



Learner Centric Advanced Manufacturing Platform



Vplivi digitalnih tehnologij 4.0 in zelenega prehoda na napovedno vzdrževanje

WP3 – Observatorij - D3.2 - M36 - PdM report



**Co-funded by
the European Union**

Funded by the European Union. Views and opinions expressed are however those of the author(s) only and do not necessarily reflect those of the European Union or the European Education and Culture Executive Agency (EACEA). Neither the European Union nor EACEA can be held responsible for them.



Co-funded by
the European Union

Financirano s strani Evropske unije. Vendar pa so izražena mnenja in stališča izključno mnenja avtorja(-jev) in ne odražajo nujno stališč Evropske unije ali Izvajalske agencije za izobraževanje in kulturo (EACEA). Niti Evropska unija niti EACEA ne moreta biti odgovorni zanje.



To delo je licencirano s strani partnerstva LCAMP pod licenco Creative Commons Priznanje avtorstva – Nekomercialno 4.0 Mednarodna.

LCAMP partnerji:

TKNIKA – Baskovski center za uporabne raziskave v poklicnem izobraževanju, CIFP Miguel Altuna LHII, DHBW Heilbronn – Dualna visoka šola Baden-Württemberg, Curt Nicolin High School, AFM – Špansko združenje industrij za obdelovalne stroje, EARLALL – Evropsko združenje regionalnih in lokalnih oblasti za vseživljenjsko učenje, FORCAM, CMQE: Združenje kampusa za poklice in kvalifikacije industrije prihodnosti, MV: Mecanic Vallée, KIC: Center za inovacije in znanje, MADE Competence Centre Industria 4.0, AFIL: Združenje inteligentne tovarne Lombardija, SIMUMATIK AB, Združenje HVC – Združenje slovenskih višjih strokovnih šol, TSCMB: Tehniški šolski center Maribor, KPDoNE: Direktorat za nacionalno izobraževanje Kocaeli, GEBKİM OIZ in Camosun College.



Povzetek dokumenta

Vrsta dokumenta:	Javno poročilo
Naslov	Predloga za ustvarjanje poročil LCAMP
Avtor/ji	Pascal Pichoutou
Soavtorji	Ralf Steck, Camille Leonard, Jesus Rebolledo
Sodelujoči	Vesna Novak, Mikel Ayani, Eda Ipek
Recenzent	Hervé Danton
Datum	januar 2025
Stanje dokumenta	0,5
Raven dokumenta	Zaupno do objave
Opis dokumenta	Ta dokument opisuje glavne vplive novih tehnologij na področju prediktivnega vzdrževanja in njihove posledice za prilagajanje organizacij in veščin.
Citiraj ta rezultat kot:	Cohen et al., L. Predloga za ustvarjanje poročil LCAMP (LCAMP4.0 Deliverable D9.1, december 2023)
Raven dokumenta	Javno

Upravljanje različic

Različica	Datum	Akcija
0,1	2025-02-07	Osnutek različice, tloris definiran
0,5	2025-04-07	Osnutek različice s prispevki partnerjev
0,8	2023-04-17	Končna različica za notranjo revizijo
0,9	2023-04-28	Končna različica za postopek revizije
0,95		Odobritev s strani usmerjevalnega odbora
1		Različica, ki bo naložena na EU portal



SLOVAR IN/ALI OKRAJŠAVE

AFDET - Francosko združenje za razvoj tehničnega izobraževanja
AFM – Asociación de Fabricantes de Máquina Herramienta - Združenje proizvajalcev obdelovalnih strojev
AFNOR - Francosko združenje za standardizacijo
AI – umetna inteligenca
AR – razširjena resničnost
CAGR - Sestavljena letna stopnja rasti
CAM - Računalniško podprta proizvodnja
CMMS - Računalniški sistem za upravljanje vzdrževanja
CNC - Računalniško numerično krmiljenje
CoVE – centri poklicne odličnosti
EaaS – oprema kot storitev.
EQF - Evropsko ogrodje kvalifikacij
ESCO - Evropske spretnosti, kompetence, kvalifikacije in poklici
HVET - Višje poklicno izobraževanje in usposabljanje
IoT – Internet stvari
IT - Informacijska tehnologija
IUT - Univerzitetni inštitut za tehnologijo
LCAMP - Na učenca osredotočena napredna proizvodna platforma
LLM - Large Language Model
MV - Mecanic Vallée
PdM – Prediktivno vzdrževanje
PLC - Programabilni logični krmilnik
MSP - Mala in srednje velika podjetja
TKNIKA - Center za uporabne raziskave v poklicnem usposabljanju v Baskiji.
TPM – Popolno produktivno vzdrževanje
VR - Virtualna resničnost
WP - delovni paket



1.	Kazalo	
POVZETEK		6
1. UVOD		7
1.1.	Pričevanje podjetja	7
1.1.	Namen poročila	8
1.2.	Metodologija	10
2. RAZVOJ STRATEGIJ VZDRŽEVANJA		19
2.1.	Vzdrževanje – definicije	19
2.2.	Optimalna strategija vzdrževanja	21
2.1.	Predvideno vzdrževanje - korak pred predpisanim vzdrževanjem	22
3. PDM - KONTEKST		23
3.1.	Tržni obeti in projekcije rasti	23
3.2.	Tehnološki razvoj in prevzem	26
3.3.	PdM kot storitev (PdMaaS): stroškovno učinkovita in razširljiva rešitev	28
4. PDM - TEHNOLOŠKI TEMELJI		30
4.1.	Kako deluje PdM	32
4.2.	PdM pomembni izzivi	42
4.3.	Evolucija v smeri generativne umetne inteligence	43
4.4.	Nastajajoči modeli in tehnologije	47
5. VPLIV PDM V VZDRŽEVALNIH DEJAVNOSTIH NA MSP		54
5.1.	Vloga PdM v MSP	54
5.2.	Najboljše prakse za MSP, ki izvajajo PdM	55
5.3.	Vpliv na organizacije	56
5.4.	Vpliv na delovno silo	56
5.5.	Študija primera	58
5.6.	Prihodnji trendi v PdM za MSP	59
5.7.	Rezultati raziskave PdM, poslani MSP	60
5.8.	Prihodnje perspektive in priporočila	73
6. VPLIV PDM NA USPOSABLJANJE IN CENTRE ZA USPOSABLJANJE		74
6.1.	Najsodobnejše usposabljanje za vzdrževanje	74
6.2.	Razvoj usposabljanja za vzdrževanje v digitalni dobi	76
6.3.	Izzivi in priložnosti za izobraževalne centre	77
6.4.	Usposobljene veščine in vpliv PdM	77
6.5.	Vloga MaaS pri usposabljanju	78
6.6.	Rezultati raziskave PdM, poslani na centre za poklicno izobraževanje in usposabljanje	79
6.7.	Povzetek	90
7. PDM: GONILNA SILA ZA ZELENO PREOBRAZBO		93
8. OBETI IN SKLEP		95
8.1.	Obeti: Prihodnji trendi in priložnosti	95
8.2.	Sklep	96
9. LITERATURA		98
10. INDEKS SLIK		107
11. KAZALO TABEL		109
12. PRILOGA		110
12.1.	Priloga 1 - Ciljna publika ANKET	110
12.2.	Priloga 2 – Obseg napovedi globalnega razvoja trga PdM	113
12.3.	Priloga 3 - 21 metod razlagalnega strojnega učenja (IML)	115
12.1.	Priloga 4 – Primeri tečajev usposabljanja za vzdrževanje	117



POVZETEK

Projekt LCAMP (Learner-Centric Advanced Manufacturing Platform) si v okviru pobude CoVE prizadeva izboljšati regionalna znanja na področju napredne proizvodnje s spodbujanjem sodelovanja, odpornosti in inovacij.

To poročilo, razvito v okviru opazovalnice LCAMP, ki jo vodita francoski grozd Mecanic Vallée in francoski center za poklicno izobraževanje Campus des Métiers et des Qualifications Industrie du Futur, analizira vpliv digitalnega in zelenega prehoda na delovna mesta in kompetence v napredni proizvodnji.

V tretjem letu raziskava preučuje, kako tehnologije Industrije 4.0 in trajnostni trendi vplivajo na prediktivno vzdrževanje in prilagajanje delovne sile, pri čemer poudarja usklajenost programov poklicnega izobraževanja in usposabljanja (VET) s potrebami industrije.

Raziskavo so izvedli partnerji LCAMP iz Francije, Švedske, Nemčije, Italije in Slovenije, pri čemer preučujejo znanja in usposabljanja, potrebna za digitalno in zeleno preobrazbo v proizvodnji.

To poročilo, ki temelji na **pregledu literature, intervjujih in anketah s centri za poklicno izobraževanje in usposabljanje ter industrijskimi podjetji**, poudarja **trenutno stanje sprejemanja PdM, ključne izzive in prihodnje trende**, ki oblikujejo njegov razvoj. Glavne ugotovitve so:

- **PdM se povečuje**, vendar mnoga **MSP ostajajo v zgodnjih fazah** in se soočajo z **visokimi stroški, tehničnimi ovirami in izzivi integracije**.
- **Analitični** (strojno učenje, globoko učenje...) **in generativni AI, IoT in strojno učenje** so **najbolj vplivne tehnologije**, ki spodbujajo **spremljanje v realnem času, napovedno analitiko in avtomatizacijo**.
- **Pomanjkanje spretnosti je velika ovira**, saj mala in srednja podjetja težko najdejo **usposobljene strokovnjake za AI, IoT, kibernetsko varnost in analitiko podatkov**.
- **Vzdrževanje kot storitev (MaaS) pridobiva na moči**, kar majhnim in srednje velikim podjetjem omogoča **dostop do rešitev PdM brez velikih vnaprejšnjih naložb**.
- **Trajnost je vse večja prednostna naloga**, saj PdM podjetjem pomaga **zmanjšati porabo energije, odpadke in ogljični odtis**.
- **Institucije poklicnega izobraževanja in usposabljanja (VET) morajo prilagoditi učne načrte potrebam Industrije 4.0**, da bodo vzdrževalni operaterji pridobili dopolnilna znanja, ki presegajo njihovo osnovno strokovno usposobljenost. Poleg tradicionalnega znanja o vzdrževanju morajo delavci razviti spretnosti na področju integracije interneta stvari (IoT), analitike, podprte z umetno inteligenco, kibernetske varnosti ter sposobnost upravljanja zunanjih partnerstev. Te razširjene kompetence jim bodo omogočile učinkovito izvajanje rešitev za prediktivno vzdrževanje (PdM) in uspešno prilagajanje vse večji digitalizaciji industrijskega vzdrževanja.

Z obravnavo teh izzivov z **naložbami v spretnosti, finančno podporo in nove modele storitev** lahko MSP **povečajo učinkovitost, zmanjšajo stroške vzdrževanja in okrepijo svojo konkurenčno prednost v razvijajočem se industrijskem okolju**.



1. UVOD

1.1. PRIČEVANJE PODJETJA

Od uvajanja celovitega produktivnega vzdrževanja (TPM) do rešitev za predvideno vzdrževanje (PdM).

Južnonemški avtomobilski dobavitelj, specializiran za plastiko, se je soočil z velikimi izzivi: konkurenco, ukinitvijo proizvodnje, 50-odstotnim padcem prometa, zmanjšanjem delovne sile in zaprtjem obratov. Da bi ohranili učinkovito maloserijsko proizvodnjo, je podjetje leta 2012 uvedlo TPM in se osredotočilo na proaktivne strategije vzdrževanja.

TPM, ki ga je razvil Seiichi Nakajima (Seiichi Nakajima, 2023), je namenjen povečanju učinkovitosti stroja in zmanjšanju izpadov. V vzdrževanje vključuje vse zaposlene, zlasti prek »avtonomnega vzdrževanja«, kjer operaterji opravljajo preprosta opravila. TPM optimizira splošno učinkovitost opreme (OEE) z zmanjšanjem šestih ključnih izgub: nenačrtovani izpadi, časi menjave, manjše okvare, izgube hitrosti, napake v kakovosti in napake pri zagonu. Zgrajen na osmih stebrih, vključno z načrtovanim vzdrževanjem, izboljšavami učinkovitosti, usposabljanjem, zagotavljanjem kakovosti, vodstvom in varnostjo, si TPM prizadeva za 'nič izpadov' in 'nič napak.'

Podjetje je prešlo iz reaktivnega k preventivnemu vzdrževanju z dokumentiranjem okvar strojev, uporabo računalniškega sistema za upravljanje vzdrževanja (CMMS) in usposabljanjem ekip za preventivne tehnike. Zbiranje podatkov na osnovi senzorjev je postavilo temelje za predvideno vzdrževanje (PdM), katerega namen je izboljšati varnost delovanja in zmanjšati stroške.

Vendar so se zgodnja prizadevanja PdM soočila z izzivi. Stroji niso imeli standardiziranih vmesnikov, kar je oteževalo zbiranje podatkov. Začetna analiza je temeljila na ročnih izvozih CSV in Excelovih izračunih, kar je omejilo natančnost. Visokokakovostni podatki v realnem času so bili bistveni za zanesljive napovedi, vendar so vrzeli v infrastrukturi in strokovnem znanju upočasnile napredek. Ovire je predstavljal tudi kulturni odpor do odločanja na podlagi podatkov. Kljub tem izzivom je tovarna uvedla sledenje OEE, optimizirala inventar rezervnih delov in izvedla obvladovanje tveganja, da bi izboljšala strategije PdM.

Vzpon interneta stvari (IoT), umetne inteligence (AI) in strojnega učenja (ML) je od takrat spremenil PdM. Napredni senzorji omogočajo neprekinjeno spremljanje, računalništvo v oblaku olajša obdelavo podatkov v realnem času, analitika, ki jo poganja AI, pa izboljša napovedi napak. Te tehnologije presegajo prejšnje omejitve z avtomatizacijo zbiranja podatkov, izboljšajo natančnost napovedovanja in zmanjšajo človeško posredovanje. Vendar uspešno sprejetje še vedno zahteva usposobljeno osebje in kulturne premike k vzdrževanju, ki temelji na podatkih.

Za MSP je PdM še vedno premalo izkoriščena priložnost. Sprejemanje IoT, AI in ML lahko znatno poveča konkurenčnost, če se odpravijo vrzeli v strokovnem znanju. Pot do inteligentnega vzdrževanja je v teku, tehnologija zdaj ponuja orodja za uresničitev 'nič izpadov'.

Ralf Steck – nekdanji vodja oddelka za brizganje in metalizacijo / odeloD



1.1. NAMEN POROČILA

Ker industrijski sistemi postajajo vse bolj zapleteni, so zagotavljanje zanesljivosti strojev, zmanjševanje izpadov in optimizacija stroškov vzdrževanja postali ključni izzivi za podjetja. Tradicionalne strategije vzdrževanja – **reaktivni in preventivni pristopi** – pogosto vodijo do neučinkovitosti, nepričakovanih okvar in pretiranih operativnih stroškov. V odgovor **Prediktivno vzdrževanje (PdM) revolucionira industrijsko vzdrževanje** in preusmerja podjetja od reaktivnih posegov k **proaktivnemu odločanju, ki temelji na podatkih**.

Pojav **tehnologij industrije 4.0** – vključno z **umetno inteligenco (AI)**, **internetom stvari (IoT)**, **digitalnimi dvojčki in analitiko velikih podatkov** – pospešuje to preobrazbo. Hkrati pa **zeleni prehod** nalaga industrijam nove zahteve glede trajnosti in učinkovitosti. V tej razvijajoči se pokrajini **PdM ni le tehnološka nadgradnja; je strateška nuja** za optimizacijo uspešnosti sredstev, zmanjšanje operativnih tveganj in spodbujanje stroškovne učinkovitosti.

Za **mala in srednje velika podjetja (MSP)** PdM ponuja konkurenčno prednost z izboljšanjem časa delovanja opreme in zmanjševanjem stroškov vzdrževanja. Vendar široko sprejetje še vedno **ovirajo ključne ovire**, kot so **visoki stroški uvedbe, pomanjkanje usposobljenega osebja in izzivi tehnološke integracije**.

Vzporedno imajo **institucije poklicnega izobraževanja in usposabljanja (VET)** ključno vlogo pri pripravi bodoče delovne sile na te spremembe. Ker se vzdrževanje usmerja k **diagnostiki in napovedni analizi, ki temelji na umetni inteligenci**, **se morajo programi usposabljanja razvijati**, da bodo strokovnjake opremili s **tehničnimi, digitalnimi in podatkovno vodenimi veščinami odločanja**, ki so potrebne v sodobni industriji.

To poročilo preučuje, kako **PdM preoblikuje industrijsko vzdrževanje**, raziskuje **tehnološke, gospodarske posledice in posledice za delovno silo** ter zagotavlja **strateške vpoglede za mala in srednja podjetja ter institucije poklicnega izobraževanja in usposabljanja** za učinkovito krmarjenje po tem prehodu.

Namen tega poročila

Glavno vprašanje je: Kako nastajajoče digitalne tehnologije 4.0 in trendi zelenega prehoda vplivajo na predvideno vzdrževanje, kako vplivajo na vzdrževalne dejavnosti znotraj panog, trga in delovnih mest, centrov za poklicno izobraževanje in usposabljanje ter učne poti?

Namen tega poročila je zagotoviti uporabna merila uspešnosti in strateške vpoglede za dve ključni ciljni skupini:

- Za **MSP**: ponuja jasen načrt za prevzem PdM, obravnavanje izzivov in izkoriščanje nastajajočih digitalnih tehnologij za izboljšanje učinkovitosti vzdrževanja.
- Za **institucije poklicnega izobraževanja in usposabljanja**: opisuje, kako se lahko programi usposabljanja uskladijo s potrebami industrije in zagotavljajo, da so delavci opremljeni s kompetencami, povezanimi s PdM, ki podpirajo industrijo 4.0 in cilje zelenega prehoda.

Področje uporabe in obravnavana ključna vprašanja

Ta študija, ki so jo v okviru Observatorija LCAMP izvedli **partnerji LCAMP iz Francije, Švedske, Nemčije, Turčije, Italije, Slovenije in Turčije**, raziskuje presečišče nastajajočih digitalnih tehnologij 4.0, trendov zelenega prehoda in predvidenega vzdrževanja, s posebnim poudarkom na njihovih vplivih na industrijo, delovno silo in programe usposabljanja. Ključna obravnavana vprašanja vključujejo:

- Zakaj je PdM lahko vzvod za transformacijo znotraj vzdrževalnih organizacij in za konkurenčnost v podjetjih?
- Kateri so glavni dejavniki in ovire za sprejetje PdM v MSP?



- Kako trendi digitalnega in zelenega prehoda vplivajo na vzdrževalne dejavnosti in delovna mesta?
- Kakšne organizacijske in kadrovske transformacije so potrebne za učinkovito izvajanje PdM?
- Kako lahko institucije poklicnega izobraževanja in usposabljanja uskladijo programe usposabljanja s potrebami industrije, da premostijo vrzeli v spretnostih?
- Katera strateška priporočila lahko podpirajo MSP in institucije poklicnega izobraževanja in usposabljanja pri tej preobrazbi?

Izraz " **nastajajoče** " tukaj ne pomeni novosti tehnologij, temveč pojav v industrijskih sprejetih in implementacijah.

Metodologija

Spoznanja, predstavljena v tem poročilu, temeljijo na **celoviti analizi** , ki združuje:

- **Pregled literature** o trendih, tehnologijah in tržnih podatkih PdM
- **Anketni podatki** MSP in institucij poklicnega izobraževanja in usposabljanja v več evropskih regijah.

Ta strukturiran pristop zagotavlja, da poročilo zagotavlja **strateške vpoglede in praktične smernice** , zaradi česar je **dragocen vir za odločevalce v MSP in sektorju poklicnega izobraževanja in usposabljanja** .



1.2. METODOLOGIJA

Metodologija Observatorija LCAMP je opisana v poglavju Observatorija o procesnem ciklu, vključenem v dokument (D3-1-Observatory-Methodology-Final-Version-1-1.Pdf, nd) .


Vključuje:

- Metodologija za izbiro delovnih mest za analizo
- Metodologija za analizo vplivov
- Metodologija za potrjevanje podporačila

Letos je bil dodan dodaten kriterij za utemeljitev izbire polja opazovanja:

- Ustreznost »Polja za opazovanje« na podlagi 6 kriterijev, predhodno opisanih v metodologiji (obstoječa delovna mesta, vplivi trendov, zaposljivost, strateška tema, stopnja izobrazbe, tečajji usposabljanja Vpliv).
- Dodana vrednost za industrijske procese: predmet je vključen v vsaj eno od 7 transformacij, analiziranih v pobudi WP7, ki se nanaša na napredno Manufacturing scans: Pobuda LCAMP, ki podpira preoblikovanje MSP ('SME - VET Connection', nd) .

Zaradi razjasnitve ciljev vsake faze ter nadzora nad načrtovanjem in glavnimi roki procesa je bila metodologija v primerjavi s preteklimi leti jasnejša. Kot je prikazano v tem diagramu, sta stopnji 3 in 4 razdeljeni na 4 različne faze:



Slika 1. Metodologija observatorija LCAMP

Faza 4: Poleg pregleda literature in razprav s strokovnjaki s tega področja je bilo odločeno, da se izvedejo raziskave MSP in centrov za poklicno izobraževanje in usposabljanje, da se okrepijo sklepi pregleda literature.



1.2.1. FAZA 1 - UTEMELJITEV TEME PdM

Prva skupna analiza, izvedena s francoskimi, švedskimi, nemškimi, turškimi, italijanskimi in slovenskimi partnerji, je opredelila glavne razloge za izbiro te teme; pričujoče poročilo ponuja natančne informacije in potrjuje te začetne navedbe.

Ustreznost:

- Obstoječa delovna mesta: PdM in Vzdrževalci delujejo v okviru industrijskih podjetij.

Tabela 1. Primer seznama poklicev ESCO, vključenih v vzdrževalne dejavnosti (poklici, nd).

Esco koda	Šifra poklica Esco	Opis poklica Esco
2152.1.13	Strokovnjak Za predvideno vzdrževanje	Strokovnjaki za predvideno vzdrževanje analizirajo podatke, zbrane iz senzorjev, ki se nahajajo v tovarnah, strojih, avtomobilih, železnicah in drugih, da bi spremljali njihove pogoje, da bi uporabnike obveščali in na koncu obvestili o potrebi po vzdrževanju.
3515.1.6	Nadzornik strojnega vzdrževanja	Nadzorniki industrijskega vzdrževanja organizirajo in nadzirajo dejavnosti in vzdrževanje strojev, sistemov in opreme. Zagotavljajo, da se pregledi izvajajo v skladu z zdravstvenimi, varnostnimi in okoljskimi standardi ter zahtevami glede produktivnosti in kakovosti.
7212.3.2	Programiranje operaterja robota za lasersko varjenje + spremljanje proizvodnje in vzdrževanja	Varilci z laserskim žarkom postavljajo in skrbijo za varilne stroje z laserskim žarkom, ki so zasnovani za spajanje ločenih kovinskih obdelovancev skupaj z uporabo laserskega žarka, ki seva koncentriran vir toplote, ki omogoča natančno varjenje. Izbirne spretnosti in kompetence vključujejo "vzdrževanje mehanske opreme"
7411.1	Električni vzdrževalec	Električarji montirajo in popravljajo električna vezja in sisteme ožičenja. Montirajo in vzdržujejo tudi električno opremo in stroje. To delo je mogoče izvajati v zaprtih prostorih in na prostem, v skoraj vseh vrstah objektov.

- Vplivi trendov: Poganjajo jih številne nastajajoče digitalne tehnologije 4.0, kot so IoT, AI, strojno učenje, računalništvo Cloud-Base in analitika velikih podatkov, spreminjajo tradicionalne pristope vzdrževanja.
- Zaposljivost: širok spekter povpraševanja v vesoljski, avtomobilski, energetske in industriji 4.0.

Tabela 2. Zaposljivost vzdrževanja

DRŽAVA	VIR	KLJUČNA BESEDA	ŠTEVILO PONUDB
Francija	France Travail	"Vzdrževanje"	72 084
	APEC. "Iskanje zaposlitve - vzdrževanje".	"Vzdrževanje"	37 187
	lindustrie-recrute	"Vzdrževanje"	1 290



Nemčija	Statistika Zveznega zavoda za zaposlovanje	Prosta delovna mesta v "Tehnično servisno osebje pri vzdrževanju in popravilih, usposobljenih za naloge"	+1500
	Statistika Zveznega zavoda za zaposlovanje	dfBrezposelnih oseb v "Tehnično servisno osebje za vzdrževanje in popravilo usposobljeno nalogo"	+1000
Slovenija	Deloglasnik.si	Filtri: stopnja izobrazbe: EQF: 4,5,6 Cela država Področje dela: vzdrževanje in popravila	38
Italija	Randstad.it	Ključna beseda: "Vzdrževanje"	803
	Indeed.com	Ključna beseda: "Vzdrževanje"	+10000

- Ustreznost za strategijo pametne specializacije: 11 regij med 21 francoskimi regijami meni, da so vzdrževalne dejavnosti med prednostnimi nalogami.
- Raven izobrazbe: Usposabljanje za vzdrževanje, opredeljeno od EQF 4 do 6

Tabela 3. Primeri usposabljanja za vzdrževanje (izvleček vseh podrobnosti je na voljo v Prilogi 4)

Država	Vir	Opis tečaja usposabljanja	Raven EQF
Francija	IUT Rodez	Strokovna diploma iz vzdrževanja za industrijo prihodnosti (Industrija 4.0).	EQF 6
	UIMM / CFAI-AFPI	Višja nacionalna diploma iz vzdrževanja sistemov, možnost proizvodnega sistema.	EQF 5
	Lycée Alexis Monteil	Strokovna matura Vzdrževanje povezanih proizvodnih sistemov.	EQF 4
Slovenija	Društvo vzdrževalcev Slovenije (DVS)	Osnove vibracijske diagnostike in izbira ležajev, namestitvev in mazanje Ponudnik: Društvo vzdrževalcev Slovenije (DVS)	SOK/ EQF 5-6
	Srednješolski http://siclj.si/center http://siclj.si/Ljubljana (SIC Ljubljana)	programa usposabljanja za strojnike: Srednješolski center Ljubljana (SIC Ljubljana).	SOK/ EQF 4
Nemčija	Vdi-wissensforum	Seminarji "Condition-/ Prozessmonitoring & Predictive Maintenance" Spremljanje stanja in spremljanje procesov.	EQF 6
	bbw-seminar	Prediktivno vzdrževanje pri usposabljanju.	EQF 4
Italija	Formazione Michelangelo	"Specialistični tečaj za vzdrževanje" Tečaj Maintenance Specialist Course je bil ustvarjen z namenom certificiranja vzdrževalcev in zagotavljanja visokokakovostnih standardov pri upravljanju sredstev podjetja.	EQF 4-5
	Festo C. TE	"Specialistični tečaj za vzdrževanje" Avtonomnost in učinkovitost operativnega vzdrževanja za izboljšanje KPI vzdrževalnih oddelkov.	EQF 4-5



		Izpolnjuje obvezne zahteve glede usposabljanja za dostop do certifikata o usposobljenosti za vzdrževanje 1. stopnje	
--	--	---	--

- Učinki tečajev usposabljanja:
 - Nastajajoče digitalne tehnologije 4.0 spreminjajo tradicionalne pristope vzdrževanja in jih je zato treba vključiti v programe usposabljanja.
 - Dvojne kvalifikacije (npr. združevanje industrijske mehatronike z digitalizacijo) postajajo vse bolj aktualne.
- Dodana vrednost za industrijske procese:
 - Prediktivno vzdrževanje obravnava vsaj eno merilo v metodologiji ADMA: Transformacija 2: digitalna tovarna, digitalne zmogljivosti, pregleden pogled na stanje proizvodnega prostora, vrednotenje 4.0.
 - Dodatni izzivi pri izvajanju PdM in organizacijskih sprememb: v industrijskih storitvah je bila ugotovljena prelomnica, pri čemer se razvijajo akterji vzdrževanja kot storitve (MaaS), kar lahko vpliva na notranjo organizacijo MSP.
 - **Modulacija:** tema PdM se zdi zanimiva, vendar v prihodnosti ni prednostna naloga, saj je trenutno veliko MSP daleč od tega; vzdrževalne organizacije so pogosto osredotočene na kurativno vzdrževanje.

1.2.2. STOPNJA 2 IN 3 – ISKANJE IN ZBIRANJE INFORMACIJ

Fazi 2 in 3 sta vključevali izvajanje pregleda literature in analize področja opazovanja, kar nam je omogočilo identifikacijo najnovejših in ustreznih virov, vključno z znanstvenimi in akademskimi članki, industrijskimi poročili in belimi knjigami, standardi in predpisi, patenti in tehnično dokumentacijo, študijami primerov in aplikacijami iz resničnega sveta, pa tudi spletnimi članki, blogi in odprtokodnimi projekti.


Vsi ti viri so navedeni v poglavjih »Literatura«.

1.2.3. PRILAGODITEV & VALIDACIJA PODROČJA OPAZOVANJA

Tako uporabljena revidirana metodologija nam je omogočila, da smo izboljšali in potrdili končni opis polja opazovanja: **Kako nastajajoče digitalne tehnologije 4.0 in trendi zelenega prehoda vplivajo na napovedno vzdrževanje, vplivajo na vzdrževalne dejavnosti v panogah, na trgu in delovnih mestih, centrih za poklicno izobraževanje in usposabljanje ter učnih poteh?**

Izraz "**nastajajoče**" tukaj ne pomeni novosti tehnologij, temveč pojav v industrijskih sprejetih in implementacijah.





Slika 2. Metodologija, uporabljena za področje opazovanja Prediktivnega vzdrževanja

1.2.4. FAZA 4 - SODELOVANJA IN PARTNERSTVA

Med stopnjami 1 do 3 so bile ugotovljene glavne ugotovitve, ki so nam omogočile, da potrdimo obseg študije, preidemo na stopnjo 4 – sodelovanja in partnerstva – ter izdelamo dve anketi za MSP in centre za poklicno izobraževanje in usposabljanje.

1.2.4.1. IZDELAVA ANKETE

Vsebina anket je bila pregledana in potrjena z osebnimi intervjuji z vodji MSP in trenerji centrov za poklicno izobraževanje in usposabljanje ter nazadnje z vsemi vključenimi notranjimi partnerji LCAMP.

Vodilne smernice za izdelavo anket so bile obravnavati naslednje točke.

Identifikacija trendov in sledenje

- **Cilj:** Slediti stopnji sprejemanja praks prediktivnega vzdrževanja v MSP in razumeti nujnost ali zamudo pri sprejemanju teh tehnologij.
- **Vpogled za mala in srednja podjetja:** ponuja informacije o tem, kje so v primerjavi s podobnimi podjetji pri sprejemanju prediktivnega vzdrževanja ter jim pomaga prepoznati vrzeli in priložnosti.
- **Vpogled za poklicno izobraževanje in usposabljanje:** razkriva trendovske tehnologije in procese, po katerih je povpraševanje, kar omogoča prilagoditve učnih načrtov, ki so v skladu s potrebami industrije.

Tehnološke in procesne ravni sprejemanja

- **Cilj:** Izmeriti stopnjo implementacije ključnih tehnologij in metod pri predvidenem vzdrževanju, kot so senzorji in internet stvari, podatkovna analitika in veliki podatki, modeli globokega učenja, odkrivanje nepravilnosti in diagnosticiranje napak, obdelava naravnega jezika (NLP), predpisano vzdrževanje ...
- **Vpogled za MSP:** Omogoča jim, da primerjajo svoj napredek pri sprejemanju novih tehnologij in ugotovijo, kje so morda potrebne dodatne naložbe.
- **Vpogled za poklicno izobraževanje in usposabljanje:** obvešča o trendih sprejemanja tehnologije in pomaga pri vključevanju teh tehnologij v programe praktičnega usposabljanja in simulacije.



Tržni premiki in konkurenčno pozicioniranje

- **Cilj:** Razumeti, kako Predictive Maintenance vpliva na tržno dinamiko, vključno s povpraševanjem strank, regulativnim pritiskom in konkurenčnim okoljem.
- **Vpogled za MSP:** ponuja pogled na tržne priložnosti na področju vzdrževanja, spodbuja strategije za izpolnjevanje novih povpraševanj ali tržnih niš + prilagoditev organizacije vzdrževanja znotraj MSP
- **Vpogled v poklicno izobraževanje in usposabljanje:** omogoča poklicnemu izobraževanju in usposabljanju, da se osredotočijo na usposabljanje za kompetence, povezane s potrebami nastajajočih trgov, in študente pripravljajo na področja z velikim potencialom.

Izzivi in ovire v tranziciji

- **Cilj:** Ugotovite glavne ovire, s katerimi se MSP srečujejo pri uvajanju prediktivnega vzdrževanja, kot so stroški, pomanjkanje strokovnega znanja ali regulativni izzivi.
- **Vpogled za MSP:** izpostavlja posebna področja, kjer bi zunanja podpora (npr. financiranje, svetovanje) lahko pospešila njihov prehod.
- **Vpogled za poklicno izobraževanje in usposabljanje:** obvešča, kje je morda potrebna dodatna izobraževalna podpora, kot je usposabljanje o skladnosti s predpisi ali postopkih prijave za financiranje.

Ocena vpliva na delovna mesta in spretnosti

- **Cilj:** oceniti, kako Prediktivno vzdrževanje vpliva na obstoječe vloge in pojav novih delovnih funkcij v proizvodnji.
- **Vpogled za MSP:** pomaga ugotoviti, katere vloge bodo zastarele ali se bodo razvile, podpira načrtovanje delovne sile in prizadevanja za ponovno usposabljanje.
- **Vpogled za poklicno izobraževanje in usposabljanje:** obvešča o nastajajočih profilih delovnih mest, kar jim omogoča, da posodobijo ponudbo tečajev in programe usposabljanja, da ustrezajo trenutnim zahtevam trga dela.

Analiza vrzeli v spretnostih in kompetencah

- **Cilj:** Identificirati posebne veščine in kompetence, ki primanjkuje trenutni delovni sili, tako tehnično kot glede ljudi, in ki so potrebne za podporo razvoju prediktivnega vzdrževanja.
- **Vpogled za mala in srednja podjetja:** zagotavlja jasno razumevanje potreb po usposabljanju znotraj organizacije in industrije ter omogoča ciljno usmerjene pobude za izpopolnjevanje.
- **Insight for VET:** Podpira razvoj kurikulumov s poudarkom na prednostnih veščinah, bodisi tehničnih (npr. analiza podatkov, upravljanje z energijo) ali netehničnih (npr. trajnostna pismenost, reševanje problemov).

Potrebe po usposabljanju in prednostni načini učenja

- **Cilj:** Odkrijte vrste usposabljanja, ki jih potrebujejo mala in srednja podjetja, in prednostne oblike dostave, kot so možnosti spletnega, osebnega ali hibridnega usposabljanja.
- **Vpogled za MSP:** Zagotavlja, da so možnosti usposabljanja dostopne in praktične ter podpirajo razvoj njihove delovne sile na prilagodljiv način.
- **Vpogled v poklicno izobraževanje in usposabljanje:** ustanovam poklicnega izobraževanja in usposabljanja omogoča prilagajanje oblik usposabljanja željam in omejitvam MSP, zaradi česar so programi bolj dostopni in učinkoviti.



Predvidene prihodnje potrebe in nastajajoči trendi

- **Cilj:** Zbrati vpogled v prihodnost MSP v zvezi s predvidenim vzdrževanjem, vključno z načrtovanimi naložbami, pričakovanimi tehnologijami in zahtevami po znanju.
- **Vpogled za mala in srednja podjetja:** podjetjem pomaga uskladiti prihodnje načrtovanje delovne sile in naložbene odločitve s pričakovanimi tržnimi in tehnološkimi spremembami.
- **Vpogled za poklicno izobraževanje in usposabljanje:** usmerja prihodnji razvoj programov usposabljanja, da ostanejo pred potrebami industrije in zagotavljajo, da so učenci usposobljeni za najnovejše kompetence in nastajajoče prakse.

1.2.4.2. IZVEDBA ANKETE

Vzorec MSP in centrov za poklicno izobraževanje in usposabljanje, ki so bili vključeni v raziskave, so bile naslovljene na:

- MSP: naši kontakti v organizaciji (odgovorni za vzdrževalne službe ali odgovorni v podjetju)
- VET: naši kontakti v organizaciji, odgovorni za učne poti.

Tabela 4. Posvetovane organizacije

CILJNO OBČINSTVO	DRŽAVA	ŠTEVILO POSVETOVANIH ORGANIZACIJ
MSP	FR	11
	NEMČ	60
	SI	11
	ŠV	20
	IT	1
Skupaj MSP		103
VET	FR	11
	NEMČ	14
	SI	16
	ŠV	10
	IT	1
Skupno poklicno izobraževanje in usposabljanje		52
Skupno skupaj		155



1.2.4.3. ANALIZA IN ZANESLJIVOST REZULTATOV ANKETE

Analiza kakovosti ankete

- **Namen ankete:** Cilj raziskave je zbrati podatke za razumevanje trenutnega stanja, izzivov in trendov na področju prediktivnega vzdrževanja (PdM) za MSP. Zastavlja specifična vprašanja o tehnologijah, strategijah izvajanja, ovirah in prihodnjem razvoju.
- **Izbor vzorca:** Raziskava je namenjena podjetjem in centrom poklicnega izobraževanja in usposabljanja v različnih sektorjih in državah (vključno s Francijo, Nemčijo, Švedsko, Italijo in Slovenijo). Uporabljena je neverjetnostna metoda, imenovana »priročno vzorčenje« (吳麗珍 et al., 2014), saj je vzorec ciljno usmerjen in osredotočen.
- **Metodologija:** Raziskava temelji na obsežnem pregledu literature o stanju tehnike v PdM. Zasnovan je kot presečna študija, ki zbira podatke v določenem trenutku. Anketa vsebuje večinoma zaprta vprašanja (npr. večkratna izbira, Likertove lestvice) in le nekaj odprtih vprašanj.

Rezultati in ugotovitve:

- **Tehnologije in strategije implementacije:** Raziskava dokumentira trenutno stanje tehnologij PdM in njihovo implementacijo v različnih panogah.
- **Izzivi:** Identificira ključne izzive pri izvajanju PdM.
- **Prihodnji razvoj:** Anketa zagotavlja vpogled v prihodnji razvoj in potrebe po usposabljanju za odpravo pričakovanih vrzeli v spretnostih.

Kategorizacija:

- **Opisna raziskava** (Silva, 2008) : dokumentira trende, izzive in status quo v PdM.
- Neverjetnostna metoda: priročno vzorčenje, ni dokazov o naključnem ali stratificiranem vzorčenju.
- **Presečna študija** (Hemmerich, nd) : Enkratno zbiranje podatkov brez ponavljajočih se procesov ali dolgih obdobj opazovanja.
- **Kvantitativno:** vprašanja zaprtega tipa s strukturiranimi podatki, ki jih je mogoče numerično oceniti.

Priporočila:

- Da bi izboljšali veljavnost raziskave in zmanjšali pristranskost, bi lahko naredili prilagoditve, kot je uvedba verjetnostnih metod vzorčenja.

Analiza reprezentativnosti ankete

Predpostavka:

- Izbrana podjetja z neposredno povezavo s tematiko, ki so strokovno in stvarno priznana, nas brez zadržkov podpirajo pri zagotavljanju kakovostnih odgovorov na naše ankete. To velja tudi za izobraževalne centre.

Realnost:

- Realnost pa je pokazala, da je zelo težko dobiti odgovore na ankete. Na koncu je bilo treba za pridobitev rezultatov ankete uporabiti hladno klicanje. To podporno obnašanje industrije in izobraževalnih centrov se je razširilo na številne evropske partnerske države.

Vrednotenje rezultatov:

- Stopnja odziva na anketo se razlikuje glede na številne dejavnike, vključno s ciljno populacijo, distribucijskim kanalom in zasnovo vprašalnika. Pri internih anketah, kot so tiste, ki se izvajajo med zaposlenimi v podjetju, je povprečna stopnja odziva na splošno med 30



- % in 40 %. Po drugi strani imajo zunanje ankete, namenjene zunanjim občinstvom, nižje povprečne stopnje odziva, pogosto med 10 % in 13 %. (Bhat, 2018; hubspot, 2023)
- V posebnem kontekstu proizvajalcev in centrov za usposabljanje se lahko stopnje odgovorov razlikujejo glede na predanost anketirancev in zaznano ustreznost ankete. Na primer, ena študija je pokazala, da ankete o zadovoljstvu strank na splošno dosežejo 33-odstotno stopnjo odziva, čeprav se ta številka razlikuje glede na zaznano vrednost za anketiranca. (Bhat, 2018)
 - Pomembno je omeniti, da dolžina in kompleksnost vprašalnika vplivata tudi na stopnjo odziva. Ankete z manj kot 12 vprašanji imajo povprečno stopnjo odziva 83 %, medtem ko imajo lahko daljše ankete nižjo stopnjo odziva. (Le Sphinx, 2024)

1.2.5. FAZA 6 - VALIDACIJA POROČILA

Poročilo so potrdili strokovnjaki na sestanku za sodelovanje.



2. RAZVOJ VZDRŽEVALNIH STRATEGIJ

Sodobna industrijska oprema je postala vse bolj zapletena, kar vodi do vse večjega zanimanja za bolj prilagodljive strategije vzdrževanja za zagotavljanje visoke zanesljivosti in trajnosti. Te strategije so razvrščene v tri glavne vrste: reaktivno (ali korektivno), preventivno in napovedno vzdrževanje.

Učinkovito upravljanje vzdrževanja katerega koli sredstva zahteva izbiro najprimernejše strategije glede na specifične potrebe opreme. Vsak pristop ima svoje prednosti in omejitve, zato je bistvenega pomena razumevanje njihovega vpliva na uspešnost sredstev in urnike dela, da lahko sprejememo premišljeno odločitev.

Okvare opreme so lahko drage, zato se zdi, da je strategija predvidenega vzdrževanja, ki je zasnovana za napovedovanje okvar, preden se zgodijo, in omogoča čas za izvedbo popravnih ukrepov, najbolj očiten pristop, ki mu je treba slediti. Vendar pa lahko nekateri nebistveni predmeti delujejo do okvare, ne da bi povzročili resne težave, poleg tega pa jih je mogoče hitro in poceni zamenjati. V takih primerih je vzdrževalna ekipa morda pripravljena sprejeti korektivni postopek vzdrževanja. Izvajanje do odpovedi se lahko sprejme tudi v situacijah, ko popravljalni ukrepi niso izvedljivi – na primer nekatera vesoljska plovila /sateliti so lahko zasnovani na podlagi predpostavk brez vzdrževanja in se jim lahko dovoli, da delujejo do odpovedi (in se nato opustijo).

Tretjo vrsto strategije, preventivno vzdrževanje, prav tako pogosto uporablja industrija. Ta pristop, tako kot prediktivno vzdrževanje, poskuša preprečiti okvaro, preden se zgodi, vendar obstaja majhna razlika med preventivnim vzdrževanjem in prediktivnim vzdrževanjem.

2.1. VZDRŽEVANJE - DEFINICIJA

Za boljše razumevanje teme so tukaj definicije treh vzdrževalnih strategij in opis optimalne vzdrževalne strategije (TWI, nd) dopolnil (arxiv, 2024).

2.1.1. STRATEGIJE VZDRŽEVANJA – DEFINICIJE

2.1.2. REAKTIVNO (KOREKTIVNO) VZDRŽEVANJE - RM

Kljub inherentnim prednostim preventivnih in napovednih tehnik je lahko reaktivno (ali korektivno) vzdrževanje v nekaterih primerih najboljša rešitev. Kadar so stroški okvare in popravila delov nižji od stroškov preventivnega ali predvidenega vzdrževanja, je korektivno vzdrževanje pogosto najboljša rešitev.

Tako je na primer v primeru žarnice korekcija zagotovo najboljša možnost, saj stroški in čas, ki sta potrebna za zamenjavo žarnice, verjetno ne bosta dramatično vplivala na proračune ali urnike dela. Vendar se to spremeni, ko postane del bolj nujen za operacije, kot je na primer lopatica vetrne turbine ali ladijski motor.

Korektivno vzdrževanje je lahko še posebej škodljivo, če dejansko ni bilo določeno kot akcijski načrt; pustiti, da se nekaj nevede pokvari, je lahko drago v času, denarju in varnosti.



2.1.3. PREVENTIVNO VZDRŽEVANJE - PM

Preventivno spremljanje se uporablja, kadar so stroški delovanja, dokler se ne pokvari, previsoki, ko je del preveč kritičen, ga je težko zamenjati ali popraviti ali bi lahko imel resne posledice za varnost zaposlenih ali urnike dela.

Ta pristop ni potreben za vse predmete, omogoča pa vzdrževanje tistih, ki so pomembnejši.

Preventivno vzdrževanje, znano tudi kot načrtovano vzdrževanje, vključuje načrtovanje rutinskih vzdrževalnih dejavnosti za določeno opremo, da se zmanjša tveganje okvar. Ta pristop zagotavlja, da se vzdrževanje izvaja, medtem ko stroj še vedno deluje in deluje normalno, s čimer se preprečijo nepričakovane okvare in zmanjšajo s tem povezani čas izpadov in stroški.

Vključuje načrtovane vzdrževalne dejavnosti, kot so čiščenje, mazanje, pregledovanje in popravilo opreme, preden pride do okvar. Z zmanjšanjem nenačrtovanih popravil PM poveča učinkovitost in podaljša življenjsko dobo sredstev; optimalne politike vzdrževanja, ki povečajo zanesljivost/razpoložljivost in varnost sistema pri najnižjih stroških vzdrževanja, so opisane v dokumentu (arxiv, 2024).

Programi preventivnega vzdrževanja zajemajo pet različnih strategij, ki vse temeljijo na načelih načrtovanega vzdrževanja. Vsaka strategija je strukturirana in razporejena drugače, da se uskladi z določenim poslom. (IBM Business operations, 2023)

Vrste preventivnega vzdrževanja:

1. Vzdrževanje na podlagi uporabe (UBM): Načrtovano glede na uporabo sredstev (npr. menjava olja po določeni kilometrini).
2. Časovno vzdrževanje: Izvaja se v določenih intervalih (npr. tedenski pregledi po smernicah proizvajalca).
3. Vzdrževanje na podlagi stanja (CBM): uporablja orodja za spremljanje v realnem času za oceno stanja opreme in načrtovanje vzdrževanja po potrebi.
4. Prediktivno vzdrževanje (PdM): izkorišča analizo podatkov in umetno inteligenco (AI) za predvidevanje napak, preden se zgodijo.
5. Predpisano vzdrževanje: presega predvideno vzdrževanje s priporočanjem korektivnih ukrepov za preprečevanje okvar.

2.1.4. PREDIKTIVNO VZDRŽEVANJE – PDM

Kot je bilo predhodno opredeljeno kot ena od 5 strategij preventivnega vzdrževanja, je predvideno vzdrževanje (PdM) pristop proaktivnega vzdrževanja, ki uporablja podatkovno vodene vpogleds in spremljanje v realnem času za napovedovanje in odpravljanje težav z opremo, preden povzročijo okvaro. Z zbiranjem podatkov iz senzorjev ter uporabo napredne analitike in strojnega učenja PdM zazna vzorce in morebitne napake, kar vzdrževalnim ekipam omogoča posredovanje le, ko je to potrebno. To zmanjšuje nenačrtovane izpade, zmanjšuje stroške vzdrževanja in optimizira delovanje opreme z obravnavanjem težav na podlagi dejanskih pogojev in ne fiksnih urnikov. (IBM Business operations, 2023)

Prediktivno vzdrževanje očitno pomeni prelomnico v svetu industrijskih storitev. Za razliko od prejšnjih pristopov, kot so reaktivni servisni modeli, preventivno vzdrževanje in vzdrževanje na podlagi stanja, napovedno vzdrževanje dodaja kritično prednost uporabi senzorjev in podatkov merilnih strojev. PdM gradi na štirih temeljnih kamnih digitalizacije: medsebojna povezljivost, digitalni podatki, avtomatizacija in ustvarjanje vrednosti. (Berger, 2018)


Tovrstno vzdrževanje postaja vse bolj dostopno zaradi izboljšav nastajajočih digitalnih tehnologij 4.0 za spremljanje, zbiranje in analizo podatkov ter znižanih stroškov.



2.2. OPTIMALNA STRATEGIJA VZDRŽEVANJA


Optimalna strategija vzdrževanja je določena z optimizacijo stroškov kakovosti, stroškov popravil, stroškov vzdrževanja, stroškov izpadov in varnosti ljudi.

- Primerjava stroškov:
 - RM ima najnižje stroške preprečevanja, vendar visoke stroške popravil zaradi svojega pristopa od zagona do okvare.
 - PM zmanjša stroške popravil z vnaprejšnjim načrtovanjem vzdrževanja.
 - PdM uravnoteži stroške popravila in preventive, zmanjša nenačrtovane okvare in se hkrati izogne pretiranemu preventivnemu vzdrževanju.
- Ključni vpogledi:
 - RM je na začetku stroškovno učinkovit, vendar vodi do daljših izpadov in nujnih popravil.
 - PM zagotavlja načrtovane posege, s čimer se izogne nepričakovanim okvaram, ki pa lahko povzročijo nepotrebno vzdrževanje.
 - PdM izkorišča podatke in analitiko za optimizacijo vzdrževanja, kar zagotavlja najboljše razmerje med stroški in zmožljivostjo.
- Primernost:
 - RM je najboljši za nekritična sredstva, kjer ima okvara minimalen vpliv.
 - PM je idealen za stroje s predvidljivo obrabo in razpoložljivimi okni izpadov.
 - PdM je najučinkovitejši za kritična sredstva visoke vrednosti, kjer lahko napovedni vpogledi povečajo čas delovanja in zmanjšajo stroške.



Slika 3. Načrti vzdrževanja RM, PM in PdM

Vir: (arxiv, 2024)



Slika 4. Primerjava RM, PM in PdM glede stroškov in pogostosti vzdrževalnih del



Tabela 5. Prednosti, izzivi in aplikacije RM, PM in PdM - Viri (A Survey of Predictive Maintenance: Systems, Purposes and Approaches, nd)

	Prednosti	Izzivi	Primerne aplikacije	Neprimerne aplikacije
RM	• Največja uporabna in proizvodna vrednost • Nižji stroški preventive	• Nenačrtovani izpadi • Visoki stroški zalog rezervnih delov • Morebitna nadaljnja škoda za opremo • Višji stroški popravila	• Redundantna ali nekritična oprema • Popravilo opreme z nizkimi stroški po okvari	• Okvara opreme ustvarja varnostno tveganje • Potrebna je 24/7 razpoložljivost opreme
PM	• Nižji stroški popravila • Manj okvar opreme in nenačrtovanih izpadov	• Potreba po inventarju • Povečanje načrtovanih izpadov • Vzdrževanje na videz brezhibne opreme	• Imajo verjetnost okvare, ki se povečuje s časom ali uporabo	• Imajo naključne okvare, ki niso povezane z vzdrževanjem
PdM	• Celovit pogled na zdravje opreme • Izboljšane možnosti analitike • Izogibajte se teku do neuspeha • Izogibajte se zamenjavi komponente z življenjsko dobo	• Povečani začetni stroški infrastrukture in nastavitvev (npr. senzorji) • Kompleksnejši sistem	• Imeti načine odpovedi, ki jih je mogoče stroškovno učinkovito predvideti z rednim spremljanjem	• Ne imejte načina okvare, ki bi bil lahko stroškovno učinkovit

Primerjava poudarja, da PdM ponuja najučinkovitejšo dolgoročno rešitev, ki uravnoteži stroške in zanesljivost, vendar zahteva napredno tehnologijo in upravljanje podatkov.

2.1. PREDIKTIVNO VZDRŽEVANJE - KORAK PRED PREDPISANIM VZDRŽEVANJEM

Medtem ko predpisano vzdrževanje (AI, ki predlaga optimalne ukrepe) postaja naslednja meja onkraj prediktivnega vzdrževanja, so naslednja poglavja osredotočena na prediktivno vzdrževanje:

- Kontekst:
- Tržni obeti in projekcije rasti
- Tehnološki razvoj in prevzem
- Prediktivno vzdrževanje kot storitev (PdMaaS): stroškovno učinkovita in razširljiva rešitev
- PdM in vplivi nastajajočih digitalnih tehnologij 4.0



- PdM na vzdrževalne dejavnosti v MSP
- Nastajajoče digitalne tehnologije 4.0: Vpliv na vzdrževalno usposabljanje v centrih za poklicno izobraževanje in usposabljanje.

3. PdM - KONTEKST

Glede na pospešek sprejemanja nastajajočih tehnologij 4.0 na področju PdM v zadnjih 10 letih se zdi primerna analiza pričakovanih obetov v dveh časovnih obdobjih .

Tu se opiramo na študijo, predstavljeno leta 2018 (Berger, 2018) in dve novejši publikaciji, prva je bila objavljena leta 2024 (Allied Market Research, 2024) in druga z zadnjo posodobitvijo januarja 2025 (Fortune Business Insights, 2025) .

Leta 2028 je Roland Berger napovedal, da bo prediktivno vzdrževanje (PdM) revolucioniralo industrijske storitve z uporabo algoritmov in podatkov senzorjev za predvidevanje okvar, preden se pojavijo, s čimer bi optimizirali delovanje sredstev in zmanjšali stroške. Ta razvoj naj bi vodil do preobrazbe storitev in poslovnih modelov, s preходом od reaktivnega vzdrževanja k proaktivnim strategijam, ki temeljijo na podatkih.


Zadnje objave potrjujejo in celo presega napovedi za leto 2018 z dvema glavnima dogodkoma: pandemijo COVID-19 in pojavom generativne umetne inteligence v tem času.

Tukaj so ključni trendi, tržne spremembe in tehnološki napredek, pričakovan v letu 2018, trenutno stanje in napovedi do leta 2033, potrjene z drugimi publikacijami.

3.1. TRŽNI OBETI IN PROJEKCIJE RASTI

3.1.1. PERSPEKTIVA, OBJAVLJENA LETA 2018

Naslednja napoved razvoja svetovnega trga PdM do leta 2022 je bila zgrajena iz naslednjih virov: (Berger, 2018) , (IoT Analytics, 2017) , (persistencemarketresearch, 2025) . (Obseg napovedi globalnega razvoja trga PdM je opisan v Prilogi 2).




Slika 3. Napoved globalnega razvoja trga PdM do leta 2022



- Trg PdM naj bi do leta 2022 dosegel 11 milijard USD , zlasti v Evropi.
- Takrat je 81 % podjetij vlagalo v PdM , 40 % pa jih je menilo, da bo ključnega pomena za prihodnji poslovni uspeh.
- svetovni trg PdM v panogah zrasel med 20 % in 40 % letno .
- Med ključnimi sektorji, ki naj bi sprejeli PdM , so avtomobilska, vesoljska in industrijska proizvodnja .

3.1.2. PERSPEKTIVE, OBJAVLJENE OD LETA 2023

Naslednja napoved razvoja svetovnega trga PdM do leta 2033 je bila zgrajena iz naslednjih virov: (*Tržni delež predvidenega vzdrževanja, Napoved velikosti svetovne industrije* , 2024) , (Fortune Business Insights, 2025) , (Fortune Business Insights, 2025) , (*Tržna velikost predvidenega vzdrževanja, delež, poročilo 2025-33* , 2024) , (<https://www.polarismarketresearch.com>, 2024) , (Allied Market Research, 2024) , (<https://www.marketresearchfuture.com>, 2022) , (Grand View Research, 2022) , ([persistencemarketresearch.com](https://www.persistencemarketresearch.com), 2025)



Slika 4. Napoved globalnega razvoja trga PdM do leta 2033

- Svetovni trg prediktivnega vzdrževanja (PdM) je bil leta 2024 ocenjen na 10,93 milijarde USD, do leta 2032 pa naj bi dosegel 70,73 milijarde USD in rasel s CAGR 26,5 %. (Fortune Business Insights, 2025) . (Obseg napovedi globalnega razvoja trga PdM je opisan v Prilogi 2).
- Nekatere projekcije ocenjujejo, da bi lahko trg **do leta 2033 dosegel 107 milijard USD** (CAGR 32,2 %) (*Predictive Maintenance Market* , nd)
- Premik k avtomatiziranim **rešitvam PdM v oblaku** še naprej spodbuja rast trga.



3.1.3. KLJUČNE RAZLIKE MED LETOMA 2018 IN 2024

- Leta 2018 je PdM še vedno veljal za **nastajajoči trend**, medtem ko je do leta 2024 postal **nujen standard** za industrijsko konkurenčnost.
- Medtem ko so **projekcije rasti trga** sledile povprečju tistih, ocenjenih v letu 2018 do leta 2020, so od leta 2021 presegle pričakovanja.
- **COVID-19 je deloval kot katalizator** za sprejetje, saj so podjetja zaradi omejitev potovanj in pomanjkanja delovne sile iskala **rešitve za spremljanje na daljavo**, kar je industrije **potisnilo k podatkovno vodenim in umetni inteligenci**. PdM rešitve.
- **Generative AI** uvaja novo obdobje v PdM.

3.1.4. REGIONALNE RAZLIKE

Članek (Allied Market Research, 2024) omenja regionalne razlike, na katere vplivajo industrijsko povpraševanje, tehnološki napredek in vladne politike.

- Severna Amerika vodi pri sprejemanju PdM zaradi zgodnje tehnološke integracije, velikih naložb v internet stvari, umetno inteligenco in strojno učenje ter koncentracije večjih tehnoloških podjetij. Vladna podpora in pobude Industrije 4.0 še naprej spodbujajo rast, zlasti v proizvodnji in vesoljski industriji.
- Evropa daje prednost trajnosti in učinkovitosti, pri čemer predpisi EU in industrijski standardi pospešujejo sprejemanje PdM. Države, kot je Nemčija, znane po svoji proizvodni moči, dejavno izvajajo pobude pametnih tovarn za izboljšanje industrijske uspešnosti.
- Azijsko-pacifiška regija je priča hitri širitvi PdM, ki jo poganja industrijska rast na Kitajskem, Japonskem in v Indiji. Povečane naložbe v digitalno preobrazbo in napredek pametne proizvodnje spodbujajo zagon trga, čeprav se stopnje sprejemanja razlikujejo, pri čemer sta vodilni Japonska in Južna Koreja.
- Latinska Amerika in Bližnji vzhod vse bolj prepoznavata koristi PdM pri zmanjševanju stroškov in izboljšavah učinkovitosti. Vendar omejena infrastruktura in nižje ravni naložb predstavljajo izzive, ki upočasnjujejo sprejemanje na nekaterih področjih.

3.1.5. GLOBALNI TRŽNI DELEŽ PDM PO ANALIZI KONČNE UPORABE, 2024


Velika podjetja so glavni uporabniki, ki v letu 2023 prispevajo **več kot 75 %** trga.

Med tehnikami PdM je bilo najbolj razširjeno spremljanje vibracij, ki je leta 2023 predstavljalo 28 % trga.

Proizvodni **sektor** se je izkazal kot največji uporabnik v industriji, saj je leta 2023 imel **več kot 29 %** tržnega deleža

(Trg predvidenega vzdrževanja , nd)





Slika 5. Globalni tržni delež PdM po analizi končne uporabe, 2024

3.2. TEHNOLOŠKI RAZVOJ IN PREVZEM

3.2.1. STANJE V LETU 2018

- PdM so v prvi vrsti poganjale senzorska tehnologija, podatkovna analitika in rešitve v oblaku.
- Podjetja so se pri odkrivanju napak zanašala na strukturirane podatke in vnaprej programirane algoritme.
- Zmožnost predvidevanja je bila še vedno omejena, modeli strojnega učenja pa niso bili v celoti vključeni v delovne poteke vzdrževanja.
- Poudarek je bil na zbiranju podatkov in ne na sprejemanju odločitev v realnem času.

3.2.2. STANJE OD LETA 2023

3.2.3. POMEMBNE TEHNOLOŠKE IZBOLJŠAVE:

V zadnjih 3 letih je prišlo do revolucije pri sprejemanju novih rešitev, ki temeljijo na generativni AI,

- **Strojno učenje in digitalni dvojčki** so postali **osrednji dejavniki** PdM.
- **Generative AI revolucionira PdM**, tako da je vzdrževanje **proaktivno, stroškovno učinkovito in visoko avtomatizirano**.
- Izboljša PdM s predvidevanjem okvar strojev, samodejnim ustvarjanjem načrtov popravil in zagotavljanjem prilagojenih navodil za popravilo. Poenostavlja razvoj napovednih modelov, zmanjšuje odvisnost od velikih podatkovnih znanstvenih skupin, hkrati pa izboljšuje natančnost in učinkovitost.
- V proizvodnji se generativni sistemi PdM, ki jih poganja AI, izkazujejo za učinkovite. Na primer, avtomobilsko podjetje je uvedlo tak sistem in doseglo 30-odstotno zmanjšanje izpadov in 20-odstotno nižje stroške vzdrževanja.
- **PdM v oblaku in digitalni dvojčki** zdaj omogočajo stalno spremljanje in **virtualne simulacije za napovedovanje opreme**.



Vzorec nedavnih dogodkov:

- Junij 2024: IBM Corporation je predstavil Maximo Application Suite (MAS) različice 9.0, ki vključuje izboljšano rešitev za predvidevanje vzdrževanja, ki temelji na AI, bolj intuitiven uporabniški vmesnik in razširjeno integracijo interneta stvari za analizo podatkov v realnem času in spremljanje sredstev
- Julij 2024: Senzit , ključni igralec na področju tehnologij prediktivnega vzdrževanja za težke industrije, je predstavil Senzit Pro, vrhunsko diagnostično rešitev, prilagojeno upraviteljem voznih parkov.
- Julij 2024: Programska oprema ManWinWin je razširila svoje rešitve za napovedno vzdrževanje in uvedla proaktivna orodja za predvidevanje in preprečevanje okvar opreme, preden do njih pride.

3.2.4. KONKURENČNA POKRAJINA

Podjetja uvajajo **rešitve PdM** , **specifične za panogo**, da bi **povečale učinkovitost in tržni delež**.

Glavni igralci, kot so **IBM, Siemens, GE in C3.ai**, se širijo s **partnerstvi, prevzemi in naložbami v raziskave in razvoj** .

- Julij 2024: Skupina I-care je sklenila pogodbo s podjetjem Sensirion Connected Solutions GmbH za pridobitev sredstev in licenc za svojo linijo izdelkov za prediktivno vzdrževanje.
- Septembra 2024 sta COMPREDICT in skupina Renault objavila partnerstvo, osredotočeno na tehnologijo prediktivnega vzdrževanja z uporabo virtualnih senzorjev. Navidezni senzori COMPREDICT, ki temeljijo na programski opremi, zagotavljajo podatke v realnem času, ne da bi potrebovali dodatno strojno opremo, kar bistveno zmanjša skupne stroške lastništva za OEM (proizvajalec originalne opreme). (Fortune Business Insights, 2025)
- Članki (Allied Market Research, 2024) in (Fortune Business Insights, 2025) omenjajo te dodatne pobude:
- Amazon Web Services (AWS) je lansiral 'Amazon Lookout for Equipment', rešitev za napovedno vzdrževanje, ki izkorišča strojno učenje in senzorje za optimizacijo načrtovanja vzdrževanja in odkrivanje morebitnih okvar opreme (2021).
- Siemens je kupil Senseye za izboljšanje zmogljivosti PdM (2022).
- Accenture je prevzel Nextira za razširitev rešitev za napovedovanje, ki temeljijo na AI (2023).
- General Electric namerava podpreti vesoljsko dejavnost z zagotavljanjem umetne inteligence in tehnologije strojnega učenja v storitvah prediktivnega vzdrževanja in avtomatiziranih inšpekcijskih postopkih (2024).

3.2.5. KLJUČNE RAZLIKE MED LETOMA 2018 IN 2024

- Leta 2018 je bil PdM osredotočen na zbiranje podatkov, medtem ko se je leta 2024 razvil v napovedno analitiko v realnem času, ki jo vodi umetna inteligenca.
- Integracija generativne umetne inteligence je znatno izboljšala natančnost napovedovanja in sprejemanje odločitev.
- Digitalni dvojčki so omogočili virtualne simulacije vzdrževanja, česar v letu 2018 niso široko sprejeli.
- Podjetja leta 2024 izkoriščajo PdM , ki temelji na programski opremi , namesto da se zanašajo zgolj na rešitve, ki zahtevajo veliko strojne opreme.
- Velika podjetja veliko vlagajo v sektor.



3.3. PDM KOT STORITEV (PDMAAS): STROŠKOVNO UČINKOVITA IN RAZŠIRLJIVA REŠITEV

Medtem ko se o MaaS (Maintenance-as-a-Service) leta 2018 ni veliko razpravljalo **kot o alternativnem poslovnem modelu**, vzpon vzdrževanja kot storitve (MaaS) leta 2024 omogoča MSP dostop do rešitev PdM, ne da bi zahtevali popolno lastništvo infrastrukture.

PdMaaS zagotavlja **proizvodnim obratom** cenovno **ugoden dostop do rešitev za predvideno vzdrževanje na zahtevo** . Številna **zagonska podjetja** izkoriščajo ta model za pomoč podjetjem **pri zmanjševanju infrastrukturnih stroškov** ob **maksimiziranju izkoriščenosti sredstev** .

Ključne prednosti **PdMaaS** vključujejo:

- **Odprava stroškov infrastrukture in razvoja**
- **Izboljšanje razširljivosti** z dostopom v oblaku
- **Podaljšanje življenjske dobe sredstev** in optimizacija **preostale življenjske dobe**
- **Povečanje časa delovanja in zanesljivosti stroja** z **odkrivanjem težav pred odpovedjo**

Ta pristop omogoča podjetjem **prehod z reaktivnega na proaktivno vzdrževanje** , kar zagotavlja **večjo operativno učinkovitost** z minimalnimi naložbami.

Vzdrževanje kot storitev (MaaS) razvijajo kot "storitve 4.0" podjetja, ki utrjujejo svoje izkušnje in strokovno znanje na tem področju ter jih želijo izkoristiti.

Vzporedno se tradicionalni model prodaje industrijske opreme razvija v smeri storitveno usmerjenega pristopa, znanega kot Equipment-as-a-Service (EaaS). V tem modelu proizvajalci obdržijo lastništvo svojih strojev in strankam ponudijo dostop na podlagi meritev uporabe, kot so delovne ure. Ta premik zavezuje ponudnike k zagotavljanju učinkovitih storitev nadzora in vzdrževanja, da zagotovijo optimalno delovanje in zadovoljstvo strank.

EaaS strankam omogoča uporabo napredne opreme brez znatnih vnaprejšnjih naložb, namesto tega pa plača dejansko uporabo. Ta ureditev prenaša odgovornost za vzdrževanje, popravila in nadgradnje na ponudnika opreme, s čimer se zagotovi, da stroji delujejo učinkovito, in skrajša čas izpadov za stranko. Na primer, letalska industrija že dolgo uporablja podoben model, kjer proizvajalci reaktivnih motorjev zaračunavajo letalskim družbam na podlagi ur letenja motorja, kar vključuje vzdrževanje in jamstva za učinkovitost. (Christiansen, 2022)

Ta model, ki temelji na storitvah, koristi tako ponudnikom kot strankam. Ponudniki pridobijo stalen dohodek in tesnejše odnose s strankami, medtem ko stranke uživajo dostop do najnovejše tehnologije z zmanjšanim finančnim tveganjem in operativnimi odgovornostmi. Posledično EaaS postaja vse bolj privlačen poslovni model v različnih panogah, ki spodbuja trajnost in učinkovitost. (Jean-Philippe Richard-Charman, 2023)

Tukaj je nekaj pomembnih primerov:

Oprema kot storitev

- **CHG-MERIDIAN** je eno vodilnih svetovnih **podjetij za uporabo technology2use** , ki razvija, financira in upravlja prilagojene poslovne modele za tehnologijo v sektorju IT, industriji in zdravstvu. Podjetje ponuja celostno upravljanje vseh sredstev od konca do konca po načelih krožnega gospodarstva. (chg-meridian, nd)
- **Trumpf – oprema kot storitev (EaaS) za laserske rezalne stroje:** Trumpf ponuja model plačila po uporabi za laserske rezalne stroje, kjer stranke uporabljajo stroje in plačajo samo dejansko operacijo. Vzdrževanje in servis sta vključena v model (*Plačilo na del* | TRUMPF , nd)



Vzdrževanje kot storitev

- **Siemens** ponuja vrsto rešitev za predvideno vzdrževanje v panogah, kot so proizvodnja, energetika in zdravstvo. Njihove tehnologije omogočajo podjetjem odkrivanje anomalij, napovedovanje okvar opreme in strateško načrtovanje vzdrževalnih dejavnosti (Marcus Law, 2023) .
- **MachineMetrics** se povezuje s številnimi obdelovalnimi stroji in zbira obsežne podatke o zdravju in zmogljivosti stroja. Ti podatki omogočajo identifikacijo indikatorjev, ki vodijo do okvar strojev, kar omogoča izvajanje vzdrževalnih programov glede na stanje (machinemetrics, nd) .
- Z 20-letnimi izkušnjami na področju PdM ponuja **I-Care** globalni pristop, zasnovan za povečanje zanesljivosti sredstev, izboljšanje učinkovitosti vzdrževanja in zmanjšanje nepričakovanih okvar (I-care, 2025) .

Oprema in vzdrževanje kot storitev

- **Festo in FlexFactory** sta združila moči, da bi zagotovila prilagodljive in stroškovno učinkovite proizvodne rešitve kot del poslovnih modelov »kot storitev«. Cilj partnerstva je omogočiti proizvodnjo širokega nabora različic izdelkov ob minimiziranju poslovnih in operativnih tveganj. Ključne komponente vključujejo modele, kot sta **"Vzdrževanje kot storitev"** in **"Oprema kot storitev"** , ki zmanjšujeta finančna tveganja s **"plačilom za del"** ali **"plačilo za uporabo"** . Festo prispeva svoje strokovno znanje in izkušnje na področju avtomatizacije proizvodnje in programskih rešitev, ki temeljijo na umetni inteligenci, medtem ko FlexFactory deluje kot pospeševalec poslovanja in orkestrator (Festo, 2021).
- **Skupina Fives:** Strokovnjaki za podatkovno znanost Fives so zasnovali preverjeno metodologijo v devetih korakih za izvajanje celovitega programa predvidenega vzdrževanja v različnih panogah. Ta proces se začne s strateško uvedbo senzorjev in uporabo specializiranih tehnik za zbiranje kritičnih podatkov. Te rešitve nam sedaj omogočajo ponudbo storitev na podlagi delovnih ur stroja (skupina petih, nd) .



4. PDM - TEHNOLOŠKI TEMELJI

Novembra 2023 je Fernando Brügge v članku (Fernando Brügge, 2023) v povzetku zapisal:

- Za prodajalce: trg PdM dozoreva, vendar izzivi ostajajo. Prodajalci se morajo osredotočiti na rešitve, specifične za panogo, boljšo integracijo podatkov in izboljšanje natančnosti napovedi, da pridobijo zaupanje trga.
- Za končne uporabnike: rešitve PdM pomagajo podjetjem prihraniti na stotine tisoče dolarjev z zmanjšanjem nenačrtovanih izpadov in optimiziranjem uporabe sredstev. Naložba v PdM se lahko izplača s prvo pravilno napovedjo neuspeha.

Kljub svojim prednostim je natančnost PdM še vedno problem, saj številne rešitve dosegajo manj kot 50-odstotno natančnost, kar vodi do lažnih alarmov, ki zmanjšujejo zaupanje v tehnologijo. Vendar pa napredek v analizi, ki temelji na umetni inteligenci, in izboljšani viri podatkov povečujejo zanesljivost.

- 95 % uporabnikov PdM poroča o pozitivni donosnosti naložbe, 27 % pa jih doseže amortizacijo v enem letu.
- Iskalno zanimanje za PdM se je od leta 2017 potrojilo in preseglo druga iskanja, povezana z vzdrževanjem, kar kaže na njegov vse večji pomen kot industrijske rešitve, ki jo je treba imeti.

Glede na ta opažanja se zdi nujno narediti korak nazaj in poudariti tehnično in industrijsko revolucijo, ki poteka od leta 2017, pospešuje pa se od leta 2023 z razpoložljivostjo obetavnih rešitev, ki temeljijo na AI.

Naslednja primerjalna analiza, ki temelji na (Fernando Brügge, 2023; FMI - Future Market Insights, nd; Knud Lasse Lueth, 2017, 2019; raziskave, 2024), poudarja pomembne spremembe v pokrajini Prediktivnega vzdrževanja (PdM) od leta 2017. Te spremembe poganjajo **razvijajoče se strategije dobaviteljev, tehnološke napredek, integracijske prakse in nastajajoči izzivi.**

Kraj in specializacija prodajalca

- 2017: Približno 110 tehnoloških podjetij je bilo dejavnih v PdM, ki zajemajo segmente, kot so strojna oprema za spremljanje stanja, strojna oprema za industrijsko avtomatizacijo, povezljivost, shranjevanje in platforme ter analitika.
- 2019: Število ponudnikov, osredotočenih na PdM, se je podvojilo na več kot 180, pri čemer je segment analitike postal najbolj obljuden, saj predstavlja 35 % ponudnikov.
- 2023: Uspešni prodajalci PdM so se začeli specializirati za posebne panoge in sredstva ter svoje rešitve integrirali v Asset Performance Management (APM) in računalniško podprte sisteme za upravljanje vzdrževanja (CMMS), da bi izboljšali ponudbo vrednosti.
- 2024: Trend k specializaciji se je okrepil, prodajalci pa se osredotočajo na tržne niše, da bi ponudili prilagojene rešitve. Ta pristop je omogočil globlje strokovno znanje na področju in učinkovitejše napovedne modele, ki so obravnavali edinstvene izzive znotraj določenih sektorjev.

Tehnološki napredek

- 2017: strategije PdM so združile tradicionalno spremljanje stanja z analitičnimi algoritmi, kar je omogočilo napovedi napak pred pojavom.
- 2019: Analitični segment se je razširil na devet vrst, vključno z vizualizacijo podatkov, strojnim učenjem, napovedno analitiko in odkrivanjem nepravilnosti, kar poudarja trend k bolj specializiranim analitičnim pristopom.
- 2023: Identificirane so bile tri primarne vrste PdM, pri čemer je zaznavanje anomalij postalo pomembnejše. Programska orodja PdM so običajno vključevala zbiranje podatkov, analitiko, vizualizacijo in predpisana dejanja, s poudarkom na celovitih rešitvah.



- 2024: Integracija umetne inteligence (AI) in strojnega učenja (ML) je postala bolj izrazita, kar je povečalo natančnost napovednih modelov. Sprejetje računalništva v oblaku in tehnologij IoT je olajšalo obdelavo podatkov v realnem času in zmožnosti nadzora na daljavo

Integracija in potek dela

- 2017: Rešitve PdM so bile predvsem samostojne in so se osredotočale na zmožnosti napovedovanja brez globoke integracije v obstoječe delovne tokove vzdrževanja.
- 2019: Prišlo je do postopnega premika k integraciji rešitev PdM z obstoječimi sistemi, vendar je veliko implementacij ostalo zaprtih.
- 2023: Integracija PdM v delovne potoke vzdrževanja je postala ključna, z rešitvami, ki so vedno bolj vgrajene v platformi APM in CMMS, kar omogoča brezhibno delovanje in pretok podatkov.
- 2024: Poudarek na integraciji se je poglobil, pri čemer so rešitve PdM postale sestavni del sistemov za upravljanje sredstev podjetja. Ta brezhibna integracija je omogočila avtomatizirano načrtovanje vzdrževanja in sprejemanje odločitev v realnem času, kar je zmanjšalo motnje delovanja.

Izzivi in priložnosti

- 2017: Poudarek je bil na dokazovanju potencialnih povečanj učinkovitosti PdM, pri čemer so uporabniki poročali o 25-30-odstotnih izboljšavah.
- 2019: Izzivi so vključevali težave s kakovostjo podatkov in potrebo po usposobljenem osebju za razlago zapletenih izhodnih podatkov.
- 2023: Kljub napredku ostajajo izzivi, zlasti natančnost rešitev PdM, pri čemer mnoge dosegajo manj kot 50-odstotno natančnost, kar vodi do težav z zaupanjem. Vendar pa je 95 % posvojiteljev poročalo o pozitivni donosnosti naložbe, 27 % pa jih je opazilo amortizacijo v enem letu, kar poudarja finančne koristi učinkovitih implementacij PdM.
- 2024: Zapletenost upravljanja podatkov in izzivi integracije so ostali pomembni. Pojav Industrial DataOps je bil namenjen reševanju teh težav z racionalizacijo delovnih tokov podatkov in izboljšanjem kakovosti podatkov, s čimer se je povečala zanesljivost sistemov PdM.

Kljub izzivom pri upravljanju podatkov in sistemski integraciji napredek v AI, IoT in analitiki še naprej izboljšuje natančnost in sprejemanje PdM.


Osredotočimo se zdaj na razumevanje delovanja PdM, kakšni so njegovi stebri in kako generativna umetna inteligenca zagotavlja odgovore za izboljšanje modelov napovedovanja ter analiziranje in razumevanje njegovih rezultatov.



4.1. KAKO DELUJE PdM

Prediktivno vzdrževanje (PdM) se je razvilo v temelj industrijske učinkovitosti s preходом iz tradicionalnih reaktivnih in preventivnih strategij v proaktiven pristop, ki temelji na podatkih. V svojem jedru je PdM zgrajen na štirih temeljnih stebrih digitalizacije: medsebojna povezljivost, vpogledi, ki temeljijo na podatkih, avtomatizacija in ustvarjanje vrednosti (Berger, 2018) . Ta načela omogočajo brezhibno zbiranje, analizo in uporabo podatkov senzorjev, kar industriji omogoča predvidevanje okvar opreme, optimizacijo urnikov vzdrževanja in izboljšanje kakovosti storitev.

- **Medsebojna povezljivost:** brezhibna integracija naprav in sistemov, ki jo omogoča IoT, zagotavlja izmenjavo podatkov v realnem času in izboljšano operativno vidljivost ter tvori temelje pametne proizvodnje (IBM Business operations, 2023) .
- **Digitalni podatki:** Nenehno zbiranje in obdelava operativnih meritev omogočata vpogled, ki jih je mogoče uporabiti, in spodbuja kulturo odločanja, ki temelji na podatkih (Google Cloud, 2025) .
- **Avtomatizacija:** uvedba algoritmov in robotike, ki jih poganja AI, zmanjša človeško posredovanje, optimizira vzdrževalna dejanja in izboljša splošno učinkovitost (IBM Business operations, 2023) .
- **Ustvarjanje vrednosti:** Digitalna preobrazba izboljšuje storitvene modele, izboljšuje zadovoljstvo strank in spodbuja trajnostno rast poslovanja (urednica SSON, Barbara Hodge, 2019) .




Source: Roland Berger

Slika 6. Štirje temeljni kamni digitalizacije - Roland Berger



Medtem ko je tradicionalno prediktivno vzdrževanje temeljilo na sistemih, ki temeljijo na pravilih, in statističnih modelih, je napredek na področju IoT, AI in generativne AI revolucioniral njegove zmogljivosti.

To poglavje preučuje okvir PdM, ki izkorišča internet stvari, umetno inteligenco in velike multimodalne modele (LMM) za reševanje izzivov predvidenega vzdrževanja. Poleg tega poudarja transformativno vlogo generativne umetne inteligence pri premagovanju omejitev, s katerimi se soočajo tradicionalni pristopi.



Slika 7. Sistemska arhitektura za inteligentne in PdM 4.0.

([1912.07383] Anketa o predvidenem vzdrževanju: sistemi, nameni in pristopi , 2019)

4.1.1. IoT KOT TEMELJ

Pridobivanje podatkov prek naprav IoT.

IoT senzorji so hrbtenica PdM , ki zagotavljajo podatke v realnem času o stanju stroja, vključno s temperaturo, vibracijami, tlakom, porabo energije itd. Ti senzorji, nameščeni neposredno na kritične komponente, omogočajo neprekinjeno spremljanje in zbiranje podatkov, kar je bistveno za napovedno analitiko (IBM Business operations, 2023) . Na primer:

- **Vibracijski senzorji** zaznavajo nepravilnosti v vrtečih se strojih.
- **Toplotni senzorji** prepoznajo pregrete komponente.
- **Akustični senzorji** zajamejo zvočne vzorce, ki kažejo na obrabo.
- Senzorji vlažnosti pomagajo zaznati tveganje korozije ali okvare, ki jih povzroči vlaga, v električnih komponentah.
- **Plinski senzorji** lahko zaznajo uhajanje v industrijskih okoljih, zlasti za nevarne pline.
- **Senzorji toka in napetosti** spremljajo električna nihanja, kar lahko kaže na poslabšanje motorja ali napake v ožičenju.



- **Senzorji napetosti** merijo mehanske napetosti in deformacije, da napovejo morebitne strukturne okvare strojev.
- **Senzorji kakovosti olja in delcev** analizirati zdravje maziva in zaznati kovinske delce, ki kažejo na obrabo zobnikov ali ležajev.
- **Ultrazvočni senzorji** prepoznajo puščanje tekočine, razpoke ali nepravilno mazanje z visokofrekvenčnimi zvočnimi valovi.

Prenos podatkov in robno računalništvo : Podatki se prenašajo prek računalniških sistemov v oblaku ali robnih računalniških sistemov za obdelavo v realnem času, zmanjšanje zakasnitve in optimizacijo pasovne širine (Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan in Yi Zhou, 2021) .

Povezljivost : Zbrani podatki se prenašajo v centralne sisteme z uporabo rešitev povezljivosti IoT. To zagotavlja, da so podatki iz različnih delov operacije združeni za celovito analizo .

Vpliv 5G na predvideno vzdrževanje

Uvedba tehnologije 5G omogoča hitrejši in zanesljivejši prenos podatkov. Z večjimi pasovnimi širinami in nižjimi zakasnitvami 5G bistveno izboljša komunikacijo med IoT senzorji in centralnimi podatkovnimi platformami. To vodi do učinkovitejše obdelave podatkov in omogoča analize v realnem času, ki še povečajo učinkovitost prediktivnih vzdrževalnih sistemov. 5G podpira tudi integracijo in uporabo obogatene resničnosti in drugih naprednih tehnologij v procesih vzdrževanja. (*Prediktivno vzdrževanje* , 2024)

4.1.2. SHRANJEVANJE IN OBDELAVA PODATKOV

- **Shranjevanje v oblaku**: Podatki interneta so pogosto shranjeni v sistemih, ki temeljijo na oblaku, da se omogočijo razširljive rešitve za shranjevanje in dostopnost za nadaljnjo obdelavo (IBM Business operations, 2023) .
- **Predhodna obdelava podatkov**: Pred analizo so podatki podvrženi korakom predhodne obdelave za čiščenje in normalizacijo podatkov, pri čemer se obravnavajo težave, kot so manjkajoče vrednosti in hrup (Riccio et al., 2024) .

4.1.3. PREDIKTIVNA ANALITIKA, KI JO POGANJA AI

4.1.3.1. IZZIVI PRI TRADICIONALNIH METODAH PREDIKTIVNEGA VZDRŽEVANJA

Čeprav tradicionalne metode prediktivnega vzdrževanja ostajajo uporabne v določenih situacijah, se soočajo z več izzivi, ki zmanjšujejo njihovo učinkovitost v današnjih zapletenih industrijskih okoljih, ki vsebujejo veliko podatkov . Glavne omejitve vključujejo:





Slika 8. Izzivi pri tradicionalnih metodah prediktivnega vzdrževanja

Tabela 6. Izzivi pri tradicionalnih metodah prediktivnega vzdrževanja


Izziv	Vpliv
Omejena uporaba podatkov	Omejena zmožnost zajemanja podatkov o zmogljivosti in stanju opreme v realnem času
Reaktivna narava	Nepričakovani izpadi, izguba proizvodnje in višji stroški popravil zaradi vzdrževanja, ki se začne šele po pojavu težave
Netočne napovedi	Lažni alarmi ali zgrešeni zgodnji znaki poslabšanja zaradi zanašanja na pristope, ki temeljijo na pravilih ali pragovih
Kakovost in doslednost podatkov	Zmanjšana zanesljivost napovedi zaradi človeške napake, nedoslednih praks snemanja in napak pri vnosu podatkov
Visoki stroški vzdrževanja	Povečani stroški vzdrževanja zaradi nujnih popravil, nadurnega dela in dragih rezervnih delov zaradi reaktivnega vzdrževanja
Vpliv izpadov	Moteni proizvodni urniki in zmanjšana operativna učinkovitost zaradi daljših izpadov opreme zaradi pregledov in popravil
Omejena razširljivost	Neučinkovita uporaba človeških virov in časa v panogah z velikim številom sredstev ali zapletenimi stroji zaradi metod, ki temeljijo na ročnih pregledih
Kompleksnost starejše opreme	Težave in stroški pri naknadnem opremljanju starejše opreme s senzorji, potrebnimi za sodobne pristope prediktivnega vzdrževanja
Pomanjkanje proaktivnega vzdrževanja	Prekomerno ali premalo vzdrževanje, ki je posledica rutinskega koledarskega vzdrževanja, ki ni usklajeno z dejanskim stanjem opreme
Varnostna tveganja	Povečana varnostna tveganja za osebe in okolje zaradi zapoznelega ali zanemarnjenega vzdrževanja zaradi reaktivne narave tradicionalnih metod
Skladnost s predpisi	Izzivi pri izpolnjevanju varnostnih in okoljskih predpisov zaradi nezadostne dokumentacije o skladnosti in sledljivosti, ki jo zagotavljajo tradicionalne metode



Konkurenčna pomanjkljivost	Težave pri tekmovanju s konkurenti, ki sprejemajo naprednejše strategije predvidenega vzdrževanja
-----------------------------------	---

4.1.3.2. PRIMERI UPORABE AI PRI PREDIKTIVNEM VZDRŽEVANJU

Da bi premagali te omejitve, se številne industrije usmerjajo k sodobnim strategijam predvidenega vzdrževanja, ki vključujejo AI, generativno AI (glejte namensko poglavje »Evolucija proti generativni AI«, ki poudarja vplive GenAI), strojno učenje in napovedno analitiko. Ti napredni pristopi povečajo natančnost napovedi, zmanjšajo čas izpadov, zmanjšajo stroške vzdrževanja in izboljšajo zanesljivost sredstev.




Slika 9. Primeri uporabe AI pri prediktivnem vzdrževanju

- **Modeli strojnega učenja:** Tradicionalni PdM se močno zanaša na modele strojnega učenja za analizo zgodovinskih podatkov in prepoznavanje vzorcev, ki kažejo na morebitne napake. Običajno se uporabljajo algoritmi, kot so regresijski modeli, drevesa odločanja, naključni gozd, stroji podpornih vektorjev in nevronske mreže (Alexander Barinov, 2022).
- **Veliki modeli strojnega učenja (LMM):** LMM izboljšujejo PdM z izkoriščanjem ogromnih količin podatkov in sofisticiranih algoritmov za izboljšanje natančnosti napovedi napak. Ti modeli lahko obdelujejo zapletene nize podatkov in se iz njih učijo, zaradi česar so bolj robustni pri napovedovanju redkih ali redkih napak (Johnson, 2023).
- **Globoko učenje (DL):** v podatkovno intenzivnih scenarijih napredne tehnike, kot je globoko učenje, bistveno izboljšajo napovedne zmogljivosti. Algoritmi globokega učenja so odlični pri obdelavi zapletenih naborov podatkov, kot so podatki visokofrekvenčnih senzorjev, kar jim omogoča zaznavanje subtilnih variacij, ki kažejo na morebitne težave. Te prednosti smo opazili v našem sodelovanju z globalnim ponudnikom širokopasovnih storitev med letom. Z uporabo strojnega učenja in napredne analitike je N- iX razvil napovedne modele za spremljanje stanja antene in predvidevanje morebitnih okvar. Ti modeli so dosegli več kot 90-odstotno natančnost pri napovedovanju težav z opremo do 30 dni vnaprej. Posledično je ta rešitev zmanjšala Gogovo stopnjo brez odkritih napak za 75 %, optimizirala operativne stroške in močno izboljšala izkušnjo potnikov med letom. (Jaroslav Mota, 2024). Študija (Hatipoğlu et al., 2023) je primerjala uspešnost šestih **metod strojnega učenja – logistične regresije, naivnega Bayesa, odločitvenih dreves, podpornih vektorskih strojev, naključnih gozdov in K-najbližjih sosedov** – skupaj z dvema arhitekturama



globokega učenja, dolgoročnim kratkoročnim spominom (LSTM) in zaprtimi ponavljajočimi se enotami (GRU). Analiza je bila izvedena z uporabo nabora podatkov Predictive Maintenance iz UCI Machine Learning Repository, rezultati pa so bili ocenjeni s štirimi ključnimi metrikami: natančnost, preciznost, priklic in F1-ocena.




Slika 10. Prediktivni sistem vzdrževanja, imena metod in arhitektur

Rezultati: V nalogi večrazredne klasifikacije sta modela globokega učenja LSTM in GRU dosegla natančnost 97,51 %, medtem ko ju je model strojnega učenja Random Forest (RF) nekoliko presegel z 98,26 % natančnostjo. Za binarno klasifikacijo, ki se uporablja za primerjavo rezultatov z obstoječimi študijami, so RF, LSTM in GRU vsi pokazali več kot 97-odstotno natančnost, kar poudarja njihovo močno napovedno učinkovitost.

4.1.3.3. PREDNOSTI PREDVIDENEGA VZDRŽEVANJA, KI GA POGANJA AI

Prediktivno vzdrževanje, ki ga poganja AI zagotavlja **znatne prednosti** v panogah, saj izboljšuje **operativno učinkovitost**, **znižuje stroške** in **povečuje zanesljivost sredstev**. Ključne prednosti prediktivnega vzdrževanja, ki ga poganja AI, vključujejo:





LeewayHertz

Slika 11. Prednosti predvidenega vzdrževanja, ki ga poganja AI

4.1.4. SISTEMI ZA PODPORO ODLOČANJU O VZDRŽEVANJU

- **Avtomatizirano načrtovanje vzdrževanja:** odločanje na podlagi umetne inteligence optimizira vzdrževalne posege, uravnaveša stroške in učinkovitost (Yaroslav Mota, 2024) .
- **Ocena tveganja napake:** modeli AI zagotavljajo vzdrževalnim ekipam intervale zaupanja in ocene zanesljivosti (SAE Media, 2024) .

4.1.5. INTERPRETACIJA PODATKOV IN KONTEKSTUALIZACIJA - VLOGA VELIKIH JEZIKOVNIH MODELOV (LLM) V PDM

Pred pojavom generativne umetne inteligence so se veliki jezikovni modeli (LLM) uporabljali predvsem za naloge **obdelave naravnega jezika (NLP)**, kot so **klasifikacija besedila, prevajanje, analiza čustev in odgovarjanje na vprašanja**. Ti modeli so bili zasnovani za **analizo, interpretacijo in pridobivanje vpogledov** iz besedilnih podatkov, namesto da bi ustvarili povsem novo vsebino na kreativen ali dinamičen način.

Kako LLM obdelujejo podatke:

- **Razumevanje nestrukturiranih podatkov:** veliki jezikovni modeli (LLM) lahko berejo in analizirajo **dnevnike vzdrževanja in opombe tehnikov** , ki so pogosto napisani v prosti obliki. Tradicionalni modeli umetne inteligence imajo težave s to vrsto podatkov, vendar LLM-ji iz njih pridobijo dragocene vpoglede (7Puentes, 2024) .
- **Izboljšanje diagnoze napak:** S primerjavo **zgodovinskih zapisov o napakah** s podatki o opremi v realnem času LLM pomagajo prepoznati **temeljne vzroke okvar strojev** , zaradi česar je diagnostika natančnejša (nevronski koncept, nd) .
- **Učenje na podlagi pravil in pod nadzorom:** Zgodnji študiji LLM so se v veliki meri zanašali na **statistične metode, algoritme, ki temeljijo na pravilih, in učenje pod nadzorom** z oznakami. Zahtevali so strukturirane nabore podatkov, kjer so bili vhodi eksplicitno preslikani v pričakovane rezultate, kar je omejilo njihovo prilagodljivost novim kontekstom. nabori podatkov (nevronski koncept, nd) .



Zgodnji LLM (pred generativnim AI) izboljšajo natančnost napovedovanja

- **Prepoznavanje vzorcev:** LLM izpopolnjujejo napovedne modele tako, da identificirajo korelacije, ki presegajo numerične podatke, kar vodi do izboljšane odkritja anomalij (Urednik, 2019) .
- **Prilagodljivo učenje:** Ti modeli se nenehno izboljšujejo z učenjem s krepitvijo in prilagajanjem spreminjajočim se delovnim pogojem (IBM Business operations, 2023) .

Z omejitvami:

- **Učenje na podlagi pravil in nadzorovano:**
 - Starejši LLM-ji so bili odvisni od **vnapij določenih pravil in strukturiranih naborov podatkov, kar pomeni, da so** za pravilno delovanje potrebovali **jasne vhodno-izhodne preslikave** (nevronske koncepte, nd) .
 - Zaradi tega so bili **manj prilagodljivi** novim situacijam, kjer so bili prisotni nepričakovani vložki.
- **Omejeno kontekstualno razumevanje:**
 - Zgodnji veliki jezikovni modeli so lahko **brali in povzemali besedilo**, vendar so imeli težave pri ustvarjanju smiselne nove vsebine (IBM Business operations, 2023) .
 - Namesto dinamičnega odzivanja so preprosto **pridobili in predstavili** najbolj ustrezne vnapij usposobljene odgovore.
- **Napovedno, ne generativno:**
 - Ti modeli so bili dobri pri **zapolnjevanju manjkajočih besed** ali prepoznavanju **ključnih vpogledov iz podatkov**, vendar **niso mogli ustvariti novih poročil, sintetičnih naborov podatkov ali ustvariti odgovorov, podobnih človeku** (Alexander Barinov, 2022) .
 - Njihova glavna uporaba je bila **pridobivanje znanja**, ne pa **pisanje poročil ali simulacija scenarijev vzdrževanja**.
 - Njihovi odgovori so večinoma **temeljili na iskanju**, kar pomeni, da so izbrali najbolj ustrezne vnapij usposobljene rezultate, namesto da bi dinamično ustvarjali nove.

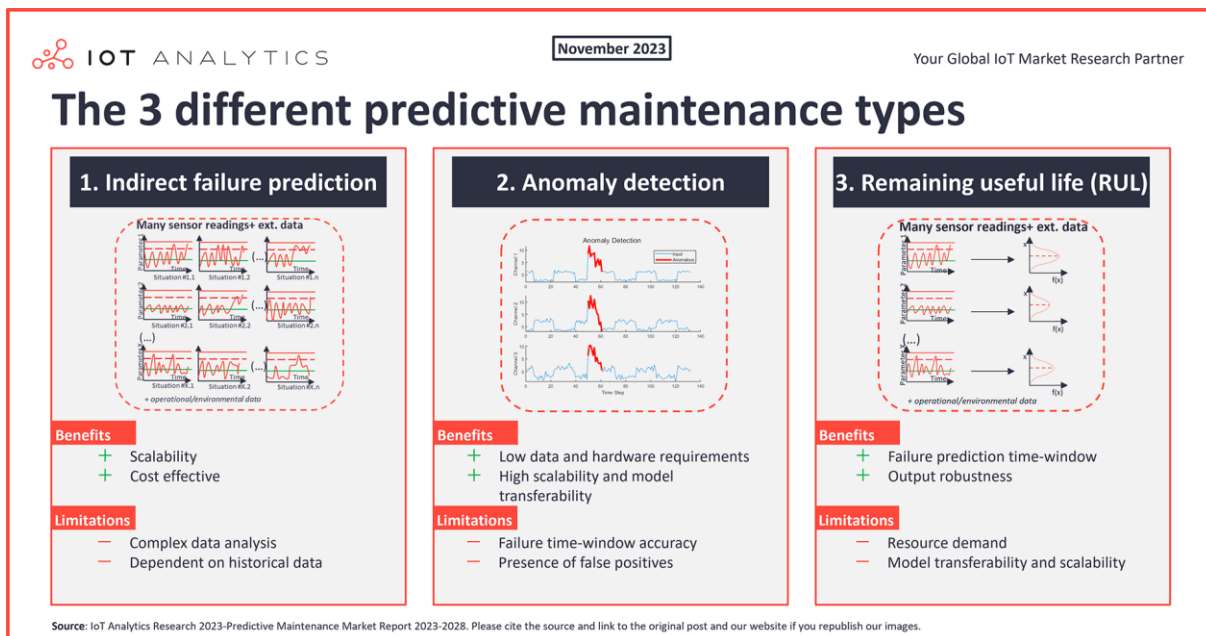
4.1.6. TRI VRSTE PREDVIDENEGA VZDRŽEVANJA

Prediktivno vzdrževanje se je razvilo v **tri glavne vrste**, od katerih se vsaka razlikuje po **ciljih, metodah analize podatkov in rezultatih** (Fernando Brügge, 2023) :

1. **Posredno predvidevanje napak** – Ocenjuje stanje stroja na podlagi zgodovine delovanja in pogojev.
 -  **Za:** razširljiv, stroškovno učinkovit, uporablja obstoječe podatke.
 -  **Slabosti:** Ne predvideva natančnega časa napake, odvisno od preteklih podatkov.
2. **Zaznavanje anomalij** – Prepozna nepravilnosti v delovanju stroja brez podatkov o napakah z uporabo **nenadzorovanega učenja** .
 -  **Prednosti:** Deluje z minimalno količino podatkov, zelo razširljiv med stroji.
 -  **Slabosti:** Ne navaja časa napake, tveganje lažnih pozitivnih rezultatov.
3. **Predvidevanje preostale uporabne življenjske dobe (RUL)** – Ocení, kako dolgo bo stroj deloval pred odpovedjo na podlagi **indikatorjev stanja** .
 -  **Za:** Zagotavlja **natančne ocene časa odpovedi** , kar je ključnega pomena za industrije, ki potrebujejo vnapijšnje načrtovanje vzdrževanja.
 -  **Proti:** visoki računski stroški, zahteva prekvalificiranje za različne stroje in okolja.



Medtem ko se posredno napovedovanje napak pogosto uporablja, raziskave kažejo, da odkrivanje nepravilnosti pridobiva na moči zaradi svoje prilagodljivosti in nižjih podatkovnih zahtev.




Slika 12. 3 različne vrste predvidenega vzdrževanja

4.1.7. KLJUČNE ZNAČILNOSTI PROGRAMSKE OPREME ZA PREDVIDENO VZDRŽEVANJE

Programska oprema je prevladovala na trgu prediktivnega vzdrževanja in leta 2022 predstavljala 44 % industrije. Kljub razlikam med prodajalci je programski opremi za napovedno vzdrževanje skupnih šest glavnih funkcij :

1. **Zbiranje podatkov** – zbira in normalizira podatke o stanju sredstev. (Primer: aplikacija Predictronics DAQ sinhronizira zbiranje podatkov med senzorji.)
2. **Analitika in razvoj modelov** – identificira vzorce napak in gradi napovedne modele. (Primer: Falkonry's Workbench omogoča analizo z nizko kodo, ki jo poganja AI.)



Slika 13. Zaslona za preverjanje kakovosti Workbench, ki prikazuje podatkovne točke skozi čas za pomoč operaterjem pri prepoznavanju vzorcev (Vir: Falkonry)


3. **Vnaprej usposobljeni modeli** – modeli, pripravljeni za uporabo za določena sredstva in načine napak (Primer: AspenTech's Mtell ponuja predloge za posamezne panoge.)

4. **Vizualizacija stanja in opozorila** – sporoča vpoglede v sredstva prek nadzornih plošč in samodejnih opozoril. (Primer: SAS Asset Performance Analytics pošilja obvestila o napakah v realnem času.)



Slika 14. Nadzorna plošča stanja SAS Asset Performance Analytics, ki prikazuje podatke o neobičajnih dogodkih izbranih sredstev (Vir: SAS Institute)


5. **Integracija tretjih oseb** – povezuje se z zunanjo programsko opremo (ERP, MES, CMMS, SCADA). (Primer: spremljanje stanja SKF je integrirano s sistemi za nadzor obrata.)



Slika 15. SKF ponuja portal za razvijalce API-jev za pomoč razvijalcem pri integracijah tretjih oseb, s prikazanimi primeri integracij (Vir: SKF)

6. **Predpisani ukrepi** – Predlaga korektivne ukrepe na podlagi napovedi napak. (Primer: Arundov maraton zagotavlja vodene delovne tokove reševanja.)





Slika 16. Vmesnik Marathon Investigations ponuja predpisane ukrepe za reševanje morebitne težave (Vir: Arundo)

Te funkcije skupaj povečujejo **učinkovitost predvidenega vzdrževanja**, kar omogoča spremljanje v realnem času, proaktivno odločanje in izboljšano zanesljivost sredstev.

4.2. POMEMBNI IZZIVI PdM

Pred pojavom **generativne umetne inteligence** se je prediktivno vzdrževanje (PdM) soočalo z več velikimi izzivi.

4.2.1. PRIDOBIVANJE PODATKOV IN KAKOVOST

- Heterogeni viri podatkov: Zbiranje doslednih in visokokakovostnih podatkov je težko zaradi raznolike opreme in sistemov za spremljanje, kar povzroča izzive pri interpretaciji podatkov.
- Ročno zbiranje podatkov: Zanašanje na ročne postopke za pridobivanje in čiščenje podatkov je bilo delovno intenzivno in nagnjeno k napakam, kar je oviralo pravočasne in natančne vzdrževalne odločitve.
- Omejena prilagodljivost nestrukturiranim podatkom:
- Predgenerativni AI LLM-ji so bili manj prilagodljivi pri ravnanju z zelo nestrukturiranim besedilom, kot so opombe tehnikov v prosti obliki pri Prediktivnem vzdrževanju (PdM).
- Potrebovali so strukturirane nabore podatkov za usposabljanje in pogosto imeli težave z razumevanjem domensko specifičnega jezika zunaj svojih usposobljenih korpusov.

(7Puentes, 2024; SAE Media, 2024)



4.2.2. INTEGRACIJA S STARIMI SISTEMI

Težave z združljivostjo: Integracija orodij PdM z obstoječo infrastrukturo je pogosto zahtevala veliko truda za zagotovitev brezhibne interoperabilnosti, kar je predstavljalo oviro za učinkovito implementacijo (Johnson, 2023; Yaroslav Mota, 2024).

4.2.3. VISOKA ZAČETNA NALOŽBA

Stroškovne ovire: Implementacija tradicionalnega PdM je zahtevala znatne vnaprejšnje naložbe v draga senzorska omrežja, shranjevanje v oblaku, programsko opremo in usposobljeno osebje, kar bi lahko bilo previsoko, zlasti za manjše organizacije, zaradi česar je manj dostopno za MSP (Johnson, 2023; Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan in Yi Zhou, 2021) .

4.2.4. NEGOTOVOST V PROGNOSTIKI

Tradicionalne metode PdM so pogosto imele težave z natančnim napovedovanjem okvar opreme zaradi negotovosti v sistemskih parametrih in modelih degradacije, kar je vodilo do nepotrebnega vzdrževanja ali nepričakovanih okvar (Alexander Barinov, 2022) .

4.2.5. KIBERNETSKA VARNOST PRI INDUSTRIJSKEM VZDRŽEVANJU

Ker se Prediktivno vzdrževanje (PdM) razvija z industrijo 4.0, je kibernetska varnost postala velika skrb zaradi povečane integracije naprav IoT, modelov AI in infrastruktur v oblaku. Ti napredki uvajajo ranljivosti, zaradi česar so industrijski nadzorni sistemi (ICS) in infrastrukture operativne tehnologije (OT) bolj dovzetni za kibernetske napade. Za ublažitev teh tveganj se pobude, kot je **DETECTA 2.0**, osredotočajo na integracijo ukrepov kibernetske varnosti v PdM , s čimer se poveča odpornost za mala in srednje velika podjetja (MSP). **Podrobnosti so opisane v temu namenjenem poglavju .**

4.3. EVOLUCIJA V SMERI GENERATIVNE UMETNE INTELIGENCE

Z Generative AI (po letu 2023) so LLM prešli iz analitičnih v kreativne sisteme , ki so sposobni koherentnega ustvarjanja besedila, ki se zaveda konteksta, ustvarjanja sintetičnih podatkov in inteligentnih odzivov na zapletene poizvedbe. (Horn, 2024) .

Kakšen vpliv ima generativni AI na PdM ? Tukaj je nekaj odgovorov.

4.3.1. KAKOVOST PODATKOV IN USPOSABLJANJE MODELA

- **Povečanje podatkov:** Eden glavnih izzivov, s katerimi se sooča PdM, je pomanjkanje podatkov o okvarah, pri čemer se za preprečevanje okvar opreme uporabljajo tradicionalne vzdrževalne strategije. Generativni AI, zlasti Generative Adversarial Networks (GAN), pomaga pri reševanju tega z ustvarjanjem sintetičnih podatkov, ki jih je mogoče uporabiti za usposabljanje modelov strojnega učenja, s čimer se izboljša njihova robustnost in natančnost (Alexander Barinov, 2022; Horn, 2024).
- **Izboljšano usposabljanje za modele:** Z vključitvijo sintetičnih podatkov generativni AI zagotavlja, da so modeli izpostavljeni širšemu naboru scenarijev napak, kar izboljša njihove napovedne zmožnosti (Riccio et al., 2024) .



- V **Predictive Maintenance** ta premik omogoča LLM-jem, da **simulirajo poročila o vzdrževanju, ustvarijo napovedne vpogleda, ustvarijo sintetične podatke o usposabljanju za izboljšanje** modelov PdM, ki jih poganja AI, in **pomagajo pri pridobivanju znanja iz nestrukturiranih dnevnikov vzdrževanja**, funkcije, ki niso bile mogoče s tradicionalnimi LLM-ji. (7 Puentes, 2024)

Revidiran sklep o treh vrstah predvidenega vzdrževanja

Medtem ko je **odkrivanje anomalij postajalo vse bolj priljubljeno** zaradi manjših potreb po podatkih, **Generative AI (Gen AI) spreminja prediktivno vzdrževanje s krepitvijo vseh pristopov**.

1. Izboljšanje posrednega predvidevanja napak

- Gen AI **generira sintetične podatke o napakah** in izboljšuje modele, tudi če so zgodovinski zapisi omejeni (Samana, 2023).
- To poveča natančnost predvidevanja v **različnih pogojih delovanja**, zaradi česar je posredno napovedovanje napak bolj razširljivo.

2. Izboljšanje odkrivanja nepravilnosti

- Gen AI **natančneje prepozna običajne in nenormalne vzorce delovanja**, kar zmanjša lažne pozitivne rezultate.
- Izboljšuje modele nenadzorovanega učenja s simulacijo **nenormalnih dogodkov**, ki se redko pojavljajo v podatkih iz resničnega sveta.

3. Napredna napoved RUL

- Gen AI **napove trende razgradnje** in sintetizira manjkajoče indikatorje stanja, zaradi česar so ocene preostale uporabne življenjske dobe (RUL) **bolj zanesljive**.
- Omogoča prilagodljive modele v **različnih okoljih**, kar zmanjšuje potrebe po ponovnem usposabljanju (Reuters, 2024a).
- Ker sprejemanje umetne inteligence v industrijskih okoljih narašča, se prediktivno vzdrževanje **usmerja k hibridnemu pristopu**, ki vključuje **več tehnik, ki jih poganja umetna inteligenca**, namesto da bi dajal prednost eni prevladujoči metodi. Vodilna podjetja, kot sta **GE Aerospace** in **Air France-KLM**, že izkoriščajo **prediktivno vzdrževanje s pomočjo umetne inteligence** za izboljšanje zanesljivosti opreme in zmanjšanje časa izpadov (Reuters, 2024b; Root, 2023).

4.3.2. STRATEGIJE AVTOMATIZIRANEGA VZDRŽEVANJA

Generativno umetno inteligenco je mogoče uporabiti tudi za razvoj avtomatiziranih načrtov in strategij vzdrževanja, napovedovanje najboljših časov za vzdrževalne dejavnosti in optimizacijo dodeljevanja virov (nevronskega koncepta, nd).

4.3.3. INTEGRACIJA S STARIMI SISTEMI

PdM, ki ga poganja AI, v obstoječo infrastrukturo (Yaroslav Mota, 2024).

4.3.4. VISOKI ZAČETNI STROŠKI NALOŽBE

Virtualni senzorji, ki jih poganja AI, zmanjšujejo odvisnost od strojne opreme, medtem ko avtomatizacija, ki temelji na AI, z optimizacijo načrtovanja vzdrževanja znižuje stroške delovne sile (IBM Business operations, 2023).



4.3.5. RAZLOŽLJIV AI (XAI) IN INTERPRETABILNO STROJNO UČENJE (IML)

Integracija umetne inteligence (AI), interneta stvari (IoT) in vmesnikov človek-stroj povezuje sisteme strojne in programske opreme za optimizacijo procesov avtomatizacije.

Ko se industrijska krajina razvija v smeri industrije 5.0, se poudarek premika s pristopov, osredotočenih na stroj, na pristope, osredotočene na človeka. V tej novi paradigmi tehnologije umetne inteligence pomagajo človeškim nalogam povečati produktivnost, kar poudarja potrebo po razločljivem umetni inteligenci (XAI) in razločljivem strojnem učenju (IML). Ti so bistveni za razumevanje kompleksnih sistemov PdM in zaupanje vnje, saj naredijo procese odločanja modelov AI pregledne za uporabnike.

O razlikovanju med **razločljivostjo** in **interpretabilnostjo** v AI in ML. Nekateri raziskovalci izraze zaradi poenostavitve uporabljajo zamenljivo, medtem ko drugi trdijo, da predstavljajo različne koncepte. Tretji pogled nakazuje, da je eno podmnožica drugega. Raziskava (Logan Cummins, 2024) jih obravnava kot sorodna, a različna, z nekaj prekrivanja, pri čemer vsak poudarja edinstvene vidike strojnega učenja.

Ta anketa ponuja temeljno razlago razločljive umetne inteligence (XAI), razločljivega strojnega učenja (iML) in predvidenega vzdrževanja (PdM) za bralce iz različnih okolij:

1. **Razločljivost proti razlagalnosti:** nekateri raziskovalci vidijo te izraze kot medsebojno zamenljive, jih drugi vidijo kot različne. Članek jih obravnava kot povezane, a ločene koncepte, pri čemer se **XAI** osredotoča na razumevanje izhodov modela (običajno prek post-hoc metod, kot sta SHAP in LIME), **iML** pa se osredotoča na interpretabilnost samega modela.
2. **Razločljiva umetna inteligenca (XAI):** XAI želi pojasniti napovedi modela AI. Tehnike delimo na:
 - **Model-agnostične metode** (npr. SHAP, LIME), uporabne v vseh vrstah modelov.
 - **Metode, specifične za model** (npr. preslikava aktivacije razreda za CNN), prilagojene specifičnim arhitekturam.
 - **Lokalne v primerjavi z globalnimi razlagami**, kjer lokalne razlage obravnavajo posamezne napovedi, globalne razlage pa dajejo splošen pogled na model.
3. **Interpretabilno strojno učenje (iML):** Za razliko od XAI, iML vključuje modele z intrinzično interpretabilnostjo, kot je logistična regresija, kjer so izhodi naravno razumljivi zaradi preprostosti modela.
4. **Predvideno vzdrževanje (PdM):** PdM uporablja AI za vnaprejšnje napovedovanje mehanskih okvar z uporabo orodij, kot so:
 - **Zaznavanje nepravilnosti** (za ugotavljanje, če je prišlo do napake),
 - **Diagnostika napak** (za določitev vzroka napak),
 - **Napoved** (za napoved preostale življenjske dobe ali časa do okvare).

Razločljive metode, specifične za model, obravnavane v dokumentu za predvideno vzdrževanje:

1. **Class Activation Mapping (CAM) in GradCAM:** CAM zagotavlja globalne razlage za CNN s poudarjanjem slikovnih regij, povezanih z napovedmi razreda, z uporabo plasti združevanja globalnih povprečij. GradCAM to izboljša z uporabo informacij o gradientu za bolj osredotočene razlage, ki prikazujejo pomembne funkcije, ki jih uporablja model.
2. **DIFFI (Depth-based Isolation Forest Feature Importance):** DIFFI pojasnjuje izolacijske gozdove, ki se uporabljajo za odkrivanje anomalij, z razvrščanjem funkcij na podlagi njihove vloge pri izolaciji nepravilnih podatkov. Ta metoda je bila uporabljena za scenarije, kot je odkrivanje nepravilnosti v podatkih časovnih vrst.



3. **LionForests:** lokalna razlagalna metoda za naključne gozdove, ki generira pravila ČE-POTEM in vizualizacije, zaradi česar so prispevki funkcij razložljivi. To je bilo razširjeno za obravnavanje klasifikacij z več oznakami pri diagnosticiranju napak.
4. **Zemljevidi opaznosti:** Za CNN zemljevidi opaznosti razvrščajo pomembnost slikovnih pik tako, da približajo izhod modela kot linearno funkcijo okoli vhoda, s poudarkom na vplivnih vhodnih funkcijah.
5. **ARCANA (Analiza temeljnega vzroka nepravilnosti na osnovi samodejnega kodiranja):** ARCANA interpretira rezultate samodejnega kodiranja za odkrivanje nepravilnosti z identifikacijo funkcij, ki povzročajo napake pri rekonstrukciji. Uporabljen je bil pri vzdrževanju vetrnih turbin za natančno določanje vzrokov odkritih nepravilnosti.

Te metode izboljšujejo interpretabilnost z izkoriščanjem posebnih arhitekturnih funkcij, kar uporabnikom omogoča boljše razumevanje odločitev modela pri nalogah, kot so diagnosticiranje napak, odkrivanje nepravilnosti in analiza temeljnih vzrokov.

Študije, ki združujejo več razložljivih metod za napovedno vzdrževanje, uporabljajo različne pristope:

1. **Zloženi pristop:** Metode se uporabljajo zaporedno. Jakubowski idr. uporabil kvazisamodejni kodirnik za odkrivanje nepravilnosti z XGBoostom kot nadomestnim modelom, s čimer je izboljšal razložljivost s SHAP-ovim TreeExplainerjem.
2. **Hkratni pristop:** več metod se uporablja skupaj za različne vpoglede:
 - **Khan et al.** uporabil LIME in SHAP na regresorju MLP za napovedi preostale uporabne dobe (RUL), pri čemer je našel podobne, a različne razlage.
 - **Serradilla et al.** uporabil ELI5 in LIME za naključni gozdni model, ki je pokazal pomembnost lastnosti lokalno in globalno.
 - **Brito et al.** našli splošno soglasje med Local-DIFFI in SHAP za odkrivanje napak brez rangiranja enega nad drugim.
3. **Primerjava metod:** Ferraro et al. ocenil LIME in SHAP z uporabo meritev identitete, stabilnosti in ločljivosti, pri čemer je opazil razlike v doslednosti razlage med razredi.
4. **Integracija AutoML:** Li et al. uporabil LIME in SHAP znotraj platform AutoML za podatke o vozilih, s čimer je dosegel potek dela z vgrajeno razložljivostjo, pri čemer se je TPOT izkazal za najbolj natančnega.

Te kombinacije omogočajo bogatejši vpogled v modele in poudarjajo prednosti in omejitve, specifične za metodo.

Med 21 metodami interpretabilnega strojnega učenja (IML), omenjenimi v raziskavi za napovedno vzdrževanje, navedenimi v prilogi 3, je 7 najpogostejše uporabljenih in splošno priznanih:

1. **Mehanizmi pozornosti – pogosto se uporabljajo v modelih globokega učenja, zlasti v LSTM in transformatorjih, za osredotočanje na kritične vhodne funkcije.**
5. **Odločitvena drevesa – Eden najbolj temeljnih interpretabilnih modelov, ki uporabnikom omogoča sledenje odločitvam skozi hierarhično strukturo. Pogosto se uporablja kot osnova pri predvidenem vzdrževanju.**
11. **Explainable Boosting Machine (EBM) – Razširitev GAM-jev, ki združuje tehnike pospeševanja z interpretabilnostjo, zaradi česar je priljubljen pristop ML, ki ga je mogoče interpretirati.**
16. **Digitalni dvojčki – zelo pomembni za industrijo 4.0 in predvideno vzdrževanje, saj ustvarjajo virtualne predstavitve fizičnih sistemov za simulacijo in napovedovanje okvar.**
18. **Splošni aditivni modeli (GAM) – Močna alternativa modelom črne škatle, saj omogočajo pregledno razlago glede na funkcije.**



20. k-Najbližji sosode (kNN) – Enostavno in razumljivo, običajno se uporablja za klasifikacijo in napovedno vzdrževanje.
21. Interpretacije, ki temeljijo na pravilih – Široka uporaba za logiko če-potem, zaradi česar so napovedi lahko razumljive v industrijskih okoljih.

Raziskava izpostavlja več izzivov in raziskovalnih smeri na področju **razložljivega predvidenega vzdrževanja (XPM)** :

1. **Namen razlag**: Pojasnila je treba oblikovati z mislijo na specifično ciljno skupino, saj imajo različne zainteresirane strani (npr. podatkovni znanstveniki, vodje projektov, mehaniki) edinstvene potrebe po razumevanju rezultatov modela. Trenutne razlage pogosto nimajo takšne prilagoditve, ki je usmerjena na občinstvo, kar vpliva na uporabnost razložljivosti .
2. **Vrednotenje razlag**: V nasprotju z meritvami uspešnosti za modele strojnega učenja vrednotenje razlag ni bilo standardizirano. V literaturi so predlagane različne meritve, tako objektivne (npr. zvestoba, stabilnost, robustnost) kot subjektivne (npr. zaupanje, učinkovitost, zadovoljstvo). Vendar ostaja potreba po doslednem okviru za celovito oceno kakovosti razlage.
3. **Dodatek človeškega sodelovanja** : za XPM je potreben pristop, osredotočen na človeka , kjer morajo biti razlage prilagojene različnim vrstam uporabnikov. Ta pristop bi vključeval prepoznavanje ciljnih skupin in prilagajanje razlag na podlagi povratnih informacij, kar bi na koncu podpiralo učinkovitejše partnerstvo med človekom in umetno inteligenco pri predvidenem vzdrževanju.
4. **Omejitve študije**: Raziskava zajema samo podmnožico metod XAI in iML , ki se uporabljajo za napovedno vzdrževanje, pri čemer se priznava, da niso vključeni vsi ustrezni algoritmi. Ta omejitev je navedena kot meja za obseg študije, s potencialom za nadaljnje raziskovanje v širšem kontekstu XPM.

Če povzamemo, ker industrija 5.0 poudarja umetno inteligenco, osredotočeno na človeka, **sta razložljiva umetna inteligenca (XAI) in razložljivo strojno učenje (iML)** bistvena za zaupanje v **prediktivno vzdrževanje (PdM)** . Medtem ko XAI post hoc pojasnjuje modele črne skrinjice, iML zagotavlja inherentno preglednost in pomaga pri odločanju v industrijskih okoljih. Prihodnje raziskave bi se morale osredotočiti na **standardizacijo metrik vrednotenja, prilagajanje razlag zainteresiranim stranem in izboljšanje sodelovanja med človekom in umetno inteligenco** za učinkovitejše rešitve predvidenega vzdrževanja.

4.3.6. ZAKLJUČEK

Generative AI revolucionira PdM z izboljšanjem natančnosti napovedovanja napak, avtomatizacijo načrtovanja vzdrževanja in ustvarjanjem sintetičnih podatkov o usposabljanju. Z naraščanjem sprejemanja umetne inteligence se bo PdM usmeril k hibridnim modelom, ki vključujejo več tehnik umetne inteligence. Vendar pa je treba obravnavati izzive, kot so tveganja kibernetске varnosti in razlagljivost modela, da bi zagotovili široko sprejetje. Podjetja, ki učinkovito izkoriščajo GenAI , bodo pridobila konkurenčno prednost pri predvidenem vzdrževanju in upravljanju sredstev.

4.4. NASTAJAJOČI MODELI IN TEHNOLOGIJE

Razvoj modelov napovednega vzdrževanja odraža prehod od statičnih urnikov vzdrževanja k dinamičnim strategijam, ki temeljijo na podatkih. Ti modeli vključujejo stalno analizo poslabšanja, modeliranje učinkov storitev in oblikovanje politik vzdrževanja za zagotovitev pravočasnih intervencij na podlagi podatkov v realnem času (Artesis, 2021).



Ker se te tehnologije še naprej razvijajo, se pričakuje, da se bo pokrajina prediktivnega vzdrževanja znatno spremenila, kar bo utrla pot za učinkovitejše delovanje v različnih panogah, vključno s proizvodnjo, nafto in plinom ter proizvodnjo električne energije. (ateam_admin, 2023; pleasedontcode, 2024). Več napredkov oblikuje prihodnost PdM.

4.4.1. ŠTUDIJA 1 - NOV METODOLOŠKI OKVIR ZA OPTIMIZACIJO PREDVIDENEGA VZDRŽEVANJA

4.4.1.1. CILJI ŠTUDIJE

Študija iz leta 2024 (Riccio & Menanno, 2024) želi razviti **nov okvir za napovedno vzdrževanje (PdM)**, ki združuje **strojno učenje (ML)** s **parametri kakovosti izdelka (PQ)**. Tradicionalne strategije PdM se v glavnem osredotočajo na stanje opreme in preprečevanje okvar, vendar ta študija predlaga **pristop, ki temelji na kakovosti**, kjer se kazalniki kakovosti izdelkov uporabljajo tudi za optimizacijo vzdrževalnih odločitev. Cilj je določiti **optimalno strategijo PdM**, ki temelji tako na **proizvodni učinkovitosti** kot na **kakovosti izdelka**, da bi zmanjšali stroške, izboljšali zanesljivost stroja in zmanjšali število okvarjenih izdelkov.


4.4.1.2. GLAVNE UGOTOVITVE

- **Integracija ML in kakovosti izdelkov za PdM**
 - Študija vzpostavlja neposredno povezavo med pogoji delovanja stroja in kazalci kakovosti izdelkov.
 - Z integracijo podatkov PQ v ogrodje PdM lahko model **predvidi morebitne okvare** in **optimizira urnike vzdrževanja**, da **zmanjša stopnjo odpadkov**.
- **Razvoj ogrodja v treh korakih**
 - **1. korak:** Določite ključne vhodne spremenljivke (status stroja, tlak, temperaturo in indikatorje PQ, kot je donos pri prvem prehodu – FPY).
 - **2. korak:** zgradite **model strojnega učenja** za predvidevanje odstopanj PQ na podlagi operativnih podatkov. Najuspešnejši model je **Bagged Tree Classifier (BTC)** z **91-odstotno natančnostjo**.
 - **3. korak:** Izvedite **mehanizem mehkega sklepanja (FIE)**, da priporočite vzdrževalne ukrepe na podlagi predvidene kakovosti izdelka in pogojev stroja.
- **Aplikacija študije primera (proizvodna linija za elektromehanske komponente)**
 - Ogrodje je bilo testirano v **proizvodni liniji za energetske transformatorje**.
 - Vakuumski **mešalnik** je bil opredeljen kot najbolj kritičen element, ki vpliva na PQ (85 % vseh odpadkov).
 - Kombinacija **nadzora temperature in tlaka** je bila uporabljena za predvidevanje okvar v **vakuumskih črpalkah**, kar je neposredno vplivalo na kakovost izolacije izdelka.

4.4.1.3. REZULTATI

- Okvir je pokazal, da **napovedovanje potreb po vzdrževanju na podlagi variacij kakovosti izdelkov** vodi do **znatnih prihrankov stroškov** in **izboljšane učinkovitosti**.
- **Finančni vpliv:**
 - **50-odstotno zmanjšanje stroškov izpada stroja**.
 - **64 % zmanjšanje stroškov, povezanih z odpadki**.






Slika 17. Primerjava stroškov med zbiranjem podatkov in uporabo modela

- **Izboljšana zanesljivost:**


- Hkrati pa optimizacija indeksa FPY potrjuje, da vključitev v model indeksa kakovosti proizvodnje, ki ga je potrebno spremljati in optimizirati, učinkovito vodi do izboljšanja kontinuitete delovanja stroja (razpoložljivost se poveča s 93,1 % na 96,6 %), ko je ta indeks odvisen od nekaterih obratovalnih parametrov samega stroja.



Slika 18. FPY primerjava med fazo kot je in uporabo modela.

- **92,8 % potencialnih okvar je bilo potrjenih** s termografskimi pregledi.
- Izboljšanje MTBM (s 37,8 na 48,6 h).





Slika 19. Primerjava MTBM med zbiranjem podatkov in uporabo modela.

¹ **MTBF** (Mean Time Between Failures) je metrika zanesljivosti, ki meri povprečni čas, ki je pretekel med dvema zaporednima okvarama sistema, komponente ali stroja med običajnim delovanjem. Običajno se uporablja pri napovednem vzdrževanju in inženiringu zanesljivosti za oceno vzdržljivosti opreme in načrtovanje urnikov vzdrževanja

² **FPY** (First Pass Yield) je metrika uspešnosti kakovosti, ki meri odstotek izdelkov, ki so pravilno izdelani, ne da bi jih bilo treba predelati ali popraviti v prvem poskusu. Običajno se uporablja v proizvodnji, proizvodnji in nadzoru kakovosti za oceno učinkovitosti in uspešnosti procesa.

- **Ugotovljeni izzivi:**
- Ena napaka je bila izpuščena, ker ni povzročila temperature anomalije, kar je poudarilo omejitve pri trenutni integraciji podatkov senzorja.

4.4.1.4. ZAKLJUČEK

Študija dokazuje, da **integracija strojnega učenja s parametri kakovosti izdelkov izboljša napovedne strategije vzdrževanja**. Predlagani okvir **zmanjša stroške vzdrževanja, minimizira napake in izboljša zanesljivost stroja**. Prihodnje raziskave bi se morale osredotočiti na **nadaljnjo optimizacijo modela, vključitev bolj raznolikih virov podatkov in razširitev njegove uporabe na druge industrijske sektorje**.

4.4.2. ŠTUDIJA 2 – ODKRIVANJE NEPRAVILNOSTI V INDUKCIJSKIH MOTORJIH Z UPORABO PODATKOV IOT V REALNEM ČASU

4.4.2.1. CILJI ŠTUDIJE

Cilj študije (Chevtchenko et al., 2023) je razviti **napovedni model vzdrževanja** z uporabo **odkrivanja nepravilnosti v indukcijskih motorjih** z uporabo **podatkov IoT v realnem času** in tehnik **strojnega učenja (ML)**. Primarni cilji so:



- Zasnovati **nizkocenovni sistem za odkrivanje nepravilnosti v realnem času** za industrijsko opremo.
- Za ovrednotenje **različnih modelov ML** za odkrivanje anomalij z minimalnim računskim naporom.
- Za zagotovitev **optimalnega ravnovesja med natančnostjo zaznavanja anomalij, stopnjo lažno pozitivnih rezultatov in hitrostjo sklepanja** prek **večciljne optimizacije**.
- Ustvariti **splošen okvir**, uporaben v različnih industrijskih kontekstih.

4.4.2.2. GLAVNE UGOTOVITVE

- **Zbiranje podatkov na podlagi interneta stvari:** nabor **podatkov po meri** je bil ustvarjen z združitvijo **podatkov o vibracijah, temperaturi in hrupu** iz senzorjev interneta stvari, priključenih na **indukcijske motorje**.
- **Tehnike predprocesiranja:** študija je uporabila **hitro Fourierjevo transformacijo (FFT), valovito transformacijo (WT) in združevanje** za ekstrahiranje ustreznih funkcij.
- **Modeli strojnega učenja:** Preizkušeni so bili trije modeli za odkrivanje nepravilnosti:
 - **Enorazredni podporni vektorski stroj (OC-SVM)**
 - **Izolacijski gozd (IF)**
 - **Lokalni izstopajoči faktor (LOF)**
- **Strategija optimizacije:** Za optimizacijo hiperparametrov modela za najboljše ravnovesje občutljivosti, specifičnosti in časa sklepanja je bil uporabljen **večciljni optimizacijski pristop (algoritem NSGA-II)**.
- **Meritve vrednotenja:** Modeli so bili ocenjeni na podlagi **občutljivosti (dejanska pozitivna stopnja), specifičnosti (dejanska negativna stopnja) in računske učinkovitosti**.

4.4.2.3. REZULTATI

Primerjava zmogljivosti modelov

Študija je primerjala **tri algoritme ML** na podlagi njihove **občutljivosti, specifičnosti in časa sklepanja** (povprečna zmogljivost med validacijskimi in testnimi nizi podatkov):

Tabela 7. Povzetek povprečnih rezultatov vrednotenja podmnožic validacije/testiranja

Algoritem	Občutljivost (%)	Specifičnost (%)	Čas sklepanja (ms)
OC-SVM	73,1 / 47,9	63,4 / 36,5	0,43
Izolacijski gozd (IF)	88,9 / 86,3	61,6 / 67,4	21.40
Lokalni izstopajoči faktor (LOF)	90,8 / 77,6	74,5 / 72,1	0,81

Ključna opažanja

- **LOF je dosegel najboljše ravnotežje** z najvišjo občutljivostjo in specifičnostjo ob razumnih računskih stroških.
- **FFT je bil dosledno učinkovit** za ekstrakcijo značilnosti, medtem ko **Wavelet Transform ni zagotovil bistvenih prednosti**.
- **Analiza glavnih komponent (PCA) je bila koristna**, saj je zmanjšala dimenzionalnost brez izgube napovedne natančnosti.
- Pristop **senzorja IoT po meri** je učinkovito zajel anomalije pri **neuravnoveženih obremenitvah, poškodovanih ležajih in kratkih stikih statorja**.



4.4.2.4. ZAKLJUČEK

Študija je uspešno razvila **nizkocenovni sistem za predvideno vzdrževanje v realnem času** z uporabo IoT senzorjev in algoritmov ML za odkrivanje nepravilnosti v **indukcijskih motorjih**.

- **LOF se je izkazal kot najučinkovitejši model**, ki zagotavlja **visoko stopnjo odkrivanja nepravilnosti z minimalnim računskim naporom**.
- **Pristop k optimizaciji z več cilji** je pomagal uravnovežiti **natančnost, lažne pozitivne rezultate in hitrost sklepanja** ter tako zagotovil **praktično in razširljivo** rešitev.
- Metodologija je **posplošljiva**, kar omogoča prilagajanje **različnim industrijskim kontekstom**, ki presegajo indukcijske motorje.

4.4.2.5. PRIHODNJE RAZISKOVALNE SMERI:

- **Raziščite kompletne modele**, da zmanjšate prekomerno opremljanje in izboljšate robustnost.
- **Ocenite modele globokega učenja** (npr. **variacijske samodejne kodirnike (VAE)**) za izboljšano odkrivanje nepravilnosti.
- **Razširite nabor podatkov** z industrijskimi stroji iz resničnega sveta, da izboljšate prilagodljivost modela.

Ta raziskava prikazuje **potencial integracije IoT in ML** za ustvarjanje **stroškovno učinkovitih rešitev za predvideno vzdrževanje v realnem času**, zmanjšanje okvar opreme in operativnih stroškov.

4.4.3. ŠTUDIJA 3 - "TRANDDL: OGRODJE PREDPISANEGA VZDRŽEVANJA, KI GA POGANJA GLOBOKO OKREPLJENO UČENJE, KI GA POGANJA TRANSFORMATOR"

4.4.3.1. CILJI ŠTUDIJE

Študija (Zhao et al., 2024) predstavlja **TranDRL**, napredno ogrodje **predpisanega vzdrževanja**, ki združuje **nevronske mreže, ki temeljijo na transformatorju, in globoko okrepljeno učenje (DRL)** za optimizacijo **napovednega in predpisanega vzdrževanja**. Cilji te študije so

- **Izboljšajte oceno preostale uporabne življenjske dobe (RUL)** z uporabo transformatorjev za obdelavo kompleksnih podatkov IoT senzorjev.
- **Optimizirajte odločanje o vzdrževanju** z uporabo DRL, zmanjšajte nepričakovane okvare in izravnajte stroške.
- **Vključite človeške povratne informacije** v okrepiteveno učenje (RLHF), da povečate zanesljivost odločitev in interpretabilnost modela.
- **Omogočite zvezno učenje** za razširljivo uvajanje na več računalnikih brez centralizacije podatkov.

4.4.3.2. GLAVNE UGOTOVITVE

- **Transformatorji prekašajo tradicionalne modele napovedovanja RUL**: v primerjavi z NBeats in DeepAR Transformers izkazujejo vrhunsko zmogljivost pri zajemanju **dolgoročnih odvisnosti v industrijskih podatkih**.
- **Načrtovanje vzdrževanja na podlagi DRL minimizira čas izpadov in stroške**: algoritmi, kot je **PPO (proksimalna optimizacija politike)**, zagotavljajo najboljše ravnotežje med raziskovanjem in izkoriščanjem pri načrtovanju vzdrževanja.



- **Človeške povratne informacije povečujejo zanesljivost modela:** vključitev okrepitvenega učenja, ki temelji na strokovnjakih, zmanjša spremenljivost odločitev in izboljša robustnost priporočil za vzdrževanje.
- **Zvezno učenje omogoča uvajanje na več strojev:** model TranDRL lahko posploši vpogled v predvideno vzdrževanje v **različnih industrijskih sredstvih**, ne da bi zahteval skupno rabo neobdelanih podatkov.

4.4.3.3. REZULTATI

- **Učinkovitost napovedi RUL**
 - Model, ki temelji na transformatorju, prekaša **DeepAR in NBeats** pri napovedovanju **RUL za nabore podatkov NASA C-MAPSS**.
 - **Pristop združenega učenja** ohranja visoko natančnost napovedi RUL na več napravah, hkrati pa zagotavlja **zasebnost podatkov**.
- **Optimizacija odločitve o vzdrževanju z DRL**
 - Primerjajo se modeli DRL (DQN, SAC, PPO) za **optimalno načrtovanje vzdrževanja**.
 - **PPO doseže najvišjo skupno nagrado**, s čimer učinkovito uravnoteži čas vzdrževanja in stroške.
 - **Human-in-the-loop RL** izboljša konsistentnost odločitev in izboljša interpretabilnost.

4.4.3.4. ZAKLJUČEK

Ogrodje TranDRL uspešno združuje poglobljeno učenje in učenje z okrepitvijo za izboljšanje napovednih rezultatov vzdrževanja. Njegovi ključni prispevki vključujejo **izboljšano oceno RUL, inteligentno načrtovanje vzdrževanja in razširljivo uvajanje zveznega učenja**. Študija izpostavlja **praktične aplikacije v industrijskem IoT**, ki prikazuje **pomemben potencial za zmanjšanje izpadov strojev, optimizacijo stroškov vzdrževanja in izboljšanje operativne učinkovitosti**.

4.4.3.5. PRIHODNJE RAZISKOVALNE SMERI

- **Razširitev učenja človeka v zanki** za izboljšanje zaupanja v vzdrževalne odločitve, ki jih vodi umetna inteligenca.
- **Vključitev multimodalnih senzorskih podatkov** (vključno s slikami) za celovitejše spremljanje sredstev.
- **Validacija modela v dejanskih industrijskih okoljih** za oceno razširljivosti in prilagodljivosti.



5. VPLIV PDM V VZDRŽEVALNIH DEJAVNOSTIH NA MSP

Kot je bilo že opisano, je predvideno vzdrževanje (PdM) napredna strategija vzdrževanja, ki izkorišča podatkovno analitiko, umetno inteligenco (AI) in industrijski internet stvari (IIoT) za napovedovanje in preprečevanje okvar opreme, preden do njih pride. Medtem ko so bila velika podjetja pionirji pri sprejemanju PdM, mala in srednje velika podjetja (MSP) vse bolj prepoznajo njegov potencial za izboljšanje operativne učinkovitosti in zmanjšanje stroškov.

5.1. VLOGA PDM V MSP

MSP se pogosto soočajo z omejitvami virov, zaradi česar so nenačrtovani izpadi še posebej dragi. Prediktivno vzdrževanje (PdM) tem podjetjem omogoča prehod z reaktivnih in preventivnih vzdrževalnih strategij na bolj proaktiven pristop, ki zagotavlja dolgo življenjsko dobo opreme, optimizira urnike vzdrževanja in minimizira motnje delovanja.

5.1.1. KORISTI ZA MSP

Izvajanje PdM lahko MSP prinese številne prednosti, vključno s prihranki stroškov, izboljšavami učinkovitosti in optimizacijo virov. Ključne prednosti so:

- **Prihranek pri stroških:** PdM lahko občutno zmanjša stroške vzdrževanja do 40 % in skrajša čas izpada do 50 % (Siemens, 2023). Z vnaprejšnjim predvidevanjem okvar se lahko podjetja izognejo nujnim popravilom, ki so zaradi nujne in nenačrtovane nakupov rezervnih delov običajno dražja.
- **Izboljšana življenjska doba opreme:** S spremljanjem stanja sredstev in predvidevanjem morebitnih okvar lahko MSP podaljšajo življenjsko dobo strojev. To preprečuje prezgodnje zamenjave in prihrani kapitalske naložbe v novo opremo (Scaife, 2024).
- **Izboljšana produktivnost:** Zmanjšano število okvar vodi do daljšega časa delovanja opreme, kar zagotavlja neprekinjeno proizvodnjo. To zmanjša motnje v delovnem toku in izboljša kakovost izpisa, kar podjetjem omogoča učinkovitejše izpolnjevanje zahtev strank.
- **Optimizirana razporeditev virov:** Vzdrževalne ekipe se lahko osredotočijo na preventivne strategije in naloge z visoko prioriteto, namesto da se nenehno ukvarjajo z nujnimi popravili. To izboljša učinkovitost delovne sile in zmanjša stres med zaposlenimi (Riccio & Menanno, 2024).
- **Energetska učinkovitost:** Prediktivna analitika lahko prepozna neučinkovitosti v delovanju strojev, kar vodi do optimizirane porabe energije. Z zgodnjo obravnavo anomalij lahko MSP znižajo stroške električne energije in prispevajo k trajnostnim ciljem (Siemens, 2025).

5.1.2. IZZIVI PRI IMPLEMENTACIJI PDM

Kljub svojim prednostim sprejetje PdM v MSP ni brez izzivov. Te segajo od finančnih in tehničnih ovir do organizacijskega odpora. Nekateri najpogostejši izzivi vključujejo:

- **Težave s kakovostjo podatkov:** sistemi PdM se za zanesljive napovedi zanašajo na točne, visokokakovostne podatke. Vendar se mnoga mala in srednje velika podjetja spopadajo z zbiranjem podatkov zaradi zastarele infrastrukture in nedoslednega vodenja evidenc (Hunkar Toyoglu, Andy Lin, John Knapp, Jonathan Van Wyck, Selena Rose in Arthur Pentecoste, 2023).



- **Visoka začetna naložba:** Implementacija PdM zahteva naložbo v senzorje, shranjevanje v oblaku in orodja za analizo podatkov. Vnaprejšnji stroški so lahko ovira za MSP z omejenimi finančnimi viri (Berger, 2018) .
- **Pomanjkanje digitalne zrelosti:** Veliko MSP nima potrebne digitalne infrastrukture in strokovnega znanja za podporo tehnologij PdM. Zaradi tega sta integracija in uporaba napovedne analitike zahtevna (Siemens, 2023) .
- **Vrzeli v spretnostih:** Učinkovita implementacija PdM zahteva strokovno znanje na področju podatkovne znanosti, strojnega učenja in tehnologije interneta stvari. MSP pogosto težko najdejo ali usposobijo zaposlene s temi tehničnimi veščinami (Scaife, 2024) .
- **Odpornost na spremembe:** Vzdrževalne ekipe, ki so navajene na tradicionalne vzdrževalne metode, morda neradi sprejmejo rešitve PdM. Premagovanje tega odpora zahteva ustrezno usposabljanje in strategije upravljanja sprememb (Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan in Yi Zhou, 2021) .
- **Izzivi integracije podatkov:** Integracija sistemov PdM s podedovano opremo in obstoječo infrastrukturo IT je lahko zapletena. Lahko se pojavijo težave z združljivostjo, ki zahtevajo prilagojene rešitve (Riccio & Menanno, 2024) .
- **Tveganja kibernetске varnosti: rešitve** PdM v oblaku uvajajo potencialne ranljivosti kibernetске varnosti. Mala in srednja podjetja morajo zagotoviti, da so vzpostavljeni ukrepi za varstvo podatkov za zaščito občutljivih podatkov o vzdrževanju (Gončarov, 2023) .

5.2. NAJBOLJŠE PRAKSE ZA MSP, KI IZVAJAJO PDM

Da bi povečali koristi PdM in hkrati premagovali skupne izzive, bi morala MSP upoštevati najboljše prakse, ki omogočajo nemoteno sprejemanje in učinkovito uporabo.

- **Prepoznavajte kritična sredstva:** MSP bi morala dati prednost sredstvom visoke vrednosti, kjer bi okvare najbolj vplivale na poslovanje. Osredotočanje na ta sredstva zagotavlja, da PdM prinaša najvišjo donosnost naložbe.
- **Začnite s pilotnimi projekti:** namesto s celovitim izvajanjem bi morala MSP začeti s pilotnimi programi majhnega obsega. Ta pristop pomaga potrditi izvedljivost PdM , oceniti donosnost naložbe in izboljšati strategije pred uvedbo v celotnem podjetju.
- **Izkoristite zunanje strokovno znanje in izkušnje:** sodelovanje s ponudniki tehnologije, svetovalci ali strokovnjaki za PdM lahko pomaga premostiti vrzeli v znanju in pospešiti implementacijo. Ti strokovnjaki zagotavljajo smernice o najboljših praksah in sistemski integraciji (Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan in Yi Zhou, 2021) .
- **Investirajte v usposabljanje: Za učinkovito uporabo** rešitev PdM morajo biti zaposleni dodatno usposobljeni za analizo podatkov, strojno učenje in orodja za digitalno vzdrževanje . Programi usposabljanja zagotavljajo nemoteno sprejemanje in dolgoročni uspeh (Riccio & Menanno, 2024) .
- **Uporabite rešitve, ki temeljijo na oblaku:** Računalništvo v oblaku omogoča MSP, da sprejmejo PdM brez potrebe po obsežni lokalni infrastrukturi. Platforme v oblaku zagotavljajo razširljivost, oddaljen dostop in nižje stroške vzdrževanja (Infraspeak, 2023) .



5.3. VPLIV NA ORGANIZACIJE

Uspešna implementacija PdM preoblikuje vzdrževalno strategijo organizacije, izboljša operativno učinkovitost, zmanjša čas izpadov in poveča prilagodljivost pri načrtovanju vzdrževalnih dejavnosti in zaustavitev proizvodnje. Ključni organizacijski vpliv vključuje:

- **Optimizirani vzdrževalni procesi:** PdM preusmeri organizacije z reaktivnega ali preventivnega vzdrževanja na napovedni model, s čimer zagotovi, da se posegi izvajajo le, ko so potrebni. Ta pristop optimizira uporabo sredstev, zmanjša nepričakovane napake in izboljša dodeljevanje virov (Hunkar Toyoglu, Andy Lin, John Knapp, Jonathan Van Wyck, Selena Rose in Arthur Pentecoste, 2023) .
- **Zmanjšanje nenačrtovanih izpadov in večja prilagodljivost:** Z vnaprejšnjim odkrivanjem potencialnih okvar PdM zmanjša nenačrtovane okvare opreme za 20 do 40 %, kar organizacijam omogoča strateško načrtovanje vzdrževalnih dejavnosti in zaustavitev proizvodnje. Ta prilagodljivost pomaga pri usklajevanju vzdrževanja s proizvodnimi cikli, zmanjševanju motenj in zagotavljanju kontinuitete delovanja (Hunkar Toyoglu, Andy Lin, John Knapp, Jonathan Van Wyck, Selena Rose in Arthur Pentecoste, 2023) .
- **Podaljšana življenjska doba opreme in stroškovna učinkovitost:** S proaktivnim obravnavanjem potreb po vzdrževanju lahko podjetja podaljšajo vzdržljivost strojev in zmanjšajo nepotrebne posege, kar vodi do nižjih stroškov vzdrževanja in izboljšane učinkovitosti (Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan in Yi Zhou, 2021) .
- **Sprejetje novih poslovnih modelov (MaaS):** Vzpon vzdrževanja kot storitve (MaaS) omogoča PdM , ki MSP omogoča učinkovitejše zunanje izvajanje vzdrževalnih storitev. To zmanjša kapitalske izdatke, izboljša napovedne vpogleds in zagotovi boljši čas delovanja in kakovost storitev (Infraspeak, 2023) .
- **Proaktivna strategija namesto tradicionalnih poprodajnih storitev:** PdM premakne fokus z reaktivnih popravil na proaktivno načrtovanje, kar zagotavlja, da so morebitne okvare odkrite in rešene, preden vplivajo na proizvodnjo. Ta prehod poveča operativno odpornost in zmanjša odvisnost od posegov poprodajnih storitev (Riccio & Menanno, 2024)

5.4. VPLIV NA DELOVNO SILO

PdM zahteva razvoj veščin delovne sile in preoblikovanje tradicionalnih vzdrževalnih vlog.

5.4.1. TRANSFORMACIJA VLOG

Prehod na PdM prinaša tudi spremembe v vlogah delovne sile. Tradicionalni vzdrževalci morajo vedno bolj nadzorovati sisteme PdM , namesto da izvajajo reaktivna popravila. Ta prehod spodbuja nastanek novih delovnih funkcij, ki povezujejo IT, operacije in vzdrževanje. Ključne preobrazbe vlog vključujejo:

- **Preusposabljanje vzdrževalnih tehnikov :** Prehod na nadzor nad sistemi PdM . Posledično morajo tehniki razviti strokovno znanje pri interpretaciji vpogledov, ki temeljijo na podatkih, in delu z orodji za napovedno analitiko.
- **Pojav novih delovnih mest :** analitiki PdM in strategji digitalnega vzdrževanja. Te vloge se osredotočajo na optimizacijo vzdrževalnih strategij z uporabo napovednih vpogledov in zagotavljanjem brezhibne systemske integracije.
- **Izboljšano sodelovanje IT-operacij :** okrepljene povezave med ekipami IT, operacijami in vzdrževanjem (Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan in Yi Zhou, 2021) . To sodelovanje pomaga pri učinkoviti implementaciji in upravljanju rešitev PdM v različnih poslovnih enotah.



5.4.2. RAZMERJE MED PDM IN VZDRŽEVANJEM KOT STORITVIJO (MAAS)

Pojav vzdrževanja kot storitve (MaaS) naredi PdM bolj dostopen za MSP. Ta model ponuja:

- **MaaS kot spodbujevalec za mala in srednja podjetja** : z zmanjšanjem zapletenosti sprejemanja PdM z oddajo določenih vzdrževalnih storitev specializiranim dobaviteljem lahko mala in srednja podjetja izkoristijo strokovne nasvete in se izognejo izgradnji obsežnih notranjih tehničnih zmogljivosti. (Infraspeak, 2023) .
- **Optimizacija stroškov** : Modeli vzdrževanja na podlagi naročnine naredijo PdM bolj dostopen. Ti modeli omogočajo malim in srednjim podjetjem, da plačajo storitve vzdrževanja na podlagi dejanske uporabe, s čimer odpravijo velike vnaprejšnje stroške in izboljšajo predvidljivost proračuna.
- **Partnerstva s specializiranimi ponudniki PdM** : Pospeševanje sprejemanja za MSP. S sodelovanjem s ponudniki storitev PdM lahko MSP hitro uvedejo rešitve za napovedno vzdrževanje brez potrebe po obsežnem internem strokovnem znanju.

5.4.3. RAZVIJAJOČI SE NABOR SPRETNOSTI ZA PREDIKTIVNO VZDRŽEVANJE (PDM) V MSP

Ko se sistemi PdM bolj integrirajo v mala in srednja podjetja, mora vzdrževalno osebje razviti raznolik nabor spretnosti, ki zajema **tehnične, analitične in mehke veščine** za učinkovito spremljanje, interpretacijo in ukrepanje na podlagi vpogledov v predvideno vzdrževanje.

Ključne veščine vključujejo:

5.4.3.1. TEHNIČNE IN ANALITIČNE SPOSOBNOSTI

Te veščine vključujejo praktično strokovno znanje in izkušnje s tehnologijami PdM , zagotavljajo pravilno implementacijo in vzdrževanje sistemov in so ključnega pomena za interpretacijo podatkov PdM , optimizacijo delovanja sredstev in sprejemanje odločitev na podlagi podatkov.

- **Integracija IoT in upravljanje senzorjev: Razumevanje orodij** PdM , senzorskih omrežij in povezovalnih protokolov, ki temeljijo na IoT, je bistveno za uvajanje in vzdrževanje rešitev za predvideno vzdrževanje (Siemens, 2025) .
- **Ozaveščenost o kibernetiki varnosti in zmanjševanje tveganja**: Ko se podatki o vzdrževanju digitalizirajo, se morajo strokovnjaki zavedati tveganj kibernetike varnosti, strategij za zaščito podatkov in varnih sistemskih arhitektur (Goncharov, 2023) .
- **Razložljiva umetna inteligenca (XAI) in razložljivo strojno učenje (iML)**: Zaposleni morajo razumeti, kako modeli PdM , ki temeljijo na umetni inteligenci, ustvarjajo vpogled in zagotoviti, da je tem napovedim mogoče zaupati in nanje učinkovito ukrepati. (Logan Cummins, 2024) .
- **Podatkovna analiza in strojno učenje**: Vzdrževalno osebje mora biti usposobljeno za napovedno modeliranje, statistično analizo in prepoznavanje vzorcev napak, da predvidi morebitne okvare in optimizira delovanje sredstev (Scaife, 2024) .
- **Spremljanje delovanja in odločanje na podlagi podatkov** : Sposobnost ocenjevanja poročil PdM, odkrivanja nepravilnosti in izboljšanja vzdrževalnih strategij na podlagi analitike v realnem času je bistvenega pomena za povečanje učinkovitosti in zmanjšanje izpadov.



5.4.3.2. MEHKE VEŠČINE

Z vse večjim premikom k modelom vzdrževanja, ki temeljijo na storitvah, morajo strokovnjaki razviti močne medosebne in vodstvene sposobnosti.

- **Upravljanje odnosov z dobavitelji in MaaS:** Ko mala in srednje velika podjetja prehajajo na vzdrževanje kot storitev (MaaS), strokovnjaki potrebujejo veščine upravljanja dobaviteljev, pogajanja o pogodbah na podlagi obstoječega postopka nabave MSP in ocene uspešnosti, da zagotovijo brezhibno integracijo storitev. Razumevanje sporazumov o ravni storitev (SLA) je ključnega pomena za ohranjanje visoke kakovosti storitev.
- **Medfunkcionalno sodelovanje in komunikacija:** Učinkovita komunikacija z IT ekipami, podatkovnimi znanstveniki in operativnimi vodji je potrebna za uskladitev vzdrževalnih strategij s širšimi poslovnimi cilji.
- **Prilagodljivost in nenehno učenje:** glede na hiter napredek tehnologije PdM morajo strokovnjaki za vzdrževanje biti na tekočem s trendi v industriji, nastajajočimi tehnologijami in najboljšimi praksami, da ohranijo operativno odličnost.

Z razvojem dobro zaokroženega nabora spretnosti, ki uravnoteži tehnične, analitične in mehke veščine, lahko vzdrževalno osebje uspešno krmari v razvijajočem se okolju prediktivnega vzdrževanja v MSP.

5.5. ŠTUDIJE PRIMEROV

PdM v resničnem svetu in poudarjajo oprijemljive koristi za MSP v različnih panogah.

5.5.1. NAČRTOVANJE IN IZVEDBA AVTOMATSKEGA SISTEMA ZA SPREMLJANJE IN VZDRŽEVANJE STANJA STROJEV V RAZMERAH Z OMEJENIMI VIRI

Vir: (Ripon et al., 2024)

- **Industrija:** Razno. Mala in srednja podjetja v različnih sektorjih imajo težave z izvajanjem prediktivnega vzdrževanja zaradi omejitev stroškov in virov.
- **Izziv:** Pomanjkanje infrastrukture, usposobljene delovne sile in finančnih virov za izvajanje tradicionalnih sistemov prediktivnega vzdrževanja. Mnoga MSP zaradi teh omejitev težko uvedejo napredne rešitve vzdrževanja.
- **Rešitev:** Razvoj stroškovno učinkovitega sistema za pridobivanje podatkov (DAS) in uporaba metod inženiringa funkcij in zmanjševanja podatkov za avtomatsko odkrivanje in diagnozo napak. Z izkoriščanjem obstoječih nizkocenovnih tehnologij je ta sistem malim in srednjim podjetjem zagotovil cenovno dostopno in razširljivo rešitev vzdrževanja.
- **Rezultati:**
 - Dosežena 89-odstotna natančnost pri zbiranju podatkov v primerjavi s profesionalnimi ročnimi nadzornimi sistemi. To je pokazalo, da lahko stroškovno učinkovite rešitve zagotovijo zanesljive rezultate, primerljive z vrhunskimi industrijskimi sistemi.
 - Natančnost napovedovanja večja od 95 % med usposabljanjem in 100 % med testiranjem novih vzorcev, kar dokazuje izvedljivost implementacije PdM v nastavitvah z omejenimi viri. Uspeh tega pristopa poudarja potencial za široko uporabo v MSP z minimalnimi naložbami.



5.6. PRIHODNJI TRENDI V PDM ZA MSP

PdM v prihodnjih letih zaradi tehnološkega napredka in spreminjajočih se potreb industrije močno razvil.

- **Robno računalništvo:** Obdelava senzorskih podatkov v realnem času na izvoru bo izboljšala odzivne čase (Siemens, 2025) . Z zmanjšanjem potrebe po obdelavi v oblaku robno računalništvo omogoča hitrejšo sprejemanje odločitev in povečuje zanesljivost sistema.
- **Vzdrževanje na podlagi naročnine (MaaS):** MSP lahko dostopajo do PdM prek modelov plačila po uporabi, kar zmanjša vnaprejšnje stroške (Infraspeak, 2023) . Ta premik omogoča podjetjem, da po potrebi povečajo svoje zmogljivosti vzdrževanja brez večjih začetnih naložb.
- **Napredni modeli umetne inteligence:** Bolj izpopolnjeni napovedni algoritmi bodo povečali natančnost in zanesljivost (Riccio & Menanno, 2024) . Rešitve za vzdrževanje, ki jih poganja AI, bodo izboljšale odkrivanje napak, optimizirale razporejanje in zagotovile globlji vpogled v stanje sredstev, kar bo MSP omogočilo sprejemanje odločitev na podlagi podatkov z večjo samozavestjo.

Če ostanejo pred temi trendi, lahko MSP izkoristijo PdM za spodbujanje učinkovitosti, zmanjšanje stroškov in ostanejo konkurenčna v vse bolj digitalnem in avtomatiziranem okolju. Sprejemanje teh inovacij ne bo le izboljšalo operativne uspešnosti, temveč bo MSP tudi omogočilo dolgoročni uspeh v razvijajočem se industrijskem ekosistemu.



5.7. REZULTATI RAZISKAVE PDM, POSLANI MSP

5.7.1. PREGLED RAZISKAVE

Da bi ocenili sprejetje in vpliv prediktivnega vzdrževanja (PdM) med malimi in srednje velikimi podjetji (MSP), je bila raziskava izvedena v petih evropskih državah: Franciji, Nemčiji, Sloveniji, Švedski in Italiji.

Raziskava je zbrala vpogled v **primarno velikost podjetja industrijski sektor, trenutne prakse vzdrževanja, tehnološko sprejetje, vpliv na delovno silo in prihodnji pogledi na PdM**. Rezultati zagotavljajo dragocene podatke o izzivih in priložnostih, s katerimi se srečujejo MSP pri vključevanju PdM v svoje poslovanje.

Skupaj so bila k sodelovanju povabljena 103 MSP, od katerih se je odzvalo 26 podjetij, ki so navedla naslednjo porazdelitev izvora in velikosti:

5.7.2. ANALIZA IN ZANESLJIVOST REZULTATOV ANKETE

S stopnjo odgovora 25 % od skupno 103 zahtevkov za informacije, poslanih MSP, rezultati kažejo na trend, ki ga je treba upoštevati (glej statistiko v poglavju o metodologiji).

5.7.3. SPLOŠNI PODATKI O ANKETIRANIH MSP

5.7.3.1. PORAZDELITEV VELIKOSTI MSP, KI SO SE ODZVALA

Anketa je zbrala odgovore 26 MSP iz petih držav: Francije, Nemčije, Slovenije, Švedske in Italije. Porazdelitev odgovorov po državah kaže opazne razlike:

Visoka stopnja odziva v Franciji kaže na močno sodelovanje z raziskavo, medtem ko je imela Nemčija, kljub največjemu številu MSP, s katerimi so kontaktirali, nižjo stopnjo odziva (15 %). Stopnja angažiranosti v Sloveniji je bila zmerna, odgovorila je slaba polovica kontaktiranih podjetij. Italija je imela celotno stopnjo odziva, vendar je bilo vključeno samo eno MSP. Švedska je imela najnižjo stopnjo angažiranosti, z enim odgovorom od 20 držav, s katerimi je bil vzpostavljen stik.

Tabela 8. Porazdelitev odgovorov v anketi MSP po državah


proti	Država	Število podjetij	Število odgovorov
MSP	FR	11	11
	NEMČ	60	9
	SI	11	4
	ŠV	20	1
	IT	1	1
Skupaj MSP		103	26



5.7.3.2. VELIKOST ORGANIZACIJ

Raziskava je MSP glede na število zaposlenih razvrstila v štiri velikostne skupine:


- Mikro (1-9 zaposlenih)
- Majhna (10-49 zaposlenih)
- Srednje (50–249 zaposlenih)
- Velika (250+ zaposlenih) (čeprav velika podjetja običajno niso MSP, so bila vseeno vključena v nekatere odgovore)



Slika 20. Porazdelitev velikosti MSP, ki so se odzvala

5.7.3.3. VELIKOST ORGANIZACIJ NA DRŽAVO

Francija in Nemčija sta zastopani v srednjih in velikih kategorijah, z dodatno majhno kategorijo v Nemčiji. Italija ima eno srednje veliko organizacijo. Slovenijo in Švedsko predstavljajo predvsem majhne in mikro organizacije.




Slika 21. Velikost organizacij na državo

Odzivi večjih organizacij bi lahko vplivali na splošne ugotovitve ankete, kar bi lahko preusmerilo fokus na težave, s katerimi se soočajo srednja do velika podjetja, namesto na mikro in mala MSP.



5.7.3.4. VELIKOST ORGANIZACIJ, KI SO ODGOVARJALE GLEDE NA SEKTOR PRIMARNE INDUSTRIJE

Sodelujoča podjetja so pripadala različnim sektorjem, predvsem strojem in opremi in avtomobilska industrija:




Slika 22. Velikost organizacij, ki so odgovorile glede na primarni industrijski sektor

5.7.3.5. VLOGE V PODJETJU

Raziskava je analizirala tudi vloge anketirancev v njihovih podjetjih. Ključne ugotovitve vključujejo:

- Sodelovala je mešanica odločevalcev podjetij, vključno z vodji vzdrževanja in vodstvenimi delavci.
- Prisotnost strokovnjakov za vzdrževanje nakazuje, da rezultati ankete odražajo praktične vpogleda na terenu v prediktivno vzdrževanje (PdM) in ne le strateških ali teoretičnih perspektiv.
- Večja podjetja imajo ponavadi namenske vloge vzdrževanja, medtem ko imajo manjša podjetja lahko zaposlene z več odgovornostmi.



Slika 23. Vloge v podjetju



5.7.3.6. POVZETEK PREGLEDA ANKETE

Nabor podatkov zagotavlja jasno razumevanje velikosti in porazdelitve MSP, ki so se odzvala, njihovih industrijskih sektorjev in vlog v organizacijah. Podatki kažejo:


- Močna udeležba francoskih MSP, pri čemer je Nemčija kljub nižji stopnji odziva prispevala precejšnje število odgovorov.
- Pestra zastopanost podjetij po velikosti, čeprav prevladujejo srednje velika podjetja.
- Visoka stopnja sodelovanja industrij, ki potrebujejo rešitve za napovedno vzdrževanje.
- Dobra kombinacija nosilcev operativnih in strateških odločitev, ki so odgovorili na anketo, zagotavlja dobro zaokrožen pogled na vprašanja, s katerimi se soočajo MSP.

5.7.4. TRENUTNO STANJE SPREJEMANJA PDM V MSP

Rezultati raziskave kažejo, da medtem ko **mala in srednja podjetja priznavajo pomen prediktivnega vzdrževanja (PdM)** pri povečanju učinkovitosti in konkurenčnosti, **je njegovo sprejetje za mnoga podjetja v zgodnji fazi**.

5.7.4.1. VRSTE STRATEGIJ VZDRŽEVANJA V UPORABI (REAKTIVNA, PREVENTIVNA, PREDIKTIVNA).

Večina MSP se še vedno **zanaša na reaktivne ali preventivne strategije vzdrževanja**, pri čemer **se prediktivni pristopi počasi uveljavljajo**, zlasti med večjimi in digitalno bolj zreliimi podjetji.




Slika 24. Trenutno se izvaja postopek vzdrževanja



5.7.4.2. PRIPRAVLJENOST MSP NA PREVZEM PDM IN NASTAJAJOČIH TEHNOLOGIJ.

Poleg tega mala in srednja podjetja kažejo **zmerno pripravljenost** za sprejemanje **nastajajočih trendov PdM, digitalnega in zelenega prehoda**, pri čemer so mnoga še **v zgodnjih fazah izvajanja**.



Slika 25. Kako pripravljena so podjetja, da sprejmejo nastajajoče trende PdM Digital in Green Transition?

5.7.4.3. OVIRE PRI SPREJEMANJU (STROŠKI, STROKOVNO ZNANJE, INTEGRACIJSKI IZZIVI).

Rezultati raziskave razkrivajo, da **glavne ovire za sprejetje PdM za MSP vključujejo visoke stroške izvajanja, pomanjkanje lastnega strokovnega znanja in omejeno poznavanje tehnologij za napovedovanje**. Ko gre za težave, s katerimi se srečujejo podjetja pri **podatkih**, so bile kot **glavne ovire** opredeljene **zbiranje podatkov, kakovost in varnost**, pred vprašanjem shranjevanja podatkov.



Slika 26. Katere so glavne ovire, s katerimi se srečuje vaša organizacija pri sprejemanju tehnologij PdM ?






Slika 27. Na katere podatkovne izzive se srečujete pri PdM ?

5.7.5. VPLIV PDM NA TRŽNO STRATEGIJO MSP

MSP vedno bolj vidijo PdM kot **strateško naložbo** in ne le kot operativno izboljšavo. Zaradi zmožnosti **zmanjšanja stroškov, izboljšanja zanesljivosti in podpore trajnostnim ciljem** je PdM ključno gonilo za **dolgoročno konkurenčnost v industriji 4.0**.


Kljub ugotovljenim oviram večina MSP priznava, da PdM oblikuje njihov **poslovni položaj in tržni pristop**. Rezultati te raziskave poudarjajo, da za MSP:

- Predvsem je **zelo pomembno** sprejeti **napovedne tehnologije** in nove digitalne trende, kot sta IoT in Ai, da bi **izboljšali prakse vzdrževanja**.
- **PdM je vsekakor bistvenega pomena za ohranjanje konkurenčnosti** v njihovi panogi.
- **PdM lahko vpliva na tržno strategijo ali konkurenčni položaj svoje organizacije**.




Slika 28. Kako pomembno je sprejeti napovedne tehnologije in nove digitalne trende, kot sta IoT in Ai, za izboljšanje praks vzdrževanja?





Slika 29. Ali MSP menijo, da je PdM bistvenega pomena za ohranjanje konkurenčnosti v njihovi panogi?




Slika 30. Kako je PdM vplival na tržno strategijo ali konkurenčni položaj vaše organizacije?

5.7.6. KAKO SE MSP PRIPRAVLJAJO NA PRIHODNOST

5.7.6.1. STROŠKOVNI IZZIVI

Za reševanje **stroškovnega izziva** sprejetja PdM MSP raziskujejo **prerazporeditev proračuna, financiranje na podlagi projektov in dolgoročne strategije varčevanja s stroški**. Nekatera podjetja iščejo tudi **zunanjo finančno podporo, partnerstva in razširljive rešitve PdM, ki temeljijo na oblaku**, da bi zmanjšale vnaprejšnje naložbe in hkrati povečale operativno učinkovitost.






Slika 31. Kako vaša organizacija obravnava stroškovne izzive, povezane s sprejetjem PdM ?

5.7.6.2. VPLIV NA DELOVNE VLOGE


Rezultati ankete kažejo, da MSP prepoznajo **preobrazbo delovnih mest**. Številni anketiranci predvidevajo, da **se bodo pojavile nove vloge**, medtem ko drugi menijo, da **se bodo obstoječe vloge razvile** tako, da bodo vključevale analizo podatkov, napovedno modeliranje in diagnostiko, ki temelji na umetni inteligenci.



Slika 32. Kako predvidevate, da bo PdM vplival na delovne vloge v vaši organizaciji?


Vendar pa so bili odgovori na vprašanje o njihovi **pripravljenosti na obvladovanje teh sprememb delovnega mesta** različni: medtem ko so nekatere organizacije začele izvajati **programe izpopolnjevanja in pobude za usposabljanje**, jih je precejšnje število še vedno **le delno pripravljenih**, kar poudarja **potrebo po bolj strukturiranih strategijah razvoja delovne sile** za zagotovitev nemotenega prehoda.





Slika 33. Kako pripravljena je vaša organizacija za obvladovanje sprememb delovnega mesta, povezanih s sprejetjem PdM ?

Rezultati raziskave kažejo, da mala in srednje velika podjetja sprejemajo **različne strategije za pripravo na pričakovano rast tehnologij PdM**, s pristopi, ki segajo od **notranje krepitve zmogljivosti in usposabljanja delovne sile do zunanjih partnerstev in tehnoloških naložb**. Medtem ko nekatere organizacije **razvijajo lastno strokovno znanje in izkušnje** za podporo sprejemanja PdM, se druge zanašajo na **zunanje ponudnike storitev, pobude sodelovalne industrije ali hibridne pristope** za integracijo prediktivnega vzdrževanja v svoje delovanje.



Slika 34. Kako se vaša organizacija pripravlja na pričakovano rast tehnologij PdM ?

5.7.6.3. USPOSABLJANJE IN IZPOPOLNJEVANJE DELOVNE SILE

Rezultati raziskave razkrivajo **veliko povpraševanje po dodatni izobraževalni podpori** na ključnih področjih, povezanih z **digitalnimi in zelenimi tehnologijami v PdM**, pri čemer mala in srednje velika podjetja izražajo **visoko stopnjo zanimanja** za programe usposabljanja, ki povečujejo zmogljivosti njihove delovne sile. **AI, IoT, kibernetska varnost in trajnost** se pojavljajo kot **kritična področja**, kjer zaposleni potrebujejo **tehnično usposabljanje, ozaveščenost in razvoj spretnosti**.

Zlasti **analitika podatkov, napovedno modeliranje in spremljanje na podlagi interneta stvari** veljajo za **bistvene kompetence** za uspešno izvajanje strategij PdM. **Usposabljanje o kibernetski varnosti** je prav tako vse večja skrb, saj se podjetja zavedajo pomena **zaščite**




prediktivnih vzdrževalnih sistemov pred kibernetскими grožnjami . Poleg tega, medtem ko je **usposabljanje, osredotočeno na trajnost, uvrščeno nekoliko nižje kot prioriteta** , MSP priznavajo njegovo vlogo pri **optimizaciji energetske učinkovitosti in zmanjševanju vpliva na okolje**.

Raziskava razkriva **potrebo po usposabljanju na področjih interneta stvari in umetne inteligence osredotočiti se** predvsem na razvoj **tehničnega strokovnega znanja** , hkrati pa **ozaveščati o tehnološko-zelenih načelih** in zagotoviti, da so inovacije usklajene s trajnostnimi načeli.


Raven zanimanja za **trende digitalnega in zelenega prehoda, povezane z usposabljanjem PdM**, se ponavadi osredotoča na **napredne aplikacije AI in IoT na višjih ravneh kvalifikacij (EQF 5-6)** za izgradnjo temeljnega znanja.





Slika 35. Na katerih področjih zaposleni v vaši organizaciji potrebujejo dodatno izobraževalno podporo za učinkovito uporabo digitalnih in zelenih tehnologij v PdM?







Slika 36. Kako vas zanimajo novi trendi digitalnega in zelenega prehoda, povezani z usposabljanjem Pdm ?




Medtem ko **večja mala in srednje velika podjetja** dajejo prednost internemu razvoju, imajo **manjša podjetja** raje zunanje ponudnike usposabljanja, vsa pa imajo raje obliko osebnih delavnic.



Slika 37. Kako vaša organizacija raje dostopa do usposabljanja?



Slika 38. Kateri so najprimernejši formati za usposabljanje PdM ?



Slika 39. Katere vrste usposabljanja bi najbolje podprle vašo delovno silo za PdM ?

Te ugotovitve poudarjajo **nujno potrebo po prilagojenih pobudah za usposabljanje**, ki obravnavajo tako **tehnične kot tudi veščine, povezane s trajnostjo**. S premostitvijo **vrzeli v digitalnih in zelenih veščinah** bodo MSP bolje opremljena za učinkovito **izkoriščanje PdM, izboljšanje operativne učinkovitosti ter uskladitev z industrijo 4.0 in cilji trajnosti**.



5.8. PRIHODNJE PERSPEKTIVE IN PRIPOROČILA

Če pogledamo naprej, MSP priznavajo vse večji pomen predvidenega vzdrževanja (PdM) in potrebo po premagovanju ovir, povezanih s stroški, vrzeli v znanju in tehnološko integracijo. Da bi pospešila sprejetje in povečala prednosti PdM, morajo MSP raziskati strateške pristope, partnerstva in nove storitvene modele, ki podpirajo razširljiv in stroškovno učinkovit prehod.

5.8.1. RAZŠIRITEV DOSTOPA DO FINANČNE PODPORE IN SPREJEMANJA TEHNOLOGIJE

Za zagotovitev, da lahko MSP učinkovito sprejmejo tehnologije prediktivnega vzdrževanja (PdM), je potreben izboljšán dostop do finančnih virov, strateških partnerstev in inovativnih modelov storitev, ki zmanjšujejo stroške in ovire pri izvajanju. Raziskati je mogoče naslednjo os:

- **Izboljšajte dostop do programov financiranja** – vladne spodbude, nepovratna sredstva EU in finančno podporo, ki jo podpira industrija, je treba uporabiti za zmanjšanje visokih začetnih investicijskih stroškov, povezanih s tehnologijami PdM.
- **Spodbujajte tehnološka partnerstva** – Sodelovanje s ponudniki tehnologije, industrijskimi združenji in raziskovalnimi ustanovami lahko malim in srednje velikim podjetjem pomaga pri integraciji IoT, AI in rešitev PdM v oblaku z minimalnimi motnjami v obstoječih operacijah.
- **Spodbudite MSP, da raziščejo vzdrževanje kot storitev (MaaS)** – veliko MSP se spopada z visokimi začetnimi stroški in pomanjkanjem lastnega strokovnega znanja, potrebnega za izvajanje PdM. S sklenitvijo pogodb s ponudniki MaaS lahko mala in srednja podjetja dostopajo do naprednih zmogljivosti PdM brez potrebe po večjih naložbah v infrastrukturo in izkoristijo naročniške razširljive vzdrževalne rešitve.

5.8.2. VLAGANJE V USPOSABLJANJE DELOVNE SILE IN RAZVOJ DIGITALNIH VEŠČIN

Da bi povečali prednosti tehnologij PdM, morajo MSP vlagati v usposabljanje delovne sile, zaposlene opremiti s potrebnimi digitalnimi veščinami in tehničnim znanjem za upravljanje napovedne analitike, ki temelji na AI, integracije IoT in kibernetske varnosti.

- **Razvijte ciljne programe usposabljanja** – Izpopolnjevanje zaposlenih na področju napovedne analitike, ki temelji na umetni inteligenci, integracije IoT in kibernetske varnosti je ključnega pomena za sprejetje PdM. Usposabljanje, specifično za industrijo, je treba prilagoditi potrebam MSP, velikosti podjetja in tehnični pripravljenosti.
- **Spodbujajte hibridne učne modele** – MSP dajejo prednost prožnim oblikam usposabljanja, kot so spletni tečaji, delavnice in simulacije, ki bi morali postati bolj dostopni s sodelovanjem z univerzami, tehničnimi šolami in centri za industrijsko usposabljanje.



5.8.3. OPTIMIZIRANJE STRATEGIJ PDM ZA DOLGOROČNO KONKURENČNOST

Da bi mala in srednja podjetja ostala konkurenčna, je treba strategije Pdm izvajati na razširljiv, stroškovno učinkovit način, z uporabo tehnologij v oblaku in pristopov, ki temeljijo na trajnosti, za izboljšanje operativne učinkovitosti in skladnosti s predpisi.

- **Sprejmite postopen pristop k izvajanju Pdm** – mala in srednja podjetja lahko začnejo s pilotnimi projekti, ki se osredotočajo na kritična sredstva, in postopoma razširijo Pdm na vse operacije, ko postane donosnost naložbe očitna.
- **rešitve Pdm, ki temeljijo na oblaku** – Računalništvo v oblaku omogoča MSP, da povečajo vzdrževalne operacije brez drage infrastrukture, kar jim omogoča analizo podatke stroja v realnem času na daljavo.
- **Vključite trajnost v strategije Pdm** – Pdm je treba uskladiti s cilji zelenega prehoda, pomagati MSP optimizirati porabo energije, zmanjšati količino odpadkov in upoštevati okoljske predpise.

6. VPLIV PDM NA USPOSABLJANJE IN CENTRE ZA USPOSABLJANJE


6.1. NAJSODOBNEJŠE USPOSABLJANJE ZA VZDRŽEVANJE

6.1.1. MODELSKI PRISTOP, OSREDOTOČEN NA UČENCA

Projekt Certified European Maintenance Professionals, ki je del programa Erasmus+, je namenjen krepitvi konkurenčnosti evropskih industrij s krepitvijo veščin vzdrževalcev v državah članicah. Ta nadnacionalna pobuda obravnava vrzel v znanjih in izkušnjah pri upravljanju vzdrževanja, pri čemer poudarja potrebo po formalnem usposabljanju, ki je usklajeno z zahtevami industrije na področju avtomatizacije, digitalizacije in prediktivnega vzdrževanja. Z osredotočanjem na poklicno izobraževanje in vključitvijo smernic Evropskega centra za razvoj poklicnega usposabljanja (CEDEFOP) projekt omogoča potrjevanje tako formalnega kot priložnostnega učenja. Ključni rezultati vključujejo vzpostavitev standardiziranih kvalifikacij za različne vloge vzdrževanja ter celovito spodbujanje vseživljenjskega učenja in poenotenje vzdrževalnih praks po vsej Evropi.

Projekt poudarja model, osredotočen na učenca, ki prilagaja potrebne veščine različnim ravnam EQF, kar učencem omogoča, da sledijo napredovanju, ki ustreza njihovim spretnostim in poklicnim ciljem. S tem pristopom je učenje ustreznejše in prilagojeno vsakemu študentu, ne glede na to, ali gre za novince ali izkušene strokovnjake, ki iščejo nadgradnjo.





Slika 40. Stopnišče za kvalifikacije vzdrževanja

Omenjeni primer:

Na 6. ravni evropskega ogrodja kvalifikacij (EQF) se pričakuje, da bodo vzdrževalci in nadzorniki dokazali:

- **Tehnično znanje:** Prediktivno, preventivno in korektivno vzdrževanje, vključno z naprednimi metodami za spremljanje stanja.
- **Spretnosti:** Sposobnost analiziranja podatkov iz sistemov vzdrževanja, razvijanja načrtov vzdrževanja in izvajanja izboljšav.
- **Avtonomija in odgovornost:** odločanje pri izvajanju strategije vzdrževanja, optimizaciji procesov ter zagotavljanju varnosti in skladnosti, vključno s strategijo predvidenega vzdrževanja.

Glej reference v viru (Kampus Češke univerze znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id219, nd)

EN 17007:2017-ACT – Delujte preventivno in/ali korektivno na postavke za vzdrževanje:

Tabela 9. Kvalifikacije za inženirje vzdrževanja in nadzornike (raven 6 EQF)

Predmet	Znanje (moral bi biti sposoben)	Spretnosti (moral bi znati)	Odgovornost in avtonomija (moral bi biti sposoben)
Preventivno vzdrževanje	– Opišite preventivno vzdrževanje in različne strategije za zagotavljanje visokega zanesljivost	– Načrtujte in izvajajte učinkovito preventivno vzdrževalne načrte	– Analizirajte in optimizirajte proces za vse naloge preventivnega vzdrževanja
Vnaprej določeno vzdrževanje	– Opišite metode in tehnike za vnaprej določeno vzdrževanje – Opišite, kako izvesti vnaprej določeno vzdrževanje	– Realizacija načrtov za vnaprej določeno vzdrževanje	– Analizirajte in optimizirajte proces za vse vnaprej določene vzdrževalne naloge
Vzdrževanje glede na stanje	– Opišite metode in tehnike za vzdrževanje glede na stanje (npr. subjektivno in objektivno vzdrževanje glede na stanje metode)	– Odločite se in izvedite načrte za intervali med pregledi in vzdrževanje glede na stanje	– Analizirajte in optimizirajte proces za vse vzdrževalne naloge glede na stanje



	– Opišite različne vrste stanja nadzorni sistemi (npr intervalih, po naročilu, centralizirano oz decentralizirano) – Opišite interval PF in kako se uporablja – Opišite metode in tehnike za pregled (vzdrževanje glede na stanje)	– Izvedite ustrezen načrt za pregled in sistem vzdrževanja glede na stanje – Odločite se in sporočite, kje je treba izvesti nepredvidljivo vzdrževanje	
Napovedno vzdrževanje	– Opišite, kako izvajati napovedovanje vzdrževanje – Opišite prediktivne metode vzdrževanja – Opišite razliko med napovednim in nepredvidljivo vzdrževanje – Opišite, kako izvajati nepredvidljivo vzdrževanje – Opišite nepredvidljive metode vzdrževanja	– Odločite se in izvedite načrte, kje potrebno je izvesti prediktivno vzdrževanje – Uporabite ustrezne sisteme za napovedovanje vzdrževanje	– Analizirajte in optimizirajte proces za vse napovedne vzdrževalne naloge

6.1.2. STROKOVNO ZNANJE NA PODROČJU NAPOVEDNIH TEHNOLOGIJ

Specialist za napovedno vzdrževanje (PdM Specialist, n.d.) ponuja izobraževalni program na ravni EQF 5, ki je na voljo tako na lokaciji kot tudi na spletu. Program zajema teme, kot so analiza vibracij, nastavitve programske opreme in zbiranje podatkov. Poudarek je na razvoju praktičnih veščin, ki so ključne za napovedno diagnostiko in vzdrževalna opravila. Izobraževanje je primerno za tehnike, ki želijo nadgraditi svoje strokovno znanje o napovednih tehnologijah.

6.2. RAZVOJ USPOSABLJANJA VZDRŽEVALCEV V DIGITALNI DOBI

Področje usposabljanja za vzdrževanje se hitro razvija z integracijo digitalnih orodij, naprednih metodologij in napovednih strategij vzdrževanja. Tradicionalno praktično učenje se preoblikuje s tehnologijami industrije 4.0, ki zahtevajo, da se strokovnjaki za vzdrževanje prilagodijo novim metodologijam, ki povečujejo učinkovitost, zmanjšujejo izpade in se prilagajajo zahtevam industrije.

- **Integracija digitalnih tehnologij:** obogatena resničnost (AR), virtualna resničnost (VR) in digitalni dvojčki postajajo bistveni sestavni deli programov usposabljanja. Te tehnologije zagotavljajo poglobljene učne izkušnje, ki pripravnikom omogočajo simulacijo scenarijev vzdrževanja v resničnem svetu v okolju brez tveganja (Organizacija Združenih narodov za izobraževanje, znanost in kulturo & Mednarodni center UNESCO-UNEVOC za tehnično in poklicno izobraževanje in usposabljanje, 2021).
- **Usposabljanje za vzdrževanje, ki temelji na podatkih in predvidevanje:** analitika, ki jo poganja AI, sistemi za spremljanje, ki podpirajo IoT, in avtomatizirana diagnostika preoblikujejo, kako strokovnjaki za vzdrževanje razlagajo sistemske anomalije. Ti napredki olajšajo strategije vzdrževanja, ki temeljijo na predvidevanju in stanju, zmanjšujejo okvare opreme in optimizirajo operativno učinkovitost (Organizacija Združenih narodov za izobraževanje, znanost in kulturo ter Mednarodni center UNESCO-UNEVOC za tehnično in poklicno izobraževanje in usposabljanje, 2021).



- **Certificiranje in standardizacija:** Programi, kot sta Erasmus+ in ISO certifikati, zagotavljajo enotne ravni spretnosti in kompetenc v državah ter spodbujajo standardiziran pristop k usposabljanju za vzdrževanje. Te pobude zagotavljajo strukturane učne poti, potrjujejo strokovno znanje in izkušnje ter zagotavljajo pripravljenost industrije (Kampus Češke univerze znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id 31, nd) .
- **Uskladitev s potrebami industrije 4.0:** učni načrti za usposabljanje vedno bolj vključujejo umetno inteligenco, internet stvari in kibernetsko varnost, da bi strokovnjake opremili z veščinami, ki so pomembne za sodobna industrijska okolja. Digitalni dvojčki, nadzor na daljavo in pametno tovarniško delovanje so zdaj sestavni del usposabljanja za vzdrževanje in delavce pripravljajo na zahteve avtomatizirane in medsebojno povezane proizvodnje (Kampus Češke univerze za znanosti o življenju v Pragi & Slovensko vzdrževalno društvo – Id 31, nd) .
- **Hibridni učni modeli:** Kombinacija spletnih modulov, učenja na podlagi simulacije in osebnega praktičnega usposabljanja povečuje dostopnost in učinkovitost. Ta mešani pristop omogoča strokovnjakom, da se izpopolnjujejo med obvladovanjem svojih delovnih obveznosti, kar zagotavlja nenehno prilagajanje tehnološkemu napredku na tem področju.

6.3. IZZIVI IN PRILOŽNOSTI ZA IZOBRAŽEVALNE CENTRE

Centri za usposabljanje igrajo ključno vlogo pri premoščanju vrzeli v znanju in zagotavljanju, da so strokovnjaki opremljeni za obvladovanje sodobnih rešitev PdM. Vendar ta prehod predstavlja več izzivov in priložnosti:

- **Posodobitev izobraževalnih infrastruktur:** Centri za usposabljanje morajo nadgraditi svoje zmogljivosti za integracijo orodij PdM , kot so senzorji, programska oprema za analizo podatkov in sistemi za spremljanje v oblaku. To zahteva naložbe v napredno opremo, pa tudi usposabljanje inštruktorjev za učinkovito poučevanje novih tehnologij (Kampus Češke univerze znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id219, nd) .
- **Razvoj hibridnih formatov usposabljanja:** Da bi izpolnili zahteve industrije, morajo programi usposabljanja sprejeti hibridni pristop, ki združuje osebne in virtualne učne izkušnje. Spletne platforme in virtualni laboratoriji zagotavljajo prilagodljivost, obenem pa zagotavljajo, da pripravniki pridobijo praktične izkušnje z interaktivnimi simulacijami in praktičnim usposabljanjem (Organizacija Združenih narodov za izobraževanje, znanost in kulturo ter Mednarodni center UNESCO-UNEVOC za tehnično in poklicno izobraževanje in usposabljanje, 2021) .
- **Krepitev sodelovanja z industrijskimi partnerji:** Partnerstva z vodilnimi v industriji omogočajo centrom za usposabljanje, da zagotovijo praktične izkušnje PdM prek vajeništva, pripravništva in sodelovalnih projektov. Te pobude povečujejo izpostavljenost pripravnikov izzivom iz resničnega sveta in jih pripravljajo na brezhibno vključevanje v delovno silo (Kampus Češke univerze za znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id219, nd) .

6.4. USPOSOBLJENE VEŠČINE IN VPLIV PDM

Prediktivno vzdrževanje (PdM) preoblikuje nabor spretnosti, potrebnih za strokovnjake za vzdrževanje. Naslednje ključne kompetence so bistvene za razvijajočo se pokrajino:



- **Tehnične veščine** : obvladovanje diagnostike, ki temelji na umetni inteligenci, upravljanje senzorjev IoT, interpretacija podatkov in aplikacije strojnega učenja pri vzdrževanju. Te veščine omogočajo strokovnjakom, da predvidijo okvare opreme in učinkovito optimizirajo urnike vzdrževanja (Organizacija Združenih narodov za izobraževanje, znanost in kulturo & Mednarodni center UNESCO-UNEVOC za tehnično in poklicno izobraževanje in usposabljanje, 2021) .
- **Analitične veščine** : usposobljenost za analizo velikih podatkov, analizo temeljnih vzrokov in odločanje na podlagi napovedne analitike. Strokovnjaki za vzdrževanje morajo biti sposobni interpretirati zapletene nize podatkov in pridobiti uporabne vpogleda, da preprečijo nepričakovane okvare (Organizacija Združenih narodov za izobraževanje, znanost in kulturo & Mednarodni center UNESCO-UNEVOC za tehnično in poklicno izobraževanje in usposabljanje, 2021) .
- **Mehke veščine** : Prilagodljivost digitalnim orodjem, timsko delo v pametnih tovarnah in reševanje problemov v realnem času. Ker vloge vzdrževanja postajajo vedno bolj sodelovalne in tehnološko usmerjene, strokovnjaki potrebujejo močne komunikacijske in kritične veščine za učinkovito delo z medfunkcionalnimi ekipami (Kampus Češke univerze za znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id219, nd) .
- **Ozaveščenost o kibernetiki in varnosti** : Razumevanje in izvajanje najboljših praks kibernetike in varnosti za zaščito podatkov, povezanih z vzdrževanjem, in sistemov, povezanih z internetom stvari. Z naraščanjem povezane opreme morajo strokovnjaki za vzdrževanje zagotoviti, da so sistemi varni pred kibernetičnimi grožnjami in ranljivostmi (Organizacija Združenih narodov za izobraževanje, znanost in kulturo ter Mednarodni center UNESCO-UNEVOC za tehnično in poklicno izobraževanje in usposabljanje, 2021) .

Vpliv PdM na programe usposabljanja je velik, saj preusmerja fokus z reaktivnih in preventivnih vzdrževalnih strategij na proaktivne in napovedne modele, s čimer skrajša izpade in izboljša dolgoživost sredstev.

6.5. VLOGA MaaS PRI USPOSABLJANJU

Vzdrževanje kot storitev (MaaS) se pojavlja kot ključni dejavnik pri usposabljanju strokovnjakov za vzdrževanje z zagotavljanjem dostopa do najsodobnejših tehnologij PdM in aplikacij v resničnem svetu.

- **Dostop do tehnologij PdM prek platform za sodelovanje v oblaku**: rešitve v oblaku učencem omogočajo delo s podatki v realnem času in napovednimi modeli. Z interakcijo z orodji za napovedno vzdrževanje, ki gostujejo v oblaku, lahko učenci analizirajo podatke iz resničnega sveta in razvijejo strokovno znanje pri uporabi teh tehnologij (Kampus Češke univerze za znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id219, nd) .
- **Uporaba simulacij in študij primerov iz resničnega sveta**: Orodja za simulacijo in digitalni dvojčki omogočajo učencem, da vadijo tehnike PdM v okolju brez tveganja. Virtualizirani modeli industrijske opreme omogočajo učencem, da eksperimentirajo z različnimi scenariji vzdrževanja, izboljšajo svoje veščine reševanja problemov, preden začnejo delati na dejanskih strojih (Kampus Češke univerze za znanosti o življenju v Pragi & Slovensko vzdrževalno društvo - Id219, nd) .

S sprejetjem teh napredkov lahko centri za usposabljanje učinkovito pripravijo bodoče strokovnjake za vzdrževanje na razvijajoče se zahteve industrije.



6.6. REZULTATI ANKETE PDM POSLANI CENTRIM ZA POKLICNO IZOBRAŽEVANJE IN USPOSABLJANJE

6.6.1. PREGLED RAZISKAVE

Za ovrednotenje trenutnega stanja programov usposabljanja v zvezi z nastajajočimi digitalnimi tehnologijami 4.0 v PdM med centri za poklicno izobraževanje (centri za poklicno izobraževanje) je bila izvedena raziskava v petih evropskih državah: v Franciji, Nemčiji, Sloveniji, Švedski in Italiji. Ta raziskava prav tako preučuje, kako lahko centri za usposabljanje prilagodijo svoje programe tem tehnološkim spremembam in potrebam industrije, tako da preučijo vzpostavljene ali načrtovane strategije za vključitev teh inovacij, izzive, s katerimi se soočajo, potrebna sredstva in priložnosti za sodelovanje industrije.

Anketo smo poslali v 52 izobraževalnih centrov. Rezultati temeljijo na odgovorih, prejetih iz skupno 25 centrov za usposabljanje.

Anketa je razdeljena na več ključnih delov: splošne informacije o centrih za usposabljanje, tečaji, povezani z nastajajočimi digitalnimi tehnologijami 4.0, kratkoročni, srednjeročni in dolgoročni razvojni načrti, uskladitev s potrebami industrije, finančne naložbe in možnosti financiranja, usposabljanje učiteljev in sodelovanje, izzivi in sodelovanje industrije ter spretnosti in viri za poučevanje.

6.6.2. ANALIZA IN ZANESLJIVOST REZULTATOV ANKETE

S stopnjo odgovora 48 % od skupno 52 zahtevkov za centre za poklicno izobraževanje in usposabljanje rezultati kažejo na trend, ki ga je treba upoštevati (glejte statistične podatke v poglavju o metodologiji).

6.6.3. SPLOŠNI PODATKI O ANKETIRANIH CENTRIH ZA USPOSABLJANJE

Rezultati raziskave nudijo podroben pregled izobraževalnih centrov, ki so sodelovali, s poudarkom na njihovi geografski porazdelitvi, velikosti, področjih specializacije, vlogah anketirancev in številu diplomantov na leto.

Največ izobraževalnih centrov, ki so se odzvali, je v Sloveniji (64 %), sledijo Francija (24 %), Nemčija (8 %) in Italija (4 %).

Rezultati kažejo, da je večina centrov srednje velikih do velikih, 44 % jih ima med 500 in 999 študentov, 28 % pa več kot 1000 študentov.

Glavno področje usposabljanja je industrijsko (64 %). Vendar pa so zastopani tudi drugi sektorji, vključno s terciarnim sektorjem (16 %) in avtomobilskim sektorjem (4 %), kar nakazuje, da se usposabljanje digitalne tehnologije širi na različna področja.

Anketiranci zasedajo ključne položaje v svojih institucijah: 24 % jih je direktorjev usposabljanja, 32 % pa vodij ali direktorjev šol. To kaže, da ima skoraj 50 % udeležencev vloge odločanja glede




integracije novih tehnologij. Preostali anketiranci imajo druge položaje, kot so učitelji (24 %) in administrativno osebje (16 %).


Centri za usposabljanje se močno razlikujejo po številu študentov, ki vsako leto diplomirajo. Medtem ko v 36 % centrih diplomira le med 1 - 99 študentov na leto, obstaja tudi znaten odstotek (24 %) centrov, ki diplomira med 100 in 299 študentov. Poleg tega ima skupina centrov večji vpliv, saj letno diplomira več kot 300 učencev.

Tabela 10. Porazdelitev odgovorov ankete Centra za poklicno izobraževanje in usposabljanje po državah

proti	Država	Število podjetij	Število odgovorov
VET	FR	11	6
	NEMČ	14	2
	SI	16	16
	ŠV	10	
	IT	1	1
Skupno poklicno izobraževanje in usposabljanje		52	25




Slika 41. Velikost organizacij na državo




Slika 42. Katero je glavno področje strokovnega usposabljanja, ki ga izvaja vaš center?





Slika 43. Kakšna je vaša vloga v instituciji?




Slika 44. Koliko študentov vsako leto diplomira?

6.6.4. TRENUTNO STANJE PROGRAMOV USPOSABLJANJA IN AVTONOMIJE CENTROV

Izobraževalni centri v Evropi nimajo vedno popolne avtonomije, saj morajo v mnogih primerih slediti smernicam, ki jih določijo hierarhično nadrejene institucije. Te smernice pogosto prihajajo od vladnih organov, kot so ministrstva za izobraževanje, ki imajo pooblastila za določanje politik in regulativnih okvirov, ki se jih morajo centri držati. Ta hierarhična struktura zagotavlja skladnost in kakovost usposabljanja na nacionalni ravni, vendar omejuje zmožnost centrov, da sprejemajo popolnoma neodvisne odločitve glede svojih programov in metod poučevanja.

V luči te situacije se nam je zdelo zanimivo razumeti stopnjo avtonomije anketiranih izobraževalnih centrov. Rezultati kažejo, da večina izobraževalnih centrov poroča o omejeni (44 %) ali delni (36 %) avtonomiji pri prilagajanju svojih programov novim tehnologijam. Le 4 % jih ima popolno avtonomijo, 8 % pa jih trdi, da je nimajo. Ti rezultati poudarjajo pomembno omejitev za večino centrov, saj se pri izvajanju sprememb v svojih programih pogosto zanašajo na zunanje podatke.





Slika 45. Kakšna je zmožnost vašega podjetja, da vsebino svojih tečajev usposabljanja prilagodi razvoju, povezanemu s trendi, kot so internet stvari, umetna inteligenca, kibernetika varnost in trajnost v vzdrževalnih poklicih?

Naslednja tabela predstavlja široko paleto izobraževalnih programov, ki jih organizira Evropsko ogrodje kvalifikacij (EQF) stopnje, s poudarkom na ključnih disciplinah, kot je npr IoT (internet stvari), umetna inteligenca (AI), kibernetika varnost, **trajnost** in Računalništvo v oblaku . Spodaj je kratka analiza pridobljenih podatkov:

Programi v IoT so na voljo od EQF 4 do EQF 6, pokrivajo teme, kot so pametne električne instalacije in industrijsko vzdrževanje, z močnim poudarkom na inovacijah za industrijo . To odraža vse večjo potrebo po strokovnjakih, usposobljenih za ustvarjanje in implementacijo pametnih naprav ter njihovo integracijo v industrijske sisteme.

Kar zadeva kibernetiko varnost, tečaji pokrivajo varnost in zaščito informacijskih sistemov na različnih ravneh ter združujejo teoretično vsebino s praktičnim usposabljanjem. Etično hekanje je bistveni del učnega načrta, ki poudarja potrebo po strokovnjakih, ki so sposobni zaščititi informacijske sisteme pred kibernetičnimi napadi. Programi zagotavljajo celovito usposabljanje za obravnavo digitalnih tveganj in groženj.

Umetna inteligenca (AI) je vključena v programe od EQF 4 do EQF 6 in se osredotoča na njeno uporabo v računalništvu, naprednih omrežjih in industrijskem vzdrževanju. Vključitev umetne inteligence v te izobraževalne ravni kaže na veliko povpraševanje po veščinah za razvoj, implementacijo in upravljanje rešitev, ki temeljijo na umetni inteligenci, kar postaja bistvenega pomena v sektorjih, kot so proizvodnja, IT in industrijska avtomatizacija.

Izobraževalni programi, povezani s trajnostjo, pokrivajo področja, kot so učinkovita uporaba orodij, obnovljivi viri energije in trajnostni industrijski procesi. Ti tečaji vključujejo tehnično usposabljanje in okoljsko upravljanje , pri čemer poudarjajo pomen vključevanja trajnostnih praks v industrijske procese ter razvoj bolj zelenih in učinkovitejših tehnologij.

Čeprav izraz računalništvo v oblaku ni izrecno omenjen, so tečaji, ki zajemajo strežniške sisteme in napredna omrežja, tesno povezani z infrastrukturo v oblaku. Obvladovanje strežniških sistemov in upravljanja omrežij je ključnega pomena za gradnjo in upravljanje platform v oblaku, kar poudarja pomembnost teh veščin v digitalnem svetu in stalno digitalno preobrazbo v različnih sektorjih.



Tabela 11. Tečaji, ki se poučujejo na področju nastajajočih tehnologij 4.0 (IoT, AI, Cyber, Sustainability, Cloud)

Tečaji	
Francija	• BAC STI2D: diploma iz znanosti in tehnologij industrije in trajnostnega razvoja (EQF 4) • BAC PRO CIEL: Poklicna matura iz kibernetske varnosti, računalništva in elektronskih omrežij (EQF 4) • BAC PRO TRPM: Poklicna diploma tehnika izdelave strojnih izdelkov, specializirana za izvajanje in spremljanje proizvodnje (EQF 4) (Francija) • BTS CIEL: Certifikat višjega tehnika na področju kibernetske varnosti, računalništva in elektronskih omrežij (EQF 5) • BTS CPRP: Certifikat višjega tehnika za zasnovno procesa razvoja izdelkov (EQF 5) • BTS CRSA: Certifikat višjega tehnika za načrtovanje in proizvodnjo avtomatiziranih sistemov (EQF 5) • LICENCA PRO Conception et Production de Systemes Electroniques : Poklicna diploma iz oblikovanja in proizvodnje elektronskih sistemov (EQF 6) • LICENCA PRO CAPPI: poklicna diploma na področju načrtovanja in izboljšave industrijskih procesov in postopkov (EQF 6)
Francija	• BTS CPRP: Certifikat višjega tehnika za zasnovno procesa razvoja izdelkov (EQF 5) • BTS CIEL na področju kibernetske varnosti, računalništva in elektronskih omrežij (EQF 5)
Francija	• BTS CRSA: Certifikat višjega tehnika za načrtovanje in proizvodnjo avtomatiziranih sistemov (EQF 5) • Trajnost: BTS STI2d: Certifikat višjega tehnika v znanosti in tehnologijah industrije in trajnostnega razvoja (EQF 5) • BTS CPI: Certifikat višjega tehnika za oblikovanje industrijskih izdelkov (EQF 5)
Francija	• IoT in AI: Certifikat višjega tehnika za industrijsko vzdrževanje • IoT, kibernetska varnost, AI: License Pro MMB: poklicna diploma za vzdrževanje biomedicinske opreme • IoT, kibernetska varnost, umetna inteligenca: License Pro MIF: poklicna diploma iz vzdrževanja industrije 4.0
Francija	• BTS CRSA: Certifikat višjega tehnika za načrtovanje in proizvodnjo avtomatiziranih sistemov (EQF 5) • Modul za robotiko
Slovenija	• Digitalno poučevanje
Slovenija	• IoT -> BUT GMP: univerzitetni diplomirani inženir strojništva in proizvodnega inženirstva, specializiran za inovacije za industrijo (EQF 6)
Slovenija	• Informacijska tehnologija in uporabniški vmesnik: Digital Teacher Project - Vaš ključ do uspeha v digitalni dobi - Webinar 1 in 2
Slovenija	• Trajnost
Slovenija	• Uporabniški vmesnik • Učinkovita uporaba orodij
Slovenija	• Etično hekanje - praktično usposabljanje • Kibernetska varnost • Umetna inteligenca v informacijski tehnologiji - praktično usposabljanje • Umetna inteligenca • Strežniški sistemi • Napredna računalniška omrežja
Slovenija	• Digitalizacija (EQF 7)
Slovenija	• Trajnost • Uporabniški vmesnik
Slovenija	• Trajnost EQF 5
Slovenija	• IoT pametne elektroinstalacije na srednji strokovni šoli in višji tehniški šoli • Trajnost, učinkovita raba in obnovljivi viri energije na Višji tehniški šoli • Kibernetska varnost, Varovanje in zaščita na Višji tehniški šoli • Kibernetska varnost, Zaščita informacijskih sistemov na Visoki tehniški šoli
Italija	• Sistemi in omrežja (EQF 4) • Tehnologije in načrtovanje informacijskih in telekomunikacijskih sistemov (EQF 4)




- Računalništvo (EQF 4)
- Telekomunikacije (EQF 4)
- Projektno vodenje, poslovna organizacija (EQF 4)

6.6.5. PRIHODNI RAZVOJ USPOSABLJANJA

Graf prikazuje, da se je veliko institucij sicer začelo prilagajati, a pomemben del še vedno deluje v dolgih prehodnih obdobjih (2–5 let ali več). Glede na hiter razvoj umetne inteligence, interneta stvari in kibernetske varnosti pri vzdrževanju bi lahko celo 2–5-letni časovni okvir upočasnili konkurenčnost delovne sile v nekaterih regijah. Institucije v kategoriji 6+ let tvegajo, da bodo diplomanti neprilagodljivi na industrijo 4.0.

Zdi se, da sta umetna inteligenca in trajnost ključni prednostni nalogi.




Slika 46. Ali se izvajajo koraki za razvoj vsebine v skladu s trendi, navedenimi v vzdrževalnih poklicih?

6.6.6. INTEGRACIJA S POTREBAMI INDUSTRIJE


Zanimivo je opazovati, kako večina centrov za usposabljanje veliko raje spodbuja praktično uporabo konceptov prediktivnega vzdrževanja (PdM) v programih usposabljanja za vzdrževanje prek partnerstev s proizvajalci namesto z univerzami. V zvezi s tem je bila kot dragocen vir za ta namen izpostavljena tudi uporaba virtualne simulacije.

Centri za usposabljanje ne vidijo partnerstva z industrijo le kot način uporabe praktičnega usposabljanja, ampak tudi kot sredstvo za vključitev industrijskih potreb v realnem času v svoje programe. V tem kontekstu predstavljajo pomembno priložnost tudi praktične izkušnje v izobraževalnih centrih. V manjši meri je bilo upoštevano oblikovanje posebnih modulov ali hibridnega usposabljanja.






Slika 47. Kakšne priložnosti ali možnosti bi lahko vaša ustanova predvidela ali jih je že predvidela za vključitev industrijskih potreb v realnem času, kot so tiste, povezane s predvidenim vzdrževanjem, v programe usposabljanja, kjer je to mogoče?



Slika 48. Katere pristope podpira vaša ustanova za krepitev praktične uporabe konceptov prediktivnega vzdrževanja (PdM) v programih usposabljanja za vzdrževanje?

Večina centrov je v prvi vrsti odvisnih od javnega financiranja, hkrati pa si prizadevajo za industrijska partnerstva in skupne projekte z drugimi centri za poklicno izobraževanje in usposabljanje, manj pa se jih zanaša na lastna sredstva. To kaže na potrebo po diverzifikaciji virov financiranja za podporo tehnološkega napredka pri usposabljanju.





Slika 49. Kakšne finančne rešitve so predvidene za razvoj dostopa do najnovejših tehnoloških dosežkov v programih usposabljanja za vzdrževanje?


6.6.7. USPOSABLJANJE IN SODELOVANJE UČITELJEV

Kar zadeva strategije, ki se izvajajo ali se zdijo potrebne za usposabljanje trenerjev in učiteljev za napredne tehnologije, se večina centrov (64 %) osredotoča na "tehnološko opazovanje", ki učiteljem pomaga, da ostanejo na tekočem z najnovejšimi trendi. Druge pomembne strategije vključujejo "zunanje usposabljanje in certificiranje" (44 %), ki zagotavlja specializirane in priznane veščine, ter "praktične delavnice" (32 %), ki ponujajo neposredne praktične izkušnje. Vendar pa je manj centrov omenilo "poglobitev v industrijo" (8 %) ali "dan novih tehnologij s centri za poklicno izobraževanje in usposabljanje" (16 %), kar nakazuje, da so te metode manj pogoste, čeprav dragocene za vključevanje izkušenj iz industrije v usposabljanje.


Večina centrov (48 %) kaže nagnjenost k občasnemu sodelovanju z drugimi centri in organizacijami, da bi spodbudili skladnost tečajev usposabljanja za vzdrževanje, kar kaže na prilagodljiv pristop, vendar brez dolgoročnih zavez. Približno 16 % centrov nima aktivnega sodelovanja, kar kaže, da nekateri raje delujejo neodvisno. Samo 12 % jih ima močna partnerstva, majhen odstotek (4 %) pa predvideva prihodnje sodelovanje. Ta situacija kaže nagnjenost k občasnim sodelovanjem in šibkost, ko gre za vzpostavljjanje trdnih, dolgotrajnih partnerstev.

Razvoj medsebojno odvisnih izobraževalnih poti podpira večina centrov (48 %) prek »industrijskega sodelovanja«, ki usklajuje usposabljanje z dejanskimi potrebami trga. Pogosti so tudi »skupni okviri usposabljanja« (52 %), ki omogočajo standardizacijo programov med institucijami. Vendar se le 20 % centrov zanima za "skupne certifikate", kar kaže na to, da je še vedno omejen poudarek na ustvarjanju skupnih poverilnic z drugimi centri za usposabljanje. Približno 32 % jih ne zanima za te medsebojno odvisne projekte, kar kaže na to, da raje ohranjajo avtonomijo in nadzor nad lastnimi programi usposabljanja.






Slika 50. Katere strategije obstajajo ali so potrebne za usposabljanje vodij usposabljanja in učiteljev za napredne tehnologije?



Slika 51. Katere strategije sodelovanja so bile vzpostavljene ali predvidene z drugimi centri za usposabljanje in drugimi organizacijami za spodbujanje skladnosti tečajev usposabljanja za vzdrževanje?






Slika 52. Kako predvidevate razvoj medsebojno odvisnih poti usposabljanja s sodelovanjem med ustanovami z različnimi področji zanimanja za usposabljanje vzdrževanja?

6.6.8. IZZIVI IN INDUSTRIJSKO SODELOVANJE

Kar zadeva preference centrov za usposabljanje za krepitev povezav z industrijo, jih 32 % daje prednost rednim ocenjevanjem svojih programov usposabljanja z industrijskimi partnerji. Večji delež, 36 %, daje prednost industrijskim svetovalnim svetom, ki zagotavljajo neposredne in specializirane povratne informacije za izboljšanje programov usposabljanja. Poleg tega se 24 % centrov zanima za druge vrste strategij. Nazadnje, 32 % meni, da povezave sodelovanja ostajajo omejene.



Slika 53. Kako je mogoče okrepiti sodelovanje s strokovnjaki iz industrije za boljšo uskladitev učne vsebine s sedanji in prihodnji potrebi na področju prediktivnega vzdrževanja (PdM) in sorodnih področij?

6.6.9. POVZETEK REZULTATOV ANKETE

Največ anketiranih centrov je v Sloveniji, sledijo Francija, Nemčija in Italija. Štiriinštirideset odstotkov centrov ima med 500 in 999 študentov, medtem ko jih ima 28 % več kot 1000 študentov.



Število študentov, ki letno diplomirajo, je različno, pri čemer v nekaterih centrih diplomira manj kot 100 študentov, medtem ko drugi presežejo 300 diplomantov na leto.

Večina anketirancev je na položajih odločanja, kot so direktorji usposabljanja ali vodje šol, kar kaže, da so bili v raziskavi zbrani prispevki posameznikov s pooblastili, da vplivajo na vključevanje novih tehnologij.

Kot je bilo pričakovano, je večina centrov za usposabljanje (64 %) v industrijskem sektorju centrov. Vendar pa je usposabljanje zagotovljeno tudi v drugih sektorjih, kot sta terciarni in avtomobilski.

Sprejemanje novih tehnologij in avtonomija

Izobraževalni centri poročajo o omejeni ali delni avtonomiji pri prilagajanju svojih programov novim tehnologijam, le nekaj centrov pa ima popolno avtonomijo. Izobraževalni centri poročajo o omejeni ali delni avtonomiji pri prilagajanju svojih programov novim tehnologijam, le nekaj centrov pa ima popolno avtonomijo. Ti centri vidijo svojo sposobnost prilagajanja kot omejeno s hierarhično nadrejenimi institucijami z resnično močjo odločanja. Ta odvisnost lahko vodi tudi do pomanjkanja hitrosti v procesih odločanja ali povečanja birokracije. Kljub tej situaciji je napredek dosežen na ključnih področjih, kot so umetna inteligenca (AI), trajnost, kibernetika, varnost, internet stvari in računalništvo v oblaku, pri čemer sta umetna inteligenca in trajnost najbolj dinamična področja kratkoročno, srednjeročno in dolgoročno. Vendar je dolgoročno opaziti zmanjšanje števila načrtovanih ukrepov, kar kaže na pomanjkanje trajne zavezanosti. Najpogosteje ponavljajoči se tečaji na področjih interneta stvari, kibernetike, varnosti, umetne inteligence in trajnosti vključujejo programe kibernetike, varnosti (s poudarkom na etičnem vedenju in zaščiti informacijskih sistemov), tečaje interneta stvari, povezane z industrijskim vzdrževanjem in pametnimi električnimi inštalacijami, ter umetno inteligenco, integrirano v IT in omrežne sisteme. Trajnost se pogosto obravnava s programi, osredotočenimi na energetske učinkovitost, obnovljivo energijo in trajnostne industrijske procese. Tečaji o strežniških sistemih in naprednih omrežjih so tesno povezani z računalništvom v oblaku, čeprav niso izrecno omenjeni. Ti navedeni programi (glejte ustrezno tabelo »Tečaji, ki se poučujejo na področju nastajajočih tehnologij 4.0«) odražajo naraščajoče povpraševanje po strokovnjakih s spretnostmi na teh ključnih tehnoloških področjih.

Na primer, v Franciji sta tehnologiji IoT in AI že vključeni v usposabljanja »Higher Technician Certificate in Industrial Maintenance« in »Licence Pro MIF: Vocational Degree in Maintenance of the Industry 4.0«.

Sodelovanja

Centri priznavajo pomen industrijskih partnerstev, praktičnih izkušenj in v manjši meri ustvarjanja posebnih modulov in hibridnega usposabljanja za integracijo potreb industrije v realnem času. Za to integracijo raje sodelujejo z industrijo kot z univerzami.

Večina centrov občasno sodeluje z drugimi centri in organizacijami, vendar so dolgoročna partnerstva manj pogosta. Industrijsko sodelovanje in skupni okviri usposabljanja so najpogosteje uporabljene strategije za medsebojno odvisne poti usposabljanja, čeprav so skupni certifikati omejeni. Številni centri raje ohranijo avtonomijo in nadzor nad svojimi programi usposabljanja, kot da ustvarijo skupne poverilnice.

Večina centrov občasno sodeluje z drugimi centri in organizacijami, vendar so dolgoročna partnerstva manj pogosta. Industrijsko sodelovanje in skupni okviri usposabljanja so najpogosteje uporabljene strategije za medsebojno odvisne poti usposabljanja, čeprav so skupni certifikati omejeni. Številni centri raje ohranijo avtonomijo in nadzor nad svojimi programi usposabljanja, kot da ustvarijo skupne poverilnice.

Viri financiranja in usposabljanje inštruktorjev

44 % volišč ima lastne prihodke, večji odstotek pa jih je navedel pridobivanje sredstev iz javnih virov ali sredstev industrije.



Centri za usposabljanje dajejo prednost strategijam, kot so "tehnološki nadzor", zunanje usposabljanje in certificiranje ter praktične delavnice ali smernice iz nacionalnih izobraževalnih načrtov usposabljanja, namesto metod, kot je industrijsko poglobitev.

Outlook

Zaradi vsebine tega poročila bi moral biti naslednji korak ocena obsega, v katerem so te nastajajoče tehnologije vključene v programe usposabljanja, s čimer bi zagotovili, da ostanejo na tekočem z najnovejšimi dosežki in izpolnjujejo potrebe MSP.

6.7. POVZETEK

Nedavno tehnološki napredek je spremenil način dojemanja vzdrževanja v podjetjih. To predstavlja priložnosti in izzive za centre za usposabljanje, ki morajo prilagoditi svoje programe spreminjajočim se potrebam industrije.

S pregledom literature smo ugotovili, da se je v sektorju usposabljanja že začel proces standardizacije, ki upošteva nove zahteve, kompetence in vloge na področju vzdrževanja.

6.7.1. POSTOPKI CERTIFICIRANJA IN STANDARDIZACIJE

Programi, kot je *Erasmus+*, in certifikati, kot je *ISO*, so namenjeni spodbujanju certificiranja in standardizacije, kar prispeva k večji poslovni produktivnosti na evropski ravni.

Evropsko *ogrodje kvalifikacij (EQF)* je bilo ključno orodje v tem procesu. Na primer:

- Na ravni 6 tega okvira mora strokovnjak za vzdrževanje imeti znanje o napovednem, preventivnem in korektivnem vzdrževanju, vključno z naprednimi tehnikami spremljanja. Od njih se pričakuje tudi, da analizirajo podatke, razvijajo načrte in izvajajo izboljšave, medtem ko imajo avtonomijo pri sprejemanju odločitev, ki optimizirajo procese, zagotavljajo varnost in skladnost s predpisi.
- Na 5. stopnji EQF mora biti specialist sposoben obravnavati teme, kot so analiza vibracij, konfiguracija programske opreme, zbiranje podatkov, napovedna diagnostika in izvajanje vzdrževanja.

6.7.2. ZAHTEVANE SPRETNOSTI V SEKTORJU VZDRŽEVANJA

Strokovnjaki za vzdrževanje ne smejo imeti le tehničnih in analitičnih veščin, kot je diagnostika na osnovi umetne inteligence ali upravljanje senzorjev interneta stvari, temveč tudi transverzalne kompetence, znane kot **mehke veščine**. Ti vključujejo: timsko delo, reševanje problemov v realnem času, večnamenskost, komunikacijske veščine

Ugotovljena so bila štiri glavna področja vzdrževanja:

- Preventivno vzdrževanje: osredotoča se na strategije za zagotavljanje visoke zanesljivosti z načrtovanjem in izvajanjem učinkovitih načrtov.
- Vnaprej določeno vzdrževanje: Zanaša se na vnaprej določene metode in tehnike za načrtovane posege.
- Vzdrževanje na podlagi stanja: uporablja subjektivne in objektivne tehnike za določitev intervalov pregledov in optimizacijo procesov.
- Prediktivno vzdrževanje: uporablja napredne metode za predvidevanje okvar, pri čemer se razlikuje od nepredvidljivega vzdrževanja in optimizira svojo uporabo prek ustreznih sistemov.



6.7.3. VPLIV NOVIH TEHNOLOGIJ NA VZDRŽEVANJE

Tehnološki napredek z največjim vplivom v sektorju vključuje: internet stvari (IoT), umetno inteligenco (AI), kibernetško varnost, trajnost (Durabilité), vzdrževanje kot storitev (MaaS), ki temelji na platformah za sodelovanje v oblaku.

Glede na rezultate raziskave izobraževalni centri te tehnologije vključujejo v svoje programe. AI in Trajnost so področja, kjer je bilo sprejetih največ pobud.

Vendar bi moral biti naslednji korak zaradi vsebine tega poročila ocena obsega, v katerem so te nastajajoče tehnologije vključene v programe usposabljanja, s čimer bi zagotovili, da so na tekočem z najnovejšimi dosežki in izpolnjujejo potrebe MSP.

6.7.4. NOVOSTI V POKLICNEM USPOSABLJANJU

S sprejetjem novih učnih strategij se je razvil tudi izobraževalni sektor. Nekatera najbolj opazna orodja vključujejo:

- Hibridno učenje (*training hybrid*), ki združuje spletne module, simulacije in osebno praktično usposabljanje za izboljšanje dostopnosti in učinkovitosti.
- Digitalni dvojčki, ki omogočajo simulacijo vzdrževalnih procesov v virtualnem okolju.
- Razširjena resničnost (AR) in navidezna resničnost (VR), ki olajšata usposabljanje v simuliranih okoljih.

Glede na rezultate raziskave centri za usposabljanje v veliki meri izvajajo *hibridno* in *virtualno simulacijo usposabljanja kot del svojega procesa prilagajanja*.

6.7.5. SODELOVANJE MED CENTRI ZA USPOSABLJANJE IN INDUSTRIJO

Druga nastajajoča priložnost je vse večje sodelovanje med institucijami.

- Večina centrov za usposabljanje priznava pomen industrijskih partnerstev za integracijo industrijskih potreb v realnem času.
- Raziskava je pokazala tudi velik razkorak med sodelovanjem s proizvajalci in sodelovanjem z univerzami, pri čemer je prvo veliko pogostejše.
- Izobraževalni centri raje sodelujejo s podjetji kot z drugimi izobraževalnimi ustanovami.

Poleg tega pri preučevanju pobud za spodbujanje standardizacije usposabljanja rezultati ankete kažejo, da je sodelovanje z drugimi centri običajno le občasno. Vendar medinstitucionalno sodelovanje krepi tudi sodelovanje s podjetji.

6.7.6. IZZIVI ZA CENTRE ZA USPOSABLJANJE

Kljub priložnostim se izobraževalni centri soočajo s precejšnjimi izzivi, predvsem pri prilagajanju svojih programov potrebam industrije. Ključno vprašanje je avtonomija. Na primer, le 5 % anketiranih centrov ima popoln nadzor nad posodabljanjem svojih programov, večina pa se sooča s precejšnjimi omejitvami. Finančne omejitve to stanje še poslabšujejo, saj tehnološki napredek zahteva znatna vlaganja v napredno opremo in stalno usposabljanje učiteljev. Glede na rezultate raziskave ima le 44 % centrov lastno financiranje, medtem ko se jih 68 % zanaša na javna sredstva in 56 % na industrijska partnerstva.

Za reševanje teh izzivov so centri za usposabljanje uvedli strategije za izboljšanje usposabljanja učiteljev, kot je uporaba tehnološke ure, zunanje usposabljanje in certificiranje, praktične delavnice in smernice iz nacionalnih izobraževalnih načrtov. Vendar podatki raziskave kažejo, da je



poglobitev v industrijo najmanj prednostni vidik usposabljanja učiteljev, kar poudarja vrzel med pripravo učiteljev in dejanskimi zahtevami industrije.



7. PDM: GONILNA SILA ZA ZELENO PREOBRAZBO


Prediktivno vzdrževanje (PdM) ima ključno vlogo pri zeleni preobrazbi proizvodne industrije z občutnim zmanjšanjem vpliva na okolje. Z izkoriščanjem tehnologij, ki temeljijo na podatkih, PdM optimizira delovanje strojev, podaljšuje življenjsko dobo opreme in zmanjšuje porabo virov, kar prispeva k prizadevanjem za trajnost v industrijskih sektorjih.

Ena od ključnih okoljskih prednosti PdM je njegova sposobnost zmanjševanja materialnih odpadkov. S predvidevanjem in preprečevanjem okvar so nepotrebna popravila in zamenjave delov čim manjša, kar vodi do nižje porabe materiala in zmanjšanja industrijskih odpadkov. Poleg tega podaljšana življenjska doba strojev zmanjša potrebo po proizvodnji nove opreme, s čimer se zmanjša pridobivanje surovin in s tem povezana degradacija okolja (Dilda, V. et al, 2017).


Drugi pomemben prispevek PdM k trajnosti je njegov vpliv na energetske učinkovitost. Dobro vzdrževani stroji delujejo učinkoviteje, porabijo manj energije in zmanjšajo emisije CO₂. Glede na (Hector, J. in Panjanathan, 2024) napredek v IoT in spremljanje v realnem času omogočata proizvajalcem, da zgodaj odkrijejo neučinkovite pogoje delovanja, kar omogoča pravočasne prilagoditve, ki zmanjšajo skupno porabo energije. Ta proaktivni pristop neposredno podpira prizadevanja za varčevanje z energijo in pomaga industrijam uskladiti globalne cilje ogljične nevtralnosti.

Poleg tega PdM optimizira globalne dobavne verige z zmanjšanjem nepotrebnih emisij pri transportu in logistiki. Učinkovito načrtovanje vzdrževanja zmanjša pošiljke nujnih delov in izpade strojev, racionalizira proizvodne načrte in zmanjša potrebo po čezmerni varnostni zalogi. Ta optimizacija vodi k boljši koordinaciji materialnih tokov, kar na koncu zmanjša ogljični odtis logističnih omrežij (Staufen AG, 2020) .

PdM podpira tudi trajnostno odločanje v organizacijah. Integracija napovedne analitike v sisteme za podporo odločanju (DSS) omogoča proizvajalcem, da učinkovito uravnotežijo ekonomske in okoljske prioritete. Z izkoriščanjem vpogledov, ki temeljijo na podatkih, lahko podjetja izvajajo strategije vzdrževanja, ki ne samo izboljšajo operativno učinkovitost, ampak so tudi usklajene s cilji trajnosti (Hector, J., & Panjanathan, 2024) .



Slika 54. Sinteza rezultatov - (Hector, J., & Panjanathan , 2024) .



Poleg tega PdM spodbuja krožno gospodarstvo s spodbujanjem učinkovite rabe virov in zmanjševanjem okoljskega bremena proizvodnje. S podaljšanjem življenjskega cikla strojev in preprečevanjem nenačrtovanih okvar lahko proizvajalci zmanjšajo svoj skupni materialni odtis in povečajo dolgoročno trajnost.

Skratka, prediktivno vzdrževanje je ključni dejavnik zelene preobrazbe proizvodne industrije. Z optimizacijo učinkovitosti strojev, zmanjševanjem odpadkov in zmanjševanjem porabe energije PdM pomaga podjetjem doseči trajnostne cilje, hkrati pa izboljšuje dobičkonosnost. Ker digitalni napredek in napredek interneta stvari še naprej izboljšujeta zmogljivosti PdM, bo njegova vloga pri spodbujanju okoljsko odgovorne proizvodnje le še bolj izrazita.



8. POGLEDI IN SKLEP

8.1. OBETI: PRIHODNJI TRENDI IN PRILOŽNOSTI

Ker se prediktivno vzdrževanje (PdM) še naprej razvija, bodo njegovo prihodnost oblikovali **tehnološki napredek, modeli, ki temeljijo na storitvah, pomisleki glede kibernetске varnosti in razvoj delovne sile** . Več ključnih trendov bo opredelilo naslednjo fazo sprejemanja PdM in njegove vloge pri industrijski transformaciji.

8.1.1. INTEGRACIJA GENERATIVNE UMETNE INTELIGENCE ZA IZBOLJŠANE NAPOVEDNE MODELE

Integracija Generative AI v napovedno vzdrževanje bo povečala natančnost predvidevanja, izboljšala preglednost pri odločanju na podlagi umetne inteligence in avtomatizirala diagnostiko za optimizacijo vzdrževalnih procesov.

- Generativna umetna inteligenca bo **izboljšala napovedno natančnost** z ustvarjanjem **synetičnih podatkov o okvarah** , zlasti za industrije z **omejenimi zgodovinskimi podatki o okvarah strojev** .
- Sprejetje **razložljive umetne inteligence (XAI)** bo zagotovilo **večjo preglednost** pri odločitvah PdM , ki temeljijo na umetni inteligenci, zaradi česar bodo napovedni vpogledi **bolj razumljivi in učinkoviti za tehnike** .
- , ki jo poganja AI, **in rešitve za predpisano vzdrževanje** bodo optimizirale **odločanje in zmanjšale ročno posredovanje** pri načrtovanju vzdrževanja.

8.1.2. RAZŠIRITEV SPREJEMANJA PDM-AS-A-SERVICE (PDMAAS)

Razvoj PdM v model storitev, ki temelji na naročninah, bo naredil prediktivno vzdrževanje bolj dostopno za mala in srednja podjetja, spodbudil sodelovanje v industriji in spodbudil sprejetje opreme kot storitve (EaaS).

- Model **PdM , ki temelji na naročnini**, bo znižal stroškovne ovire, zaradi česar bo PdM **bolj dostopen malim in srednjim podjetjem**, saj odpravlja potrebo po velikih začetnih naložbah.
- Proizvajalci originalne opreme (OEM) in **ponudniki industrijskih storitev** bodo vse pogosteje sodelovali pri zagotavljanju **integriranih, razširljivih rešitev PdM** , kar bo podjetjem omogočilo **zunanje izvajanje strokovnega znanja o vzdrževanju in hkrati izboljšalo operativno učinkovitost** .
- Vzpon **EaaS (Equipment-as-a-Service)** bo dodatno podpiral predvideno vzdrževanje, saj proizvajalci ponujajo stroje z vgrajenimi zmogljivostmi PdM v okviru pogodb s plačilom po uporabi.

8.1.3. NAPREDNA KIBERNETSKA VARNOST ZA INDUSTRIJSKI IOT

Ker sistemi predvidenega vzdrževanja, ki podpirajo internet stvari, rastejo, bo krepitev ukrepov kibernetске varnosti ključnega pomena za zaščito industrijskih podatkov, zagotavljanje zanesljivosti sistema in blažitev nastajajočih kibernetских groženj.



- Ko se **sistemi predvidenega vzdrževanja, ki podpirajo IoT**, širijo, se bodo **grožnje kibernetiki varnosti** povečevale, kar zahteva **varnostne rešitve, ki temeljijo na umetni inteligenci**, za zaščito **industrijskih podatkov in povezanih sredstev v realnem času**.
- **Pobude, kot je DETECTA 2.0**, bodo vodilne pri razvoju **robustnih ogrodij kibernetike varnosti**, prilagojenih za okolja PdM, ki zagotavljajo celovitost podatkov in zanesljivost sistema.
- Podjetja bodo sprejela **arhitekture ničelnega zaupanja in načela varnega oblikovanja**, da bi zmanjšala kibernetika tveganja, povezana z rešitvami v oblaku in robnimi računalniškimi rešitvami pri vzdrževanju.

8.1.4. USKLADITEV USPOSABLJANJA Z INDUSTRIJO 5.0

Prehod na predvideno vzdrževanje, ki ga poganja AI, bo zahteval stalno izpopolnjevanje delovne sile, nove modele usposabljanja in integracijo naprednih učnih orodij za uskladitev z zahtevami industrije 5.0.

- Ko se PdM preusmerja k **avtomatizaciji, ki temelji na umetni inteligenci**, bodo strokovnjaki za vzdrževanje potrebovali **nove kompetence na področju umetne inteligence, interneta stvari, kibernetike varnosti in analitike podatkov**, da bodo ostali konkurenčni.
- **Modeli vseživljenjskega učenja in mikrokreditni programi** bodo postali norma, kar bo delavcem omogočilo **nenehno posodabljanje njihovih veščin**, ko se bodo pojavile nove tehnologije PdM.
- Ustanove za usposabljanje bodo morale **premostiti vrzel v spretnostih z vključitvijo študij primerov iz resničnega sveta, simulacij, ki jih poganja AI, in hibridnih učnih formatov** v programe usposabljanja za vzdrževanje.

8.2. ZAKLJUČEK

Prediktivno vzdrževanje (PdM) ni več le **tehnološka nadgradnja** – je **strateška nuja za industrijsko konkurenčnost, učinkovitost in trajnost**. Kot ključni spodbujevalec **industrije 4.0 in prehoda na industrijo 5.0** PdM preoblikuje vzdrževalne operacije prek **AI, IoT, digitalnih dvojčkov in generativne umetne inteligence** ter ponuja **zmogljivosti napovedovanja brez primere**.

Medtem ko **velika podjetja** hitro napredujejo, se **MSP še vedno soočajo s precejšnjimi ovirami**, kot so **visoki stroški izvajanja, pomanjkanje strokovnega znanja in izzivi pri vključevanju**. Premagovanje teh ovir zahteva **razširljive rešitve**, kot je **PdM -as-a-Service (PdMaaS)**, ki podjetjem omogočajo dostop do naprednih vzdrževalnih strategij brez **velikih vnaprejšnjih naložb**.

Poleg tehnologije **se delovna sila močno spreminja**. Strokovnjaki za vzdrževanje morajo razviti **analitiko podatkov, diagnostiko na podlagi umetne inteligence in veščine kibernetike varnosti** za učinkovito implementacijo rešitev PdM. Vendar se **institucije poklicnega izobraževanja in usposabljanja (VET)** še vedno trudijo uskladiti učne načrte z **nastajajočimi digitalnimi trendi**. Krepitev **industrijsko-akademijskih partnerstev**, vključevanje **hibridnih modelov usposabljanja** in vključevanje **študij primerov PdM iz resničnega sveta** bo bistvenega pomena za zapolnitev **vrzeli v spretnostih** in pripravo strokovnjakov na **vse večjo digitalizacijo industrijskega vzdrževanja**. **Modeli vseživljenjskega učenja in programi mikrokreditiranja bodo postali norma**, kar bo zagotovilo, da bodo delavci lahko nenehno posodabljali svoje kompetence in ostali prilagodljivi v hitro razvijajočem se tehnološkem okolju.

PdM ima tudi **ključno vlogo pri zelenem prehodu**, saj optimizira **porabo energije, zmanjšuje količino odpadkov in krepi trajnostne cilje** v proizvodnji. Vendar pa **dolgoročno sodelovanje**



centrov za usposabljanje in podjetij ostaja nedosledno, pri čemer mnogi še vedno oklevajo, da bi se zavezali k **popolni uporabi**.

Za popolno sprostitve potenciala PdM so ključnega pomena **medsektorsko sodelovanje, naložbe v digitalno infrastrukturo in razširljivi programi usposabljanja**. **Finančna podpora, politične spodbude in tesnejše sodelovanje med MSP, ustanovami za usposabljanje in ponudniki tehnologije** bodo pospešili sprejemanje in pripravljenost delovne sile. Poleg tega **vzpon vzdrževanja kot storitve (MaaS)** nakazuje premik k **servisno usmerjenim modelom vzdrževanja**, zaradi česar je PdM **bolj dostopna in prilagodljiva** podjetjem vseh velikosti.

Zagotavljanje **kohezivne strategije** med **sprejetjem tehnologije, izpopolnjevanjem delovne sile in trajnostnimi praksami** bo ključnega pomena za **vzdrževalne strategije, pripravljene na prihodnost**, in zagotavljanje **konkurenčnosti evropskih industrij v digitalni dobi**.



9. REFERENCE

- 7Puentes. (2024, September 3). *Challenges and opportunities for applying AI in predictive maintenance*. <https://www.7puentes.com/blog/2024/09/03/ai-in-predictive-maintenance/>
- [1912.07383] *A Survey of Predictive Maintenance: Systems, Purposes and Approaches*. (2019, December). <https://arxiv.org/abs/1912.07383>
- Alexander Barinov. (2022, April 15). *Using a Traditional Machine Learning approach for Predictive Maintenance | The AI Journal*. <https://aijourn.com/using-a-traditional-machine-learning-approach-for-predictive-maintenance/>
- Allied Market Research. (2024, August). *Predictive Maintenance Market Size, Forecast—2033*. Allied Market Research. <https://www.alliedmarketresearch.com/predictive-maintenance-market>
- Artesis. (2021, December 16). *Key Predictive Maintenance Trends for 2023 and Beyond—Condition Monitoring and Predictive Maintenance*. <https://artesis.com/key-predictive-maintenance-trends-for-2023-and-beyond/>
- arxiv. (2024, March). *A Survey of Predictive Maintenance: Systems, Purposes and Approaches*. <https://arxiv.org/html/1912.07383v2>
- ateam_admin. (2023, May 12). *IoT Predictive Maintenance Explained with Case Studies. A-Team Global*. <https://a-team.global/blog/iot-predictive-maintenance/>
- Berger, R. (2018, July). *Roland_berger_predictive_maintenance_2018.pdf. A TURNING POINT IN INDUSTRIAL SERVICES (2018). Roland Berger*. https://www.rolandberger.com/publications/publication_pdf/roland_berger_predictive_maintenance_2018.pdf
- Bhat, A. (2018, August 27). *Taux de réponse à l'enquête | Bon taux de réponse à l'enquête | . QuestionPro*. <https://www.questionpro.com/blog/fr/bon-taux-de-reponse-au-sondage-2/>



Campus of the Czech University of Life Sciences in Prague & Slovenian Maintenance Society - Id

31. (n.d.). *The project – Certified European Maintenance Professionals – Erasmus+*.

Retrieved 25 February 2025, from https://www.cemaint.eu/?page_id=31

Campus of the Czech University of Life Sciences in Prague & Slovenian Maintenance Society -

Id219. (n.d.). *Qualifications for Maintenance personnel at EQF level 6 – Certified European*

Maintenance Professionals – Erasmus+. Retrieved 25 February 2025, from

https://www.cemaint.eu/?page_id=219

Chevtchenko, S. F., Santos, M. C. M. dos, Vieira, D. M., Mota, R. L., Rocha, E., Cruz, B. V., Araújo,

D., & Andrade, E. (2023). Predictive Maintenance Model Based on Anomaly Detection in

Induction Motors: A Machine Learning Approach Using Real-Time IoT Data. *Proceeding of*

the 33rd European Safety and Reliability Conference, 3173–3180.

https://doi.org/10.3850/978-981-18-8071-1_P578-cd

chg-meridian. (n.d.). *Why own technology when you can simply use it?* Retrieved 26 February

2025, from <https://www.chg-meridian.de/>

Christiansen, B. (2022, March 10). What is Equipment as a Service (EAAS)? *Limble CMMS*.

<https://limblecmms.com/blog/what-is-equipment-as-a-service/>

D3-1-Observatory-Methodolgy-Final-version-1-1.pdf. (n.d.).

chrome-

extension://efaidnbmnnnibpcajpcglclefindmkaj/[https://lcamp.eu/wp-](https://lcamp.eu/wp-content/uploads/sites/53/2024/12/D3-1-Observatory-Methodolgy-Final-version-1-1.pdf)

[content/uploads/sites/53/2024/12/D3-1-Observatory-Methodolgy-Final-version-1-1.pdf](https://lcamp.eu/wp-content/uploads/sites/53/2024/12/D3-1-Observatory-Methodolgy-Final-version-1-1.pdf)

Dilda, V. et al. (2017, August). *Manufacturing: Analytics unleashes productivity and profitability* |

McKinsey. [https://www.mckinsey.com/capabilities/operations/our-insights/manufacturing-](https://www.mckinsey.com/capabilities/operations/our-insights/manufacturing-analytics-unleashes-productivity-and-profitability#/)

[analytics-unleashes-productivity-and-profitability#/](https://www.mckinsey.com/capabilities/operations/our-insights/manufacturing-analytics-unleashes-productivity-and-profitability#/)

Editor, S. (2019, June 19). *The 4 Drivers of Digital Transformation*. SSON.

[https://www.ssonetwork.com/continuous-improvement-process-improvement/articles/the-](https://www.ssonetwork.com/continuous-improvement-process-improvement/articles/the-4-drivers-of-digital-transformation)

[4-drivers-of-digital-transformation](https://www.ssonetwork.com/continuous-improvement-process-improvement/articles/the-4-drivers-of-digital-transformation)

Fernando Brügge. (2023, November 29). *Predictive maintenance market: 5 highlights for 2024 and*

beyond. IoT Analytics. <https://iot-analytics.com/predictive-maintenance-market/>



- Festo. (2021). *Festo und FlexFactory bündeln ihre Lösungen für as a Service-Geschäftsmodelle* | Presse. https://press.festo.com/de/company/festo-und-flexfactory-buendeln-ihre-loesungen-fuer-as-a-service-geschaeftsmodelle?utm_source=chatgpt.com
- fivesgroup. (n.d.). *Predictive Maintenance*. Retrieved 10 February 2025, from <https://www.fivesgroup.com/digital-solutions-ai/predictive-maintenance>
- FMI - Future Market Insights. (n.d.). *Predictive Maintenance Market Size & Trends 2034*. Retrieved 12 February 2025, from <https://www.futuremarketinsights.com/reports/predictive-maintenance-market>
- Fortune Business Insights. (2025, January). *Predictive Maintenance Market Size, Share | Growth Trends*. <https://www.fortunebusinessinsights.com/predictive-maintenance-market-102104>
- Goncharov, E. (2023). *ICS cyberthreats in 2023 – what to expect*. <https://ics-cert.kaspersky.com/media/Kaspersky-ICS-CERT-ICS-cyberthreats-in-2023-what-to-expect-En.pdf>
- Google Cloud. (2025). *Développer une culture basée sur les données*. <https://cloud.google.com/resources/building-a-data-driven-culture>
- Grand View Research. (2022). *Predictive Maintenance Market Size | Industry Report, 2030*. <https://www.grandviewresearch.com/industry-analysis/predictive-maintenance-market>
- Hatipoğlu, A., Güneri, Y., & Yılmaz, E. (2023). Makine ve derin öğrenme temelli karşılaştırmalı bir öngörücü bakım uygulaması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(2), Article 2. <https://doi.org/10.17341/gazimmfd.1221105>
- Hector, J., & Panjanathan. (2024). *The role of predictive maintenance in sustainable industrial strategies*. <https://peerj.com/articles/cs-2016.pdf>
- Hemmerich, W. A. (n.d.). *Querschnittsstudie* | StatistikGuru.de. Retrieved 3 March 2025, from <https://statistikguru.de/lexikon/querschnittsstudie.html>
- Horn, M. (2024, May 21). *How Generative AI is Transforming Predictive Maintenance in the Energy Sector*. InnovateEnergy. <https://innovateenergynow.com/resources/how-generative-ai-is-transforming-predictive-maintenance-in-the-energy-sector>



<https://www.marketresearchfuture.com>, M. R. F. (2022). *Predictive Maintenance Market Size & Share Report, 2030*. <https://www.marketresearchfuture.com/reports/predictive-maintenance-market-2377>

<https://www.polarismarketresearch.com>, P. M. R. (2024). *Predictive Maintenance Market Share, Size, Trends, Industry Analysis Report, 2024—2032*. Polaris. <https://www.polarismarketresearch.com/industry-analysis/predictive-maintenance-market>

hubspot. (2023, October 11). *Taux de réponse à un questionnaire: Comment le calculer et l'améliorer*. <https://blog.hubspot.fr/service/taux-de-reponse>

Hunkar Toyoglu, Andy Lin, John Knapp, Jonathan Van Wyck, Selena Rose, and Arthur Pentecoste. (2023, September). *Predictive Maintenance in Manufacturing* | BCG. <https://www.bcg.com/publications/2023/predictive-maintenance-in-manufacturing>

IBM Business operations. (2023, May 9). *What is Predictive Maintenance?* | IBM. <https://www.ibm.com/topics/predictive-maintenance>

I-care. (2025). *Changing the Way the World Performs*. I-care. <https://www.icareweb.com/fr/>

Infraspeak. (2023, December 18). *Manufacturing & Industrial maintenance trends [2022-2030]* • Infraspeak Blog. *Infraspeak Blog*. <https://blog.infraspeak.com/manufacturing-industrial-maintenance-trends-decade/>

IoT Analytics. (2017, March 21). *New Report Indicates US\$11 Billion Predictive Maintenance Market By 2022, Driven By IoT Technology And New Services*. IoT Analytics. <https://iot-analytics.com/report-us11-billion-predictive-maintenance-market-by-2022/>

Jean-Philippe Richard-Charman. (2023, March). *Equipment-as-a-Service, a sustainable business model*. Software AG. http://www.softwareag.com/en_corporate/blog/iot-equipment-as-a-service.html

Johnson, E. (2023, August). *Predictive Maintenance: Resistance to Scalability* | Siemens Blog | Siemens. <https://blog.siemens.com/2023/08/predictive-maintenance-resistance-to-scalability/>



Knud Lasse Lueth. (2017, April 6). *The Top 20 Companies Enabling Predictive Maintenance*. IoT Analytics. <https://iot-analytics.com/top-20-companies-enabling-predictive-maintenance/>

Knud Lasse Lueth. (2019, October 8). *Predictive Maintenance Companies Landscape 2019*. IoT Analytics. <https://iot-analytics.com/predictive-maintenance-companies-landscape-2019/>

Le Sphinx. (2024, February). *Qualité des réponses: Comment les évaluer et les améliorer ? Le Sphinx*. <https://www.lesphinx-developpement.fr/blog/les-indicateurs-de-qualite-des-reponses-et-comment-les-optimiser/>

Logan Cummins. (2024, January). *Explainable Predictive Maintenance: A Survey of Current Methods, Challenges and Opportunities*. Ar5iv. <https://ar5iv.labs.arxiv.org/html/2401.07871>

machinemetrics. (n.d.). *Predictive Maintenance Manufacturing | MachineMetrics*. Retrieved 18 February 2025, from <https://www.machinemetrics.com/predictive-maintenance>

Marcus Law. (2023, May). *The Top 10 predictive maintenance companies using AI | AI Magazine*. <https://aimagazine.com/top10/the-top-10-predictive-maintenance-companies-using-ai>

Neural concept. (n.d.). *How AI Is Used in Predictive Maintenance | Neural Concept*. Retrieved 17 February 2025, from <https://www.neuralconcept.com/post/how-ai-is-used-in-predictive-maintenance>

Pay per Part | TRUMPF. (n.d.). Retrieved 26 February 2025, from https://www.trumpf.com/de_AT/produkte/services/services-maschinen-systeme-und-laser/pay-per-part/

PdM Specialists. (n.d.). *About. PdM Specialists*. Retrieved 25 February 2025, from <https://pdmspecialists.com/company/>

persistencemarketresearch. (2025, January). *Predictive Maintenance Market Size & Forecast, 2032*. Persistence Market Research. <https://www.persistencemarketresearch.com/market-research/predictive-maintenance-market.asp>

pleasedontcode. (2024, November). *Please Don't Code Blog—Understanding the Role of Sensors in Predictive Maintenance*. <https://www.pleasedontcode.com/blog/understanding-the-role-of-sensors-in-predictive-maintenance>



- Predictive Maintenance: Definition, Benefits, and Implementation*. (2024, December 27). ProCom Automation. <https://procom-automation.com/en/news/predictive-maintenance>
- Predictive Maintenance Market*. (n.d.). Market.Us. Retrieved 12 February 2025, from <https://market.us/report/predictive-maintenance-market/>
- Predictive Maintenance Market Share, Global Industry Size Forecast*. (2024). MarketsandMarkets. <https://www.marketsandmarkets.com/Market-Reports/operational-predictive-maintenance-market-8656856.html>
- Predictive Maintenance Market Size, Share, Report 2025-33*. (2024). <https://www.imarcgroup.com/predictive-maintenance-market>
- Research, S. (2024, October). *Predictive Maintenance Market Trends 2024 | Growth Insights, Forecasts, and Key Players*. <https://straitsresearch.com/report/predictive-maintenance-market>
- Reuters. (2024a, October 21). *Honeywell partners with Google to integrate data with generative AI*. <https://www.reuters.com/technology/artificial-intelligence/honeywell-partners-with-google-integrate-data-with-generative-ai-2024-10-21/>
- Reuters. (2024b, December 4). *Google Cloud partners with Air France-KLM on AI technology*. <https://www.reuters.com/technology/artificial-intelligence/google-cloud-partners-with-air-france-klm-ai-technology-2024-12-04/>
- Riccio, C., & Menanno, M. (2024, July). *A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters*. <https://www.mdpi.com/2075-1702/12/7/443>
- Riccio, C., Menanno, M., Zennaro, I., & Savino, M. M. (2024). A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters. *Machines*, 12(7), Article 7. <https://doi.org/10.3390/machines12070443>
- Ripon, A. H. M., Ullah, M. A., Paul, A. K., & Morshed, M. M. (2024). *Design & Implementation of Automatic Machine Condition Monitoring and Maintenance System in Limited Resource Situations* (No. arXiv:2401.15088). arXiv. <https://doi.org/10.48550/arXiv.2401.15088>



- Root, A. (2023, September). *GE Partners With Microsoft to Bring New AI Tools to Its Workforce*. Barrons. <https://www.barrons.com/articles/ge-stock-price-microsoft-ai-partnership-a9aef4dd>
- SAE Media. (2024, May 1). *Understanding the Limits of Artificial Intelligence for Predictive Maintenance*. <https://www.mobilityengineeringtech.com/component/content/article/50601-understanding-the-limits-of-artificial-intelligence-for-predictive-maintenance>
- Samana, S. (2023, December 8). *Improving Predictive Maintenance with Generative AI*. Pecan AI. <https://www.pecan.ai/blog/improving-predictive-maintenance-generative-ai/>
- Scaife, A. D. (2024). Improve predictive maintenance through the application of artificial intelligence: A systematic review. *Results in Engineering*, 21, 101645. <https://doi.org/10.1016/j.rineng.2023.101645>
- Seiichi Nakajima. (2023, May 27). *Seiichi Nakajima—Introduction to TPM (Total Productive Maintenance)-Productivity Press (1988).pdf*. SlideShare. <https://www.slideshare.net/slideshow/seiichi-nakajima-introduction-to-tpm-total-productive-maintenanceproductivity-press-1988pdf/258061951>
- Siemens. (2023). *Readiness for predictive maintenance at scale report 2023*. <https://assets.new.siemens.com/siemens>
- Siemens. (2025). *AI for Everyone capability included free in IoT*. Siemens Digital Industries Software. <https://resources.sw.siemens.com/en-US/article-insight-hubs-iot-includes-ai-for-everyone/>
- Silva, C. N. (2008). Review: Catherine Marshall & Gretchen B. Rossman (2006). Designing Qualitative Research. *Forum Qualitative Sozialforschung / Forum: Qualitative Social Research*, 9(3), Article 3. <https://doi.org/10.17169/fqs-9.3.996>
- SME - VET Connection. (n.d.). *LCAMP*. Retrieved 6 February 2025, from <https://lcamp.eu/activity/sme-vet-connection/>



- SSON Editor, Barbara Hodge. (2019, June). *The 4 Drivers of Digital Transformation*.
<https://www.ssonetwork.com/continuous-improvement-process-improvement/articles/the-4-drivers-of-digital-transformation>
- Staufen AG. (2020, September 24). *The underestimated optimization potential: Planned machine maintenance and repair in the food and beverage industry*. Staufen.
<https://en.staufen.ag/the-underestimated-optimization-potential-planned-machine-maintenance-and-repair-in-the-food-and-beverage-industry/>
- Takyar, A. (2023, December 4). *AI in predictive maintenance: Use cases, technologies, benefits, solution and implementation*. LeewayHertz - AI Development Company.
<https://www.leewayhertz.com/ai-in-predictive-maintenance/>
- Thomaz Cortes, Guillaume Decaix, Thomas Hansmann, Khoon Tee Tan, and Yi Zhou. (2021, July). *Prediction at scale: How industry can get more value out of maintenance* | McKinsey.
<https://www.mckinsey.com/capabilities/operations/our-insights/prediction-at-scale-how-industry-can-get-more-value-out-of-maintenance>
- TWI. (n.d.). *What is the Difference Between Corrective, Preventive and Predictive Maintenance Approaches?* Retrieved 10 February 2025, from <https://www.twi-global.com/technical-knowledge/faqs/what-is-the-difference-between-corrective-preventive-and-predictive-maintenance.aspx>
- United Nations Educational, Scientific and Cultural Organization & UNESCO-UNEVOC International Centre for Technical and Vocational Education and Training. (2021). *Understanding the impact of artificial intelligence on skills development*.
https://unevoc.unesco.org/pub/understanding_the_impact_of_ai_on_skills_development.pdf
- Yaroslav Mota. (2024, November). *AI in predictive maintenance: Transforming asset management and reducing downtime*. Software Development Company - N-iX. <https://www.n-ix.com/ai-in-predictive-maintenance/>



Zhao, Y., Yang, J., Wang, W., Yang, H., & Niyato, D. (2024). *TranDRL: A Transformer-Driven Deep Reinforcement Learning Enabled Prescriptive Maintenance Framework* (No. arXiv:2309.16935). arXiv. <https://doi.org/10.48550/arXiv.2309.16935>

吳麗珍, 黃惠滿, & 李浩銑. (2014). 方便取樣和立意取樣之比較. *護理雜誌*, 61(3), 105–111. <https://doi.org/10.6224/JN.61.3.105>



10. KAZALO SLIK

Slika 1. Metodologija observatorija LCAMP	10
Slika 2. Metodologija, uporabljena za polje opazovanja	14
Slika 3. Načrti vzdrževanja RM, PM in PdM Slika 4. Primerjava RM, PM in PdM glede stroškov in pogostosti vzdrževalnih del	21
Slika 5. Napoved razvoja svetovnega trga PdM do leta 2022	23
Slika 6. Napoved razvoja svetovnega trga PdM do leta 2033	24
Slika 7. Globalni tržni delež PdM glede na analizo končne uporabe, 2024	26
Slika 8. Štirje temeljni kamni digitalizacije - Roland Berger	32
Slika 9. Sistemska arhitektura za intelligent in PdM 4.0.	33
Slika 10. Izzivi pri tradicionalnih metodah prediktivnega vzdrževanja	35
Slika 11. Primeri uporabe umetne inteligence pri predvidenem vzdrževanju	36
Slika 12. Sistem predvidenega vzdrževanja, imena metod in arhitektur	37
Slika 13. Prednosti predvidenega vzdrževanja, ki ga poganja AI	38
Slika 14. 3 različne vrste predvidenega vzdrževanja	40
Slika 15. Zaslon za preverjanje kakovosti Workbench-a, ki prikazuje podatkovne točke skozi čas za pomoč operaterjem pri prepoznavanju vzorcev (Vir: Falconry)	40
Slika 16. Nadzorna plošča stanja SAS Asset Performance Analytics, ki prikazuje podatke o neobičajnih dogodkih izbranih sredstev (Vir: SAS Institute)	41
Slika 17. SKF ponuja portal za razvijalce API-jev za pomoč razvijalcem pri integracijah tretjih oseb, s prikazanimi primeri integracij (Vir: SKF)	41
Slika 18. Vmesnik Marathon Investigations ponuja predpisana dejanja za obravnavo morebitne težave (Vir: Arundo)	42
Slika 19. Primerjava stroškov med zbiranjem podatkov in uporabo modela	49
Slika 20. Primerjava FPY med fazo, kot je, in uporabo modela.	49
Slika 21. Primerjava MTBM med zbiranjem podatkov in uporabo modela.	50
Slika 22. Porazdelitev velikosti MSP, ki so se odzvala	61
Slika 24. Velikost organizacij po državah	61
Slika 25. Velikost organizacij, ki so odgovorile glede na sektor primarne industrije	62
Slika 26. Vloge v podjetju	62
Slika 27. Trenutno izvajanje postopek vzdrževanja	63
Slika 28. Kako pripravljena so podjetja na sprejemanje nastajajočih trendov PdM Digital in Green Transition?	64
Slika 29. Katere so glavne ovire, s katerimi se srečuje vaša organizacija pri sprejemanju tehnologij PdM?	64
Slika 30. Na katere podatkovne izzive naletite pri PdM?	65
Slika 31. Kako pomembno je sprejeti tehnologije za napovedovanje in nove digitalne trende, kot sta IoT in AI, za izboljšanje praks vzdrževanja?	65
Slika 32. Ali MSP menijo, da je PdM bistvenega pomena za ohranjanje konkurenčnosti v njihovi panogi?	66
Slika 33. Kako je PdM vplival na tržno strategijo ali konkurenčni položaj vaše organizacije?	66



Slika 34. Kako vaša organizacija obravnava stroškovne izzive, povezane s sprejetjem PdM?	67
Slika 35. Kako predvidevate, da bo PdM vplival na delovne vloge v vaši organizaciji?	67
Slika 36. Kako pripravljena je vaša organizacija za upravljanje sprememb delovnega mesta, povezanih s sprejetjem PdM?	68
Slika 37. Kako se vaša organizacija pripravlja na pričakovano rast tehnologij PdM?	68
Slika 38. Na katerih področjih zaposleni v vaši organizaciji potrebujejo dodatno izobraževalno podporo za učinkovito uporabo digitalnih in zelenih tehnologij v PdM?	70
Slika 39. Koliko vas zanimajo novi trendi digitalnega in zelenega prehoda, povezani z usposabljanjem PdM?	71
Slika 40. Kako vaša organizacija raje dostopa do usposabljanja?	72
Slika 41. Kateri so prednostni formati za usposabljanje PdM?	72
Slika 42. Katere vrste usposabljanja bi najbolj podprle vašo delovno silo za PdM?	72
Slika 43. Stopnišče kvalifikacije vzdrževanja	75
Slika 44. Velikost organizacij po državah	80
Slika 45. Katero je glavno področje strokovnega usposabljanja, ki ga izvaja vaš center?	80
Slika 46. Kakšna je vaša vloga v instituciji?	81
Slika 47. Koliko študentov vsako leto diplomira?	81
Slika 48. Kakšna je zmogljivost vaše ustanove za prilagajanje vsebine svojih tečajev usposabljanja razvoju, povezanemu s trendi, kot so internet stvari, umetna inteligenca, kibernetika varnost in trajnost v vzdrževalnih poklicih?	82
Slika 49. Ali se izvajajo koraki za razvoj vsebine v skladu s trendi, navedenimi v vzdrževalnih poklicih? ...	84
Slika 50. Kakšne priložnosti ali možnosti bi lahko predvidela vaša ustanova ali jih je že predvidela za vključitev industrijskih potreb v realnem času, kot so tiste, povezane s predvidenim vzdrževanjem, v programe usposabljanja, kjer je to mogoče?	85
Slika 51. Katere pristope podpira vaša ustanova za krepitev praktične uporabe konceptov prediktivnega vzdrževanja (PdM) v programih usposabljanja za vzdrževanje?	85
Slika 52. Kakšne finančne rešitve so predvidene za razvoj dostopa do najnovejših tehnoloških dosežkov v programih usposabljanja za vzdrževanje?	86
Slika 53. Katere strategije obstajajo ali so potrebne za usposabljanje vodij usposabljanja in učiteljev za napredne tehnologije?	87
Slika 54. Katere strategije sodelovanja so bile vzpostavljene ali predvidene z drugimi centri za usposabljanje in drugimi organizacijami za spodbujanje skladnosti tečajev usposabljanja za vzdrževanje?	87
Slika 55. Kako predvidevate razvoj medsebojno odvisnih izobraževalnih poti s sodelovanjem med ustanovami z različnimi področji zanimanja za usposabljanje vzdrževanja?	88
Slika 56. Kako je mogoče okrepiti sodelovanje s strokovnjaki v panogi za boljšo uskladitev učne vsebine s sedanjimi in prihodnjimi potrebami v prediktivnem vzdrževanju (PdM) in sorodnih področjih?	88
Slika 57. Sinteza rezultatov - (Hector, J. in Panjanathan, 2024) .	93



11. KAZALO TABEL

<i>Tabela 1. Primer seznama poklicev ESCO, vključenih v vzdrževalne dejavnosti (poklici, nd).</i>	11
<i>Tabela 2. Zaposljivost za vzdrževanje</i>	11
<i>Tabela 3. Primeri usposabljanja za vzdrževanje (izvleček vseh podrobnosti je na voljo v Prilogi 4)</i>	12
<i>Tabela 4. Posvetovane organizacije</i>	16
<i>Tabela 5. Koristi, izzivi in aplikacije RM, PM in PdM – Viri (A Survey of Predictive Maintenance: Systems, Purposes and Approaches, nd)</i>	22
<i>Tabela 6. Izzivi pri tradicionalnih metodah prediktivnega vzdrževanja</i>	35
<i>Tabela 7. Povzetek povprečnih rezultatov vrednotenja validacijskih/testnih podskupin</i>	51
<i>Tabela 8. Porazdelitev odgovorov v anketi MSP po državah</i>	60
<i>Tabela 9. Kvalifikacije za inženirje vzdrževanja in nadzornike (raven 6 EQF)</i>	75
<i>Tabela 10. Porazdelitev odgovorov ankete centra za poklicno izobraževanje in usposabljanje po državah</i>	80
<i>Tabela 11. Tečaji, ki se izvajajo na področju nastajajočih tehnologij 4.0 (IoT, AI, Cyber, Sustainability, Cloud)</i>	83



12. PRILOGA

12.1. PRILOGA 1 - CILJNA PUBLIKA ANKET

COUNTRY	TARGET AUDIENCE	Distribution list
FR	EXPERT	3DS
		Adocc
		Aerospace valley
		AFDET
		Afnor
		CETIM
		Efficairn
		Ministère éducation
	SMEs	ACTEMIUM
		AD INDUSTRIE
		FIGEAC AERO
		FIVES MACHNING
		FIVES MAINTENANCE
		IUT Rodez
		LISI BLANC AERO
		MECABRIVE
		MET ENERGIE
		RATIER FIGEAC
		ROBERT BOSCH
		UMICORE VM ZINC
		VPM AUTOMATION
	VET	ALEXIS MONTEIL
		ANTOINE BOURDELLE
		DEODAT DE SEVERAC
		GASTON MONNERVILLE
		INEMA
		INU Champollion
		IUMM
		IUT Figeac
		IUT Limousin
		IUT Rodez
GER	SMEs	ASYS Group
		BoschRexroth
		Braun Steine
		Büchel Luftreinhaltung und Anlagenbau
		BWF Profiles
		Carl Zeiss AG



		DAIMLER TRUCK
		Gebr. Binder
		Grünbeck Wasseraufbereitung GmbH
		GUTMANN-GROUP
		HAUFF Technik
		Heidelberg Manufacturing Deutschland
		Hillenbrand
		IHK Ostwürttemberg
		INDEX Werke
		Inneo
		Klueber
		KÖHN
		LEITZ
		LIEBHERR
		MAN
		MAPAL
		MEFFLE
		MegMee
		Mitsubishi Electric Europe B. V.
		N. N.
		NAGEL Spanntechnik
		Pfeifer Metalltechnik
		robatherm GmbH & Co. KG
		ROBERT BOSCH
		Rosenberger
		RR-RIEGER
		Schaerer AG
		Schellenberg
		Schuck Group GmbH
		SIAL
		Siemens AG
		Sortimo International GmbH
		Stark Gummiwalzen GmbH
		TE Connectivity
		TUH GmbH
		WEISSER SPK
		WESSER SPK
		WIELAND Werke
		Yanmar
	VET	Carl-Benz-Schule Karlsruhe
		Claude-Dornier FN
		GARP
		Gewerbliche Schule Geislingen
		Gewerbliche Schule Gmünd
		Gewerbliche Schule Göppingen
		Heid-Tech Heidenheim



		Robert-Bosch-Schule-Ulm
		Rolf-Benz-Schule
		Technische Schule Aalen
SI	SMEs	Danfoss Trata
		FANUC
		Grammer Automotive Slovenija
		GZS
		Hisense Gorenje
		Kopa d.d.
		LTH Castings
		MIC Škofja Loka
		MIEL
		Robeta
		TGK
	VET	Academia
		B&B
		Erudio
		IC Geoss
		ŠC Celje
		ŠC Kranj
		ŠC Ljubljana
		ŠC Nova Gorica
		ŠC Novo mesto
		ŠC Postojna
		ŠC Ptuj
		ŠC Ravne
		ŠC Škofja Loka
		ŠC Velenje
		TŠC Maribor
SWE	SMEs	ACFloby
		Alleima
		Elektroautomatik
		FPanalyzer
		Hifa
	VET	Alströmergymnasiet
		Dacapo gymnasiet
		Edumate
		Mark Gymnasieskola
		Nösnäsgymnasiet
		Uddevalla Gymnasieskola
		Volvogymnasiet



12.2. PRILOGA 2 – OBSEG NAPOVEDI RAZVOJA SVETOVNEGA TRGA PDM

Kategorija	Podkategorija	Podrobnosti
Z aplikacijo	Sledenje sredstvi	(video)
	Spremljanje stanja	
	Načrtovanje vzdrževanja	(video)
	Prediktivna analitika	
	Oddaljeno spremljanje	(video)
Po komponentah	Strojna oprema	
	Programska oprema	Integrirano
		Samostojna
Z namestitvijo	V oblaku	(video)
	Lokalno	
Po končni uporabi	Energetika in komunalne storitve	(video)
	Zdravstveno varstvo	
	IT in Telekom	(video)
	Logistika in transport	
	Proizvodnja	(video)
	in obramba	
	Drugo (kemikalije, papir in tiskarstvo ter kmetijstvo itd.)	(video)
Po vrsti podjetja	Velika podjetja	
	Mala in srednje velika podjetja (MSP)	(video)
Po regiji	Azija Pacifik	ASEAN
		Kitajska
		Indija
		Japonska
		Oceanija
		Preostali del Azije in Pacifika
		Južna Koreja
	Evropi	Beneluks
		Francija
		Nemčija
		Italija
		Nordijci
		Ostala Evropa
		Rusija
		Španija
		Združeno kraljestvo
	Bližnji vzhod & Afrika	GCC
		Izrael



		Severna Afrika
		Preostali del Bližnjega vzhoda in Afrike
		Južna Afrika
		Turčija
	Severna Amerika	Kanada
		Mehika
		ZDA
	Južna Amerika	Argentina
		Brazilija
		Preostali del Južne Amerike
Po tehnologiji	Napredna analitika	
	Umetna inteligenca in strojno učenje	(video)
	Digitalni dvojček	
	IoT	(video)
	Drugo (Modern Database, ERP itd.)	




12.3. PRILOGA 3 - 21 METOD

RAZLAGALNEGA STROJNEGA UČENJA (IML).

(Logan Cummins, 2024)

1. **Mehanizmi pozornosti:** Uporablja se v nevronske mrežah za osredotočanje na pomembne dele vhodnih podatkov, izboljšanje razlage s poudarjanjem ustreznih funkcij za napovedi.
2. **Sistemi, ki temeljijo na mehkih sistemih:** uporabite mehko logiko za obvladovanje negotovosti in nenatančnosti, ki zagotavlja interpretacije rezultatov modela, ki temeljijo na pravilih.
3. **Sistemi, ki temeljijo na znanju:** Uporabite že obstoječe znanje o domeni v napovednih modelih za izboljšanje interpretabilnosti, pogosto s simbolno predstavitvijo.
4. **Interpretabilni filtri:** uvedite filtre znotraj nevronske mreže, ki imajo fizično pomembne predstavitve in pomagajo razložiti fokus modela.
5. **Odločitvena drevesa:** Klasična metoda, ki razdeli podatke v vozlišča na podlagi vrednosti funkcij, zaradi česar je enostavno slediti sprejemanju odločitev.
6. **Drevesa napak:** Vizualne predstavitve poti napak v sistemih, ki prikazujejo, kako lahko različne napake povzročijo okvare sistema.
7. **Fizične omejitve:** integrirajte omejitve iz resničnega sveta v modele, da zagotovite, da so napovedi razložljive in upoštevajo znane fizikalne zakone.
8. **Statistične metode:** Uporabite statistično analizo, da ugotovite pomembnost lastnosti, s čimer povečate preglednost pri odločanju.
9. **Graph Attention Networks (GAT):** Razširite mehanizme pozornosti na grafično strukturirane podatke, kar omogoča interpretacijo odnosov znotraj omrežij.
10. **Gaussovi mešani modeli (GMM):** verjetnostni modeli, ki identificirajo skupine znotraj podatkov, pri čemer vsaka skupina zagotavlja razložljive vzorce vedenja.
11. **Explainable Boosting Machine (EBM):** Model, ki uporablja generalizirane aditivne modele (GAM), ki združuje tehnike pospeševanja z interpretabilnostjo.
12. **Skriti Markovljevi modeli (HMM):** Uporabljajo se za zaporedne podatke, kjer so stanja razložljive stopnje poslabšanja v kontekstu vzdrževanja.
13. **Redka omrežja:** Zmanjšajte število parametrov v modelu, tako da bo bolj razumljiv, tako da se osredotočite na najvplivnejše funkcije.
14. **Učenje prototipov:** uporablja reprezentativne primere (prototipe) iz nabora podatkov za razlago napovedi, ki ponuja jasno povezavo med vhom in izhodom.
15. **Signalna časovna logika (STL):** Metoda za definiranje časovno omejenih pravil v podatkih, ki se pogosto uporablja za spremljanje časovnega vedenja pri predvidenem vzdrževanju.
16. **Digitalni dvojčki:** Virtualni modeli fizičnih sredstev, ki omogočajo interpretacijo s simulacijo različnih scenarijev okvar.
17. **Simbolni modeli življenja:** Uporabite simbolične predstavitve za modeliranje stopenj v življenju sistema, kar pomaga pri razumevanju časovnih okvirov napak.
18. **Splošni aditivni modeli (GAM):** modeli, ki aditivno združujejo značilnosti in zagotavljajo jasno razlago z izolacijo učinka vsake funkcije.
19. **Mahalanobis -Taguchi (MTS):** uporablja statistične razdalje za razvrščanje podatkovnih točk in ponuja razložljiv vpogled v to, kako funkcije odstopajo od običajnega delovanja.
20. **k-Najbližji sosedje (kNN):** Klasificira primere na podlagi podobnosti s sosednjimi podatkovnimi točkami, kjer je mogoče odločitve izslediti do določenih sosedov.
21. **Interpretacije, ki temeljijo na pravilih:** Zagotovite razlage v obliki "če-potem", zaradi česar so odločitve lahko razumljive z razdelitvijo napovedi na nize pravil.





PRILOGA 4 – PRIMERI TEČAJEV USPOSABLJANJA ZA VZDRŽEVANJE

Država	Vir	Opis tečaja usposabljanja	Raven EQF
Francija	IUT Rodez https://www.iut-rodez.fr/fr/les-formation/lp-mif-maintenance-40/lp-maintenance-industrie-futur-presentation	Strokovna diploma Vzdrževanje za industrijo prihodnosti (Industrija 4.0): Cilj je usposobiti zaposlene, sposobne izvajati povezane vzdrževalne projekte znotraj industrijskih podjetij, z izbiro, namestitvijo in konfiguracijo potrebne opreme in programske opreme.	EQF 6
	INU Champollion https://www.univ-jfc.fr/licences-professionnelles/maintenance-et-technologie-organisation-de-la-maintenance	Strokovna diploma iz vzdrževanja in tehnologije: Cilj je usposobiti bodoče menedžerje, odgovorne za tehnični sektor in nadzor storitev, povezanih z vzdrževanjem opreme ali vozil na področju kmetijske opreme, strojev za javna dela, opreme za manipulacijo in industrijskih vozil.	EQF 6
	Licej Gaston Monnerville https://gaston-monnerville.mon-ent-occitanie.fr/actualites/orientation/je-suis-en-classe-de-3eme/le-bac-professionnel-maintenance-des-systemes-de-production-connectes-au-lycee-gaston-monnerville-37625.htm?URL_BLOG_FILTRE=%3FDATE%3DTOUS%235332	Poklicna matura Vzdrževanje povezanih proizvodnih sistemov: študente pripravi na zagotavljanje preventivnega, izboljšavnega in korektivnega vzdrževanja (vzdrževanje in popravilo) vse avtomatizirane opreme, ki se uporablja v proizvodnji, rokovanju, distribuciji in pakiranju. Dejavnosti vključujejo odpravljanje težav na industrijski opremi ter testiranje električnih, pnevmatskih, hidravličnih in mehanskih energetskih sistemov. Razvite veščine vključujejo popravilo industrijskega sistema z zamenjavo (standardna zamenjava) mehanskih, električnih, pnevmatskih ali hidravličnih komponent. Usposabljanje vključuje tudi sodelovanje pri testiranju in zagonu nove opreme ter spremljanje opreme z ustreznimi meritvami za zagotavljanje pravilnega delovanja.	EQF 4
	Lycée Alexis Monteil https://alexis-monteil.mon-ent-occitanie.fr/informations-pratiques/enseignements/lycee-professionnel/bac-pro-maintenance-des-systemes-de-production-connectes-14362.htm	Poklicna diploma iz vzdrževanja povezanih proizvodnih sistemov: Naloge vključujejo izvajanje preventivnih vzdrževalnih operacij, kot so menjave komponent, prilagoditve, mazanje in preverjanje ravni, tlaka in zračnosti delov. Vključuje tudi ožičenje in spreminjanje električnih, pnevmatskih in hidravličnih tokokrogov, izbiro komponent in njihovo povezovanje. Vloga zahteva dekodiranje in analizo električnih, pnevmatskih in hidravličnih diagramov, prepoznavanje komponent in njihovih funkcij. Poleg tega vključuje izdelavo varjenih mehanskih delov, razstavljanje in popravilo mehanskih podslopov, analizo mehanskih gibov, diagnosticiranje napak s preskusi in meritvami, namestitvev in zagon sistemov ter izvajanje varnostnih ukrepov.	EQF 4



	Cité scolaire Jean Jaurès https://jaures-saint-affrique.mon-ent-occitanie.fr/parents-et-eleves/les-formations/lycee-professionnel/	Poklicna diploma iz vzdrževanja povezanih proizvodnih sistemov: delo bo popravljalo, popravljalo, diagnosticiralo, nameščalo in prilagajalo opremo. Traja 3 leta, s praktičnim poukom. Vključuje 22 tednov praktičnega usposabljanja v različnih sektorjih, kot so vetrna energija, agroživilstvo in drugo. To delo je nagrajujoče in ponuja veliko zaposlitvenih možnosti, zlasti pri vzdrževanju vetrne energije. Študij lahko nadaljujete tudi z visokošolsko državno diplomom. Po končanem usposabljanju lahko diplomanti delajo v različnih panogah, kot so agroživilska, farmacevtska, avtomobilska, kmetijska, tekstilna, kemična, aeronavtika in proizvodnja vetrne energije. Delajo lahko tudi v javnih službah, kot so bolnišnice, vojska, občine, čiščenje vode, SNCF itd.	EQF 4
	Lycée Déodat de Séverac https://maforpro-occitanie.fr/nos-formations/bts-maintenance-des-systemes-option-systemes-de-production-1490	Višja nacionalna diploma o vzdrževanju sistemov, možnost proizvodnega sistema: višji tehnik mora biti v vzdrževalnem oddelku proizvodne enote ali podjetja za tehnične storitve/poprodajnega servisa sposoben izvajati korektivne in preventivne vzdrževalne posege, izboljšati varnost delovanja in integrirati nove sisteme.	EQF 5
	Lycée Gaston Monnerville https://maforpro-occitanie.fr/nos-formations/bts-maintenance-des-systemes-option-systemes-de-production-1490	Višja nacionalna diploma o vzdrževanju sistemov, možnost proizvodnega sistema: višji tehnik mora biti v vzdrževalnem oddelku proizvodne enote ali podjetja za tehnične storitve/poprodajnega servisa sposoben izvajati korektivne in preventivne vzdrževalne posege, izboljšati varnost delovanja in integrirati nove sisteme.	EQF 5
	Lycée Alexis Monteil https://maforpro-occitanie.fr/nos-formations/bts-maintenance-des-systemes-option-systemes-de-production-1490	Višja nacionalna diploma o vzdrževanju sistemov, možnost proizvodnega sistema: višji tehnik mora biti v vzdrževalnem oddelku proizvodne enote ali podjetja za tehnične storitve/poprodajnega servisa sposoben izvajati korektivne in preventivne vzdrževalne posege, izboljšati varnost delovanja in integrirati nove sisteme.	EQF 5
	UIMM / CFAI-AFPI: https://www.pole-formation-lda.fr/formation/bts-ms-maintenance-des-systemes-option-systeme-de-production/	Višja nacionalna diploma iz vzdrževanja sistemov, možnost proizvodnega sistema: usposablja strokovnjake za vzdrževanje in študentom nudi tehnološke, organizacijske in medosebne veščine. Opcija Proizvodni sistemi omogoča študentom, da obvladajo delovanje proizvodnih sistemov, da lahko učinkovito komunicirajo z operaterji in/ali odločevalci.	EQF 5
Nemčija	bbw-seminar	Predvideno vzdrževanje v usposabljanju: Predstavite osnove predvidenega vzdrževanja, primerjajte vrste vzdrževanja in poudarite prednosti. Zajema spremljanje stanja pokrova, senzorsko tehnologijo, digitalno integracijo, načrtovanje dinamičnega vzdrževanja in izvedbene strategije.	EQF 4



	Vdi-wissensforum	Seminarji "Condition-/ Prozessmonitoring & Predictive Maintenance" Spremljanje stanja in spremljanje procesov: zajema osnove predvidenega vzdrževanja, spremljanje procesov in pogojev ter ključne dejavnike vpliva. Predstavlja pridobivanje signalov prek senzorjev in kontrolnih podatkov, metode spremljanja stanja in ustrezne standarde. Raziskuje izzive spremljanja procesov, infrastrukturo za analizo velikih podatkov in napredne tehnike vrednotenja.	EQF 6
Slovenija	<u>Agencija POTI: agencija-poti.si</u>	Delovanje in vzdrževanje elektroinštalacij in opreme: Izvajalec: Agencija POTI Opis: Strokovno usposabljanje z usmeritvami za varno obratovanje in vzdrževanje elektroinštalacij in opreme v skladu s predpisi in standardi.	SOK/EQF 4-5
	<u>Društvo vzdrževalcev Slovenije (DVS): drustvo-dvs.si</u>	Osnove vibracijske diagnostike ter izbira, namestitvev in mazanje ležajev Izvajalec: Društvo vzdrževalcev Slovenije (DVS) Opis: Usposabljanje zajema vibracijsko diagnostiko ter izbiro, namestitvev in mazanje kotalnih ležajev.	SOK/EQF 5-6
	<u>Srednješolski center Ljubljana (SIC Ljubljana): siclj.si</u>	Program usposabljanja za strojnike Izvajalec: Srednješolski center Ljubljana (SIC Ljubljana) Opis: Usposabljanje za vzdrževanje in servisiranje motornih vozil, primerno za avtomobilskega tehnika ali mehanika.	SOK/EQF 4
	<u>Obrtno-podjetniška zbornica Slovenije (OZS): ozs.si</u>	Izobraževanje in certificiranje tehnikov hladilne tehnike Izvajalec: Obrtno-podjetniška zbornica Slovenije (OZS) Opis: Usposabljanje tehnikov, ki se ukvarjajo z montažo, vzdrževanjem in servisiranjem hladilne tehnike ter ravnanjem s hladilnimi sredstvi.	SOK/EQF 4–5
	<u>Izobraževalni center za zaščito in reševanje Republike Slovenije: gov.si</u>	Usposabljanje za vzdrževanje opreme in infrastrukture za NMP Izvajalec: Izobraževalni center za zaščito in reševanje Republike Slovenije Opis: Programi so usmerjeni v vzdrževanje opreme in infrastrukture za zaščito, reševanje in pomoč pri nesrečah.	SOK/EQF 5–6
	<u>ZVD Zavod za varstvo pri delu: zvd.si</u>	Pregled in vzdrževanje otroških igrišč in naprav Izvajalec: ZVD Zavod za varstvo pri delu Opis: Usposabljanje za varno pregledovanje in vzdrževanje otroških igrišč in otroških igral.	SOK/EQF 4–5



Italija	Formazione Michelangelo	"Specialistični tečaj za vzdrževanje" Tečaj Maintenance Specialist Course je bil ustvarjen z namenom certificiranja vzdrževalcev in zagotavljanja visokokakovostnih standardov pri upravljanju sredstev podjetja.	EQF 4-5
	Festo C. TE	"Specialistični tečaj za vzdrževanje" Avtonomnost in učinkovitost operativnega vzdrževanja za izboljšanje KPI vzdrževalnih oddelkov. Izpolnjuje obvezne zahteve glede usposabljanja za dostop do certifikata o usposobljenosti za vzdrževanje 1. stopnje	EQF 4-5





Learner Centric Advanced Manufacturing Platform



**Co-funded by
the European Union**

Funded by the European Union. Views and opinions expressed are however those of the author(s) only and do not necessarily reflect those of the European Union or the European Education and Culture Executive Agency (EACEA). Neither the European Union nor EACEA can be held responsible for them.