0.6180	59.2757	56.5319	3.4475	3.3390
	Mat 3	-1.4984	-0.0293	66.4527	42.6533	2.1047	1.8832

4.2.3. Implementacija modelov za uporabo v končnem produkcijskem okolju

Razvita sta bila dva alternativna pristopa za napoved porabe proizvodnega procesa mletja. Prvi pristop je bil razvit v okolju Python, drugi pa v okolju Matlab. Končni različici napovednih modelov sta bili pripravljene v obliki Docker kontejnerja, kar omogoča njuno enostavno vključitev v pripravljeno okolje za končno implementacijo modelov predstavljeno v poglavju 2. V okviru priprave kontejnerske rešitve je bila vzpostavljena tudi podpora za branje in pisanje napovednih zahtevkov prek centralnega MQTT strežnika sistema ter inicializacija ključnih sistemskih knjižnic (Python ali Matlab).

Implementacijsko okolje modelov z ostalimi gradniki sistema komunicira prek REST API vmesnika. Pri tem sta ključni predvsem dve spletni storitvi. Prva omogoča pridobitev seznama oziroma imen vseh trenutno aktivnih kontejnerjev (*/containers*), druga pa omogoča ovrednotenje poljubnega napovednega zahtevka in vračanje rezultata napovedi (*/containers/evaluate*).

4.3. Integracija rešitve v proizvodni informacijski sistem MES v proizvodnem okolju

Za namen integracije rešitve v proizvodni informacijski sistem MES smo razvili produkt Sinapro Smart Process, ki predstavlja aplikacijsko rešitev za zajem, obdelavo, shranjevanje, napovedovanje in vizualizacijo procesnih podatkov v industrijskem okolju. Namen rešitve je podpreti spremljanje procesnega stanja v realnem času ter omogočiti kratkoročno napovedovanje izbranih procesnih veličin z uporabo modelov strojnega učenja.

Rešitev omogoča povezavo z industrijskimi viri podatkov, pripravo časovno urejenih podatkov za analitično obdelavo, izvajanje napovednih modelov, shranjevanje rezultatov modelov ter prikaz dejanskih in napovedanih vrednosti v uporabniških pregledih.

Sistem je zasnovan kot modularna aplikacijska arhitektura, ki povezuje procesno avtomatizacijo, podatkovno plast, izvajanje modelov in vizualizacijo rezultatov.

Razvita rešitev pokriva naslednje funkcionalne sklope:

- zajem procesnih podatkov iz industrijskega vira prek OPC UA komunikacije,
- zapis procesnih podatkov v časovno serijsko podatkovno bazo,
- pripravo podatkovnih agregatov za potrebe modelov in vizualizacije,
- periodično izvajanje modelnih klicev,
- shranjevanje napovedanih vrednosti v strukturirani obliki,
- prikaz dejanskih in napovedanih vrednosti v uporabniškem vmesniku,
- primerjavo napovedi z dejanskimi meritvami,
- izračun odstopanj med napovedanimi in izmerjenimi vrednostmi,
- spremljanje kakovosti modelnih napovedi skozi čas.

4.3.1. Procesni podatki in zajem meritev

Procesni podatki se pridobivajo iz industrijskega nadzornega oziroma avtomatizacijskega sistema prek OPC UA vmesnika. V konfiguraciji sistema se določijo procesni tagi, ki predstavljajo vhodne veličine za spremljanje, modelno obdelavo ali vizualizacijo.

Zajeti podatki vključujejo časovni žig meritve, identifikacijo procesne veličine in izmerjeno vrednost. Podatki se zapisujejo v časovno serijsko podatkovno bazo, kjer so pripravljeni za nadaljnjo obdelavo.

Podatkovna plast mora zagotavljati:

- časovno pravilno shranjevanje meritev,
- sledljivost posameznih procesnih veličin,
- možnost poizvedovanja po časovnih intervalih,
- pripravo agregiranih vrednosti,
- podporo za prikaz zgodovinskih trendov,
- podporo za primerjavo dejanskih meritev z modelnimi napovedmi.

4.3.2. Podatkovna plast

Za shranjevanje procesnih podatkov in rezultatov modelov se uporablja časovno serijska podatkovna baza. Struktura podatkovne plasti je zasnovana tako, da omogoča ločeno shranjevanje surovih meritev, agregiranih vrednosti, modelnih napovedi in rezultatov primerjav.

Podatkovni model vključuje najmanj naslednje tipe podatkov:

- dejanske procesne meritve,
- časovne agregate procesnih meritev,
- modelne napovedi za izbrane časovne horizonte,
- metapodatke modelnih klicev,
- izračunana odstopanja med napovedjo in dejansko meritvijo.

Agregati se pripravljajo v časovnih intervalih, ki so primerni za potrebe modelnega napovedovanja in vizualizacije. Tipičen primer je priprava minutnih agregatov, ki se uporabijo kot vhod v napovedni model ali kot vir podatkov za uporabniške grafe.

4.3.3. Izvajanje modelnih napovedi

Modeli se kličejo prek aplikacijskega vmesnika, pri čemer aplikacijski sloj pripravi vhodne podatke, izvede klic modela in shrani rezultate napovedi. Napovedi se lahko izvajajo za več časovnih horizontov. Implementirani horizonti so: (i) napoved za 15 minut naprej, (ii) napoved za 30 minut naprej, (iii) napoved za 45 minut naprej.

Vsaka napoved mora biti shranjena s časovnim žigom izvedbe modelnega klica in časovnim žigom, za katerega napoved velja. Tak način shranjevanja omogoča kasnejšo primerjavo napovedane vrednosti z dejansko izmerjeno vrednostjo, ko je ta na voljo.

Modelni klic vključuje naslednje korake:

1. pridobitev vhodnih procesnih podatkov,
2. pripravo podatkov v obliki, ki jo zahteva model,
3. izvedbo klica modela prek API vmesnika,
4. prevzem rezultatov napovedi,
5. zapis rezultatov v podatkovno bazo,
6. zapis metapodatkov o izvedbi modelnega klica.

4.3.4. Primerjava napovedi z dejanskimi meritvami

Za ocenjevanje uporabnosti modelnih napovedi sistem izvaja primerjavo med napovedano vrednostjo in dejansko izmerjeno procesno vrednostjo. Primerjava se izvede za ustrezen časovni trenutek, za katerega je bila napoved podana.

Za posamezen napovedni horizont se lahko izračunajo naslednje vrednosti: (i) absolutno odstopanje, (ii) relativno oziroma odstotno odstopanje, (iii) trend odstopanja skozi čas,

Primerjava napovedi z meritvami omogoča spremljanje stabilnosti in uporabnosti modela. Na podlagi zbranih podatkov je mogoče identificirati časovna obdobja ali procesna stanja, v katerih model dosega večja odstopanja. Ti podatki predstavljajo osnovo za nadaljnje izboljševanje modela, prilagoditev vhodnih podatkov, spremembo modelnega toka ali nadgradnjo uporabniških prikazov.

4.3.5. Vizualizacija in uporabniški pregledi

Uporabniški pregledi so pripravljeni v okolju za vizualizacijo časovnih serij. Namen pregledov je zagotoviti jasen vpogled v trenutno stanje procesa, zgodovinske meritve in kratkoročne napovedi.

Implementiran uporabniški pregled vključuje:

- graf dejanske procesne vrednosti,
- prikaz modelnih napovedi za izbrane časovne horizonte,
- prikaz trenutne procesne vrednosti,
- prikaz napovedane vrednosti za posamezen horizont,
- prikaz odstopanja med napovedjo in dejansko meritvijo,
- tabelo zadnjih izvedenih modelnih klicev,
- zgodovinski pregled kakovosti napovedi.

Vizualizacija je zasnovana tako, da omogoča primerjavo dejanskih in napovedanih vrednosti na istem časovnem grafu. Napovedana vrednost se prikaže na časovni točki, za katero napoved velja, kar omogoča neposredno primerjavo z dejansko meritvijo.

Pregledi se lahko prilagodijo posameznemu procesu, izbranim procesnim veličinam, uporabniškim vlogam in ključnim kazalnikom spremljanja.

4.3.6. Orkestracija obdelav

Periodične obdelave se izvajajo z uporabo orkestracijskega sistema. Ta skrbi za časovno proženje nalog, pripravo agregatov, izvajanje modelnih klicev in posodabljanje podatkovnih struktur.

Orkestrirane naloge vključujejo:

- periodični zajem oziroma obdelavo procesnih podatkov,
- pripravo agregiranih podatkov,
- preverjanje razpoložljivosti vhodnih podatkov,
- izvajanje modelnih klicev,
- zapis rezultatov modelov,
- izračun odstopanj,
- pripravo podatkov za uporabniške prikaze.

Takšna zasnova omogoča ponovljivost obdelav, nadzor nad izvajanjem nalog in lažje odpravljanje napak pri posameznih korakih podatkovnega toka.

4.3.7. Tehnična arhitektura

Rešitev je zasnovana modularno. Posamezni sestavni deli so izvedeni kot ločene storitve, ki se izvajajo v kontejnerskem okolju. Takšna arhitektura omogoča prenosljivost, nadgradljivost in prilagoditev različnim namestitvenim okoljem.

Glavne komponente sistema so:

- OPC UA integracija za povezavo z industrijskim virom procesnih podatkov,
- časovno serijska podatkovna baza za shranjevanje meritev, agregatov in napovedi,
- orkestracijski sloj za periodično izvajanje obdelav in modelnih klicev,
- modelni vmesnik za komunikacijo z modeli strojnega učenja,
- vizualizacijski sloj za prikaz podatkov, napovedi in odstopanj,
- reverzni posrednik za urejen dostop do storitev,
- Kontejnersko (dockerizirano) izvajalno okolje za namestitev in upravljanje komponent.

Komponente so med seboj povezane prek definiranih vmesnikov. Podatkovni tok je zasnovan tako, da omogoča sledljivost od izvirne meritve do prikaza napovedi in izračunanega odstopanja.

4.4. Uporabniški vmesnik

Aplikacija Sinapro Smart Process za svojo vizualizacijo uporablja odprtokodno platformo Grafano. Pregledi so pripravljeni kot uporabniški pogled nad podatki, ki jih rešitev zbira in obdeluje v ozadju. Uporabniku ni treba poznati strukture podatkovne baze, je pa koristno razumeti, kaj posamezen pregled prikazuje in kako pravilno izbrati časovno obdobje za analizo.

Pregledi temeljijo na podatkih iz »Timescale« podatkovne baze:

- minutni procesni podatki
- modelne evaluacije
- modelne napovedi

Minutni procesni podatki predstavljajo pripravljeno obliko surovih OPC meritev. Napovedi modelov pa so shranjene ločeno od dejanskih meritev, zato Grafana pri primerjavah povezuje napovedi z dejansko vrednostjo za isti ciljni čas.

4.4.1. Pregled dashboardov

Za Sinapro Smart Process so pripravljeni štirje osnovni dashboardi. Vsak ima drugačen namen: dva sta namenjena spremljanju posameznega modela, eden vhodnim procesnim signalom, eden pa primerjavi točnosti modelov.

Vizualizacija spremljanja napovednega modela E2.



Slika 11: Prikaz dejanske vrednosti in napovedi modela IJS-E2

Dashboard Sinapro Smart Process - E2 prikazuje napovedi modela E2 skupaj z dejansko procesno vrednostjo. Namenjen je temu, da uporabnik hitro vidi, kako se napoved E2 ujema s trenutnim in preteklim obnašanjem procesa

Prvi dashboard prikazuje štiri sklope vrednosti, en del so realni zajeti podatki iz procesa ostali trije sklopi pa predstavljajo napovedane vrednosti, ki so postavljene naprej na časovni osi. Vizualizacija je sestavljena iz grafičnega prikaza kot tudi prikazuje same vrednosti meritev.

4.4.2. Pregled napovedi modela

Pri obeh modelih so prikazane prav tako vrednosti glede na ažurno stanje (trenutno zabeleženo vrednostjo) kakšna so odstopanja glede na napovedane vrednosti. Torej odstopanje od vrednosti pred 15, 30 ali 45 minutami glede na trenutno stanje.



Slika 12: Prikaz dejanske vrednosti in napovedi modela ULFE-LAK

Pri uporabi pregleda je priporočljivo opazovati tako obliko krivulje kot tudi absolutne vrednosti. Model je lahko uporaben, če dobro sledi trendu, tudi če ima v določenem obdobju manjši sistematičen zamik. Tak zamik se nato preveri v primerjalnem dashboardu z metrikami bias, RMSE in MAE.


Če je na primer model ob 10:00 izračunal napoved za 10:15, se ta napoved na grafu prikaže pri 10:15. S tem je omogočena neposredna primerjava z dejansko meritvijo ob 10:15, ko ta postane znana.

4.4.3. Primerjava točnosti modelov

vsaka napoved primerja z dejansko meritvijo v času, za katerega je bila napoved narejena. Za oceno točnosti se ne uporablja čas klica modela, ampak ciljni čas napovedi.

Za vsak model in horizont se izračunajo kazalniki:


- RMSE / RMS napake - Koren povprečja kvadratov napak. Bolj kaznuje večja odstopanja. Manjša vrednost pomeni boljši model.
- MAE- Povprečna absolutna napaka. Je intuitivna mera povprečnega odstopanja. Manjša vrednost pomeni boljši model.
- Bias - Povprečna napaka z znakom. Pozitivna vrednost pomeni, da model v povprečju napoveduje previsoko; negativna, da prenizko.
- MAPE - Povprečna absolutna odstotna napaka. Uporabna za relativno primerjavo, vendar je ob majhnih dejanskih vrednostih lahko manj stabilna.
- Percentili absolutne napake - Prikažejo, kakšna je tipična napaka in kakšna so večja odstopanja, na primer p90 ali p95.



Slika 13: Primerjava točnosti modelov E2 in LAK po urnih intervalih

4.4.4. Beleženje in prikaz vrednosti vhodnih (zajetih) podatkov

Ta pregled je pomemben, ker kakovost napovedi ni odvisna samo od modela, ampak tudi od vhodnih signalov. Če je vhodni signal prekinjen, konstanten, nenavadno šumen ali zunaj običajnega območja, se to lahko pozna tudi na napovedih.



Slika 14: Pregled vhodnih procesnih spremenljivk, ki jih uporabljata modela

V zgornjem desnem kotu Grafane izberemo časovno obdobje prikaza. Izbira obdobja je pomembna, ker neposredno vpliva na to, kateri procesni podatki, napovedi in izračuni točnosti se prikažejo.

Za zgodovinske podatke iz testnega izvoza je smiselno izbrati absolutno obdobje, ki pokriva uvožene meritve.

5. Razvoj sistema za neinvazivno spremljanje porabe komprimiranega zraka

Vzporedno z aktivnostmi napovedovanja porabe električne energije so tekale tudi aktivnosti za razvoj prototipnega sistema, ki bi omogočal neinvazivno spremljanje porabe komprimiranega zraka kot primera neelektričnega oziroma posrednega električnega energetskega vektorja. Cilj razvoja je bil zagotoviti rešitev, ki omogoča merjenje pretoka brez poseganja v razvodni sistem, s čimer se zmanjša potreba po mehanskih posegih, prekinitvah delovanja sistema in dodatnih tlačnih izgubah v omrežju komprimiranega zraka. Razvita rešitev se lahko nadgradi z ustreznimi napovednimi modeli porabe električne energije, kot so bili predstavljeni v predhodnih poglavjih.

5.1. Proizvodnja in poraba komprimiranega zraka v industrijskem okolju

Velik del električne energije v diskretni/kosovni proizvodnji se porabi za proizvodnjo komprimiranega zraka. Le-ta služi za delovanje pnevmatskih aktuatorjev, pnevmatskih orodij in ostalih pnevmatskih komponent potrebnih za delovanje proizvodne linije. V proizvodnih obratih se komprimiran zrak generira s pomočjo kompresorskih enot, ki polnijo tlačne rezervoarje. Spremljanje porabe komprimiranega zraka lahko pomembno prispeva k učinkovitejši rabi električne energije, saj se pri kompresiji zraka le 10-20 % vložene energije porabi za komprimiran zrak, preostala energija so toplotne izgube. Optimizacija porabe je mogoča z uporabo tlačnih zalogovnikov, ki omogočajo prilagoditev delovanja kompresorjev glede na trenutne presežke energije v elektroenergetskem omrežju.

Poleg optimizacije proizvodnje je ključnega pomena tudi zmanjšanje izgub v razvodnem sistemu, saj te pogosto predstavljajo 20-30 % proizvedenega komprimiranega zraka. Z zmanjšanjem izgub komprimiranega zraka posledično zmanjšamo toplotne izgube pri kompresiji zraka.

Ena izmed možnosti nadgradnje predstavljenega koncepta napovedovanja porabe električne energije torej predstavlja tudi napovedovanje potreb po komprimiranemu zraku. S sposobnostjo napovedovanja le-tega bi bilo mogoče tudi bolj pametno upravljati s kompresorji zraka (*demand-shifting*), jih uporabljati kot kratkotrajne zalogovnike energije ter tudi hitreje zaznavati izgube v razvodnem sistemu (puščanje).

5.2. Spremljanje pretoka komprimiranega zraka


Merjenje pretoka komprimiranega zraka je bistveno za spremljanje učinkovitosti porabe in detekcijo izgub v industrijskih razvodnih sistemih. Za dober vpogled v dogajanje v razvodnem sistemu je priporočljivo meriti pretok na čim več mestih, torej tako na glavni dovodni liniji kot tudi pri končnih aktuatorjih. To zahteva cenovno dostopne in za namestitev enostavne senzorske naprave, ki ne zahtevajo mehanskih posegov v razvodni cevovod, torej morajo omogočati t.i. neinvazivno namestitev. Poleg tega morajo biti čim manj občutljive na industrijsko obratovalno okolje (nečistoče, vlaga, tresljaji, obraba). V takih pogojih se kot najbolj praktičen in zanesljiv pristop izkaže uporaba ultrazvočnega principa merjenja. Ultrazvočni merilniki merijo časovni zamik med ultrazvočnim signalom, ki potuje v smeri in proti smeri pretoka. Prednost metode so neinvazivnost, delovanje brez gibljivih mehanskih delov in visoka natančnost pri ustrezni izvedbi. Glavne omejitve oziroma izzive za razvoj senzorske naprave, ki smo jih naslovili pri načrtovanju, pa predstavljajo visoka cena obstoječih ultrazvočnih

senzorjev, ki onemogoča množično uporabo v celotnem razvodnem sistemu, in potreba po natančnem pozicioniranju pretvornikov.

5.3. Osnovni koncept merilnega sistema

Najprej je bil zasnovan osnovni koncept merilnega sistema, pri katerem se pretok zraka ocenjuje na podlagi širjenja ultrazvočnih valov skozi dovodno cev. Posebna pozornost je bila namenjena izbiri primerne merilnega principa, postavitvi ultrazvočnih pretvornikov ter zagotavljanju ustreznih pogojev za stabilno zajemanje merilnih signalov.

Ultrazvočni merilniki pretoka temeljijo na merjenju časovne razlike med potovanjem ultrazvočnega signala v smeri in v nasprotni smeri toka zraka. V osnovni izvedbi sta pod določenim kotom glede na vzdolžno os na cev nameščena dva ultrazvočna pretvornika, ki izmenično delujeta kot oddajnik in sprejemnik. Ko zrak teče skozi cev, se hitrost širjenja ultrazvočnega vala, ki potuje v smeri pretoka, poveča, medtem ko se hitrost vala, ki potuje v nasprotni smeri, zmanjša. Razlika v času potovanja signala v obeh smereh je sorazmerna hitrosti pretoka zraka v cevi. Pretvornika sta lahko nameščena na nasprotno ali isto stran cevi in glede na njuno oddaljenost lahko izkoriščata tudi odboje ultrazvočnih valov na prehodih med različnimi mediji (zrak – stena cevi – pretvornik). Odboji znotraj cevi so pogosto šibki, poleg tega pa dodajajo dušenje signala in slabšajo razmerje signal/šum, zato smo se pri izvedbi senzorske naprave odločili za namestitev pretvornikov na nasprotnih straneh cevi brez izkoriščanja odbojev, kot prikazuje Slika 15.



Slika 15: Identifikacija tipa izdelka na podlagi obratovalnih procesnih podatkov

5.4. Prototip senzorske naprave


Razvit je bil prototip senzorske naprave na podlagi uporabe ultrazvočnih pretvornikov z ustreznim elektronskim vezjem za filtriranje in ojačanje sprejetih signalov ter ohišjem za neinvazivno namestitev na razvodni sistem komprimiranega zraka. Uporabili smo standardna ultrazvočna pretvornika pri 300 kHz, kar znižuje skupno ceno naprave. Pretvornika delujeta izmenično kot oddajnik in sprejemnik.

Pomemben del razvoja je predstavljala tudi zasnova mehanskega ohišja za pritrditev ultrazvočnih pretvornikov na cev. Ohišje je bilo razvito z namenom zagotavljanja stabilne in ponovljive namestitve senzorjev ter ustreznega sklopa za prenos ultrazvočnih valov med pretvorniki in cevjo. Pri razvoju ohišja so bili upoštevani mehanska stabilnost, enostavnost montaže, možnost uporabe na različnih cevni sistemih ter zagotavljanje ustreznega kontakta med pretvorniki in merilno površino. Prototip senzorske naprave nameščene na cev prikazuje Slika 16.



Slika 16: Prototip senzorske naprave


V nadaljevanju je bilo razvito analogno vezje za obdelavo zajetih ultrazvočnih signalov, ki vključuje filtriranje, ojačenje in pripravo signalov za nadaljnjo digitalno obdelavo. Ker so ultrazvočni signali lahko šibki in občutljivi na motnje iz okolja, je bil pomemben del razvoja usmerjen v izboljšanje razmerja signal/šum ter zagotavljanje ponovljivih in zanesljivih meritev. Analogni del sistema je bil zato zasnovan tako, da omogoča učinkovito zajemanje relevantnih signalnih značilnosti in zmanjšanje vpliva neželenih motenj. Slika 17 prikazuje prototipno vezje za ojačenje in filtriranje signalov.



Slika 17: Prototipno vezje za ojačenje in filtriranje signalov

5.5. Demonstracijsko okolje za spremljanje pretoka komprimiranega zraka


Za testiranje in validacijo prototipa naprave je bilo vzpostavljeno reprezentativno demonstracijsko okolje za sprotno spremljanje komprimiranega zraka pri različnih hitrostih pretoka, ki ga prikazuje Slika 18.



Slika 18: Testiranje prototipa na testnem demonstracijskem preizkuševališču

Sistem se prek hitrega odklopnika cevi priključi na napeljavo komprimiranega zraka, ki je razpeljana po laboratoriju. Komprimiran zrak se generira s kompresorjem. V demonstracijski postavitvi imamo na vходу glavni ventil, ki odpre ali popolnoma zapre pretok. Zaporedno je vezan precizen ventil pretoka, s katerim lahko natančno reguliramo zračni pretok. Na ventil je povezana cev, na kateri merimo pretok zraka. Preko hitrih odklopnikov lahko enostavno zamenjamo cev na kateri merimo pretok. V testnih eksperimentih smo uporabili cevi premera 8 mm in 12 mm. Na izhodu cevi je prek hitrega odklopnika povezan še dušilec, s katerim zadušimo piskanje zaradi izhajanja zraka.

Demonstracijsko okolje smo uporabili za testiranje in karakterizacijo prototipa neinvazivne senzorske naprave. Po zajemu signalov smo izvedli aktivnosti za obdelavo in analizo merilnih podatkov. To je vključevalo razvoj postopkov za prepoznavanje uporabnih signalnih vzorcev, filtriranje motenj, določanje relevantnih časovnih oziroma amplitudnih značilk ter pripravo podatkov za nadaljnjo oceno pretoka zraka (Slika 19). Obdelava signalov predstavlja ključen del sistema, saj omogoča pretvorbo zajetih ultrazvočnih signalov v informacije, uporabne za oceno trenutne porabe oziroma za kratkoročno napovedovanje porabe komprimiranega zraka.



Slika 19: Merilni signali zajeti z razvitim prototipom merilne opreme

Na koncu je bila izvedena karakterizacija razvitega prototipa senzorske naprave. Namen karakterizacije je bil preveriti delovanje naprave, oceniti stabilnost in ponovljivost meritev ter določiti njene osnovne merilne lastnosti. V okviru teh aktivnosti so bili analizirani odzivi senzorske naprave pri različnih pogojih delovanja, s čimer je bila preverjena primernost razvite rešitve za uporabo v sistemih komprimiranega zraka. Natančnost naprave je bila verificirana z referenčnim merilnikom podjetja Keyence. Pri verifikaciji je bila potrjena linearna korelacija med zakasnitvijo signala in pretokom. Predlagani merilnik omogoča meritve nad 10 l/min. Pri nižjih pretokih (< 10 l/min) natančnost upade, kar je predvsem posledica nižje vzbujevalne frekvence (300 kHz) v primerjavi z referenčnim merilnikom (1 MHz). Izmerjeno karakteristiko signala prikazuje Slika 20.



Slika 20: Karakterizacija časovnega zamika delovanja senzorja

Rezultati karakterizacije predstavljajo osnovo za nadaljnjo optimizacijo sistema, izboljšanje natančnosti meritev ter vključitev senzorja v širši sistem za spremljanje in napovedovanje porabe energije oziroma komprimiranega zraka.

Bibliografija

- [1] Dejan Gradišar, Miha Glavan, Gregor Černe, Grega Kmer, Rezultat D8.1: Izvedba in testiranje napovedovanja porabe energije, Poročilo o rezultatu, DIGITOP, julij 2025.
- [2] Docker Inc., "Docker: A safer container ecosystem, for everyone." Dostopno: <https://www.docker.com/>. [Dostopano: 10. 3. 2026].
- [3] Institut Jožef Stefan, "ModelDockManager-api dokumentacija." Dostopno: <https://repo.ijs.si/digitop-energy/modeldockmanager-api/-/tree/eabf28bc10067c91ec4d401da8734d422b92a3a0/>. [Dostopano: 10. 3. 2026].
- [4] F. Pedregosa et al., "Scikit-learn: Machine Learning in Python," Journal of Machine Learning Research, vol. 12, pp. 2825–2830, 2011.
- [5] Ž. Stržinar, "Implementation of ERAL algorithm." Dostopno: <https://pypi.org/project/eral/>. [Dostopano: 15. 6. 2026].
- [6] J. Friederich, A. Khodadadi, and S. Lazarova-Molnar, "PySPN: A Python library for stochastic Petri net modeling, simulation, and event log generation," *Simulation*, 2025.
- [7] M. Glavan and D. Gradišar, "Pristop za razvoj energijskega digitalnega dvojčka kosovne proizvodne linije," interno tehnično poročilo, Institut Jožef Stefan, Ljubljana, Slovenija, junij 2026. Dostopno: <https://ijssi.sharepoint.com/:b:/s/DIGITOP/IQAU3JvgG2j6Q6DgnVwjQd8lATsPA6Iv2TOZQRmShS1LHsw?e=0JeK4k>.