

Preskriptivno održavanje

Curman, Martin

Undergraduate thesis / Završni rad

2019

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://um.nsk.hr/um:nbn:hr:235:598310>

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

Download date / Datum preuzimanja: **2024-04-17**

Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Martin Curman

Zagreb, 2019. godina.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Dragutin Lisjak, dipl. ing.

Student:

Martin Curman

Zagreb, 2019. godina.

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

Zahvaljujem se svom mentoru prof. dr.sc. Dragutinu Lisjaku na ukazanom povjerenju, svojoj obitelji na konstantnoj podršci tokom studija te svima onima koji su me podržavali i vjerovali u mene.

Martin Curman



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **MARTIN CURMAN**

Mat. br.: 0035206381

Naslov rada na hrvatskom jeziku: **PRESKRIPTIVNO ODRŽAVANJE**

Naslov rada na engleskom jeziku: **PRESCRIPTIVE MAINTENANCE**

Opis zadatka:

Preskriptivno održavanje je najnovija strategija održavanja industrijske opreme, a temelji se na analitici velike količine podataka. Za razliku od prediktivnog održavanja koja nam daje mogućnost nadzora i ranog otkrivanja potencijalnih kvarova, preskriptivna strategija održavanja daje odgovor na pitanje kada će se kvar dogoditi i što u tom slučaju treba poduzeti. U skladu s navedenim u radu je potrebno:

1. Opisati postojeće strategije održavanja.
2. Prikazati mogućnost primjene analitike velike količine podataka (eng. *Big Data Analytics*) u održavanju industrijske opreme.
3. Proanalizirati i detaljno opisati strategiju preskriptivnog održavanja.
4. Prikazati slučajeve implementacije preskriptivnog održavanja.
5. Analizom sprovednog istraživanja izvesti zaključak.

Zadatak zadan:
29. studenog 2018.

Rok predaje rada:
1. rok: 22. veljače 2019.
2. rok (izvanredni): 28. lipnja 2019.
3. rok: 20. rujna 2019.

Predviđeni datumi obrane:
1. rok: 25.2. - 1.3. 2019.
2. rok (izvanredni): 2.7. 2019.
3. rok: 23.9. - 27.9. 2019.

Zadatak zadao:

Izv. prof. dr. sc. Dragutin Lisjak

Predsjednik Povjerenstva:

Prof. dr. sc. Branko Bauer

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	II
POPIS TABLICA.....	III
POPIS OZNAKA	IV
SAŽETAK.....	V
SUMMARY	VVI
1. UVOD.....	1
2. STRATEGIJE ODRŽAVANJA	2
2.1. Korektivno održavanje	4
2.2. Preventivno održavanje.....	5
2.2.1. Održavanje po konstantnom ciklusu	5
2.2.2. Održavanje po stanju.....	6
2.3. Proaktivno održavanje.....	6
2.4. Kontrolni pregledi	7
2.5. Ostale strategije održavanja	8
3. PRESKRIPTIVNA ANALITIKA	9
3.1. Stupnjevi analitičkog procesa	10
4. PRINCIP RADA PRESKRIPTIVNOG ODRŽAVANJA.....	11
4.1. Prikupljanje podataka.....	12
4.1.1. Big Data	12
4.1.2. Načini pohrane velike količine podataka	13
4.1.2.1. Hadoop.....	14
4.2. Analiza i dijagnoza.....	16
4.3. Predviđanje kvarova.....	18
4.3.1. Duboko učenje	19
4.3.2. Usporedba konvencionalnih metoda i metoda dubokog učenja.....	21
4.4. Potpora donošenju odluka	23
4.5. Planiranje održavanja – optimiranje	25
4.5.1. Operacijska istraživanja	25
4.6. Implementacija i analiza	27
5. PRIMJERI IMPLEMENTACIJE PRESKRIPTIVNOG ODRŽAVANJA	28
5.1. Saras - Aspen Mtell.....	29
5.1.1. Princip rada Aspen Mtell	30
5.2. IBM preskriptivno održavanje na oblaku.....	29
6. ZAKLJUČAK.....	36
LITERATURA.....	37
PRILOZI.....	40

POPIS SLIKA

Slika 1.	Povijesni razvoj strategija održavanja	3
Slika 2.	Podjela korektivnog održavanja	4
Slika 3.	Podjela preventivnog održavanja	5
Slika 4.	Glavne strategije održavanja	8
Slika 5.	Vrste analitike.....	9
Slika 6.	Stupnjevi analitičkog procesa.....	10
Slika 7.	Realizacija preskriptivnog održavanja	11
Slika 8.	Rast količine podataka.....	13
Slika 9.	Hadoop infrastruktura.....	14
Slika 10.	HDFS struktura.....	15
Slika 11.	MapReduce struktura	16
Slika 12.	IIoT prikupljanje podataka	17
Slika 13.	Umjetne neuronske mreže	19
Slika 14.	Model neurona u ANN	20
Slika 15.	Usporedba konvencionalnog modela predviđanja kvarova i modela dubokog učenja.....	21
Slika 16.	Analiza kvara ležaja konvencionalnom metodom i metodom dubokog učenja	22
Slika 17.	Proces donošenja odluke	23
Slika 18.	Faktori koji se uzimaju u obzir kod odlučivanja	24
Slika 19.	Podjela metoda operacijskih istraživanja	26
Slika 20.	PriMa-X model analize zrelosti preskriptivnog održavanja.....	27
Slika 21.	Unos datoteka i izgled datoteke događaja	31
Slika 22.	Rezultati analize	32
Slika 23.	Detaljni prikaz rezultata analize	33
Slika 24.	Prikaz pojedinog generatora sa karticom o detaljima	33
Slika 25.	Kartica sa značajkama i faktorima rizika	34
Slika 26.	Kartica sa dnevnikom održavanja	34
Slika 27.	Kartica sa histogramima	35

POPIS TABLICA

Tablica 1. Usporedba konvencionalnih metoda i metoda dubokog učenja	22
---	----

POPIS OZNAKA

Oznaka	Opis
EFNMS	<i>European Federation of National Maintenance Societies</i>
RTF	<i>Run to failure</i>
UFR	<i>Unintended failure replacement</i>
CBM	<i>Condition Based Maintenance</i>
PdM	<i>Predictive maintenance</i>
RDFA	<i>Root Cause Failure Analysis</i>
FMEA	<i>Failure Mode and Effects Analysis</i>
RCM	<i>Reliability Centered Maintenance</i>
RPN	<i>Risk Priority Number</i>
IIoT	<i>Industrial Internet of Things</i>
M2M	<i>Machine to Machine</i>
SQL	<i>Structured Query Language</i>
NoSQL	<i>Not only Structured Query Language</i>
HDFS	<i>Hadoop Distributed File System</i>
RUL	<i>Remaining Useful Life</i>
STL	<i>Seasonal, Trend and Residue decomposition</i>
ARIMA	<i>Autoregressive integrated moving average</i>
LSTM	<i>Long Short-Term Memory</i>

SAŽETAK

Tema ovog rada je analiza procesa preskriptivnog održavanja i primjer njegove implementacije. U prvom poglavlju navedene su postojeće strategije održavanja i njihove karakteristike, zatim je u drugom opisana preskriptivna analitika i njena važnost kod preskriptivnog održavanja. U trećem poglavlju detaljno je prikazan proces preskriptivnog održavanja koji se sastoji od prikupljanja velike količine podataka, njihove analize i predviđanja kvarova pomoću metoda strojnog učenja, propisivanja aktivnosti s kojima se nastanak kvara može spriječiti ili odgoditi te konačne implementacije aktivnosti održavanja i analize uspješnosti. Zadnje poglavlje sadrži primjer implementacije u elektroenergetskoj tvrtki Solas i primjer preskriptivnog održavanja na oblaku.

Ključne riječi: preskriptivno održavanje, preskriptivna analitika, velika količina podataka, duboko učenje, optimizacija, analiza, implementacija

SUMMARY

The topic of this paper is an analysis of prescriptive maintenance and its application in industry. The first chapter contains existing maintenance strategies along with characteristics of each one. Then in the second chapter there is a brief explanation of prescriptive analytics along with its role in prescriptive maintenance. Third chapter contains a detailed process of prescriptive maintenance, which consist of gathering Big Data, analysis of the data and fault prediction using machine learning methods, prescribing a maintenance activity to avoid or prolong failure occurrence and the assessment of the current state maturity. In the final section of this paper, example of implementation of prescriptive maintenance is given along with prescriptive maintenance on cloud.

Key words: prescriptive maintenance, prescriptive analytics, Big Data, deep learning, optimization, analysis, implementation

1. UVOD

Održavanje je jedna od temeljnih djelatnosti proizvodnog procesa kojoj se dodjeljuje zadatak provođenja kontrole nad sredstvima za rad, izvođenje određenih popravaka i provođenje preventivnih postupaka radi sprječavanja zastoja u procesu proizvodnje. Kako je napredovala tehnologija, a sa tehnologijom i industrija tako su napredovale i strategije održavanja.

Preskriptivno održavanje je najnovija strategija održavanja industrijske opreme koja se prvenstveno temenji na preskriptivnoj analitici i analizi velike količine podataka. Preskriptivno održavanje je posebno u tome što, za razliku od prediktivnog održavanja koje nam daje mogućnost nadzora i ranog predviđanja potencijalnih kvarova, ima mogućnost dati odgovor na pitanje kada će se kvar dogoditi i što u tom slučaju poduzeti. Cijela strategija preskriptivnog održavanja temelji se na konceptu Industrije 4.0. Ovaj novi tip industrije utemeljen je na modelu pametne tvornice u kojoj kibernetičko-fizički sustavi prate procese u tvornici i samostalno donose odluke. Koristeći ono što se zna i ono što se može predvidjeti, cilj preskriptivnog održavanja je donijeti ispravnu odluku za postizanje željenog rezultata u svrhu pomaganja stručnjacima održavanja kod optimizacije rasporeda održavanja i alociranja sredstava za izvođenje operacija održavanja.

Cilj ovoga rada je analizirati postojeće stanje preskriptivnog održavanja i ključne koncepte koji čine preskriptivno održavanje. U radu će se prikazati postojeće strategije održavanja, opisati analitika velike količine podataka i mogućnost njene primjene u održavanju industrijske opreme, proanalizirati i detaljno opisati strategija preskriptivnog održavanja, prikazat će se primjeri implementacije preskriptivnog održavanja te će se analizom sprovedenog istraživanja izvesti zaključak.

2. STRATEGIJE ODRŽAVANJA

Razvoj metoda i strategija održavanje započinje još od 1930. godine, u razdoblju prije drugog svjetskog rata. U to vrijeme strojevi su bili općenito robusni i relativno spori, a instrumenti i sustavi kontrole su bili poprilično osnovni. Zahtjevi za proizvodnjom nisu bili pretjerano visoki tako da vrijeme prekida rada stroja zbog kvara nije predstavljao kritičan problem i bilo je primjereno održavati strojeve kada se pokvare (korektivno održavanje). Takvi strojevi su bili inherentno pouzdani primarno zbog manjka složenih komponenti i elektroničkih dijelova. Danas se mogu vidjeti primjeri takvih strojeva koji su radili duži niz godina i još uvijek obavljaju zadatke kao i od prvoga dana.

Početkom 1950-ih godina raste razvoj kompetitivnog tržišta koje stavlja manje tolerancije na vrijeme zastoja. Trošak radne snage značajno je porastao što je dovelo do sve veće i veće mehanizacije i automatizacije, strojevi su postajali kompleksiji i radili sa većim brzinama nego prije tako da su se brže trošili i činili su se manje pouzdanim. Proizvodnja je zahtjevala bolje održavanje što je dovelo do razvoja preventivnog održavanja.

Na 1. europskom kongresu europske federacije nacionalnih udruženja održavatelja EFNMS (European Federation of National Maintenance Societies) predstavljeno je pet načela održavanja [1]:


1. Čekaj i vidi (aktivnosti popravka kvara započinje nakon pojave kvara).
2. Oportunističko održavanje (nakon pojave kvara uvodi se preventivno održavanje).
3. Preventivno održavanje (aktivnosti održavanja provode se prije pojave kvara u cilju sprječavanja pojave kvara u budućnosti).
4. Predviđanje održavanja (aktivnosti održavanja provode se prije pojave kvara u cilju predviđanja vjerojatnosti nastanka kvara).
5. Održavanje po stanju (aktivnosti održavanja provode se na temelju utvrđenog stanja tehničkih sustava).

S porastom značaja održavanja, vremenom su se javljale nove strategije, a ponekad su se na različitim mjestima u svijetu javljale slične strategije definirane i nazvane na različite načine.

Današnje strategije održavanja podijeljene su u sljedeće skupine [1]:

- Korektivno
- Preventivno
- Terotehnološko
- Logističko
- Održavanje po stanju
- Plansko
- Totalno produktivno
- Pouzdanosti usmjereno održavanje
- Ekspertni sustavi održavanja
- Samoodržavanje

Na slici 1. prikazan je povijesni razvoj strategija održavanja.




Slika 1. Povijesni razvoj strategija održavanja [1]

Dvije glavne i najzastupljenije strategije održavanja su korektivno i preventivno održavanje.

2.1. Korektivno održavanje

Korektivno održavanje (eng. *On-Faliure Maintenance*) je najstariji pristup održavanju, to je prva strategija koja se pojavila i temelji se na otklanjanju kvara ili oštećenja nakon što se pojavi. Danas se korektivno održavanje zadržalo kao metoda samo kod pomoćne opreme, opreme kratkog vijeka trajanja i opreme koja se ne može drugačije održavati, a manje kod radne opreme. Na opremi su uvijek mogući kvarovi, a samim time i određeni udio korektivnog održavanja u ukupnom održavanju. Kada nastane kvar rad se najčešće organizira bez prekida u cilju što bržeg otklanjanja kvara. [1]




Slika 2. Podjela korektivnog održavanja [2]

Aktivnosti korektivnog održavanja se mogu izvoditi planirano i neplanirano. Planirano se izvode kod primjene strategije „čekaj i vidi“ RTF (Run to Faliure) gdje se namjerno i svjesno ostavlja oprema da radi do nastanka kvara, dok se neplanirano izvode kod propusta ostalih strategija održavanja ili kod nemara vlasnika i nesvjesnog zanemarivanja opreme UFR (Unintended Failure Replacement). [2]

Prednosti korektivnog održavanja su maksimalno vrijeme rada stroja između prekida, minimalno planiranje (nema rasporeda održavanja i aktivnosti dok ne dođe do kvara) dok su nedostaci neplanirani zastoji, sigurnosni rizik, veći proizvodni gubici, dulje vrijeme popravka, veći broj zaposlenika na održavanju, nema nadzora i pouzdanosti u radu postrojenja... [1]

2.2. Preventivno održavanje

Preventivno održavanje (eng. *Preventive maintenance*) je strategija na čijoj bazi su razvijene mnoge nove strategije održavanja, temelji se na provođenju radova i aktivnosti održavanja prije nego što se kvar dogodi. Aktivnosti i radovi koji se provode izvođe se često i zahtijevaju unaprijed određen plan i raspored. Osnovna podjela preventivnog održavanja je održavanje po konstantnom ciklusu (eng. *Fixed-time maintenance*), održavanje po stanju (eng. *Condition based maintenance (CBM)*, *Predictive maintenance (PdM)*), proaktivno održavanje (eng. *Proactive mainenance*) te kontrolni pregledi. [1]



Slika 3. Podjela preventivnog održavanja [1]

2.2.1. Održavanje po konstantnom ciklusu

Ovaj način održavanja još se naziva plansko-preventivno održavanje, obavlja se na temelju unaprijed pripremljenih uputa i postupaka. Aktivnosti održavanja obavljaju se planski po nekom od radnih kriterija kao što su vrijeme, prijedeni put, broj uključivanja i isključivanja sustava, količina izrađenih proizvoda itd.

Održavanje po konstantnom ciklusu uključuje aktivnosti kao što su pregledi, čišćenje i pranje, podmazivanje i zamjena rezervnih dijelova. To su aktivnosti koje se obavljaju u cilju utvrđivanja i sprječavanja neispravnosti u funkcioniranju koje bi mogle izazvat oštećenja i kvarove. Izvođenjem plansko-preventivnog održavanja smanjuju se pojave oštećenja, kvarova i havarija, usklađuju se planovi održavanja s proizvodnim planovima dok s druge strane troškovi održavanja rastu s obzirom da je vrijeme između i do preventivnih pregleda kraće od

vremena pojave kvara (vrijeme rada stroja između prekida se smanjuje), također može se desiti da dođe do odstupanja stvarnog stanja u kojem se sustav nalazi s obzirom na definirane preporuke i norme tako da se plansko-preventivno održavanje uvodi kao nadopuna ostalim strategijama održavanja. [1]

2.2.2. Održavanje po stanju

Održavanje po stanju koristi regularnu procjenu stvarog stanja svakog dijela tehničkog sustava koji se može mjeriti i čije ponašanje se može kontrolirati određenim parametrima [1]. Ako se koristi na pravi način, održavanje po stanju može identificirati većinu, ako ne i sve faktore koji limitiraju efektivnost i efikasnost stroja. Umjesto oslanjanja na prosječni vijek trajanja, za određivanje aktivnosti održavanja koriste se metode tehničke dijagnostike što znači utvrđivanje stvarnog stanja radnog sustava u određenom trenutku te se na temelju dijagnostičkih informacija i praćenja stvarnog stanja te uspoređivanja s dopuštenim vrijednostima donose odluke o budućim koracima kod planiranja održavanja čime se sprječava pojava kvara ili oštećenja ili se isti brzo locira.

Postoje mnoge tehnologije koje bi mogle i trebale dati uvid u stanje sustava. Tehnologije se biraju na temelji parametara koji se proučavaju. Izbor parametara zavisi od funkcije tehničkog sustava i pronalaženju utjecajnih parametara koji najbolje opisuju rad i trošenje radnog sustava. Parametri mogu biti: razina vibracija, razina buke, napon struje, temperatura... Na temelju izabranih parametara odabiru se tehnologije koje omogućuju mjerenje tih istih parametara, a to su: kontrola mjerenjem vibracija, termografija, tribologija, kontrola parametara procesa, vizualna inspekcija i nerazorna ispitivanja. Kontrola mjerenjem vibracija je često ključna komponenta strategije održavanja po stanju, no ona ne može pružiti sve informacije tako da se ona koristi u kombinaciji s nekom od drugih metoda. Nakon što se mjerenja obave, uspoređuju se izmjereni parametri s dopuštenim vrijednostima. Konačna odluka o daljnjim koracima i izvođenju popravaka i revizija donosi se na bazi intuicije i iskustva inženjera održavanja. [1] [3]

2.3. Proaktivno održavanje

Proaktivno održavanje može se svrstati pod preventivno održavanje u smislu poduzimanja aktivnosti da se spriječe kvarovi, a radi na principu otklanjanja korjena problema kvarova. Svrha proaktivnog održavanja je sagledavanje zastoja stroja kao nečega što se može predvidjeti i eliminirati prije nego što nastane.

Metode proaktivnog održavanja:

- Analiza uzroka korijena kvarova – RDFA (eng. *Root Cause Faliure Analysis*)
- Analiza uzroka i posljedica kvarova – FMEA (eng. *Faliure Mode and Effects Analysis*)
- Održavanje usmjereno ka pouzdanosti - RCM (eng. *Reliability Centered Maintenance*)

Analiza uzroka korijena kvarova je logička, strukturirana i deduktivna tehnika kojom se mogu otkriti uzroci koji su doveli do kvara. Cilj ove analize je da pruži dovoljno činjenica o uzrocima kvarova kako bi se omogućilo stvaranje točne i prikladne metode otklanjanja. Ona se provodi u situacijama kada se na opremi često ponavlja neki kvar. Kada dođe do kvara neke opreme, treba se istražiti što je prouzrokovalo kvar tako da u budućosti ne dođe do istog. Postoji nekoliko metodologija istraživanja poput odgovaranja na pitanja što, kada, kako, zašto, zatim dijagram riblja kost, logičko stablo... [4]

Analiza uzroka i posljedica kvarova je metoda kojom se indentificiraju svi mogući kvarovi te se analiziraju njihove posljedice. U idealnom slučaju ova metoda počinje u najranijoj fazi životnog vijeka opreme počevši od koncepta i dizajna pa sve do kraja uporabe. Provodi se na način da se kvarovi ocjenjuju po kriteriju ozbiljnosti, učestalosti i težine otkrivanja te se zatim određuje vrijednost prioriteta rizika RPN (eng. *Risk Priority Number* – umožak ozbiljnosti, učestalosti i težine otkrivanja) za svaki kvar. Na temelju dobivene RPN procjenjuju se troškovi rizika i uspoređuju se sa troškovima aktivnosti za eliminaciju rizika na temelju čega se donosi odluka o poduzimanju daljnjih aktivnosti. [1]


Održavanje usmjereno ka pouzdanosti ima zadatak da omogući dostupnost i pouzdanost one opreme ili dijelova koja najviše utječu na izvršavanje funkcionalnosti nekog sustava. Kod implementacije ove strategije podrazumjeva se postavljanje i odgovaranje na 7 pitanja po SAE JA1011 standardu koja daju uvid u značaj funkcije promatranog dijela i na koji sve način može doći do toga da dio prestane obavljati svoju funkciju, uzrok kvara, posljedice kvara, načine predviđanja i sprječavanja kvara te što napraviti ako se ne može odrediti prikladan način održavanja. [1]

2.4. Kontrolni pregledi

Kontrolni pregledi služe za utvrđivanje funkcionalne i tehničke ispravnosti radnih sredstava te ih obavljaju inspektori koji rade u sklopu državnih institucija ili posebne tvrtke koje rade prema određenim zakonskim pravilima i propisima. Mogu se kontrolirati transportna sredstva, vatrogasni aparati, energetske instalacije... [1]

2.5. Ostale strategije održavanje

Ostale strategije održavanja nisu toliko zastupljene no važno ih je spomenuti da postoje. Terotehnoški pristup održavanju temelji se na koncepciji da stručnjaci održavanja sa svojim znanjem i iskustvom izvorno ili posredno sudjeluju u svim fazama životnog vijeka strojeva ili opreme, logistički pristup ima težište na tome da se kroz projektiranje i proizvodnju učini maksimalno kako bi oprema imala visok stupanj pouzdanosti i lako održavanje, održavanja zasnovano na pouzdanosti temelji se na vjerovatnosti da će neki stroj ili oprema obavljati zadani zadatak u određenom vremenu dok se kod cjelovitog produktivnog održavanja osoblje koje rukuje s opremom i održava opremu. Ekspertni sustavi su računalni programi koji detektiraju potencijalne kvarove te predlažu rješenja za njihovo otklanjanje. Koncepcija kod koje postoji mogućnost automatizirane agregatne zamjene uređaja ili dijelova opreme koja se upravlja ekspertnim sustavom ili više njih zove se samoodržavanje. [1]



Slika 4. Glavne strategije održavanja [1] [2]

Na slici 4. prikazana je podjela glavnih strategija održavanja gdje je preskriptivno održavanje podkategorija preventivnog održavanja. Preskriptivno održavanje dakle svrstava se u preventivne strategije održavanja kojima se nastoji sprječiti nastanak kvara, oštećenja i minimizirati zastoj opreme.

3. PRESKRIPTIVNA ANALITIKA

Preskriptivna analitika je područje poslovne analitike čiji je zadatak predložiti najbolje rješenje za danu situaciju. Preskriptivno održavanje temelji se upravo na preskriptivnoj analitici, ona je treći stupanj poslovne analitike nakon deskriptivne i prediktivne analitike.

Deskriptivna analitika koristi i prikuplja podatke i informacije iz prošlosti da bi se došlo do informacija što se dogodilo te je ona daleko najprimjenjivija trenutno. Koristi metode s kojima se prepoznaju uzorci u podacima, a neke od metoda su metoda vizualizacija podataka, *cluster* analiza i prepoznavanje trendova u podacima. Nakon deskriptivne analitike pojavila se dijagnostika koja daje odgovor na pitanje zašto se nešto dogodilo (npr. RCFA koristi ovu vrstu statistike), a koristi metode poput rudarenja podataka i analize korelacija. Prediktivna analitika je nadogradnja na ostale dvije analitike, koristi povijesne podatke uz primjenu algoritama kako bi se odredila vjerojatnost da dođe do nekog događaja. Metode prediktivne analitike su regresijska analiza, Monte Carlo simulacije, metode strojnog učenja... Preskriptivna analitika koristi ostale vrste analitike te uz predviđanja što će se dogoditi predlaže radnje koje bi se trebale poduzeti u cilju postizanja korisnosti. Predlaganje i donošenje odluka ostvaruje se uz pomoć simulacija i optimizacija mogućih odluka koje se mogu donijeti [5].


Razvojem analitike smanjuje se količina ljudskog rada u analiziranju podataka te se pažnja stavlja na donošenje odluka. Preskriptivnom analitikom nastoji se u potpunosti eliminirati ljudski rad u analizi podataka pa čak i u nekim slučajevima kod donošenju odluka kao što se može vidjeti na slici 5.



Slika 5. Vrste analitike [29]

3.1. Stupnjevi analitičkog procesa

Analitički proces preskriptivnog održavanja opreme odvija se kroz stupnjeve kao što je prikazano na slici 6.



Slika 6. Stupnjevi analitičkog procesa [6]


Sve počinje prikupljanjem podataka pomoću senzora ugrađenih u strojeve ili mjernih uređaja kojima rukuje čovjek. Prikupljeni podaci mogu biti povijesni ili prikupljeni u stvarnom vremenu, no kombinacija oba dati će najbolje rezultate. Objedinjavanjem nastalih podataka koji mogu biti strukturirani, polustrukturirani i nestrukturirani nastaje velika količina podataka (eng. *Big Data*) koja je komplicirana i duga za procesuiranje te se mora organizirati u set podataka. Prikupljanje seta podataka omogućuje analizu istih te provođenje raznih simulacija pomoću kojih se optimizacijom dolazi do optimalnog rješenja koje se onda predlaže korisniku. U sljedećem poglavlju detaljnije će se objasniti navedeni stupnjevi i princip rada preskriptivnog održavanja. [6]

4. PRINCIP RADA PRESKRIPTIVNOG ODRŽAVANJA

Preskriptivno održavanje relativno je novi pojam te je još u ranoj fazi nastajanja i implementacije. Postoji nekoliko faktora zbog čega raste potražnja za preskriptivnim strategijama [7]:

- Automatizacija – što se više automatizacije koristi u proizvodnji, zahtjeva se što brži odziv na probleme u vezi održavanja opreme
- Ekonomija – odluka o tome koje je rješenje najekonmičnije postaje sve više kompleksno pa je kod održavanja važno ustanoviti što svaka odluka predstavlja u financijskom smislu.
- Promjene radne snage – stariji radnici se umirovljavaju te dolazi nova radna snaga koja očekuje da ima moderne alate kako bi im olakšali posao
- Radni uvjeti opreme – osim zbog starenja i degradacije, oprema se kvari i zbog uvjeta rada koji mogu odstupati od propisanog zbog prirode procesa ili nemara radnika, u tom slučaju preskriptivna analitika može uzeti u obzir te uvjete i donjeti preporuke na temelju njih.
- Uspješnost opreme – potrebna je veća razina sofisticacije u pogledu organizacije podataka procesa i opreme. Industrijski internet stvari i analitika imaju posebnu mogućnost prikupljanja velike količine podataka koji su razmješteni u različitim sustavima.

Realizacija preskriptivnog održavanja odvija se na sljedeći način [8].



Slika 7. Realizacija preskriptivnog održavanja [8]

Preskriptivno održavanje sastoji se od prikupljanja podataka, analize i dijagnoze, predviđanja kvarova, potpore donošenju odluka, optimiranja i implementacije i analize.

4.1. Prikupljanje podataka

Preskriptivno održavanje je najkompleksnije od svih strategija održavanja koje se baziraju na znanju (deskriptivno, dijagnostičko, prediktivno). Kod strategija održavanja baziranih na znanju uzimaju se u obzir svi proizvodni procesi, a ne samo pojednini stroj ili uređaj koji se održava. Na taj način stavlja se pažnja na analiziranje održavanja kao neizoliranu pod-domenu proizvodnog sustava koja ima utjecaj na cjelokupnu organizaciju i procese u njoj. Kako bi se održavanje realiziralo potrebno je prikupiti određene podatke o proizvodnom sustavu i samoj opremi koja se održava poput količine proizvodnje, utrošku energije, povijesnih podataka održavanja (trošak popravka, uzrok kvara, vrijeme izvan pogona...), stanja komponenata stroja i ostalih informacija koje bi mogle utjecati na proizvodni proces. Sve te informacije i podatke karakterizira veličina, velika brzina nastajanja i raznolikost koji su predovjeti za nastanak Big Data [8].

4.1.1. Big Data

Preskriptivno održavanje koristi velike količine podataka koji se onda analiziraju i iz njih izvlače korisne informacije, podaci mogu nastajati u stvarnom vremenu (eng. *real time data streams*) ili mogu biti povijesni. Big data je skup podataka koje karakterizira velika količina, visoka brzina nastajanja i velika raznolikost. Podaci koji čine *Big Data* mogu biti strukturirani, polustrukturirani i nestrukturirani i mogu dolaziti iz različitih izvora kao što su unutarnji koji su u domeni tvrtke ili vanjski koji dolaze iz okruženja tvrtke [9].

Strukturirani podaci su oni koji imaju definiranu strukturu, organizirani su i pohranjeni u bazama podataka te se mogu lako pronaći što omogućuje efektivno procesuiranje i analizu. To mogu biti npr. podaci u obliku excel tablica koje karakterizira lak unos, pohrana i analiza. Polustrukturirani podaci nisu organizirani u bazi podataka, ali imaju pridruženu neku vrstu informacije koja im omogućuje lakše procesuiranje od sirovih podataka. Nestrukturirani podaci mogu biti različitih oblika i karakterizira ih nemogućnost pohranjivanja u tradicionalnim bazama podataka zbog čega su se razvile alternativne platforme za pohranu tih vrsta podataka. Nestrukturirani podaci su: slike, tekstualni zapisi, zapisi senzora stoja, video i audio datoteke i slično. Rast količine podataka se svakodnevno povećava, 90% svih podataka u svijetu je generirano u zadnje dvije godine i taj trend raste kao što se može vidjeti na slici 8. [10].



Slika 8. Rast količine podataka [30]

Rastu količine podataka doprinjela je i pojava industrijskog interneta stvari IIoT (eng. Industrial Internet of Things) u proizvodnji, gdje su strojevi ili uređaji opremljeni sa tehnologijama za prikupljanje podataka (senzori) koji imaju mogućnost međusobne komunikacije (M2M komunikacija) te su spojeni na internet [9]. To doprinosi činjenici da je 80% od svih podataka nestrukturirano jer senzori generiraju takvu vrstu podataka. Zbog količine i veličine tih podataka pojavila se potreba za novim sustavima pohranjivanja.


4.1.2. Načini pohrane velike količine podataka

Nestrukturirani i polu struktuirani podaci teško se pohranjuju u tradicionalnim bazama podataka poput relacijske baze podataka koja je temeljena na modelu entiteti-veze gdje je osnovna zamisao skupinu podataka rastaviti u manje logički povezane cijeline te podatke svake cijeline pohraniti u zasebnu tablicu, podaci iz različitih tablica povezuju se preko polja koje sadrži identične podatke [11]. Relacijske baze podataka realizirane su pomoću SQL računalnog jezika koji je među najpopularnijim jezicima u svrhu izrade, ažuriranja i brisanja podataka iz relacijskih baza podataka. Baza podataka je samo spremnik podataka i njom se rukuje pomoću prikladnog programa na bazi SQL-a poput MS Acces-a. Za pohranjivanje nestrukturiranih

podataka koriste se jezici poput NoSQL i na njemu temeljenih aplikacija poput Cassandra, Riak TS i sličnih, no za pohranu i obradu velike količine podataka prikladnije je koristiti softverski okvir poput Hadoop-a koji će se uzeti za primjer [9] [10].


4.1.2.2. Hadoop

Hadoop je otvoreni kod (eng. *open source*) i implementira MapReduce programski model kojeg je razvio Google zbog potrebe bržeg procesuiranja, bolje distribucije podataka te lakšeg i bržeg pristupa podacima. Napisan je većinom u programskom jeziku Java uz neke dijelove koji su napisani u C jeziku. Tradicionalni sustavi koriste ETL sistem (eng. *Extract, Transform, Load*) koji uzima podatke iz izvora, transformira ih u prikladni format/strukturu i na kraju pohranjuje u bazu podataka. Rastom količine podataka, procesuiranje i pohrana podataka postaje zahtjevna i to je jedan od glavnih nedostataka tradicionalnog pristupa uz to što je vremenski dug proces. Hadoop se sastoji od dva sloja, prvi sloj koji omogućuje paralelno procesuiranje podataka (MapReduce) i drugi sloj koji omogućuje distribuiranu pohranu podataka (HDFS – Hadoop Distributed File System) zbog čega se mogu ostvariti uštede u pogledu računalnih komponenti. Za brže procesuiranje koriste se primarno računalo (eng. *Master node*) i sekundarno računalo (eng. *Slave node*) ili više njih koji se nalaze u grupi servera (eng. *Cluster*) [12]. Infrastruktura se jasnije može vidjeti na slici 9.




Slika 9. Hadoop infrastruktura [30]

HDFS je sustav za distribuciju podataka koji pruža siguran i učinkovit način pohrane podataka tako što koristi jeftine servere koji se mogu lako dodati ili zamjeniti ako postoji potreba za više prostora za pohranu. Kod pohrane HDFS sustav razloži blok podatka na dijelove koji se onda kopiraju na više servera, obično 3 ili više puta, što osigurava očuvanje informacija u slučaju da do kvara nekog servera. Razlaganjem podataka na dijelove omogućuje se i paralelno procesuiranje iste informacije na različitim mjestima što ubrzava postupak pohrane i dohvata tog podatka. HDFS sloj se sastoji od imenskog čvora (eng. *Name node*) i podatkovnog čvora (eng. *Data node*). Imenski čvor nalazi se na primarnom računalu i pohranjuje lokacije svih razloženih podataka na različitim serverima te upravlja raspodjelom podatkovnih blokova, dok podatkovni čvor koji se nalazi na sekundarnom računalu pohranjuje i poslužuje podatkovne blokove te šalje izvještaje imenskom čvoru. Kvar na imenskom čvoru potencijalno uzrokuje nedostupnost cijelog sustava i zbog toga se postavlja i „sekundarni imenski čvor“ čija je funkcija preuzimanje funkcije glavnog imenskog čvora u slučaju njegovog kvara ili gašenja [12]. Struktura HDFS-a prikazana je na slici 10.



Slika 10. HDFS struktura [12]

MapReduce programski model određuje kako se dodjeljuju operacije pohranjivanja svakom čvoru. Sastoji se od pratitelja rada (eng. *Job tracker*) i pratitelja zadatka (eng. *Task tracker*). Korisnik koji je u interakciji sa primarnim računalom daje zahtjev pratitelju rada, čiji se proces odvija na primarnom računalu (slika 9.), koji onda traži od imenskog čvora lokaciju unutar HDFS sustava koja će se procesuirati. Pratitelj rada zatim locira pratitelja zadatka na sekundarnom računalu i daje mu naredbe koje treba izvršiti. Operacija mapiranja (*Map*) odvija se paralelno na način da se set podataka podijeli na jednake dijelove kojima se dodjeljuju ključne vrijednosti koje se zatim sortiraju i reduciraju (*Reduce*) u konačan oblik [12].




Slika 11. MapReduce struktura [12]

Na slici 11. nalazi se prikaz MapReduce programskog modela.

4.2. Analiza i dijagnoza

Važan dio preskriptivnog održavanja nalazi se u području tehničke dijagnostike koja omogućava utvrđivanje stvarnog stanja radnog sustava. Tehnička dijagnostika obuhvaća metode, postupke i sredstva za kontinuirano ili povremeno mjerenje fizikalnih veličina od najvećih značaja za rad i stanje opreme te uspoređivanje tih vrijednosti s utvrđenim graničnim vrijednostima normalnog rada. Određuje se stanje svakog dijela tehničkog sustava koji se može mjeriti i čije ponašanje se može kontrolirati određenim parametrima. Izbor parametara zavisi od funkcije tehničkog sustava i pronalaženju utjecajnih parametara koji najbolje oslikavaju rad i trošenje tehničkog sustava ili neke od njegovih komponenti. Parametri mogu biti: razina vibracija, razina buke, napon struje, količina proizvoda, temperatura, nečistoća u ulju, protok fluida, iznos brzina, iznos moment, jakost struje, iznos tlaka, jakost magnetskog polja, pomak... [1]

Kako je preskriptivno održavanje dio Industrije 4.0 i predviđa se za implementaciju u pametnoj tvornici za mjerenje navedenih parametara podrazumjeva se primjena IIoT senzora. Takvi senzori su „pametni“ i imaju mogućnost komunikacije sa ostalim sensorima i računalima. Upravo zbog takvih senzora i nastaje velika količina podataka. Razvoj tehničkih materijala i tehnologija izrade omogućio je da senzori budu precizniji, jeftiniji, manje veličine i da troše manje struje [13]. Slika 12. prikazuje način prikupljanja podataka sa senzora u IIoT okruženju.



Slika 12. IIoT prikupljanje podataka [13]

Senzori ostvaruju bežičnu ili žičnu komunikaciju sa mrežnim uređajima koji su spojeni na internet. Prikupljeni podaci šalju se preko interneta do računala i servera koji pohranjuju podatke. Važno je da se ti podaci integrišu u sustave upravljanja proizvodnjom, održavanjem i resursima. Nakon što se ti podaci pohrane kako je već opisano ranije kreće se sa analizom i dijagnozom. Kada se ustanovi koji parametri ukazuju na „zdravlje sustava“ i koliki je njihov iznos u odnosu na normalne vrijednosti kreće se na sljedeći korak koji je izrada predikcijskog modela [8].

4.3. Predikcija kvarova

Procjenjivanje preostalog korisnog vijeka trajanja RUL (eng. *Remaining Useful Life*) je središnji zadatak za optimizaciju intervala popravka i minimiziranje troškova neplaniranih zastoja urokovanih kvarovima. Kvarovi se predviđaju na temelju uzoraka kvarova koji su se već događali i na temelju novih podataka koji se prikupljaju da bi se odredila vjerovatnost nastanka kvara. Za poboljšanje predikcije potrebno je, uz podatke koje ukazuju na stanje stoja, prikupiti i podatke vezane uz proizvodnju kao što su opterećenje stroja u budućnosti koje može poslužiti kao dodatni parametar za poboljšanje predikcije [8].

Kroz godine metode su napredovale pa je tako pristup baziran na pravilima zamjenjen sa pristupom koji se temelji na podacima kod kojeg se koriste statističke metode ili metode strojnog učenja poput metode potpornih vektora (eng. *Support Vector Machines*), Bayesian metode učenja (eng. *Bayesian learning techniques*), skriveni Markov modeli (eng. *Hidden Markov models*), i modeli temeljeni na sličnosti ili metode nenadziranog učenja. Navedene konvencionalne metode se jako oslanjaju na ručnu istragu i identifikaciju mogućih karakteristika kvara ili naknadnu kreaciju značajki. Kako bi se prešle prepreke ručne istrage i identifikacije karakteristika kvarova razvijene su razne metode dubokog učenja kao što su konvulucijske neuronske mreže (eng. *Deep Convolutional Neural Network*) [8].


Otkrivanje anomalija i trenda u vrijednostima mjerenih i proučavanih parametara je također često korištena metoda predviđanja kvarova. Mogu se koristiti metode poput STL dekompresije (eng. *Seasonal, Trend and Residue decompression*), klasifikacijska i regresijska drveća, ARIMA (eng. *Autoregressive integrated moving average*), eksponencionalno izravnavanje i druge. Posebno su zanimljive metoda strojnog učenja temeljenih na dubokim neuronskim mrežama kao što su povratna neuronska mreža (eng. *Recurrent Neural Network*) i LSTM (eng. *Long Short-Term Memory*) [14]. Povratna neuronska mreža sadrži povratnu vezu koja služi kao „kratko pamćenje“ dok je LSTM ista kao i povratna neuronska mreža samo što sadrži kompleksniju arhitekturu uz više povratih veza. Sve navedene metode otkrivanja anomalija imaju zajednički problem, a to je da koriste samo podatke koje dolaze sa senzora bez da uzimaju u obzir parametre vezane za proizvodnju.

Aktivno učenje je još jedna od mogućih tehnika za treniranje algoritma strojnog učenja u okruženju sa malom dostupnošću podataka. Ključna ideja je da algoritam sam može izabrati iz kojih podataka će učiti. Usprkos tome primjena tehnika aktivnog učenja još nije istražena u stvarnom svijetu problema preskriptivnog održavanja [8].

4.3.1. Duboko učenje


Duboko učenje je grana nadziranog strojnog učenja koja je prikladna za rješavanje kompleksnih problema i nalaženju uzoraka koji ljudima nisu vidljivi. Modeli dubokog učenja napravljeni su uz pomoć velikog skupa podataka sa značenjem (eng. *labelled data*) i višeslojnih arhitektura neuronskih mreža [15].

Umjetne neuronske mreže (eng. *Artificial Neural Networks – ANN*) su glavni dio dubokog učenja. Inspirirani su mozgom i trebali bi oponašati način učenja kod ljudi i životinja. Sastoje se od ulaznog, izlaznog i skrivenog sloja koji pretvaraju ulaznu vrijednost u izlaznu. Tradicionalne neuronske mreže sadrže 2 ili 3 skrivena sloja dok neke mogu imati i do 150. Primjer neuronske mreže može se vidjeti na slici 13.



Slika 13. Umjetne neuronske mreže [15]

Skriveni sloj umjetne neuronske mreže sastoji se od jedinica koje se zovu neuroni. Takvi neuroni međusobno su povezani sinapsama koje su zapravo težinski ulazi (eng. *weighted inputs*), što znači da je ulaz u neuron pomnožen težinskim faktorom specifičnim za taj ulaz (slika 14). Neuron uzme skup ulaza ($x_1, x_2 \dots x_n$) i svaki ulaz je zatim pomnožen sa određenim težinskim faktorom ($w_{1j}, w_{2j} \dots w_{nj}$). Svi težinski unosi su zatim zbrojeni zajedno u prijenosnu funkciju koja zatim prolazi kroz aktivacijsku funkciju koja je najčešće sigmoid funkcija (aktivacijska funkcija može varirati s obzirom na to koja ANN se koristi) te ona određuje izlaz iz tog neurona. Granica označava određeni *Bias* koji je zapravo nagib funkcije i određuje do koje vrijednosti se neuron aktivira [16]. Način rada vidi se na slici 14.



Slika 14. Model neurona u ANN [16]

Funkcija sloja neurona može se napisati na sljedeći način [17]:

$$f_l(x) = g_l(W_l \cdot z + b_l) \quad (1)$$

gdje su:

g – aktivacijska funkcija koju određuje programer

W_l – matrica težinskih faktora l-tog sloja

z – vektor ulaza u sloj

b_l – vektor granica (*Bias*) l-tog sloja

Funkcija neuronske mreže koja sadrži 2 skrivena sloja sa slike 13. zatim glasi [17]:

$$f_{NN}(x) = f_2(f_1(x)) \quad (2)$$


Učenje neuronske mreže ostvaruje se uz treniranje i testiranje mreže. Kod seta podataka 80% njih se uzima za trening te se pomoću njih namještaju težinski faktori koji utječu na aktivaciju pojedinih neurona dok se ostalih 20 % koristi za ispitivanje točnosti neuronske mreže. Isprva se težinski faktori određuju slučajno te se treningom postepeno namještavaju njihove vrijednosti. Prvi rezultat je totalno slučajan tako da korisnik ispravlja mrežu na način da unese točan odgovor. Usporedbom dobivenog i pravog rješenja dobiva se funkcija gubitka. Funkcija gubitka računa koliko je mreža pogriješila za određeni slučaj, što je manja vrijednost to je rezultat točniji i obrnuto. Ukupna točnost mreže računa se tako da se uzme srednja vrijednost funkcije gubitka od svih rezultata dobivenih na vježbanju mreže. Konvergencija ka točnom rezultatu dobiva se minimiziranjem funkcije gubitaka. Iako zvuči jednostavno treba uzeti u

obzir da neuronska mreža može imati i do desetke tisuća ulaznih podataka što predstavlja traženje minimuma funkcije sa 10000 varijabli. Postupak traženja minimuma funkcije gubitka zove se postupno opadanje (eng. *gradient descent*) [18].

4.3.2. Usporedba konvencionalnih metoda i metoda dubokog učenja

Konvencionalne metode predviđanja kvarova obično se sastoje od ručnog odabira promatranih značajki, izvačenja tih značajki iz podataka i trening modela strojnog učenja. Odabran set promatranih značajki daju se plitkom modelu strojnog učenja koji su već navedeni ranije (SVM, Bayesian metode učenja...). Izvedba strojnog učenja ovisi o odabranim značajkama, no teško je odrediti koje značajke bi bilo dobro odabrati. Ručan odabir značajki zahtjeva veliki utrošak rada od strane čovjeka. U ovom problemu mogu pomoći stabla odluke (eng. *Decision Tree*) i slučajne šume (eng. *Random Forest*) koji mogu identificirati najznačajnije senzore no njih karakterizira slaba preciznost [19].

Cilj metode dubokog učenja je izvlačenje hijerarhijskih reprezentacija od ulaznih podataka u pomoć duboke neuronske mreže sa više slojeva te one ne zahtijevaju veliki utrošak rada od strane čovjeka. Većina modela „plitkog“ učenja može izvući samo neke vrijednosti iz signala te uzrokuje smanjenje dimenzionalnosti iz izvornog signala. Korištenjem neuronskih mreža izbjegava se ispuštanje bilo kakve informacije o kvaru, a sve to rezultira boljom izvedbom dijagnoze kvarova [19]. Na slici 15. prikazana je usporedba konvencionalnih metoda i metoda dubokog učenja.




Slika 15. Usporedba konvencionalnog modela predviđanja kvarova i modela dubokog učenja [19]

U tablici su navedene karakteristike obje metode.

Tablica 1. Usporedba konvencionalnih metoda i metoda dubokog učenja [19]

Konvencionalne metode predviđanja kvara	Metode temeljene na dubokom učenju
Potrebno je ekspertno znanje i intenzivan ljudski rad da bi se odabrale prave značajke. Individualni moduli su trenirani korak po korak. Nemogućnost modeliranja velike količine podataka.	Struktura bez ručnog odabira značajki. Svi parametri se treniraju zajedno. Prikladno za veliku količinu podataka.

Glavna prednost metode temeljene na dubokom učenju je povećana točnost u odnosu na konvencionalne metode i mogućnost primjene na velike količine podataka. Provedeno je istraživanje vibracijske analize na ležajevima stroja. Rezultati su pokazali da metoda sa konvalucijskim dubokim učenjem daje preciznost od 93.61 % u usporedbi sa konvencionalnom metodom koja je koristila slučajne šume za predviđanja koja je ostvarila preciznost od 87.25% (slika 16.) [20].


**Slika 16. Analiza kvara ležaja konvencionalnom metodom i metodom dubokog učenja [20]**

Na slici se vidi da se kod konvencionalne metode uzela i vremenska i frekvencijska domena te se prvo trebalo odabrati koje značajke će se gledati te se zatim išlo u klasifikaciju da bi se našao najznačajniji pokazatelj kvara dok se kod metode dubokog učenja pomoću konvalucijske neuronske mreže automatski analizirao signal u frekvencijskoj domeni. Došlo se do zaključka da je rezultat za 6.36% bolji kod metode dubokog učenja [20].

4.4. Potpora donošenju odluka


Donošenje odluka je teško. Općenito odluke se donose nadmetanjem ciljeva, svaku odluku karakterizira nesigurnost i subjektivna perspektiva osobe koja donosi odluku. Ako se odluke donose skupno može doći do nesuglasica što se želi postići, a u tome može igrati i politika tako da je donošenje odluka kompleksna aktivnost. Kod donošenja odluke treba se jasno definirati koji se ciljevi žele postići, koje su alternative i nesigurnosti kod tih ishoda te naravno koje su posljedice odluke koja se donosi [21].

Proces donošenja odluka kreće od definiranja ciljeva (ono što se želi postići), zatim se odrede alternative toj odluci nakon čega se problem koji se treba savladati razloži i modelira (treba uključiti strukturu, nesigurnost i preference) nakon čega se bira najbolja alternativa. U proces donošenja bitno je uključiti i analizu osjetljivosti tj. treba pogledati koje su posljedice ako se donese neka druga odluka u usporedni sa odabranom. Ako nije potrebna daljnja analiza donosi se preporuka, a ako je potrebna potrebno je vratiti se na neku od prethodnih koraka [21]. Proces donošenja odluka može se vidjeti na slici 17.



Slika 17. Proces donošenja odluke [21]

Glavni cilj ovog koraka je u sustavnoj prioritizaciji i preskripciji aktivnosti održavanja. Definiranjem tvrtkinih specifičnih operacijskih (npr. vrijeme izvan rada, troškovi održavanja...) i menadžerskih (npr. stupanj rizika, profitne ciljeve, strateški prioriteti) parametara odluke dobiva se dinamičan skup pravila koja utječu na odluku te se ta pravila integriraju u višekriterijalni model odluke. Model odluke automatski prioritizira predviđene kvarove iz prethodnog koraka. Uzimajući u obzir trenutni plan održavanja, dostupnost rezervnih dijelova i ostalih resursa može se predložiti određena aktivnost održavanja kako bi se izbjega kvar i neželjeni utjecaji koji su posljedica tog kvara. Slika 18. prikazuje faktori koji se uzimaju u obzir kod odlučivanja [8].



Slika 18. Faktori koji se uzimaju u obzir kod odlučivanja [22]

Svi navedeni faktori dobivaju se iz podataka tvrtke. Faktori odlučivanja dobivaju se iz podataka o proizvodnji (statički podaci o konfiguraciji postrojenja i upravljanju imovinom), a tržišni model se dobiva iz podataka o tržištu (potražnja, predviđanje troškova energije). Kod modela kvara, modela troškova i proizvodnog modela koristi se strojno učenje koje koristi kombinaciju podataka kao što su povijesni podaci održavanja, podaci o proizvodnji i podacima o postrojenju [22].

Primjer prijedloga odluke: Promatra se pumpa tijekom rada i analitički software uoči malu promjenu u radu pumpe. Software predlaže opciju popravka dijela pumpe koji loše utječe na rad sa sigurnošću uspješnog obavljenog zahvata od 80% ili zamjenu komponenti pumpe sa sigurnošću od 95%. Sada je na osoblju održavanja da odredi koju opciju će primijeniti s obzirom na troškove dijelova pumpe, dostupnost dijelova i osoblja te ostala ograničenja [7].

4.5. Planiranje održavanja – optimiranje

Peti korak u procesu preskriptivnog održavanja usredotočen je na stvaranje konkretnih radnih naloga u sklopu kompanijinog CMMS sustava. Stručnjaci održavanja sami prihvaćaju ili odbacuju aktivnosti koje su preporučene u prethodnom koraku. Inženjeri održavanja svojim znanjem i iskustvom donose odluku o tome šta će se poduzeti kako bi se riješio problem. Spajanjem već postojeg rasporeda pregleda i propisane aktivnosti održavanja može se postići dodatna učinkovitost na operacijskoj i menadžerskoj razini unutar svih funkcionalnih područja (održavanje, planiranje proizvodnje, kontola kvalitete). [8].


Optimizacijom se postiže:

- stvaranja optimalnog plana aktivnosti održavanja
- definiranje optimalnog plana proizvodnje
- definiranje smjena stručnjaka održavanja
- definiranje radnih uvjeta s kojima se smanjuje mogućnost pojave kvara

U ovom koraku veliku ulogu imaju operacijska istraživanja.

4.5.1. Operacijska istraživanja

Operacijska istraživanja je stručno-znanstvena disciplina koja omogućuje donošenje odluka korištenjem razvijenih egzaktnih matematičkih modela i metoda. Spadaju u polje primjenjene matematike i bave se matematičkim modeliranjem radnih procesa u svrhu donošenja optimalnih odluka. Primjena operacijskih istraživanja nalazi se u upravljanju proizvodnjom i održavanjem, upravljanjem lancem opskrbe, projektiranju i razvoju proizvoda i kod mnogih drugih aktivnosti [23]. Odluke koje se optimiziraju mogu biti statičke ili dinamičke. Statičke odluke ne uzimaju u obzir vrijeme dok kod dinamičkih se donosi nekoliko odluka kroz vrijeme. Svaka od njih ima nekoliko modela s kojima se optimizira odluka i svaki od njih se primjenjuje za određeni slučaj [24]. Slika 19. prikazuje podjelu modela operacijskih istraživanja.



Slika 19. Podjela metoda operacijskih istraživanja [24]

Optimizacija odluka kod preskriptivnog održavanja rješavaju se prikladnim modelom čijim se rješavanjem postižu optimalni planovi održavanja nakon čega slijedi izvršavanje te radnje, dokumentiranje i analiza. Faze rješavanja problema optimiranja [23]:


1. Izbor i definiranje problema – izbor i (pravilno) definiranje problema
2. Prikupljanje i analiza podataka – prikupljanje i analiza podataka s ciljem utvrđivanja svih utjecajnih faktora i ograničenja
3. Izrada matematičkog modela – stvaranje modela i postavljanje hipoteze u obliku matematičkog modela
4. Rješavanje problema – pomoću programskih paketa
5. Postoptimalna analiza i prijedlog rješenja
6. Implementacija rješenja – realizacija predloženog rješenja, praćenje efekata te usporedba sa očekivanjima
7. Korekcija i dopuna – mogu se odnositi na definiciju problema, model...

4.6. Implementacija i analiza

U zadnjem koraku osim pravovremene implementacije aktivnosti održavanja uz koje se generira dokumentacija važno je i analizirati koliko je uspješna bila implementacija i preporuka koju je program generirao da bi se ti podaci mogli koristiti u budućnosti kao jedan od parametara koji ulazi u strojno učenje. Stručnjaci održavanja također detaljno specificiraju i konkretiziraju vrstu kvara i razinu težine njegovog otklanjanja u obliku povratne veze sustavu. Te informacije koriste se za poluautomatsku dopunu metoda strojnog učenja i modela odluke [8]. Kod analize uspješnosti implementacije koristi se analitički pristup za analizu svakog koraka preskriptivnog održavanja, gledaju se relevantni pokazatelji uspješnosti:

- Dimenzija održavanja – održivost, pouzdanost, dostupnost dijelova, raspoloživost stroja, vrijeme izvan rada stroja, trošak i utrošak ljudske radne snage
- Dimenzija analitike podataka – mjera kvalitete podataka (struktura, istinitost), preciznost predviđanja kvarova, nesigurnost i pouzdanost predikcija

PriMa-X model analize zrelosti preskriptivnog održavanja navodi da se kvantificiranjem navedenih pokazatelja uspješnosti procjenjuje stupanj zrelosti preskriptivnog održavanja te se identificiraju slabosti. Na temelju uviđenih slabosti i procjene uspješnosti gradi se temelj za poboljšanja kod budućih postupaka održavanja (slika 20.) [8].



Slika 20. PriMa-X model analize zrelosti preskriptivnog održavanja [8]

5. PRIMJERI IMPLEMENTACIJE PRESKRIPTIVNOG ODRŽAVANJA

Nekoliko istraživanja pokazalo je važnost prediktivnog i preskriptivnog održavanja kako bi se prešlo preko prepreka koje postavlja digitalizacija i Industrija 4.0, no unatoč tome implementacija tih strategija je slaba. Nedavna istraživanja pokazala su da 15% proizvodnih kompanija koristi djelomično prediktivne strategije održavanja dok preskriptivne strategije održavanja koristi tek 4% [28]. Taj podatak pokazuje da je preskriptivno održavanje još u začetnoj fazi i da kompanije koje imaju druge „staromodnije“ strategije održavanja treba potaknuti da implementiraju novija i bolja rješenja [8]. Čak i kompanije koje koriste prediktivne strategije održavanja imaju problema s prelaženjem na preskriptivno održavanje zbog ograničenja koja mogu biti [7]:

- Cijena – dok je cijena senzora, pohrane podataka i analitičkih programa pala, još je prisutna visoka cijena hardware-a i software-a. Također javljaju se troškovi učenja kod implementacije preskriptivnog održavanja kod organizacija koje koriste tradicionalne strategije održavanja.
- Regulacije i propisi – određene regulacije i propisi mogu ograničiti primjenu novijih strategija održavanja (npr. zamjena neke opreme nakon točno određenog vremena ili drugog radnog pokazatelja)
- Kultura – ovisno o stupnju povjerenja u tehnologiju u organizaciji ili navikama na trenutne strategije održavanja koje se pokazuju dobrim, može doći do otpora prema implementaciji strategije preskriptivnog održavanja koja ipak iziskuje određena financijska sredstva.

Preskriptivno održavanje može jako doprinjeti uspjehu kompanije ako se primjeni na pravi način, no kako je ono tek u začetku rezultati će se vidjeti u godinama koje dolaze. U nastavku će se pokazati primjer uspješne implementacije strategije preskriptivnog održavanja u talijanskoj elektroenergetskoj tvrtki Saras uz pomoć Aspen Mtell programskog paketa te će se zatim prikazati primjer IBM Maximo održavanja na oblaku.

5.1. Saras - Aspen Mtell

Saras je talijanska elektroenergetska tvrtka i vlasnik najkompleksnije rafinerije na mediteranu sa kapacitetom 300 000 barela po danu i termoelektrane kapaciteta 575 MW. Kao dio programa digitalizacije, proučavali su na koje bi načine povećali pouzdanost u imovinu i opremu koja se intenzivno koristi u procesu rafinerije. Odabrali su Aspen Mtell kompetitivni projekt koji se primarno fokusira na kritičnu opremu u rafineriji poput velikih kompresora i pumpi. Aspen Mtell rudari povijesne i trenutne radne podatke kao i podatke o održavanju da bi se otkrili precizni pokazatelji kvarova koji ukazuju na degradaciju opreme te se predviđa nastanak kvara uz propisivanje detaljne radnje u svrhu rješavanja ili odgode kvara. Aspen Mtell je uspio realizirati projekt u roku nekoliko tjedana, impresionirajući svojom brzinom, preciznošću, izbjegavanjem lažnih uzbuna i primjenom na različite sustave. Saras planira upotrijebiti srodnu kompaniju Sartec za implementaciju Aspen Mtell kroz cijelo postrojenje.

Inicijalni projekt se fokusirao na četiri stroja:

- Pumpa za vodu – pumpa vodu iz drugih dijelova postrojenja do generatora pare.
- Pumpa za ulje – pumpa ulje koje dolazi iz separatora.
- H₂ kompresor – tlači vodik koji dolazi iz zaliha vodika prema generatoru pare.
- Reciklirni kompresor – reciklira vodik koji dolazi iz generatora pare.

Podaci koje je Aspen Mtell koristio sastojali su se od 52 milijuna podataka koji su dolazili sa senzora, uključujući podatke o stanju i proizvodnji. Povijest održavanja za ta 4 stroja sastojala su se od 340 radnih naloga uz 17 klasificiranih problema koji su se pojavili. Za reciklirni kompresor postignuta je preciznost predviđanja u vremenu od 30 dana prije nastanka kvara uz pouzdanost 91%. Predviđene su i sljedeće radnje:

- Uočen rast temperature ventila – 36 dana prije nastanka kvara
- Zamjena uljne brtve – 45 dana prije nastanka kvara
- Zamjena brtve na pumpi – 33 dana prije nastanka kvara
- Zamjena brtve za plin – 24 dana prije nastanka kvara

Postignuto je točno predviđanje kvarova i radnji za izbjegavanje istih bez lažnih uzbuna. Rezultati provedenog preskriptivnog održavanja su smanjeno vrijeme neplaniranog zastoja za 10 dana, povećana dobit od 1-3 %, smanjeni troškovi održavanja u iznosu od 1-5% [25].

5.1.1 Princip rada Aspen Mtell


Aspen Mtell sustav može biti inkonponiran sa gotovo svim uređajima i sustavima koji se mogu naći u proizvodnji kao što su programibilni logički kontroleri, distribuirani kontrolni sustavi, razni instrumenti, informatički sustavi, CMMS sustav, EAM sustav i ostali. Radi na način da skuplja podatke o uređajima koji su prisutni u informatičkom sustavu da bi se izgradila hijerarhija za nadziranje i mapirali senzori koji pripadaju opremi i strojevima. Jednom kada se to uspostavi, sustav analizira radne naloge iz prošlosti kako bi se informacije sadržane u njima koristile pri razvoju znakova kvarova. Software automatski motri i traži pojavu tih uzoraka te štiti od pojave sličnih kvarova uz pomoć detekcije novih anomalija koje su onda kategoriziraju kao novi uzrok kvara. Aspen Mtell koristi strojno učenje i prilagođava se novim operativnim uvjetima, što mu omogućuje lako otkrivanje novih kvarova. Sustav izdaje upozorenje korisnicima te šalje CMMS sustavu radne naloge za otklanjanje kvarova sa točnim kodom kvara uz IoT tehnologije i M2M komunikacije. U tom procesu preskriptivnog održavanja sustav propisuje prigodnu aktivnost održavanja ovisno o ponašanju stroja. Odjel proizvodnje i održavanja jako rano dobije upozorenje o potencijalnom nastanku kvara i mogu odlučiti hoće li ukloniti kvar na najekonomičniji način ili će prilagoditi proizvodnju da odgode nastanak kvara [26].

5.2. IBM preskriptivno održavanje na oblaku

IBM preskriptivno održavanje na oblaku je dizajnirano da zadovolji potrebe inženjera pouzdanosti kojima je cilj pronaći rizike koje mogu utjecati na poslovne i proizvodne operacije. U usporedbi sa strategijom održavanja po stanju, prediktivne analitičke sposobnosti mogu pomoći u identificiranju kvarova opreme u ranoj fazi tako da se onda proaktivno mogu ukloniti uzroci tih kvarova. Koristeći strojno učenje da bi se analizirali radni uvjeti stroja dobiva se uvid u faktore koji utječu na uzrok kvarova kao i uvid u stanje održavanja stroja tj. je li on dobro, loše ili previše održavan. Glavni cilj IBM preskriptivnog održavanja na oblaku je pomoći inženjerima optimizirati raspored i resurse održavanja. U ovom primjeru gledat će se analiza 21 dizel generatora koji rade u dvije različite elektrane. Proučavat će se vremenski razmak od 14 dana [27].

Sve počinje unosom datoteka koje sadrže podatke koji će se analizirati. Datoteka sa entitetima opisuje detalje o opremi (oznaka, proizvođač, lokacija...) i ostale relevantne podatke o opremi. Datoteka s događajima sadrži informacije o događajima koji su se odvijali na opremi (kvarovi, održavanje, zamjena dijelova, pregledi, prosječna temperatura okoline, napon, vrijeme


u radu, start/stop ciklusi, razina ulja, razina goriva...). Obje datoteke su formata .csv (eng. *comma separated values*) kao što se može vidjeti na slici 21. [27].



Slika 21. Unos datoteka i izgled datoteke događaja [27]

Kada se završi unos obje datoteke počinje automatska analiza podataka. IBM koristi *gradient boosting* algoritam strojnog učenja za vršenje analize. Po završetku analize dobije se ispis brojeva opreme koja se analizirala kao i datum i vrijeme. U slučaju neuspjele analize korisnik dobiva obavijest o neuspjehu za određenu opremu [27].

Rezultati analize sortirani su po marginama – razlici između predviđenog datuma održavanja i datuma sljedeće planirane aktivnosti održavanja. Negativna margina (crvene boje) ukazuje da je stroj loše održavan, a pozitivne margine (bijela i žuta) ukazuju na to da je stroj dobro ili previše održavan. Ako nema margine to znači da nedostaje podataka da bi se pravilno analizirao stroj. Na slici 22. i 23. prikazano je objašnjenje oznaka kod rezultata analize.




Slika 22. Rezultati analize [27]




Slika 23. Detaljni prikaz rezultata analize [27]

Pomoću tih rezultata može se odmah vidjeti koji su strojevi previše održavani, a koji premalo te se na temelju toga mogu alocirati resursi održavanja tamo gdje je više potrebnije. Klikom na „*Under maintained*“ (slika 26.) karticu dobiva se uvid u sve strojeve koji su loše održavani, a „*Well maintained*“ i „*Over maintained*“ kartica ukazuju koji su strojevi dobro i previše održavani. Cilj je postići da su svi strojevi u području „*Well maintained*“. U postrojenju može biti nekoliko različitih vrsta strojeva na različitim lokacijama, filterima se postiže sortiranje onih strojeva kao i glavnih značajki koje utječu na kvar [27]. Moguće je i svaki generator gledati zasebno. Prikaz korisničkog sučelja za pojedini generator vidi se na slici 24.



Slika 24. Prikaz pojedinog generatora sa karticom o detaljima [27]


Kartica o detaljima (*Details*) prikazuje informacije o stroju kao što su lokacija, proizvođač i predviđanje datuma kvara (slika 24.). Kartica o glavnim značajkama i faktorima rizika (*Drivers and Risk Factors*) rangira glavne značajke koji negativno utječu na specifičan generator dok su vidljive i značajke koje pozitivno utječu na generator (ne predstavljaju problem) (slika 25.). Kartica dnevnika održavanja (*Maintenance Log*) bilježi kvarove, održavanje, inspekciju i zamjenu dijelova za svaki datum i označava ih sa *true* ako se aktivnost dogodila i *false* ako se aktivnost nije dogodila (slika 26.). Istraži (*Explore*) kartica prikazuje kronološki prikaz histograma usporedbe dvije glavne značajke kao i kvarove, održavanje i zamjenu dijelova da bi se procijenili efekti značajki i održavanja na kvarove stroja. Mogu se mijenjati glavne značajke kao i vremenski okvir usporedbe (slika 27.) [27].



Slika 25. Kartica sa značajkama i faktorima rizika [27]

Timestamp	failure	maintenance	replace_part	inspection
2017-03-18	false	false	false	false
2017-03-19	false	true	false	false
2017-03-20	false	false	true	false
2017-03-21	false	false	false	false
2017-03-22	false	false	false	false
2017-03-23	false	false	false	false
2017-03-24	false	false	false	false
2017-03-25	false	false	false	false
2017-03-26	true	false	false	false
2017-03-27	false	true	false	false

Slika 26. Kartica sa dnevnikom održavanja [27]



Slika 27. Kartica sa histogramima [27]

Gartner opisuje računalstvo u oblacima kao oblik računalstva u kojem se dinamički, skalabilni resursi pružaju kao usluga putem interneta [1]. Tako je i IBM preskriptivno održavanje na oblaku dio tog interneta usluga uz pomoću kojeg se izbjegava potreba za kupnjom i instalacijom infrastrukture (računala, opreme, serverskih prostora...). Kako kompanije prisvajaju računalstvo u oblacima i pametnu tvornicu javlja se potreba za integracijom različitih usluga i sustava, tako da je u sklopu IBM-ovog preskriptivnog održavanja mogućnost integracija sa IoT uređajima i IBM Watson IoT platformom. Integracija se vrši putem jednostavnih izbornika klikom na IoT karticu te se unosi ID organizacije, API ključ i token identifikacije. Nakon toga biraju se uređaji te se određuje interval analize i izbor se na kraju potvrđuje [27].

6. ZAKLJUČAK

Preskriptivno održavanje nova je strategija i nadogradnja je na postojeće strategije održavanja. Razvojem tehnologije i pojavom Industrije 4.0 javila se potreba za fleksibilnim, pouzdanim, ekonomičnim i automatiziranim sustavima u svim područjima pa i u području održavanja. Preskriptivno održavanje odgovor je na te potrebe jer smanjuje udio ljudskog rada u prikupljanju i analiziranju podataka. Svakim danom generira se sve više podataka koje karakterizira velika veličina, velika brzina nastajanja i velika raznoliost. Takvi podaci, generirani u realnom vremenu, uz povijesne podatke koji su dostupni od prije, omogućuju predikciju kvarova sa impresivnom pouzdanošću. Za predviđanje kvarova koriste se moderne metode strojnog učenja kao što su duboko učenje koje poboljšava točnost otkrivanja kvarova i koje napreduju sve više i više. Problem preskriptivnog održavanja je u tome što je to relativno nov koncept koji još nije doživio masovnu primjenu u industriji, primarno zbog troškova implementacija i nesigurnosti u tu investiciju, a ulogu u tome ima i nesvjesnost potrebe pravilnog održavanja opreme. Kao što je navedeno u primjeru implementacije kod elektroenergetske tvrtke Saras, postignuta je relativno brza implementacija uz predviđanje kvarova 30 dana prije njihovih nastanaka s pouzdanošću od 91%. Troškovi održavanja smanjeni su za 1-5% dok je profit povećan za 1-3%. Trenutačna uporaba preskriptivnog održavanja je samo oko 4% što pokazuje da je preskriptivno održavanje još u fazi istraživanja te da postoji mnogo mjesta za napredak. Sigurno je da će se u budućnosti posvetiti više pažnje ovoj tematici te daljnjem razvoju preskriptivnog održavanja.

LITERATURA

- [1] Lisjak D.: Održavanje, nastavni materijal, FSB, 2018.
- [2] http://www.assetinsights.net/Glossary/G_Unintended_Failure_Replacement.html
(datum pristupa: 27.12.2018.)
- [3] Mobley, K. :Maintenance Engineering Handbook, McGraw-Hill, Boston, Massachusetts 2012.
- [4] <https://conference.reliableplant.com/root-cause-failure-analysis/>
(datum pristupa: 29.12.2018.)
- [5] <http://analytics-magazine.org/the-analytics-journey/>
(datum pristupa: 30.12.2018.)
- [6] Huang E.: Model-Based Systems Engineering in Prescriptive Analytics, SEDC, 2014.
- [7] <https://hpreliability.com/what-is-prescriptive-maintenance/>
(datum pristupa: 26.12.2019.)
- [8] Nemeth T, Ansari F, Sihn W, Haslhofer B, Schindler A: PriMa-X: A reference model for realizing prescriptive maintenance and assessing its maturity enhanced by machine learning, Procedia CIRP, Volume 72, 2018, stranice 1039-1044. Dostupno na: <https://www.sciencedirect.com/science/article/pii/S2212827118304566>
- [9] <https://searchbusinessanalytics.techtarget.com/definition/big-data-analytics>
(datum pristupa: 31.1.2018.)
- [10] <https://searchbusinessanalytics.techtarget.com/definition/unstructured-data>
(datum pristupa: 31.1.2018.)
- [11] Kolar D.: Uvod u baze podataka i MS Access, nastavni materijal, FSB, 2016.
- [12] Ghazi M.R., Gangodkar D,: Hadoop, MapReduce and HDFS: A Developers Perspective, Procedia Computer Science, Volume 48, 2015, stranice 45-50. Dostupno na: <https://www.sciencedirect.com/science/article/pii/S1877050915006171>
- [13] <https://www.embitel.com/blog/embedded-blog/7-most-commonly-used-sensors-for-developing-industrial-iot-solutions>
(datum pristupa: 03.02.2018.)
- [14] <https://blog.statsbot.co/time-series-anomaly-detection-algorithms-1cef5519aef2>
(datum pristupa: 28.01.2018.)
- [15] <https://www.mathworks.com/discovery/deep-learning.html>
(datum pristupa: 29.01.2018.)

[16] <https://medium.com/@ivanliljeqvist/the-essence-of-artificial-neural-networks-5de300c995d6>

(datum pristupa: 28.01.2018.)

[17] Burkov A.: The Hundred-Page Machine Learning Book, Amazon, 2019.

[18] Nielsen M.: Neural Networks and Deep Learning, Determination Press, 2015.

[19] Zhao R., Yan R., Chen Z., Mao K., Wang P., Gao R.X.: Deep learning and its applications to machine health monitoring, Mechanical Systems and Signal Processing, Volume 115, stranice 213-237, 2019.

Dostupno na: <https://www.sciencedirect.com/science/article/pii/S0888327018303108>

[20] Janssens O., Slavkovikj V., Vervisch B., Stockman K., Loccufier M., Verstockt S., Van de Walle R., Van Hoecke S.: Convolutional Neural Network Based Fault Detection for Rotating Machinery, Journal of Sound and Vibration, Volume 377, stranice 331-345, 2016.

Dostupno na: <https://www.sciencedirect.com/science/article/pii/S0022460X16301638>

[21] Laskey K.B.: Decision Modeling in Prescriptive Analytics, SEDC, 2014.

[22] <https://minditsolutions.it/en/index.html#services>

(datum pristupa: 05.02.2018.)

[23] Šakić, N., Štefanić, N.: Metode Optimiranja, Inženjerski priručnik IV, Školska knjiga, Zagreb, 2002.

[24] Ganesan R.: Optimization in Prescriptive Analytics, SEDC, 2014.

[25] <https://www.aspentech.com/en/resources/case-studies/prescriptive-maintenance-software-helps-saras-improve-business-performance>

(datum pristupa: 08.02.2018.)

[26] <https://www.aspentech.com/en/resources/brochure/aspen-mtcell-brochure>

(datum pristupa: 08.02.2018.)

[27] <https://www.ibm.com/us-en/marketplace/predictive-maintenance-insights>

Video: https://www.youtube.com/watch?v=C0Cx Ej_8yFY

(datum pristupa: 09.02.2018.)

[28] Institute of Technology Management. Industry Study 2016 Manufacturing Data Analytics, University of St. Gallen, 2016.

Dostupno na: http://tectem.ch/content/2-news/20170401-item-study-manufacturing-data-analytics-2017/item-hsg_manufacturing-data-analytics_general-report.pdf

[29] <https://www.sv-europe.com/blog/10-reasons-organisation-ready-prescriptive-analytics/>

(datum pristupa: 30.12.2018.)

[30] <https://www.slideshare.net/MichaelBeatty/ibm-cloud-storage-cleversafe>

(datum pristupa: 31.01.2019.)

[31] https://upload.wikimedia.org/wikipedia/en/2/2b/Hadoop_1.png

(datum pristupa: 01.02.2019.)

PRILOZI

I. CD-R disc