

# **UTJECAJ 4.0 INDUSTRIJE NA ODRŽAVANJE STROJEVA I SUSTAVA**

---

**Marinović, Luka**

**Master's thesis / Specijalistički diplomski stručni**

**2023**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **Karlovac University of Applied Sciences / Veleučilište u Karlovcu**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/um:nbn:hr:128:141533>

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

*Download date / Datum preuzimanja:* **2024-05-19**



**VELEUČILIŠTE U KARLOVCU**  
Karlovac University of Applied Sciences

*Repository / Repozitorij:*

[Repository of Karlovac University of Applied Sciences - Institutional Repository](#)





VELEUČILIŠTE U KARLOVCU

STROJARSKI ODJEL

SPECIJALISTIČKI DIPLOMSKI STRUČNI STUDIJ STROJARSTVA

LUKA MARINOVIC

**UTJECAJ 4.0 INDUSTRIJE NA ODRŽAVANJE STROJEVA I  
SUSTAVA**

**THE INFLUENCE OF INDUSTRY 4.0 ON THE MAINTENANCE  
OF MACHINES AND SYSTEMS**

DIPLOMSKI RAD

Karlovac, 2023





VELEUČILIŠTE U KARLOVCU

STROJARSKI ODJEL

SPECIJALISTIČKI DIPLOMSKI STRUČNI STUDIJ STROJARSTVA

LUKA MARINOVIC

**UTJECAJ 4.0 INDUSTRIJE NA ODRŽAVANJE STROJAVA I**

**SUSTAVA**

**THE INFLUENCE OF INDUSTRY 4.0 ON THE MAINTENANCE  
OF MACHINES AND SYSTEMS**

DIPLOMSKI RAD

Mentor: Tomislav Božić, dipl. ing.

Karlovac, 2023

# Sadržaj

Izjava .....	1
Popis slika.....	2
Sažetak .....	4
Summary .....	4
1.    Uvod .....	5
2.    Industrija 4.0 .....	6
3.    Sigurnosni izazovi u kontekstu industrije 4.0 .....	8
4.    Ljudski aspekti u kontekstu industrije 4.0 .....	10
5.    Evolucija industrijskog održavanja.....	11
6.    Prediktivno održavanje .....	12
6.1.    Alati i materijali za prediktivno održavanje .....	13
6.1.1.    Cyber-fizički sustavi.....	13
6.1.2.    Industrial Internet of Things (IIoT) .....	14
6.1.3.    Big Data .....	14
6.1.4.    Digital Twin.....	15
6.1.5.    Augmented reality.....	15
6.1.6.    Artificial intelligence (AI) .....	16
6.1.7.    Machine Learning (ML) and Deep Learning (DL).....	16
7.    Izazovi prediktivnog održavanja.....	18
7.1.    Finansijska i organizacijska ograničenja .....	18
7.2.    Ograničenja izvora podataka .....	19
7.3.    Ograničenja aktivnosti popravka strojeva .....	19
8.    Remont horizontalne glodalice DIXI 300 (Eksperimentalni dio).....	21
8.1.    Općenito o stroju .....	21

8.2.	Zamjena dijelova i čišćenje .....	22
8.3.	Geometrija stroja.....	37
8.4.	Testiranje .....	46
8.5.	Završna kontrola.....	48
9.	Zaključak.....	49
10.	Literatura.....	50

## Izjava

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena u dosadašnjem dijelu studija te koristeći navedenu literaturu.

Zahvaljujem se mentoru Tomislav Božić dipl. ing. na savjetima, konzultacijama i pomoći pri izradi ovog završnog rada, također veliko hvala kolegama iz tvrtke HSTEC na savjetima i korisnim informacijama. Hvala profesorima, kolegama i svima koji su mi pomogli za vrijeme studiranja.

## **Popis slika**

Slika 1. Komponente tehnologije Industrije 4.0 u kontekstu inteligentne proizvodnje[4] .....	6
Slika 2. Razvoj Industrija kroz povijest[5] .....	7
Slika 3. Primjer phishing napada[7] .....	9
Slika 4. Evolucija aktivnosti i metoda održavanja[10].....	11
Slika 5. Dijagram potencijalnog kvara koji prikazuje intervale pregleda i prediktivno održavanje[5] .....	12
Slika 6. CPS arhiktetura[12].....	13
Slika 7. 3V model proširen na 5V Big Data[12] .....	14
Slika 8. Primjer Digital Twin-a[12].....	15
Slika 8. Klasifikacija tehnika vođenih podacima i kategorija strojnog učenja[12] .....	17
Slika 9. DIXI 300 -75[Autor].....	21
Slika 10. Trapezni vijak sa zazubljenom glavom[Autor].....	22
Slika 11. Podizanje stola stroja[Autor] .....	23
Slika 12. Mjerna skala stroja za određivanje kuta stola[Autor] .....	23
Slika 13. Poklopac kućišta motora stola[Autor] .....	24
Slika 14. Ručica za fino pozicioniranje[Autor].....	24
Slika 15. 3D model poklopca[Autor] .....	25
Slika 16. Novi poklopac stola[Autor].....	25
Slika 17. Novi poklopac montiran na stol[Autor].....	25
Slika 18. Tuširana klizna staza[Autor] .....	26
Slika 19. Novi zaštitni limovi za klizne staze[Autor] .....	27
Slika 20. Elektromotor i nova remenica[Autor] .....	27
Slika 22. Novi kuglični ležaj vretena[Autor] .....	28
Slika 23. Potreban poklopac instalacija[Autor] .....	29
Slika 24. 3D model poklopca instalacija[Autor] .....	29
Slika 25. Hidraulički cilindar[Autor] .....	30
Slika 26. Unutrašnji dio optike s puknutim zrcalom[Autor].....	30
Slika 27. Optika za pozicioniranje (x-os) [Autor].....	31
Slika 28. Izgled kućišta hladnjaka prije ugradnje novog sustava[Autor] .....	31
Slika 29. Dodatna unutarnja jedinica za hlađenje ulja[Autor] .....	32

Slika 30. Novi termo par(desno) za mjerjenje temperature okoline[Autor] .....	32
Slika 31. Regulator temperature ulja[Autor] .....	33
Slika 32. Izgled kućišta hladnjaka nakon ugradnje novog sustava[Autor] .....	33
Slika 33. Nekorišteni dijelovi starog sustava hlađenja[Autor] .....	34
Slika 34. Kolture za prijenos lanca za protu uteg[Autor] .....	34
Slika 35. Osvježene kolture s novim ležajima[Autor] .....	35
Slika 36. Novi i stari lanac[Autor].....	35
Slika 37. Ozračivanje hidrauličkih cilindara[Autor] .....	36
Slika 38. Nosač stroja[Autor] .....	37
Slika 39. Mjerni instrument za provjeru ravnosti stroja[Autor] .....	38
Slika 40. Alat za geometriju stroja[Autor].....	38
Slika 41. Ispitivanje paralelnosti površine s kliznim stazama stola[Autor] .....	39
Slika 45. Mjerjenje paralelnosti stola s kliznim stazama[Autor].....	40
Slika 46. Mjerjenje ravnosti kliznih staza[Autor] .....	41
Slika 47. Mjerjenje pravokutnosti stola prema okomitim kliznim stazama[Autor].....	42
Slika 48. Mjerjenje ravnosti stupova[Autor] .....	43
Slika 49. Mjerjenje pravokutnosti vretena[Autor] .....	44
Slika 50. Konačni rezultati mjerjenja[Autor].....	45
Slika 51. Ravnanje čela obratka[Autor].....	46
Slika 52. Centriranje obratka[Autor].....	46
Slika 53. Priprema alata za završnu obradu na mjeru[Autor] .....	47
Slika 54. Završna obrada na mjeru[Autor] .....	47
Slika 55. Završna kontrola testnog obratka[Autor].....	48

## Sažetak

U ovom završnom radu bit će obrađena tema vezana za utjecaj 4.0 industrije na praćenje sustava održavanja kroz rad će se popratiti kako ovaj način praćenje omogućava lakše snalaženje, bržu i precizniju povijest u održavanju kvalitetniju obradu podataka. Dolaskom 4.0 industrije omogućilo nam se bolje predviđanje kvarova, a jednostavnijim pristupom podacima uočit će se problematična mjesta unutar proizvodnog pogona vezana za strojeve i opremu. Omogućit će praćenje resursa, materijala i ljudi, izvođenje i planiranje radova u sklopu održavanja.

Kroz eksperimentalni dio ovog rada bit će prikazan remont na horizontalnoj glodalici DIXI 300 u kojem će biti izneseni svi relevantni podaci o radovima na konkretnom stroju

**Ključni pojmovi:** Industrija 4.0, prediktivno održavanje, remont

## Summary

In this final paper, the topic related to the impact of Industry 4.0 on the monitoring of the maintenance system will be covered. The paper will show how this method of monitoring enables easier navigation, faster and more accurate history in maintaining quality data processing. With the arrival of Industry 4.0, we have been able to predict better breakdowns, and with simpler access to data, problem areas within the production plant related to machines and equipment will be noticed. It will enable monitoring of resources, materials and people, execution and planning of maintenance works.

Through the experimental part of this work, the overhaul of the horizontal milling machine DIXI 300 will be shown, in which we show all relevant data on the work on the specific machine.

**Key terms:** Industry 4.0, predictive maintenance, overhaul

## 1. Uvod

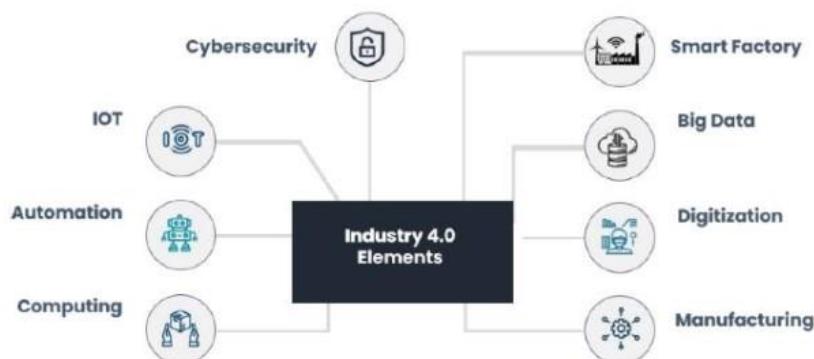
U trenutnom gospodarskom kontekstu obilježenom snažnom globalizacijom i sve zahtjevnijim tržištima, industrije su potaknute poboljšati performanse i učinkovitost svojih proizvodnih linija kako bi ojačale svoju konkurentnost i zadovoljile svoje kupce. Povezanost, podaci, novi uređaji, smanjenje zaliha, prilagodba i kontrolirana proizvodnja iznjedrili su ono što se zove Industrija 4.0, koja se danas čini nezaustavljivom. To implicira potrebu primjene tehnika automatizacije za integraciju svih novih tehnologija koje će naknadno povećati produktivnost. Tehnologije *Internet stvari* (*Internet of Things, IoT*) i *veliki podaci* (*Big Data*), te integracija metoda umjetne inteligencije (artificial intelligence, AI) i kibernetičko-fizičkih sustava (cyber-physical systems, CPS) igraju važnu ulogu u ovom kontekstu uvođenjem kognitivne automatizacije i, poslijedično, implementacijom koncepta intelligentne proizvodnje, što dovodi do intelligentnih proizvoda i usluga. Ovaj inovativni pristup navodi tvrtke da se suoče s izazovima mnogo dinamičnijeg okruženja. U tom smislu, tvrtke mogu maksimizirati životni vijek svoje opreme uz izbjegavanje neplaniranih zastoja i minimiziranje potrošnje energije i troškova kroz primjenu prediktivnog održavanja. Prediktivno održavanje postalo je pristup koji obećava, pružajući rješenja za preostali vijek trajanja opreme kroz predviđanje podataka prikupljenih različitim senzorima na opremi. Postigao je kritičnu važnost za industrije zbog sve veće složenosti interakcija između različitih proizvodnih aktivnosti u sve većim proizvodnim ekosustavima. Suvremeni pristupi održavanju razlikuju se ovisno o različitim modelima učenja koji se koriste i različitim problemima s kojima se susreću strojevi/oprema. S obzirom na cilj izgradnje intelligentnog proizvodnog sustava, detekcija, interpretacija i predviđanje kvarova koji se događaju u opremi temelje se na podacima dobivenim od senzora na opremi. Međutim, usvajanje ovih tehnoloških dostignuća ne dolazi samo. Važno je imati dobru predodžbu o prednostima i izazovima primjene održavanja 4.0 bilo da se radi o finansijskoj, organizacijskoj strani, izvoru podataka ili popravku opreme. Prediktivno održavanje doista se sastoji od rudarenja podataka za formuliranje modela strojnog učenja koji uspijevaju steći znanje i predvidjeti zdravstveno stanje opreme. U tom smislu, prediktivno održavanje nudi metode kao što su održavanje temeljeno na stanju (Condition-Based Maintenance, CBM), prognostika i zdravstveno upravljanje (Prognostics and Health Management, PHM) i preostali korisni vijek (Remaining Useful Life, RUL).[1]

## 2. Industrija 4.0

U eri četvrte industrijske revolucije, nekoliko koncepata nastalo je zajedno s ovom novom revolucijom, poput prediktivnog održavanja, koje danas ima ključnu ulogu u održivoj proizvodnji i proizvodnim sustavima uvođenjem digitalne verzije održavanja strojeva. Podaci izvučeni iz proizvodnih procesa eksponencijalno su se povećali zbog širenja senzorskih tehnologija. Čak i ako se "Maintenance 4.0" suoči s organizacijskim, finansijskim ili čak izazovima s izvorima podataka i popravkom strojeva, postaje snažna točka za tvrtke koje ga koriste. Doista, omogućuje minimiziranje vremena zastoja stroja i povezanih troškova, maksimiziranje životnog ciklusa stroja i poboljšanje kvalitete i tempa proizvodnje.[2]

Kada su računala uvedena u Industriju 3.0, dodavanje cijele nove tehnologije imalo je disruptivan učinak. Danas, a i u budućnosti u Industriji 4.0, računala i industrijska oprema povezani su i međusobno komuniciraju kako bi u konačnici donosili odluke bez ljudske intervencije. Kombinacija cyber-fizičkih sustava, Internet of things (IoT) što označava povezivanje uređaja putem interneta, predstavlja mrežnu infrastrukturu u kojoj fizičke i virtualne "stvari" svih vrsta komuniciraju i nevidljivo su integrirane, te čine Industriju 4.0 mogućom, a pametnu tvornicu stvarnošću.[3]

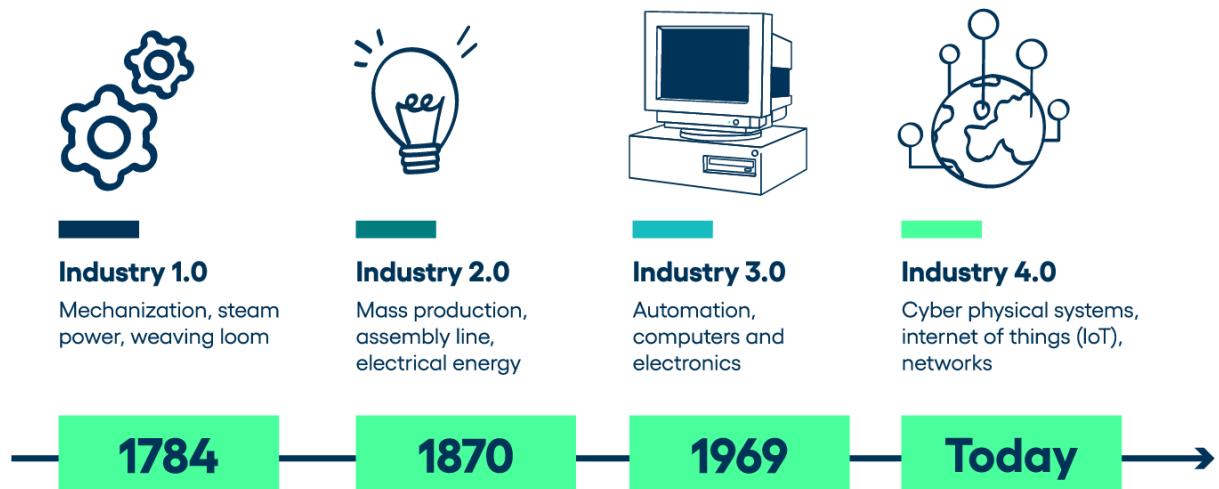
Podržavajući pametne strojeve koji postaju pametniji kako se pristupa većem broju podataka, tvornice će postati učinkovitije i produktivnije te će proizvoditi manje otpada. U konačnici, upravo mreža tih strojeva koji su digitalno povezani te stvaraju i dijele informacije daju pravu snagu Industrije 4.0.



Slika 1. Komponente tehnologije Industrije 4.0 u kontekstu inteligentne proizvodnje[4]

Primjena komponenti ove četvrte industrijske revolucije donosi strategiju održavanja koja pokušava produžiti vijek trajanja opreme i smanjiti troškove zahvaljujući kontinuiranoj i trenutnoj komunikaciji između različitih strojeva/opreme bilo u proizvodnom ili opskrbnom lancu. Jedan od stupova ove posljednje industrije je prediktivno održavanje, koje pokušava primijeniti najnovije tehnologije za promjenu scenarija i izbjegavanje bilo kakvog kvara ili anomalije kroz predviđanje, smanjenje troškova i smanjenje vremena zastoja.

S obzirom na prikazano temeljno razumijevanje četvrte industrijske revolucije i nekih čimbenika koji je karakteriziraju, važno je istražiti razloge sigurnosnih izazova koji stoje na putu Industrije 4.0 i ljudskog aspekta Industrije 4.0.[4]



*Slika 2. Razvoj Industrija kroz povijest[5]*

### **3. Sigurnosni izazovi u kontekstu industrije 4.0**

Tehnološka evolucija dovela je do značajnih promjena u načinu na koji organizacije svakodnevno rade, stvarajući neviđeni pritisak za učinkovitost i učinak. Organizacije se uvelike oslanjaju na performanse svojih informacijskih sustava kako bi razvile svoje aktivnosti, zbog njihove udobnosti i pojave novih tehnologija.

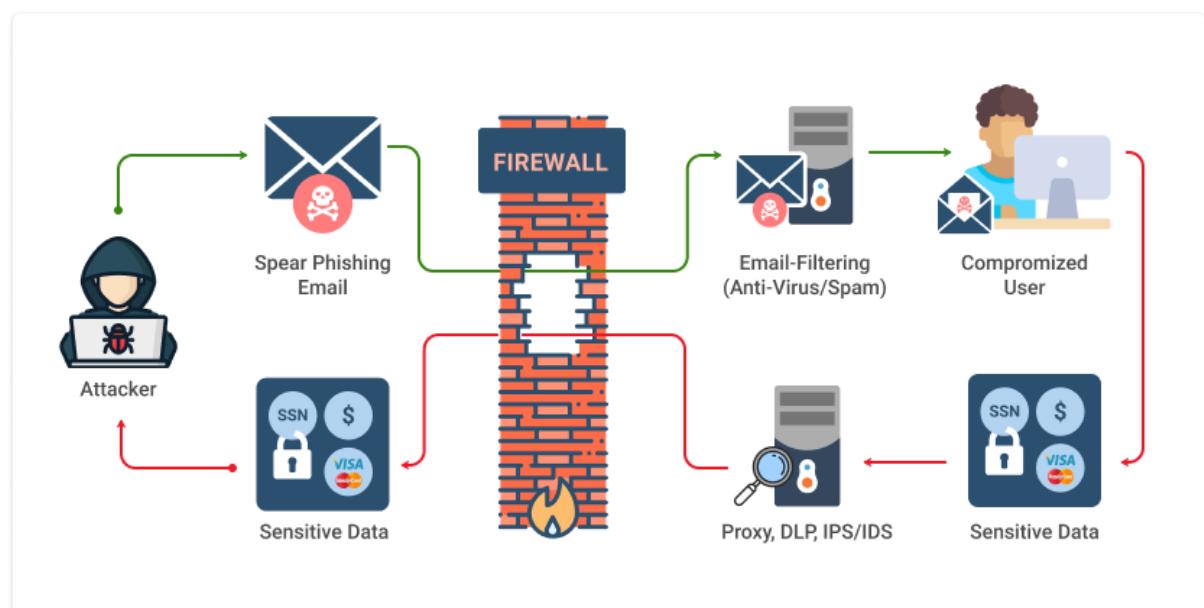
Međutim, sustavi temeljeni na oblaku, *Internet stvari* (IoT) i međusobna povezanost pametnih industrija doveli su do značajnog porasta neočekivanih sigurnosnih probaja. Industrija 4.0 je ranjivija na kibernetičku špijunažu ili kibernetičku sabotažu zbog digitaliziranih i povezanih poslovnih procesa. Trenutno su ljudi svjedoci razvoja dobro organiziranih skupina kibernetičkih kriminalaca s izvrsnim vještinama i naviknutih na ciljanje specifičnih industrija, s ciljem *hakiranja* osjetljivih informacija i intelektualnog vlasništva. Problem povezan s ovim fenomenom nije ograničen na njegov utjecaj na prodaju, već također uključuje štetu imidžu organizacije, gubitak znanja i smanjenje razine konkurentnosti pogođenih organizacija.

Jedna od karakteristika Industrije 4.0 je mogućnost povezivanja preko organizacijskih okruženja, što ima potencijal učiniti lanac pružanja usluga učinkovitijim. Međutim, sustavi opskrbnog lanca imaju inherentne sigurnosne ranjivosti koje napadači iskorištavaju. Jedna takva sigurnosna ranjivost je na razini dobavljača, koja je ranjiva na *phishing* napade i krađu povlaštenih vjerodajnica, što rezultira golemlim izlaganjem podataka. Glavna ranjivost nalazi se na vrhu opskrbnog lanca i utječe na ostatak organizacijskih procesa preko aktera koji o njoj ovise.

Sigurnosna svijest, kontrola pristupa kroz mehanizme autentifikacije, kriptografske procese i analizu ponašanja sigurnosni su mehanizmi koji mogu pomoći u sprječavanju *hakiranja* opskrbnog lanca. *Uskraćivanje usluge* (DoS) je čin kojim se sustav ili aplikacija onemogućuju. Na primjer, DoS napad može se postići „bombardiranjem“ poslužitelja s velikim brojem zahtjeva za procesuiranje svih dostupnih resursa sustava, prosljeđivanjem pogrešno oblikovanih ulaznih podataka poslužitelju koji mogu srušiti proces, infiltracijom virusa ili uništavanjem ili onesposobljavanjem senzora u sustav, ne dopuštajući mu

normalno funkciranje. Industrija 4.0 oslanja se na veliki broj međusobno povezanih sustava i procesa, a DoS napadi su vrlo značajna prijetnja u takvim okruženjima.[6]

Prijelaz na Industriju 4.0 monumentalan je zadatak koji će utjecati na mnoga područja današnje proizvodne industrije, uključujući sigurnost. Većina proizvodnih tvrtki nije u potpunosti svjesna sigurnosnih rizika povezanih s prihvaćanjem paradigme Industrije 4.0. Obično se bave sigurnosnim problemima samo kada se dogodi ozbiljan incident. Stoga je kritično i bitno da organizacije usvoje razvoj strategije za implementaciju i upravljanje procesima usklađenosti sa sigurnošću koje zahtijeva Industrija 4.0, uključujući smanjenje izloženosti organizacije i učinkovito upravljanje procesom ublažavanja.[4]



Slika 3. Primjer phishing napada[7]

## **4. Ljudski aspekti u kontekstu industrije 4.0**

Kako bismo se pozabavili aspektom povezanim s ljudima u kontekstu industrije 4.0, postoji sve veći interes za istraživanje i industrijske prakse u kojima su ljudi stavljeni u središte dizajna u svim disciplinama. Ljudska inteligencija i intervencija i dalje igraju ključnu ulogu zbog sigurnosnih i društvenih aspekata te neizvjesnosti koje predstavljaju ovi autonomni i intelligentni sustavi. Osim toga, usporedno s naprednim tehnologijama ovih intelligentnih sustava, uloga ljudi je evoluirala od operacija niske razine koje mogu biti opasne, teške i dosadne do visoko specijaliziranih i sigurnih zadataka. Međutim, ljudi mogu osjećati da se lako mijenjaju zbog primjene tehnologije.

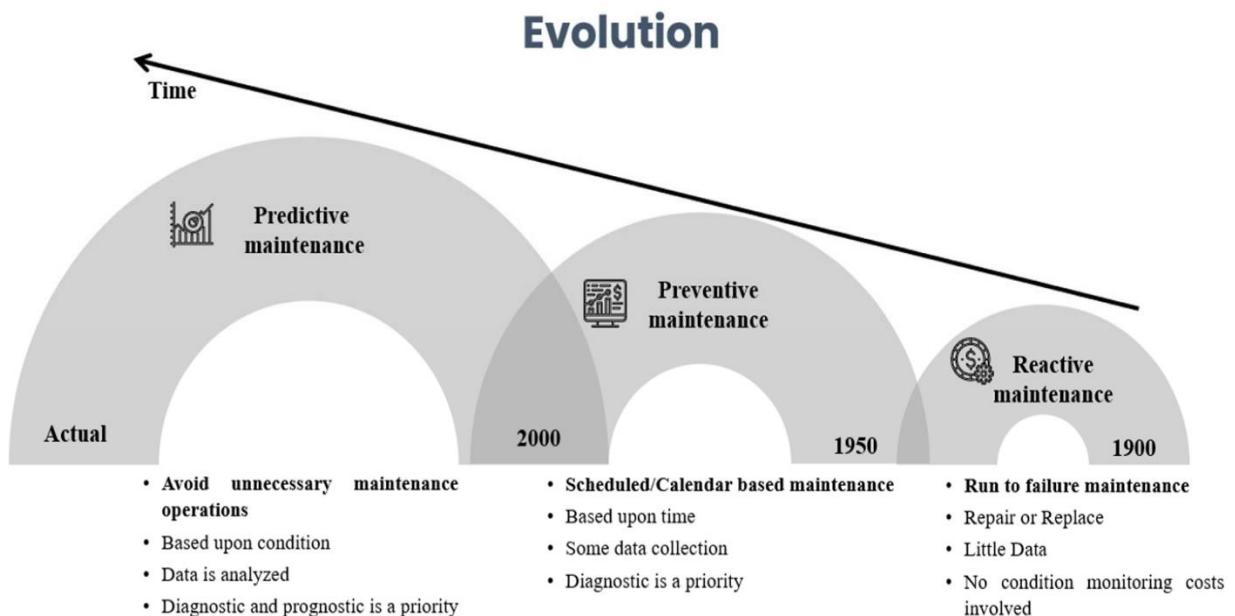
Osim tehničkih vještina, ističe se da ljudski rad u proizvodnom sektoru sve više zahtijeva tehnološke vještine, socijalne i komunikacijske vještine, kao i timske vještine i vještine samoupravljanja. Moraju se identificirati bitne vještine za obavljanje zadataka i osigurati obuka kako bi se ispunili zahtjevi. Osoba bi trebala imati više mogućnosti za autonomno donošenje odluka, raznolikost na radnom mjestu i socijalnu interakciju. Također i sa svojim vrijednostima, stavovima i poštovanjem prema drugima, što ga odvaja od tehnoloških uređaja, a to se mora naglasiti u procesima upravljanja.[8]

## 5. Evolucija industrijskog održavanja

Kao što je objašnjeno u prethodnom odjeljku, koncept Industrije 4.0 vodi do povezane tvornice vođene podacima. Na temelju ovog koncepta, dominantan trend u održavanju je odmak od skupog reaktivnog održavanja prema preventivnom i prediktivnom održavanju, koje se također naziva pametnim održavanjem. Tijekom industrijskih revolucija, kao što je prikazano na slici 4, strategije održavanja su prošle postupnu evoluciju i trenutno je to kontinuirani proces.

Zaista, filozofija reaktivnog ili korektivnog održavanja češća je u proizvodnim pogonima koji nemaju dovoljno osoblja i ne mogu zadržati kvalificirano osoblje za održavanje. Industrije su se godinama borile da napuste ovu filozofiju održavanja jer je skupa i često rezultira značajnim neplaniranim zastojima i povećanim troškovima.

Preventivno održavanje je skup radnji usmjerenih na sprječavanje kvarova, smanjenje rizika od kvara te broja i trajanja neplaniranih isključenja, što podrazumijeva produljenje vijeka trajanja opreme i sastoji se od intervencije u sustavu prije nego što dođe do kvara.[9]



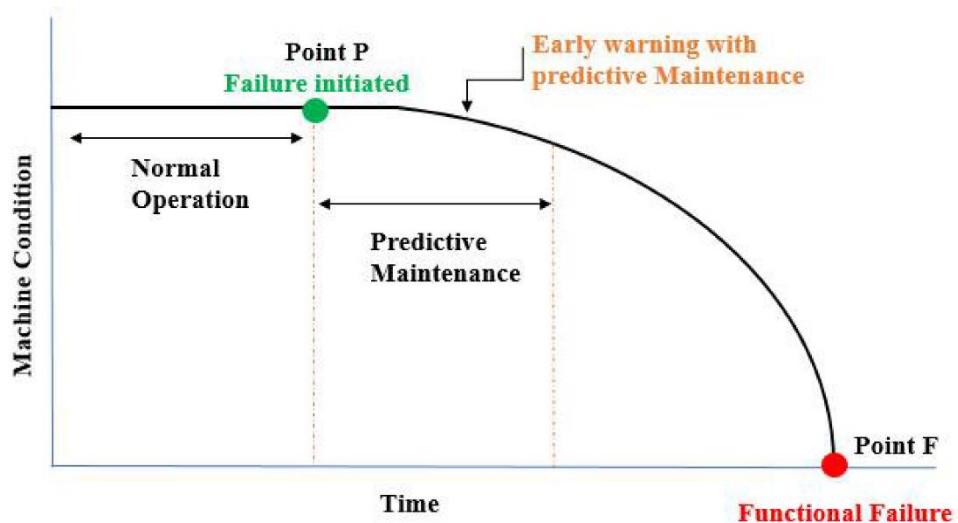
Slika 4. Evolucija aktivnosti i metoda održavanja[10]

## 6. Prediktivno održavanje

Prediktivno održavanje noviji je pristup preventivnom održavanju koji se sastoji od poboljšanja performansi i učinkovitosti proizvodnog procesa produljenjem životnog vijeka opreme i osiguravanjem održivog operativnog upravljanja. To podrazumijeva, s jedne strane, smanjenje vremena zastoja i broja nepotrebnih zaustavljanja, popraćeno smanjenjem troškova popravka, nudeći mogućnost intervencija kroz predviđanje kvarova.

Inteligentne prediktivne strategije održavanja sada provode proizvodne tvrtke. Ova se implementacija provodi procjenom preostalog vijeka trajanja elemenata odgovornih za kvar i dopuštanjem daljinskog praćenja kvarova opreme u stvarnom vremenu. Zato je potrebna detekcija i dijagnoza kako bi oprema ispravno radila.

Prediktivno održavanje je najnoviji oblik održavanja, koji nudi najdulji vijek trajanja i najveću pouzdanost opreme (prikazano na slici 5), te ekološki najsplativija. Metoda održavanja koja se koristi za rješavanje problema odlaskom do izvora naziva se proaktivno održavanje. Ova metoda održavanja, koja je vrlo učinkovita kada se primjenjuje zajedno s prediktivnim održavanjem, postaje sve popularnija.[11]



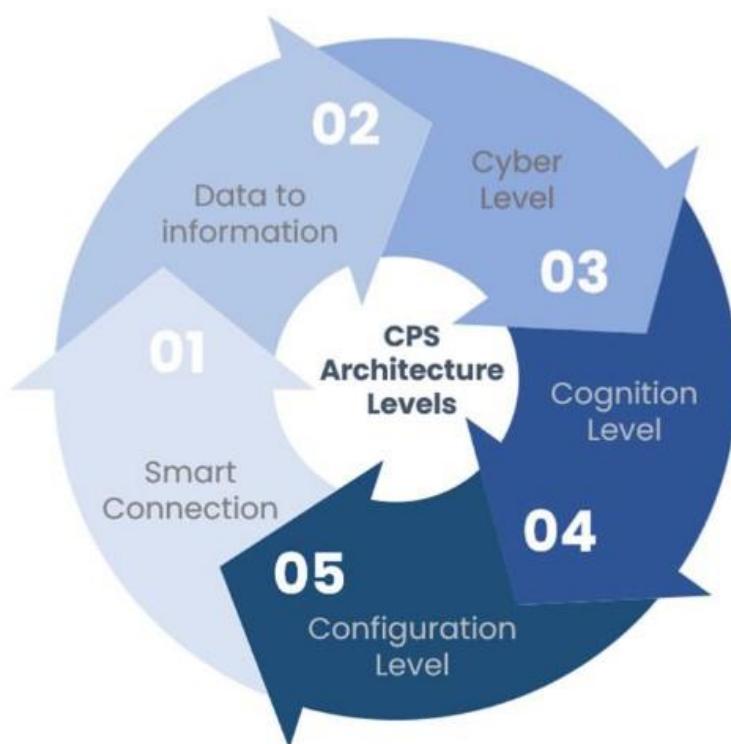
Slika 5. Dijagram potencijalnog kvara koji prikazuje intervale pregleda i prediktivno održavanje[5]

## 6.1. Alati i materijali za prediktivno održavanje

Početkom 21. stoljeća, u eri četvrte industrijske revolucije, računalni i napredni alati za vizualizaciju temeljeni na najnovijim tehnologijama postali su glavne i nužne komponente digitalne transformacije u Industriji 4.0. Usvojile su ih proizvodne tvrtke u višestrukim industrijskim primjenama i, točnije, u prediktivnom održavanju, nazvanom održavanje 4.0. U sljedećim pododjeljcima predstavljeni su glavni tehnološki alati primjenjeni u održavanju 4.0.[12]

### 6.1.1. Cyber-fizički sustavi

Najnoviji napredak u inteligentno povezanim proizvodnim uređajima i senzorima te autonomnim intelligentnim nadzornim, kontrolnim, senzorskim i dijagnostičkim sustavima poznati su kao *cyber-physical systems* (CPS), koji su opremljeni raznim računalnim i fizičkim metodama i alatima koji savršeno odgovaraju ljudskim potrebama. Petostupanska CPS arhitektura (5C arhitektura) prikazana je slikom 6. Ove faze pružaju jednostavniju tehniku za dizajniranje i prakticiranje CPS-a korak po korak od faze prikupljanja podataka do konačne analize i faze stvaranja vrijednosti.



Slika 6. CPS arhiktetura[12]

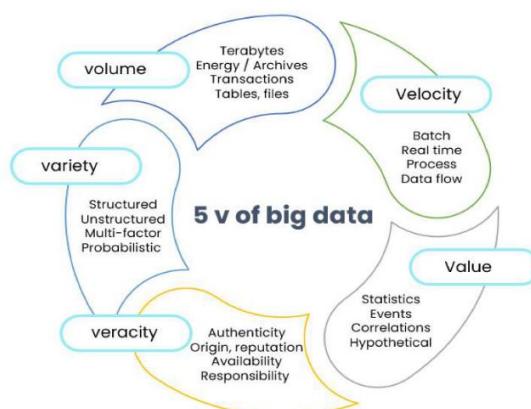
### 6.1.2. Industrial Internet of Things (IIoT)

Povezivanje strojeva, uređaja i sustava najosnovniji je korak u implementaciji aplikacija IoT. Koncept IoT pruža pogodnost u industrijskim okruženjima, gdje se naziva *Industrial Internet of Things* (IIoT). IIoT se smatra glavnim čimbenikom iza načela Industrije 4.0. To je mreža koja povezuje cyber-fizičke sustave i omogućuje međusobno povezivanje i interakciju između fizičkih uređaja u procesu, omogućujući automatsko prikupljanje i dohvaćanje ogromnog protoka podataka. Ovo predstavlja pojam *Big Data*. IIoT nudi i mogućnost prijenosa podataka putem interneta, a atmosfera je ta koja omogućuje izravan pristup procesnim podacima, virtualizaciju resursa, međusobno povezivanje, suradnju, međukomunikaciju i interakciju stroj-stroj na transparentan način i bez ljudske intervencije.

### 6.1.3. Big Data

Prikupljanje, obrada i analiza velikih podataka u stvarnom vremenu iz cyber-fizičkih sustava strateška je faza za inteligentnu transformaciju funkcije održavanja, posebno u pogledu predviđanja kvarova, planiranja i upravljanja rizikom. To se postiže kroz planiranje i optimizaciju intervencija korištenjem alata i tehnika umjetne inteligencije kao što su „strojno učenje“ i „duboko učenje“ ili putem statističkih modela i pristupa koji se temelje na podacima i informacijama koje prikupljaju različiti senzori.

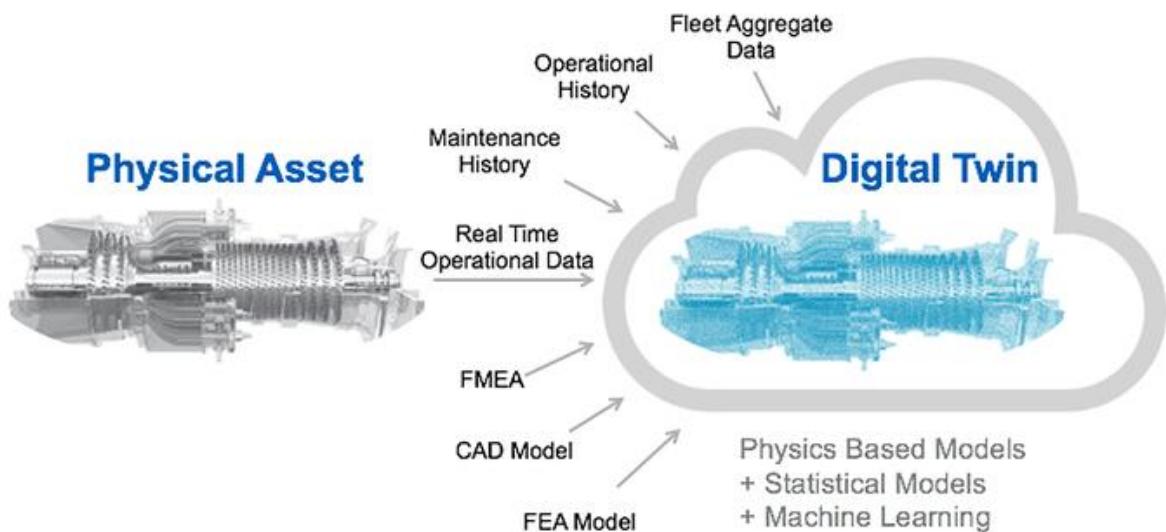
Karakterizacija velikih podataka ili Big Data obično se vrši prema tri „V“ odnosno Volume, Variety and Velocity (volumena, raznolikosti i brzine), kojima se dodaju drugi komplementarni "V-ovi", kao što su Value i Veracity/Validity (vrijednost i istinitost/valjanost) (vidi sliku 7).



Slika 7. 3V model proširen na 5V Big Data[12]

#### 6.1.4. Digital Twin

Digital Twin (DT) (slika 8.) je digitalna ili virtualna kopija fizičke imovine ili proizvoda. Pojam je izvorno skovao dr. Michael Grieves 2002 godine. NASA je bila jedna od prvih koja je koristila tehnologiju za istraživanje svemira. DT povezuju stvarni i virtualni svijet prikupljanjem podataka u stvarnom vremenu s instaliranih senzora. Prikupljeni podaci su ili lokalno decentralizirani ili centralno pohranjeni u oblaku. Podaci se zatim procjenjuju i simuliraju u virtualnoj kopiji imovine. Nakon primanja informacija iz simulacije, parametri se primjenjuju na stvarnu imovinu. Integracija podataka u stvarnom i virtualnom prikazu pomaže u optimiziranju performansi stvarnih sredstava.[8]



Slika 8. Primjer Digital Twin-a[12]

#### 6.1.5. Augmented reality

*Augmented reality (AR)* ili *proširena stvarnost* je tehnologija u nastajanju razvijena na temelju *virtual reality (VR)* (virtualna stvarnost), koja generira trodimenzionalne virtualne informacije kroz računalni sustav, uključujući virtualne scene, virtualne objekte itd., a zatim postavlja te informacije u stvarnu scenu kako bi ostvario funkciju poboljšanja stvarnog svijeta i poboljšao korisničku percepciju stvarnog svijeta. Iako je razvijen na temelju VR tehnologije, AR ne zahtijeva renderiranje prirodnog okruženja kao VR tehnologija.

AR je primijenjen za podršku različitim procesima u tvornici, kao što su montaža, održavanje itd. Budući da različiti proizvodni procesi zahtijevaju visoku kvalitetu i gotovo nultu stopu pogreške kako bi se osigurali zahtjevi i sigurnost krajnjih korisnika, AR također može opremiti operatere s impresivnim sučelja za postizanje produktivnosti, točnosti i autonomije u kvaliteti.

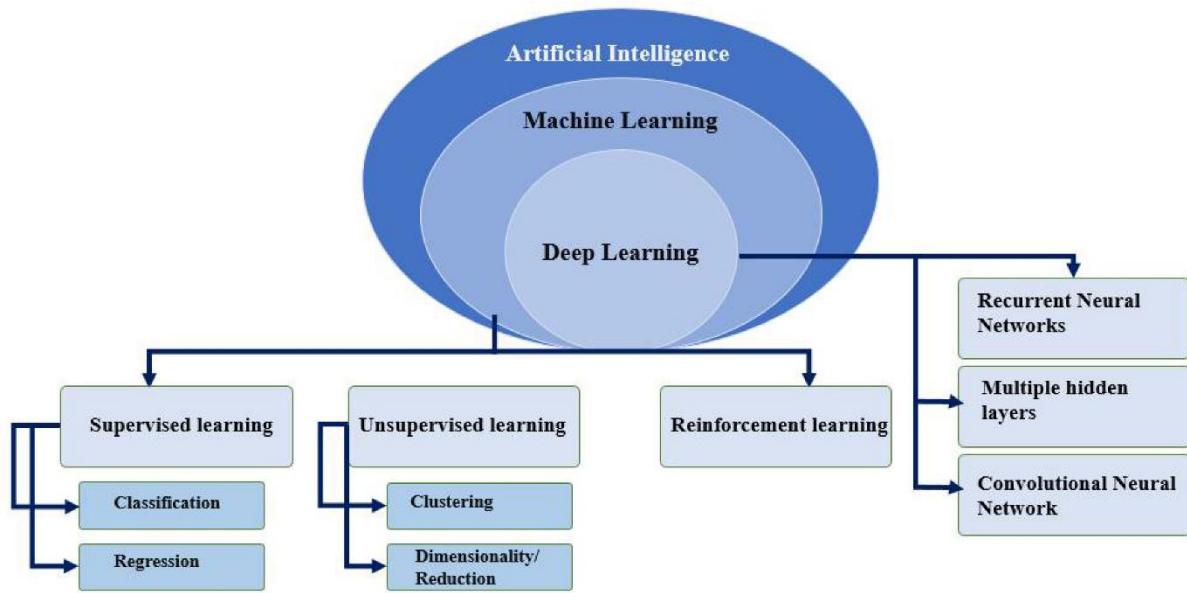
#### **6.1.6. Artificial intelligence (AI)**

Umjetna inteligencija (AI) ključna je riječ u prijelazu na Industriju 4.0 to je moćna tehnologija koja nadoknađuje nedostatke i nesposobnost tradicionalnih tehnika i pristupa koji se prakticiraju u industriji. Pojavio se kao moćan alat za razvoj inteligentnih prediktivnih algoritama u mnogim primjenama. Pristupi umjetne inteligencije mogu obrađivati višedimenzionalne i multivariantne podatke i izdvajati skrivene odnose u podacima u složenim i dinamičnim okruženjima. Umjetna inteligencija je usko povezana i prikladna za Big Data za odgovaranje na kritična pitanja, rješavanje slabosti i rasvjetljavanje ključnih pitanja procesa, posebno u fazi analize i obrade Big Data.

#### **6.1.7. Machine Learning (ML) and Deep Learning (DL)**

Strojno učenje (ML) je potpodručje umjetne inteligencije koje se razvilo od prepoznavanja uzorka do analize struktura podataka i njihove integracije u modele koje korisnici mogu razumjeti i regenerirati. Slika 7 identificira sve ML kategorije, metode i modele primjenjive na projekte povezane s održavanjem.

Nadalje, ML je klasificiran u četiri kategorije, naime nadzirano učenje, nenadzirano učenje, učenje s potkrepljenjem i *duboko učenje*. Za vrste nadziranog i nenadziranog učenja namijenjene predviđanju ili opisivanju postojećih odnosa u skupu podataka kaže se da su nadzirani kada je zavisna varijabla dostupna i nenadzirani kada nisu, dok je učenje s potkrepljenjem računalni pristup koji uči iz interakcije s okolinom , što znači određivanje načina na koji akteri u sustavu mogu izvoditi radnje u svom okruženju kako bi maksimizirali kumulativne nagrade.



*Slika 8. Klasifikacija tehnika vođenih podataka i kategorija strojnog učenja[12]*

*Duboko učenje* (DL) pripada umjetnim neuronskim mrežama (ANN). To je velika skupina tehnika u mnogim područjima, koje se mogu primijeniti i na nadzirano i na nenađirano učenje. ANN-ovi su nadahnuti funkcijom mozga, s primarnim ciljem učenja iz nestrukturiranih ili neoznačenih podataka, koristeći jedan ili više slojeva za izvlačenje značajki više razine korak po korak iz sirovog unosa. Tehnike dubokog učenja mogu se primijeniti na industrijsku opremu u različitim situacijama kao što su otkrivanje grešaka, predviđanje kvarova itd.[12]

## **7. Izazovi prediktivnog održavanja**

Iako je usvajanje prediktivnog održavanja u industrijskom kontekstu neizbjegno, ono je okruženo izazovima koji ometaju primjenu i kolektivno usvajanje ovog pametnog pristupa održavanju. Unatoč dostupnosti algoritama za prediktivno održavanje, tvrtke koje žele imati koristi od Industrije 4.0 još uvijek moraju zamijeniti mogućnosti prediktivnog održavanja u odnosu na kapitalne izdatke potrebne za kupnju potrebnih instrumenata, softvera i stručnosti.[13]

Ovaj je nedostatak važniji u ranim fazama razvoja prediktivnog održavanja kada nedostaju ili su rijetki stvarni podaci o normalnom i nenormalnom ponašanju opreme, te u slučaju novih sustava, kada nema iskustva s njihovim radom. Ova situacija može navesti tvrtke da više ulažu u rješenja za prediktivno održavanje. Na popisu izazova koji se susreću u znanstvenoj literaturi mogu se razlikovati četiri skupine koje će se razmatrati, a to su finansijska i organizacijska ograničenja, ograničenja izvora podataka, ograničenja aktivnosti popravka strojeva i ograničenja u implementaciji modela industrijskog prediktivnog održavanja.

### **7.1. Finansijska i organizacijska ograničenja**

Profitne tvrtke neizbjegno razmatraju očekivane troškove svake nove investicije. Prediktivni napor održavanja, kao što su instalacija senzora, pronalaženje informacija, priprema modela i održavanje te aktivnosti održavanja stvaraju troškove za tvrtke u kojima su uvedene metode prediktivnog održavanja.

Ovi troškovi mogu varirati ovisno o više čimbenika, kao što su vrsta i složenost opreme i odgovarajućih senzora, troškovi savjetovanja, instalacije i izvlačenja znanja te može li se potrebna ekspertiza pronaći interno ili eksterno. Jedna od metoda procjene može li uvođenje prediktivnog održavanja biti korisno je stvoriti *return on investment* (ROI) odnosno povrat ulaganja. Kreiranje prediktivnog ROI-a treba uzeti u obzir vrijednost predvidljivih rezultata održavanja, vrijeme povrata i opisane troškove. Finansijsko obrazloženje za korištenje i primjenjivost prediktivnog održavanja također ovisi o veličini i vrsti poslovanja u kojem se ono uvodi.

## **7.2. Ograničenja izvora podataka**

Za izradu modela upravljanja proizvodnim procesom neophodna je dostupnost relevantnih podataka. Međutim, poduzeća rijetko imaju sve relevantne podatke na početku uvođenja upravljanja proizvodnim procesom. Nakon korištenja podataka koji su već dostupni, potrebno je identificirati nedostatke i nastojati ih riješiti.

Nadalje, kvaliteta postojećih izvora informacija možda neće zadovoljiti tražene potrebe. Ako je samo dio podataka pod utjecajem nezadovoljavajuće kvalitete, to se može prevladati tijekom pripreme podataka, sve dok je količina podatkovnih točaka dovoljna za postizanje statističke značajnosti i sve dok otkrivanje nedostataka može uspješno izolirati kritične točke za stroj. Tvrta koja koristi prediktivne metode održavanja može se tada suočiti s izazovima kada potrebno povjerenje u podatke nije istinito, tj. ako senzori, kontroleri ili drugi izvori podataka daju netočna mjerena.

To može rezultirati netočnim predviđanjima i propuštenim hitnim održavanjem ili lažnim alarmima. Dodatni izazov za tehnologiju senzora je taj što senzori trenutno rade izvan mreže bez doprinosa mrežnim podacima. Osim toga, senzori su podložni zastoju, degradaciji instrumenta, buci ili jednostavno senzor može pokvariti. Zatim je važno očistiti podatke prije primjene algoritma prediktivnog održavanja kako bi se predvidjela prava stvarnost i ne bi se iskrivili rezultati.[14]

## **7.3. Ograničenja aktivnosti popravka strojeva**

Budući da je moguće predvidjeti preostali vijek trajanja komponente, može se odrediti vrijeme održavanja, ali stvarno održavanje komponente i dalje se suočava s izazovima koji se odnose na ovisnost o ljudskim interakcijama i nedostatku samoodržavanja. Zapravo, učinkovitost održavanja ovisi o kvaliteti ljudskog upravljanja i vještina, s obzirom na to da komponente stroja trenutno ovise o ljudskim operaterima za kontrolu i održavanje.

Industrijski strojevi posebno rade tako što izvršavaju naredbe na reaktivni način i ne dovode u pitanje plan za njih. Međutim, ljudsko planiranje zadatka temelji se na podacima i iskustvu, koje bi stroj također mogao dohvatiti. Stoga bi inteligentna komponenta mogla

autonomno predložiti ili čak pokrenuti radnje koje su korisne za zdravlje sustava, protok imovine ili kvalitetu proizvoda.

Daljnji korak prema autonomiji imovine oslanja se na svijest o imovini i autonomno održavanje. Samosvjesna imovina može procijeniti svoje uvjete na temelju podataka koji su trenutno izdvojeni i pohranjeni u sustavu prediktivnog održavanja i može prepoznati kritične uvjete do točke autonomnog definiranja odluka o održavanju.

Za razliku od središnjeg sustava koji kontrolira jednu ili više imovine, sve informacije potrebne za donošenje odluka o prediktivnom održavanju, kao i model degradacije i predviđanja, bile bi distribuirane i dostupne na razini komponente. Strojevi tada mogu sami planirati programe održavanja.[15] Međutim, trenutno industrijski strojevi nemaju ovu razinu samosvijesti i samoodržanja.

## **8. Remont horizontalne glodalice DIXI 300 (Eksperimentalni dio)**

### **8.1. Općenito o stroju**

DIXI 300 je dio niza poznatih horizontalnih strojeva za glodanje i bušenje čiji je proizvođač DIXI prvi u svijetu, tad se koristio najnovijim dostignućima moderne tehnologije tog doba u kombinaciji s velikim iskustvom i temeljnim načelima, snažnim i provjerениm umovima. Sinteza ovih elemenata omogućila je realizaciju univerzalnog stroja velike preciznosti, brzog, snažnog i geometrijski izuzetno stabilnog koji i danas ispunjava sve kriterije današnje proizvodnje. DIXI 300 ispunjava najviše zahtjeve preciznosti u proizvodnji, konstrukcijskih alata, proizvodnji prototipova i pojedinačnih dijelova u najrazličitijim područjima. Opća preciznost stroja za bušenje koji je po svojoj konstrukciji suočen s najrazličitijim i promjenjivim naprezanjima ovisi o mnogim važnim parametrima, kako sa stajališta projektiranja, konstrukcije tako i proizvodnje.



*Slika 9. DIXI 300 -75[Autor]*

#### **Osnovni tehnički podaci stroja:**

- Hod (x, y, z) – 920, 680, 780 mm
- Dimenzije stola – 840 x 1000 mm (360°)
- Masa – 12 t

Što se tiče specifično našeg stroja ovo mu je prvi remont otkad je izašao iz tvornice davne 1973. godine. Na prvu smo bili malo skeptični oko toga, ali gospodin koji je vodio remont i koji ima preko 40 godina iskustva s radom na ovim strojevima provjerio je serijski broj u svojoj "bazi podataka" i ustvrdio da se nikad nije ništa radilo na njemu. Brzo smo povjerovali da je to istina kad smo počeli skidati dio po dio stroja i nailazili na slomljene i istrošene dijelove. U nastavku rada ćemo prikazati glavne zahvate obuhvaćene ovim remontom.

## 8.2. Zamjena dijelova i čišćenje

Stol se sastoji od snažno pregrađene i dijagonalno rebraste kutije od lijevanog željeza kako bi se odupro torziji koju stvara poprečno kretanje stola. Ova uvijanja su zapravo izravan uzrok, između ostalog, grešaka u poravnanju provrta koje nastaju okretanjem stola. To je razlog zašto ovaj okvir također mora biti zabrtvlen na temelju osiguravajući zajedno maksimalnu krutost.

Za uklanjanje stroja potrebno je ukloniti 4 trapezna vijka (slika 10.) koje je potrebno prije odvijanja označiti s markerom kako bi kod vraćanja znali gdje su bili u zahvatu. Svaki vijak ima svoj ugravirani broj da se zna u koji provrt ide. Nakon uklanjanja vijaka stol smo učvrstili sa 4 očna vijka (slika 11.) kako bi ga sigurno podigli dovoljno da se može ispod njega stati i pregledati.



Slika 10. Trapezni vijak sa zazubljenom glavom[Autor]



Slika 11. Podizanje stola stroja[Autor]

Nakon detaljne inspekcije podnožja stola sve je bilo u redu samo je trebalo dobro očistiti i odmastiti mjeru skalu (slika 12.).



Slika 12. Mjerna skala stroja za određivanje kuta stola[Autor]

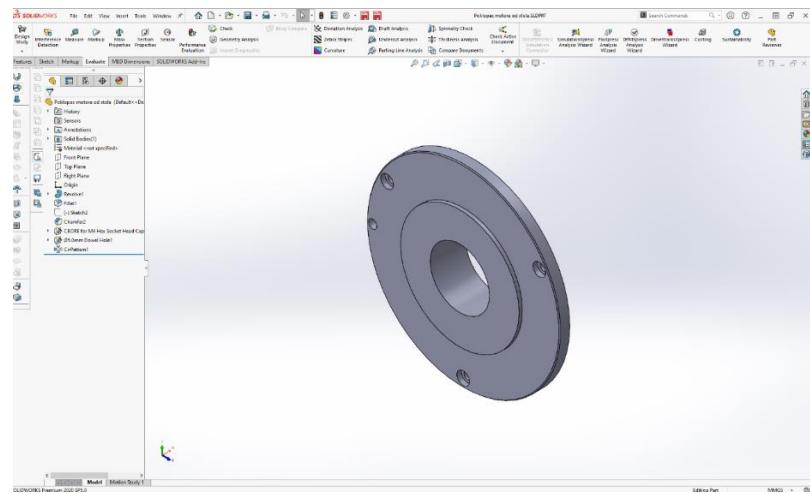


Slika 13. Poklopac kućišta motora stola[Autor]

Na slici 13. vidimo istrošeni poklopac, oštećenje je nastalo uslijed trenja između samog poklopca i kućišta ručice. Do kolizije je došlo zbog pinova koji su zapekli te nisu odvajali. Stroj ima mogućnost pokretanja stola pomoću elektromotora kao što vidimo u pozadini slike 13. za grubo pomicanje te za fino pomoću ručice (slika 14.). Bilo je potrebno napraviti *reverse engineering* poklopca. Strojni dio je nacrtan pomoću programa SolidWorks (slika 15.), te je kod nas i proizведен.



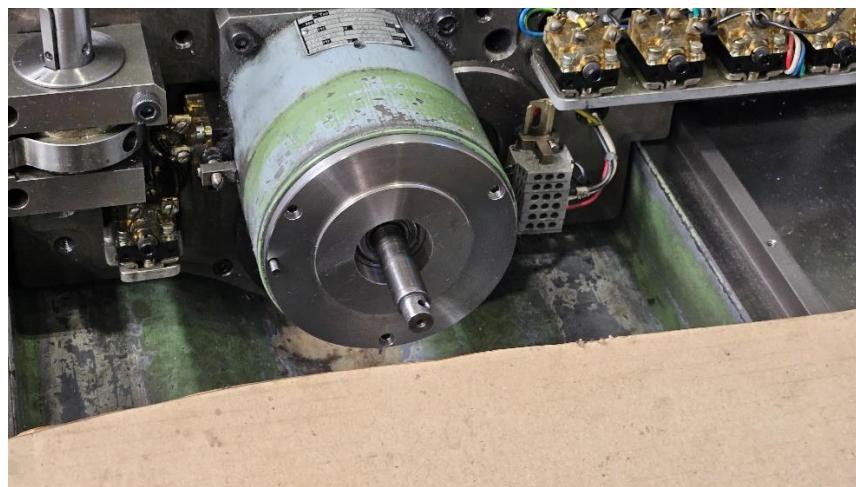
Slika 14. Ručica za fino pozicioniranje[Autor]



Slika 15. 3D model poklopca[Autor]



Slika 16. Novi poklopac stola[Autor]



Slika 17. Novi poklopac montiran na stol[Autor]

Na slici 18. možemo vidjeti kako su klizne staze obrađene struganjem ili tuširanjem što nam omogućava vrlo visoku razinu preciznosti njegovu dosljednost i krivulje geometrijske kompenzacije koje se mogu osigurati struganjem kliznih staza. Ova metoda završne obrade pomaže u održavanju trajnog uljnog filma između pokretnih dijelova, čak i pod visokim opterećenjem što jamči vrlo nisko trošenje kliznih staza, a time i dulji vijek trajanja.

Sve staze osim staze x-osi su bile u odličnom stanju. Do nepovratnog oštećenja je došlo zbog neredovite zamjene brisača odnosno strugača te je špena propala kroz isto i ostala zarobljena na kliznim staza gdje je uslijed pomaka osi špena strugala i napravila oštećenje. Tokom geometrije stroja ustvrdili smo da je greška na tom dijelu od  $10 \mu\text{m}$ . Također možemo vidjeti na slici 19. Ugradnju novih limova i brisača za zaštitu kliznih staza.



*Slika 18. Tuširana klizna staza[Autor]*



*Slika 19. Novi zaštitni limovi za klizne staze[Autor]*

Također se obavio detaljni pregled elektromotora, s motorom je sve bilo uredu samo smo promijenili remenicu te stavili pripadajući remen, odnosno umjesto zupčaste stavili smo vise kanalnu remenicu s V ozubljenjem (slika 20.) zbog prednosti prijenosa velike snage i okretnog momenta.



*Slika 20. Elektromotor i nova remenica[Autor]*

Svrha ovog elektromotora je pokretanje vretena za pinolu (slika 21.), vreteno je očišćeno pregledano i stavljen mu je novi kuglični ležaj (Slika 22.).



Slika 21. Vreteno za pokretanje pinole[Autor]

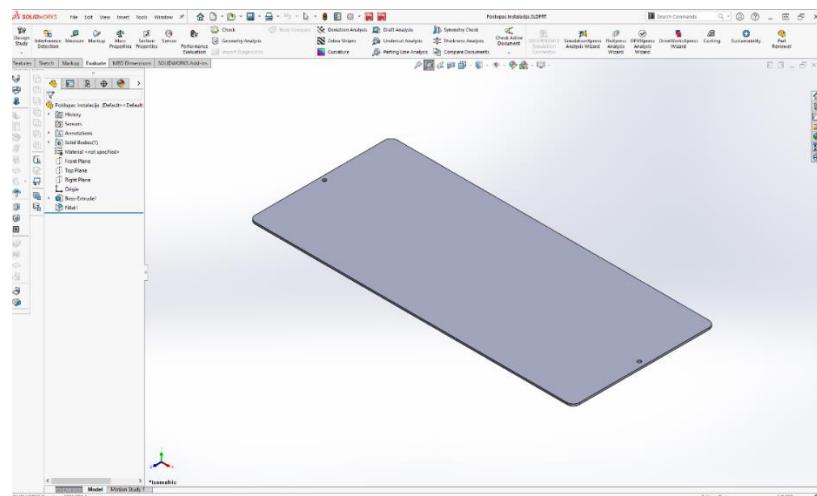


Slika 22. Novi kuglični ležaj vretena[Autor]

Bilo je potrebno dizajnirati poklopac instalacija (slika 23), poklopac je također dizajniran u SolidWorksu (Slika 24.) i proizveden od konstrukcijskog čelika (St-37).



Slika 23. Potreban poklopac instalacija[Autor]



Slika 24. 3D model poklopca instalacija[Autor]

Kao što znamo osi x, y, z pokretane su hidrauličkim cilindrima (slika 25). Cilindri su rastavljeni i detaljno pregledani te su mu promijenjeni brtve i O-prstenovi i stavljen je novo hidrauličko ulje.



Slika 25. Hidraulički cilindar[Autor]

Za precizno pozicioniranje služi nam optika koja pomoću niza zrcala pomaže nam točno namjestiti željenu os na željenu poziciju. U našem slučaju na jednoj od optika stroja jedno zrcalo je napuklo (slika 26.) što nam ne dozvoljava pozicioniranje na tom dijelu mjerne skale. Sama zamjena tog zrcala je nemoguća jedino što dolazi u obzir je zamjena čitave optike.



Slika 26. Unutrašnji dio optike s puknutim zrcalom[Autor]



Slika 27. Optika za pozicioniranje (x-os) [Autor]

Na slici 28. možemo vidjeti stari sustav hlađenja koji služio svih ovih godina, naravno sustav nije radio kako treba jer nije dovoljno hladilo ulje u pinoli gdje na vanjskoj strani pinole mora biti hladno na dodir.

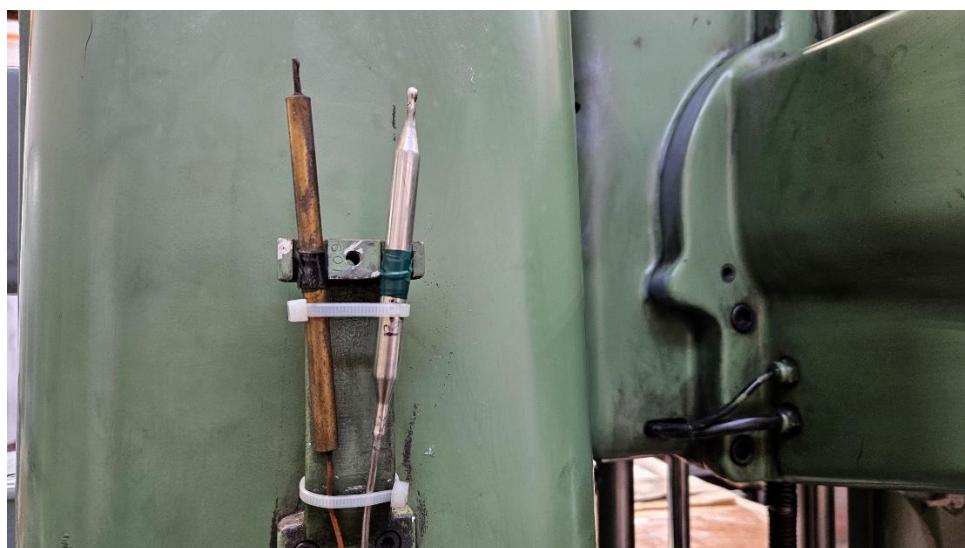


Slika 28. Izgled kućišta hladnjaka prije ugradnje novog sustava [Autor]

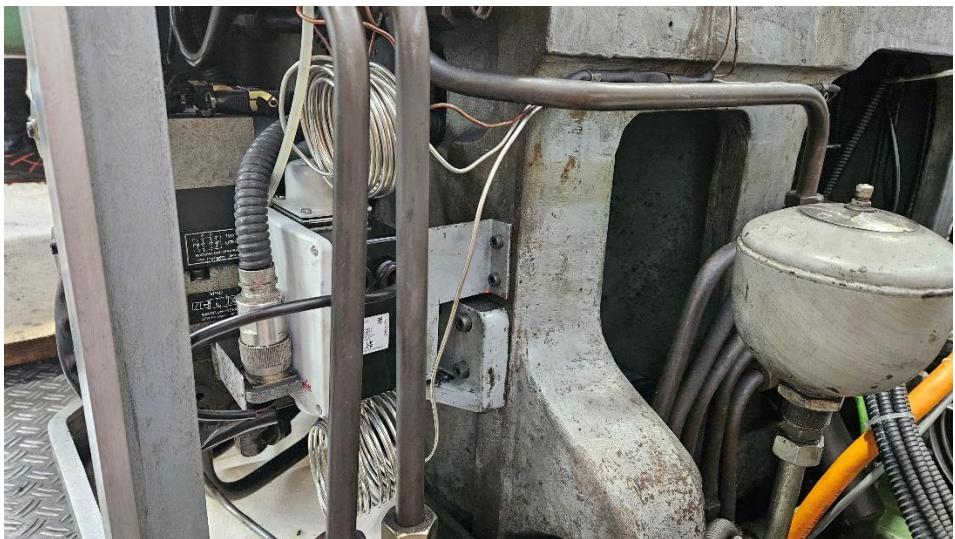
Kako bi smo to popravili naručena je dodatna unutarnja jedinica za hlađenje slika 29. s ostalim popratnim dijelovima za kompletну instalaciju.



Slika 29. Dodatna unutarnja jedinica za hlađenje ulja[Autor]



Slika 30. Novi termo par(desno) za mjerenje temperature okoline[Autor]



Slika 31. Regulator temperature ulja[Autor]

Slika 32. pokazuje gotovu verziju rashladnog sustava stroja, ne samo što smo dobili bolje hlađenje ulja nego isto tako puno preglednije kućište zbog uklanjanja dijelova koja više nisu potrebna što će olakšati sva buduća održavanja koja budu potrebna.

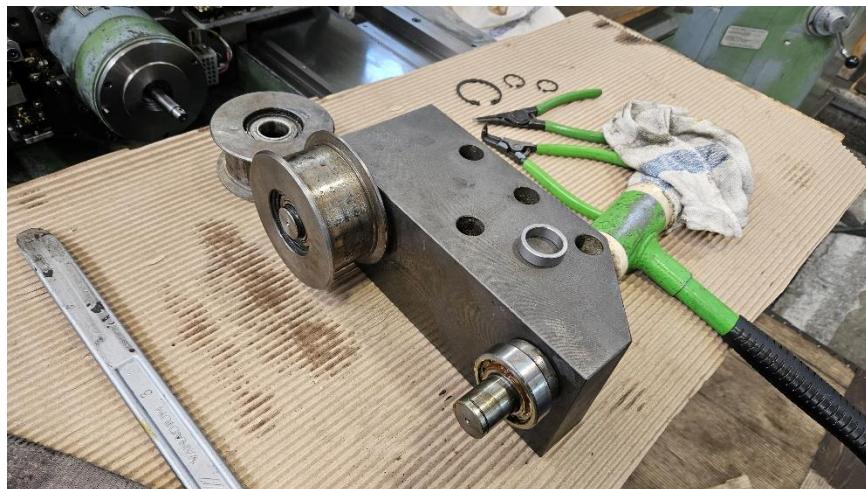


Slika 32. Izgled kućišta hladnjaka nakon ugradnje novog sustava[Autor]

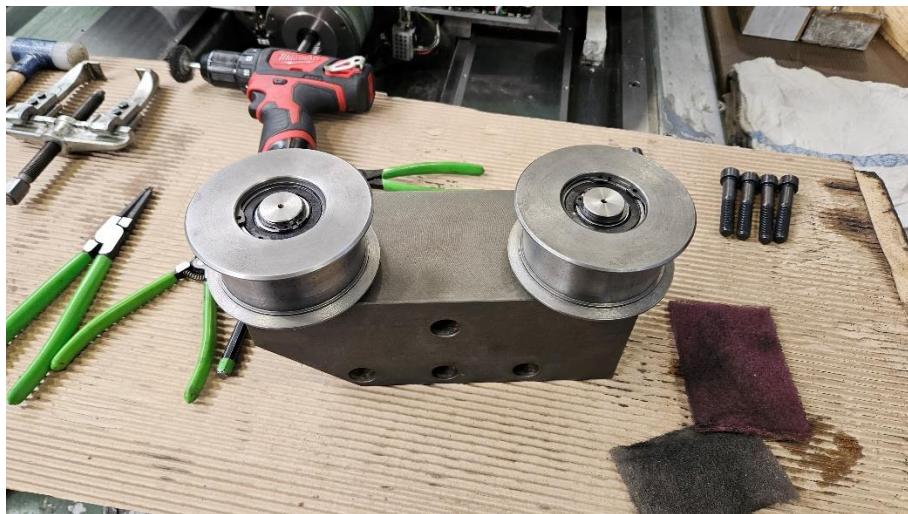


Slika 33. Nekorišteni dijelovi starog sustava hlađenja[Autor]

Na slikama 34. i 35. možemo vidjeti dvije koloture sa nosačem po kojem kliže lanac. Koloture su osvježene i stavljeni su novi ležaji.



Slika 34. Koloture za prijenos lanca za protu uteg[Autor]



Slika 35. Osvježene koloture s novim ležajima[Autor]

Na slici 36. možemo vidjeti razliku u duljini između dva lanca. Svrha lanaca je povezivanje protu utega sa Y-osi. Produljene starog lanca je 18 mm, što je utjecaj konstantnog pomicanje iste osi i samog tereta utega.



Slika 36. Novi i stari lanac[Autor]

Postavljanje novih lanaca i čišćenje kolotura bila je jedna od zadnjih operacija prije čišćenja okoline stroja i same pripreme za završno umjeravanje stroja tzv. geometrija stroja. Prije početka geometrije bilo je potrebno ozračiti sve hidrauličke cilindre slika 37.



*Slika 37. Ozračivanje hidrauličkih cilindara[Autor]*

### 8.3. Geometrija stroja

Geometrija se izvodi putem zadanih protokola danih od proizvođača koje ćemo opisati u nastavku rada. Na slici 38. možemo vidjeti nosač stroja pomoću kojeg se može namještati ravnost stroja. Stroj je sastoji od 8 takvih nosača što nam omogućuje vrlo precizno namještanje, također stroj leži na vlastitim temeljima odnosno odvojen je od ostatka proizvodnog objekta kako bi se minimalizirao utjecaj vibracija.



Slika 38. Nosač stroja[Autor]

Na slici 39. vidimo uređaj pomoću kojeg određujemo ravnost stroja. Kako bi se dobila što veća ravnost stol stroja se pozicionira na osam točaka, tada pomoću mjernog instrumenta očitamo vrijednosti te potom otpuštamo ili zatežemo maticu na nosaču stroja kako bi ga podigli ili spustili na potrebnu visinu kako bi doveli stroj u traženi položaj.



Slika 39. Mjerni instrument za provjeru ravnosti stroja[Autor]



Slika 40. Alat za geometriju stroja[Autor]

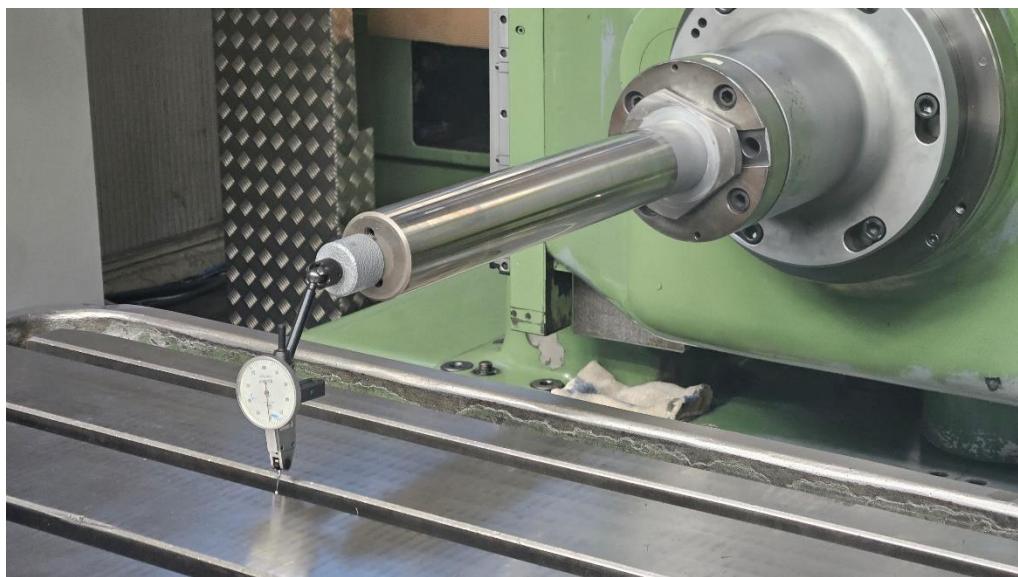
Mjerenje paralelnosti stola (slika 41.) izvodi se na način da pozicioniramo stol na poziciju X=500 mm, Z=400 mm, te postavimo etalon na radijus približno 400 mm. Nakon toga nuliramo sat i okrećemo stol na 8 pozicija ( $B_1=30^\circ$ ,  $B_2=70^\circ$ ,  $B_3=110^\circ$ ,  $B_4=150^\circ$ ,  $B_5=210^\circ$ ,  $B_6=250^\circ$ ,  $B_7=290^\circ$ ,  $B_8=330^\circ$ ) te uzimamo srednju vrijednost. To nam je bio drugi indikator problema sa stolom uz prvi vizualni, a to je sama površina stola koja je također tuširana no kod nas je brušena što dovodi do loših mjerena kao što smo mogli i vidjeti u rezultatima ispitivanja.



Slika 41. Ispitivanje paralelnosti površine s kliznim stazama stola[Autor]

Sljedeći korak je mjerjenje paralelnosti kliznih staza stola s uzdužnim i transverzalnim kliznim stazama slika 45.. Za uzdužno mjerjenje pozicioniramo stol na X=500 mm te putujemo po z-osi od Z1=70 mm do Z2=730 mm i zabilježimo vrijednosti mjerjenja nakon toga okrenemo stol za 180° i očitamo vrijednosti.

Isto to ponovimo za transverzalno mjerjenje samo se ovdje pozicioniramo na Z=400 mm i putujemo po x-osi od X1=100 mm do X2=900 mm.



*Slika 45. Mjerjenje paralelnosti stola s kliznim stazama[Autor]*

Nakon toga slijedi mjerjenje ravnosti uzdužnih i transverzalnih kliznih staza slika 46. Za mjerjenje uzdužne ravnosti kliznih staza također se koristimo vretenom na koji montiramo dva mjerna sata nakon toga pozicioniramo stol na X=500 mm.

Potrebno se pozicionirati tri puta po z-osi ( $Z_1=150$  mm,  $Z_2=400$  mm,  $Z_3=700$  mm) te na svakoj to poziciji se putuje po y osi od  $Y_1=100$  mm do  $Y_2=700$  mm. Nakon toga dobivamo tri izmjere za uzdužnu i transverzalnu ravnicu, tada uzimamo srednju vrijednost za svaku. Isto tako ponovimo i za mjerjenje transverzalnih kliznih staza samo se tu pozicioniramo na  $Y=150$ , a po x-osi ( $X_1=100$  mm,  $X_2=500$  mm,  $X_3=900$  mm) putujemo kao i po y-osi ( $Y_1=100$  mm do  $Y_2=700$  mm).

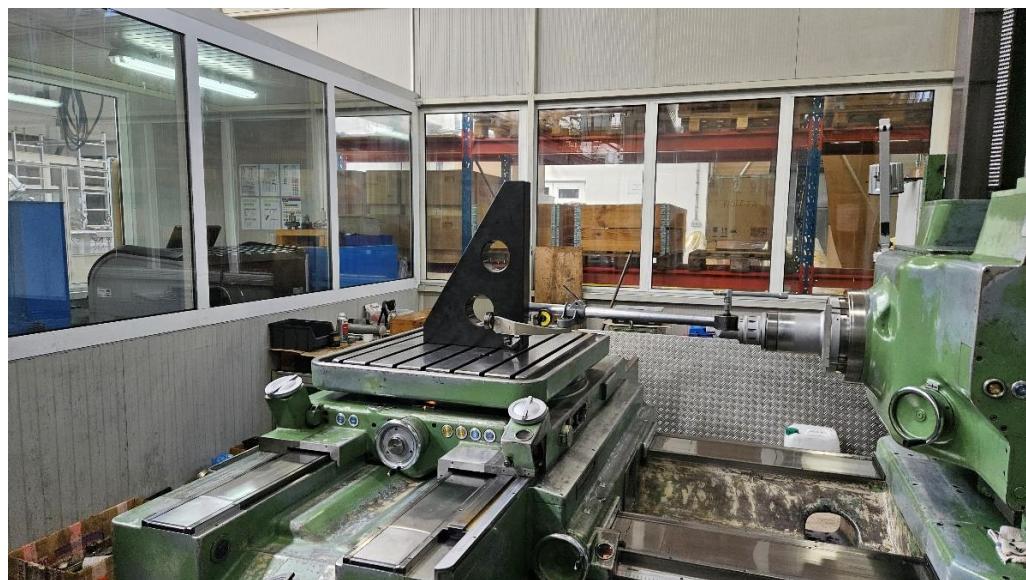
Pomoću istog etalona provjeravali smo ravnost stola s obzirom na visinu koja je iznosila 300 mm. Tu se stol pozicionira na  $X=500$  mm,  $Z=230$  mm,  $B=0^\circ$ , a etalon na sredinu stola te se pomoću dva mjerna sata izmjere odstupanja koja su nastala od početka pa do kraja ispitivanja.

Isto to ponovimo ali okrenemo stol na poziciju  $B=180^\circ$  te ponovno izmjerimo. S ovim ispitivanjem smo dobili još jedan rezultat koji nam pokazuje oštećenje stola kao i u mjerjenjima prije.



Slika 46. Mjerjenje ravnosti kliznih staza[Autor]

Na slici 47. vidimo mjerjenje pravokutnosti stola u odnosu na okomite staze. Kao što možemo vidjeti mjerjenje se vrši s vretena pomoću dva mjerna sata, stol se postavlja na poziciju  $X=500$  mm,  $Z=150$  mm,  $B=0^\circ$ . Nakon toga se putuje po etalonu od  $Y_1=100$  mm do  $Y_2= 400$  mm. Kao rezultat dobijemo dvije vrijednosti  $D_1$  i  $D_2$  za uzdužnu i za transverzalnu ravninu gdje izabiremo prosjek za iste. Sve se isto ponovi samo stol bude zakrenut na položaj  $B=180^\circ$ .



Slika 47. Mjerjenje pravokutnosti stola prema okomitim kliznim stazama[Autor]

Na slici 48. možemo vidjeti način mjerjenja ravnosti za vertikalne klizne staze odnosno stupove (y-os). Mjerenje se vrši sa stola tako da postavimo mjerni sat na sami stol te mjerimo u vodoravnoj i okomitoj ravnini u odnosu na ispitnu osovINU u vretenu. Duljina osovine iznosi  $D=250$  mm, te postavljamo stol na poziciju  $Z1=300$  mm i putujemo do  $Z2=550$  mm koristeći tri visine  $Y1=100$  mm,  $Y2=400$  mm,  $Y3=700$  mm.

Nakon mjerjenja dobijemo tri vrijednosti ( $D1$ ,  $D2$ ,  $D3$ ) za svaku od ravnina gdje onda tražimo srednju vrijednost.



Slika 48. Mjerenje ravnosti stupova[Autor]

Nakon toga je potrebno izmjeriti pravokutnost vretena u odnosu na transverzalnu kliznu stazu (slika 49). To radimo tako da mjerni sat montiramo na stol stroja, a kontrolnu šipku s adapterom montiramo na vreteno. Postavimo vreteno na visinu  $Y=250$  mm a stola na prvu poziciju  $X1=300$  mm i zapišemo vrijednost. Nakon toga pomaknemo stol na poziciju  $X2=700$  mm i okrenemo vreteno za  $180^\circ$  i očitamo razliku između dva mjerena. Nakon mjerena smo saznali da imamo odstupanja zbog ležaja vretena koje je bilo istrošeno. Trošenje je došlo uslijed već spomenute temperature ulja koja je bila previsoka zbog nedostatka hlađenja.

Isto tako mjerimo i pravokutnost vretena u odnosu na vertikalnu kliznu stazu samo što kod ovog mjerena se pozicioniramo na  $X=500$  mm i pomičemo se po y-osi od  $Y1=50$  mm do  $Y2=450$  mm.

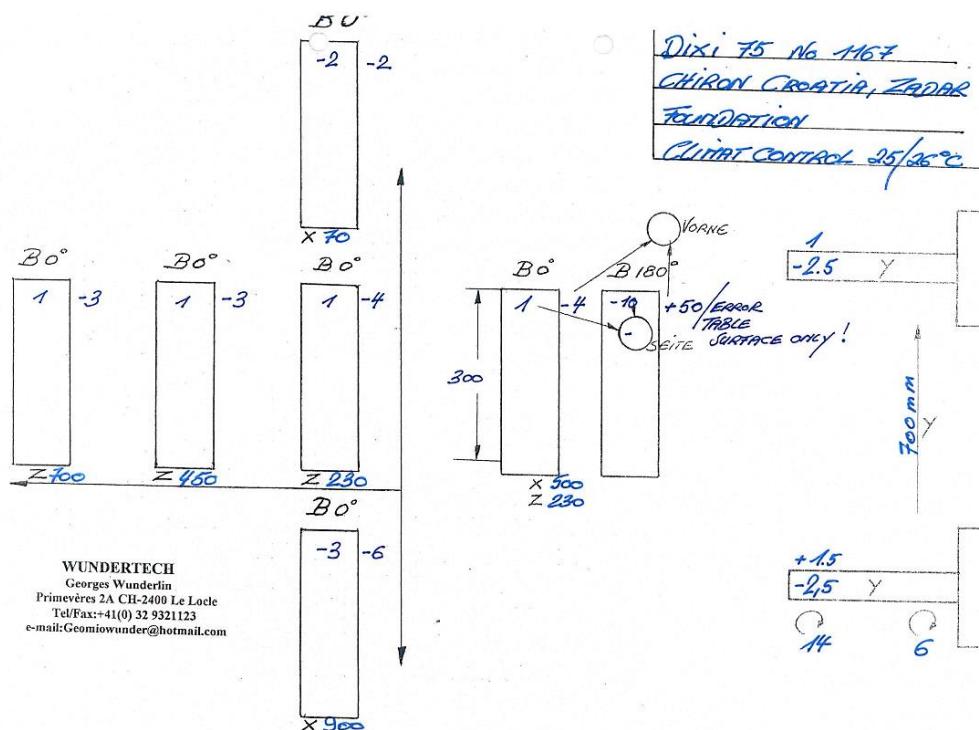


Slika 49. Mjerenje pravokutnosti vretena[Autor]

Potrebno je izmjeriti koncentričnost konusa prirubnice vretena tako da postavimo mjerni sat na stol te rotiramo vreteno  $360^\circ$  i mjerimo razliku odstupanja između maksimuma i minimuma. Nakon toga je potrebno mjeriti aksijalno odstupanje prirubnice vretena na isti način kao i konus.

I za kraj ispitivanja geometrije još mjerimo aksijalni pomak vretena na način da sat postavimo na isti način kao i kod mjerjenja odstupanja prirubnice samo rotiramo vreteno n puta u trajanju 1 minute i mjerimo prosječno odstupanje između maksimuma i minimuma (M1), isto ponovimo i u suprotnom smjeru rotacije vretena te time dobijemo (M2). Tako dobijemo prosječnu vrijednost odstupanja između M1 i M2. To nam je bio dodatan pokazatelj oštećenja ležaja vretena.

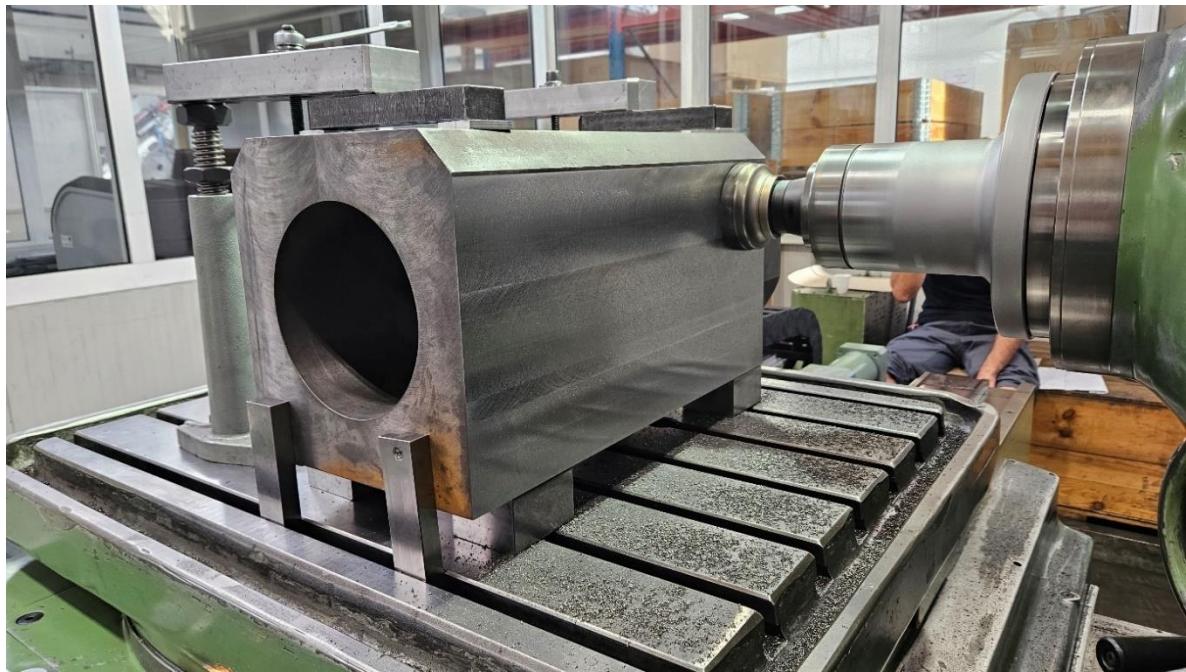
Na slici 50. možemo vidjeti konačne rezultate ispitivanja nakon podešavanja stroja tokom geometrije stroja.



Slika 50. Konačni rezultati mjerjenja[Autor]

## 8.4. Testiranje

Nakon detaljno obrađene geometrije stola potrebno je obraditi testni obradak kako bi uvidjeli koliko je stroj poboljšan u odnosu na stanje prije remonta. Prvi korak je poravnati čela kako bi se obradak mogao centrirati.



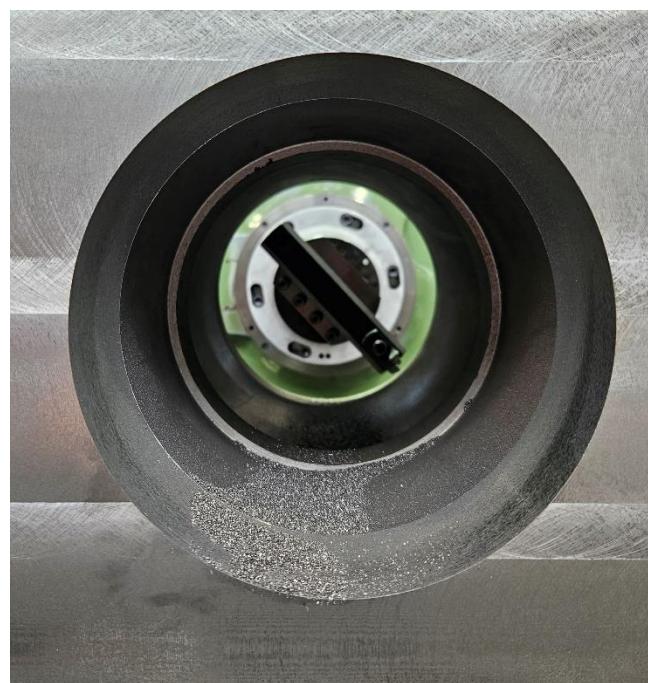
*Slika 51. Ravnanje čela obratka[Autor]*



*Slika 52. Centriranje obratka[Autor]*



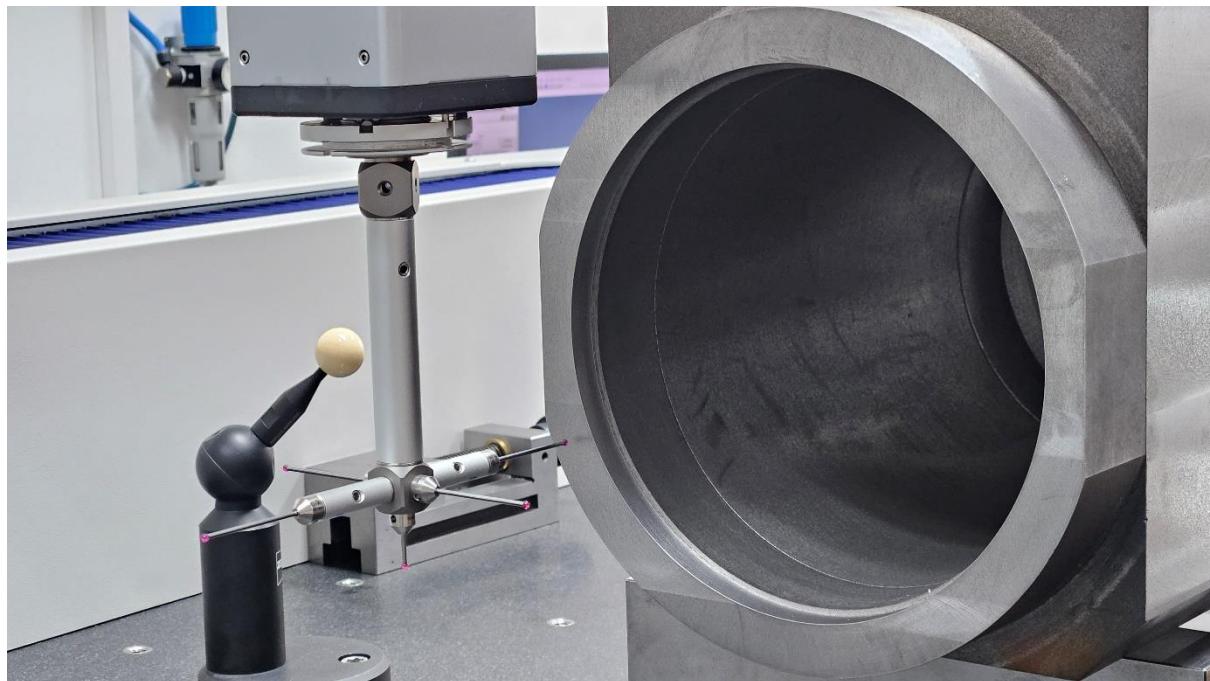
*Slika 53. Priprema alata za završnu obradu na mjeru[Autor]*



*Slika 54. Završna obrada na mjeru[Autor]*

## 8.5. Završna kontrola

Nakon završne obrade obradak se odvezao u prostoriju kontrole gdje je odležao neko vrijeme kako bi se ohladio i bio spremna za završnu kontrolu. U ovom ispitivanju mjerili smo međusobnu okomitost i paralelnost te ravnost obrađenih baza. Nakon kontrole smo zaključili da je preciznost stroja oko  $4 \mu\text{m}$  što zadovoljava naše standarde.



Slika 55. Završna kontrola testnog obratka[Autor]

## **9. Zaključak**

Što se tiče prvog dijela ovog rada kao zaključak možemo reći da je prediktivno održavanje definitivno budućnost održavanja kao grane strojarstva, jer nam omogućuje puno bolji uvid na samo održavanje i na buduće zahvate na strojevima. Implementacija ove vrste održavanja nosi sa sobom jedan poveći nedostatak, a to je cijena zbog velike količine senzora te programiranje istih, tako da većina tvrtki to još ne uvodi u svoja postrojenja

Zaključak eksperimentalnog dijela ovog rada je vrlo jednostavan, a to je da redovito održavanja ključ dugoročne preciznosti stroja, a time i uspjeh poslovanja tvrtke. Što se tiče našeg stroja mogli smo vidjeti kako je neredovito odnosno loše održavanje kroz povijest dovelo do nepovratnog uništenja dijelova stroja (V klizne staze X-Osi), a time gubitak preciznosti i pouzdanosti stroja. Takva vrsta održavanja (kurativno održavanje) je zastarjeli koncept održavanje, gdje se izvode „samo“ popravci stroja po potrebi te nakon manjih ili većih havarija, a kao zastarjeli koncept održavanja, dovodi do povećanja i prekoračenja troškova suvremenog održavanja. Pri ovom remontu se pokazalo kako je navedena filozofija kurativnog održavanja najnepovoljniji oblik održavanja te je budžet za remont probijen nekoliko puta.

Konačan cilj ovog rada je bilo pokazati razliku između dva načina održavanja korektivno i prediktivno. Pokazati napredak u načinu održavanja strojeva i sustava kroz povijest, odnosno pokazati gdje smo bili i gdje smo sad.

## **10. Literatura**

- [1] -<https://www.grandviewresearch.com/industry-analysis/predictive-maintenance-market>
- [2] - Lasi, H.; Fettke, P.; Kemper, H.-G.; Feld, T.; Hoffmann, M. Industry 4.0. Bus. Inf. Syst. Eng. 2014.
- [3] - Li, Z.; Wang, Y.; Wang, K.-S. Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. Adv. Manuf. 2017.
- [4] - Bécue, A.; Praça, I.; Gama, J. Artificial intelligence, cyber-threats and Industry 4.0: Challenges and opportunities. Artif. Intell. Rev. 2021.
- [5] - Cakir, M.; Guvenc, M.A.; Mistikoglu, S. The experimental application of popular machine learning algorithms on predictive maintenance and the design of IIoT based condition monitoring system. Comput. Ind. Eng. 2020.
- [6] - Pedreira, V.; Barros, D.; Pinto, P. A review of attacks, vulnerabilities, and defenses in industry 4.0 with new challenges on data sovereignty ahead. Sensors 2021.
- [7] - <https://celltrackingapps.com/hack-cell-phone/>
- [8] - Pilloni, V. How Data Will Transform Industrial Processes: Crowdsensing, Crowdsourcing and Big Data as Pillars of Industry 4.0. Future Internet 2018.
- [9] - Levitt, J. Complete Guide to Preventive and Predictive Maintenance; Industrial Press Inc.: New York, NY, USA, 2003.
- [10] - Lee, J.; Ni, J.; Singh, J.; Jiang, B.; Azamfar, M.; Feng, J. Intelligent Maintenance Systems and Predictive Manufacturing. J. Manuf. Sci. Eng. 2020.
- [11] - Poór, P.; Basl, J.; Zenisek, D. Predictive Maintenance 4.0 as next evolution step in industrial maintenance development. In Proceedings of the 2019 International Research Conference on Smart Computing and Systems Engineering (SCSE), Colombo, Sri Lanka, 28 March 2019.

[12] - Nacchia, M.; Fruggiero, F.; Lambiase, A.; Bruton, K. A Systematic Mapping of the Advancing Use of Machine Learning Techniques for Predictive Maintenance in the Manufacturing Sector. *Appl. Sci.* 2021

[13] - zu Wickern, V.F.M. Challenges and Reliability of Predictive Maintenance. Master's Thesis, Faculty of Communication and Environment, Rhine-Waal University of Applied Sciences, Kleve, Germany, 2019.

[14] - Keleko, A.T.; Kamsu-Foguem, B.; Ngouna, R.H.; Tongne, A. Artificial intelligence and real-time predictive maintenance in industry 4.0: A bibliometric analysis. *AI Ethics* 2022

[15] - Mousavi, S. Simultaneous Control of the Production, Maintenance, and Inspection Strategies for a Failure-Prone Manufacturing System with Quality-Based Financial Penalties/Incentives. Ph.D. Thesis, École de Technologie Supérieure, Montreal, QC, Canada, 2021.