

Merjenje učinka uporabe strojnega učenja pri mikroplaniranju proizvodnje

Matjaž Roblek,¹ Vukašin Radisevljević,² Alenka Brezavšček²

¹ Domel d.o.o., Železniki, Slovenija
matjaz.roblek@domel.com

² Univerza v Mariboru, Fakulteta za organizacijske vede, Kranj, Slovenija
vukas.in.radisevljevi@student.um.si, alenka.brezavscek@um.si

Tekom izvajanja širše raziskave o uporabi strojnega učenja (ang. machine learning - ML) v procesu mikroplaniranja proizvodnje, ki jo štiri leta izvajamo v realnem okolju podjetja Domel, smo odkrili težave z merjenjem točnosti napovedovanja trajanja proizvodnih nalogov (v nadaljevanju PN). Napovedovanje trajanja PN razbremeni planerje in mojstre v proizvodnji ročnega usklajevanja, ko proizvodnja ni sposobna dosegati želenih normativov tehnološkega postopka, ali so prisotne težave z nezanesljivostjo proizvodnega procesa. Ugotovili smo, da v fazi uvajanja novega izdelka v proizvodnjo ML izboljšuje svoje napovedi. Ko smo longitudinalno povečevali število ponovitev PN za enake izdelke, so na meritve začeli vplivati dejavniki nezanesljive proizvodnje in slabšali napovedi trajanja PN. V prispevku prikazujemo uporabljen metodo za čiščenje podatkov, na podlagi katere smo lahko na izbranem vzorcu izdelkov dokazali, da zaradi nestabilnosti proizvodnega procesa in pomanjkanja zanesljivih podatkov ne moremo trditi, da ML napoveduje trajanje PN bolje od človeka (niti slabše). Predstavljamo izzive pri statističnem dokazovanju te trditve.

Ključne besede:

strojno učenje
mikroplaniranje proizvodnje
merjenje
nezanesljivost proizvodnje
nezanesljivi podatki

1 Uvod

Z razvojem tehnologij *strojnega učenja in globokega učenja* (v nadaljevanju ML) se povečuje število praktičnih uporab v poslovnih procesih [1-3]. V prispevku se osredotočamo na področje planiranja v proizvodnih podjetjih, natančneje na uporabo ML v procesu *mikroplaniranja proizvodnje* (ang. production scheduling). Ta proces z vidika razvrstitve informacijskih sistemov podpirajo napredni sistemi za terminiranje in razvrščanje PN (ang. advanced production scheduling - APS), ki obogatijo poslovne informacijske sisteme z naprednimi algoritmi za optimizacijo razporedov PN v proizvodnji, s katerimi povečujemo izkoristek proizvodnih kapacitet. Z razvojem in vključenostjo tehnologije ML ti sistemi dodatno pomagajo razreševati problem razlik med želenim trajanjem PN po normativih in dejansko dosegljivim trajanjem. Velike razlike so značilne za serijsko proizvodnjo tehnološko zahtevnih izdelkov, kjer proizvodnja pri izdelavi določenega izdelka začneja z velikimi odstopanji od želenega in se z vsako ponovitvijo PN nekaj nauči bolje in tako približuje ciljnim normativom. Planiranje takega procesa je zahtevno, saj mora planer ob vsaki iteraciji oceniti izboljšavo, popraviti napoved trajanja PN na podlagi podatkov o dejanski realizaciji in rahlo »priganjati« proizvodnjo pri naslednji ponovitvi, da ima ta motiv za izboljševanje. Klasični APS tega ne zna, *napredni APS z AI* (ang. AI APS, tudi Smart APS) pa poskuša to ročno napovedovanje planerja in mojstra posnemati s ML in »robotizirati« planske aktivnosti v procesu mikroplaniranja (ang. RPA - Robotic Process Automation) [4].

Izsledki v literaturi [5,6] navajajo številne pozitivne učinke naprednih APS z AI, zaradi katerih se podjetja zanimajo za vpeljavo ML v svoje procese. Po drugi strani pa primanjkuje empiričnih študij, ki bi se osredotočale na merjenje konkretnih učinkov algoritmov ML pri napovedovanju trajanja PN, kar je osnovni kriterij pri ugotavljanju dodane vrednosti in ekonomske upravičenosti tovrstnih tehnologij. Z rezultati pričujoče raziskave smo skušali to raziskovalno vrzel vsaj delno zapolniti.

Raziskava predstavlja študijo primera, ki smo jo izvedli v realnem okolju na vzorcu proizvodnje izdelkov podjetja Domel [7], kjer pri mikroplaniranju proizvodnje uporabljajo AI APS rešitev LEAP slovenskega podjetja Qlector [8] in sicer na proizvodnih tehnologijah stiskanja in brizganja. LEAP se uporablja od začetka leta 2021 [9], kar zagotavlja dovolj dolgo časovno obdobje za zajem dovolj velikega vzorca podatkov za prve analize njenih učinkov.

Motiv za raziskavo je izhajal iz problema, da algoritmi ML potrebujejo določeno količino podatkov o ponovitvah PN enakega izdelka na postrojenjih, pri različnih pogojih, kot so določen stroj, čas izmene, dan v tednu, usposobljenost prisotnih delavcev ipd., da lahko zagotovijo bolj natančne, smiselne in uporabne napovedne informacije [10]. Predvidevali smo, da se točnost predvidevanja algoritmov AI APS za posamezni izdelek izboljšuje z naraščanjem števila ponovitev (iteracij) PN za dotični izdelek. Z analizo različnih testnih primerov smo ugotovili, da lahko naše predvidevanje potrdimo le deloma. Namreč, zaradi ne povsem predvidljivih razmer v proizvodnji in »posebnosti« procesa proizvodnje, kjer nastopa veliko različnih bolj ali manj naključnih/izrednih dogodkov se dogaja, da algoritmi ML generirajo veliko napako pri predvidevanju kljub temu, da so predhodno že dosegali kvalitetne napovedi trajanja dotičnega PN. V poglobljenih analizah želimo ugotoviti po kolikšnem času (t.j. po kolikšnem številu izvedenih iteracij PN za določen izdelek) lahko zaupamo, da so napovedi AI APS dovolj natančne in zanesljive, da lahko planer izračunavanje trajanja povsem prepusti avtomatiki z AI APS. Poleg tega želimo ugotoviti, kaj vse vpliva na to, kako hitro se sistem AI APS stabilizira, da ponovno dobro napoveduje, ter na kakšen način lahko v proizvodnji k temu pripomoremo.

Z izsledki raziskave podajamo konkretne izkušnje pri merjenju učinkov uporabe ML pri napovedovanju trajanja PN in izpostavljammo zanimive izjave, v katere bi se veljalo osredotočati v prihodnjih raziskavah. Rezultati so koristni in uporabni za podjetje, ki je v študiji primera sodelovalo, kakor tudi za ostala podjetja, ki se soočajo z izzivi uvajanja algoritmov ML v svoje proizvodne in poslovne procese.

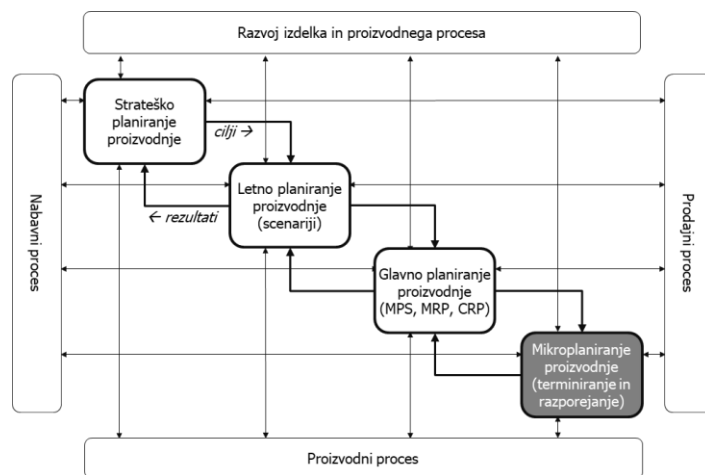
2 Metodologija

2.1. Opis proučevanega podjetja in proizvodnega okolja

Podjetje Domel je mednarodno podjetje, katerega glavna dejavnost je razvoj in proizvodnja komponent in aplikacij elektromotorjev. Sedež podjetja je v Sloveniji, proizvodne lokacije pa ima na Kitajskem in v Srbiji. Predmet proučevanja je proizvodnja na oddelku avtomatskih stiskalnic, kjer se izdelujejo deli iz elektro pločevine, ki se proizvajajo neposredno za kupce ali za nadaljnjo vgradnjo v kompleksne izdelke. Delavnica ima delavnično razporeditev vzporednih istovrstnih strojev. Oskrbuje se po principu ravno pravočasno z materialom elektro pločevino iz vhodnega skladišča. Elektro pločevina različnih tipov in dimenzij je pripravljena na embalažnih enotah, kolutih. Embalažne enote se izda iz skladišča in z viličarjem dostavi na stroj, kjer se izdelajo izdelki, rotorske in statorske lamele različnih dimenzij in oblik. Izdelki se polnijo v izhodne embalažne enote, zaboje, in se sproti odpremljajo z viličarji v izhodno skladišče. Od tam sledi transport h kupcem ali v druge proizvodne enote Domela. V proizvodnji se uporablja le tehnologija stiskanja. Delovno postajo v proizvodnji tvori stroj stiskalnica, orodje za določen izdelek ter robot ali človek za pakiranje izdelkov v izhodno embalažno enoto. Nekateri izdelki se lahko proizvajajo le na namenskem stroju, izdelave drugih pa se lahko razporeja na različne stroje z različno zmogljivostjo, vendar imajo določeno primarno verzijo stroja, ki je prioriteta pri razporejanju. Tehnološki postopek je enostaven, ima do dve zaporedni delovni operaciji, ki jih izvedemo s pomočjo orodja na stroju. Posebnost proizvodnje je sočasna proizvodnja različnih izdelkov z istim orodjem (zaradi boljšega izkoristka pločevine na stroju), ki se hkrati polnijo v različne embalažne enote za različne kupce.

V podjetju imajo vzpostavljene štiri hierarhično in časovno strukturirane procese planiranja proizvodnje (slika 1). Proučevano delavnico planira, terminira in razporeja le en planer proizvodnje, ki je prisoten le v dopoldanski izmeni. Raziskava obravnava najnižji in najbolj dinamičen proces mikroplaniranja proizvodnje, ki planerju predstavlja 90% dela. Ostalih 10% je obremenjen z izvajanjem glavnega planiranja. V ostalih dveh hierarhično višjih procesih planiranja proizvodnje planer ne sodeluje, dobiva pa iz teh procesov smernice in pravila ter zagotavlja zanj povratne informacije iz realizacije proizvodnje, le-te pa vstopajo v mikroplaniranje proizvodnje.

Celoten proizvodni proces je informacijsko podprt in generira podatke v realnem času. Proizvodnja večino leta poteka v treh izmenah, tudi preko vikendov. Proizvodnjo pripravljajo v poslovnem informacijskem sistemu ERP - SAP HANA, mikroplaniranje pa je podprto s spletno storitvijo AI APS LEAP. Realizacija proizvodnje, ki je pomembna za merjenje točnosti predvidevanj ML, se beleži ročno s potrditvami delavcev v proizvodnem informacijskem sistemu MES Kiner. V primeru izvedbe proizvodnega procesa z malo odstopanja od planskih vrednosti se večina podatkov o realizaciji PN prenaša v bazo podatkov avtomatsko s potrditvami delavca. V primeru variabilnosti, kot so zastoji, izmet ipd., pa se dodatne informacije o odmikih PN ročno izbira in poroča v MES. Organizacijski predpis določa, katere korekcije v IS sme določati delavec, kaj njegov izmenovodja in kaj vodja delavnice.



Slika 1: Shematični prikaz umeščenosti mikroplaniranja proizvodnje v proces planiranja v podjetju Domel. [9]

2.2. Predmet raziskave

Raziskava izhaja iz realnega izziva, ki ga običajno rešujemo z znanjem in izkušnjami planerja in mojstra: če je napoved trajanja PN dovolj točna, so doseženi pozitivni učinki na večino proizvodno poslovnih procesov:

- dosežemo zanesljivo oskrbo kupca v prodajnem procesu; ne zamudimo,
- dosežemo stabilno, umirjeno in posledično kvalitetno delo v proizvodnem procesu; manj izmeta,
- dosežemo terminsko usklajeno oskrbo z materiali v nabavnem procesu; posledično imamo na nižje zaloge.

Naloga planerja ni zagotoviti izvedbo proizvodnje, kot je določeno v želenih normativih proizvodnje. To je poslovni cilj, h kateremu stremimo, da ga čim prej dosežemo in je v domeni razvoja proizvodne tehnologije in proizvodnje same. Ko je dejansko trajanje PN enako planiranemu trajanju in to enako želenemu trajanju, je poslovni cilj dosežen. Tako od planerja pričakujemo, da »zna delati« z odstopanji od želenih normativov, da doseže zanesljivo oskrbo kupca. Ta v obstoječem procesu zahteva, da mu tehnologija pripravi dodatne proizvodne verzije v ERP z različnimi normativi, npr. pesimistični normativi za uvajanje izdelka v proizvodnjo. *Ker je to dodatno delo za poslovno področje tehnologije, se ne izvaja redno za vse izdelke.*

Kompleksno raziskovalno vprašanje, ki nas zanima, je, kako se pri tem izzivu v praksi izkaže ML in to primerjati z izkušenim planerjem. Algoritmi ML potrebujejo določeno količino podatkov, da lahko zagotovijo točne napovedne informacije. Praktično vprašanje je, kako se uspešnost teh algoritmov pri predvidevanju trajanja PN spreminja s časom oziroma s številom ponovitev. Tovrstne informacije bi bile uporabne za podjetja, ki načrtujejo uvedbo AI APS v svoj proizvodni sistem, saj bi lahko načrtovala, koliko časa bo potrebno vlagati resurse v "učenje" do točke, ko bo lahko ML koristno služil proizvodnemu sistemu. Trenutno tovrstne informacije za sistem LEAP niso na voljo, zato morajo podjetja, ki se za LEAP odločijo, prevzeti tveganje vlaganja sredstev za nedoločen čas. Da bi odgovorili na zastavljeno raziskovalno vprašanje, je potrebno proučiti dva scenarija:

- *1 scenarij: Analiza uspešnosti napovedovanja trajanja PN na podlagi normativov iz ERP sistema:* pred prvo izvedbo serije izdelka planer predvidi (izračuna) trajanje proizvodnega naloga na podlagi matičnih podatkov (angl. master data – MD) o želenih normativih izdelave iz ERP sistema. Pred vsako novo ponovitvijo proizvodnega naloga planer preveri, kakšno je bilo odstopanje realiziranega trajanja PN iz MES, ter se ob posvetovanju z mojstrom v proizvodnji odloči, ali bo v nadaljevanju uporabil pesimistično proizvodno verzijo iz ERP (če obstaja). Sicer subjektivno podaljšuje planirano trajanje PN v ERP s časovnimi pribitki (t.i. časovni »blažilniki«) izven podatkov v normativih.
- *2 scenarij: Analiza uspešnosti napovedovanja trajanja proizvodnih nalogov s stojnim učenjem LEAP:* pred prvo izvedbo LEAP nima drugih podatkov kot normative iz ERP in iz njih izračuna trajanje. Zato pričakujemo, da na začetku »greši« bolj kot planer. Po več ponovitvah proizvodnega naloga LEAP preklopi na lastno bazo, kjer je primerjal izračune iz podatkov ERP z realizacijo iz MES in je začel razvijati svoj napovedovalni model, kjer za določanje trajanja PN ne upošteva več matičnih podatkov ERP.

Za potrebe raziskave smo pridobili empirične podatke iz proizvodnje v obdobju januar 2021 – november 2023. Podatki o normativih s korekcijo planerja so MD iz ERP HANA, podatki o napovedih trajanja LEAP so pridobljeni iz sistema APS LEAP, podatki o realizaciji pa so pridobljeni iz sistema MES KINER. Vsi podatki so bili izvoženi v Microsoft Excel, pri čemer so bili podatki za posamezne proizvedene ID-je izdelkov prikazani na ločenih listih (slika 2). V preliminarni fazi raziskave smo uporabili vzorec 23 različnih izdelkov (identov) z različnim številom ponovitev PN. Posamezna ponovitev PN je vsebovala 22 različnih podatkov (npr. število kosov, planirani čas, normativni čas na 1000 kosov, začetni/končni datum in ura, pripravno-končni čas...). Za začetno testiranje uporabnosti metode dokazovanja koristi ML smo zožili nabor in se osredotočili na 6 izdelkov: ID 421577, 237597, 270833, 351660, 272811, 442122. Pri izbiri končne množice testnih izdelkov je bil ključni dejavnik število ponovitev PN. Osredotočili smo se namreč na izdelke, pri katerih je bilo zabeleženih vsaj nekaj 10 ponovitev PN v obdobju opazovanja. Glede na to, da je bila v septembru 2021 izvedena obsežnejša prilagoditev algoritma v APS LEAP so za potrebe naše raziskave merodajni zapisi, ki so se zgodili po tej spremembi.

The image shows a screenshot of a data table with columns labeled A through V. The table contains numerous rows of numerical data. At the bottom of the table, a row is highlighted in green, containing the following values: 448819, 394152, 394154, 485399, 349734, 349735, 349724, 402305, 467371, 439515, 435417, 421577, 270833, 283606, 351660, 270793, 228469.

Slika 2: Vhodni podatki za potrebe raziskave. [9]

Glavno merilo, ki ga bo osnova za statistične analize v pričujoči raziskavi, je relativna napaka napovedi trajanja izvedbe PN, ki jo generira sistem LEAP v primerjavi s potrjenim in absolutno oziroma realnim trajanjem izvedbe PN. To napako izračunamo na naslednji način:

$$\Delta LEAP = \frac{t_{LEAP} - t_{MES}}{t_{LEAP}} \times 100 \quad (2.1)$$

Kadar nam je pomembna le velikost napake ne pa tudi njena smer (+,-), uporabimo absolutno vrednost $\Delta LEAP$.

2.3. Tri-stopenjski pristop k čiščenju podatkov

Po pregledu podatkov iz proizvodnje smo ugotovili, da nekatere vrednosti močno odstopajo od ostalih, kar najverjetneje kaže na pojav neobičajnih okoliščin pri realizaciji PN. Čeprav ekstremne situacije vplivajo na realizacijo proizvodnje, smo se odločili, da jih v tej fazi analize izločimo, saj smo za začetek želeli proučiti obnašanje LEAP sistema v hipotetično stabilnih razmerah v proizvodnji. Za izločitev ekstremnih situacij smo določili 3 kriterije:

- 1 kriterij: *eliminacija popolnoma neveljavnih podatkov*: V prvi fazi smo želeli izločiti tiste realizirane PN, ki sploh niso bili planirani preko sistema LEAP, saj niso relevantni za našo raziskavo. Iz podatkov smo izločili vse zapise, kjer je
 - o čas nastavljanja pred septembrom 2021; tak PN ni bil obdelan skozi LEAP,
 - o čas nastavljanja po septembru 2021, vendar so vrednosti LEAP napovedi natanko enake, kot je vrednost po matičnih podatkih; sklepamo, da tak PN ni obdelan skozi LEAP,
 - o potrjeni čas obdelave je 0h,
 - o planirani čas trajanja po LEAP je 0h.
- 2 kriterij: *eliminacija zapisov, ki predstavljajo velika odstopanja*: Po izvedenem čiščenju po 1 kriteriju smo želeli identificirati zapise, kjer je odstopanje med napovedjo LEAP in MD zelo veliko. Do takih situacij lahko pride zaradi morebitnega izrednega dogodka v proizvodnji, razlike med planiranimi in narejenimi kosi, ali drugih neusklenosti med različnimi informacijskimi sistemi, npr. delovnega koledarja LEAP in ERP (v

enem informacijskem sistemu je določena sobota označena kot delovni dan, v drugem sistemu je ta ista sobota označena kot prosti dan). Za identifikacijo zapisov z velikimi odstopanji, smo:

- izračunali tretji kvartil Q_3 za relativno napako $\Delta LEAP$,
- za vrednosti $\Delta LEAP$, manjše od Q_3 , smo izračunali povprečje \bar{x}_{Q_3} in standardni odklon σ_{Q_3} ,
- nato smo izračunali kritično vrednost po naslednji enačbi:

$$\text{kritična vrednost} = \bar{x}_{Q_3} + 2 \times \sigma_{Q_3} \quad (2.2)$$

- nato smo izločili vse zapise, pri katerih je $\Delta LEAP$ večji ($>$) od izračunane kritične vrednosti.
- 3 kriterij: *glajenje podatkov*. Če po uporabi kriterija 2 še ne dobimo dovolj homogenih podatkov, nadaljujemo z metodo glajenja podatkov. Kot osnovo za izbiro vrednosti, ki jih je potrebno zgladiti, smo uporabili regresijsko premico linearne trenda ter njen interval zaupanja, ki ga izračunamo tako, da regresijski premici prištejemo ali odštejemo vrednost 2 standardnih odklonov. Vrednosti $\Delta LEAP$, ki so zunaj teh meja (t.i. »neveljavni« podatki), se gladijo po postopku:
- če je podatek, ki ga je potrebno gladiti, prvi v vzorcu podatkov, ga izenačimo s prvim naslednjim podatkom, ki je v mejah (je »veljaven«),
 - v primeru, da ima »neveljavni« podatek »veljavnega« predhodnika in naslednika, se le-ta nadomesti z njuno povprečno vrednostjo,
 - če je več podatkov zaporedoma zunaj meja (»neveljavnih«), nadomestimo prvi »neveljavni« podatek s povprečjem zadnjega »veljavnega« podatka pred njim in prvega »veljavnega« podatka za njim. Nadalje podatke gladimo po enakem postopku, dokler niso zglajeni vsi podatki v vzorcu.

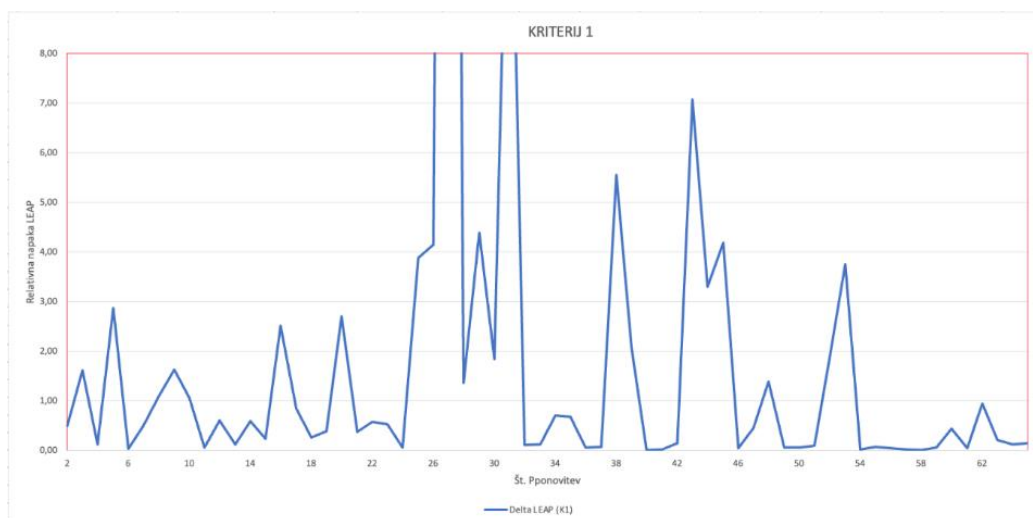
3 Rezultati

V nadaljevanju bomo podrobneje predstavili postopek izvedbe tri-stopenjskega čiščenja podatkov ter rezultate analize za enega od šestih izbranih testnih primerov (t.j. ID 421577), medtem ko bomo zaradi omejitve dolžine prispevka za ostalih pet testnih primerov prikazali le sumarne rezultate.

3.1. Podrobnejši rezultati analize za testni primer ID 421577

ID 421577 je od začetka uporabe LEAP 1.1.2021 vseboval 126 ponovitev PN: od 18. do 144. ponovitve PN. Torej je bil izdelek pred začetkom uporabe mikroplaniranja z ML relativno »mlad«, z le 17 ponovitvami PN. Po uporabi 1. kriterija je bilo izmed 126 zapisov izločenih 61 neveljavnih zapisov. Tretji kvartil za izračunane vrednosti $\Delta LEAP$ tega ID je 0.532, kritična vrednost za izločitev po kriteriju 2 pa je 0.32. Po uporabi 2. kriterija je bilo tako izločenih še 17 zapisov, ki so predstavljali velika odstopanja, po uporabi 3. kriterija pa je bilo za ublažitev vpliva ekstremnih vrednosti dodatno zglajenih še 12 zapisov.


V nadaljevanju prikazujejo odvisnost relativne napake $\Delta LEAP$ za ID 421577 od števila ponovitev PN, glede na tri-stopenjski postopek čiščenja podatkov. Slika 3 prikazuje odvisnost relativne napake $\Delta LEAP$ od števila ponovitev PN za vzorec podatkov, ki je bil prečiščen skladno s 1. kriterijem (odstranjeni neveljavni zapisi, vpliv ekstremnih odstopanj še ni izločen). Na podlagi take grafične analize težko potrdimo, da je vrednost relativne napake $\Delta LEAP$ kakorkoli povezana s številom ponovitev PN. Mestoma zaznamo zelo velika odstopanja (nad 4000%). Kljub temu izračun Spearmanovega koeficienta korelacije (tabela 1) pokaže zmerno stopnjo negativne povezanosti (-0,284). Dobljena p vrednost testa povezanosti je $0,022 < 0,05$, kar pomeni, da ob 5% stopnji značilnosti testa lahko trdimo, da povezava med izbranimi veličinama obstaja že na dejanskih podatkih iz proizvodnje.



Slika 3: Odvisnost relativne napake $\Delta LEAP$ od števila ponovitev; podatki prečiščeni skladno s 1.kriterijem. [4]


Ko smo zapise podatkov ID 42577 dodatno prečistili z uporabo kriterija 2 (eliminacija ekstremnih odstopanj), je odvisnost relativne napake od števila ponovitev bolj jasno razvidna že iz grafične predstavitev (slika 4). Slednje potrjuje tudi vrednost Spearmanovega koeficienta korelacije (-0,415). Tudi p vrednost testa povezanosti je statistično značilna ($0,003 < 0,05$), kar pomeni, da ob eliminaciji zapisov, kjer relativna napaka $\Delta LEAP$ ekstremno odstopa, lahko potrdimo, da se napoved trajanja PN z naraščanjem števila ponovitev znatno zmanjšuje.

Iz slike 4 je razvidno, da v vzorcu podatkov še vedno obstajajo velika odstopanja v vrednostih $\Delta LEAP$, ki zahtevajo glajenje. Na sliki 4 so to vrednosti, ki »štrlijo« izven intervala zaupanja linearnega trenda.



Slika 4: Odvisnost relativne napake $\Delta LEAP$ od števila ponovitev; podatki prečiščeni skladno s 2.kriterijem. [4]

Da bi izločili vplive teh odstopanj, izvedemo glajenje z uporabo kriterija 3. Grafična predstavitev glajenih podatkov (slika 5) jasno pokaže negativni trend relativne napake $\Delta LEAP$ v odvisnosti od števila ponovitev PN. Slednje potrjuje tudi razmeroma visoka in negativna vrednost Spearmanovega koeficienta korelacije (-0,673). Tudi p vrednost testa povezanosti je tudi tokrat statistično značilna ($0,0000002 < 0,05$).



Slika 5: Odvisnost relativne napake Δ LEAP od števila ponovitev; podatki prečiščeni skladno s 3.kriterijem. [4]

3.2. Sumarni rezultati analize za izbrane testne primere

Na isti način, kot je predstavljeno v prejšnjem poglavju za testni primer ID 42577, smo izvedlo analize še za ostalih 5 testnih primerov, in sicer: ID 237597, ID 270833, ID 351660, ID 272811 in ID 442122. Sumarni rezultati so predstavljeni v tabeli 1.

Tabela 1: Rezultati statističnih analiz vzorca šestih izbranih testnih primerov

	Kriterij 1	Kriterij 2	Kriterij 3
ID 421577			
Število podatkov (n)	65	48	36+12
Spearmanov coef. korelacije	-0,284	-0,415	-0,673
p vrednost	0,022	0,003	0,0000002
ID 237597			
Število podatkov (n)	60	47	42+5
Spearmanov coef. korelacije	0,101	0,254	0,293
p vrednost	0,442	0,085	0,046
ID 270833			
Število podatkov (n)	46	32	30+2
Spearmanov coef. korelacije	-0,190	-0,253	-0,300
p vrednost	0,207	0,162	0,095
ID 351660			
Število podatkov (n)	44	32	31+1
Spearmanov coef. korelacije	-0,114	-0,426	-0,451
p vrednost	0,461	0,015	0,010
ID 272811			
Število podatkov (n)	40	30	28+2
Spearmanov coef. korelacije	-0,243	-0,470	-0,601
p vrednost	0,132	0,009	0,0004
ID 442122			
Število podatkov (n)	27	18	17+1
Spearmanov coef. korelacije	-0,281	-0,449	-0,756
p vrednost	0,155	0,06	0,0003

4 Diskusija

Rezultati uporabe tri-stopenjskega čiščenja podatkov za izločanje ekstremov v proizvodnji so pokazali, da s tem postopkom lažje statistično dokažemo, da se uporaba ML podjetju izplača pri doseganju zelenega cilja: s časom se sistem ML dovolj dobro nauči, da postane pri napovedovanju trajanja PN boljši od planiranja z normativi, kar pomeni, da lahko planerja razbremenimo odločanja pri izbiranju proizvodnih verzij v ERP v procesu mikroplaniranja. Zavedati pa se je potrebno, da smo se postopkom čiščenja podatkov umetno približali razmeram stabilnejše proizvodnje, kjer je razlogov, ki vodijo v odstopanja napovedi pričakovati manj.


Da bi lahko potrdili, je bil proces čiščenja podatkov izveden korektno in so bili ekstremi izločeni upravičeno (in so posledično statistični zaključki relevantni), je potrebno imeti dokaze iz MES. Potrebovali bi namreč potrditev, da so bili podatki, ki smo jih odstranili ali gladili, resnično vezani na naključne/izredne dogodke v proizvodnem procesu. Upravičenost izločanja posameznih zapisov smo preverjali tako, da smo si pri analizi zapisali izločeno številko PN. Nato smo v bazi sistema MES pregledali pripadajoče zapise o razlogih, ki bi lahko vplivali ali na močno predčasen zaključek ali močno podaljšano trajanje PN, (npr. ali za izločen PN obstaja poročilo o zastoju na stroju, kot kaže primer na sliki 6). *Ugotovili smo, da proizvodnja v proučevanem podjetju zastojev ne beleži dovolj natančno in sistematično* (ne vsi delavci in mojstri na enak način). To je zelo pomembna ugotovitev za potrditev ustreznosti/neustreznosti izločanja ekstremov. Nenazadnje, učinkovit algoritem ML bi moral znati take naključne/izredne dogodke pri nadaljnjih napovedih upoštevati. Da ML lahko spremlja zakonitosti pojavljanja takih dogodkov in to uporabi pri napovedovanju trajanja PN, mora imeti natančen in standardiziran razlog zastoja (koda zastoja). V proučevanem proizvodnem okolju je izbira vrste zastoja prepuščena subjektivni presoji delavca, ko v MES opredeli, zakaj stroj stoji.

1	Stroj	Zastoj	Tip zast.	Podstroj	Začetek	Odprava	Dolež. zast.	Dolež. vzdr.	Opis
2	AS01	Stroj; Fine nastavitve	NEP	AS01	31.05.2024 23:38	01.06.2024 00:00	0,35	0,00	
3	AS02	Stroj; Fine nastavitve	NEP	AS02	31.05.2024 23:26	01.06.2024 00:00	0,55	0,00	zmeden pomk
5	AS03	Stroj; ZastZaradDrugStroja	NEP	AS03	31.05.2024 23:10	31.05.2024 23:20	0,18	0,00	
6	AS01	Stroj; ZastZaradDrugStroja	NEP	AS01	31.05.2024 22:22	31.05.2024 22:39	0,28	0,00	
7	AS01	Stroj; ZastZaradDrugStroja	NEP	AS01	31.05.2024 22:02	31.05.2024 22:10	0,13	0,00	
48	AS13	Orodje; LomOrodja-Izpenjanje	NEP	AS13	31.05.2024 22:00	01.06.2024 00:58	2,98	0,00	Zastoj od:31.05.24 17:31:25; 1.red zabiti izmetač.
49	BSD 13	Orodje; LomOrodja-Izpenjanje	NEP	BSD 13	31.05.2024 22:00	01.06.2024 06:00	8,00	0,00	Zastoj od:31.05.24 13:48:35; neenakomerno brizganje
50	BSD 6	Orodje; LomOrodja-Izpenjanje	NEP	BSD 6	31.05.2024 22:00	01.06.2024 06:00	8,00	0,00	Zastoj od:31.05.24 13:43:05;
51	BST-05	Stroj; Fine nastavitve	NEP	BST-05	31.05.2024 22:00	01.06.2024 06:00	8,00	0,00	Zastoj od:31.05.24 12:19:55;
54	AS07	Orodje; LomOrodja-Izpenjanje	NEP	AS07	31.05.2024 22:00	31.05.2024 22:03	0,05	0,00	Zastoj od:31.05.24 20:40:01;
115	AS07	Orodje; LomOrodja-Izpenjanje	NEP	AS07	31.05.2024 20:40	31.05.2024 22:00	1,33	0,00	
129	BST-08	Stroj; Fine nastavitve	NEP	BST-08	31.05.2024 19:34	31.05.2024 19:35	0,03	0,00	
131	AS16	Stroj; Fine nastavitve	NEP	AS16	31.05.2024 18:00	31.05.2024 18:45	0,77	0,00	Zastoj od:31.05.24 16:44:30
132	AS01	Stroj; Fine nastavitve	NEP	AS01	31.05.2024 18:00	31.05.2024 21:58	3,98	0,00	Zastoj od:31.05.24 15:59:11
133	AS13	Orodje; LomOrodja-Izpenjanje	NEP	AS13	31.05.2024 17:31	31.05.2024 22:00	4,48	0,00	1.red zabiti izmetač.
134	AS14	Orodje; LomOrodja-Izpenjanje	NEP	AS14	31.05.2024 17:31	31.05.2024 21:20	3,83	0,00	
137	AS16	Stroj; Fine nastavitve	NEP	AS16	31.05.2024 16:44	31.05.2024 17:30	0,76	0,00	
139	AS16	Stroj; Fine nastavitve	NEP	AS16	31.05.2024 16:41	31.05.2024 16:43	0,04	0,00	
140	AS14	Orodje; LomOrodja-Izpenjanje	NEP	AS14	31.05.2024 16:40	31.05.2024 16:42	0,03	0,00	
141	AS08	Stroj; Fine nastavitve	NEP	AS08	31.05.2024 16:22	31.05.2024 17:28	1,11	0,00	
142	AS14	Orodje; LomOrodja-Izpenjanje	NEP	AS14	31.05.2024 16:18	31.05.2024 16:39	0,35	0,00	
144	AS14	Stroj; Fine nastavitve	NEP	AS14	31.05.2024 16:10	31.05.2024 16:18	0,14	0,00	
145	AS01	Stroj; Fine nastavitve	NEP	AS01	31.05.2024 15:59	31.05.2024 17:30	1,51	0,00	
146	AS02	Stroj; Fine nastavitve	NEP	AS02	31.05.2024 15:37	31.05.2024 17:10	1,55	0,00	
147	AS14	Stroj; Fine nastavitve	NEP	AS14	31.05.2024 14:41	31.05.2024 15:21	0,67	0,00	

Slika 6: Preverjanje časovne usklajenosti izločenih ekstremnih proizvodnih nalogov z zastoji na strojih.

Pri analizi meritev realiziranih PN smo tudi *ugotovili, da je v proučevanem podjetju zabeležen čas realizacije odvisen od pravočasnega prijanzanja začetka in konca PN s strani delanca preko sistema MES*. Če obstaja v realnosti razlika med dejanskim začetkom/koncem dela na PN in tistim, ki ga je prijavil delavec, to lahko napačno usmeri ML, da načrtuje prihodnje PN dlje ali krajše, kot bi jih sicer, kar lahko vpliva tudi na druge funkcije AI APS, kot je modul za optimalno razporejanja delovnih nalogov. Na podlagi teh ugotovitev predlagamo za izboljšanje merjenje učinka uporabe ML pri mikroplaniranju proizvodnje naslednje ukrepe:

- bolj precizno in pravilno zapisovanje vzrokov o zastojih/prekinitvah v proizvodnem procesu,
- bolj precizno in pravilno zapisovanje začetkov in koncev izdelave PN na strojih,
- če je možno, popolnoma avtomatizirati ugotavljanje in poročanje trajanja zastojev, kar je lažje pri robotiziranih in računalniško krmiljenih strojih (slika 7).



Slika 7: Uporaba avtomatiziranih meritev ciklov delovanja stroja za verifikacijo zastojev v MES in izločanje ekstremnih proizvodnih situacij iz meritev koristi uporabe strojnega učenja pri mikroplaniranju proizvodnje.

Ugotovili smo, da *na pravilnost meritev vpliva tudi človeški dejavnik, planer, in s tem vpliva, da podatki o normativnem trajanju PN niso pravilni: planer »iz izkustvene baze preteklih novitet«* s subjektivno metodo analogije oceni realno trajanje v proizvodnji. Pri tem se posvetuje tudi z mojstrom, ki sprejema noviteto v svojo proizvodnjo. Nato na podlagi »mnenja« korigira predlagan izračun trajanja PN iz ERP na samem PN (časovni blažilec). Če ni informacije, kateri izračun trajanja PN je bil prilagojen s »človeško inteligenco«, to pomembno vpliva na kvaliteto podatkov, ki vstopajo v meritve, s katerimi dokazujemo, ali ML lahko nadomesti izkušnje planerja pri mikroplaniranju ter pri katerih ponovitvah PN doseže ali preseže planerja.

Pomembna ugotovitev je povezana z naravo pojavljanja dogodkov nezanesljive proizvodnje, ki vplivajo na dejansko trajanje PN: *nekateri dogodki proizvodnji nastopajo naključno (npr. pojav nekvalitetnega materiala, odpoved naročila tekom proizvodnje), nekateri imajo svoje funkcijske zakonitosti (npr. odpovedi orodja, stroja), kar pomeni, da jih je lažje bolj precizno napovedati.* Če dostopa do teh podatkov ML nima, ne moremo pričakovati, da se ponovna ekstremna odstopanja med napovedjo trajanja PN z ML in dejansko realizacijo PN ne bodo več dogajala.

Ugotovili smo tudi, da pri dejanski proizvodnji na meritve uporabe ML vpliva tudi *kvaliteta vboodnih podatkov o realizaciji*, npr. zakaj se je ob enakem naključnem dogodku, ki se je ponovil, sprejelo različne ukrepe, tega iz obstoječih podatkov ne moremo ločiti (enak vzrok, npr. odpoved orodja lahko vpliva kot predčasen zaključek PN ali kot podaljšan čas izdelave PN; odločitev sprejme subjektivno proizvodnja skupaj z vzdrževanjem glede na ocenjeno težavo, npr. ali je na zalogi rezervni del).

5 Zaključek

Ugotovili smo, da je v proučevanju proizvodnem sistemu zelo veliko nezanesljivih podatkov, ki jih potrebuje ML za dobro predvidevanje trajanja PN. Zato je težko izmeriti koristi uporabe nove tehnologije ML za predvidevanje trajanja PN, če ne posežemo tudi v prenovo pridobivanja podatkov o realizaciji proizvodnih procesov, kot je zajem točnih razlogov iz proizvodnega procesa o njegovi nezanesljivosti, doslednost poročanja ipd..

Z vpeljavo postopka tri-stopenjskega čiščenja izvornih podatkov proizvodnje smo opazili koristi AI APS LEAP pri predvidevanju trajanja PN, vendar jih zaradi vzorca le šestih izdelkov ne moremo posplošiti na celotno populacijo aktivnih izdelkov. Analiza meritev na prečiščenih podatkih nakazuje, da bolj kot so razmere stabilne (bolj kot so podatki homogeni), bolj učinkovito je lahko učenje ML. Ugotavljamo, da je metoda čiščenja dovolj enostavna in dobra, da jo v nadaljevanju raziskave lahko apliciramo na reprezentativnem vzorcu, pod pogojem, da bodo izločeni zapisi dodatno validirani s strani podatkov iz MES, ti pa z neposrednimi podatki o delovanju/nedelovanju strojev.

Odkrili smo, da je zahtevna primerjava napovedovanja LEAP s planiranjem planerja z normativi iz ERP, ker tudi podatki o trajanju PN iz normativov vsebujejo »šume«, kot je subjektivno dodajanje časovnih blažilcev. Nimamo zapisov ne kdaj ne zakaj so se planerji tega poslužili. Za zaključek je tu še naključna ali funkcijsko neznanu opredeljena pojavnost dogodkov nezanesljive proizvodnje. Bolj kot je proizvodnja nezanesljiva, več bo ekstremnih

odstopanj napovedi z ML od realne proizvodnje in težje bo dokazovanje koristi ML. Po analizi ugotavljamo, da tehnologija ML sicer zna delati z nezanesljivim proizvodnim procesom podobno dobro (slabo) kot človek, a to ne pomeni, da lahko zaradi tega opustimo napore za stabilizacijo proizvodnega procesa, saj bomo na ta način izboljšali tudi točnost predvidevanj trajanja PN z ML.

Literatura

- [1] Zhong, R. Y.; Xu, X.; Klotz, E.; Newman, S. T. Intelligent Manufacturing in the context of industry 4.0: A Review. *Engineering* 2017, 3(5), 616–630.
- [2] Xu, L. D., Xu, E. L., Li, L. (2018). Industry 4.0: State of the art and future trends. *International Journal of Production Research*, 56(8), 2941–2962.
- [3] Dellermann, D., Ebel, P., Söllner, M., Leimeister, J. M. (2019). Hybrid intelligence. *Business & Information Systems Engineering*, 61(5), 637-643.
- [4] Vukašin, R. (2024). Učinkovitost algoritmov umetne inteligence pri mikroplaniranju proizvodnje. Diplomsko delo. Univerza v Mariboru, Fakulteta za organizacijske vede.
- [5] Bueno, A., Godinho Filho, M., Frank, A. G. (2020). Smart production planning and control in the industry 4.0 context: A systematic literature review. *Computers & Industrial Engineering*, 149, 106774.
- [6] Marzia, S., AlejandroVital-Soto, Azab, A. (2023). Automated Process Planning and dynamic scheduling for Smart Manufacturing: A Systematic Literature Review. *Manufacturing Letters*, 35, 861–872.
- [7] www.domel.com, Informacije o podjetju Domel, obiskano 26. 7. 2024.
- [8] www.qlector.com, Informacije o podjetju Qlector in produktu Leap, obiskano 26. 7. 2024.
- [9] Roblek, M., Zajec, M., Georgievski, A. (2022). Izzivi uporabe umetne inteligence na področju operativnega planiranja proizvodnje. *Sodobni pristopi inženiringa poslovnih sistemov*, 1st, 181-216.
- [10] Roblek, M. (2022). The use of artificial intelligence in the operational planning process, the case of Domel. 42th International Conference on Organizational Science Development.
- [11] www.kiner.si, Informacije o podjetju SGM in produktu Kiner, obiskano 26. 7. 2024.

