

Optimizacija procesa prikupljanja i obrade podataka u proizvodnim sustavima

Primorac, Ana

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:718227>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-01-28**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Ana Primorac

Zagreb, 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Doc. dr. sc. Miro Hegedić

Dr. sc. Mihael Gudlin

Student:

Ana Primorac

Zagreb, 2024.

Izjavljujem da sam ovaj rad izradila samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru Miri Hegediću na savjetima i prenesenom znanju tijekom cijelog studija, asistentu Mihaelu Gudlinu na pomoći i savjetima tijekom izrade diplomskog rada.

Zahvaljujem se svim kolegama i direktoru tvrtke RBT Technologies na pomoći, podršci te dijeljenju savjeta i znanja, a posebno hvala kolegi Dominiku Vezmaru koji mi je uvelike pomogao i olakšao pri realizaciji diplomskog rada.

Posebna zahvala mojoj obitelji na neizmjerne ljubavi i razumijevanju, mami i tati koji su uvijek vjerovali u mene te me poticali na rad i upornost, sestri i bratu čija mi je podrška uvijek značila. Vaša podrška je uvelike olakšala moje školovanje.

Na kraju, zahvaljujem se dragom Bogu na snazi i volji kroz cijelo studiranje: „*Sve je moguće onome koji vjeruje!*“ (Mk 9, 23)

Ana Primorac



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
Proizvodno inženjerstvo, inženjerstvo materijala, industrijsko inženjerstvo i menadžment,
mehatronika i robotika, autonomni sustavi i računalna inteligencija

Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa: 602 - 04 / 24 - 06 / 1	
Ur.broj: 15 - 24 -	

DIPLOMSKI ZADATAK

Student: **Ana Primorac** JMBAG: 0035221948

Naslov rada na hrvatskom jeziku: **Optimizacija procesa prikupljanja i obrade podataka u proizvodnim sustavima**

Naslov rada na engleskom jeziku: **Optimization of Data Collection and Processing in Manufacturing Systems**

Opis zadatka:

Znanost o podacima sve više postaje integralni dio modernih proizvodnih poduzeća, omogućujući im da pretoče ogromne količine sakupljenih podataka u akcijske uvide i prediktivne modele za optimizaciju operacija. Ova disciplina obuhvaća i umjetnu inteligenciju kako bi pružila alate potrebne za predviđanje trendova, automatizaciju procesa i donošenje informiranih odluka, što je posebno važno u dinamičnom proizvodnom okruženju.

U radu je potrebno:

- Istražiti i definirati ključne aspekte znanosti o podacima u kontekstu proizvodnje što uključuje prikupljanje i pripremu podataka, strojno učenje i umjetnu inteligenciju te koje vrste podataka se najčešće prikupljaju u proizvodnim sustavima.
- Usporediti različite softverske platforme koje se koriste za prikupljanje i obradu podataka u proizvodnji, vrednujući njihove prednosti i nedostatke te sposobnost integracije s postojećim proizvodnim procesima.
- Odabrati softver koji se čini najprikladnijim za proizvodno okruženje i demonstrirati njegovu upotrebu kroz studiju slučaja, prikazujući kako softver rješava specifične izazove u proizvodnji.
- Analizirati prikupljene i obrađene podatke koristeći odabrani softver, procijeniti njihovu relevantnost i učinkovitost u optimizaciji proizvodnih procesa, te identificirati područja gdje znanost o podacima može donijeti najviše poboljšanja.
- Izvesti zaključke i dati preporuke na temelju analize, uključujući kako proizvodna poduzeća mogu poboljšati procese prikupljanja podataka i kako najbolje iskoristiti znanost o podacima za ostvarivanje konkurentne prednosti.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

Datum predaje rada:

Predviđeni datumi obrane:

18. siječnja 2024.

21. ožujka 2024.

25. – 29. ožujka 2024.

Zadatak zadao:

Doc.dr.sc. Miro Hegedić

Dr. sc. Mihael Gudlin

Predsjednik Povjerenstva:

Prof. dr. sc. Ivica Garašić

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	V
POPIS KRATICA	VI
SAŽETAK.....	VII
SUMMARY	VIII
1. UVOD.....	1
2. ZNANOST O PODACIMA	2
2.1. Umjetna inteligencija	5
2.2. Odabrani algoritmi umjetne inteligencije	7
3. PODACI	8
3.1. Struktura podataka	9
4. ARHITEKTURA SUSTAVA	13
4.1. Primjena arhitekture sustava	15
4.2. Softverska rješenja za optimizaciju.....	16
4.2.1. MELSOFT MaiLab.....	16
4.2.2. KNIME	17
4.2.3. RapidMiner	18
4.3. Usporedba softvera za obradu podataka	19
4.4. Teorijski prikaz MaiLab-a	20
4.5. Smart Manufacturing Kaizen Level	27
5. OPIS EKSPERIMENTA	35
5.1. Opis procesa	37
5.1.1. Pokretna traka	38
5.1.2. Spremnik	39
5.1.3. Bušilica	40
5.1.4. Preša	41
5.2. Opis eksperimenta za optimizaciju procesa	42
5.2.1. Priprema za eksperiment	45
6. OBRADA PODATAKA U MAILAB-U.....	46
6.1. Analiza podataka za kontrolu kvalitete	46
6.1.1. Stvaranje skupa podataka.....	46
6.1.2. Stvaranje umjetne inteligencije	47
6.1.3. Izrada zadatka	54
6.1.4. Izvršenje zadatka i praćenje	55
6.2. Prilagođena analiza podataka za kontrolu kvalitete	58
6.3. Analiza za predviđanje brzine bušenja.....	62
6.3.1. Stvaranje skupa podataka.....	62
6.3.2. Stvaranje umjetne inteligencije	63
6.3.3. Izrada zadatka	68

6.3.4. Izvršenje zadatka i praćenje	68
6.4. Prilagođena analiza za predviđanje brzine bušenja.....	70
6.5. Rezultati analiza.....	76
7. ZAKLJUČAK.....	78
LITERATURA.....	79
PRILOZI.....	81

POPIS SLIKA

Slika 1.	Aktivnosti koje obuhvaća Znanost o podacima [3].....	3
Slika 2.	Podjela Znanosti o podacima [4].....	3
Slika 3.	Prikaz strukturiranih podataka u Excel tablici [9].....	10
Slika 4.	Slikovni prikaz prikupljanja podataka [10].....	11
Slika 5.	Prikaz primjera arhitekture sustava [14].....	14
Slika 6.	Prikaz određenog procesa digitalizacije [11].....	15
Slika 7.	Prikaz procesa u MaiLab-u [16].....	17
Slika 8.	Prikaz procesa KNIME-u [18].....	18
Slika 9.	Prikaz procesa u RapidMiner-u [20].....	19
Slika 10.	Prikaz smanjenja troškova zamjenom alata [22].....	22
Slika 11.	Nasljeđivanje vještina i ušteda radne snage [22].....	23
Slika 12.	Praćenje produktivnosti [22].....	23
Slika 13.	Poboljšanje kvalitete [22].....	24
Slika 14.	Prikaz dviju faza korištenja podataka.....	24
Slika 15.	Korisničko sučelje MaiLab-a.....	27
Slika 16.	Stupanj zrelosti po SMKLU [25].....	28
Slika 17.	Razine upravljanja po SMKLU [25].....	29
Slika 18.	SMKL matrica.....	31
Slika 19.	Prikaz značajki SMKLU-a.....	32
Slika 20.	Prikaz pitanja po razinama matrice.....	33
Slika 21.	Optimizacija na razinama 1D-2D.....	34
Slika 22.	Ilustracija integracije MaiLab-a [22].....	34
Slika 23.	Prikaz Pametne tvornice na Fakultetu Strojарstva i Brodogradnje.....	35
Slika 24.	Prednji poklopac [26].....	36
Slika 25.	Stražnji poklopac [26].....	36
Slika 26.	Paleta [26].....	37
Slika 27.	Nosač [26].....	37
Slika 28.	Tvornica za učenje s radnim stanicama [29].....	38
Slika 29.	Pokretna traka [26].....	39
Slika 30.	Spremnik [26].....	40
Slika 31.	Bušilica [26].....	41
Slika 32.	Preša [26].....	42
Slika 33.	Shema radnih stanica i transportne trake.....	43
Slika 34.	Dodavanje skupa podataka.....	46
Slika 35.	Parametri od kojih se sastoji skup podataka.....	47
Slika 36.	Stvaranje umjetne inteligencije.....	48
Slika 37.	Odabir vrste analize.....	48
Slika 38.	Izbor parametra za praćenje.....	49
Slika 39.	Postavke učenja i metode analize.....	50
Slika 40.	LightGBM.....	50
Slika 41.	Random Forest.....	50
Slika 42.	Graf Rezidualnog ostatka (LightGBM).....	52
Slika 43.	Linijski graf (LightGBM).....	52
Slika 44.	Graf Rezidualnog ostatka (Random Forest).....	53
Slika 45.	Linijski graf (Random Forest).....	53
Slika 46.	Završeni procesi.....	54
Slika 47.	Stvaranje zadatka.....	55
Slika 48.	Prikaz praćenja procesa.....	56

Slika 49.	Rezultati dijagnoze	56
Slika 50.	Tablični prikaz rezultata	57
Slika 51.	Primjer kvalitete kontrole prešanja.....	58
Slika 52.	Kreiranje naprednog zadatka	59
Slika 53.	Prilagođeni proces	59
Slika 54.	Deep Learning	60
Slika 55.	Graf Rezidualnog ostatka (Deep Learning).....	60
Slika 56.	Linijski graf (Deep Learning).....	61
Slika 57.	Rezultati dijagnoze	61
Slika 58.	Tablični prikaz rezultata	62
Slika 59.	Odabir vrste analize	63
Slika 60.	Izbor parametra za predviđanje	64
Slika 61.	LightGBM	64
Slika 62.	Random Forest	65
Slika 63.	Graf Rezidualnog ostatka (LightGBM).....	65
Slika 64.	Linijski graf (LightGBM).....	66
Slika 65.	Graf Rezidualnog ostatka (Random Forest)	66
Slika 66.	Linijski graf (Random Forest)	67
Slika 67.	Procesi učenja.....	67
Slika 68.	Stvaranje zadatka.....	68
Slika 69.	Rezultati dijagnoze	69
Slika 70.	Tablični prikaz rezultata	69
Slika 71.	Stvaranje zadatka.....	70
Slika 72.	Prilagođeni proces	71
Slika 73.	Gradient Boosting Decision Tree	71
Slika 74.	Deep Learning	72
Slika 75.	Graf Rezidualnog ostatka (Gradient Boosting Decision Tree)	73
Slika 76.	Linijski graf (Gradient Boosting Decision Tree)	73
Slika 77.	Graf Rezidualnog ostatka (Deep Learning).....	74
Slika 78.	Linijski graf (Deep Learning).....	74
Slika 79.	Rezultati dijagnoze	75
Slika 80.	Tablični prikaz rezultata	75

POPIS TABLICA

Tablica 1. Usporedba softvera..... 19
Tablica 2. Definicija razina zrelosti 29

POPIS KRATICA

CP – Kibernetičko-fizička tvornica – *eng. Cyber-Physical Factory*

CSV – Zarezom odvojene vrijednosti – *eng. Comma-Separated Values*

ERP – Planiranje resursa poduzeća – *eng. Enterprise Resource Planning*

IM – Idealni model – *eng. Ideal Model*

IoT – Internet stvari – *eng. Internet of Things*

LASSO – Operator najmanje apsolutne redukcije i selekcije – *eng. Least Absolute Shrinkage and Selection Operator*

LightGBM – Lagano strojno pojačavanje gradijenta – *eng. Light Gradient Boosting Machine*

MES – Sustavi za izvođenje proizvodnje – *eng. Manufacturing Execution System*

mm – milimetar

RMSE – Korijen srednjeg kvadrata odstupanja – *eng. Root Mean Square Error*

RFID – Radiofrekvencijska identifikacija – *eng. Radio Frequency Identification*

SMKL – Pametna proizvodnja na razini Kaizena – *eng. Smart Manufacturing Kaizen Level*

SVM – Metoda potpornih vektora – *eng. Support Vector Machine*

XML – Proširivi jezik za označavanje podataka – *eng. Extensible Markup Language*

SAŽETAK

Ovaj diplomski rad fokusira se na primjenu softverskog rješenja kako bi se odgovorilo na specifične izazove unutar proizvodnje. Kroz analizu i obradu podataka koristeći Mailab softver, istražuju se mogućnosti optimizacije proizvodnih procesa primjenom algoritama umjetne inteligencije i znanosti o podacima. Cilj istraživanja je pružiti uvid u važnost softvera u rješavanju kompleksnosti proizvodnih okruženja te demonstrirati konkretnu primjenu MaiLab-a u prikupljanju, analizi i optimizaciji podataka. Kroz studiju slučaja, rad ilustrira kako se ovi alati mogu integrirati u stvarna proizvodna okruženja radi postizanja učinkovitijih i optimalnih procesa. Kroz ovu analizu, istraživanje također pokušava identificirati buduće smjerove razvoja i unapređenja kako bi se dodatno potaknula integracija softverskih rješenja u proizvodne sektore.

Ključne riječi: znanost o podacima, umjetna inteligencija, strojno učenje, analiza podataka, optimizacija, proizvodni procesi.

SUMMARY

This paper focuses on the application of software solution to address specific challenges within manufacturing. Through the analysis and processing of data using Matlab software, the possibilities of optimizing manufacturing processes are explored by applying artificial intelligence algorithms and data science. The research aims to provide insights into the importance of software in tackling the complexities of manufacturing environments and to demonstrate the practical application of Matlab in data collection, analysis, and optimization. Through a case study, the paper illustrates how these tools can be integrated into real manufacturing environments to achieve more efficient and optimal processes. In this analysis, the research also attempts to identify future development directions and improvements to further encourage the integration of software solutions in manufacturing sectors.

Key words: data science, artificial intelligence, machine learning, data analysis, optimization, production processes.

1. UVOD

U kontekstu ubrzanog tehnološkog razvoja, optimizacija podataka postaje ključni faktor za postizanje učinkovitosti, smanjenje troškova i poboljšanje konkurentske prednosti u industrijskim sektorima. Ovaj diplomski rad fokusirat će se na problematiku optimizacije podataka u domeni prikupljanja i obrade podataka proizvodnih sustava, istražujući primjenu softverskih alata u procesima prikupljanja, analize i optimizacije podataka. Softveri su temeljeni na Znanosti o podacima (eng. Data Science), Strojnom učenju (eng. Machine Learning) i Umjetnoj inteligenciji (eng. Artificial Intelligence). Znanost o podacima kao disciplina istražuje načine za analizu i interpretaciju kompleksnih podataka, uzoraka i trendova, dok Strojno učenje, kao grana umjetne inteligencije, omogućuje softverima da uče iz iskustva i samostalno poboljšavaju svoje performanse. Umjetna inteligencija, pak, prožima softverske sustave sa sposobnošću zaključivanja, prilagodbe i donošenja autonomnih odluka. Uzimajući sve to u obzir, odabire se softver koji je jednostavan za korištenje te nisu potrebne posebne vještine za korištenje istim, a donosi poboljšanja u procesima te unapređuje poslovanje.

Proizvodna industrija, suočena s izazovima kompleksnosti i dinamičnosti, sve više prepoznaje važnost optimalnog upravljanja podacima kako bi se poboljšala kvaliteta proizvoda, smanjili gubici i optimizirali radni procesi. U tom kontekstu, alati koji pomažu pri optimizaciji procesa ključni su za praćenje trendova i konstantno napredovanje kroz procese koji prikupljaju i obrađuju podatke. Trendovi razvoja tehnologije u proizvodnji dodatno naglašavaju potrebu za efikasnim korištenjem podataka kako bi se tvornički procesi prilagodili zahtjevima tržišta i osigurala konkurentnost tvrtki u sve zahtjevnijem okruženju. Također, naglasak na održivosti i ekološki prihvatljivim praksama potiče proizvodne tvrtke da koriste podatke za praćenje i smanjenje negativnog utjecaja na okoliš, što dodatno povećava važnost optimizacije podataka u proizvodnim procesima. Tehnološka rješenja poput pametnih energetske sustava, recikliranja otpada i praćenja emisija mogu pomoći tvrtkama da postignu svoje ciljeve održivosti dok istovremeno smanjuju troškove proizvodnje i poboljšavaju svoj ugled među potrošačima.

U proizvodnoj industriji postoje brojni izazovi s kojima se suočavaju tvrtke svakodnevno, a tehnologija može igrati ključnu ulogu u njihovom rješavanju. Primjerice, jedan od glavnih izazova je povećanje produktivnosti i efikasnosti proizvodnih procesa. Tehnološka rješenja poput automatizacije i robotike omogućuju tvrtkama da povećaju brzinu proizvodnje, smanje vrijeme potrebno za proizvodnju i minimiziraju pogreške.

2. ZNANOST O PODACIMA


U posljednjem desetljeću svjedočimo ubrzanom razvoju tehnologije, a posebno u području znanosti o podacima te korištenjem umjetne inteligencije čiji je najsnažniji alat posljednjih godina strojno učenje. U kontekstu proizvodnje, ove napredne tehnologije igraju ključnu ulogu u prijelazu prema Industriji 4.0 i njezinoj nadogradnji Industriji 5.0. Razmatranjem novijih trendova u korištenju umjetne inteligencije, posebno se naglašava strojno učenje kako bi se optimizirali procesi proizvodnje, povećala učinkovitost i omogućilo inovativno upravljanje u modernim tvornicama. Industrija 4.0 u proizvodnji donosi potpunu digitalizaciju, a različiti senzori, uređaji i napredni sustavi za prikupljanje podataka transformiraju proizvodnju, omogućuju praćenje procesa u stvarnom vremenu i optimizaciju procesa [1]. Dok je Industrija 5.0 usmjerena na humanizaciju proizvodnje, integrirajući napredne tehnologije s ljudskim radom [2]. Umjetna inteligencija i strojno učenje igraju ključnu ulogu u stvaranju inteligentnih sustava koji surađuju s radnicima. Znanost o podacima je polje koje se brzo razvija, a uvođenjem u proizvodnju revolucionira način na koji tvornice posluju.

Znanost o podacima predstavlja interdisciplinarno područje koje kombinira statistiku, matematiku, računarstvo i domensko znanje kako bi ekstrahiralo značenje iz podataka. Ova grana znanosti obuhvaća niz aktivnosti sa ciljem analize, interpretacije i zaključivanja iz podataka radi donošenja informiranih odluka. Ima ključnu ulogu u modernom društvu, doprinoseći razvoju tehnologije, poslovanja i drugih sektora pružajući dublje razumijevanje podataka i omogućujući informirane odluke [3]. Neke od ključnih aktivnosti prikazane su na [Slika 1].



Slika 1. Aktivnosti koje obuhvaća Znanost o podacima [3]

Znanost o podacima ima tri glavne podjele; inženjering, analiza i modeliranje/zaključivanje, prikazano na [Slika 2] [4].



Slika 2. Podjela Znanosti o podacima [4]

Postoje određene vještine u svakom dijelu Znanosti o podacima. Različite kombinacije definiraju određene uloge u području Znanosti o podacima. Kada ljudi razgovaraju o svim algoritmima strojnog učenja i umjetne inteligencije, često zanemaruju ključni dio podatkovnog inženjeringa koji čini sve mogućim. Podatkovni inženjering je nevidljivi ledeni brijeg ispod površine vode, odnosno temelj je koji omogućuje sve ostalo. Grana je inženjeringa koja se bavi prikupljanjem, obradom, pohranom i upravljanjem podacima. Cilj podatkovnog inženjeringa je stvoriti robusnu i učinkovitu infrastrukturu za obradu podataka, omogućujući organizacijama i istraživačima dobivanje smislenih informacija iz svojih podatkovnih izvora. Predstavlja ključni korak u procesu izvlačenja vrijednosti iz podataka jer pruža temeljnu infrastrukturu koja omogućuje drugima učinkovit rad s podacima [4].

Analiza pretvara sirove informacije u uvide na brz i često istraživački način. Općenito, analitičar treba imati pristojno znanje domene, provesti učinkovitu istraživačku analizu i predstaviti rezultate kroz pripovijedanje. Znanje domene je razumijevanje organizacije ili industrije gdje se primjenjuje znanost o podacima, nemoguće je razumjeti podatke bez konteksta. Obuhvaća postupke i tehnike za istraživanje, interpretaciju i zaključivanje iz podataka. Glavni cilj analize podataka je pridobivanje korisnih informacija, prepoznavanje i otkrivanje trendova i donošenje informiranih odluka [4].

Modeliranje/zaključivanje je proces koji dublje ulazi u podatke kako bi otkrio uzorke koji nisu lako vidljivi. Modeliranje se odnosi na stvaranje matematičkih ili statističkih modela kako bi se opisali, predvidjeli ili razumjeli podaci. Zaključivanje se odnosi na proces donošenja zaključaka, tumačenja ili generaliziranja na temelju analize podataka. Najveći dio vremena se provodi komunicirajući s različitim dionicama te prikupljajući i čisteći podatke [4].

Kakva pitanja Znanost o podacima može riješiti? Znanost o podacima ne može riješiti sve probleme niti dati odgovore na sva pitanja. Potrebno je odraditi dobru klasifikaciju problema te temeljitom analizom pokušati doći do odgovora. Potrebno je odrediti klasifikaciju pitanja, pitanje mora biti dovoljno specifično, treba provjeriti dostupnost potrebnih podataka, početi s analizom i potražnjom odgovora itd.

Umjetna inteligencija i znanost o podacima često su usko povezane, zajedno oblikujući pristup rješavanju složenih problema. Umjetna inteligencija pruža temelje za razvoj algoritama i modela koji omogućuju sustavima učenje iz podataka, dok znanost o podacima pruža ključne metode za analizu, interpretaciju i izvlačenje značajki iz ogromnih skupova podataka. Kroz primjenu strojnog i dubokog učenja, umjetna inteligencija omogućuje sustavima da prepoznaju

obrasce, donose predviđanja i automatski poboljšavaju svoje performanse s iskustvom. S druge strane, znanost o podacima pruža strukturu za prikupljanje, obradu i upravljanje podacima, čime osigurava da modeli umjetne inteligencije imaju visokokvalitetne i relevantne podatke za učenje [5]. Dakle, spoj umjetne inteligencije i znanosti o podacima omogućuje stvaranje moćnih sustava koji ne samo da razumiju kompleksnost podataka, nego i autonomno evoluiraju kako bi rješavali izazove različitih industrija i disciplina.

2.1. Umjetna inteligencija

Umjetna inteligencija predstavlja područje računarstva koje se bavi stvaranjem sustava sposobnih za obavljanje zadataka koji obično zahtijevaju ljudsku inteligenciju. Osnovna svrha umjetne inteligencije jest razviti algoritme i modele koji omogućuju računalima da donose odluke, uče iz iskustva, prepoznaju obrasce, rješavaju probleme i obavljaju druge zadatke bez eksplicitnog programiranja. Osnovne značajke umjetne inteligencije uključuju sposobnost učenja (učenje iz podataka ili iskustva), prepoznavanje uzoraka, donošenje odluka, jezik i komunikaciju te prilagodbu okolini [5]. Primjena umjetne inteligencije je širokog spektra i obuhvaća različite industrije. Koristi se u gotovo svim područjima, od vozila, prepoznavanja govora, dijagnostici, robotskoj automatizaciji... Metode i pristupi za rješavanje problema koje umjetna inteligencija koristi slične su ljudskom razmišljanju, ali koriste se i algoritmi i modeli za automatizaciju procesa. Neke ključne metode i pristupi koje umjetna inteligencija koristi u rješavanju problema uključuju [6]:

- Strojno učenje – grana umjetne inteligencije koja omogućuje računalima da uče iz iskustva i poboljšavaju svoje performanse bez izričitog programiranja. Algoritmi strojnog učenja prepoznaju uzorke u podacima te koriste ta znanja za donošenje odluka ili predviđanje budućih događaja.
- Duboko učenje – specifičan oblik strojnog učenja koji koristi umjetne neuronske mreže s više slojeva za obradu podataka. Ove mreže sposobne su automatski ekstrahirati značajke iz složenih skupova podataka, često postižući visoku razinu apstrakcije i interpretacije.
- Naučeno planiranje – u području umjetne inteligencije, planiranje se odnosi na sposobnost sustava da generira niz koraka kako bi postigao određeni cilj. Naučeno planiranje znači da sustav uči najučinkovitije planove iz iskustva.

- Optimizacija – umjetna inteligencija koristi algoritme optimizacije za pronalaženje najboljih rješenja među različitim mogućnostima. Često se primjenjuje u situacijama gdje je potrebno optimizirati resurse, vrijeme ili performanse.

Umjetna inteligencija kombinira ove pristupe i tehnike kako bi rješavala različite vrste problema, od prepoznavanja slika do optimizacije procesa.

Strojno učenje, kao najčešće korišteni alat umjetne inteligencije, fokusira se na razvoj algoritama koji omogućuju računalima da automatski poboljšavaju svoje performanse iz iskustva. Algoritmi automatski prilagođavaju svoje parametre kako bi izvukli uzorke, donosili odluke ili predviđali buduće vrijednosti na temelju ulaznih podataka.

Postoji nekoliko ključnih faza u procesu strojnog učenja [7]:

1. Prikupljanje podataka; strojno učenje zahtijeva podatke na kojima će se model trenirati. Podaci mogu biti u obliku tablica, slika, teksta ili drugih formata, ovisno o vrsti problema.
2. Priprema podataka; podaci se često moraju očistiti, normalizirati ili transformirati kako bi bili prikladni za treniranje modela. To uključuje uklanjanje nedostajućih vrijednosti, standardizaciju mjera ili kodiranje kategoričkih varijabli.
3. Odabir modela; na temelju vrste problema (regresija, klasifikacija, klasteriranje) odabire se odgovarajući model. To može uključivati odabir između linearnih modela, stabala odlučivanja, neuronskih mreža ili drugih.
4. Treniranje modela; model se trenira pomoću skupa podataka za učenje. Tijekom treniranja, model prilagođava svoje parametre kako bi minimizirao grešku između stvarnih i predviđenih vrijednosti.
5. Evaluacija modela; nakon treniranja, model se evaluira na skupu podataka za testiranje kako bi se procijenila njegova sposobnost generalizacije na novim podacima. Ovisno o vrsti problema, mogu se koristiti različite metrike evaluacije.
6. Optimizacija modela; ako je potrebno, model se može optimizirati podešavanjem hiperparametara ili korištenjem tehnika poput validacije unaprijed.
7. Predviđanje i primjena; kada je model treniran i evaluiran, može se koristiti za predviđanje novih vrijednosti ili donošenje odluka u stvarnom okruženju.

Što se tiče modela, ponajviše ovisi o vrsti problema. Na primjer, za klasifikaciju se često koriste logistička regresija, k-najbližih susjeda, stabla odlučivanja, stroj s potpornim vektorima (*eng. Support Vector Machine, SVM*) i drugi modeli. U regresiji su popularni Linearna regresija, Regresija grebena (*eng. Ridge regression*), Operator najmanje apsolutne redukcije i selekcije (*eng. Least Absolute Shrinkage and Selection Operator, LASSO*) itd. Neuronske mreže koriste se za kompleksne zadatke poput prepoznavanja uzoraka u slikama ili obradi prirodnog jezika. Važno je odabrati odgovarajući algoritam ovisno o karakteristikama podataka i zahtjevima problema.

2.2. Odabrani algoritmi umjetne inteligencije

Posebno će se prikazati određeni algoritmi koji će se koristiti pri stvarnom procesu optimizacije u sljedećim poglavljima s realnim podacima, koji spadaju u metode kombiniranja modela strojnog učenja (ansambli); Deep Learning, Light Gradient Boosting Machine (Light GBM), Gradient Boosting Decision Tree, Slučajna šuma (*eng. Random Forest*).

- Deep Learning – područje strojnog učenja koje se bavi proučavanjem i izgradnjom modela koji koriste umjetne neuronske mreže s više slojeva, odnosno duboke neuronske mreže za analizu i tumačenje podataka. Naglašava sposobnost računala da samostalno uče i donose zaključke iz velikih količina podataka [6].
- Light Gradient Boosting Machine – algoritam strojnog učenja koji se koristi za probleme regresije i klasifikacije. To je vrsta ansambla modela pojačavanja gradijentom koji je popularan pristup u strojnom učenju. S obzirom na svoje performanse i prilagodljivost, često se koristi kada se radi s velikim skupovima podataka i zahtjevima za brzim testiranjem modela [6].
- Gradient Boosting Decision Tree - ansambl metoda strojnog učenja koja kombinira više stabala odlučivanja kako bi poboljšala prediktivnu snagu modela [6].
- Slučajna šuma - ansambl metoda strojnog učenja koja koristi više stabala odlučivanja kako bi poboljšala stabilnost i preciznost modela. Spada u kategoriju metoda gdje se različiti modeli treniraju na različitim skupovima podataka kako bi se smanjila varijanca i spriječila prenaučenaost [6].

3. PODACI

Podaci su skup informacija ili činjenica koje su prikupljene, pohranjene ili obrađene, a mogu biti različitih vrsta i u različitim oblicima. Postoji više definicija vrsta podataka ovisno o području ljudske djelatnosti. Glavni konsenzus je da se podaci dijele na kvantitativne i kvalitativne [8]. Prema tipu podataka mogu biti strukturirani, nestrukturirani i polustrukturirani podaci. Strukturirani podaci najčešće su pohranjeni u Excel tablicama ili u bazama podataka, dok nestrukturirani nemaju definiranu strukturu pa se nalaze u obliku tekstualnih dokumenata, slika, video ili audio zapisa. Na osnovi izvora podataka dijele se na interne (podaci se prikupljaju unutar organizacije) ili eksterne podatke (potječu iz vanjskih izvora). Po formatu podatke dijelimo na tekstualne (dokumenti, e-mail-ovi, poruke), brojevne (financijski izračuni), grafički podaci (slike, grafikoni, dijagrami) te zvučni podaci (audio zapisi, zvučni signali). Ovisno o namjeni prikupljenih podataka dijele se na operativne, analitičke i istraživačke. Podaci su ključan resurs u današnjem digitalnom dobu, a njihova pravilna obrada i analiza mogu pridonijeti informiranom donošenju odluka, inovacijama i poboljšanju. U proizvodnim sustavima prikupljaju se različite vrste podataka kako bi se pratila i optimizirala proizvodnja. Neke od najčešće vrsta podataka koje se prikupljaju u proizvodnim okruženjima [8]:

- Operativni podaci; informacije o svakodnevnim operacijama, uključujući brzinu proizvodnje, vrijeme rada opreme, status strojeva i linija te ostali parametri relevantni za trenutni proizvodni proces.
- Senzorski podaci; podaci prikupljeni putem senzora koji mjere različite parametre kao što su temperatura, tlak, vibracije, razina materijala.
- Podaci o kvaliteti; informacije o kvaliteti proizvoda ili sirovina, uključujući rezultate ispitivanja kvalitete, odbačene proizvode ili defekte.
- Proizvodni redoslijed; podaci koji opisuju redoslijed operacija u proizvodnji, vrijeme trajanja svake faze, te eventualne promjene u rasporedu proizvodnje.
- Održavanje opreme; informacije o stanju opreme, održavanju, servisima te podaci o potrebnim zamjenama dijelova kako vi se održala učinkovitost opreme.
- Logistički podaci; podaci o upravljanju zalihama, praćenju proizvoda kroz lanac opskrbe i dr.
- Podaci o radnicima; informacije o radnicima, uključujući radno vrijeme, obuku, učinkovitost.

- Financijski podaci; troškovi proizvodnje, cijene materijala, radne snage te drugi financijski aspekti povezani s proizvodnjom.
- Podaci o održivosti; informacije u utjecaju proizvodnje na okolinu, praćenjem emisija stakleničkih plinova.

Ovi podaci najčešće proizlaze iz senzora, sustava za praćenje i upravljanje, računalnih sustava za planiranje resursa (ERP) i drugih tehnologija koje se koriste u proizvodnih sustavima. Obrada i analiza ovih podataka može pridonijeti optimizaciji proizvodnje, povećanju učinkovitosti, smanjenju troškova te poboljšanju ukupne kvalitete proizvoda.

3.1. Struktura podataka

Struktura podataka u poduzeću igra ključnu ulogu u učinkovitosti, prilagodljivosti i sposobnosti organizacije da iskoristi digitalne alate za optimizaciju. Optimizacija strukture podataka obično uključuje prikupljanje, prilagodbu, analizu i pohranu podataka, a treba biti kontinuiran proces koji prati razvoj tehnologije i poslovnih potreba. Podaci se mogu strukturirati na različite načine, ovisno o vrsti koje se prikupljaju i potrebama organizacije. Postoji nekoliko osnovnih oblika strukturiranja podataka [8]:


- Relacijska struktura; koristi se tablična struktura gdje su podaci organizirani u redove i stupce (Excel tablice, relacijske baze podataka).
- Tekstualna struktura; podaci su organizirani kao tekstualne datoteke (CSV, XML).
- Objektna struktura; podaci su organizirani kao objekti koji sadrže podatke i metode za njihovu obradu (Objektno orijentirano programiranje, JSON format).

	A	B	C	D	E	F	G	H	I
1	Uplate za program								
2	Redni broj	Ime i prezime	1. rata	2. rata	3. rata	4. rata	5. rata	Ukupno plaćeno:	
3	1	Ivana Horvat	100.00 kn	300.00 kn	200.00 kn	450.00 kn	100.00 kn	1,150.00 kn	
4	2	Kristina Lipić	300.00 kn	100.00 kn	200.00 kn	100.00 kn	450.00 kn	1,150.00 kn	
5	3	Danijela Rok	100.00 kn	200.00 kn	300.00 kn	100.00 kn	450.00 kn	1,150.00 kn	
6	4	Dino Borić	300.00 kn	100.00 kn	450.00 kn	200.00 kn	100.00 kn	1,150.00 kn	
7	5	Zrinka Kovač	200.00 kn	300.00 kn	450.00 kn	100.00 kn	100.00 kn	1,150.00 kn	
8	6	Mirna Kovačević	450.00 kn	200.00 kn	100.00 kn	100.00 kn	300.00 kn	1,150.00 kn	
9	7	Ivana Lem	300.00 kn	100.00 kn	200.00 kn	100.00 kn	450.00 kn	1,150.00 kn	
10	8	Danijel Kovač	100.00 kn	450.00 kn	100.00 kn	200.00 kn	300.00 kn	1,150.00 kn	
11	9	Kristijan Horvat	450.00 kn	100.00 kn	100.00 kn	300.00 kn	200.00 kn	1,150.00 kn	
12	10	Ivan Šimić	200.00 kn	100.00 kn	300.00 kn	450.00 kn	100.00 kn	1,150.00 kn	
13		Cijena programa:	1,150.00 kn						
14									

Slika 3. Prikaz strukturiranih podataka u Excel tablici [9]

Prikupljanje podataka može se provoditi na različite načine, ovisno o vrsti podataka i kontekstu, a neke od uobičajenih metoda su [8]:

- Ručni unos; osoblje ručno unosi podatke u određene obrasce ili sustave, npr. unos podataka u Excel tablice, web forme.
- Automatizirano prikupljanje; korištenje automatiziranih alata za prikupljanje podataka, često putem senzora ili posebnih programa.
- Ispitivanja i anketiranja; prikupljanje podataka putem upitnika ili intervjua, anketiranje korisnika, istraživanje tržišta.
- Senzorsko prikupljanje podataka; upotreba senzora za prikupljanje fizičkih podataka iz okoline npr. temperaturni senzori.
- Podaci iz vanjskih izvora; uvoz podataka iz vanjskih izvora, poput partnerskih tvrtki, državnih agencija, npr. financijski izvještaji, meteorološki podaci.



Slika 4. Slikovni prikaz prikupljanja podataka [10]

Kombinacijom odgovarajuće strukture podataka i odgovarajućih metoda prikupljanja, kompanije mogu stvoriti snažan temelj za analizu, donošenje odluka i optimizaciju poslovnih procesa. Koliko je bitno dobro strukturirati podatke i znati gdje i kako su pohranjeni govori činjenica da tvrtke u prosjeku koriste samo mali postotak podataka koje posjeduju, upravo iz razloga jer ne uspijevaju naći podatke. Danas je prikupljanje podataka postalo jako jeftino, većinom ljudi digitaliziraju podatke, zatim ih analiziraju u baze podataka, tablice i slično. Sustav za prikupljanje podataka podrazumijeva proces koji je dizajniran za prikupljanje informacija, dokumentiranje ili analizu. Tehničar koji nadzire temperaturu pećnice i zatim bilježi te podatke na papir zapravo prikuplja podatke [11]. Razvojem tehnologije proces prikupljanja podataka postao je lakši, pouzdaniji i točniji korištenjem elektroničke opreme. Današnji sustavi putem jednostavnih programa prikupljanju podatke. Sustav za prikupljanje podataka radi kao središnje čvorište, povezuje razne proizvode (senzore, informacijske uređaje) te prikuplja, prikazuje i pohranjuje te informacije. Neke prednosti akvizicije podataka su poboljšana učinkovitost i pouzdanost strojeva i procesa, brže analiziranje problema, eliminiranje ljudskih pogrešaka te poboljšanje kontrole kvalitete. Pri korištenju sustava za

prikupljanje podataka pomaže pri bržem rješavanju problema, omogućuje prikaz rezultata u grafičkom korisničkom sučelju, a sva mjerenja i podatke je jednostavno dokumentirati. Također, omogućuju korisnicima da smanje radnu snagu, poboljšaju učinkovitost, dobivaju se povratne informacije o procesima u stvarnom vremenu, moguće je izvršiti potrebne promjene u procesima te zatim pratiti rezultate tih promjena.

4. ARHITEKTURA SUSTAVA


Arhitektura sustava u kontekstu digitalizacije odnosi se na strukturu, organizaciju i međusobne odnose komponenti unutar informacijskog sustava koji podržava digitalne procese. Digitalizacija podrazumijeva pretvaranje analognih ili tradicionalnih procesa u digitalni oblik, čime se omogućuje bolja integracija, analiza i optimizacija podataka, a samim time postiže se povećanje učinkovitosti i poboljšanja u odnosu na konkurenciju. Trendovi razvoja novih tehnologija mijenjaju se brže nego ikada, a izazovi tržišta pred kojima se organizacije svakodnevno nalaze dodatno su ubrzani. Možda jedan od najvećih izazova organizacijama, a posebno u pandemijsko vrijeme, predstavljao je pristup informacijama i podacima. U većini organizacija informacije su se najčešće nalazile ili u papirnatom obliku ili u različitim formatima unutar pojedinih odjela. Neuređenost podataka i njihova nesortiranost uvelike su otežavale napredovanje u poslovanju te gubitak vremena na nepotrebnim stvarima koje bi proces digitalizacije uvelike olakšao. Samo ovaj primjer predstavlja prioritet uvođenja digitalizacije na svim razinama upravljanja organizacijama [12].

Priprema tvrtke za digitalizaciju i optimizaciju uključuje nekoliko ključnih koraka kako bi se osigurao glatki prijelaz i maksimalna korist od digitalnih transformacija. Nekoliko ključnih koraka koji mogu pojednostavniti proces digitalizacije [13]:

1. Strategija digitalizacije; obuhvaća razumijevanje ključnih poslovnih ciljeva i izazova koji se žele postići digitalizacijom. Potrebno je definirati strategiju, odnosno postaviti jasne ciljeve digitalizacije i izraditi strategiju koja će podržavati te ciljeve.
2. Osnaživanje zaposlenika; organizacija da zaposlenici imaju potrebna znanja i vještine za rad u digitalnom okruženju, potrebno je pružiti obuke o novih tehnologijama i alatima. Uz edukaciju, također, treba poticati inovacije i suradnju kako bi se izgradila digitalna kultura unutar organizacije.
3. Prikupljanje i analiza podataka; prvobitno se identificira vrsta podataka koje tvrtka posjeduje te kako se ti podaci trenutno prikupljaju i koriste, zatim se postavlja infrastruktura za prikupljanje podataka. Ako je potrebno, implementira se sustav i tehnologija za učinkovito prikupljanje i pohranu podataka.

4. Sigurnost podataka; identifikacija potencijalnih sigurnosnih prijetnji i rizika u vezi s digitalnim procesima te postavljanje sigurnosnih mjera kako bi se zaštitili podaci od neovlaštenog pristupa.
5. Integracija sustava; procjena trenutnih informacijskih sustava i kako se oni mogu integrirati u digitalno okruženje. Ukoliko je potrebno uvesti integracijska rješenja, odnosno implementacija alata i tehnologija koje olakšavaju integraciju različitih sustava.
6. Izbor tehnoloških partnera; razmatranje različitih tehnoloških rješenja i odabir onih koja najbolje odgovaraju poslovnim promjenama. Ako je potrebno, surađuje se s vanjskim stručnjacima ili konzultantima kako bi se dobila stručna podrška.
7. Planiranje etapa implementacije; planiranje i implementacija vrše se faza po faza kako biste smanjili rizik i omogućili bolju kontrolu na procesom.
8. Kontinuirano praćenje i prilagodba; praćenje učinkovitosti digitalnih tehnologija i prilagodba strategije prema potrebi te kontinuirano unapređenje kako bi se osigurala stalna optimizacija i prilagodba.
9. Postavljanje ključnih pokazatelja uspješnosti (KPI-jeva); definiranje KPI-jeva, postavljanje istih kako bi se mogao pratiti napredak i postignuća ciljeva.
10. Osiguranje konzistentnosti i standarda; postavljanje standarda za rad u digitalnom okruženju kako bi se osigurala konzistentnost i usklađenost.

Ovi koraci su općenite smjernice, a prilagodba će biti ovisno o specifičnostima tvrtke i industrije. Potrebno je planirati i pratiti svaku fazu kako bi se ostvarila maksimalna korist od digitalizacije i optimizacije.




Slika 5. Prikaz primjera arhitekture sustava [14]

4.1. Primjena arhitekture sustava

Različite kompanije na različite načine slažu svoju arhitekturu sustava, ovisno o potrebi same kompanije, strukturi podataka, alatu koji koriste, stupnju digitalizacije, zaposlenicima itd. Kao što je navedeno u prošlom poglavlju, digitalizacija konkretno dosta ovisi o podacima; o kojoj vrsti podataka je riječ, na koji način su strukturirani, koji su im izvori, kako se prikupljaju, obrađuju, sigurnost tih podataka, optimizacija cijelog procesa te cilj prema kojem se ide.

Izvor podataka može biti iz senzora ili Internet stvari (*eng. Internet of Things*) uređaja, tj. skup senzora i uređaja koji prikupljaju podatke iz fizičkog okruženja, s proizvodnih linija. Dodatni podaci mogu se dobiti iz vanjskih izvora poput podataka o opskrbnom lancu ili vremenskim informacija. Akvizicija podataka podrazumijeva proces prikupljanja, prijenosa i integracije podataka iz različitih izvora u svrhu analize, obrade i korištenja tih podataka u poslovne svrhe. Analizom podataka u stvarnom vremenu omogućuju neprekidno praćenje ključnih pokazatelja iz performansi sustava, dok dubinska analiza generira izvještaje za donošenje odluka. Integracija softvera generalno olakšava i ubrzava pojedine procese te se korištenjem takvih alata može obratiti pozornost na druge dijelove procesa koji su do sada bili zanemareni zbog obima posla koje su oduzimali poslovi koje alat može sam odraditi. Konkretno u ovom slučaju podatke ćemo obrađivati koristeći softversku platformu za prikupljanje i obradu podataka, koja nudi alate za programiranje i optimizaciju. Centralno sučelje omogućuje operaterima praćenje performansi.



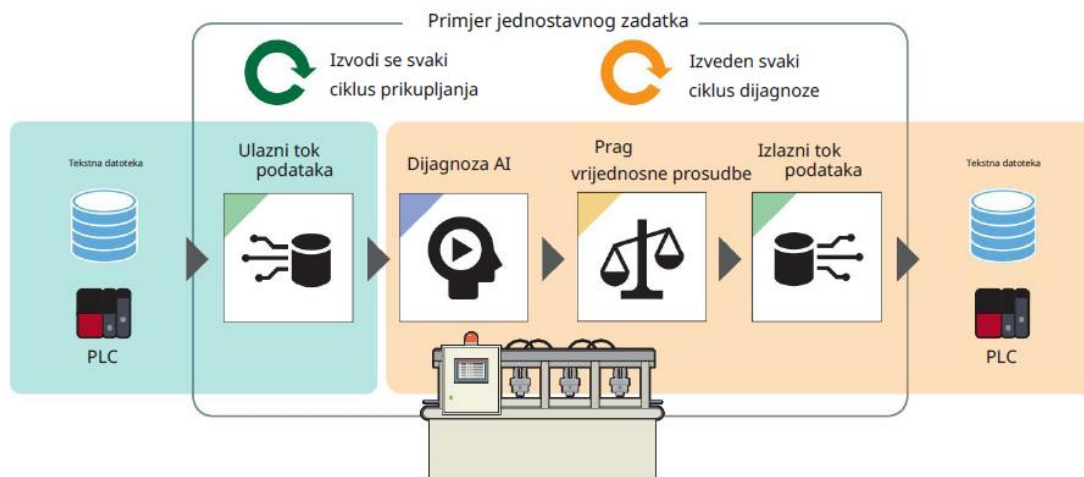
Slika 6. Prikaz određenog procesa digitalizacije [11]

4.2. Softverska rješenja za optimizaciju

Softverska rješenja za prikupljanje i obradu podataka predstavljaju ključnu komponentu u suvremenim poslovnim okruženjima, posebno u industrijskim i proizvodnim sektorima. Ova rješenja omogućuju automatsko prikupljanje raznolikih podataka iz različitih izvora poput senzora, strojeva, računalnih sustava i drugih resursa. Obrada ovih podataka u realnom vremenu omogućuje organizacijama da dobiju brze i precizne uvide u svoje operacije. Softveri za obradu podataka često koriste napredne tehnologije poput analitike, strojnog učenja i umjetne inteligencije kako bi identificirali uzroke, predvidjeli buduće događaje i optimizirali radne procese. Osim toga, ta rješenja olakšavaju praćenje performansi, održavanje opreme, upravljanje zalihama te donošenje informiranih odluka. U konačnici, softverske platforme za prikupljanje i obradu podataka donose efikasnost, transparentnost i inovacije u poslovanje, pridonoseći unapređenju ukupne produktivnosti i konkurentske prednosti organizacija. U nastavku će se opisati i obraditi tri softvera te odabrati jedan softver s kojim će se ići u obradu podataka, a izbor je sveden na MELSOFT MaiLab, KNIME (Konstanz Information Miner) i RapidMiner. Potrebno je napraviti usporedbu kako bi se mogao odabrati optimalan softver. Usporedba ovih softvera mora uključivati kriterije poput skalabilnosti, prilagodljivosti, performansi i ukupnih troškova vlasništva. Razmatranje korisničkih recenzija, podrške za korisnike i implementacijske fleksibilnosti također igra ključnu ulogu u donošenju informirane odluke. Kroz temeljitu analizu, odabrat će se softver koji najbolje odgovara specifičnim potrebama, pružajući optimalnu kombinaciju funkcionalnosti, pouzdanosti i ekonomske isplativosti za postizanje ciljeva prikupljanja i obrade podataka u našem poslovnom kontekstu.

4.2.1. MELSOFT MaiLab

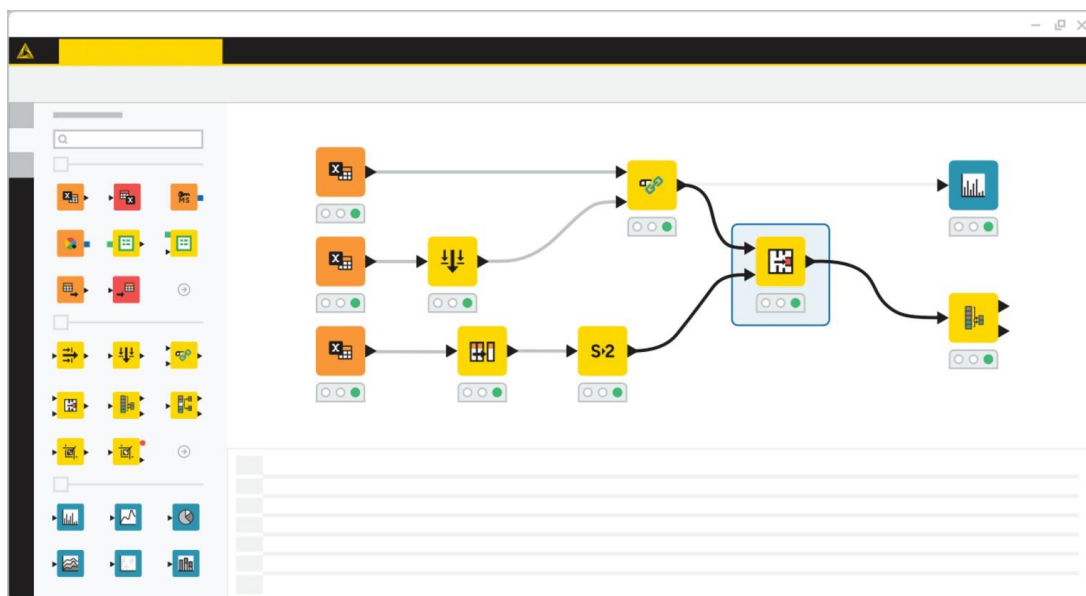
MaiLab je softverski alat razvijen od strane Melsoft Mitsubishi Electric Corporationa, alat je koji omogućuje prikupljanje, praćenje i analizu podataka u proizvodnom okruženju. Ključne značajke uključuju sposobnost povezivanja s različitim izvorima podataka, praćenja performansi opreme, generiranje izvještaja te olakšavanje procesa donošenja odluka u proizvodnom okruženju. MaiLab je softver baziran na umjetnoj inteligenciji koji prati cijeli proces proizvodnje i na osnovu brojnih parametara unapređuje proizvodnju i smanjuje broj loše proizvedenih dijelova. Alat je za proučavanje podataka koji dodatno unapređuje proizvodnju zamjenjujući ljudsko iskustvo i intuiciju digitalnom tehnologijom i omogućava jednostavnu ugradnju u nove i postojeće upravljačke sustave [15].



Slika 7. Prikaz procesa u MaiLab-u [16]

4.2.2. KNIME


KNIME (Konstanz Information Miner) predstavlja otvoreni softverski alat za analizu i procesiranje podataka, dizajniran s ciljem integracije, analize, vizualizacije i interpretacije podataka. Ovaj alat nudi korisnicima grafičko sučelje koje omogućava jednostavno povezivanje čvorova u radnom prostoru, olakšavajući stvaranje, prilagodbu i dijeljenje kompleksnih analitičkih tokova. Sve se odvija u radnom prostoru za analitiku, gdje se čvorovi postavljaju i organiziraju kako bi oblikovali tok podataka. KNIME obuhvaća širok spektar čvorova koji podržavaju različite zadatke, uključujući čišćenje podataka, analizu, strojno učenje, statistiku i druge. Sposoban je raditi s različitim formatima podataka, kao što su tekstualne datoteke, baze podataka, Excel tablice i slike. Fleksibilnost KNIME-a proširuje se kroz dodatke i podršku za integraciju s drugim alatima, omogućujući prilagodbu alata prema specifičnim potrebama korisnika. Osim analize podataka, KNIME pruža bogat skup alata za strojno učenje, podržavajući izgradnju, treniranje i evaluaciju modela, uz posebnu potporu za rad s velikim skupovima podataka i integraciju s distribuiranim sustavima. Sve ove značajke čine KNIME snažnim alatom za istraživače podataka, analitičare i znanstvenike, omogućujući im intuitivan pristup analizi podataka i donošenju informiranih odluka [17].



Slika 8. Prikaz procesa KNIME-u [18]

4.2.3. *RapidMiner*

RapidMiner predstavlja sofisticirani alat za analizu podataka i strojno učenje s fokusom na jednostavnu upotrebu i snažne analitičke mogućnosti. S grafičkim korisničkim sučeljem, ovaj alat omogućuje korisnicima da kreiraju analitičke procese povezivanjem vizualnih čvorova u radnom prostoru. Ključne značajke uključuju modularnost, podršku za rad s velikim skupovima podataka te integraciju s različitim izvorima podataka poput baza podataka i Excel tablica. RapidMiner se ističe bogatstvom algoritama strojnog učenja prilagođenih za različite zadatke, omogućujući klasifikaciju, regresiju, grupiranje i druge analize. Automatski odabir najboljih modela i parametara putem optimizacije olakšava korisnicima postizanje preciznih rezultata. Vizualizacija rezultata analize kroz grafove, tablice i druge vizualne prikaze dodatno olakšava interpretaciju rezultata. RapidMiner podržava rad s velikim količinama podataka, što omogućuje analizu i obradu velikih količina podataka. Ova svestrana platforma zadovoljava potrebe korisnika različitih stručnosti, od početnika do iskusnih stručnjaka za podatke, nudeći intuitivan pristup analizi podataka i informiranim odlukama [19].



Slika 9. Prikaz procesa u RapidMiner-u [20]

4.3. Usporedba softvera za obradu podataka

Svaki od prethodno navedenih alata ima svoje specifičnosti, a odabir između njih ovisi o konkretnim potrebama i preferencijama korisnika. MaiLab se često koristi u industrijskim postavkama za praćenje proizvodnje, dok KNIME i RapidMiner pružaju širu paletu funkcionalnosti za analizu podataka i strojno učenje, čime su popularni u različitim sektorima, uključujući istraživanje i poslovnu analizu. Usporedba softvera prikazana je niže u [Tablica 1].

Tablica 1. Usporedba softvera

	Specifičnosti	Prednosti	Ograničenja
MaiLab	Fokusiran na industrijsko praćenje i upravljanje proizvodnjom.	Integracija s opremom, praćenje performansi, olakšava donošenje odluka u proizvodnom okruženju.	Može biti specifičan za industrijske primjene,
KNIME	Platforma otvorenog koda za analizu	Fleksibilnost, podrška za različite izvore podataka,	Zahtijeva određeno vrijeme prilagodbe,

	podataka s vizualnim sučeljem.	alati za analizu i modeliranje podataka.	posebno za početnike.
RapidMiner	Softver za analizu podataka i strojno učenje s naglaskom na jednostavno vizualno modeliranje.	Brza implementacija modela, bogat skup alata za strojno učenje, podrška za velik broj formata podataka.	Nešto manje fleksibilnosti od KNIME-a u određenim aspektima.

Konačni odabir ovisi o konkretnim zahtjevima projekta, razini stručnosti korisnika te integraciji s postojećim sustavima. Ako je glavni fokus praćenje i upravljanje proizvodnim procesima, MaiLab može biti optimalan izbor. Ako je potrebna šira paleta funkcionalnosti s naglaskom na otvorenost i fleksibilnost, KNIME je dobra opcija. Ukoliko je potrebno jednostavno i brzo vizualno modelirati podatke, RapidMiner može zadovoljiti potrebe.

Pošto se u ovom slučaju radi o optimizaciji procesa u proizvodnom sustavu, MaiLab se nameće kao optimalan izbor koji može zadovoljiti sve potrebe, a pri tome je i jednostavan za uporabu. Naglasak potrebnog softvera je na jednostavnosti te nije potrebna široka paleta funkcija što također izdvaja MaiLab kao zadovoljavajući softver. MaiLab daje uvid u broj dobro i loše proizvedenih komada, prati kontrolu kvalitete te na temelju informiranih odluka daje prijedloge poboljšanja. U konačnici, odabir MaiLab-a preporučuje se kada je glavni fokus na optimizaciji proizvodnih procesa, posebno u kontekstu industrije gdje su integracija s opremom i praćenje performansi ključni faktori. Na osnovu svih navedenih karakteristika, predstavljenih softvera te međusobne usporedbe, MaiLab se uzima kao alat pomoću kojeg će se provesti analiza podataka i dati prijedloge poboljšanja te samim time poraditi na optimizaciji procesa.

4.4. Teorijski prikaz MaiLab-a

Brojne tvrtke koje se bave proizvodnjom dolaze do velikih problema kada iskusni operateri odlaze u zasluženu mirovinu. Posao preuzimaju mladi, neiskusni operateri koji ne mogu jednako reagirati na različite stvari koje se događaju u procesu proizvodnje jer to zahtijeva dugotrajan proces praćenja i učenja. Automatizacija opreme napreduje, ali još uvijek postoji mnogo procesa koji se oslanjaju na iskustvo radnika na licu mjesta. Digitalizacijom

takvog znanja može se postići nasljeđivanje vještina, suočavanje s nedostatkom radne snage, smanjenje troškova, poboljšana produktivnost i kvaliteta itd.


MaiLab ima tri glavne značajke [21]:

- I. "AI Data Scientist" - sustav podrške za analizu umjetne inteligencije koji omogućuje korištenje podataka bez specijaliziranog znanja. AI Data Scientist omogućuje iskorištavanje podataka kao da podatkovni znanstvenik sjedi odmah do. Opremljen je obiljem analitičkih metoda i može se koristiti u razne svrhe usvajanjem mnogih metoda strojnog učenja i statističke analize, poput dubokog učenja i analize višestruke regresije. Osim toga, MaiLab ne zahtijeva programiranje, pa je lako konfigurirati i odmah započeti analizu podataka. U prošlosti je analiza podataka zahtijevala razna znanja i stručnost. AI Data Scientist, zahvaljujući funkciji automatskog strojnog učenja ugrađenoj u MaiLab, automatski odabire metode obrade podataka i analize te provodi analizu. To olakšava izgradnju modela učenja bez specijaliziranog znanja. Također moguće je prilagoditi modele učenja izgrađene od strane AI Data Scientist prema vlastitim željama. Mogu se koristiti prošireni blokovi za prilagodbu modela. Osim toga, ako želimo programirati sami, mogu se izgraditi precizniji modeli učenja kodiranjem pomoću Pythona, koji se često koristi u analizi podataka.
- II. Strojno učenje - za razliku od tradicionalnih metoda u kojima ljudi pronalaze i formuliraju korelacije između podataka, strojno učenje MaiLab-a uči iz povijesnih podataka proizvodnje. Može donositi ključne odluke ili preporuke koje su tradicionalno zahtijevale nebrojene radne sate. Osim prosudbe "prolazi/ne prolazi" poput prediktivnog održavanja, ova značajka izvodi višestruke odgovore, čime postaje učinkovita za primjene koje su konvencionalno zahtijevale znanje inženjera. Primjerice, učeći iz povijesnih čimbenika koji uzrokuju kvarove na stroju, moguće je procijeniti čimbenike bez specijaliziranog znanja kada se pojave slični čimbenici. U slučaju obrade, kroz kontinuirano učenje operativnih zapisa, moguće je predložiti optimalne parametre na stroju bez pomoći stručnih radnika. To pridonosi nedostatku prijenosa stručnog znanja.
- III. Sofisticiran dizajn - pružanje intuitivnog sučelja i iskustva čini ga jednostavnim čak i za korisnike koji ga koriste prvi put. Sofisticirani dizajn i bogati prikazi grafikona omogućuju analizu iz različitih perspektiva. Uređivanje modela učenja i njihovo implementiranje na dijagnostičke uređaje također je intuitivno i lako za svakoga. Osim

toga, grafički prikaz i druge funkcije praćenja omogućuju intuitivan pristup informacijama koje su potrebne. Primjerice, kada se više strojeva dijagnosticira u stvarnom vremenu, moguće je pregledati dijagnozu svakog stroja pojedinačno ili jedan pored drugoga, ovisno o potrebama. Osim toga, ako se koristi pametni telefon ili tablet, može se provjeriti dijagnostička situacija iz bilo kojeg mjesta.

Što MaiLab sve može? Uključuje automatsku izradu pomoću umjetne inteligencije čak i početnicima u analizi podataka. Obraduje sve vrste podataka, a analizu i dijagnozu izvršava s jednim alatom. Rješava mnogo izazova, razne procese koji su temeljeni na ljudskom iskustvu i intuiciji [22]:

- Smanjenje troškova – obično, vrijeme zamjene potrošnog materijala određuje se na temelju vremena i broja upotreba. Analizom i dijagnosticiranjem podataka o potrošnom materijalu, može se razumjeti stanje potrošnog materijala i zamijeniti ga u optimalnom trenutku, što rezultira smanjenjem troškova.



Slika 10. Prikaz smanjenja troškova zamjenom alata [22]

- Nasljeđivanje vještina i ušteda radne snage – unos parametara za proizvodnu opremu obično se oslanja na stručnost iskusnih radnika. Korištenjem umjetne inteligencije moguće je digitalizirati stručnost iskusnih radnika, koja je teška za dokumentiranje, i podržati prijenos vještina na početnike.



Slika 11. Nasljeđivanje vještina i ušteda radne snage [22]

- Poboljšana produktivnost – kako bi se spriječili iznenadni kvarovi koji smanjuju radne stope, potrebno je pratiti status opreme i izvršiti održavanje prije nego dođe do kvara. Digitalizacijom statusa opreme i njegovom analizom pomoću umjetne inteligencije mogu se predvidjeti kvarovi, što dovodi do poboljšane produktivnosti.



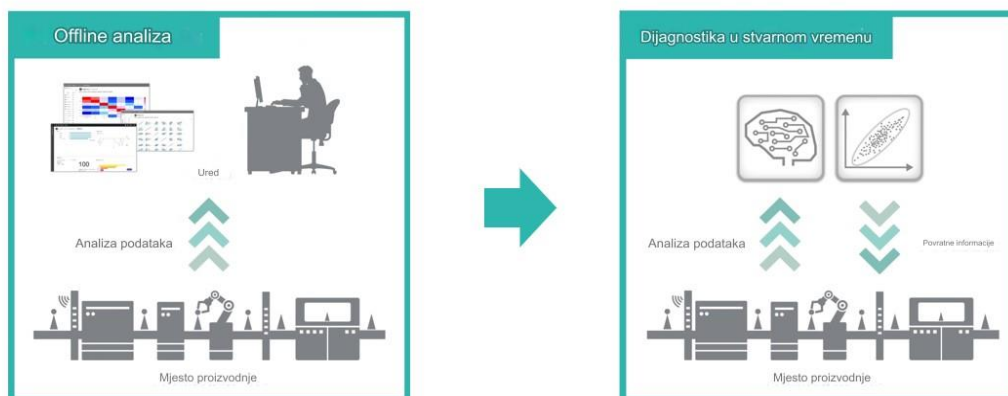
Slika 12. Praćenje produktivnosti [22]

- Poboljšana kvaliteta – kada ljudski operateri vizualno pregledavaju kvalitetu proizvodnje koristeći grafičke podatke, javlja se ljudska varijabilnost. Izvođenjem inspekcija kvalitete pomoću umjetne inteligencije moguće je provesti detaljne inspekcije bez varijacija i poboljšati kvalitetu proizvoda.



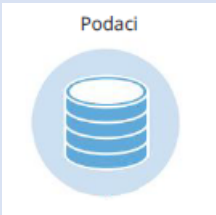
Slika 13. Poboljšanje kvalitete [22]


Korištenje podataka u tvorničkoj automatizaciji podijeljeno je u dvije faze. U prvoj fazi unaprijed se analiziraju podaci prikupljeni iz proizvodnje, a u sljedećoj fazi započinje dijagnostika na mjestu proizvodnje na temelju rezultata analize. Faze su prikazane na [Slika 14].




Slika 14. Prikaz dviju faza korištenja podataka

Korištenje MaiLab-a je jednostavno i opisano je kroz četiri koraka, prikupljanje podataka prethodi analizi te nakon što su podaci prikupljeni kreće se u analizu od četiri koraka [23]:

Prikupljanje podataka	
	<p>Potrebno je istražiti koje podatke treba prikupiti te kako ih treba prikupiti.</p>

Offline analiza	
	<p>Korak 1: Stvaranje skupa podataka</p> <p>Prvo je potrebno pročitati podatke za analizu u MaiLab-u i registrirati ih. Grupa registriranih podataka naziva se „Skup podataka“. Skup podataka može se prikazati u raznim vrstama grafikona, te se tako može lako provjeriti ljudskim očima prije izvođenja dijagnoze pomoću umjetne inteligencije.</p>

Offline analiza	
	<p>Korak 2: Stvaranje umjetne inteligencije</p> <p>Izvodi se učenje iz skupa podataka. Model koji omogućuje dijagnozu nepoznatih podataka naziva se „AI“. Kada je odabrano što se želi postići („cilj“), pravilnost i pravila podataka automatski se izvode, a MaiLab stvara „AI“.</p>

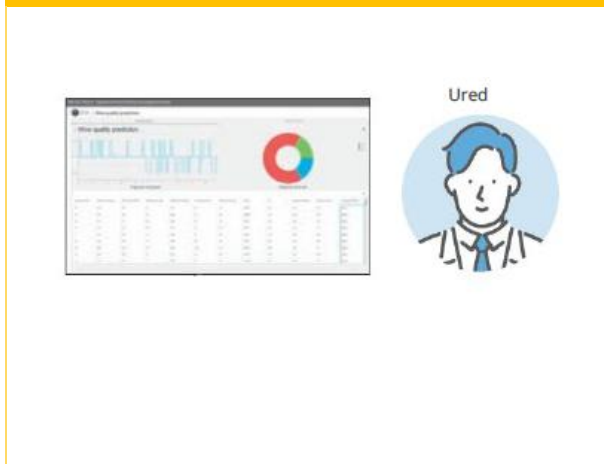
Dijagnoza u stvarnom vremenu



Korak 3: Izrada zadatka

Postavke za izvođenje dijagnoze nepoznatih podataka nazivaju se „Zadatak“. Mailab će definirati unos podataka, izlazne metode i granične vrijednosti za to jesu li dijagnostički rezultati dobri ili loši. Točnost se prikazuje kao rezultat koji služi kao smjernica za prosudbu.

Dijagnoza u stvarnom vremenu

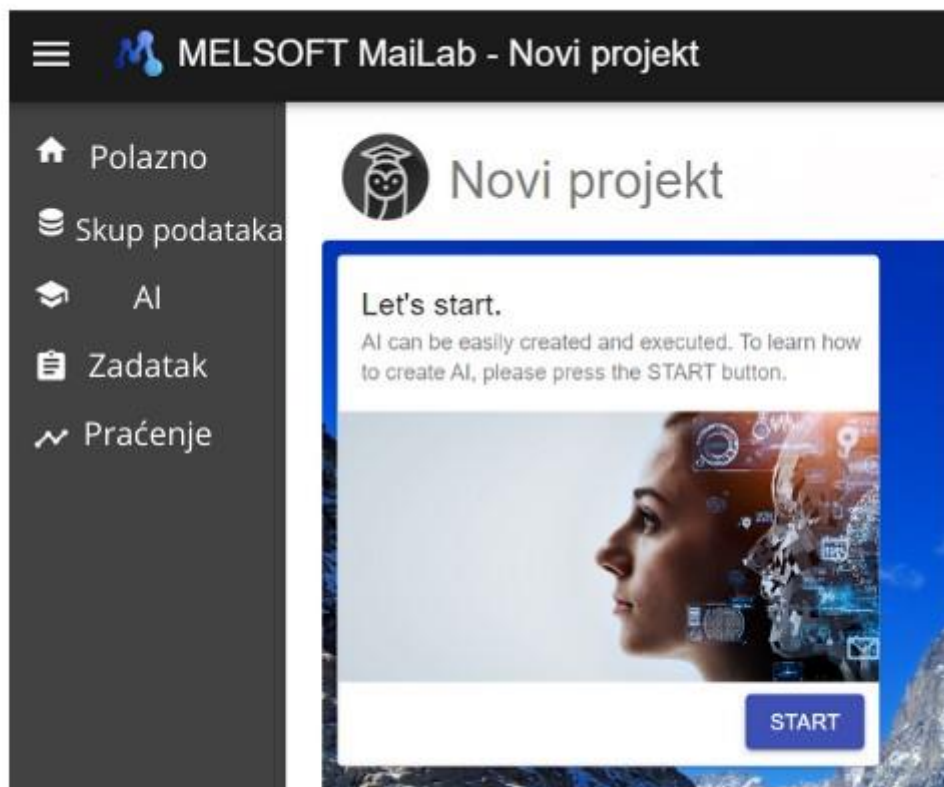


Korak 4: Izvršenje zadatka i praćenje

Moguće je izvršavati i pratiti status dijagnoze nepoznatih podataka, a postavljanje na opremu je jednostavno i izvršava se samo jednim klikom. Tijek podataka i status dobro ili loše procjene mogu se potvrditi na grafičkom prikazu putem poslužitelja za učenje.

Pokretanjem MaiLab-a otvara se korisničko sučelje prikazano na [Slika 15] koje je jednostavno i pregledno. S lijeve strane u izborniku vide se svi dijelovi MaiLab-a koji su opisani prethodno; skup podataka, AI, zadatak i praćenje te svaki od njih vodi do jednog od četiri faze u analizi podataka pritiskom na samu ikonu. MaiLab omogućuje učitavanje podataka u različitim formatima poput CSV i TSV datoteka. Nakon učitavanja podataka, slijedi korak odabira analitičke metode pomoću umjetne inteligencije, uključujući strojno učenje i statističku analizu, prilagođeno potrebama korisnika. Zatim, nakon što je odabrana metoda, MaiLab automatski obavlja pretprocesiranje i analizu podataka u odjeljku zadatak. A konačni rezultati analize

prikazuju se na sučelju gdje korisnici mogu lako interpretirati rezultate i donositi informirane poslovne odluke, a rezultati su vidljivi u odjeljku praćenje.

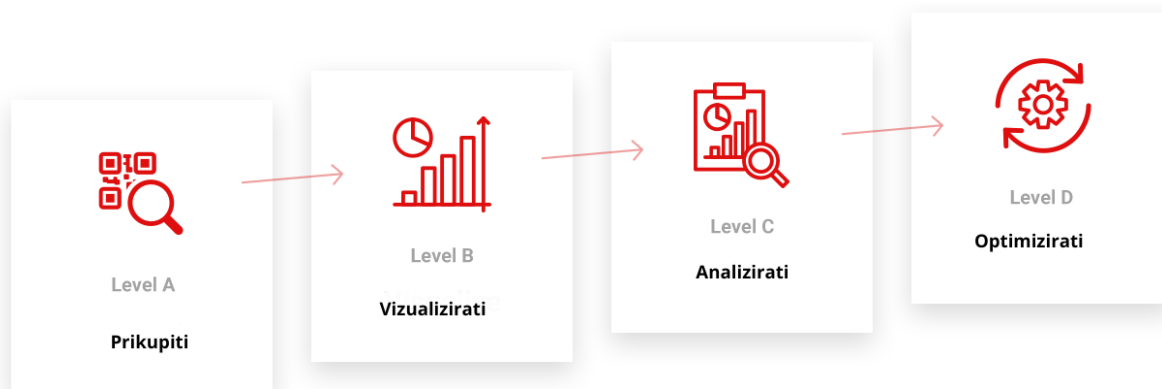


Slika 15. Korisničko sučelje MaiLab-a

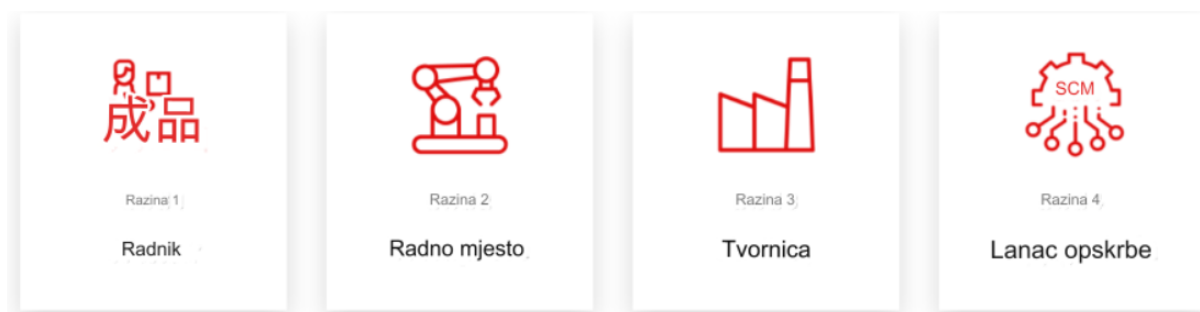
4.5. Smart Manufacturing Kaizen Level

U procesu digitalizacije svaka kompanija treba odlučiti kako započeti s digitalizacijom, koje korake napraviti te na koji način i uz pomoć kakvih alata uvesti procese digitalizacije. Kako započeti s digitalizacijom? Zašto je digitalizacija stvarno važna? Na koji način poboljšati učinkovitost? Na takva i slična pitanja odgovori se mogu pronaći u japanskoj filozofiji upravljanja. Kaizen je japanski izraz koji se koristi u poslovnom kontekstu i znači stalno poboljšanje. Glavna ideja iza Kaizena je stalno traženje, identificiranje i implementacija poboljšanja u procesima, proizvodima i organizaciji kako bi se postigla kontinuirana efikasnost i kvaliteta. Primjenom Kaizena tvrtke poboljšavaju svoje poslovanje, optimiziraju procese te konstantno teže prema većem uspjehu. Neki ključni elementi Kaizena uključuju kontinuirano poboljšanje, uključivanje svih zaposlenika, smanjenje gubitaka, timski rad, standardizaciju[24].

Fokusira se na postizanje malih poboljšanja u svim aspektima poslovanja, na svim razinama organizacije, od radnika na proizvodnoj liniji do viših menadžera. Fokus Kaizena je na eliminiranju gubitaka u procesima, cilj je postići učinkovitost i smanjenje nepotrebnih troškova. Nakon postizanja poboljšanja procesi se standardiziraju kako bi se osiguralo da se takav način poslovanja i dobitci zadrže. Upravo Smart Manufacturing Kaizen Level (dalje u tekstu SMKL) provodi i integrira koncept Kaizena u pametne proizvodne procese, potičući poboljšanje i efikasnost kroz tehnologije i inovacije. Svrha SKML-a je prilagoditi se zahtjevima poput povećanja produktivnost i smanjenja emisije CO₂ u pametnoj proizvodnji, istovremeno podržavajući vođenje implementacije i metode evaluacije performansi sustava kako bi se postigla koordinacija veza između procesa implementacije i Kaizena [24]. Jedna od ključnih stvari za početak i uspješnu digitalizaciju je pravilno iniciranje procesa prikupljanja, organizacije i analize podataka kao temeljnog koraka prema učinkovitom transformiranju operacija, pa tako SMKL ocjenjuje zrelost na temelju matrice od četiri razine zrelosti i četiri razine upravljanja. Stupnjevi zrelosti, prikazani na [Slika 16], su prikupiti, vizualizirati, analizirati i optimizirati, dok su razine upravljanja instalacija i radnici, radno mjesto, tvornica i opskrbeni lanac, prikazane na [Slika 17].





Slika 16. Stupanj zrelosti po SMKL-u [25]





Slika 17. Razine upravljanja po SMKL-u [25]

Razina zrelosti u proizvodnim operacijama, s naglaskom na kontinuirano poboljšanje, koristi se kao konkretna mjera sposobnosti razumijevanja i unaprjeđivanja proizvodnih operacija, pri čemu se osobitosti izražavaju u smislu sposobnosti procesa na odgovarajućoj razini korištenja podataka na razini upravljanja. Različite razine upravljanja obuhvaćaju kompleksnost i tempo od trenutne situacije do cilja, što dovodi do različitih točaka primjene napora u implementaciji. Opis postupka rada te pripadajući primjeri svakog koraka razine zrelosti prikazani su u [Tablica 2]. Počevši s prikupljanjem različitih podataka, SMKL postavlja pitanja mogu li se ti podaci vizualizirati ili analizirati, zatim koliko se može optimizirati kako bi se postigao određeni cilj.

Tablica 2. Definicija razina zrelosti

Razina zrelosti		Opis	Primjer
a	Prikupiti 	Podaci o proizvodnji, status instalacije ili rada, prikupljaju se i pohranjuju elektronskim putem automatski ili ručno s jednostavnim postupkom unosa.	<ul style="list-style-type: none"> - Baza podataka - CSV datoteka
b	Vizualizirati 	Grafovi ili tablice automatski se generiraju na temelju prikupljenih i/ili pohranjenih podataka o proizvodnji zajedno sa ciljem upravljanja.	<ul style="list-style-type: none"> - Opis popisa - Opis grafikona (histogram, trend i sl.)

c	Analizirati 	Grafovi i tablice koje opisuju usporedbu ciljane izvedbe s trenutnim statusom uz varijacije automatski se generiraju prema razini zrelosti. Na primjer, ručna analitika radnika može biti izuzeta.	<ul style="list-style-type: none"> - Upravljanje proizvodnim operacijama - Rješavanje problema
d	Optimizirati 	Kaizen instrument automatski pruža povratne informacije o upravljačkim ciljevima kako bi riješio razlike u izvedbi koje su specificirane na razini zrelosti.	<ul style="list-style-type: none"> - Kaizen pokrenut umjetnom inteligencijom

[Slika 18] prikazuje kako je SMKL predstavljen kao matrica sa 16 kvadrata, a izražava se kao metoda za procjenu trenutne razine i njezino poboljšanje do sljedećeg koraka. SMKL procjenjuje trenutnu situaciju pametne proizvodnje kroz svoju matricu koristeći sljedeće korake za procjenu:

- Evaluacijski indeks za usvajanje interneta stvari (IoT) dostupan je za svaki pojedini uređaj, radnika, radnog mjesta, lanca, tvornice i lanca opskrbe.
- Koristan je za aktivnosti kontinuiranog poboljšanja (Kaizen) jer omogućuje shvaćanje razine vizualizacije podataka potrebne za digitalnu transformaciju na proizvodnom mjestu.
- Uprava i odgovorna osoba mogu donijeti planiranu odluku o ulaganju za usvajanje digitalne transformacije u tvornici.

Optimizacija može nastati na svakoj razini, sve do cijele tvornice i čitavog lanca opskrbe, što dovodi do značajnih poboljšanja poslovanja.

Razina D Optimizirati				
Razina C Analizirati				
Razina B Vizualizirati				
Razina A Prikupiti				
	Razina 1 Radnik	Razina 2 Radno mjesto	Razina 3 Tvornica	Razina 4 Lanac opskrbe

Razine zrelosti


Razine upravljanja

Slika 18. SMKL matrica

Kako koristiti SMKL matricu? Postavljaju se specifična pitanja i istražuje se gdje je korisnik sada i kojim putem treba ići da postigne svoj cilj.

- Gdje se trenutno nalaziš?
- Gdje želiš biti?
- Koji su vaši nedostaci?

Pružajući odgovore na ova i slična pitanja moguće je odrediti trenutnu poziciju te se može donijeti odluka za kapitalna ulaganja jer će se pokazati koju vrstu opreme treba uvesti i koliko je ulaganja potrebno. [Slika 19] prikazuje značajke SMKL-a po matrici, od pozicije na kojoj se nalazimo do ciljnih pozicija te smjernice kako doći do željenog cilja uz velika ulaganja. Najbitnije je na početku prepoznati na kojoj poziciji se trenutno nalazimo te uz koje promjene na određenim razinama doći do postavljenog cilja, promjene je moguće provesti kroz sve razine upravljanja i zrelosti.




Slika 19. Prikaz značajki SMKL-a

Pri postavljanju pitanja za određivanje trenutačne pozicije tvrtke po razinama u matrici, ključno je ispitati različite aspekte poslovanja kako vi se dobila cjelovita slika. Pitanja se fokusiraju na područja kao što su digitalna transformacija, stupanj usvajanja tehnologija, razine automatizacije, efikasnost proizvodnih procesa, pristupi kontinuiranom poboljšanju (Kaizen), sustavi vizualizacije podataka i upravljanje ključnim pokazateljima uspješnosti. Osim toga, važno je provesti istraživanje o postojećim sustavima za praćenje učinkovitosti strojeva, praćenju kvalitete primjenom statističkih metoda (SPC), održavanju robota te planovima za korištenje analize vibracija na uređajima. Integriranjem tih pitanja, tvrtka može bolje procijeniti svoju trenutačnu poziciju, identificirati nedostatke i prepoznati područja za daljnje poboljšanje. Neka od pitanja za postavljanje po svim razinama zrelosti i upravljanja prikazana su na [Slika 20].


	Razine zbirne			
Razina D Optimizirati				
Razina C Analizirati	Imate li sustav za praćenje učinkovitosti strojeva (OEE)? Mjerite li potrošnju energije i računate EPU parametar?		Pratite li kvalitetu na stvaran način pomoću SPC metoda? Pratite li trošenje vaših robota? Planirate li koristiti analizu vibracija vaših uređaja? Pratite li svoje KPI-jeve u stvarnom vremenu?	
Razina B Vizualizirati	Na kojoj razini trenutno vizualizirate statuse i povijesne podatke? Jesu li informacije vidljive samo na razini stroja? Osim praćenja, želite li i kontrolirati?		Imate li centralni sustav vizualizacije u tvornici (npr. SCADA)? Imate li poslovni oblak?	
Razina A Prikupiti	Prikupljate li podatke? Radite li to na automatiziran način? Imate li centraliziran sustav prikupljanja podataka? S koliko uređaja prikupljate podatke?		Kojim uređajima prikupljate? Koliko često? Koliko informacija skupite sa svakog uređaja? Planirate li slati podatke u oblak?	
	Razina 1 Radnik	Razina 2 Radno mjesto	Razina 3 Tvornica	Razina 4 Lanac opskrbe
				Upravljanja

Slika 20. Prikaz pitanja po razinama matrice

Optimizacija na razini stroja ili proizvodne linije predstavlja ključan korak prema postizanju učinkovitijih i produktivnijih operacija u industrijskom okruženju. Te razine u matrici predstavljaju polja 1D i 2D, a prikazani su na [Slika 21]. Kada se optimizacija primjenjuje od pojedinačnih radnih mjesta i svakog radnika dolazi do povećanja produktivnosti, smanjenja gubitaka vremena i resursa te se poboljšava radna učinkovitost. Osim toga, optimizacija na razini radnika doprinosi stvaranju pozitivnog radnog okruženja, potiče motivaciju i angažman zaposlenika te može rezultirati boljom kvalitetom proizvoda ili usluga. Kroz primjenu optimizacije na ranoj razini, poput radnika, postavlja se temelj za kontinuirano poboljšanje cijelog proizvodnog procesa. Korištenje alata poput Mailab-a omogućuje precizno prikupljanje, analizu i interpretaciju podataka kako bi se identificirali potencijalni nedostaci ili prostori za poboljšanje. Mailab pruža sredstva za praćenje ključnih pokazatelja performansi, učinkovito upravljanje resursima, te prilagodbu i optimizaciju parametara rada strojeva ili proizvodne linije. Kroz detaljnu analizu prikupljenih podataka, tvrtke mogu donositi informirane odluke o prilagodbama u procesima proizvodnje sa ciljem postizanja maksimalne učinkovitosti. Mailab tako postaje nezamjenjiv alat u postizanju optimizacije na razini stroja ili proizvodne linije, pridonoseći konkurentске prednosti i unapređenju ukupnih poslovnih performansi. Na [Slika 22] nalazi se ilustracija kako MaiLab služi kao most između proizvodnih procesa na terenu i analitičara u uredu, stvarajući integrirani sustav za praćenje, analizu i optimizaciju poslovanja.




Slika 21. Optimizacija na razinama 1D-2D



Slika 22. Ilustracija integracije MaiLab-a [22]

5. OPIS EKSPERIMENTA

Pametna tvornica za učenje oblik je kibernetičko fizičkog sustava što znači da se digitalno upravlja fizičkim mehanizmima. CP tvornica (*eng. Cyber-Physical Factory*) razvijena je u bliskoj suradnji s nastavnicima i instruktorima. Rezultat je sustav za obuku na kojem se mogu prikazati i vježbati teme o mrežama, komunikaciji i prikupljanju podataka na jednostavan i razumljiv način. Dizajnirana je u svrhu pomaganja u učenju i pripremi za rad u industrijskim procesima [26]. Model tvornice na Fakultetu Strojarstva i Brodogradnje Sveučilišta u Zagrebu sastoji se od četiri različita modula: spremnika, bušilice, preše i pokretne trake; prikazano na [Slika 23].




Slika 23. Prikaz Pametne tvornice na Fakultetu Strojarstva i Brodogradnje

Pametna tvornica je model za učenje koji simulira proizvodnju procesa određenog proizvoda, a u ovom slučaju to je simulacija proizvodnje sklopa koji se sastoji od prednjeg [Slika 24] i stražnjeg poklopca [Slika 25]. To su dva osnovna dijela proizvoda pri čijoj proizvodnji će se pratiti određeni parametri, te promjenom tih vrijednosti pokušat će se dobiti optimalan iznos svih parametara za dobivanje idealnog proizvoda, a za određivanje iznosa pojedinih parametara koristit će se softver MaiLab koji pomoću umjetne inteligencije daje vrijednosti za optimalan proces.




Slika 24. Prednji poklopac [26]



Slika 25. Stražnji poklopac [26]

Dijelovi proizvoda kreću se po pokretnoj traci tako da se postavljaju na palete [Slika 26] koje stoje na nosačima [Slika 27]. Nosači s paletama skidaju se s pokretne trake kada je potrebno izvršiti ručni rad ili kada je proizvod gotov. Kada nosače detektira senzor koji signalizira da su došli u položaj u kojem treba izvršiti neku aktivnost (prešanje ili bušenje) aktivirat će se stoper i izaći će vijak koji će zaustaviti nosač kako bi se mogla izvršiti potrebna aktivnost. Kada je aktivnost izvršena, vijak će se vratiti u početni položaj i nosač će nastaviti dalje [27]. Nosači su opremljeni RFID čipovima, radiofrekvencijska identifikacija (*eng. Radio Frequency Identification*), koji omogućuju slanje podataka u MES (*eng. Manufacturing Execution System*) sustav kako bi se

znalo u kojem se dijelu procesa nalazi proizvod te kako bi se omogućilo upravljanje dijelovima procesa. Radiofrekvenzijska identifikacija je sustav koji omogućuje bežičnu razmjenu podataka između čipa i antene pomoću radio valova. Kad antena registrira valove, šalje podatke računalu koje ih dalje obrađuje [28].



Slika 26. Paleta [26]



Slika 27. Nosač [26]

5.1. Opis procesa

Simulirani proces proizvodnje sastoji se od kretanja poluproizvoda po pokretnoj traci između radnih stanica. Sam proces na modelu tvornice za učenje započinje ispuštanjem stražnjeg poklopca iz spremnika na paletu koja pokretnom trakom na nosaču putuje između radnih stanica, stvarni prikaz na [Slika 28]. Na prvoj radnoj stanici se simulira bušenje potrebnog broja provrta, nakon što je simulacija izvršena, nosač putuje do preše koja se u prvom

krugu ne aktivira jer nema prednjeg poklopca. Zatim se u drugom krugu na paletu ispusti i prednji poklopac, na stražnji iz prvog kruga, te nastavlja putovati pokretnom trakom do radne stanice za prešanje, preskačući sada bušenje. Kada nosač napravi dva kruga po pokretnoj traci proces je završen te je dobiven jedan proizvod. Radne stanice sastoje se od operacija koje imaju podešene određene parametre koje je moguće mijenjati, a promjenom tih parametara utječe se na optimizaciju procesa. Npr. kod radne stanice za bušenje moguće je promijeniti brzinu bušenja, a kod prešanja može se definirati sila i vrijeme prešanja. Promjenom vremena pri bušenju i prešanju mijenja se vrijeme trajanja ukupnog procesa, ali ipak najveći udio ukupnog vremena trajanja procesa određeno je brzinom pokretne trake, odnosno vremenom vožnje nosača po pokretnoj traci između radnih stanica.




Slika 28. Tvornica za učenje s radnim stanicama [29]

5.1.1. Pokretna traka

Pokretna traka, prikazana na [Slika 29], povezuje radne stanice tvornice za učenje, a sastoji se od glavne pokretne trake te dvije trake za odvod ili dovod nosača. Pogoni ju elektromotor, a


ima i senzor za detekciju nosača te usmjerivač. Kada senzor detektira nosač iskače usmjerivač koji preusmjerava nosač na traku koja vodi do sljedećeg koraka u procesu. Brzina vožnje nosača na pokretnoj traci znatno utječe na ukupno vrijeme trajanja procesa.



Slika 29. Pokretna traka [26]

5.1.2. Spremnik


Spremnik, prikazan na [Slika 30], je modul koji sadrži poklopce koji se ispuštaju na nosač s paletom u trenutku kada on dođe u potreban položaj. Sadrži i prednje i stražnje poklopce koje ispušta ovisno o potrebi i postavljenoj konfiguraciji, a za ispuštanje različitih poklopaca potrebno je na drugačiji način postaviti module u konfiguraciji. Kada nosač s paletom prođe svjetlosnu barijeru, zaustavlja se te se cilindar za podizanje pomiče prema dolje. Poklopac se ispusti na nosač, cilindar se podigne u početni položaj, a nosač s poklopcem se nastavlja kretati po pokretnoj traci [26].



Slika 30. Spremnik [26]

5.1.3. Bušilica


Bušilica, prikazana na [Slika 31], služi za simulaciju bušenja dva provrta na stražnjem poklopcu. Kada nosač s poklopcem prođe svjetlosnu barijeru, zaustavlja se te se cilindar jedinice za bušenje pomiče i spušta, a svrdla se rotiraju određenom brzinom i simuliraju bušenje provrta. Nakon bušenja se cilindar vraća u početni položaj, a nosač s poklopcem nastavlja se kretati prema sljedećoj radnoj stanici [26].



Slika 31. Bušilica [26]

5.1.4. Preša


Preša, prikazana na [Slika 32], simulira proces sklapanja stražnjeg i prednjeg poklopca. Sila prešanja i vrijeme trajanja prešanja su dva promjenjiva parametra pri samom procesu prešanja, može se postaviti da su oba parametra promjenjiva ili da je jedan parametar konstantan, a drugi promjenjiv, ovisno što će dati najbolju kvalitetu proizvoda u određivanju optimalnog procesa. Kada nosač s poklopcem prođe kroz svjetlosnu barijeru, zaustavlja se, pneumatski klip za prešanje se spušta i simulira spajanje dva poklopca. Nakon toga se klip vraća u početni položaj, a nosač nastavlja dalje prema sljedećoj fazi procesa [26].



Slika 32. Preša [26]

5.2. Opis eksperimenta za optimizaciju procesa

Eksperimentalni dio samog rada sastoji se od prikupljanja i obrade podataka koristeći softver MaiLab koji za cilj ima dati optimalne vrijednosti promjenjivih parametara kako bi se optimizirao cijeli proces, a da gotovi proizvod ima najveću moguću kvalitetu. Kako se proces proizvodnje sastoji od različitih radnih stanica, radne stanice povezane transportnom trakom prikazane su na [Slika 33], na svakoj je moguće pratiti i mijenjati neke parametre koji igraju ključnu ulogu za proces. Tako će se redom navesti svi parametri na pojedinim radnim stanicama, kao i interval vrijednosti koji može iznositi, na osnovu čega će softver dati vrijednost za optimalan proces. Cilj je dobiti gotovi proizvod koji se sastoji od prednjeg i stražnjeg poklopca, s tim da je na stražnjem poklopcu potrebno izbušiti dva provrta čiji promjer treba biti tri milimetra.



Slika 33. Shema radnih stanica i transportne trake

Prva radna stanica je spremnik koji ispušta poklopac, nakon tog poklopac putuje do druge radne stanice koja je bušilica te na kraju zadnja radna stanica je preša. U sljedećem koraku definirat će se koje sve parametre je moguće podesiti i pratiti na svakoj od radnih stanica.

- I. Spremnik; ispuštanje poklopaca je fiksna radnja koja traje 2 sekunde te nije moguće podešavati taj parametar.
- II. Bušilica; operacija bušenja ima tri parametra:
 - Brzina bušenja – vrijednost od 600 do 1200 okretaja u minuti. Ova varijabla predstavlja broj okretaja bušilice u minuti i ima raspon vrijednosti od 600 do 1200 okretaja u minuti koji je simuliran za generiranje slučajnih vrijednosti kako bi se mogla uspoređivati kvaliteta provrta na osnovu drugačijih brzina bušenja.
 - Vrijeme bušenja – vremenski interval od 2 do 8 sekundi. Interval vremena bušenja uzet je za simulaciju kako različito vremensko trajanje procesa bušenja može utjecati na kvalitetu provrta, a i na ukupno vremensko trajanje procesa.
 - Životni vijek alata – ovisno o životnom vijeku alata (svrdla), kvaliteta provrta može varirati. Ova varijabla predstavlja trajanje životnog vijeka svrdla koji u idealnim uvjetima iznosi 60 dana, a njezina distribucija može biti primjenjiva na stvarnim podacima te je uzeta kao dodatni parametar koji utječe na kvalitetu izrađenog provrta.

III. Preša; operacija prešanja također ima dva parametra:

- Sila prešanja – 0,2 do 1 Newton-a. Sila prešanja je simulirana u postavljenom intervalu jer izravno najviše utječe na kvalitetu prešanja proizvoda. Različit iznos sile daje drugačije rezultate proizvoda, a interval je uzet kontrolu utjecaja drugačije sile.
- Vrijeme prešanja – realni podesivi parametar za vrijeme prešanja je od 0 do 120 sekunde, a za potrebe ovog eksperimenta je uzet vremenski interval od 5 do 11 sekundi. Taj vremenski interval je uzet jer odgovara podesivoj sili za dobit proizvod s odgovarajućom kvalitetom.

Sada kad postoje definirani svi parametri svake pojedine radne stranice, može se raditi obrada i analiza podataka koje će generirati softver kao rješenje te na osnovu njega dati konačni zaključak. Navedeni parametri su uzeti iz razloga jer mogu biti primijenjeni na stvarnom procesu, utječu izravno na gotovi proizvod. Simulacija je napravljena kako bi se proces što više približio stvarnom, a podešavanje određenih parametara je napravljeno kako bi podaci bili relevantni za realnu primjenu. Logički uvjeti u skripti postavljeni su za idealni model, iskustveno radu u realnosti. IM-press je idealni model za kontrolu prešanja. Idealni model je proizvoljno određen, a parametri su podešeni tako da imaju smisla u stvarnoj primjeni (npr. ako je sila prešanja jača, logično je da je potrebno manje vremena za prešanje da se dobije dobar proizvod, i obrnuto). Proces bušenja provrta od 3 mm na poklopcu proizvoda ovisan je o tri varijable; vremenu bušenja, brzini bušenja i životnom vijeku alata. Na osnovu tih parametara kvaliteta provrta može biti drugačija (npr. pri maloj brzini i kratkom vremenu bušenja neće se dobiti provrt potrebne dimenzije, ili ako su vrijeme i brzina bušenja dobro prilagođeni ukoliko je svrdlo pri kraju životnog vijeka postoji mogućnost pucanja istog). Modeli funkcioniraju po logičkim pretpostavkama koje su izvede u simulaciji, ali su temeljene na iskustvu i primjeni u praksi. Na istom skupu podataka provest će se dva procesa za dvije radne stanice, praćenjem različitih parametara pri različitim vrijednostima u uzorku. Prvi put će se isti proces automatski izvesti s algoritmima umjetne inteligencije koje MaiLab predloži, dok će se drugi put postupak ponoviti s ručnim podešavanjem i dodavanjem dodatnih algoritama. Rezultati će se usporediti kako bi se donijeli zaključci koji proizlaze iz krajnjih rezultata dijagnoze. MaiLab može detektirati greške u proizvodu, procijeniti kvalitetu proizvoda te predvidjeti vrijednosti parametara kako bi proizvod bio što kvalitetniji. Prva analiza podataka usredotočit će se na

kontrolu kvalitete prešanja, ovisno o parametrima kao što su sila uprešavanja i vrijeme prešanja. Druga analiza imat će za cilj predviđanje optimalne brzine bušenja, prateći promjer provrta te životni vijek svrdla.

5.2.1. Priprema za eksperiment

Priprema podataka za obradu i analizu odrađena je kroz pisanje Python skripte za generiranje podataka za učenje, izrađen je model od 1000 mjerenja. Model je napravljen putem Pythona radi praktičnosti, jer bi stvarno mjerenje podataka za model od 1000 proizvoda trajalo jako dugo. Pojedini podaci su modificirani i parametri su postavljeni drugačije nego u realnom slučaju za svrhu istraživanja kako bi proces bio što sličniji primjeru iz stvarne tvornice. Pripremljeni podaci se spremaju u CSV obliku, a prethodno je navedeno da MaiLab može učitati podatke u CSV obliku. Kad imamo prikupljene podatke možemo kreirati Skup podataka (*eng. Data Set*) uvozeći ih u CSV obliku, što je ujedno i prvi korak pri korištenju MaiLab-a. Nakon što su podaci učitani počinju su obrađivati kroz četiri koraka MaiLab-a, što će biti detaljno razrađeno u sljedećem poglavlju.


6. OBRADA PODATAKA U MAILAB-U

Proces prikupljanja i obrade podataka za simuliranu proizvodnju poklopca na CP liniji poslužit će kao temelj za detaljnu analizu putem softvera, koji će generirati rezultate. Na temelju tih rezultata izvest će se zaključci o tome kako poboljšati procese, raditi na optimizaciji te ostvariti konkurentske prednosti. MaiLab, kao alat temeljen na umjetnoj inteligenciji, koristi različite algoritme za izvođenje analiza na osnovu podataka koji su mu dani za učenje. Softver omogućuje samostalno podešavanje zadataka i korištenje naprednih funkcija koje automatski generiraju algoritme i pružaju rezultate analize.

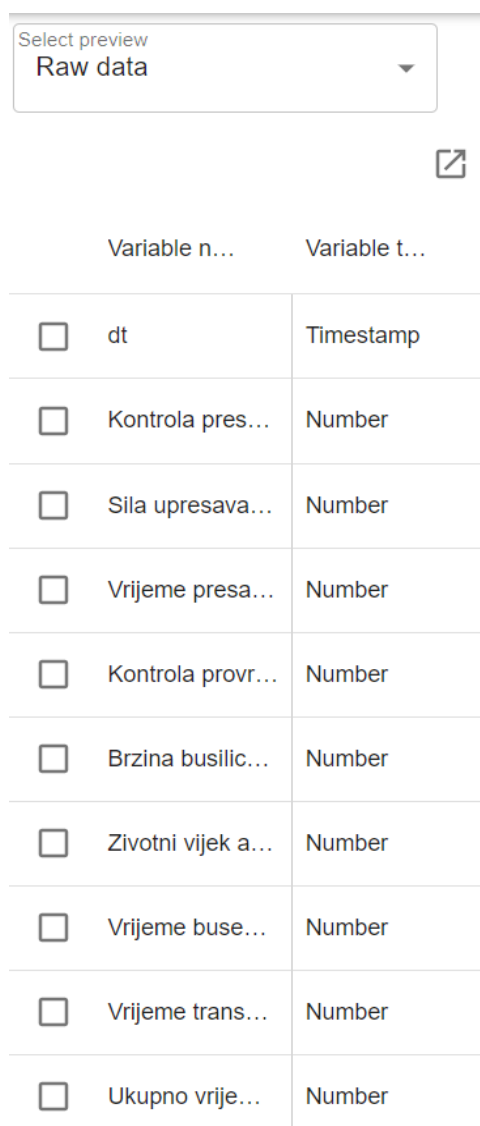
6.1. Analiza podataka za kontrolu kvalitete

6.1.1. Stvaranje skupa podataka

U Mailab softveru, prvi korak u procesu obrade podataka počinje dodavanjem skupa podataka za učenje. Ovaj ključni korak omogućuje softveru da stvori temelj za analizu i učenje algoritama umjetne inteligencije. Korisnik unosi relevantne podatke koji odražavaju parametre proizvodnje ili druge važne informacije o radnom procesu. Ti podaci služe kao ulaz za algoritme koji će ih analizirati, prepoznati obrasce i naučiti iz njih. Ova faza omogućuje Mailab-u da prilagodi svoje analitičke metode i pripremi se za daljnje korake u dijagnostici i optimizaciji procesa. Dodavanje skupa podataka za učenje ključan je za postizanje preciznih i relevantnih rezultata analize unutar Mailab platforme. Na [Slika 34] prikazan je skup podataka koji je dodan u softver, a na [Slika 35] prikazani su parametri koji se prate s linije.



Slika 34. Dodavanje skupa podataka



Select preview
Raw data

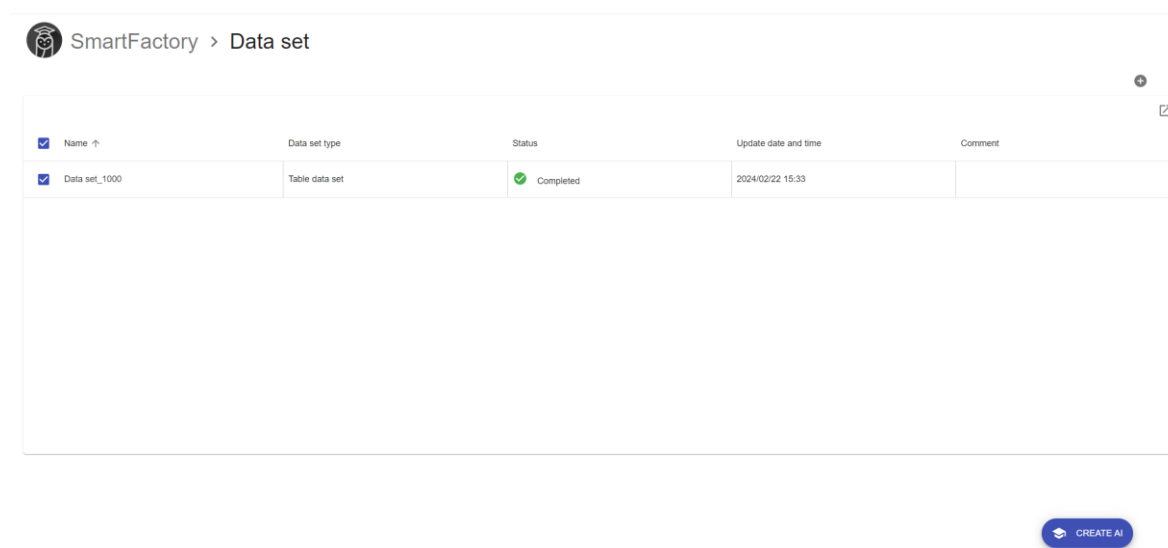
Variable n... Variable t...

<input type="checkbox"/>	dt	Timestamp
<input type="checkbox"/>	Kontrola pres...	Number
<input type="checkbox"/>	Sila upresava...	Number
<input type="checkbox"/>	Vrijeme presa...	Number
<input type="checkbox"/>	Kontrola provr...	Number
<input type="checkbox"/>	Brzina busilic...	Number
<input type="checkbox"/>	Zivotni vijek a...	Number
<input type="checkbox"/>	Vrijeme buse...	Number
<input type="checkbox"/>	Vrijeme trans...	Number
<input type="checkbox"/>	Ukupno vrije...	Number

Slika 35. Parametri od kojih se sastoji skup podataka

6.1.2. Stvaranje umjetne inteligencije

Nakon što je skup podataka napravljen, sljedeći korak je stvaranje umjetne inteligencije prikazano na [Slika 36], što predstavlja drugi korak korištenja. Početak stvaranja umjetne inteligencije zahtjeva odabir namjene započetog procesa, a ovisno o namjeni, proces je podijeljen u dvije analize prethodno definirane.



SmartFactory > Data set

<input checked="" type="checkbox"/> Name ↑	Data set type	Status	Update date and time	Comment
<input checked="" type="checkbox"/> Data set_1000	Table data set	<input checked="" type="checkbox"/> Completed	2024/02/22 15:33	

[CREATE AI](#)

Slika 36. Stvaranje umjetne inteligencije

Već je predstavljeno kako će se prva analiza provesti za procjenu kontrole kvalitete postupka prešanja u ovisnosti parametara za prešanje, parametri koji određuju kontrolu kvalitete za proizvod na radnoj stanici preše su vrijeme prešanja i sila uprešavanja.

What is the purpose?

To detect errors

To predict the quality index value
To predict the size after machining before performing the machining

To automate the cause estimation

To adjust device parameters

BACK

FORWARD

CANCEL

Slika 37. Odabir vrste analize

Which variable will be predicted?



- Kontrola presanja [mm]
- Sila upresavanja [N]
- Vrijeme presanja [s]
- Kontrola provrta [mm]
- Brzina busilice [o/min]
- Zivotni vijek alata [dan]
- Vrijeme busenja [s]
- Vrijeme transporta [s]
- Ukupno vrijeme procesa [s]



Slika 38. Izbor parametra za praćenje

Na [Slika 37] prikazano je kako se odabere jedan postupak za analizu parametara, odnosno ono što se želi postići s podacima, a na [Slika 38] vidljivo je koje je parametre moguće pratiti, u ovom slučaju odabire se kontrola prešanja kao parametar za prvu analizu podataka. Kada je sve postavljeno, MaiLab je pripremljen za izvršavanje učenja. Učenje će koristiti dva algoritma za analizu, Light Gradient Boosting Machine i Slučajna šuma, vidljivo na [Slika 39].



SmartFactory > AI > AI_1.1

Learning setting

Diagnosis target
Kontrola presanja [mm]

Learning level

High speed — High precision

AI model details

Preprocessing	Analysis method used	Optimization	Analysis method selection
Date and time encoding: None	LightGBM	Number of optimization attempts: 0	Ensemble learning
	Random forest	Optimization time limit: -	



Slika 39. Postavke učenja i metode analize

Kada je učenje završeno, generiraju se rezultati mjerenja za svaku korištenu analizu: [Slika 40] prikazuje evaluaciju performansi LightGBM modela, a [Slika 41] isto za Random Forest model.

LightGBM

RMSE	
Learning score	0.06599635901349057
Evaluation score	0.0886444264987995

Learning time: 0 [s]
Diagnosis time: 0.01 [ms]





Slika 40. LightGBM

Random forest


RMSE	
Learning score	0.080531124480814
Evaluation score	0.086330979395065

Learning time: 0 [s]
Diagnosis time: 0.01 [ms]




Slika 41. Random Forest


Podaci koje je pružio odnose se na evaluaciju performansi modela, a svaki dio na slikama daje određene informacije za proces; Ocjena učenja (*eng. Learning score*) predstavlja mjeru performansi modela na skupu podataka za učenje, što je ocjena niža to je bolje jer ukazuje na to da je model dobro generaliziran na podatke za učenje. Ocjena evaluacije (*eng. Evaluation score*) predstavlja mjeru performansi modela na skupu podataka koji nije korišten za učenje, tj. skup podataka za evaluaciju. Niža ocjena sugerira da se model dobro ponaša i na novim, nepoznatim podacima. Korijen srednjeg kvadrata odstupanja (*eng. Root Mean Square Error, RMSE*) je metrika korištena za ocjenu učenja. RMSE je mjera koja kvantificira prosječnu veličinu odstupanja između stvarnih i predviđenih vrijednosti. Računa se kao korijen srednje vrijednosti kvadrata razlika između stvarnih i predviđenih vrijednosti. Idealna vrijednost je nula, što znači potpuno precizno predviđanje [30]. RMSE je često korištena metrika za regresijske modele jer daje jasnu sliku o tome koliko su predviđanja udaljena od stvarnih vrijednosti, a pri korištenju zadanih podataka reći će koliko dobro model predviđa vrijednosti parametara potrebnih za optimizaciju podataka. U ovom slučaju metrika nije birana nego je automatski podešena. Vrijeme učenja predstavlja vrijeme koje je bilo potrebno da model nauči na skupu podataka za učenje, a vrijeme dijagnoze vrijeme koje je bilo potrebno za dijagnosticiranje modela. Ukratko, niske ocjene i brza vremena učenja i dijagnoze ukazuju na dobre performanse modela na danom skupu podataka. Osim numeričkih ocjena, prikazani su i grafovi kako bi dodatno ilustrirali performanse modela. Uključujući graf rezidualnog ostatka i linijski graf, ovi vizualni prikazi pružaju dublje razumijevanje kako se model ponaša na stvarnim podacima.




Slika 42. Graf Reziidualnog ostatka (LightGBM)



Slika 43. Linijski graf (LightGBM)



Slika 44. Graf Rezidualnog ostatka (Random Forest)




Slika 45. Linijski graf (Random Forest)

[Slika 42] i [Slika 44] prikazuju grafove koji daju razliku između stvarnih i predviđenih vrijednosti (ostatak) na osi y u odnosu na predviđene vrijednosti na osi x. Ako su ostaci nasumično raspoređeni oko nule bez ikakvog uočljivog obrasca, to ukazuje na dobru prilagodbu

modela podacima. Grafički ocjenjujući ostatak, moguće je identificirati eventualne trendove ili sistemske pogreške. Na oba ovdje prikazana modela nema velikog odstupanja od predviđenih rezultata, vidljivo je da su rezultati uzorka isti ili jako slični predviđenima, nema velikog rasipanja. [Slika 43] i [Slika 45] prikazuju linijske grafove stvarnih i predviđenih vrijednosti. U idealnom slučaju linije se trebale preklapati, što bi značilo da su stvarne i predviđene vrijednosti međusobno usklađene. Ovdje su također linije jako slične, najvećim dijelom se poklapaju što ukazuje na slaganje modela i stvarnih podataka. Nakon što je učenje završeno može se preći na sljedeći korak analize u MaiLab-u, a to je stvaranje zadatka. Koji sve su procesi do sad odrađeni prikazano je na [Slika 46] gdje se mogu vidjeti i algoritmi umjetne inteligencije u stablu koji su izvršavali analizu podataka.

Creating AI has been completed.



Slika 46. Završeni procesi

6.1.3. Izrada zadatka

Zadatak se može napraviti na dva načina, prikazano na [Slika 47]: jednostavni zadatak pri kojem MaiLab automatski generira sve dijelove procesa i sam izabire metode koje će se provoditi, a drugi način je napredni zadatak u kojem se ručno može dodavati, mijenjati odnosno osobno prilagoditi postupak.

Create a new task



Name
Task 01

Select AI
AI_1.1

Select diagnosis terminal
Local diagnosis terminal

Select task type

Simple task Advanced task



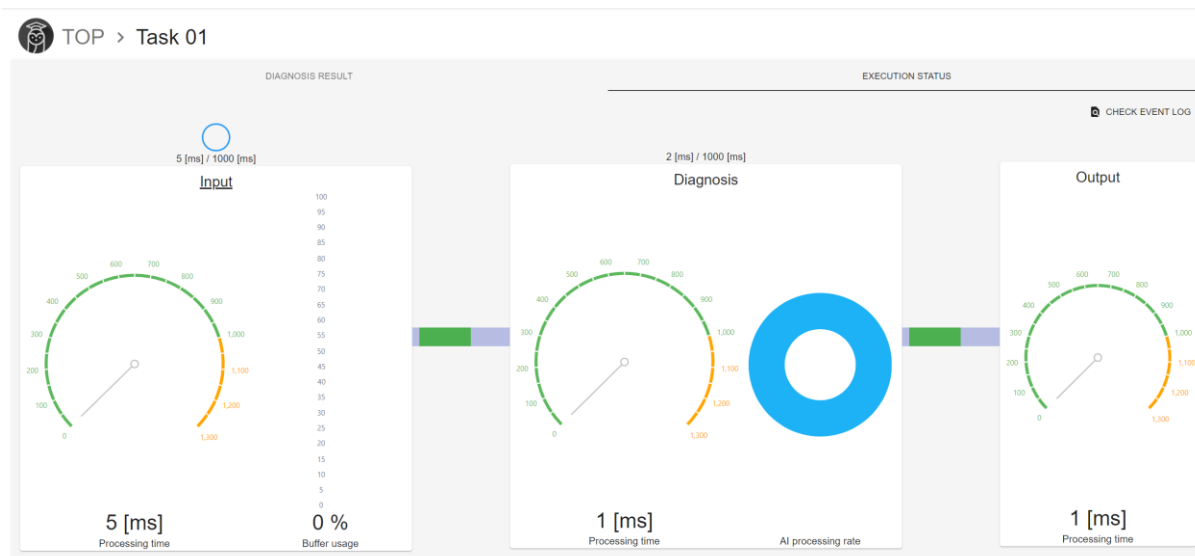
OK CANCEL

Slika 47. Stvaranje zadatka

Prilikom stvaranja zadatka potrebno je definirati sljedeće informacije: definirati otkuda će se uzeti podaci kao ulazne varijable; postavi se pripremljena mapa s uzorkom od 500 podataka za uvoz, definirati gdje će se rezultati procesa spremati; također se postavi prazna mapa u koju će se pri kraju procesa spremati rezultati obrade podataka sa svim parametrima i njihovim vrijednostima za pojedini podatak. Kada se sve to definira i odrede odredišne mape završen je korak stvaranja zadatka, a proces je pripremljen za četvrti, ujedno i zadnji korak u analizi podataka u MaiLab-u, izvršenje zadatka i praćenje.


6.1.4. Izvršenje zadatka i praćenje

Praćenje uključuje učitavanje ulaznih podataka, dijagnozu te spremanje rezultata, proces prikazan na [Slika 48].



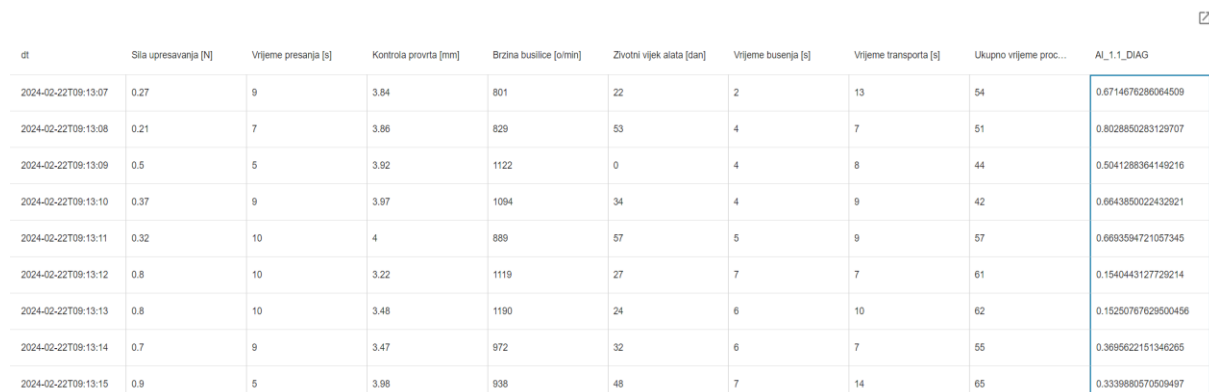
Slika 48. Prikaz praćenja procesa

A rezultati samog procesa prikazani su u dijagramu i grafikonu vidljivo na [Slika 49].



Slika 49. Rezultati dijagnoze

Osim grafičkog prikaza rezultati se ispisuju i u tabličnom obliku te spremaju u CSV oblik, prikaz dijela rezultata na [Slika 49].



dt	Sila upresavanja [N]	Vrijeme presanja [s]	Kontrola provrta [mm]	Brzina busilice [o/min]	Zivotni vijek alata [dan]	Vrijeme busenja [s]	Vrijeme transporta [s]	Ukupno vrijeme proc...	AI_1.1_DIAG
2024-02-22T09:13:07	0.27	9	3.84	801	22	2	13	54	0.6714676286064509
2024-02-22T09:13:08	0.21	7	3.86	829	53	4	7	51	0.8028850283129707
2024-02-22T09:13:09	0.5	5	3.92	1122	0	4	8	44	0.5041288364149216
2024-02-22T09:13:10	0.37	9	3.97	1094	34	4	9	42	0.6643850022432921
2024-02-22T09:13:11	0.32	10	4	889	57	5	9	57	0.6693594721057345
2024-02-22T09:13:12	0.8	10	3.22	1119	27	7	7	61	0.1540443127729214
2024-02-22T09:13:13	0.8	10	3.48	1190	24	6	10	62	0.15250767629500456
2024-02-22T09:13:14	0.7	9	3.47	972	32	6	7	55	0.3695622151346265
2024-02-22T09:13:15	0.9	5	3.98	938	48	7	14	65	0.3339880570509497

Slika 50. Tablični prikaz rezultata

Rezultati procesa mjerenih parametara za kontrolu prešanja pružaju značajne uvide u ponašanje procesa u ovisnosti o sili uprešavanja i vremenu prešanja. Analizirajući ove parametre, može se dobiti dublje razumijevanje utjecaja različitih sila uprešavanja i vremena prešanja na kvalitetu i karakteristike proizvoda. Ako se promatra sila uprešavanja, interval sile je od 0,2 do 1 Newton, mogu se identificirati optimalne vrijednosti koje rezultiraju visokokvalitetnim proizvodima. Previše ili premalo sile uprešavanja može dovesti do problema, poput neujednačenog oblika proizvoda ili čak oštećenja materijala. Stoga, važno je pronaći ravnotežu koja osigurava optimalnu čvrstoću i oblik proizvoda. MaiLab je generirao rezultate na uzorku od 500 podataka te ih podijelio u klase koje su određene intervalima koji definiraju zadovoljavajuću kontrolu proizvoda. Zadnji stupac je rezultat kontrole kvalitete prešanja, što je broj bliži 0 to je veća kvaliteta gotovog proizvoda. Najniži dobiven broj je 0,1481832205111539 pri čemu sila iznosi 0,92 N, a vrijeme prešanja je 11 sekundi. Što se tiče vremena prešanja, interval vremena za prešanje je od 5 do 15 sekundi, a analiza pokazuje kako različite duljine vremena mogu utjecati na homogenost proizvoda i njegovu strukturu. Optimizacija vremena prešanja može rezultirati uštedom vremena i energije, dok istovremeno osigurava visoku kvalitetu proizvoda. Iz dobivenih rezultata može se iščitavati što se događa s proizvodom kada se mijenja vrijednost sile i vrijeme prešanja; najlošiji proizvod dobiven je pri sili od 0,35 N i vremenu od 5 sekundi prešanja, dok je najveći broj proizvoda smješten oko kvalitete 0,5. Proizvodi s tom vrijednošću dobiju se na dva načina, ukoliko je sila niža i bliža vrijednosti 0,2 N vrijeme prešanja je duže, ili obrnuto, primjer rezultata prikazan na [Slika 51].

dt	Sila upresavanja [N]	Vrijeme presaња [s]	Kontrola provrta [mm]	Brzina busilice [o/min]	Zivotni vijek alata [dan]	Vrijeme busenja [s]	Vrijeme transporta [s]	Ukupno vrijeme proc...	AI_1.1_DIAG
2024-02-22T09:13:09	0.5	5	3.92	1122	0	4	8	44	0.5041288364149216
2024-02-22T09:13:19	0.48	6	3.68	937	38	6	9	59	0.525680321416009
2024-02-22T09:13:23	0.47	11	3.85	993	23	3	9	46	0.5120685395906123
2024-02-22T09:13:25	0.75	6	3.83	672	22	7	9	46	0.5076284334813808
2024-02-22T09:13:29	0.21	11	3.96	830	22	2	8	56	0.5191144304434729
2024-02-22T09:13:35	0.57	5	3.9	703	28	7	8	51	0.515238500672676
2024-02-22T09:13:38	0.44	11	3.83	760	32	4	11	54	0.517461631395357
2024-02-22T09:13:43	0.55	7	3.47	901	18	8	9	44	0.5122958466398704

Slika 51. Primjer kvalitete kontrole presaња

U konačnici, ovi rezultati pružaju korisne informacije za prilagodbu parametara presaња kako bi se postigla optimalna proizvodnja s visokom učinkovitošću i minimalnim gubicima. Sveukupno, ova analiza pomaže u usklađivanju proizvodnih procesa s ciljem postizanja vrhunske kvalitete proizvoda.

6.2. Prilagođena analiza podataka za kontrolu kvalitete

U ovom poglavlju analize implementiran je još jedan algoritam umjetne inteligencije kako bi se proširilo proučavanje i uvidjelo što se mijenja, ako se mijenja, dodavanjem još jednog algoritma. Dodatni algoritam integriran je radi dublje analize i bolje sagledavanja rezultata u odnosu na prethodno provedene postupke. Početak analize podataka je potpuno isti kao u prethodnom slučaju, tako da se samo nastavi na nju do dijela gdje se doda novi algoritam umjetne inteligencije, kada se definira zadatak treba odabrati unapređeni zadatak, prikazano na [Slika 52], koji omogućuje unositi ručne promjene u proces. Uz postojeća dva algoritma umjetne inteligencije, Light Gradient Boosting Machine i Slučajna šuma, dodat će se Deep Learning, te sada proces izgleda kao na [Slika 53] gdje je vidljivo da je dodano i Deep Learning.

Create a new task



Name
Task 02

Select AI
AI_1.1

Select diagnosis terminal
Local diagnosis terminal


Select task type

Simple task Advanced task




OK CANCEL

Slika 52. Kreiranje naprednog zadatka




Slika 53. Prilagođeni proces


Rezultati učenja za LightGBM i Random Forest su isti kao u prethodnoj analizi jer je korišten isti skup podataka sa istim parametrima, a samo je još dodatno izvršeno učenje za Deep Learning, a grafički prikaz rezultata je vidljiv na [Slika 54]. Ovdje je vidljivo da se stvarne vrijednosti u velikoj većini poklapaju s pretpostavljenima, što daje informaciju da se model dobro ponaša s uzorkom podataka te daje dobre rezultate.



Slika 54. Deep Learning




Slika 55. Graf Rezidualnog ostatka (Deep Learning)



Slika 56. Linijski graf (Deep Learning)

Na [Slika 55] i [Slika 56] bolje su prikazani grafovi za algoritam Deep Learning. Iz grafova je jasno da se model dobro ponaša te su stvarni rezultati gotovo jednaki onim predviđenima.

[Slika 57] i [Slika 58] prikazuju grafički i brojni rezultate druge analize.



Slika 57. Rezultati dijagnoze

dt	Sila upresav...	Vrijeme pres...	Kontrola pro...	Brzina busill...	Zivotni vijek ...	Vrijeme buse...	Vrijeme tran...	Ukupno vrije...	AL_1_1_DIAG
2024-02-22T0...	0.27	9	3.84	801	22	2	13	54	0.67823359430...
2024-02-22T0...	0.21	7	3.86	829	53	4	7	51	0.79471001071...
2024-02-22T0...	0.5	5	3.92	1122	0	4	8	44	0.48093575156...
2024-02-22T0...	0.37	9	3.97	1094	34	4	9	42	0.65652098035...
2024-02-22T0...	0.32	10	4	889	57	5	9	57	0.67182778932...
2024-02-22T0...	0.8	10	3.22	1119	27	7	7	61	0.15847769476...
2024-02-22T0...	0.8	10	3.48	1190	24	6	10	62	0.15362272172...
2024-02-22T0...	0.7	9	3.47	972	32	6	7	55	0.37406745529...
2024-02-22T0...	0.9	5	3.98	938	48	7	14	65	0.33580610174...

Slika 58. Tablični prikaz rezultata

Rezultati su gotovo jednaki onima iz analize bez dodavanja novog algoritma, Deep Learning daje razlike na trećoj decimali što u nekim analizama može biti potrebno, ali u ovom slučaju ne igra značajnu ulogu. To vidimo iz podatka da za najbolju dijagnozu 0,1405808047147979 sila iznosi 0.92 N, a vrijeme 11 sekundi što je jednako kao i u analizi bez dubokog učenja. Iako u ovom slučaju dodavanjem još jednog algoritma nije donijelo značajne promjene, ne mora značiti da bi tako bilo u nekom drugom slučaju ili za ovaj slučaj izbor dubokog učenja nije donio promjene, a možda neki drugi algoritam bi.

6.3. Analiza za predviđanje brzine bušenja

U ovom poglavlju odradit će se analiza za predviđanje optimalne brzine bušenja provrta od 3 mm, s posebnim naglaskom na kvalitetu provrta, zadovoljavajuće tolerancije te utjecaj životnog vijeka svrdla koji je potrebno mijenjati svaka 2 mjeseca, ukoliko ne dođe do problema pa ga je potrebno zamijeniti i ranije. Brzina bušenja ključni je parametar koji direktno utječe na karakteristike provrta. S obzirom na varijabilnost životnog vijeka svrdla, cilj je odrediti optimalne postavke brzine bušenja koje će osigurati kvalitetne provrte tijekom cijelog životnog vijeka svrdla.

6.3.1. Stvaranje skupa podataka

Opet će se koristiti isti skup podataka, isti algoritmi i tehnike za predviđanje brzine bušilice.

6.3.2. Stvaranje umjetne inteligencije

Kako se koristi isti skup podataka, umjetna inteligencija i učenje iz podatak je odrađeno na istom skupu podataka te se za ovu analizu prva dva koraka korištenja MaiLab-a samo preuzimaju iz prethodne analize, što je sve detaljno objašnjeno u poglavljima prije.

Proces se započinje tako što je potrebno odabrati, odnosno što se sada želi postići, koju vrstu analize izabrati, prikazano na [Slika 59] i koji parametar predvidjeti, prikazano na [Slika 60].

What is the purpose?

<input type="radio"/> To detect errors	▼
<input type="radio"/> To predict the quality index value	▼
<input type="radio"/> To automate the cause estimation	▼
<input checked="" type="radio"/> To adjust device parameters	▲

To automate parameter tuning which has relied on intuition and experience

BACK FORWARD CANCEL

Slika 59. Odabir vrste analize

Which variable will be adjusted?



- Kontrola presanja [mm]
- Sila upresavanja [N]
- Vrijeme presanja [s]
- Kontrola provrta [mm]
- Brzina busilice [o/min]
- Zivotni vijek alata [dan]
- Vrijeme busenja [s]
- Vrijeme transporta [s]
- Ukupno vrijeme procesa [s]

BACK

FORWARD

CANCEL

Slika 60. Izbor parametra za predviđanje


Nakon odabira analize i parametra, pokreće se učenje te MaiLab opet postavlja iste algoritme za izvršavanje učenja, LightGBM i Random Forest, prikazano na [Slika 67].

LightGBM

RMSE	
Learning score	125.39504411295144
Evaluation score	160.4654323425551

Learning time: 0 [s]

Diagnosis time: 0.01 [ms]




Slika 61. LightGBM

Random forest

RMSE	
Learning score	150.0840974828948
Evaluation score	170.99818844909427


Learning time: 0 [s]

Diagnosis time: 0.02 [ms]




Slika 62. Random Forest


Učenja algoritama, prikazanih na [Slika 61] i [Slika 62], daju informacije o ponašanju algoritma sa stvarnim podacima u odnosu na predviđene. Ponašanje modela je gotovo jednako predviđenom što ukazuje na dobro ponašanje modela s nepoznatim podacima. Detaljni prikazi grafova modela učenja na [Slika 63], [Slika 64], [Slika 65] i [Slika 66]. Vrijednosti po grafovima gotovo se u potpunosti preklapaju s predviđenim vrijednostima.




Slika 63. Graf Reziidualnog ostatka (LightGBM)



Slika 64. Linijski graf (LightGBM)

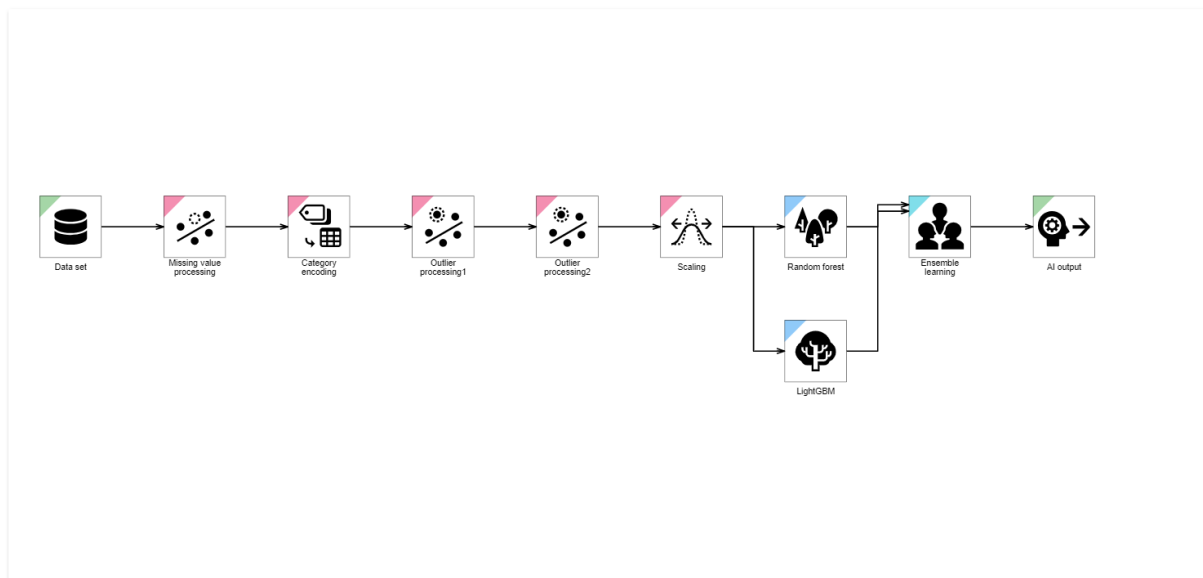


Slika 65. Graf Rezidualnog ostatka (Random Forest)



Slika 66. Linijski graf (Random Forest)

Creating AI has been completed.



Slika 67. Procesi učenja

6.3.3. Izrada zadatka

Sljedeći korak je stvaranje zadatka, s tim da je opet potrebno definirati otkud će se dobiti podaci te kamo spremati rezultate dijagnoze. Pripremljene mape koje se koriste za uvoz podataka i spremanje rezultata iste su u svakoj analizi. Zadatak se kreira opet po automatskom prijedlog MaiLab-a, prikazano na [Slika 68].

Create a new task

Name
Task 03


Select AI
AI_2.1


Select diagnosis terminal
Local diagnosis terminal

Select task type

Simple task

Advanced task






OK CANCEL

Slika 68. Stvaranje zadatka

6.3.4. Izvršenje zadatka i praćenje

Zatim se prelazi na zadnji korak izvršavanje zadatka i praćenje rezultata, rezultati se opet prikazuju grafički na [Slika 69] i brojčano na [Slika 70].



Slika 69. Rezultati dijagnoze

dt	Kontrola pre...	Sila upresav...	Vrijeme pres...	Kontrola pro...	Zivotni vijek ...	Vrijeme buse...	Vrijeme tran...	Ukupno vrije...	AI_2.1_DIAG
2024-02-22T0...	0.86	0.27	9	3.84	22	2	13	54	894.043554954...
2024-02-22T0...	0.74	0.21	7	3.86	53	4	7	51	894.002660841...
2024-02-22T0...	0.49	0.5	5	3.92	0	4	8	44	878.899778433...
2024-02-22T0...	0.84	0.37	9	3.97	34	4	9	42	911.879876706...
2024-02-22T0...	0.68	0.32	10	4	57	5	9	57	918.830378395...
2024-02-22T0...	0.19	0.8	10	3.22	27	7	7	61	1092.22838088...
2024-02-22T0...	0.21	0.8	10	3.48	24	6	10	62	934.658883669...
2024-02-22T0...	0.36	0.7	9	3.47	32	6	7	55	940.181404410...
2024-02-22T0...	0.33	0.9	5	3.98	48	7	14	65	966.510457240...

Slika 70. Tablični prikaz rezultata

Promatrajući dobivene rezultate brzine bušenja za provrt promjera 3 mm, jasno se uočava značajan utjecaj brzine na kvalitetu izbušenog provrta. Brojčane vrijednosti pružaju kvantitativni uvid u performanse modela u predviđanju brzine bušenja, omogućujući preciznu procjenu učinkovitosti različitih postavki brzine u postizanju željenih karakteristika provrta. Zanimljivo je uočiti trendove u promjenama brzine bušenja tijekom životnog vijeka svrdla. Primjerice, kada je životni vijek svrdla duži od 50 dana, predviđena brzina iznosi između 800 i 900 okretaja u minuti kako bi se izbjeglo pucanje svrdla prema kraju životnog vijeka. U većini slučajeva s rezultatima najbližim idealnom provrtu od 3 mm, predviđena brzina iznosi otprilike 1100 okretaja u minuti, a životni vijek svrdla u tim situacijama doseže do 30 dana, odnosno polovice predviđenog životnog vijeka svrdla. Ovaj dinamičan pristup pruža dodatne uvide u

potrebu prilagodbe postavki brzine bušenja kako bi se održala konzistentna kvaliteta provrta tijekom cijelog procesa bušenja. Na kraju, ova analiza omogućuje identifikaciju optimalnih postavki brzine bušenja za postizanje visokokvalitetnih provrta, uzimajući istovremeno u obzir životni vijek svrdla. To rezultira optimizacijom procesa bušenja, poboljšava učinkovitost proizvodnje i smanjuje troškove održavanja alata.

6.4. Prilagođena analiza za predviđanje brzine bušenja

Kako bi se dobio precizniji provrt uz kontrolu životnog vijeka svrdla, dodat će se dva algoritma umjetne inteligencije za učenje kako bi softver predložio bolju brzinu bušenja za ostvarivanje navedenih uvjeta. Uz dva algoritma od prije, dodat će se još Deep Learning i Gradient Boosting Decision Tree. Dodajući još dva algoritma, pratit će se može li se dobiti preciznija brzina za ostvarit provrt od 3 mm uz kontrolu životnog vijeka svrdla. Opet se nastavlja na isti skup podataka s jednakim postavkama za parametre, samo je zadatak potrebno prilagoditi i dodati mu dva nova algoritma, kreirat će se novi zadatak prikazano na [Slika 71].

Create a new task

Name
Task 04


Select AI
AI_2.1


Select diagnosis terminal
Local diagnosis terminal

Select task type

Simple task

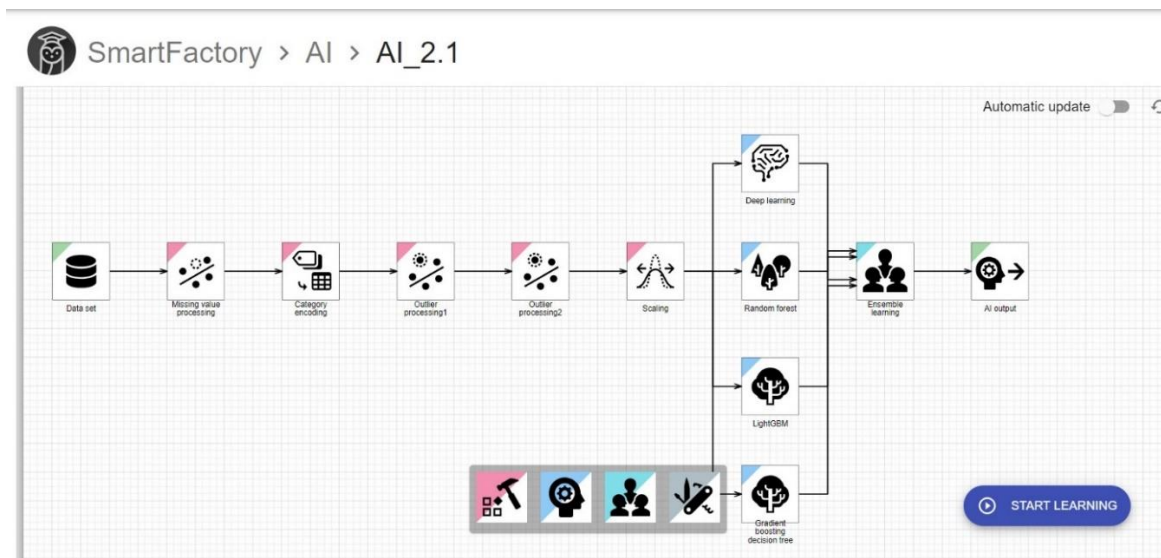
Advanced task





OK CANCEL


Slika 71. Stvaranje zadatka



Slika 72. Prilagođeni proces

[Slika 72] prikazuje proces koji sadrži dva algoritma od prije te još naknadno dodane algoritme Deep Learning i Gradient Boosting Decision Tree.

Gradient boosting decision tree




Slika 73. Gradient Boosting Decision Tree

Deep learning


RMSE	
Learning score	162.86751785926862
Evaluation score	173.5915671044139

Learning time: 1.2 [m]


Diagnosis time: 0.07 [ms]

**Slika 74. Deep Learning**


Učenje algoritama vidljivo na [Slika 73] i [Slika 74] prikazuje da se algoritmi dobro ponašaju sa stvarnim podacima u usporedbi s predviđenim vrijednostima. Ocjena učenja i ocjena dijagnoze su poprilično visoke vrijednosti, ali unatoč tome učenje je brzo izvršeno što pokazuju vrijeme učenja i dijagnoze te su vrijednosti stvarnih podataka gotovo jednake predviđanima, a detaljniji prikazi grafova su niže na [Slika 75], [Slika 76], [Slika 77] i [Slika 78]. Vrijednosti stvarnih podataka označene crvenom bojom najvećim dijelom se poklapaju s predviđenim vrijednostima plave boje.




Slika 75. Graf Reziidualnog ostatka (Gradient Boosting Decision tree)



Slika 76. Linijski graf (Gradient Boosting Decision Tree)




Slika 77. Graf Rezidualnog ostatka (Deep Learning)



Slika 78. Linijski graf (Deep Learning)

Nakon što su izvršene promjene na učenju te je kreiran zadatak dobiju se rezultati dijagnoze.



Slika 79. Rezultati dijagnoze

dt	Kontrola pre...	Sila upresav...	Vrijeme pres...	Kontrola pro...	Zivotni vijek ...	Vrijeme buse...	Vrijeme tran...	Ukupno vrije...	AI_2.1_DIAG
2024-02-22T0...	0.86	0.27	9	3.84	22	2	13	54	892.519437192...
2024-02-22T0...	0.74	0.21	7	3.86	53	4	7	51	890.113443365...
2024-02-22T0...	0.49	0.5	5	3.92	0	4	8	44	888.002563904...
2024-02-22T0...	0.84	0.37	9	3.97	34	4	9	42	915.568623946...
2024-02-22T0...	0.68	0.32	10	4	57	5	9	57	910.229198725...
2024-02-22T0...	0.19	0.8	10	3.22	27	7	7	61	1081.47562257...
2024-02-22T0...	0.21	0.8	10	3.48	24	6	10	62	932.962794324...
2024-02-22T0...	0.36	0.7	9	3.47	32	6	7	55	928.792879257...
2024-02-22T0...	0.33	0.9	5	3.98	48	7	14	65	949.371818230...

Slika 80. Tablični prikaz rezultata

Rezultati vidljivi na [Slika 79] i [Slika 80] poprilično su slični onima iz analize prije, bez dodavanja još dvaju algoritama umjetne inteligencije, što znači da je model dao dobre rezultate i predviđanja po automatskom generiranju učenja koje je softver sam odabrao. Rezultati se opet razlikuju na trećoj dimenziji te to ukazuje da dodatna analiza nije bila potrebna za ovaj primjer jer su i u prvoj analizi podaci bili dovoljno točni. Ponovljen je rezultat s najpreciznijim provrtom prema 3 mm, predviđena brzina iznosi malo manje od 1100 okretaja u minuti te životni vijek od 27 dana.

6.5. Rezultati analiza

Rezultati analize procesa mjerenih parametara za kontrolu prešanja pružaju značajne uvide u ponašanje procesa u odnosu na silu uprešavanja i vrijeme prešanja. Analizirajući ove parametre, postignuto je dublje razumijevanje utjecaja različitih sila uprešavanja i vremena prešanja na kvalitetu i karakteristike proizvoda. Identificirane su optimalne vrijednosti sile uprešavanja koje rezultiraju visokokvalitetnim proizvodima, dok prevelika ili premala sila može uzrokovati probleme, uključujući neujednačen oblik proizvoda ili oštećenje materijala. Kroz analizu sila uprešavanja, pronađena je ravnoteža koja osigurava optimalnu čvrstoću i oblik proizvoda. MaiLab je generirao rezultate na uzorku od 500 podataka, klasificirajući ih u različite intervale koji definiraju zadovoljavajuću kontrolu proizvoda. Prikupljeni podaci pružaju uvid u optimalne postavke procesa prešanja, omogućavajući identifikaciju problema i mogućnosti optimizacije. Na primjer, analiza rezultata sugerira da prilagodba sile uprešavanja može rezultirati poboljšanjem ujednačenosti proizvoda i smanjenjem oštećenja. Osim toga, optimizacija vremena prešanja može dovesti do uštede vremena i energije, uz održavanje visoke kvalitete proizvoda. Najbolji rezultat, odnosno najveća kvaliteta proizvoda pri kontroliranju prešanja iznosi 0,140580804714797, za tu vrijednost sila iznosi 0,92 N, a vrijeme prešanja je 11 sekundi. Veća kvaliteta predstavlja broj što bliži nuli. Iako je ovaj postignuti rezultat dobiven pri korištenju 3 algoritma; Slučajna šuma, LightGBM i Deep Learning, vrijednost parametara je ista dobivena i u analizi bez Deep Learning-a, odnosno samo sa Slučajnom šumom i LightGBM-om. Prednost korištenja softverskog alata za prikupljanje i obradu podataka je i u tome što nam podaci budu već klasificirani, bez da to mora raditi zaposlenik te se tu već dobije ušteda na vremenu za dobit klasificirane podatke, a zaposlenik može obavljati drugi zadatak te na takav način optimizirati proces. To su samo neki primjeri kako optimizirati proces uštedom vremena.

Analiza brzine bušenja za provrt promjera 3 mm također pruža važne uvide. Rezultati pokazuju značajan utjecaj brzine na kvalitetu izbušenog provrta. Za provrt od 3 mm, optimalna brzina iznosi oko 1100 okretaja u minuti pri čemu životni vijek svrdla iznosi 27 dana po rezultatima analize. Algoritmi Slučajna šuma i LightGBM korišteni su u analizi koja je dala najbolji rezultat. Precizne numeričke vrijednosti omogućuju procjenu učinkovitosti različitih postavki brzine u postizanju željenih karakteristika provrta. Dinamika promjena brzine bušenja tijekom životnog vijeka svrdla ukazuje na potrebu prilagodbe postavki brzine kako bi se održala konzistentna kvaliteta provrta. Kako softver generira prilagodbu brzine bušenja s obzirom na

životni vijek svrdla, moguće je pratiti kada je potrebno zamijeniti svrdlo te ne gubiti dodatno vrijeme ukoliko nepažnjom zaposlenika ne primijete da je svrdlo već trebalo biti zamijenjeno pa dođe do pucanja svrdla ili se dobije oštećen proizvod. Tu je optimizacija primjenjiva za prediktivno održavanje koje ulazi u planiranje procesa te neće doći do neplaniranih zastoja u procesu, što automatski osigurava zadovoljavajuću kvalitetu svih proizvedenih dijelova.

Prateći rezultate i analize pri različito podešenim algoritmima, osobno smatram da neovisno o kontroliranom parametru softver generira dobre rezultate. Konačni rezultati mogu se interpretirati i primijeniti na realnim procesima jer pružaju dovoljnu količinu informacija. Ono što rezultate čini još značajnijima jest činjenica da su isti parametri postignuti i kada su korišteni dodatni algoritmi, kada je proces ručno prilagođavan. To potvrđuje konzistentnost i ispravnost pristupa što ukazuje na pouzdanost postignutih rezultata bez uključivanja najnaprednijih tehnika. Umjetna inteligencija uvelike olakšava razne procese u proizvodnih sektorima, te smatram kako se i najmanjom primjenom algoritama umjetne inteligencije mogu postići značajni pomaci u optimizaciji te ostvariti napredovanje na tržištu. Na temelju ovih analiza, moguće je poboljšati procese prešanja i bušenja. Prilagodбом sile uprešavanja i brzine bušenja prema optimalnim vrijednostima, može se postići konzistentna kvaliteta proizvoda, smanjiti oštećenja i optimizirati proizvodne performanse. Kontinuirano praćenje parametara uz pomoć MaiLab softvera omogućava brzu reakciju na promjene i stalno poboljšanje procesa.

7. ZAKLJUČAK

Analiza podatka, u ovom slučaju parametara prešanja i bušenja, pružila je uvide u dinamiku proizvodnih procesa. Prilagodбом ključnih varijabli prema optimalnim vrijednostima postignuta je konzistentna kvaliteta proizvoda. Smanjenje oštećenja i optimizacija proizvodnih performansi predstavljaju ključne rezultate ovih pristupa. MaiLab softver se pokazao korisnim alatom u praćenju i analizi parametara u stvarnom vremenu. Kontinuirano praćenje uz pomoć umjetne inteligencije omogućava brzu reakciju na promjene, što dovodi do stalnog poboljšanja procesa. Preciznost analiza i brzina odgovora pridonose efikasnost proizvodnje te omogućavaju poduzećima da održe razinu kvalitete proizvoda. U konačnici, primjena znanosti o podacima i umjetne inteligencije u procesima proizvodnje omogućava poduzećima da teže ka optimalnim performansama. Poboljšana preciznost u postavljanju parametara i brza reakcija na promjene rezultiraju ne samo uštedama u resursima, već i dugoročno konkurentsku prednost na tržištu. Ove tehnologije postaju ključne za inovativne i efikasne proizvodne prakse, čineći ih središnjim dijelom modernizacije industrijskih procesa. Proizvodna poduzeća mogu poboljšati procese automatizacijom prikupljanja podataka, integracijom u sustave i platforme te primjenom umjetne inteligencije i strojnog učenja. Korištenje algoritama umjetne inteligencije omogućuje predviđanje otkaza opreme, optimizaciju parametara proizvodnje te prilagodbu proizvodnje prema stvarnim potrebama. Ove tehnologije pridonose bržim i inteligentnijim odlukama, kao što je prikazano u poglavljima prije. Analizom je utvrđeno da se korištenjem softverskog alata uvelike može doprinijeti optimizaciji procesa uz ostvarivanje konkurentске prednosti, a da kvaliteta proizvoda ne trpi.

LITERATURA

- [1] Rolon, Alvaro Junior Caicedo; Alvarado, Wlamyr Palacios; Peret, Marvin Vladimir Davila: Industry 4.0 In Modern Patient Management, Webology, 2022.
- [2] Grabowska, Sandra; Saniuk, Sebastijan; Gajdzik, Božena: Industry 5.0.: Improving Humanization and Sustainability of Industry 4.0, Scientometrics, 2022.
- [3] <https://www.medianet.hr/en/umjetna-inteligencija-big-data-i-nlp-tehnologije-koje-koristimo-u-poslovanju/> pristupljeno 23.1.2024.
- [4] Hui Lin, Ming Li: Practitioner's Guide to Data Science, Boca Raton, 2023.
- [5] Hunt, Earl B.: Artificial Intelligence, New York, 1975.
- [6] Mijić, N.: Umjetna inteligencija – modeli učenja (Završni rad), Osijek, 2019.
- [7] Li, R., Dong, X., Ma, C., Liu, L.: Computational identification of surrogate genes for prostate cancer phases using machine learning and molecular network analysis, Shanghai 2014.
- [8] <https://www.mymarketresearchmethods.com/data-types-in-statistics/> pristupljeno 4.1.2024.
- [9] <https://www.edukacentar.hr/EdukaZona/Prakticni-vodic-za-pivot-tablice-u-Microsoft-Excelu> pristupljeno 4.1.2024.
- [10] <https://brocoders.com/blog/data-collection-methods-definition-types-and-tools/> pristupljeno 5.1.2024.
- [11] <https://www.softwaresuggest.com/blog/benefits-of-using-data-acquisition-system/> pristupljeno 4.1.2024.
- [12] <https://plmadventure.com/2021/09/28/trendovi-digitalizacije/> pristupljeno 3.1.2024.
- [13] Luo, ZQ.: Applications of convex optimization in signal processing and digital communication. *Math. Program., Ser. B* **97**, 177–207 (2003)
- [14] <https://repozitorij.fpz.unizg.hr/islandora/object/fpz%3A734/datastream/PDF/view> pristupljeno 3.1.2024.
- [15] <https://www.mitsubishielectric.com/fa/products/software/data-science-tools/mailab/index.html> pristupljeno 6.2.2024.
- [16] <https://emea.mitsubishielectric.com/fa/products/edge/edgsw/edgap/melsoft-mailab> pristupljeno 6.2.2024.
- [17] <https://en.wikipedia.org/wiki/KNIME> pristupljeno 6.2.2024.
- [18] <https://www.knime.com/downloads> pristupljeno 6.2.2024.
- [19] <https://en.wikipedia.org/wiki/RapidMiner> pristupljeno 6.2.2024.

- [20] https://www.researchgate.net/figure/RapidMiner-process-for-the-development-of-the-functionality-of-the-framework-to-perform_fig1_353059889 pristupljeno 6.2.2024.
- [21] https://www.youtube.com/watch?v=IZJXrRTB0hU&t=100s&ab_channel=MITSUBISHIIELECTRICFactoryAutomation pristupljeno 6.2.2024.
- [22] <https://www.mitsubishielectric.com/fa/products/software/data-science-tools/mailab/index.html> pristupljeno 6.2.2024.
- [23] <https://www.mitsubishielectric.com/fa/products/software/data-science-tools/mailab/use/index.html> pristupljeno 6.2.2024.
- [24] M. Imal: Kaizen, the key to Japan's competitive success, ISBN 9780394551869
- [25] <https://www.mitsubishielectric.com/fa/sols/digital-manufacturing/en/smkl/index.html> pristupljeno 9.1.2024.
- [26] https://ip.festo-didactic.com/Infoportal/CPFactoryLab/data/CP-F-LINEAR/files/manual_en.pdf pristupljeno 20.2.2024.
- [27] Brkičić, L.: Analiza povezanosti parametara i ključnih pokazatelja na tvornici za učenje (Završni rad), Zagreb, 2023.
- [28] [radiofrekvencijska identifikacija - Hrvatska enciklopedija](#) 20.2.2024.
- [29] Miro Hegedić, Petar Gregurić, Mihael Gudlin, Matija Golec, Anja Đenadija, Nataša Tošanović, Nedeljko Štefanić: Design and Establishment of a Learning Factory at the FMENA Zagreb, 2022.
- [30] https://en.wikipedia.org/wiki/Root-mean-square_deviation pristupljeno 5.3.2024.

PRILOZI

I. Python skripta