

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat D8.4:

Integracija zajemanja veščin operaterja v programsko
platformo

Projekt/RRP	DIGITOP/RRP 8 - Aktivnost 8.4 Zajemanje spretnosti operaterja
Vrsta dokumenta	Poročilo o rezultatu D8.4
Verzija dokumenta	v1
Sodelujoči partnerji	METRONIK, IJS-E2, ULFE-LAK
Avtorji	Miha Glavan, Dejan Gradišar, Gregor Mlinarič, Goran Andonovski, Rok Prešeren, Jure Veler
Datum priprave	30. 06. 2026

Kazalo

1.	UVOD	3
2.	DEMONSTRATOR ŠARŽNEGA PROCESA PROIZVODNJE PENICILINA	4
1	DEMONSTRACIJSKI SISTEM PROIZVODNJE PENICILINA.....	4
2	IMPLEMENTACIJA ALGORITMOV ZA PODPORO PRI ODLOČANJU	5
3	VALIDACIJA REZULTATOV	6
4	DEMONSTRATOR PROCESA PRIPRAVE ZMESI ZA INDUSTRIJSKE BRUSE.....	7
5	PROCESNI KORAKI ZA PRIPRAVO ZMESI	7
2.1.	PRISTOP ZA ZAJEM VEŠČIN OPERATERJA.....	7
6	PREGLED ZBRANIH PODATKOV	8
2.2.	MODEL ZA ZAZNAVANJE POTREBE PO KOREKCIJI RECEPTA	9
2.3.	MODEL ZA OCENO POTREBNE KOREKCIJE RECEPTA	10
2.4.	SPROTNO ZBIRANJE IN DOSTOP DO RELEVANTNIH PROIZVODNIH PODATKOV	12
7	IMPLEMENTACIJA V PRODUKCIJSKO OKOLJE	13
2.5.	RAZVOJ UPORABNIŠKEGA VMESNIKA	14
2.6.	INTEGRACIJA V OKOLJE MEPIS	15
	BIBLIOGRAFIJA	16

1. Uvod

Za zajemanje veščin operaterjev sta bila v programu DIGITOP izbrana dva demonstratorja: simulacijski proces proizvodnje penicilina in industrijski proces priprave zmesi za bruse.

Prvi demonstrator je šaržni proces proizvodnje penicilina, kjer ena šarža traja okoli deset dni. Proces poteka po vnaprej določenih recepturah, vendar lahko kljub enakim pogojem prihaja do velikih razlik v končnem izplenu. Ravno zato je pomembno, da operaterji sproti spremljajo potek procesa ter pravočasno ukrepajo ob zaznanih odstopanjih. Za demonstrator je bil uporabljen simulacijski proces, razvit v RRP4 in A8.3. Proces in rezultati razvoja algoritmov so bili že predstavljeni v poročilih D4.4 [1], D4.6 [2] in D8.2 [3].

Drugi demonstrator se nanaša na šaržni industrijski proces priprave zmesi za bruse. Čeprav podjetje uporablja podrobne recepture in procesni nadzor, se pojavljajo odstopanja v kakovosti pripravljene zmesi, kar lahko vpliva na kakovost končnih izdelkov. Tudi v tem primeru je ključno operatersko znanje, saj omogoča zgodnje prepoznavanje in kompenzacijo nepravilnosti ter zmanjšuje potrebo po naknadnih korekcijah. Tudi obravnavan industrijski proces in razviti algoritmi za ta proces pa so bili že predstavljeni v poročilu D8.2.

V sledečem poglavju so predstavljeni rezultati priprave in validacije simulacijskega demonstratorja šaržnega procesa proizvodnje penicilina. Poglavlje 3 pa poda več podrobnosti glede priprave demonstratorja v slovenskem podjetju, ki proizvaja bruse.


2. Demonstrator šaržnega procesa proizvodnje penicilina

Prvi vzpostavljen demonstrator za zajem veščin operaterjev predstavlja simulacijski model za industrijsko proizvodnjo penicilina. Cilj demonstratorja je bil razvoj sistema za priporočanje korekcij receptov šaržnega procesa z namenom povečanja končnega izplena proizvedenega penicilina. Modeli ter metodološki pristopi učenja in zajema veščin operaterja so bili že predstavljeni v D8.2 [1]. V tem poročilu pa je podrobneje predstavljena končna arhitektura demonstratorja ter validacija rezultatov pridobljenih na podlagi upoštevanja priporočil razvitega sistema.

1 Demonstracijski sistem proizvodnje penicilina

Osnova demonstratorja je realističen simulacijski model za industrijsko proizvodnjo penicilina [4]. Model je implementiran v okolju Matlab. V okviru aktivnosti RRP4 je bil model korigiran za namene demonstratorja, prav tako pa so bili pripravljeni simulacijski klici modela, preko katerih smo pridobili zgodovinske podatke dobrih obratovalnih primerov. Zgodovinski podatki uspešnih obratovalnih primerov so bili uporabljeni za razvoj in testiranje različnih priporočilnih pristopov, ki so bili razviti v okolju Python.


Končno arhitekturo demonstratorja prikazuje Slika 1. Python skripta preko REST-API vmesnika prebere trenutno stanje procesa. Na podlagi trenutnega stanja in izbrane logike priporočilnega sistema, se izbere ustrezno priporočilo za operaterja proizvodnje. Med validacijo je bilo predpostavljeno, da operater sprejme predlagane korekcije recepta ter le-te tudi implementira v realnosti. Potrjene korekcije recepta se preko REST-API vmesnika potrdijo v procesu. Iterativno spremljanje stanja in korekcija receptov se je izvajala vsakih 24 ur operativnega teka procesa.




Slika 1 Arhitektura demonstratorja za zajem veščin procesa za industrijsko proizvodnjo penicilina

2 Implementacija algoritmov za podporo pri odločanju

Za priporočanje korekcij recepta so bili razviti trije podatkovno vodeni pristopi. Prvi pristop (Slika 2) temelji na napovednem modeliranju in optimizaciji, kjer modeli, kot sta XGBoost in MLP, najprej ocenijo vpliv možnih nastavitvev procesnih spremenljivk na povečanje mase penicilina, nato pa optimizacijski algoritmi izberejo najugodnejšo korekcijo. Drugi pristop (Slika 3) uporablja priporočilne sisteme na osnovi heterogenih grafovskih nevronskih mrež, ki na podlagi podobnosti med trenutnim stanjem procesa in preteklimi uspešnimi eksperimenti priporočijo ustrezne vrednosti manipulativnih spremenljivk. Tretji, hibridni pristop združuje prednosti obeh predhodnih skupin metod, saj upošteva priporočila več modelov in jih poveže v končno odločitev. S tem omogoča bolj robustna priporočila, višji končni izplen in stabilnejše delovanje v primerjavi z uporabo vnaprej določenega recepta.



Slika 2: Priporočilni pristop z regresijskim modelom in optimizacijo



Slika 3: Priporočilni pristop grafovskimi nevronskimi mrežami

Vsi trije razviti pristopi so bili implementirani v okolju Python in povezani v demonstracijsko arhitekturo, predstavljeno v prejšnjem razdelku. Izvorna koda vseh implementiranih algoritmov je bila urejeni in arhivirani v lokalnem GitLab repozitoriju na strežniku IJS [5].

3 Validacija rezultatov

Validacija pristopov za priporočanje korekcij recepta je bila izvedena v pripravljenem demonstracijskem okolju. Simulacijski način validacije omogoča ponovljivo preverjanje vpliva predlaganih operaterskih akcij na potek proizvodnje penicilina. Za oceno učinkovitosti modelov je bilo pripravljenih 100 novih simulacijskih eksperimentov, ki niso bili vključeni v fazo učenja modelov. Vsi modeli so bili preverjeni na enakih začetnih pogojih oziroma na istih naključnih semenih, s čimer je bila zagotovljena neposredna primerljivost rezultatov.

Vsak eksperiment je bil izveden v dveh različicah. V prvi različici je proces sledil osnovnemu, vnaprej določenemu receptu brez dodatnih korekcij. V drugi različici pa so bile v izbranih časovnih točkah uporabljene korekcije, ki jih je predlagal posamezni odločitveni oziroma priporočilni sistem. Na ta način je bilo mogoče neposredno oceniti, ali priporočila modela izboljšajo delovanje procesa glede na referenčni recept.

Učinkovitost pristopov je bila ovrednotena z več merami. Osnovna mera je bila končna masa proizvedenega penicilina, pri čemer so bili za vsak model izračunani povprečje, standardni odklon, najmanjša in največja dosežena vrednost. Dodatno je bilo preverjeno, v koliko eksperimentih je model presegel izbrani prag uspešnosti 3100 kg in v koliko primerih je izboljšal rezultat glede na osnovni recept. Takšna zasnova validacije ne upošteva samo povprečne uspešnosti, temveč tudi robustnost modela in stabilnost priporočil v različnih procesnih pogojih. Rezultati so pokazali, da hibridni pristopi dosegajo najboljše rezultate in da bistveno presegajo osnovni recept.

Rezultati predlaganega pristopa so bili dodatno ovrednoteni s primerjavo z obstoječimi pristopi iz literature, ki so bili prav tako preizkušeni na enakem simulacijskem modelu (za podrobnejšo primerjavo glej [6]). Najboljši povprečni rezultat med primerjanimi metodami doseže najboljši pristop iz literature (10-bit RPC), vendar je razlika do modela HYBv1 razmeroma majhna. HYBv1 doseže povprečni izplen 4642 kg, medtem ko 10-bit RPC doseže 4864 kg. Ob tem pa HYBv1 doseže tudi najvišjo posamezno opaženo vrednost izplena, 5431 kg, kar kaže, da lahko predlagani pristop v ugodnih pogojih doseže zelo konkurenčne rezultate.

Ključna prednost razvitega pristopa ni zgolj v doseženem izplenu, temveč tudi v nižji pogostosti intervencij. Medtem ko preostali pristopi zahtevajo prilagajanje procesnih nastavitev vsakih 12 minut, razvit pristop pričakuje korekcije le vsakih 24 ur. To pomeni, da je pristop manj invaziven in bolj primeren za scenarije, kjer sistem ne nadomešča operaterja, temveč ga podpira pri sprejemanju odločitev. Takšna zasnova je skladna z namenom sistema za podporo odločanju, saj ohranja človeka v odločevalski povratni zanki, hkrati pa omogoča znatno izboljšanje proizvodnega rezultata.


Primerjava z literaturo zato kaže, da predlagani hibridni pristop dosega rezultate, ki so primerljivi z najboljšimi objavljenimi metodami za optimizacijo proizvodnje penicilina. Čeprav ne doseže najvišjega povprečnega izplena, predstavlja zelo ugoden kompromis med učinkovitostjo, robustnostjo in praktično uporabnostjo, saj dosega visoke izplene ob bistveno manjšem številu potrebnih korekcij recepta.

4 Demonstrator procesa priprave zmesi za industrijske bruse

Drugi demonstrator je bil razvit v slovenskem podjetju, specializiranem za izdelavo industrijskih brusov. Obravnavali smo proces izdelave keramičnih brusov, pri katerem imata pomembno vlogo izkušnost in znanje procesnih operaterjev. Cilj predlaganega pristopa pa je bil formalizirati del operatorskega znanja ter čim bolj zmanjšati število potrebnih korekcij recepta priprave zmesi za bruse.

5 Procesni koraki za pripravo zmesi

Proces priprave zmesi za industrijske bruse poteka kot šaržni proizvodni proces, kot ga prikazuje Slika 4. V začetni fazi se posamezne surovine in veziva odmerijo skladno s predpisano recepturo ter zmešajo v industrijskem mešalniku. Po končanem mešanju operater preveri ustreznost pripravljene zmesi na podlagi vizualne in fizične ocene. Če zmes ne dosega zahtevanih lastnosti, operater izvede korekcijo recepture z dodatkom ustrezne količine vlažilnega sredstva (ovlažila). Namen korekcije je zagotoviti primerno kakovost zmesi pred nadaljnjimi fazami oblikovanja, stiskanja, sušenja oziroma termične obdelave ter končne kontrole izdelka.



Slika 4: Prikaz operacij procesa za izdelavo brusov skupaj s povratno zanko za korekcijo recepture za bruse

Problem obravnavanega procesa je, da ustreznosti pripravljene zmesi za industrijske bruse po fazi mešanja ni mogoče neposredno in objektivno ovrednotiti z merljivim kazalnikom. Kljub uporabi predpisanih receptur se zaradi sprememb v lastnostih surovin, okoljskih pogojih in procesnih okoliščinah pojavljajo odstopanja v kakovosti zmesi. Zato ima ključno vlogo operater, ki na podlagi izkušenj, vizualne ocene in fizičnega preverjanja presodi, ali je potrebna korekcija recepture.

2.1. Pristop za zajem veščin operaterja


Osnovni obravnavani problem je zajetje in formalizacija operatorskega znanja na podlagi razpoložljivih proizvodnih podatkov in zabeleženih korekcij. Cilj je določiti povezavo med procesnimi pogoji, operatorskimi posegi in ustreznostjo pripravljene zmesi. Problem smo razdelili na dva koraka: najprej je potrebno ugotoviti, ali je korekcija zmesi potrebna, nato pa še oceniti obseg potrebne korekcije. Tako pridobljen model lahko predstavlja osnovo za sistem za podporo odločanju, ki operaterju pomaga pri pravočasnem in bolj konsistentnem prilagajanju recepture.

Ključni izzivi pri obravnavanem procesu izhajajo predvsem iz pomanjkanja objektivnega merila za oceno ustreznosti zmesi po mešanju. Ocena kakovosti je zato močno odvisna od izkušenj operaterja, njegove vizualne in fizične presoje ter odločanja. Dodatno težavo predstavlja dejstvo, da operatersko znanje ni neposredno merljivo in ga je težko formalizirati v model. Pri podatkovnem modeliranju so izzivi povezani tudi z nepopolno sledljivostjo nekaterih surovin, delno ročno zabeleženimi korekcijami receptur ter omejeno velikostjo razpoložljivega nabora podatkov. Le-to pa je bilo že naslovljeno v poročilu D8.2 [1].

Modeliranje je bilo izvedeno v dveh korakih. Najprej je bil problem obravnavan kot klasifikacijska naloga, pri kateri model napove, ali je korekcija recepture potrebna. V drugem koraku je bil uporabljen regresijski model za oceno velikosti potrebne korekcije. Tak pristop omogoča tako zaznavanje potrebe po operaterskem posegu kot tudi določitev priporočene količine popravka, kar predstavlja osnovo za sistem za podporo odločanju.

6 Pregled zbranih podatkov


Za zajem znanja operaterjev so bili uporabljeni zgodovinski proizvodni podatki, zbrani na ravni posameznih šarž. Podatki se nanašajo na en izbran proizvodni recept in pokrivajo obdobje od 13. 1. 2023 do 18. 11. 2024. V tem obdobju je bilo zabeleženih 227 proizvodnih šarž, razporejenih čez 73 proizvodnih dni (Slika 5).



Slika 5: Število izdelanih šarž izbranega izdelka po opazovanih mesecih

V podatkovni zbirki so zajete predpisane količine vhodnih surovin v skladu z recepturo ter dejansko odmerjene količine, ki jih je pri pripravi zmesi stehal in dodal operater. Za modeliranje niso bile uporabljene absolutne količine, temveč odstopanja med predpisanimi in dejansko odmerjenimi količinami posameznih surovin. Poleg teh procesnih podatkov je bil vključen tudi tip mešanja kot kategorična spremenljivka.

Proizvodni podatki so bili dopolnjeni z okoljskimi meritvami, predvsem z dnevno temperaturo in relativno vlažnostjo zraka (Slika 6). Okoljski podatki so bili na voljo za 680 dni in so bili časovno usklajeni s proizvodnimi zapisi. Po združitvi proizvodnih in okoljskih podatkov ter omejitvi na skupno časovno območje je za končno modeliranje ostalo 193 uporabnih vzorcev.



Slika 6: Okoljski podatki za opazovano obdobje

2.2. Model za zaznavanje potrebe po korekciji recepta

Prvi problem je bil obravnavan kot binarna naloga, kjer je model napovedoval, ali je bila pri posamezni šarži potrebna korekcija ali ne. Za učenje so bili uporabljeni časovno usklajeni vzorci, razdeljeni na učno in testno množico v razmerju 80/20. Pri tem je bila podatkovna množica izrazito neuravnotežena, saj so primeri brez korekcije predstavljali večinski razred, primeri s korekcijo pa manjšinski, vendar operativno pomemben razred.

Za klasifikacijsko nalogo je bilo uporabljenih 11 vhodnih značilk: devet numeričnih značilk, ki opisujejo odstopanja vhodnih materialov, ter dve okoljski značilki, temperatura in relativna vlažnost. Ciljna spremenljivka je določala, ali je bila po operatorski oceni potrebna korekcija recepture. Podatki so bili neuravnoteženi, saj je bilo 86.8% šarž označenih, da korekcije ne potrebujejo, 13.2 šarž pa kot šarže s potrebno korekcijo.

Med preizkušenimi klasifikacijskimi modeli se je kot najbolj uravnotežen izkazal model gradientnega boostinga, kot to prikazuje Tabela 1. Na testni množici je dosegel točnost 0,92, vrednost F1 0,73, AUC 0,71 in priklic 0,67. To pomeni, da je model pravilno prepoznal štiri od šestih primerov, kjer je bila korekcija dejansko potrebna, pri čemer je napačno označil le en primer brez korekcije kot korekcijski. V primerjavi z drugimi modeli je gradientni boosting najbolje uravnotežil zaznavanje redkih korekcijskih primerov in ohranjanje nizkega števila napačnih alarmov.


Tabela 1: Rezultati klasifikacije na testni množici

Model	Točnost	F1-mera	Površina pod krivuljo AUC	Priklic / občutljivost
Logistic (reg.)	0.8421	0.0000	0.5104	0.0000
Decision Tree	0.6842	0.0000	0.4688	0.0000
Gradient Boost	0.9211	0.7273	0.7135	0.6667
GLM (logit)	0.7895	0.2000	0.6250	0.1667
SVM linear	0.8421	0.0000	0.5260	0.0000
SVM RBF	0.8421	0.0000	0.7708	0.0000
KNN	0.8684	0.2857	0.8828	0.1667

Model KNN je dosegel najvišjo vrednost AUC, vendar je zaznal le enega od šestih korekcijskih primerov, zato je imel nizek priklic in nižjo vrednost F1. Podobno je model SVM z RBF jedrom dosegel razmeroma visoko vrednost AUC, vendar pri izbranem odločitvenem pragu ni napovedal nobenega pozitivnega primera. To kaže, da sama točnost ali AUC nista zadostna kazalnika uspešnosti pri neuravnoteženih podatkih, saj lahko model doseže navidezno dobre rezultate predvsem z napovedovanjem večinskega razreda.

Rezultati torej potrjujejo, da je uporaba mer, kot so F1, priklic in analiza napačno razvrščenih primerov, ključna pri klasifikaciji potrebe po korekciji. Visoka točnost nekaterih modelov je lahko zavajajoča, ker modeli pravilno razvrstijo predvsem primere brez korekcije, hkrati pa spregledajo korekcijske primere. Ker so prav ti primeri za podporo operaterju najpomembnejši, je gradientni boosting v tej fazi najprimernejši kandidat za nadaljnji razvoj. Pri tem pa je potrebno poudariti, da tudi korekcija operaterjev ni vedno konsistentna in ne zasleduje enakih meril, saj le-ti se nekoliko spreminjajo glede na operaterja in njegovo presojo.

Vizualizacija podatkov s PCA projekcijo, kot to prikazuje Slika 7, dodatno kaže, da korekcijski primeri niso popolnoma ločeni od primerov brez korekcije. Del manjšinskega razreda je mogoče zaznati z nelinearnimi modeli, vendar omejeno število pozitivnih primerov in prekrivanje razredov še vedno povzročata napačne negativne napovedi. Rezultati zato predstavljajo obetavno osnovo za razvoj sistema za podporo odločanju, vendar modelov v trenutni obliki še ni mogoče obravnavati kot zanesljiv mehanizem za samodejno korekcijo recepture.



Slika 7: Vizualizacija podatkov s PCA projekcijo in prikaz klasifikacijskih napovedi (Gradient Boost) na testnih podatkih

2.3. Model za oceno potrebne korekcije recepta

Regresijski del modeliranja je bil namenjen napovedovanju velikosti operaterske korekcije, izražene kot sprememba deleža dodanega vlažilnega sredstva pri posamezni proizvodni šarži. Za to nalogo je bila uporabljena

ista časovno usklajena podatkovna množica s 193 vzorci, pri čemer je bilo 155 vzorcev uporabljenih za učenje in 38 za testiranje. Vhodni podatki so vključevali odstopanja sestave zmesi, trenutne okoljske pogoje ter zakasnjene vrednosti temperature in relativne vlažnosti za predhodnih pet dni.


Za regresijsko nalogo je bila ciljna spremenljivka velikost potrebne korekcije, izražena kot količina oziroma delež dodanega vlažilnega sredstva po operaterjevi ročni oceni zmesi. Pri tej nalogi je bilo uporabljenih 20 vhodnih značilk, poleg trenutnih procesnih in okoljskih podatkov tudi zakasnjene okoljske značilke, ki vključujejo povprečne vrednosti temperature in relativne vlažnosti za predhodnih pet dni. S tem je bil v model vključen tudi vpliv predhodnih okoljskih pogojev na lastnosti pripravljene zmesi.

Preizkušeni so bili štiri regresijski modeli: linearni ridge model, odločitveno drevo, gradientni boosting in SVM z RBF jedrom. Najboljše rezultate je dosegel model gradientnega boostinga oziroma LSBoost (Slika 8), ki je imel najnižji vrednosti RMSE in MAE ter najvišjo vrednost koeficienta R^2 . Doseženi rezultati so bili $RMSE = 0,2291$, $MAE = 0,1148$ in $R^2 = 0,410$. To pomeni, da je model v primerjavi z ostalimi pristopi najboljše sledil zabeleženim operaterskim korekcijam.

Drugi najboljši rezultat je dosegel model SVM z RBF jedrom, medtem ko sta bila odločitveno drevo in predvsem linearni model manj uspešna. Slabši rezultat linearnega modela kaže, da povezava med vhodnimi procesnimi in okoljskimi spremenljivkami ter velikostjo korekcije ni izrazito linearna. To potrjuje smiselnost uporabe nelinearnih metod, kot sta gradientni boosting in SVM.

Kljub temu so vrednosti R^2 zmerne, kar kaže, da razpoložljivi podatki pojasnijo le del variabilnosti operaterskih korekcij. Velikost korekcije je namreč odvisna tudi od dejavnikov, ki v trenutni podatkovni zbirki niso v celoti zajeti, na primer lastnosti surovin, njihove predhodne izpostavljenosti okoljskim pogojem, posebnosti posamezne šarže ter subjektivne operaterske ocene zmesi. Zato regresijski model v trenutni obliki predstavlja predvsem podporno informacijo za operaterja in ne popolnoma zanesljivega mehanizma za samodejno določanje korekcije.


Rezultati vseeno kažejo, da je iz zgodovinskih proizvodnih podatkov mogoče pridobiti uporabne informacije o velikosti operaterskih posegov. Najboljši model lahko služi kot začetna osnova za sistem za podporo odločanju, ki bi operaterju predlagal okvirno velikost korekcije, končna odločitev pa bi ostala v domeni operaterja.



Slika 8: Validacija najbolj uspešnih modelov za napoved korekcije recepta (dodatek ovlažila)

2.4. Sprotno zbiranje in dostop do relevantnih proizvodnih podatkov

V fazi analize procesa izdelave brusov z metodami strojnega učenja se je pokazalo, da sta za kvaliteto zmesi ključna vplivna faktorja temperatura in vlaga v prostoru, kjer se zmes pripravlja in kjer se oblikujejo in stiskajo brusi. Meritve temperature in vlage zajema digitalna senzorika in jih hrani bazi časovnih vrst, izvedene informacije (max, min, drseče povprečje ...) pa so shranjene v relacijski podatkovni bazi aplikacije MePIS Energy v izbranem podjetju (Slika 9).



Slika 9: Koncept rešitve »Priprave zmesi«


Zgodovinske podatke o izdelavi delovnih nalogov, ki smo jih predhodno uporabili pri izdelavi modela procesa, smo črpali iz relacijske podatkovne baze ERP sistema. Zapis delovnega naloga vsebuje ključne informacije o

receptu priprave zmesi, korekcijah recepta, ki jih je naredil tehnolog in o končni kvaliteti izdelka izvedeni po sušenju. Informacije delovnih nalogov smo uporabili v fazi priprave modela procesa.

Podatkovna vira senzorike in delovnih nalogov smo integrirali v platformo MePIS, kjer je konfigurirano procesiranje podatkov (čiščenje, agregacija, transformacije ...). Tako pripravljeni podatki so na voljo za razvoj modela procesa in za produkcijsko uporabo modela.

7 Implementacija v produkcijsko okolje

Rešitev deluje v okolju MS Windows, kar je zahteva industrijskega partnerja. Elementi rešitve, tj. poslovni sistemi ERP/MES/MePIS Energy, modul »Receptura zmesi in korekcije« in AI model »Priprava zmesi« so integrirani s podatkovnim vmesnikom z REST tehnologijo. Centralna točka integracije je Metronikov Universal Data Gateway (UDG).



Slika 10: Arhitektura rešitve

Algoritmi napovednih modelov so bili razviti v programskem okolju MATLAB. Za potrebe implementacije v industrijskem okolju je bila pripravljena MATLAB Runtime aplikacija. Pri tem so bile napovedne funkcije pripravljene za samostojno izvršljivo obliko, ki za delovanje ne zahteva nameščenega celotnega MATLAB razvojnega okolja, temveč le ustrezno različico MATLAB Runtime knjižnice. V postopek priprave aplikacije so bile vključene vse potrebne programske knjižnice, pomožne funkcije, konfiguracijske datoteke in podatkovne strukture, ki so potrebne za pravilno izvajanje napovednih algoritmov.

Za potrebe komunikacije z uporabniškim vmesnikom in drugimi deležniki v sistemu je bil izbran programski vmesnik REST API, ki omogoča enostavnejšo integracijo. Okoli MATLAB Runtime aplikacije je bil v programskem okolju Python razvit ovojni programski sloj, ki implementira zunanji vmesnik za klic MATLAB napovednih funkcij. Ta sloj skrbi za sprejem vhodnih podatkov, posredovanje podatkov napovednim algoritmom ter vračanje rezultatov v standardizirani obliki.

Pripravljena implementacija algoritmov je bila nameščena v okolje Microsoft IIS Web Service, kar omogoča dostop do napovednih modelov prek spletnih storitev ter njihovo uporabo v industrijskem proizvodnem okolju.

2.5. Razvoj uporabniškega vmesnika

Cilj uporabniškega vmesnika je omogočiti tehnologu enostaven pregled nad recepturo za izdelavo zmesi in oceno kvalitete te zmesi pri danih pogojih proizvodnje (temperatura in vlaga v proizvodni hali). Pri tem rešitev trenutno deluje za eno izbrano recepturo, ki je bila predmet projekta.

V sodelovanju s tehnologijo proizvodnje smo uporabniški vmesnik zasnovali tako, da sledi procesni logiki tehnologa:

- izbor recepture zmesi,
- glede na izkušnje so odloči za dejansko recepturo v konkretnih pogojih,
- vnos podatkov o predlagani recepturi in ovrednotenje modela za oceno kvalitete zmesi,
- sprejem odločitve o končni recepturi in priprava zmesi.


Ta procesna logika se odraža tudi v izvedeni uporabniški izkušnji, kot to predstavljajo sledeče slike. Po izbiri recepture uporabnik vnese željeno količino zmesi in aplikacija preračuna potrebna količine surovin (srednji stolpec na sliki). Uporabnik nato vnese dejanske količine surovin, ki jih bo uporabil za zmes, izbere mešalnico na kateri bo delal in izbere akcijo "Ovrednoti šaržo". S tem sproži procesiranje razvitega modela, ki oceni kvaliteto šarže in pove, katere surovine je potrebno prilagoditi in za koliko (količinsko). Uporabniški vmesnik je bil preizkušen v praksi in prilagojen zahtevam tehnologov.




Slika 11: Prikaz osnovnega okna uporabniškega vmesnika za korekcijo recepture – izbor ustreznega recepta



Slika 12: Prikaz osnovnega okna uporabniškega vmesnika za korekcijo recepture - zbiranje dejanskih podatkov o šarži mase za bruse, ki je trenutno v pripravi (zamegljeno zaradi zaščite podatkov)



Slika 13: Pregled priporočila o korekciji recepta za 1. primer (zamegljeno zaradi zaščite podatkov)



Slika 14: Pregled priporočila o korekciji recepta za 2. primer (zamegljeno zaradi zaščite podatkov)

2.6. Integracija v okolje MePiS

Celotna rešitev je integrirana v produkcijsko digitalno okolje MePiS, ki deluje na infrastrukturi industrijskega partnerja. Senzorika je preko vodil in odjemalcev povezana z bazo časovnih vrst (*time-series DB*), od tam pa se podatki zajemajo v platformo MePiS. Informacija o recepturah je bila v MePiS prenesena enkratno. Jedro rešitve je AI/ML model procesa, ki deluje v kontejnerju na infrastrukturi industrijskega partnerja in je z API povezan v MePiS platformo. Celotna integrirana rešitev tako deluje v okolju industrijskega partnerja.

Izvedeni so bili funkcionalni in sistemski testi s katerimi smo preverili kvaliteto in zanesljivost delovanja integrirane rešitve.

Bibliografija

- [1] M. Glavan, D. Gradišar, B. Pregelj, G. Andonovski, A. Zdešar, Rezultat D4.4: Procesni model za raziskave zajemanja veščin operaterjev, Digitop, jul 2024.
- [2] M. Glavan, D. Gradišar, G. Mlinarič, R. Prešeren, Rezultat D4.6: Algoritem za zajem veščin operaterjev, Digitop, jul 2025.
- [3] M. Glavan, D. Gradišar, G. Mlinarič, G. Andonovski, R. Prešeren, Rezultat D8.2: Izvedba in testiranje zajemanja veščin operaterja, julij 2025.
- [4] S. Goldrick, C. A. Duran-Villalobos, K. Jankauskas, D. Lovett, S. S. Farid, B. Lennox, Modern day monitoring and control challenges outlined on an industrial-scale benchmark fermentation process, Computers & Chemical Engineering, Volume 130, 2019, <https://doi.org/10.1016/j.compchemeng.2019.05.037>.
- [5] IJS GitLab, Repozitorij IJS-E2, Zajemanje veščin operaterjev z uporabo priporočilnih sistemov, <https://repo.ijs.si/digitop-operater/msc-indpensim/-/tree/a0a3e316f4580c237725a6005eab6bff5c2ca27c/do>, (dostop možen na zahtevo)
- [6] G. MLINARIČ, Sistemi za podporo odločanju pri optimizaciji proizvodnje penicilina : magistrsko delo. Ljubljana: 2025. [COBISS.SI-ID [251233027](#)]