

IZZIVI UPORABE UMETNE INTELIGENCE NA PODROČJU OPERATIVNEGA PLANIRANJA IN RAZPOREJANJA PROIZVODNJE

MATJAŽ ROBLEK,¹ ANA GEORGIEVSKI,² MAJA ZAJEC³

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

² Knauf Insulation, Kranj, Slovenija
ana.georgievski@gmail.com

³ Univerza v Mariboru, Fakulteta za organizacijske vede, Kranj, Slovenija
maja.zajec@um.si

Sinopsis Operativno planiranje in razporejanje proizvodnje je vsebinsko in informacijsko eno zahtevnejših poslovnih področij v proizvodnih podjetjih. Zaradi upoštevanja množice poslovnih in proizvodnih spremenljivk, katerih pomembnost se dinamično menja glede na razmere v poslovnem okolju, je sprejemanje celovito optimalnih odločitev brez podpore naprednih optimizacijskih algoritmov zelo zahtevno in zato tudi zanimivo za vpeljavo naprednih orodij digitalne dobe, kot je umetna inteligenca. Združili smo izsledke pomembnejših raziskav na tem področju in jih podkrepili z analizo primera iz proizvodnega podjetja. Iz analize primera predstavljamo strokovne izzive in smernice, ki jim je treba slediti, da je uporaba umetne inteligence uspešna na področju operativnega planiranja proizvodnje.

Ključne besede:

umetna inteligenca,
strojno učenje,
oskrbovalne verige,
operativno
planiranje
proizvodnje,
razporejanje
proizvodnje

CHALLENGES OF APPLYING ARTIFICIAL INTELLIGENCE IN OPERATIONAL PRODUCTION PLANNING AND SCHEDULING

MATJAZ ROBLEK,¹ ANA GEORGIEVSKI,² MAJA ZAJEC³

¹ Domel, Železniki, Slovenia
matjaz.roblek@domel.com

² Knauf Insulation, Kranj, Slovenia
ana.georgievski@gmail.com

³ University of Maribor, Faculty of Organizational Sciences, Kranj, Slovenia
maja.zajec@um.si

Abstract Operational planning and production scheduling are among the most information- and content- intensive business areas in manufacturing companies. Considering the multitude of business and production variables, the importance of which changes dynamically depending on the situation in the business environment, makes it very challenging to prepare comprehensively optimal decisions without the support of advanced optimisation algorithms and therefore also interesting for the introduction of advanced tools of the digital era, such as artificial intelligence (AI). We have brought together significant research findings in this area and supported them with a case study from a manufacturing company. From the case study, we presented the professional challenges and guidelines that need to be followed for the successful application of AI in the field of operational production planning.

Keywords:
artificial
intelligence,
machine learning,
supply chains,
operational
production
planning,
production
scheduling

1 Uvod

Tudi proizvodna podjetja niso spregledala hitrega razvoja strojnih in programskih računalniških tehnologij. Raziskave na tem področju kažejo, da imajo proizvodna podjetja največji potencial v izrabi robotske avtomatizacije procesov (RPA¹), v tehnologiji veriženja blokov in umetni inteligenci (AI²) (Hartley in Sawaya, 2019). Umetna inteligenca je znanost in tehnologija, s katero dosežemo, da se računalniški programi obnašajo na način, za katerega smo do danes menili, da potrebujemo človeka in njegovo inteligenco (Iriundo, 2018). Umetna inteligenca je tehnologija, ki v času nastanka prispevka začena intenzivno aplikativno uporabo v oskrbovalnih verigah, katere del so tudi aplikacije v proizvodnih podjetjih. Z vidika znanstvenega proučevanja je dobro raziskano akademsko področje in je zanimiva zaradi potenciala, da bi z njo dosegli hitrejše in preciznejše reševanje problemov v oskrbovalnih verigah (Toorajipour idr., 2021), npr. realno ocenjevanje tveganj, nihanja napovedi kupcev ali nezanesljivost transportnih poti (Baryannis idr., 2019). Raziskovalci preučujejo različne tehnike umetne inteligence za uporabo v oskrbovalnih verigah, njihovo uporabo na različnih delovnih mestih in poslovnih področjih v dobavni verigi, in raziskujejo, za katere poslovno-oskrbovalne probleme je lahko uporabna (Toorajipour idr., 2021). Raziskovalci poskušajo tudi ugotoviti, kako najučinkoviteje vpeljati umetno inteligenco v podjetje (pristop) in v katere poslovne procese (Cadavid idr., 2019).

Tehnologija umetne inteligence je prepoznana tudi pri podpori procesa planiranja proizvodnje, ki je eden ključnih procesov v oskrbovalnih procesih. S planiranjem proizvodnje poskušamo doseči zanesljivo, odzivno in prilagodljivo oskrbo kupca ob minimalno povzročenih stroških in z velikim izkoristkom uporabljenih proizvodnih sredstev. Zaradi kompleksnih in tudi medsebojno izključujočih ciljev je v postopku operativnega planiranja proizvodnje prisotno mnogo parametrov negotovosti: kaj bo, če material zamudi, če delovno sredstvo odpove, če se kupec premisli, če dobimo material z napako, če nam zaposleni zbolijo, če tehnična dokumentacija novega projekta zamudi ipd., ter kakšne bodo posledice negotovosti, kot so prekomerne ali premajhne zaloge, večji stroški dela, slaba dobičkonosnost delovnih sredstev. Ob teh bolj ali manj zanesljivo predvidenih dogodkih in njihovih posledicah imamo mnogo

¹ RPA = angl. Robotic Process Automation

² AI = angl. Artificial Intelligence

podatkov v poslovnih in proizvodnih informacijskih sistemih. In kjer so podatki, nam umetna inteligenca ponuja priložnosti pametnega odločanja na podlagi prepoznanega znanja iz podatkov. To vključuje tako predvidljive kot manj predvidljive dogodke in posledično omogoča bolj robustno planiranje proizvodnje (Cadavid idr., 2019).

2 Opredelitev pojmov

2.1 Umetna inteligenca

V pregledni raziskavi (Goertzel in Wang, 2007) so zbrane definicije različnih avtorjev o tem, kaj je umetna inteligenca. Predstavlja zmožnost:

- doseganja kompleksnih ciljev v kompleksnem okolju,
- uspešnosti sistema v kompliciranem okolju,
- reševanja zahtevnih problemov,
- optimalne uporabe omejenih virov za doseganje ciljev,
- sistema, da za doseg cilja generira prilagojeno obnašanje znotraj okolja,
- obravnave problemov v kompleksnem okolju, kjer kriteriji primernosti niso predhodno definirani, temveč so pridobljeni skozi procesiranje informacij.

Z znanstvenega vidika je pomembno vprašanje, ki si ga je leta 1950 zastavil britanski matematik Alan Turing. Spraševal se je, ali stroji lahko razmišljajo, in določil test za dokazovanje inteligentnosti strojev, kjer človek postavlja vprašanja, na katera odgovarja računalnik, spraševalec pa tega ne ve. Če računalniku uspe prepričati spraševalca, da mu odgovarja človek, lahko rečemo, da je računalnik inteligen. Sam test ima negativne znanstvene kritike, toda z njim je Turing odprl nov cilj znanstvenih raziskav, in sicer ugotavljanje »prisotnosti«
inteligence v umetno ustvarjenih sistemih (Finlay in Dix, 1996).

Z dvigom sposobnosti računalnikov se izboljšujejo tudi algoritmi v različnih tehnikah umetne inteligence, kar omogoča vedno več uporabnih aplikacij (Anyoha, 2017). Razvija se tehnike od strojnega učenja do globokega učenja, ki omogočajo računalniškim sistemom učenje z uporabo izkušenj, predstavi se postopke posnemanja procesa odločanja človeških ekspertov. Umetna inteligenca dobiva vedno širšo aplikativno uporabnost (Zupan, 2010):

- dedukcija, sklepanje, reševanje problemov,
- predstavitev znanja,
- samodejno načrtovanje in razporejanje,
- strojno učenje,
- gibanje in rokovanje,
- obdelava jezika in govora,
- socialna inteligenca.

Danes so najpogostejše aplikacije umetne inteligence narejene s tehniko strojnega učenja (ML³), kjer gre za oblikovanje in preoblikovanje algoritmov, zaradi katerih se stroji lahko učijo na podlagi že izvedenih primerov (tabela 1). Predpogoj je dostop ML do velike količine podatkov, da lahko z algoritmi posnema razmišljanje človeka.

Tabela 1: Primerjava umetne inteligence in strojnega učenja

Umetna inteligenca	Strojno učenje
Strojem omogoča človeku podobna obnašanja.	Strojem omogoča avtomatsko učenje na podlagi preteklih podatkov.
Cilj: izdelati kot človek pametne računalniške sisteme za reševanje kompleksnih problemov.	Cilj: omogočiti strojem učenje iz podatkov za napoved točnih izidov.
Razvijalci izdelujejo inteligentne sisteme, namenjene opravljanju nalog ljudi.	Razvijalci s podatki učijo stroje za izvedbo točno določenih nalog s pravilnim izidom.
Široko področje uporabe.	Omejeno področje uporabe.
Želi ustvariti inteligentni sistem, ki lahko izvaja več različnih kompleksnih nalog.	Ustvarja stroje za določene naloge, za katere so usposobljeni.
Stremi k uspehu.	Stremi k vzorcem in točnosti.
Na podlagi zmožnosti se ta deli na: šibko (angl. Weak AI), splošno (angl. General AI) in močno (angl. Strong AI) umetno inteligenco.	Delimo na: nadzorovan ML (angl. Supervised learning), nenadzorovan ML (angl. Unsupervised learning), ojačan/podkrepljen ML (angl. Reinforcement learning).

Vir: Javatpoint, 2021

³ ML = angl. Machine Learning

2.2 Oskrbovalne verige in proizvodna podjetja

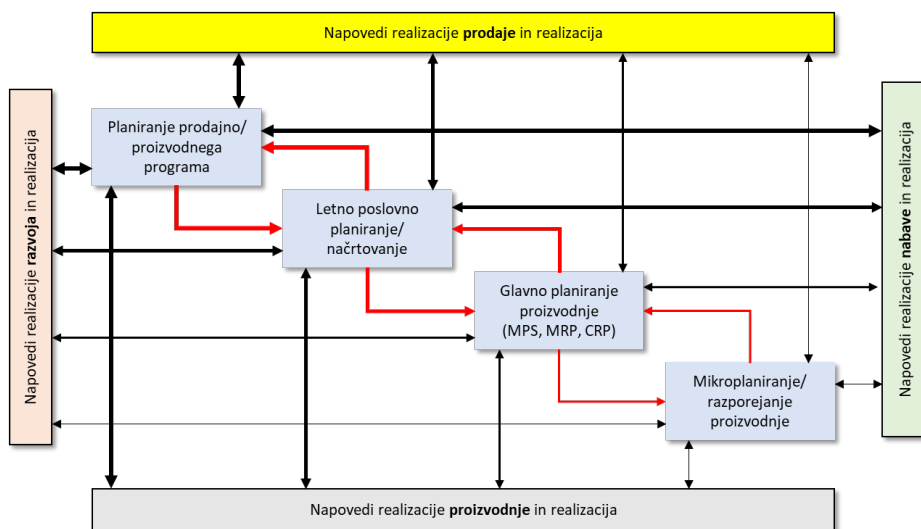
Oskrbovalna veriga je kompleksen sistem načrtno povezanih individualnih poslovnih sistemov (členov): kupcev, distributerjev, logistov, proizvodnih podjetij in dobaviteljev. Materialna oskrbovalna veriga vključuje procese, s katerimi izdelek prihaja iz materiala do kupca (Kenton, 2020). Načeloma imajo vsi členi oskrbovalne verige enake cilje glede uspešnosti poslovanja. Zelo različno pa si predstavljajo cilje glede učinkovitosti poslovanja, npr. kupci bi radi poslovali brez zalog izdelkov, vse zaloge naj držijo distributerji. Dobavitelji bi želeli nespremenljiva naročila materialov daleč v prihodnost, nasprotno kupci želijo poslovati le z neobvezujočimi kratkoročnimi prodajnimi napovedmi. Management oskrbovalnih verig poskuša tveganja za poslovni neuspeh in neučinkovito poslovanje enakomerno porazdeliti med posameznimi členi na način, da zasledovanje globalnega optimuma celotne oskrbovalne verige daje posameznemu členu verige dolgoročno mnogo večje koristi, kot če posamezen člen zasleduje zgolj svoj kratkoročni lokalni optimum.

Proizvodna podjetja so običajno udeležena kot eden ali več členov v oskrbovalnih verigah in proizvajajo sestavne dele, polizdelke ali izdelke. Na eni strani imajo odjemalce oz. kupce, na drugi strani so oskrbovana s strani dobaviteljev. Management proizvodnega podjetja se trudi, da bi proizvajal s čim manj izgubami, minimalno potrebnimi stroški, čim večjim zaslužkom in z zanesljivo oskrbo kupcev. Tveganja, ki jih prepoznava na strani kupcev, poskuša enakomerno prenesti tudi na dobavitelje. Zato mora usklajeno obvladati interne funkcije in njihove procese (PlanetTogether, 2019):

- nabavljanje; da se pravočasno zagotovi oskrba z materiali,
- prodajanje; da se napoveduje in realizira oskrba kupcev,
- proizvodjanje; da se zagotovi proizvodna tehnologija in kapacitete,
- logistika; da se zagotovi embaliranje, skladiščenje in transport,
- planiranje; ki vse predhodne procese časovno in količinsko usklajuje.

2.3 Planiranje v proizvodnih podjetjih

Usklajenost in učinkovitost internih oskrbovalnih verig v proizvodnih podjetjih je odvisna od funkcije planiranja proizvodnje, ki vzdržuje ravnotežje med povpraševanjem, proizvodnjo in dobavljenimi materiali. Zaradi razlike med zahtevanimi dobavnimi časi do kupcev, ki so navadno mnogo krajši od potrebnega časa za preoblikovanje materiala v končni izdelek ali krajši od dobavnih časov materialov do proizvodnega podjetja, planiranje pretežno deluje v okolju bolj ali manj zanesljivih podatkov. Druga pomembna spremenljivka je reakcijski čas prilagoditve materialnih in proizvodnih virov spremenjenemu povpraševanju. Določene vire lahko prilagodimo relativno hitro, npr. razporeditev dela na dodaten že obstoječ stroj, določeni viri pa imajo dolg čas prilagajanja, npr. vključitev in usposabljanje novih delavcev. Zato klasični model hierarhičnega planiranja v proizvodnih podjetjih (Jacobs idr., 2018) vsebuje različne metode in tehnike, ki se razlikujejo od predmeta planiranja in od dolžine planskega horizonta. Pri tem na hierarhičnih nivojih planiranja izrabljamo različno agregirane podatke iz preteklosti (statistika poslovanja), podatke o trenutni situaciji in podatke o prihodnosti. Močnejša puščica pomeni bolj agregirane podatke (slika 1).



Slika 1: Poenostavljen klasični model hierarhičnega planiranja proizvodnje

Vir: lasten.

Planiranje prodajno/proizvodnega programa asociiramo s strateškim hierarhičnim nivojem planiranja. Predmet planiranja so trenutni in bodoči prodajno/proizvodni programi in njihove blagovne skupine, s katerimi bomo uresničili dolgoročne poslovne cilje proizvodnega podjetja. Npr. ena izmed izhodnih informacij, ki nižjim hierarhičnim nivojem planiranja pomeni usmeritev, je, kdaj bomo ukinili prodajo določene blagovne skupine. Ker gre posledično lahko za zapiranje proizvodnih linij in ukinjanje dobaviteljev, se časovno oziramo več let v prihodnost in analiziramo življenjske cikle proizvodov. Ker se »morebitne zmotke« o napačni predvideni ukinitvi linije in izhoda iz prodajnega trga ne da hitro »popraviti«, odločitve na tem nivoju povzročajo velike poslovne posledice in potrebni so dolgi reakcijski časi, da se izvedejo korekcije.

Letno poslovno planiranje ali načrtovanje asociiramo s taktičnim nivojem planiranja. Predmet planiranja so ključni predstavniki blagovnih skupin in njihove ocenjene mesečne količine, ki jih bo potrebno dobaviti kupcem tekom prihodnjega leta, da bi dosegli letne cilje poslovanja. Taktika pomeni, da razvijamo več scenarijev, kako stroškovno optimalno pokriti te mesečne potrebe s proizvodnjo, logistiko in materiali. Iz letnega planiranja poiščemo proizvodne, logistične in materialne ključne omejitve ter poiščemo rešitve zanje. Npr. ena izmed izhodnih informacij, ki nižjim nivojem planiranja pomeni usmeritev, je, da se bodo izdelki te blagovne skupine proizvajali enakomerno tekom leta. V primeru manjših mesečnih potreb se bodo proizvedeni izdelki odlagali v skladišče, v primeru večjih potreb pa se bodo iz skladišča črpali. Morebitno zmoto reakcijsko lahko hitreje saniram: uporabimo drug scenarij in navadno se v mesecu ali dveh s proizvodnimi in nabavnimi viri že lahko prilagodimo spremembi.

Osnovno (glavno) planiranje proizvodnje (MPS⁴) asociiramo s prvim od operativnih nivojev planiranja. Predmet planiranja so realni izdelki in njihove prodajne potrebe tako daleč v prihodnost, kot to določajo najdaljši dobavni časi materialov, običajno od 3 do 6 mesecev. Perioda planiranja je običajno teden. Z njim realiziramo mesečne cilje proizvodnega podjetja. Npr. izhodna informacija v proizvodnji in nabavi je, kdaj v mesecu se bo nekaj proizvajalo, kdaj se mora dobaviti določen material. Usmeritev za nižjo hierarhijo planiranja je npr., da je za realizacijo potreben 80-% izkoristek proizvodne linije. Izvaja se planiranje materialnih potreb

⁴ MPS = angl. Master Production Scheduling

(MRP) in proizvodnih kapacitet (CRP), ki je osnova za organizacijo proizvodnje. Bistveni del spreminjanja osnovnega plana proizvodnje so prodajne potrebe, če so po času ali po strukturi izdelkov zelo drugačne od planiranih v prejšnjih iteracijah oblikovanja osnovnega plana in hkrati močno odstopajo od podatkov letnega plana.

Mikroplaniranje ali razporejanje proizvodnje asociiramo z najnižjim hierarhičnim nivojem planiranja v proizvodnih podjetjih. Z vpogledom v dobavljen material (in odstopanja), v že realizirano proizvodnjo (in odstopanja), v že pokrite prodajne potrebe (in odstopanja), v testiranja novih izdelkov (in odstopanja) proizvodnji odredimo zaporedje dela, ki je z vidika njih samih (čim večji izkoristek) in celotne interne verige (nizke zaloge, malo zamud) v določenem času optimalen in materialno pokrit. Načeloma bi lahko rekli, da ima napačna odločitev relativno majhno posledico, toda zamuda prihoda enega samega materiala za en teden lahko pomeni preigravanje n možnih novih razporedov, da bi proizvodnji omogočili doseganje 80 % izkoristka.

Klasični hierarhični model planiranja kljub svojim pomanjkljivostim, ki se kažejo v nenehnem večnivojskem prenosu in usklajevanju podatkov realizacije s predvidevanji, kar zahteva mnogo ur sestankovanj med službami v interni dobavni verigi, zadovoljivo deluje v vseh oskrbovalnih modelih od razvoja po naročilu do izdelave na zalogo, obvladuje zelo široke prodajne programe, hkrati maloserijsko in velikoserijsko proizvodnjo, zelo širok spekter različnih materialov z zelo raznolikimi prodajno/nabavnimi pogoji in se kot univerzalen smatra tudi danes, saj je steber vseh poslovnih informacijskih sistemov (ERP⁵) za proizvodna podjetja. V uporabi so tudi drugi modeli planiranja (Kanban, DDMRP⁶), ki izhajajo iz odvzema izdelkov (princip »vleci«). Z vidika znižanja zalog delujejo bolje, a v zelo specifičnem (npr. masovni izdelki) in kontroliranem oskrbovalnem okolju, kjer je majhno število različic izdelkov ali pa ima podjetje v oskrbovalni verigi veliko poslovno moč, da lahko vsa tveganja preloži na dobavitelja.

⁵ ERP = angl. Enterprise Resource Planning information systems

⁶ DDMRP = angl. Demand Driven Material Requirements Planning

2.4 Računalniška orodja za podporo planiranja proizvodnje

ERP sistemi so zasnovani kot transakcijski sistemi. Beležijo poslovne dogodke, ki se procesno in hierarhično nadgrajujejo in povezujejo (Günther, 2005). Imajo ustrezno rešene prve tri hierarhične nivoje planiranja proizvodnje, nekoliko več težav imajo s podporo mikroplaniranja in razporejanja. Samo planiranje proizvodnje je učinkovito podprto šele, ko se v ERP sistemih (ali v obliki komplementarnih sistemov) pojavijo moduli za napredno planiranje in razporejanje proizvodnje (APS⁷), ki omogočajo (De Santa-Eulalia idr., 2011):

- izrabo statističnih metod za analizo podatkov,
- optimizacijo na podlagi matematičnih modelov in algoritmov,
- simulacijo in primerjavo različnih proizvodnih možnosti,
- vključevanje interne in eksterne prioritete v obliki uteži,
- celovito obravnavo učinkovitosti proizvodnega problema namesto parcialnih hevrističnih optimizacij.

Na nivoju mikroplaniranja se stalno prepleta preverjanje operativnega plana navzgor, da bi sledili agregiranim planom in posledično podpirali poslovne cilje podjetja, in navzdol s tekočo realizacijo proizvodnje, ki se navadno ne poroča direktno v ERP, ampak v namenske proizvodne sisteme, ki so namenjeni nadzoru in poročanju proizvodnje na nivoju proizvodnih linij in strojev (MES⁸) in so »podaljšek ERP« sistema na nivo delavnice. Opravka imamo z množico realnih dogodkov v proizvodnji (odpovedi, zamude, nekvaliteta, nerealizacija ipd.), ki kontinuirano prožijo potrebo po popravkih operativnega proizvodnega plana nazaj v smer, ki jo določajo višje postavljeni plani. Pred prihodom APS sistemov so planerji s pomočjo izkušenj izbrali prvo možno rešitev oz. prvi izvedljiv razpored proizvodnje. S pomočjo APS sistemov so dobili optimalno rešitev izmed možnih, tj. po večkriterijski poslovni funkciji, ki je lahko vključevala hkrati:

- čim manj zamud pri naročilih,
- popolno količinsko in časovno usklajeno materialno pokritost novega optimalnega razporeda,

⁷ APS = angl. Advanced Planning and Scheduling

⁸ MES = angl. Manufacturing Execution System

- čim manj izgub produktivnosti zaradi menjav izdelkov na linijah,
- čim nižje zaloge med posameznimi proizvodnimi fazami,
- čim bolj zasedene proizvodne zmogljivosti,
- čim bolj uravnoteženo zasedenost proizvodnih zmogljivosti po času ipd.

Do približno leta 2018 je integracija ERP in APS sistemov v strokovni javnosti obravnavana kot najbolj napredna praksa pri podpori operativnega planiranja in razporejanja proizvodnje v proizvodnih podjetjih (SCOR, 2017), z robustnimi in preverjeno delujočimi računalniškimi orodji, toda s precej neuspešnimi implementacijami: optimalno izračunan proizvodni raspored je bil tako dober, kot so bili kvalitetni vhodni matični podatki: o materialnih identih, kosovnicah, delovnih mestih, proizvodnih postopkih, operacijah, orodjih, delovnih koledarjih, na katerih je bazirala priprava proizvodnega plana in rasporeda. Če upoštevamo še zadnje spremembe v prometnih podatkih: o prodajnih naročilih in nezanesljivosti nabavne oskrbe ter različne spremembe, ki so bile rezultat nezanesljive realizacije v proizvodnji (strojelomi), je APS zahteval od proizvodnega podjetja, da zagotovi skoraj popolno - idealno poslovno, proizvodno in informacijsko okolje. To pa je v praksi težko doseči. Zato so bili uspehi APS vezani predvsem na procesno industrijo, kjer je ozek prodajni program, malo vhodnih materialov in popolna avtomatizacija proizvodnje.

3 Priložnosti naprednih digitalnih tehnologij

Napredne digitalne tehnologije so postale zanimive za vključitev v proizvodna podjetja z dostopnostjo zmogljive strojne opreme in s pojavom prvih dovolj robustnih programskih rešitev, ki same kot take niso več vzrok za povečano tveganje pri realizaciji naročil.

Robotska avtomatizacija procesov avtomatizira rutinske naloge in odločitve v procesih, npr. avtomatski odgovori, prilagojeni stranki, ki sledijo določenim smernicam/pravilom. Na ta način se delavce usmerja, da delajo na znanjsko intenzivnih nalogah. RPA je po raziskavah prva digitalna tehnologija, ki jo podjetja uporabljajo pri digitalni transformaciji oskrbovalnih verig. Uporablja se za avtomatizacijo rutinskih nalog, npr. za avtomatiziran vnos podatkov, enostavne

kalkulacije, branje in pridobivanje podatkov iz ERP sistemov. Od uporabnikov ne zahteva znanja kodiranja in razen na področju kompatibilnosti sistemov ne zahteva intenzivnega vključevanja IT oddelka.

Tehnologija veriženja blokov z decentralizacijo in kriptografskim zgoščevanjem zagotavlja zgodovino digitalnih sredstev in njeno nespreminjanje, s čimer je omogočena vidnost transakcij v realnem času po celi oskrbovalni verigi in je s tem zmanjšana verjetnost manipulacije podatkov in goljufij. Danes se v oskrbovalnih verigah najpogosteje uporablja za dokazovanje porekla materiala in za sledljivost.

Umetna inteligenca se v procesih oskrbovalne verige najpogosteje uporablja za napovedovanje različnih dogodkov. Raziskave kažejo (Banker, 2019), da se AI največ uporablja za napovedovanje prodaje, pri tem pa prilagaja algoritme značilnostim posameznih izdelkov, npr. različno za uveljavljene izdelke, različno za nove izdelke, ki nastopajo v promocijskih kampanjah, do algoritmov za izdelke, katerim bo kmalu potekel rok. AI preuči napoved, jo primerja s tekočo prodajo in predlaga menjave algoritmov. Vpletanje človeka v rezultate AI navadno vodi do slabših rezultatov. Pri tem pa slabi rezultati predvidevanja, ki je zgolj v domeni AI, povzročajo težave pri prevzemu odgovornosti, še posebno, ker je potrebno odkriti in razumeti, kako je AI prilagajala algoritme, saj so ti lahko popolnoma drugačni od začetnih. AI se uporablja tudi za analiziranje kritičnih proizvodnih parametrov in za njihovo napovedovanje, da bi bili izdelki proizvedeni skladno s specifikacijami kupca. Znane so tudi aplikacije AI za napovedovanje trajanja dela v proizvodnji, kjer z optimizacijskimi algoritmi uravnotežimo zahteve kupcev s proizvodno zmogljivostjo. Večina trenutnih implementacij AI v oskrbovalnih verigah sloni na tehnologiji strojnega učenja, ki daje najboljše rezultate pri veliki količini podatkov, imamo zagotovljeno povratno zanko za samoučenje AI in imamo dovolj časa za samoučenje AI.

3.1 Najpogosteje uporabljene tehnike pri strojnem učenju

Umetna inteligenca, ki temelji na tehnologiji strojnega učenja, kombinira različne tehnike umetnih nevronske mreže, mehke logike, agentne sisteme, genetske algoritme in podatkovno rudarjenje (Toorajipour idr., 2021).

Tehnika umetnih nevronskih mrež (ANN⁹) se uporablja za iskanje vzorcev, modelov ali znanja. Zaradi svoje vsestranskosti se uporablja kot glavna tehnika v računski inteligenci na različnih področjih oskrbovalne verige: trženje, napovedovanje proizvodnje, oblikovanje cen, izbira dobaviteljev.

Tehnika mehke logike (FL¹⁰) predstavlja mejo med tehnikami umetne inteligence in tiste brez nje. Posnema interpretacijo kvantitativnih podatkov, še posebej mejnih vrednosti na kvalitativen način, kot jih interpretiramo ljudje, npr. kaj je še dobro, kaj slabo.

Tehnika agentnih sistemov (ABS¹¹ in MAS¹²) temelji na agentu oz. vrsti računskega modela, ki simulira dejanja in interakcije avtonomnih agentov, kolektivno ali individualno, ter istočasno ocenjuje njihov splošni vpliv na sistem. Agenti so entitete, ki so sposobne zaznavanja okolja in lahko delujejo samostojno in proaktivno pri reševanju določenih težav. Ko je agentov več in ti lahko med seboj sodelujejo, govorimo o mreži agentov.

Tehnika genetskih algoritmov (GA¹³) posnema tri naravne zakone: naravno selekcijo, križanje in mutacije. S pomočjo njih se algoritem razvije do te mere, da problem primerno reši z dovolj dobro rešitvijo (lahko tudi optimalno). Ti algoritmi kodirajo potencialne rešitve določenih problemov z uporabo podatkovne strukture, ki je podobna obliki kromosoma. GA se uporablja na širšem problemskem območju oskrbovalnih verig, najpogosteje za iskanje dovolj dobrih rešitev problemov v prodaji in proizvodnji. Odlikuje jo hitrost reševanja.

Tehnika podatkovnega rudarjenja¹⁴ se je razvila zaradi težav s prepoznavanjem znanja v obsežnih podatkovnih zbirkah, ki lahko predstavlja pomembne informacije za odločanje v podjetjih. Rudarjenje podatkov se na področju oskrbovalnih verig uporablja za nadzor in spremljanje zalog, izboljšanje managementa znanja in trženje.

⁹ ANN = angl. Artificial Neural Networks

¹⁰ FL = angl. Fuzzy Logic and models

¹¹ ABS = angl. Agent - Based Systems

¹² MAS = angl. Multi - Agent Systems

¹³ GA = angl. Genetic Algorithms

¹⁴ angl. Data Mining

3.2 Uporaba strojnega učenja pri planiranju proizvodnje

Raziskave trdijo, da se umetna inteligenca trenutno največ izkorišča za podporo najnižjega hierarhičnega nivoja planiranja - operativnega planiranja in razporejanja proizvodnje. Na tem nivoju planiranja se sprejema glavna odločitev, ki pomembno vplivajo na konkurenčnost proizvodnega podjetja preko zniževanja stroškov in izpolnjevanja dobavnih rokov. V dobro informacijsko podprti proizvodni delavnici se dnevno generira masovna količina podatkov, v katerih se skriva koristno znanje, ki ga s klasičnimi analizami podatkov težko hitro prepoznamo. Prav to pa omogoča koristno izrabo predvsem tehnologije strojnega učenja za napovedovanje proizvodnje in soočanje s predvidenimi in nepredvidenimi dogodki (Kang idr., 2020). To je prepoznala tudi večina industrijsko razvitih držav, ki so digitalizacijo tega področja uvrstile na prioriteto listo digitalizacije proizvodnih podjetij (Cadavid idr., 2019):

- Nemčija preko paradigme Industry 4.0,
- ZDA preko paradigme Smart Manufacturing Leadership Coalition,
- Kitajska preko strategije China Manufacturing 2025,
- Evropa preko smernic Factories of the Future.

Strojno učenje uporablja različne poslovne in proizvodne podatke podjetja kot osnovni »material« za razvoj avtonomnega računalniškega znanja. Pomembno je, da so ti podatki ustrezni, saj le tako nudijo smiselne rezultate. Tao (2018) ugotavlja, da mora imeti strojno učenje za namen operativnega planiranja in razporejanja proizvodnje dostop do naslednjih virov podatkov:

- podatki vodenja proizvodnje; pretekle informacije, shranjene v proizvodnih informacijskih sistemih (MES, ERP, CRM ...), ki zajemajo informacije o planiranju proizvodnje, vzdrževanju, prodaji,
- podatki opreme; izvirajo iz IoT¹⁵ in ponujajo zabeležene informacije o delavcih, strojih, delovnih postajah,
- uporabniški podatki; izhajajo iz informacij uporabnikov izdelkov, ki se jih pridobi s pomočjo interneta,

¹⁵ IoT = angl. Internet of Things

- podatki produkta; izhajajo iz produkta oziroma storitve in se pridobijo tekom proizvodnega procesa oziroma iz zahtev kupcev,
- javni podatki; prihajajo iz odprtih baz podatkov, kot so na primer vladni podatki, podatki drugih raziskovalcev,
- umetni podatki; vezani na informacije, generirane s strani računalnika za dostop do aplikacij strojnega učenja v procesu planiranja proizvodnje.

Konceptualno gledano lahko strojno učenje smatramo kot najbolj napredno tehnologijo, ki je vključena v APS sisteme. Z njo pa se zamenjuje tudi vloga podatkov, ki jih hranimo v ERP, APS in MES sistemih. Po obstoječi proceduri za izboljšanje planiranja smo morali v ERP opredeliti čim bolj točne proizvodne matične podatke, na podlagi katerih je ERP grobo terminiral delo, da je lahko naročil potrebne materiale. Podatke je nato uporabil APS in s pomočjo naprednih algoritmov določil optimalni razpored dela v proizvodnji na mikro nivoju. Ta razpored se je kot »želja« prenesel v MES sistem. Delavci so predlagani razpored zaradi različnih realnih dogodkov bolj ali manj upoštevali. Informacije o dejanski realizaciji je hranil MES. Podatki o realizaciji so se nato prenesli nazaj v ERP sistem, kjer so analitiki ugotavljali razloge odstopanj in po potrebi korigirali matične podatke v ERP, ki bi jih APS uporabil za bolj točen plan. Toda pozor: matični podatki v ERP so tisti podatki, po katerih je posel »prodan« kupcu. Torej je bilo potrebno dodatno kreirati ter prilagajati verzije matičnih podatkov, ki so bile namenjene APS za boljšo optimizacijo razporedov. Če povzamemo, so bili vsi naporji usmerjeni v:

- pridobitev čim bolj točnih matičnih podatkov v ERP sistemih za izračunavanje trajanja delovnih nalog,
- iskanje in statistično obdelavo podatkov o dogodkih v MES sistemih, ki so vplivali na to, da se optimalen plan ni realiziral, ter posledično v dodajanje »ohlapnosti« na proizvodne entitete v ERP, ki so zato »stalno« odstopale od nazivnih vrednosti.

Z uporabo strojnega učenja se pomembnost točnih matičnih podatkov v ERP za potrebe planiranja, da bi ustrezali trenutni sposobnosti proizvodnega procesa, zmanjšuje. V ERP še vedno zapisujemo matične podatke, ki so preko ciljnih stroškov dela in materiala »prodani« kupcu. To so ciljne vrednosti, ki ji v fazi uvajanja izdelka

v proizvodnjo navadno ne dosegamo, v vrhu življenjskega cikla pa smo celo boljši. APS sistemi, opremljeni s tehnologijo strojnega učenja, za prve iteracije proizvodnje (poskusne serije) seveda nimajo drugih podatkov, kot da vzamejo matične podatke iz ERP sistema. Toda že prvo učenje s podatki o realizaciji iz MES sistema povzroči, da si APS začne pripravljati svojo bazo matičnih podatkov. Pri tem upošteva tudi vpliv zaznanih dogodkov, izpadov ipd. Torej že pri novi iteraciji priprave trajanja delovnih nalog za proizvodnjo enakega izdelka ML izdela plan na podlagi »prilagojenih matičnih podatkov« in z upoštevanjem »množice drugih pomembnih podatkov iz statistike MES«, da so plani realistični in s tem usklajena proizvodnja na način, da bodo doseženi dobavni termini kupca. Če povzamemo:

- bazo podatkov, ki so namenjeni pripravi realističnega plana, ima APS in se stalno spreminja na podlagi strojnega učenja, podatki v ERP so namenjeni za primerjalne analize,
- bistveno se spreminja vloga MES (Koelesch, 2019), ki mora beležiti vse vrste podatkov o dogodkih in razmerah, v katerih se proizvaja (pridobljenih iz naprav, linij, senzorjev, delavcev). Čim več teh različnih podatkov lahko obdelata strojno učenje, vgrajeno v APS, bolj točno bo razumevanje, kaj vpliva na proizvodnjo v določenih okoliščinah, boljša bo priprava optimalnih planov in razporedov.

Raziskovalci trdijo, da je po prihodu nove generacije APS sistemov, ki bazirajo na strojnem učenju, nastala tudi obvezna potreba po novi generaciji inteligentnih MES sistemov, ki s podporo obdelave masovnih industrijskih podatkov prehajajo iz analize vzrokov k analizi asociacij (Zhang idr., 2019).

4 Izzivi uporabe umetne inteligence pri razporejanju proizvodnje

Raziskali smo dve skupini virov, kjer smo poskušali odkriti izzive, s katerimi se soočajo proizvodna podjetja pri izrabi umetne inteligence pri razporejanju proizvodnje. Na vrhnjem nivoju smo izzive razdelili na tiste, ki so prepoznani v novejši znanstveni literaturi (ALR¹⁶), in tiste, ki so prepoznani v novejši strokovni

¹⁶ ALR = angl. Academic Literature Research

literaturi (NALR¹⁷). Raziskane izzive smo v naslednjem poglavju primerjali z izzivi analize primera.

4.1 Raziskava izzivov iz znanstvenih publikacij

Pregled ALR smo izvedli na platformi ScienceDirect in se ciljno usmerili na raziskave, objavljene v revijah in založbah nivoja založbe Elsevier v zadnjih petih letih (do novembra 2021). Uporabili smo ključni besedi »artificial intelligence« in »production planning« in dobili preko 6000 zadetkov.

Korist 1: Izboljšanje izkoristka proizvodnih kapacitet in povečanje dobavne zanesljivosti

Z uporabo ML pri operativnem planiranju je omogočeno (Kang idr., 2020), da odkrivamo in napovedujemo napake na izdelkih, ki so posledica proizvodjanja. Posledično lahko napovemo tudi prekinitve in s tem izpade v razpoložljivosti proizvodnih kapacitet. Prav tako je možno določiti najbolj optimalne nastavitve proizvodnih linij za proizvodnjo kakovostno skladnih izdelkov in s tem maksimalno zmanjšati izgube proizvodnih kapacitet (»Do It Right First Time«). S predvidevanjem okvar tudi lahko izvedemo preventivne vzdrževalne posege takrat, ko je z vidika zasedenosti kapacitet najmanj škodljivo za realizacijo posla. V vseh treh primerih to pomeni tudi večjo zanesljivost doseganja planiranih rokov do kupcev. **Izzivi:**

- ML mora imeti dostop do velike količine proizvodnih podatkov. To je najlažje zagotoviti, če ima podjetje stroje, linije, izdelke in procese opremljene s tehnologijo IoT in povezane v stabilno računalniško infrastrukturo. V realnem okolju imamo v postrojenjih tudi stroje, ki so popolnoma neopremljeni, da bi avtomatsko beležili in posredovali proizvodne podatke. V večini primerov jih namesto stroja beleži človek in kvaliteta vhodnih podatkov v obdelavo ML je temu primerno manj zanesljiva.
- ML bo lahko v smislu operativnega planiranja kvalitetno napovedoval razpoložljivost določene naprave, če ima tudi odprt

¹⁷ NALR = angl. Non-Academic Literature Research

dostop do zunanjih podatkov o enakih strojih pri drugih uporabnikih. Te podatke navadno zbirajo proizvajalci opreme in jih shranjujejo v »oblaku« ter so tako na voljo vsem. Izziv je, da podjetja niso pripravljena deliti svojih internih podatkov javnosti in konkurenci, vsaj ne v takem obsegu in vsebini, da bi lahko ML imel od tega korist.

Korist 2: Povečana produktivnost proizvodnje in nižji stroški proizvodnje

Raziskava kaže (Phuyal idr., 2020), da je s pomočjo ML pri operativnem planiranju možno doseči v povprečju 20-% povečano produktivnost v proizvodnji in pri izkoristku energije, saj ML izbira v vsakem trenutku prioriteten proizvodni razpored z izrabo strojev, ki so energetskega najmanj potratni. Prav tako je možno doseči celo 50-% večjo produktivnost planskega osebja, ki je odgovorno za pripravo optimalnih proizvodnih planov, saj ML s sposobnostjo samoodločanja, samooptimiziranja in samodejnega odzivanja na zaznane fizične spremembe v proizvodnji lahko neskončno mnogokrat spreminja in prilagaja urnike proizvodnje in upošteva samo rešitve, ki so izvedljive z vidika razpoložljivosti vseh virov in hkrati čim bližje želenim poslovnim KPI. **Izzivi:**

- doseči, da so podatki iz obratovanja proizvodnih sistemov povezani z načrtovanjem produkta, analitiko, razvojem proizvodnega procesa, sistemom zalog in dobavno verigo, kar naredi proizvodnjo na zahtevo (prilagajanje izdelkov in proizvodnega procesa) bolj učinkovito. Če so vsi novejši izdelki v razvoju planirani, da se obvezno izdelujejo na najbolj produktivnih strojih, ker le tako lahko dosežemo pričakovano nizke stroške izdelave, ti stroji so pa že danes ozka grla, nam ML težko pomaga doseči koristi z optimalnimi razporedi. Paradoks: ML nam lahko odkrije, na kateri »prepovedan« stroj proizvodnja »samovoljno« razporeja delo, ki je prepovedano po matičnih podatkih ERP sistema, in ga pri pripravi novih razporedov (če ugotovi, da koristi) »samovoljno« vključuje v iskanje optimalne rešitve;
- doseči zaupanje planskega in proizvodnega osebja, da so ML razporedi delovnih nalog pripravljeni »optimalno« in z nadzorom razpoložljivosti materiala. Po nekem času ML tako prilagodi začetno

pripravljene algoritme, da je težko odkriti oziroma pojasniti, zakaj ML smatra, da je določen razpored optimalen. Še posebno, če globalna idealna rešitev pomeni popolnoma neoptimalen razpored v neki lokalni delavnici. Trenutne rešitve ML delujejo po principu »črne škatle« in ne pojasnjuje zainteresirani javnosti, tako kot morajo planerji, zakaj je neoptimalen razpored pri mojstru »a« odličen za podjetje kot celoto. Paradoks glede produktivnosti planerjev: planerji v povprečju trdijo, da cca. 20 % svojega časa porabijo za dokazovanje optimalnosti razporeda zainteresirani javnosti - iskanje podatkov, analiza podatkov s pripravo prezentacije in utemeljitve.

Korist 3: Hitrejša odzivnost in prilagodljivost proizvodnje na spremembe

V močno robotizirani in avtomatizirani proizvodnji ima ML v zadnji fazi operativnega planiranja – odrejanju ali lansiranju proizvodnje tudi dovoljenje, da preko »oddaljenega upravljanja nastavitve strojev« spremeni oz. krmili proizvodni proces v smeri zelene spremembe razporeda. Ob hkrati sočasnemu pridobivanju realnih podatkov iz strojev o trenutnem stanju so zakasnitve v reakcijskem času na izvedbo prilagoditev strojev zanemarljive (Jasko idr., 2020). **Izzivi:**

- Uvedba ML v operativno planiranje posega tako v delo planerja proizvodnega oddelka kot v delo mojstra v proizvodnem oddelku. Izziv je, kako doseči, da človek s »svojo pomembnostjo« ne bo namerno ustavljal procesa. Trenutno se z vidika RPA priporoča hibridna vključitev ML v operativno planiranje (ML + planer), kljub temu da je dokazano, da vmešavanje človeka v ML rešitev večinoma poslabša rešitev.
- Zbiranje podatkov iz ročnih delovnih mest za obdelavo ML (maloserijska, unikatna proizvodnja). Ti podatki so tudi danes v večini zajeti v MES, vendar kot omenjeno, je težava zaupanje v zbrane in pridobljene podatke, če jih poročajo zaposleni. Delavci se pozabijo prijaviti, odjaviti, javiti zastoj in zgolj »ocenjujejo« njegovo trajanje. Ideje so, da bi v primeru ročne proizvodnje avtomatsko zbiranje podatkov prepustili izdelku: ta bi prepoznaval delo, ki se na njem izvaja, trajanje ipd. S tem bi zagotovili dobre podatke za ML pri pripravi optimalnih razporedov proizvodnje.

Ima pa vključitev ML na področje operativnega planiranja tudi **splošne izzive** (Pyuyal idr., 2020):

- **Varnost podatkov;** v pametni proizvodnji se uporablja integriran mrežni sistem za delitev informacij med posameznimi segmenti. Za ta namen se običajno uporablja internet. Ta način deljenja podatkov zahteva varnost podatkov in informacij v celotnem sistemu na različnih točkah z globalno edinstveno identifikacijo in šifriranjem podatkov. Zaščititi je treba vsako vozlišče omrežja, da se izognemo zunanjim napadom in zlorabi podatkov. Zato je pomembno, da pri načrtovanju omrežnih sistemov zagotovimo varnost sistema in s tem celotnega procesa planiranja.
- **Povračilo naložbe** v novo tehnologijo in istočasno finančne težave med postavljanjem nove pametne proizvodnje ali pa nadgradnje obstoječe. Kljub temu da nove tehnologije, tudi ML, za planiranje proizvodnje postajajo cenovno dostopne, je na trgu premalo implementacij, še posebno v podobnih proizvodnjah, da bi lahko z gotovostjo trdili, da se bo implementacija povrnila. StartUp podjetja navadno odlično obvladajo novo tehnologijo, a imajo premalo izkušenj, ko govorijo o enostavnosti njene implementacije v proizvodni sistem. Več o tem bomo prikazali v nadaljevanju pri analizi primera.
- **Sistemska integracija:** velik izziv predstavlja implementacija pametne proizvodnje v že obstoječo programsko in strojno računalniško opremo. Obstoječa oprema je lahko stara in zato velikokrat ni kompatibilna z novo tehnologijo.

4.2 Raziskava izzivov iz strokovnih publikacij

Korist 1: Izboljšanje izkoristka proizvodnih virov in tržnih priložnosti ter izničenje vpliva negotovosti in motenj

Analitska hiša Gartner ugotavlja (Salley idr., 2021), da podjetja intenzivno raziskujejo AI in druge novejšje digitalne tehnologije za reševanje izzivov na vseh štirih ključnih problemskih področjih, ki vplivajo na kakovost planiranja proizvodnje (Payne, 2019):

- negotovost; vključuje izziv negotovosti v povpraševanju v obliki spreminjajočih potreb kupcev in negotovosti na strani oskrbe, ki se kaže v nezanesljivosti dobavnih akcij in motenj v sami proizvodnji,
- pristranskost; predstavlja izziv vpliva odločitev človeka – planerja na pripravo proizvodnih planov,
- podatki; vključuje izzive, povezane z razpoložljivostjo, kakovostjo in starostjo razpoložljivih podatkov,
- model planiranja; izziv predstavlja tudi preciznost uporabljenega modela (njegova izbira), ki se uporablja za sprejemanje odločitev pri planiranju, in kako odraža razmere v resničnem svetu.

Z uporabo kompleksnih matematičnih algoritmov (npr. tehnologije genetskih algoritmov) se poskuša skrajšati čas priprave optimalnih proizvodnih planov in pri procesu odločanja zajeti čim več razpoložljivih podatkov ter s tem pospešiti in izboljšati odzivnost proizvodnje na trenutne in prihajajoče spremembe. ML nastopa v skupku tehnologij, ki so namenjena digitalizaciji procesa planiranja proizvodnje, in vključuje tudi tehnologije »obdelave masovnih podatkov«, »računalništva v oblaku« in RPA, s katerimi se želi izboljšati kvaliteto procesa odločanja pri planiranju proizvodnje in robustnost planiranja. Slednje pomeni, da se »odpornost proti negotovosti« dosega z vključenostjo ML na nivoju srednjeročnih in dolgoročnih planov, ki pokrivajo optimum celotnega procesa, na drugi strani pa z integracijo ML na kratkoročne proizvodne plane, kjer blažimo negotovost na nivoju izvedljivosti v proizvodnji. Ta značilnost izboljšuje »prilagodljivost ali prožnost planiranja« na način, da algoritem kratkoročnega planiranja ne optimizira vedno celotnega procesa proizvodnje, ampak zgolj lokalno posamezne dele, da se zagotovi izvedljivost plana na nivoju proizvodne delavnice. **Izzivi:**

- prepustiti ML upravljanje matičnih podatkov (samostojno prepoznavanje anomalij v podatkih, ki jih samostojno prečisti in popravlja),
- zagotoviti vključitev podatkov o trenutnih razmerah na nivoju izvajanja (npr. spremembe v naročilih) v proces odločanja prilagajanja planov na višjih hierarhičnih nivojih (in nazaj), s pogledom preko celotnega E2E procesa,

- vzpostaviti zaupanje v ML pri pripravi predlogov optimalnih proizvodnih planov (avtomatizirana priprava odločitev).

Korist 2: Znižanje stroškov priprave proizvodnih planov, posledično skrajšanje dobavnih časov

Združenje APQC (Brown, 2020) na vzorcu 554 podjetij ugotavlja, da podjetja, ki imajo v proces planiranja implementirano napredno analitiko in napovedne algoritme, dosegajo v povprečju za 9 % krajše dobavne čase do kupcev kot podjetja, kjer odločitve pri pripravi planov bazirajo le na izkušnjah človeka, in za 5,5 % krajše od podjetij, kjer priprava planov vključuje klasično statistično analizo preteklih odločitev in posledic. **Izzivi:**

- zelo različna ponudba novih digitalnih tehnologij naslavlja koristnost uporabe pri planiranju proizvodnje, od napovedne analitike, rešitev v oblaku, RPA, AI ipd., kar vodi do izbire nekompatibilnih platform in težav z upravičevanjem koristi nove tehnologije. Priporoča se sistematičen pristop, ki natančno naslavlja doseganje zelenih ciljev v podjetju in na samem procesu planiranja.
- Izboljšanje planiranja ne dosegamo z najboljšo digitalno tehnologijo na trgu, najbolj celovitimi naprednimi algoritmi ML ipd. Ključno je, kako se z uporabo digitalne tehnologije izboljša konkreten proces planiranja, kako bo bolje izpolnjevalo proizvodne in poslovne zahteve.

Korist 3: Konkurenčna prednost

Združenje ASCM (James, 2021) je med 10 ključnih trendov za izboljšanje konkurenčnosti oskrbovalnih verig za leto 2022 kar v tri uvrstilo tehnologijo ML: na področje napredne analitike, na področje avtomatizacije procesov v oskrbovalnih verigah (vključuje planiranje proizvodnje) in na področju industrije 5.0, ki vključuje sodelovanje oz. partnerstvo med ljudmi in roboti. **Izzivi:**

- Predvidevajo, da bo imelo prav sodelovanje med ljudmi in roboti največji vpliv na procese planiranja in izpolnjevanja naročil. Zato je

potrebno zagotoviti tudi pametne stroje, ki bodo omogočili še bolj kvalitetne podatke in vpogled v resnično dogajanje na mikro nivoju proizvodnje, kar bo vodilo do še boljših odločitev ML. Za večino proizvodnih podjetij bo to velik finančni zalogaj.

V tabeli 2 smo na podlagi raziskave in predstavitve izbora znanstvenih in strokovnih virov razvrstili neposredne in posredne izzive uvajanja ML na področje operativnega planiranja in razporejanja proizvodnje. Razvrstili smo jih v dve kategoriji: tiste, ki jih je potrebno rešiti pred projektom digitalizacije, in tiste, ki jih je potrebno rešiti med projektom digitalizacije.

Tabela 2: Izzivi uvajanja ML na področje operativnega planiranja in razporejanja proizvodnje

Področje izziva	Izziv
I. Izzivi, ki jih je potrebno razrešiti pred implementacijo ML	
1. Strateško načrtovanje	<ul style="list-style-type: none"> – izbrati sistematičen pristop, ki natančno naslavlja doseganje zelenih ciljev v podjetju in na samem procesu planiranja, – izbrati ML rešitev, ki ustreza značilnostim procesa proizvodnje in operativnega planiranja. Merilo so KPI za izboljšanje procesa planiranja (in ne za izbor najbolj napredne ML tehnologije), – v dogovoru s ponudnikom rešitve izbrati način za povračilo naložbe v novo tehnologijo, ki je vezan na neposredne in posredne koristi.
2. Informacijska infrastruktura	<ul style="list-style-type: none"> – pred uvajanjem zagotoviti stabilno strojno in mrežno infrastrukturo na nivoju proizvodne delavnice, – zagotovitev informacijske varnosti.
3. Kompatibilnost info. sistemov	<ul style="list-style-type: none"> – zagotoviti popolno vertikalno in horizontalno integracijo in kompatibilnost med vsemi obstoječimi IS podjetja, ki se jih uporablja v procesu planiranja in realizacije naročila, – izbrati rešitev ML na platformi, ki je kompatibilna z informacijskimi sistemi, še posebno z ERP in MES.
II. Izzivi, ki jih je potrebno razrešiti med implementacijo ML	
4. Razpoložljivost podatkov	<ul style="list-style-type: none"> – zagotoviti dostop do velike količine prometnih proizvodnih podatkov iz proizvodnega procesa s pametnimi stroji (izziv zastarelih strojev), – zagotoviti vključitev podatkov o trenutnih razmerah na nivoju izvajanja (npr. spremembe v naročilih) v proces prilagajanja planov na višjih hierarhičnih nivojih (in nazaj), s pogledom preko celotnega E2E procesa, – zagotoviti dostop do podatkov izven poslovnega sistema.
5. Upravljanje podatkov	<ul style="list-style-type: none"> – prepustiti ML upravljanje matičnih podatkov, – umakniti človeka iz kreiranja prometnih proizvodnih podatkov v proizvodnem procesu.

Področje izziva	Izziv
6. Prehod	– v uvajanje ML že v začetek projekta vključiti planerje in mojstre iz proizvodnje in s tem vzpostaviti zaupanje da so avtomatizirano (z algoritmi) pripravljeni razporedi optimalni.

V nadaljevanju bomo z analizo primera ugotavljali, koliko se izsledki raziskav o izzivih iz znanstvene in strokovne literature ujemajo s konkretnim projektom implementacije nove digitalne tehnologije v konkretno proizvodno podjetje.

5 Analiza primera

Primer bazira na večjem slovenskem podjetju¹⁸, ki ima širok proizvodni program: od izdelkov za končnega kupca do izdelkov, namenjenih kot sklopi za vgradnjo v kompleksne izdelke. Podjetje ima več proizvodnih obratov v Sloveniji in v tujini. Dominantno sodeluje v mednarodnih globalnih oskrbovalnih verigah, ki obsegajo transportne poti čez celo zemeljsko oblo.

5.1 Strateško načrtovanje uvedbe digitalizacije operativnega planiranja

Podjetje je leta 2019 začelo razvijati »strategijo poslovanja« za obdobje 2020 do 2025 in kot eno strateških aktivnosti za to obdobje identificiralo »SA-digitalizacijo procesov«. Eden izmed začetnih izdelkov te aktivnosti, ki določa smernice digitalizacije, je bila priprava »digitalne strategije«, ki je pokrivala želeno stanje digitalizacije procesov v obdobju 2022 do 2027, in je bila pripravljena leta 2021. Vključevala je:

- metodologijo priprave digitalne strategije; ki je izhajala iz priporočil priprave digitalnih strategij podjetja Gartner in Siemens,
- identifikacijo 440 bolečin v vseh procesih, od poslovnih do proizvodnih; to so bili izzivi (ne samo informacijski), zaradi katerih podjetje že danes ne dosega planiranih poslovnih rezultatov, postavljenih za leto 2025 in zapisanih v »strategiji poslovanja«. Podjetje se ni lotilo detajlnega posnetka procesov. Izdelalo je grobo mrežo procesov in ključnih medsebojnih relacij, da je z vključitvijo v

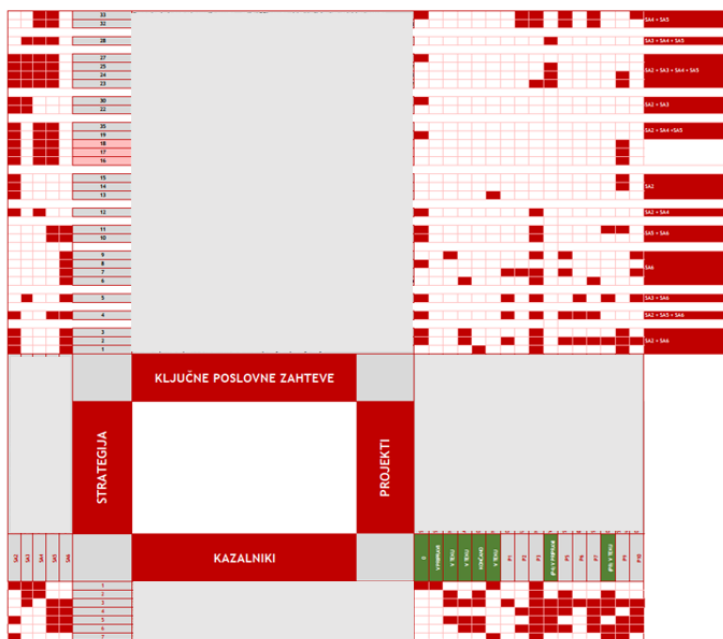
¹⁸ Zaradi varovanja konkurenčne prednosti se za dostop do podrobnih podatkov, ki dokazujejo verodostojnost analize primera ali jih želite uporabiti pri nadaljnjih raziskavah, obrnite na prvega avtorja prispevka.

time zagotovilo popolno vsebinsko pokritje celotnih E2E procesov, vključno s povezanimi procesi,

- po grupaciji bolečin po podobnosti in identificiranih izvornih vzrokih se je za celo podjetje oblikovala »lista 35 ključnih poslovnih zahtev«, ki jih je potrebno izpolniti/izboljšati v procesih podjetja. Seznam ključnih poslovnih zahtev sta obdelali skupina internih ekspertov za informacijsko-komunikacijsko tehnologijo, digitalizacijo, podatkovno analitiko in skupina vsebinskih specialistov s posameznih področij podjetja, kombinirana z zunanjimi eksperti, z namenom, da ocenita, kakšen je možen doprinos izrabe digitalnih oz. IKT¹⁹ tehnologij k uresničitvi posamezne poslovne zahteve in kakšna je zahtevana radikalnost spremembe, ki jo prinaša predlagana digitalna oz. IKT tehnologija glede na trenutno stanje. Izločilo se je zahteve brez ocenjenega doprinosa IKT,
- nato se je s sodelavci, ki so jih predlagali direktorji poslovnih področij, pristopilo k nizanju idejnih predlogov digitalnih projektov, ki lahko prispevajo k izpolnjevanju ključnih poslovnih zahtev, vključno s presojo vključitve digitalnih projektov, ki so bili že v delu v času priprave »strategije digitalizacije«. Predlaganih je bilo 33 projektov z različnih področij, ki so se glede na skupne značilnosti agregirali v 10 usklajenih predlogov projektov za digitalizacijo v podjetju za predvideno obdobje (slika 2). Matrika opisuje relacije med strategijo podjetja, poslovnimi zahtevami do procesov in izbranimi digitalnimi projekti ter nabor KPI, s katerimi projekti direktno naslavlja želene vrednosti strateških poslovnih rezultatov²⁰.

¹⁹ IKT = informacijsko-komunikacijske tehnologije

²⁰ Vsebina je zamegljena zaradi poslovne tajnosti.



Slika 2: Matrika digitalnih projektov podjetja


Vir: lasten.

Po predstavljenem postopku se je cca. 10 % prepoznanih bolečin v procesih poenotilo v poslovno zahtevo »uravnotežen proizvodni raspored (manj zamud naročil, višja zasedenost kapacitet, bolj enakomerna zasedenost kapacitet, z manj menjalnimi časi, z nižjimi zalogami polizdelkov) je pridobljen v realnem času«. Poslovna zahteva je naslavljala projekt »Uvedba umetne inteligence za predvidevanje in sestavo optimalnih proizvodnih rasporedov«, ki je bil aktiven že v času priprave »strategije digitalizacije«. S tem je bil tudi revidiran pomen projekta v smislu utemeljene umeščenosti v »strategijo digitalizacije« in podpiranja »strategije poslovanja podjetja«.

5.2 Značilnosti proizvodnega procesa

Prva predprojektna aktivnost je vključevala detaljne posnetke zahtev procesov operativnega planiranja in same proizvodnje. Podjetje ni imelo izkušenj z uvedbo ML tehnologije v različna področja poslovanja. Za vzpostavitev zaupanja v koristi nove tehnologije, minimiziranje tveganja za neuspeh in nadzor nad porabo stroškov,

se je najprej implementacija izvedla na enem proizvodnem obratu. Njegove splošne značilnosti so predstavljene na sliki 3:



Slika 3: Shema kapacitivnih mest, delavnic skladišč in glavni materialni tokovi podjetja
Vir: lasten.

Na dan 1. 1. 2022 je bila proizvodnja razdeljena na 3 proizvodne oddelke, ki imajo skupaj 60 oskrbovanih kapacitivnih mest in so znotraj oddelkov razporejena po »delavnični razporeditvi«. Stroji znotraj posamezne delavnice so istovrstni, na večini kapacitivnih mest so avtomatsko krmiljeni, človek opravlja funkcijo strežbe materiala in odvoza polizdelkov ali izdelkov. Stroji so v prvi fazi proizvodnje univerzalni glede izdelkov (znani so dovoljeni alternativni stroji). V drugi fazi proizvodnje (če je potrebna) so tako univerzalni (namenjeni izdelavi različnih izdelkov) kot specialni stroji (vezani na izdelavo določenega izdelka). Nekaj delovnih mest v drugi fazi proizvodnega procesa (če jo izdelek potrebuje) je ročnih. Vsi stroji so povezani v WiFi omrežje. Prometni podatki iz strojev se preko SCADA sistema neposredno beležijo v MES preko brezžičnega omrežja. Proizvodni delavec je v funkciji potrjevanja in izvedbe morebitnih korekcij podatkov zaradi nepričakovanih dogodkov. Iz MES se podatki posredujejo v različne prometne entitete ERP sistema. Osnovni zapisi o zastojih se beležijo avtomatsko (trajanje), deloma stanja dogodkov opredeli človek (vrsta zastoja).

Izdelki se večinoma proizvajajo z uporabo orodij. Znotraj prve faze proizvodnje se v celoti proizvedejo na enem stroju, v drugi fazi proizvodnje gredo lahko čez več različnih kapacitivnih mest (odvisno od proizvodnega postopka). Nekatera kapacitivna mesta v drugi fazi so aktivna le občasno, da se zagotovi skladnost izdelka po specifikacijah kupca. Na dan 1. 1. 2022 je celotni obrat operiral s 160 različnimi vhodnimi materiali in 620 različnimi polizdelki in izdelki.

Z vidika operativnega planiranja in razporejanja proizvodnje obvladujeta obrat 2 planerja. Prvi pokriva prvo fazo proizvodnje, drugi drugo fazo proizvodnje. Za planiranje se uporablja ERP sistem, razporejanje dela (zaporedje) po strojih se izvaja v MES sistemu. Planerji morajo na mikro nivoju sočasno delati hkrati z obema sistemoma. Vsaka želena ali potrebna sprememba v zaporedju dela na nekem stroju v oddelku proizvodnje (MES) mora obvezno skozi ERP kontrolo pokritosti materialov in medoddelčno sinhronizacijo, preden je s strani obeh planerjev potrjena.

Značilnosti proizvodnje

- **Nestabilen proizvodni proces** (ob zagonu in tekom izvajanja); s strojem in orodjem je zelo težko ujeti skladnost izdelkov s specifikacijami. Pogoste so odpovedi orodja ali stroja. To zahteva pogosto spreminjanje zaporedov.
- **Nestabilen prodajni proces**; razlike med napovedmi in dejanskimi odpoklici so velike ($MAPE^{21} > 100\%$), dobavni časi kupcem so kratki ($LT^{22}_{kupca} \ll LT_{materiala}$). To zahteva pogoste spremembe v zaporedju proizvodnje.
- **Vhodni materiali so logistično zahtevni** (teža); ko je embalažna enota materiala na stroju (v uporabi), je racionalno, da se jo porabi do konca. S tem se proizvaja več, kot je določeno s proizvodnim zaporedom.
- **Nestabilen nabavni proces**; materiali so globalni in odvisni od dolgih transportnih časov. Pogosto zamujajo ali prispe le del

²¹ MAPE = angl. Mean Absolute Percentage Error

²² LT = angl. Lead Time

naročene količine. To vpliva na pogoste spremembe v razporedu proizvodnje.

- **Nezanesljivi vhodi razvojnih testiranj** v redno proizvodnjo; imajo posebne značilnosti glede dovoljene proizvodne izmene testiranja, nezanesljivo trajanje in rok začetka testiranja, kar zahteva spreminjanje postavljenih razporedov.
- **Z orodjem se hkrati proizvaja več različnih izdelkov.** Pogosto je primer, da ima en izdelek večji izmet kot drugi. Kar pomeni, da se »obvezno« proizvodja tudi izdelek, ki ga sploh ne potrebujemo.
- **Alternativni stroji imajo različno izmensko/dnevno zmogljivost.** Pri iskanju alternativnega razporeda je potrebno na novo prerazporediti oskrbo in posledično proizvodnjo.
- **Matični tehnološki podatki** (proizvodni postopek in normativi), ki se uporabljajo za izračunavanje trajanja proizvodnih nalogov in posledično za pripravo razporedov, so pripravljene na obdobje v življenjskem ciklu izdelka, ko bo proizvodnja optimizirana. To povzroča stalne korekcije sicer nerealnih razporedov, da so plani pripravljene na zmogljivost proizvodnje.
- problemi s **sekundarnimi omejitvami**: zaradi različnih razlogov zmanjka delavcev (s pravim znanjem) za posluževanje strojev in se zahteva spremembe mikro razporedov; kupec zadržuje vračanje ekskluzivne vračljive embalaže in ni možno proizvajati – polniti (ali se proizvaja v alternativno embalažo), zato je treba prilagajati razporede na mikro nivoju.
- Lahko se pojavi tudi **logistični razlog** za spremembo razporeda, npr. nerazpoložljivost skladišča končnih izdelkov (odstopanje od ciljnih zalog iz različnih razlogov) ipd.

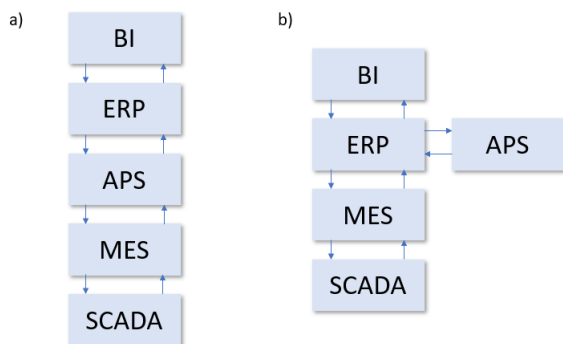
Vse te značilnosti so bile predstavljene ponudnikom APS rešitev tekom pilotnih projektov. Pogostost različnih tipov sprememb je bila ocenjena ali izračunana iz statistike dogodkov.

5.3 Izbira ustrezne ML rešitve

Pred izbiro ustrezne rešitve za uresničitev poslovne zahteve so bile izvedene naslednje predprojektne aktivnosti: definiranje platformskih in integracijskih zahtev (do planiranega ERP, MES), raziskava zrelosti rešitev in ponudnikov na trgu ter izvedba kontrolnih predkalkulacij, da smo lahko pričakovane dobrobiti različnih rešitev vrednotili preko predvidenega učinka na strateške rezultate podjetja.

Ko je bila »strategija digitalizacije podjetja« končana, sta bila že zaključena 2 pilotna projekta testiranja primernih rešitev APS. Prepoznali smo **dve glavnih funkciji** RPA za podporo operativnega planiranja in razporejanja, ki bi izpolnili poslovno zahtevo iz »strategije digitalizacije«: **avtomatizacija predvidevanja proizvodnje in avtomatizacija optimalnega razporeda**. Vplive njunih učinkov smo predračunavali na izpolnjevanje poslovnih KPI.

Na podlagi rezultatov 2 pilotnih projektov smo najprej izvedli popravke na obstoječi IT infrastrukturi v podjetju, na integraciji obstoječih ERP in MES sistemov in na kvaliteti zajema prometnih podatkov iz proizvodnega procesa. Pri tem smo se v nasprotju s predlagano umestitvijo APS (slika 4, a.) (Kletti, 2007) odločili za rešitev, ki prepoznava ERP kot vodilni sistem, in je APS z ML njegova napredna tehnološka nadgradnja (slika 4, b.).

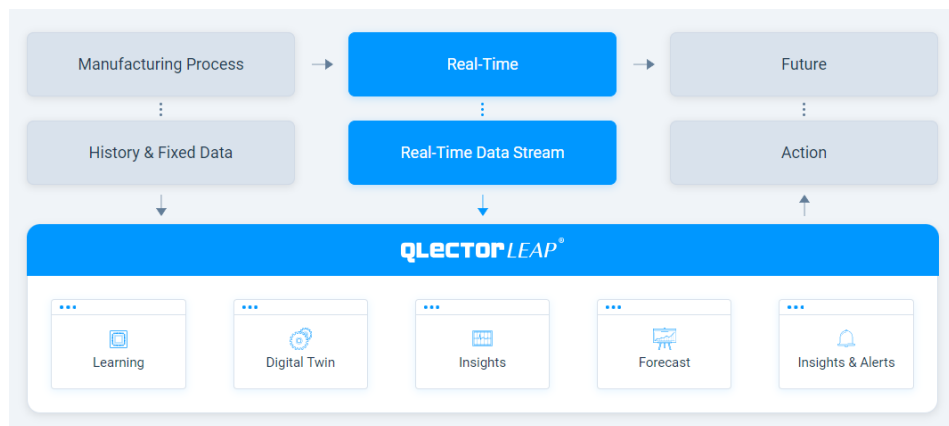


Slika 4: Umestitev APS (z ML) v hierarhijo informacijskih sistemov podjetja

Vir: lasten.

5.4 Konkretni izzivi tekom implementacije APS z ML

Izbrana je bila rešitev Leap (APS z ML) podjetja Qlector, njegovo arhitekturo opisuje slika 5.



Slika 5: Arhitektura izdelka Qlector Leap

Vir: Qlector, 2022

Odkriti in rešeni funkcionalni izzivi pri simulaciji optimalnih razporedov tekom implementacije (slika 6):

- dodana opcija izbire upoštevanja kriterija maksimalne zaloge,
- dodana opcija izbire upoštevanja razvojnih nalogov,
- dodan pregled stanja zalog materiala po izvedeni simulaciji,
- dodan pregled o upoštevanju varnostnih zalog pri simulaciji,
- dodan takojšnji izračun kvalitete simulacij razporeda preko izbranih KPI: na izhodiščne KPI zamud in menjav, dodani kriteriji: izkoristek delovnega časa stroja (ozka grla), enakomerna zasedenost strojev (za postrojenja znotraj določene proizvodnje), vmesne in nedokončane zaloge (med proizvodnjami ali v postrojenjih),
- dodan prikaz/izbira primerjave izhodiščnega razporeda z razporedi med različnimi simulacijami preko KPI, da se planerju predlaga najboljša izvedljiva rešitev,

- dodano začasno arhiviranje KPI simulacije z zapisom (Log) sporočenih »neresjenih« težav, z možnostjo izvoza v npr. Excel (za analitično obdelavo uporabe APS po različnih filtrih: planer, lokacija razporejanja),
- dodano omejevanje simulacije: po potrebi omogočeno izključevanje razporeda delovnih nalogov na izbranem stroju/postrojenju,
- dodana opcija izbire upoštevanja že lansiranih (a ne začelih) proizvodnih nalogov,
- dodano shranjevanje konfiguracij parametrov/uteži za izvedbo simulacij v poimenovane skupine: npr. konfiguracija za osnovno optimizacijo, konfiguracije za optimizacijo v posebnih okoliščinah,
- k avtomatski frekvenci osveževanja podatkov med APS in ERP dodana opcija »osveži na zahtevo«.



Slika 6: Na podlagi izzivov APS ML nadgrajeni uporabniški vmesnik za planerja

Vir: lasten.

Pred prehodom na produkcijo se je skupaj z implementatorjem pripravila lista možnih izzivov (tveganj), ki se lahko pojavijo tekom uporabe APS z ML:

1. Izzivi iz naslova skritih tehničnih in programskih napak:
 - nepopoln prenos podatkov iz APS v ERP in obratno,
 - izpad povezave med ERP, APS z ML in MES.

2. Človeške napake:

- planer pomotoma prerazporedi »vse« proizvodne naloge in shrani v ERP. Izziv: če APS nima ažurne informacije o lansiranih nalogih in nalogih v izvajanju, bodo prerazporejeni tudi nalogi v izvajanju. Zaradi frekvence ažuriranja podatkov med sistemi nov razpored proizvodnih nalogov ne bo takoj viden delavcem v proizvodnji (v MES),
- planer v Leap prerazporedi naloge za celotno delavnico za predolgo obdobje in vse naloge pošlje v ERP. Problem: MRP ne bo mogel več prilagajati planskih nalogov spremembam potreb: pri povečanju potreb bo po nepotrebnem kreiral nove planske naloge, pri zmanjšanju potreb bo samo javljal obvestila izjem, zaradi česar se zamegli slika dejanskih potreb in situacija postane nepregledna in težko obvladljiva. Planerji so navajeni uveljavljati že izvedene spremembe s spreminjanjem odprtih v fiksirane planske naloge. Ker bodo vsi prej odprti in fiksirani planski nalogi v APS razporejeni za daljše časovne obdobje, jih v ERP ne bo več mogoče spreminjati.

3. Konfliktne situacije znotraj APS in z drugimi sistemi:

- pojavljanje konfliktnih situacij zaradi sočasnih sprememb v ERP, APS in MES, npr.: kreiranje novih planskih nalogov v ERP, spremembe proizvodnih nalogov (datumi, količine, status naloge), sprememba planskega naloga v ERP (datum, količina, proizvodna verzija) in brisanje planskih nalogov v ERP, medtem ko se ravno izvaja razporejanje v APS,
- izziv sočasnega razporejanje v APS: več planerjev hkrati razporeja naloge in shrani rezultat. Nevarnost je, da drug drugemu spremenijo, pokvarijo izdelan plan, še posebno pri ločenem optimiranju interne proizvodne verige delavnic.

4. Izvajanje razporejanja nalogov, shranjevanje v ERP, osveževanje iz ERP traja nekaj časa (lahko več minut):

- človeški izziv: čakanje na izvedbo razporeda, čakanje na prepis v ERP, čakanje na osveževanje iz ERP v APS. To uporabnika

dekoncentrira in lahko pozabi, kaj je pravzaprav delal v APS oziroma je nameraval narediti.

6 Diskusija in zaključki

Primerjava med analizo primera in ugotovitvami iz znanstvene in strokovne literature kaže, da so bili vsi izzivi iz tabele 2, ki se nanašajo na strateško načrtovanje, informacijsko infrastrukturo in kompatibilnost informacijskih sistemov prepoznani in obdelani pred izbiro ML rešitve in jih tako iz analize primera lahko potrdimo tudi na izvedbeni ravni.

Prav tako smo v analizi primera prepoznali, da je pomembno pred projektom natančno predstaviti proces planiranja, njegove posebnosti in strateške ter operativne cilje projekta ter stroške/najem rešitve vezati pogodbeno na dokazano izmerjeno dobrobit. Potencialnim implementatorjem je potrebno predstaviti tudi trenutno kakovost dosegljivih podatkov in stopnjo avtomatizacije zajemanja podatkov iz proizvodnega procesa. Tudi ti izzivi primera se skladajo z izzivi v literaturi. Razpoložljivost podatkov je prikazana v tabeli 2.

Izkazalo se je tudi, da raziskovalci in strokovnjaki ne morejo z raziskavami prepoznati in predvideti vseh izzivov, ki jih prinaša uporaba ML pri operativnem planiranju proizvodnje. Na splošno smo pri prepoznavanju izzivov iz konkretnega primera ugotovili, da so ti enaki, ko gre za uvajanje ali uporabo katerekoli informacijske rešitve (ne le ML): za realno uporabnost v konkretni proizvodnji so potrebni popravki in dopolnila funkcionalnosti, izzivi so z izmenjavo in obsegom prometa podatkov in tudi s človeškimi navadami, ki izhajajo iz obstoječega procesa planiranja. Ugotavljamo, da drugih posebnih izzivov uvajanje ML za podjetje ne predstavlja.

Za natančne kvantitativne meritve učinkov na sam proces planiranja in na delo neposredno (planerji, mojstri, delavci) in posredno vključenih zaposlenih (tehnologi, pripravljavci osnovnih matičnih podatkov za planiranje) je od implementacije tehnologije ML na področje operativnega planiranja in razporejanja proizvodnje preteklo premalo časa, da bi lahko iz interpretacije meritev izločili vplive faze uvajanja oz. vpliv prehoda na spremenjen proces planiranja. Meritve bomo opravili

in primerjali s predvidenimi dobrotbitmi (skladno po pogodbi s ponudnikom rešitve) eno leto po implementaciji rešitve.

Literatura

- Anyoha, R. (2017). Sitn.hms. Pridobljeno iz The History of Artificial Intelligence: <https://sitn.hms.harvard.edu/flash/2017/history-artificial-intelligence/>. 24. 2. 2022
- Banker, S. (2019). 20 Things To Know About Artificial Intelligence For Supply Chain Management. Pridobljeno iz forbes.com: <https://www.forbes.com/sites/stevebanker/2019/01/01/20-things-to-know-about-artificial-intelligence-for-supply-chain-management/?sh=3877b67a5371>. 24. 2. 2022
- Baryannis, G., Dani, S., Antoniou, G. (12 2019). Future Generation Computer Systems 101. Predicting supply chain risks using machine learning: The trade-off, str. 993–1004.
- Brown, M. (2020). Planning for the Supply Chain of the Future. APQC. Pridobljeno iz <https://www.apqc.org/resource-library/resource-listing/planning-supply-chain-future>.
- Cadavid, J. P., Lamouri, S., Grabot, B., Fortin, A. (2019). Machine Learning in Production Planning and Control: A Review of Empirical Literature. IFAC PaperOnLine 52–13, 385–390.
- Finlay, J., Dix, A. (1996). An introduction to Artificial Intelligence. London in New York: CRC Press.
- Goertzel, B., Wang, P. (2007). Advances in Artificial General Intelligence: Concepts, Architectures and Algorithms. Amsterdam: IOS Press. Pridobljeno iz https://books.google.si/books?hl=en&lr=&id=t2G5srpFRhEC&oi=fnd&pg=PA17&dq=different+definition+of+artificial+intelligence&ots=hBW5kQPIR0&sig=41YNdC-I_FvFTtCXdy7euAHsmMc&redir_esc=y#v=onepage&q=different%20definition%20of%20artificial%20intelligence&f=false. 24.02.2022
- Günther, H.-O. (2005). Supply Chain Management and Advanced Planning Systems: A Tutorial. Berlin: Physica-Verlag Heidelberg.
- Hartley, J. L., Sawaya, W. J. (2019). Tortoise, not the hare: Digital transformation of supply chain business processes. Business Horizons, 707–715.
- Iriondo, R. (2018). Machine Learning (ML) vs. Artificial Intelligence (AI) — Crucial Differences. Pridobljeno iz <https://towardsai.net/p/machine-learning/differences-between-ai-and-machine-learning-1255b182fc6>. 24. 2. 2022
- Jacobs, F. R., Berry, W., Whybark, D., Vollmann, T. (2018) Manufacturing planning and control for supply chain management: the CPIM reference, 2nd edition. McGraw Hill
- James, A. (2021). 10 Supply Chain Trends to Watch for in 2022. ASCM Insights. Pridobljeno iz <https://www.ascm.org/ascm-insights/10-supply-chain-trends-to-watch-for-in-2022/>.
- Jaskó, S., Skrop, A., Holczinger, T., Chován, T., Abonyi, J. (2020). Development of manufacturing execution systems in accordance with Industry 4.0 requirements: A review of standard- and ontology-based methodologies and tools. Computers in industry 123, 103300.
- Javatpoint. (2021). javatpoint.com. Pridobljeno iz <https://www.javatpoint.com/difference-between-artificial-intelligence-and-machine-learning>. 4. 3. 2021
- Kang, Z., Catal, C., Tekinerdogan, B. (2020). Machine learning applications in production lines: A systematic literature review. Computers & Industrial Engineering 149.
- Kenton, W. (2020). Supply Chain. Pridobljeno iz Investopedia: <https://www.investopedia.com/terms/s/supplychain.asp#:~:text=The%20functions%20in%20a%20supply,and%20a%20faster%20production%20cycle>. 24. 2. 2022
- Kletti, J. (2007). Manufacturing Execution System – MES. Springer. Kindle edition, May 1, 2007.
- Koesch, J. R. (2019). AutomationWorld. Pridobljeno iz The Role of MES in an IIoT World: <https://www.automationworld.com/home/article/21096844/the-role-of-mes-in-an-iiot-world>. 24. 2. 2022

- Payne, T., (2019). Supply Chain Brief: Counter the Four Evils of Supply Chain Planning to Improve Plan Quality, GartnerGroup. Pridobljeno iz <https://www.gartner.com/>.
- Phuyal, S., Bista, D., Bista, R. (2020). Challenges, Opportunities and Future Directions of Smart Manufacturing: A State of Art Review. Sustainable Feauters 2.
- PlanetTogether. (2019). planettogether.com. Pridobljeno iz The 5 Functions of Supply Chain Management: <https://www.planettogether.com/blog/the-five-functions-of-supply-chain-management>. 27.06.2019
- Qlector. (2022). Produkt Leap. Pridobljeno iz <https://qlector.com/qlector-leap.html>, 14.02.2021.
- Salley, A., Payne, T., Lund P.O. (2021). Magic Quadrant for Supply Chain Planning Solutions, GartnerGroup, Pridobljeno iz <https://www.gartner.com/>.
- De Santa-Eulalia, L. A., D'Amours, S., Frayret, J.-M., César, C. (2011). Supply chain management pathways for research and practice. Intechopen. Pridobljeno iz <https://www.intechopen.com/books/supply-chain-management-pathways-for-research-and-practice/advanced-supply-chain-planning-systems-aps-today-and-tomorrow>. 24. 2. 2022
- SCOR. (2017). Supply Chain Operations Reference Model, Version 12.0. APICS. Chicago.
- Tao, F., Qi, Q., Liu, A., Kusiak, A. (2018). Data-driven smart manufacturing. Journal of Manufacturing Systems. Volume 48, Part C, Pages 157–169.
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., Fischl, M. (2021). Artificial intelligence in supply chain management: A systematic literature review. Journal of Business Research 122, 502–517.
- Zhang, L., Zhou, L., Ren, L., Laili, Y. (2019). Modeling and simulation in intelligent manufacturing. Computers in Industry 112, 103123.
- Zupan, S. (2010). Uvedba informacijsko podprtega terminiranja operacij v proizvodnji podbojev v podjetju LIP Bled: magistrsko delo. University of Ljubljana