

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat D8.2:

Izvedba in testiranje zajemanja veščin operaterja

Projekt/RRP	DIGITOP/RRP 8 - Aktivnost 8.4 Zajemanje spretnosti operaterja
Vrsta dokumenta	Poročilo o rezultatu D8.2
Verzija dokumenta	v1
Sodelujoči partnerji	IJS-E2, ULFE-LAK, METRONIK
Avtorji	Miha Glavan, Dejan Gradišar, Gregor Mlinarič, Goran Andonovski, Rok Prešeren
Datum priprave	31. 07. 2025

Kazalo

1	UVOD	3
2	DEMONSTRATOR ŠARŽNEGA PROCESA PROIZVODNJE PENICILINA	3
2.1	PREDSTAVITEV PROCESA	3
2.2	PROIZVODNI PODATKI	5
2.3	ZAJEM VEŠČIN OPERATERJEV INDUSTRIJSKE PROIZVODNJE PENICILINA	6
2.3.1	OPTIMIZACIJA NA OSNOVI NADOMESTNEGA MODELA PROIZVODNE UČINKOVITOSTI	6
2.3.2	GNN PRIPOROČILNI SISTEMI	6
2.4	VALIDACIJA UČINKOVITOSTI RAZVITIH PODPORNIH ODLOČITVENIH SISTEMOV	9
3	DEMONSTRATOR PROCESA PRIPRAVE BRUSNIH ZMESI	11
3.1	PREDSTAVITEV PROIZVODNEGA PROCESA	ERROR! BOOKMARK NOT DEFINED.
3.2	LASTNOSTI PODATKOV IZ PROIZVODNO-INFORMACIJSKEGA SISTEMA	ERROR! BOOKMARK NOT DEFINED.
	BIBLIOGRAFIJA	13

1 Uvod

Za področje zajemanja veščin operaterja sta bila v programu DIGITOP izbrana dva različna demonstratorja: (i) proces proizvodnje penicilina in (ii) proces za pripravo zmesi za bruse.

Prvi demonstracijski proces se nanaša na šaržni proizvodni proces industrijske proizvodnje penicilina (simulacija procesa). Ena proizvodna šarža poteka okoli 10 dni in se izvaja v velikih bioreaktorjih, kjer vsako odstopanje in neustrezno upravljanje procesa s strani tehnologa lahko povzroči velike finančne izgube. Vodenje procesa poteka po vnaprej definiranih recepturah, ki definirajo prilagajanje manipulativnih procesnih spremenljivk tekom celotnega proizvodnega obdobja. Kljub enakim pogojem in sledenju recepturi procesa je lahko končni izplen zelo raznolik. Zato je pomembno, da operaterji sledijo dogajanju v proizvodnem procesu in ustrezno reagirajo na zaznane deviacije v procesu. Za izvedbo demonstratorja zajema veščin operaterjev je bil uporabljen simulacijski proizvodni proces, ki je bil pripravljen v RDp4 in tudi že predstavljen v D4.4.

Drug izbran demonstracijski proces se prav tako nanaša na šaržni proizvodni proces in sicer proces priprave mase za pripravo industrijskih brusov. Proizvodni proces poteka v slovenskem proizvodnem podjetju. Za vsakega izmed izdelkov imajo v podjetju razvite podrobne recepte za pripravo mase brusov. Kljub skrbnemu sledenju in izvajanju posamezne recepture ter procesnemu nadzoru operacij, v podjetju zaznavajo odstopanja v kvaliteti pripravljene zmesi. Te variacije so dovolj velike, da lahko vodijo do neustrezne kvalitete končnih izdelkov. Kot v primeru prvega procesa je tudi tukaj pomembno operatorsko znanje, da se že predhodno kompenzira morebitne nepravilnosti in pripravo ustrezne zmesi že v začetnih fazah, s čimer se izognejo naknadnim korekcijam in zmanjšajo tveganja za neustrezno kvaliteto izdelkov.

V 2. poglavju tega poročila je predstavljen vzpostavljen simulacijski demonstrator šaržnega procesa proizvodnje penicilina in prvi rezultati razvoja algoritmov za zajem veščin operaterjev na tem procesu. V 3. poglavju pa je predstavljen dejanski industrijski proizvodni proces priprave mase za bruse ter pregled razpoložljivih proizvodnih podatkov iz proizvodno-informacijskega sistema.

2 Demonstrator šaržnega procesa proizvodnje penicilina

2.1 Predstavitev procesa

Za prvi demonstracijski proces je bil izbran simulacijski model industrijskega bioreaktorja za proizvodnjo penicilina. Simulacijsko okolje proizvodnega procesa je bilo že podrobneje predstavljeno v [1].

Atribute simuliranega procesa lahko razdelimo na sledeče skupine:


- Spremenljivke stanja (35 spremenljivk) opisujejo simulirane meritve med potekom proizvodnega procesa ob času t . Primera teh spremenljivk sta pretok hladilne tekočine F_c ali hitrost sproščanja ogljika (CER). Predstavimo jih z vektorjem S_t .
- Manipulativne spremenljivke (11 spremenljivk) so tiste, na katere lahko operater neposredno vpliva z namenom povečanja mase proizvedenega penicilina. Za poenostavitev problema smo se osredotočili le na podmnožico šestih spremenljivk, ki so se izkazale kot najbolj vplivne. Le-te so temperatura (T), hitrost

dovajanja sladur (F_s), pretok fenilacetne kisline (F_{PAA}), pretok olja (F_{oil}), pretok zraka (F_g) in pretok vode (F_w). Ob času t so bile te spremenljivke predstavljene z vektorjem A_t .

- Ciljni spremenljivki $Y_{increase,t}$ in $Y_{total,t}$ opisujeta spremembo v količini proizvedenega penicilina med potekom eksperimenta. $Y_{increase,t}$ pove, za koliko se je povečala masa od prejšnjega časovnega koraka, medtem ko $Y_{total,t}$ predstavlja skupno proizvedeno maso ob času t . Spremenljivko $Y_{total,final}$ definiramo kot končni izplen penicilina na koncu eksperimenta.

V industrijski praksi se proces tipično usmerja na podlagi vnaprej definiranih receptov, ki temeljijo na preteklih izkušnjah operaterjev in določajo vrednosti manipulativnih spremenljivk. Vloga operaterjev je spremljanje trenutnega stanja procesa in po potrebi korekcija recepta. Kot prikazuje Slika 1 lahko proces ob uporabi istega recepta dosega zelo raznolike rezultate, kar poudarja pomen sprotnega nadzora in adaptacije manipulativnih spremenljivk.

Cilj je zajeti znanje operaterjev iz zgodovinskih podatkov s čimer bi bili sposobni predlagati ustrezne manipulativne akcije, s katerimi bi bilo mogoče v procesu industrijske proizvodnje penicilina (simulacijski model procesa) povečati končni izplen penicilina ($Y_{total,final}$).



Slika 1: Porazdelitev končne mase produkta na 1000 različnih eksperimentih

V okviru eksperimenta smo predpostavili, da lahko operater izvaja akcije opisane z A_t ob vnaprej določenih časovnih točkah, kot je prikazano na Slika 2.



Slika 2: Shema prikazuje, kdaj operater vpliva na manipulativne spremenljivke opisane z A_t . Ob času $t \in \{96, 120, 144, 168, 192, 216\}$ operater izvede akcijo A_t na podlagi trenutnega stanja opisanega s S_t .

2.2 Proizvodni podatki

Za ta demonstracijski proces je osnova simulacijski proces IndPenSim, zato nimamo na razpolago dejanskega operatorskega znanja. Da pa bi vseeno pridobili primere dobrih praks, smo izvedli serijo simulacij, s katerimi smo pridobili vpogled v karakteristike procesa in s tem emulirali odločitve operaterjev. Učna množica za zajem znanja operaterjev je bila generirana preko API vmesnika procesa, opisanega v [1]. Podatki so bili pridobljeni s tremi različnimi pristopi:

- **Predefinirani recepti:** izvedenih je bilo 3200 eksperimentov, pri katerih operater ni izvajal nobenih prilagojenih akcij, temveč je uporabil vnaprej določen recept.
- **Monte Carlo simulacija z naključnimi akcijami:** izvedenih je bilo 1600 eksperimentov, pri katerih je operater v vsakem odločitvenem trenutku naključno izvedel eno iz nabora dovoljenih akcij.
- **Pohlepna optimizacija:** izvedenih je bilo 1600 eksperimentov, pri katerih je operater v vsakem koraku izbral najboljšo iz nabora možnih akcij (t. j. tisto, ki je najbolj povečala izplen penicilina v naslednjem koraku).

Nabor možnih akcij je bil definiran na naslednji način: operater je lahko ob vnaprej določenih časovnih trenutkih aktivno vplival le na manjšo podmnožico manipulativnih spremenljivk A_t . V večini primerov je šlo le za eno spremenljivko, v manjšem deležu pa za dve spremenljivki hkrati. Preostale manipulativne spremenljivke so sledile vrednostim iz recepta.

Nabor izbranih spremenljivk se med potekom posameznega eksperimenta ni spreminjal, medtem ko se je nabor možnih akcij prilagajal glede na prejšnjo izvedeno akcijo. V vsakem odločitvenem trenutku ob času t je bila operaterju na razpolago množica petih možnih vrednosti za izbrano spremenljivko $a_i \in A_t$: $\{m - 2k, m - k, m, m + k, m + 2k\}$, kjer je vrednost m spremenljivke a_i iz prejšnjega koraka in k velikost koraka (diskretna vrednost različna za vsako spremenljivko a_i).

V primeru hkratne manipulacije dveh spremenljivk, so bile izbire med seboj neodvisne, zato je imel operater na voljo 25 (5x5) možnih kombinacij. Eksperimenti so bili nadalje razdeljeni v dve podskupini glede na čas začetka vplivanja: v eni skupini je operater začel vplivati na manipulativne spremenljivke že od začetka simulacije ($t = 0h$), v drugi pa šel po natanko pretečenem času ($t = 96$). Za namen primerjave so bili vsi eksperimenti, z uporabo istih naključnih semen, ponovljeni tudi tako, da so v celoti sledili osnovnemu receptu proizvodnje brez operatorjevih posegov (R). Tabela 1 prikazuje statistične lastnosti učne množice 6400 eksperimentov.

Tabela 1: Statistični povzetek učinkovitosti simulacijskih potekov glede na metodo generiranja znanja operaterjev

Metoda	Št. eksperimentov	Povprečje [kg]	Mediana [kg]	Std. Odklon [kg]	Min [kg]	Max [kg]
MC	1600	2403	2541	1252	0	4715
GGW	1600	3309	3548	652	1474	4900
R	3200	3050	3390	654	1127	4207
Skupaj	6400	2953	3386	908	0	4900

2.3 Zajem veščin operaterjev industrijske proizvodnje penicilina

Operaterji proizvodnje se ob diskretnih dogodkih odločajo glede sprejemanja odločitev za korekcijo manipulativnih spremenljivk procesa A_t (glej Slika 2). Za zajem veščin operaterja, ki bi lahko pomagal pri dejanskem odločanju operaterjev, smo razvili dva različna podporno odločitvena sistema:

- Optimizacija na osnovi nadomestnega modela proizvodne učinkovitosti in
- GNN priporočilni sistemi.

2.3.1 Optimizacija na osnovi nadomestnega modela proizvodne učinkovitosti

Prvi uporabljen pristop je bil razvoj podporno-odločitvenega sistema, kjer na podlagi optimizacije nadomestnega modela proizvodne učinkovitosti priporočamo akcije A_t na podlagi dveh komponent: (i) napovednega modela proizvodne učinkovitosti (M_t) na podlagi trenutnega stanja proizvodnje (S_t) in nastavljenih manipulativnih spremenljivk (A_t), ter (ii) optimizacijske metode za določitev optimalne odločitvene akcije (A_t).


Za razvoj napovednega modela proizvodnje penicilina sta bili uporabljeni dve metodi strojnega učenja, in sicer XGBoost (XGB) ter nevronskega modela MLP (MLP). Struktura modela je bila določena kot:

$$M_t(S_t, A_t) = Y_{increase, t+1}$$

Za iskanje potrebnih odločitev operaterja na podlagi napovednega modela smo testirali različne optimizacijske pristope. Uporabili smo sledeče metode: gradientni spust (GD), Adam optimizator, Bayesovska optimizacija (BAY), metoda CMA-ES in diferencialna evolucija (DE).

2.3.2 GNN priporočilni sistemi

Modeli iz družine GNN (ang. *Graph Neural Networks*) priporočilnih sistemov izkoriščajo grafovsko predstavitev podatkov za odkrivanje primernih manipulativnih akcij na novih eksperimentih. Ključna dejavnika za učinkovitost pristopa sta izbor primerne grafovske predstavitve podatkov in ustrezne arhitekture modela. Več o tem pristopu je bilo predstavljeno v [2]. Za zajem znanja procesa proizvodnje penicilina sta bila razviti dve poddružini GNN modelov: HETv1 in HETv2, ki sta imeli osnovno strukturo modela podobno, kot je to prikazano na Slika 3.



Slika 3: Struktura GNN modela za razvoj priporočilnega sistema procesa za proizvodnjo penicilina


HETv1: modeli so naučeni na grafih, katerih vozlišča $S_{i,t}$ vsebujejo kot atribut resnično spremembo mase penicilina $Y_{increase,t+1}$. Za napoved akcij na novih vozliščih $S_{new,t}$, kjer vrednost $Y_{increase,t+1}$ ni znana, vanjo vstavimo visoko vrednost (npr. 97. percentil vseh znanih vrednosti), s čimer usmerimo pozornost modela na pretekle obetavne eksperimente.

HETv2: modeli te poddružine niso imeli na razpolago vrednosti $Y_{increase,t+1}$. Namesto tega smo v vsakem koraku iz učne množice izločili delež primerov z najnižjo rastjo mase penicilina in ohranili le p odstotkov najboljših primerov (npr. HETv2- T80 pomeni, da smo ohranili zgornjih 80 % učnih primerov glede na vrednosti $Y_{increase,t+1}$).

Za optimizacijo strukture GNN modelov smo preiskali prostor hiperparametrov modelov. Skladno z metodologijo, predstavljeno v [3], je bilo izvedeno preiskovanje prostora možnih konfiguracij GNN modelov. S tem smo želeli poiskati najboljše arhitekture za napovedovanje uteži povezav. Naš prostor hiperparametrov je bil definiran s pomočjo naslednjih dimenzij:

- Aktivacijska funkcija $Act \in \{ReLU, LeakyReLU, PreReLU, Swish\}$
- Način agregacije $Agg \in \{max, mean, sum\}$
- Prag povezovanja $\epsilon \in \{0.2, 0.15, 0.1, 0.05, 0.0\}$
- Skrita dimenzija $HidDim \in \{32, 64, 128\}$
- Povezljivost med plastmi $LayConn \in \{skipcat, skipsum, \emptyset\}$
- Število plasti za prenos sporočil $MPL \in \{2, 3, 4\}$
- Število plasti predobdelave $PostPL \in \{0, 1, 2\}$
- Število plasti poobdelave $PrePL \in \{0, 1, 2\}$
- ϵ - stopnja povezanosti uporabniških vozlišč. Povezava med dvema vozliščema uporabnikov je vzpostavljena, če je razlika v rasti mase penicilina med njima manjša od praga ϵ (vrednosti so normalizirane).

Primer analize vplivnosti hiperparametrov za odločanje ob času $t=144\text{h}$ je predstavljen na Slika 4. Enaka analiza je bila narejena za vse točke odločanja. Na podlagi analize vplivnosti hiperparametrov smo za vsako časovno točko odločanja in vplivanja na proces identificirali optimalne konfiguracije modelov, ki so povzete v Tabela 2.



Slika 4: Analiza vplivnosti hiperparametrov GNN modela za določanje ob času 144 h

Tabela 2: Pregled izbranih hiperparametrov po izbranih časih odločanja vodenja proces

	96 h	120 h	144 h	168 h	192 h	216 h
Act	PreReLU	LeakyReLU	LeakyReLU	Swish	Swish	LeakyReLU
Agg	max	max	max	max	sum	max
ϵ	0.0	0.0	0.0	0.0	0.0	0.0
HidDim	128	64	128	64	64	64
LayConn	skipsum	skipsum	skipsum	skipsum	skipsum	Skipsum
MPL	2	2	2	2	2	2
PostPL	0	0	1	0	1	1
PrePL	0	0	0	0	0	0

2.4 Validacija učinkovitosti razvitih podpornih odločitvenih sistemov

Uspešnost posameznih pristopov za razvoj podporno-odločitvenih sistemov je bila ovrednotena na podlagi treh ključnih kriterijih:

1. **Stabilnost rezultatov:** ocenjena je bila na podlagi standardnega odklona končne mase penicilina na različnih eksperimentih.
2. **Povprečna izboljšava izplena:** izračunana je bila kot razlika med povprečnima končnima masama ob uporabi priporočil izbrane metode in pri uporabi recepta.
3. **Delež uspešnih eksperimentov:** delež testnih primerov, kjer je bil presežen prag 3100kg končnega izplena penicilina.

Tablea 3 prikazuje rezultate testnih eksperimentov uporab podpornih odločitvenih sistemov in njihovo validacijo na simulacijskem modelu procesa. Izkaže se, da je z uporabo predlaganih podporno-odločitvenih priporočil v skoraj vseh primerih mogoče doseči boljše rezultate, kakor če bi operater zgolj sledil akcijam iz vnaprej določenih receptov.

Tabela 3 Validacijska primerjava modelov z različnimi metrikami uspešnosti. Stolpec nad označuje, koliko eksperimentov je končalo nad predpisanim pragom 3100kg. Zadnji stolpec predstavlja število izboljšanih eksperimentov, če operater sledi priporočilom, kot pa če uporablja predpisan recept.


Model	Povp. [kg]	Std. dev. [kg]	Min [kg]	Max [kg]	# nad	# izboljšav
HETv1-97	3948	369	2329	4522	94	99
HETv2-T100	2797	661	1557	4733	20	30
HETv2-T95	3691	771	1556	4785	77	90
HETv2-T90	3917	262	2990	4508	99	100
HETv2-T85	3986	436	1417	4964	98	94
HETv2-T80	2577	518	1574	4109	14	14
MLP + Adam	3367	564	1599	4171	80	98
MLP + GD	4329	1005	1487	5361	85	91
MLP + CMA-ES	4560	540	1438	4435	73	84

XGB + CMA + ES	3316	621	1506	4150	74	77
MLP + DE	4180	904	1549	5228	87	91
XGB + DE	3783	803	1369	5090	87	83
MLP + BAY	3873	803	1469	5090	87	83
XGB + BAY	3259	1130	0	5140	59	63
Recepti	3007	650	1587	4044	47	/

Med predlaganimi rešitvami izstopata dva podporno odločitvena sistema, in sicer MLP + GD in GETv2-T90.

MLP + GD: ta kombinacija je med vsemi metodami dosegla najvišjo posamezno vrednost izplena, kot tudi najvišjo povprečno končno maso penicilina (stolpec Povp.). Kljub temu je slabost te metode, da ima najvišji standardni odklon, kar nakazuje na visoko variabilnost rezultatov med posameznimi eksperimenti. Pomembno je izpostaviti, da je bil v 9 % primerov končni izplen nižji, kot če bi namesto priporočil te metode uporabili kar osnovni recept, kar nakazuje na možnost slabših odločitev v posameznih situacijah.

HETv2-T90: ta GNN priporočilni sistem, ki je bil naučen na učni množici brez 10 % najslabših primerov, se je izkazal za nastabilnejšo rešitev z najnižjim standardnim odklonom. Glede na recept je model izboljšal končni izplen vseh 100 eksperimentov, za nameček so bile izboljšave konsistentno visoke. To nakazuje, da lahko s filtriranjem učne množice pozitivno vplivamo na robustnost in kvaliteto priporočil. Opisane ugotovitve podpira tudi Slika 5, od koder je razvidno, da je večina eksperimentov presegla prag 3100kg.




Slika 5: Primerjava porazdelitve proizvodnje penicilina z uporabo predhodno definiranega recepta (siva barva) in priporočil podporno-odločitvenega sistema HETv2-T90 (modra).

3 Demonstrator procesa priprave brusnih zmesi

Za drugi demonstracijski proces je Metronik, preko komunikacije s svojimi strankami, identificiral primeren proizvodni proces, kjer se srečujejo s sorodno problematiko, kakor jo naslavlja program DIGITOP na področju zajema večšin operaterjev. Izbran demonstracijski proizvodni proces predstavlja dejanski proizvodni proces izdelave industrijskih brusov pri industrijskemu partnerju, ki ni del konzorcija.

Izdelava brusov poteka šaržno glede na naročila. V prvi fazi se pripravijo brusni elementi in njihova veziva, iz njih pa nato izdelajo zmesi za bruse. Pripravljene zmesi se v kalupih oblikujejo v ustrezno obliko in na preši stisnejo, čemur sledi še sušenje izdelkov. Prva faza operacij do sušenja, skupaj s povezanimi proizvodnimi aktivnostmi, je predstavljena na Slika 6.



Slika 6: Začetna faza izdelave brusov in povezane proizvodne operacije

V nadaljevanju izdelave brusov sledi termična obdelava. Pred termično obdelavo poteka še dodatna faza delnega oblikovanja, ki ji sledi žganje izdelkov v plinski peči. Temu sledi še kontrola izdelkov, končna obdelava oblike ter končna kontrola kakovosti. Slika 7 prikazuje končne korake, potrebne za izdelavo brusov.



Slika 7: Druga faza izdelave brusov in prikaz povezanih proizvodnih operacij

Pomen znanja operaterjev in tehnologov je ključna predvsem v začetnem koraku priprave zmesi. Izkaže se, da kljub jasnim recepturam, dobro odmerjenim in popisanim količinam, prihaja do deviacij v kakovosti pripravljenih zmesi. Kot kaže dodatni zunanji pogoji (poleg sestavin in njihovih količin) pomembno vplivajo na ustreznost pripravljene zmesi. Fiksni recepti, ki se določajo preko dobro definiranega algoritma, tako ne dajo vedno

zadovoljivih in konsistentnih rezultatov. Posledično so pogosto potrebne korekcije s strani operaterjev, ki recept prilagodijo, da dosežejo želene lastnosti zmesi, ki je primerna za nadaljnjo oblikovanje.

Pri tem je zelo pomembno in zahtevno pridobiti znanje operaterjev, ki iz izkušenj razpoznajo, kdaj je pripravljena zmes ustrezna. Pri tem se operaterji ne zanašajo zgolj na recepturo zmesi, temveč po lastni presoji in z manualnim pregledom zmesi le-to ustrezno korigirajo.

Na podlagi domenskega znanja smo v prvi fazi identificirali ključne vplive na kakovost izdelkov, ki bi lahko pomembno prispevali k potrebam za spremembo izdelovalnega recepta zmesi brusov. Ključni identificirani zunanji parametri, ki potencialno vplivajo na lastnosti zmesi so:

- *Lastnosti vhodnih surovin*
 - Vlažnost komponent za zmesi
 - Gostota tekočih komponent
 - Oblika zrn
 - Velikost delcev / prašnost
- *Okoljski pogoji*
 - Vlažnost v prostoru
 - Temperatura v prostoru
- *Operacije proizvodnega procesa*
 - Uporabljen tip mešalnika ter količina mešane zmesi
 - Zaporedje doziranja komponent
 - Količina posamezne komponente v zmesi
 - Čas mešanja
 - Kvantitativni indikator kakovosti izdelkov

Pri tem je potrebno izpostaviti dejstvo, da ne obstaja zanesljiv objektiven sistem za kvantitativno merjenje kvalitete zmesi, tj. ustreznosti končnih lastnosti zmesi. Presoja je tako predana operaterjem, da na podlagi lastnih izkušenj ob mehanskem pregledu zmesi odločijo ali je kvaliteta ustrezna ali ne. Izkušnje jih tudi usmerjajo kako popraviti neustrezno zmes. Pri naši analizi procesa se moramo tako zanašati na subjektivno odločanje operaterja in predpostaviti, da vsaka korekcija recepta, ki jo naredi operater, predstavlja popravek neke (neidentificirane) nezadovoljive lastnosti zmesi. Predpostavki našega pristopa sta torej dve:

1. »Izkušnje operaterja« so skozi leta akumulirano izkustveno znanje, ki ga (še) ne znamo kvantificirati z analitičnimi metodami in postopki
2. Vsaka akcija izkušenega operaterja izboljšuje kvaliteto zmesi

V naslednjem koraku smo izvedli pregled proizvodno-informacijskega sistema in pregled razpoložljivih podatkov. Ključni pogoji pri identifikaciji ustreznih podatkov so bili sledljivost posameznih operacij in povezanih podatkov na ustrezno šaržo zmesi ter ključni zunanji vplivi, ki bi lahko imeli pomembno vlogo pri spremembi lastnosti zmesi. Dodatni pogoj za analizo je bila tudi zadostna podatkovna zgodovina na podlagi katere bi lahko sklepali na relacije med proizvodnimi spremenljivkami.

Na podlagi podanih zahtev je sodelujoče podjetje skupaj s podjetjem Metronik izbralo skupino sorodnih izdelkov, za katere je mogoče dobiti najbolj širok nabor zgodovinskih podatkov, kjer se je iz več relacijskih podatkovnih

baz pripravil izvoz ustreznih podatkovnih tabel. Izkazalo se je, da informacije o korekciji receptov niso bile popolnoma digitalizirane. Sodelujoče industrijsko podjetje je tako izvedlo ročni popis predajnic, kjer so tehnologi popisali vse deviacije od receptov v fazi priprave zmesi. Za izbran izdelek brusov so bili izvoženi podatki za obdobje dveh let, pri čemer imamo na razpolago okoli 150 različnih primerov šarž. Pri analizi podatkovno-informacijskih sistemov se je tudi izkazalo, da določene operacije nimajo popolne sledljivosti na šaržo zmesi (npr. vhodne meritve kakovosti surovin/zrn), zato so bile takšne informacije izvzete iz nadaljnjih analiz.

Izvoženi in urejeni podatki iz proizvodnega informacijskega sistema predstavljajo osnovo za drugi demonstracijski proces. Zaradi zaupnosti informacij pa smo v tem dokumentu opustili podrobnejši pregled zbranih in urejenih podatkov. Tekoče aktivnosti na tem demonstracijskem procesu tečejo v smeri identifikacije vplivnosti posameznih zunanjih vplivnih parametrov proizvodnega procesa z uporabo enostavnih metod za oceno kavzalnosti med procesnimi podatki ter razvojem poenostavljenih napovednih modelov. Zaradi omejenega nabora razpoložljivih primerov iz zgodovinskih podatkov podrobnejša analiza z bolj kompleksnimi metodami, kot so bile uporabljene v prvem demonstracijskem procesu, zaenkrat žal ni mogoča.

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] J. You, Z. Ying, and J. Leskovec, “Design space for graph neural networks,” Advances in Neural Information Processing Systems, vol. 33, pp. 17009–17021, 2020.