

Sustavi za dijagnostiku kvarova na električnim strojevima

Bosanac, Marino

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Maritime Studies, Rijeka / Sveučilište u Rijeci, Pomorski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:187:295521>

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

Download date / Datum preuzimanja: **2024-10-26**



Sveučilište u Rijeci, Pomorski fakultet
University of Rijeka, Faculty of Maritime Studies

Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Maritime Studies - FMSRI Repository](#)



**SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET**

MARINO BOSANAC

**SUSTAVI ZA DIJAGNOSTIKU KVAROVA NA
ELEKTRIČNIM STROJEVIMA**

ZAVRŠNI RAD

Rijeka, 2024.

**SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET**

**SUSTAVI ZA DIJAGNOSTIKU KVAROVA NA ELEKTRIČNIM
STROJEVIMA**

**SYSTEMS FOR FAULT DIAGNOSIS ON ELECTRICAL
MACHINES**

**ZAVRŠNI RAD
BACHELOR THESIS**

Kolegij: Brodski električni strojevi

Mentor: izv. prof. dr. sc. Aleksandar Cuculić

Student: Marino Bosanac

Studijski smjer: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0112069980

Rijeka, rujan 2024.

Student: Marino Bosanac

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0112069980

IZJAVA O SAMOSTALNOJ IZRADI ZAVRŠNOG RADA

Kojom izjavljujem da sam završni rad s naslovom SUSTAVI ZA DIJAGNOSTIKU KVAROVA NA ELEKTRIČNIM STROJEVIMA izradio samostalno pod mentorstvom izv.prof.dr.sc. Aleksandar Cuculića.

U radu sam primijenio metodologiju izrade stručnog/znanstvenog rada i koristio literaturu koja je navedena na kraju završnog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući naveo u završnom radu na uobičajen, standardan način citirao sam i povezo s fusnotama i korištenim bibliografskim jedinicama, te nijedan dio rada ne krši bilo čija autorska prava. Rad je pisan u duhu hrvatskoga jezika.

Student



Marino Bosanac

Student: Marino Bosanac

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0112069980

IZJAVA STUDENTA – AUTORA
O JAVNOJ OBJAVI OBRANJENOG ZAVRŠNOG RADA

Izjavljujem da kao student – autor završnog rada dozvoljavam Pomorskom fakultetu Sveučilišta u Rijeci da ga trajno javno objavi i besplatno učini dostupnim javnosti u cjelovitom tekstu u mrežnom digitalnom repozitoriju Pomorskog fakulteta.

U svrhu podržavanja otvorenog pristupa završnim radovima trajno objavljenim u javno dostupnom digitalnom repozitoriju Pomorskog fakulteta, ovom izjavom dajem neisključivo imovinsko pravo iskorištavanja bez sadržajnog, vremenskog i prostornog ograničenja mog završnog rada kao autorskog djela pod uvjetima *Creative Commons* licencije CC BY Imenovanje, prema opisu dostupnom na <http://creativecommons.org/licenses/>

Student - autor

Bosanac

SAŽETAK

Ovaj rad analizira različite metode i sustave za dijagnostiku kvarova na brodskim električnim strojevima, uključujući analizu struje stroja (MCSA), analizu vibracija, termografsku analizu, akustičnu emisiju i druge napredne tehnike. Detaljno su obrađeni sustavi temeljeni na umjetnoj inteligenciji, poput umjetnih neuronskih mreža, fuzzy logike i strojnog učenja, koji značajno poboljšavaju točnost i učinkovitost dijagnostike. Implementacija ovih sustava u brodske operacije pokazuje značajne prednosti u povećanju pouzdanosti i smanjenju operativnih troškova, omogućujući pravovremeno otkrivanje i otklanjanje kvarova te optimizaciju resursa za održavanje. Unatoč tehničkim izazovima i visokim početnim troškovima, dugoročne prednosti značajno nadmašuju te troškove, čineći ove sustave neophodnim alatom za suvremenu pomorsku industriju. Preporučuje se daljnji razvoj algoritama za obradu podataka i predviđanje kvarova, integracija novih tehnologija poput digitalnih blizanaca i IoT-a, te istraživanje ekonomskih aspekata kako bi se omogućila šira primjena ovih sustava. Sigurnost i privatnost podataka također su identificirane kao ključni aspekti koje je potrebno naglasiti kako bi se osigurala cjelovitost i pouzdanost dijagnostičkih sustava.

Ključne riječi: **dijagnostika kvarova, brodski električni strojevi, umjetna inteligencija, prediktivno održavanje, digitalni blizanci.**

SUMMARY

This paper analyzes various methods and systems for fault diagnosis in marine electrical machines, including Motor Current Signature Analysis (MCSA), vibration analysis, thermographic analysis, acoustic emission, and other advanced techniques. Detailed attention is given to systems based on artificial intelligence, such as artificial neural networks, fuzzy logic, and machine learning, which significantly enhance diagnostic accuracy and efficiency. The implementation of these systems in marine operations shows significant advantages in increasing reliability and reducing operational costs, enabling timely fault detection and correction, and optimizing maintenance resources. Despite technical challenges and high initial costs, the long-term benefits far outweigh these costs, making these systems essential tools for the modern maritime industry. Further development of data processing and fault prediction

algorithms, integration of new technologies like digital twins and IoT, and exploration of economic aspects are recommended to enable broader adoption of these systems. Data security and privacy are also identified as key aspects that need to be addressed to ensure the integrity and reliability of diagnostic systems.

Keywords: fault diagnosis, marine electrical machines, artificial intelligence, predictive maintenance, digital twins.

SADRŽAJ

SAŽETAK.....	I
SUMMARY	I
SADRŽAJ	III
1. UVOD	1
2. KLASIFIKACIJA KVAROVA U BRODSKIM ELEKTRIČNIM STROJEVIMA.....	2
2.1. Kvarovi ležajeva.....	3
2.2. Kvarovi na statoru ili armaturi	4
2.3. Kvarovi povezani s ekscentričnošću	8
2.4. Kvarovi sustava napajanja i elektronike i ostali mehanički i električni kvarovi specifični za brodske uvjete	11
3. TEHNIKE I METODE DIJAGNOSTIKE KVAROVA.....	13
3.1. Analiza struje stroja (MCSA).....	13
3.2. Analiza vibracija	14
3.3. Termografska analiza	16
3.4. Akustična emisija	17
3.5. Analiza parcijalnih pražnjenja	18
3.6. Spektralne analize (FFT, HOS)	19
4. PRAĆENJE STANJA STROJA I DIJAGNOSTIKA KVAROVA TEMELJENO NA UMJETNOJ INTELIGENCIJI.....	21
4.1. Umjetne neuronske mreže (ANN).....	21
4.2. Fuzzy logika	23
4.3. Neuro fuzzy sustavi.....	24
4.4. Strojno učenje (Machine Learning) i duboko učenje (Deep Learning).....	25
5. IMPLEMENTACIJA SUSTAVA ZA DIJAGNOSTIKU KVAROVA NA BRODOVIMA 28	
5.1. Hardverska arhitektura sustava za dijagnostiku	28
5.2. Softverski algoritmi za obradu podataka i donošenje odluka	29
5.3. Integracija sustava u brodske operacije i održavanje	31
6. NAPREDNE TEHNIKE I BUDUĆI TRENOVI U DIJAGNOSTICI KVAROVA NA BRODOVIMA	32
6.1. Internet stvari (IoT) i dijagnostika u stvarnom vremenu na brodovima	32
6.2. Prediktivno održavanje u pomorskoj industriji	33

6.3. Digitalni blizanci i simulacije za brodske sustave	35
6.4. Integracija s pametnim brodskim sustavima i industrijom 4.0.....	35
6.5. Tehnička ograničenja i složenost sustava u brodskom okruženju.....	36
7. ZAKLJUČAK	38
LITERATURA	40
POPIS ILUSTRACIJA.....	43

1. UVOD

Dijagnostika kvarova na brodskim električnim strojevima odnosi se na postupak identifikacije, analize i predviđanja potencijalnih kvarova kako bi se osigurala pouzdanost, sigurnost i učinkovitost brodskih operacija. S obzirom na složenost i važnost brodskih sustava, pravovremeno otkrivanje kvarova ključni je faktor za smanjenje rizika od neplaniranih zastoja, optimizaciju resursa za održavanje te produljenje vijeka trajanja opreme. Povijest dijagnostike kvarova na brodovima prati razvoj brodskih električnih sustava i tehnologija održavanja. Tradicionalni pristupi održavanja temeljili su se na preventivnim metodama i redovitim inspekcijama, dok je razvoj novih tehnologija, poput Interneta stvari (IoT), umjetne inteligencije (AI) i digitalnih blizanaca, omogućio uvođenje naprednih dijagnostičkih sustava koji pružaju preciznije i pravovremene informacije o stanju opreme. Cilj ovog rada je istražiti i analizirati različite metode i sustave za dijagnostiku kvarova na brodskim električnim strojevima, te prikazati kako integracija naprednih tehnologija može unaprijediti održavanje i operativnu učinkovitost brodova. Rad će obuhvatiti klasifikaciju kvarova, tehnike dijagnostike, sustave temeljene na umjetnoj inteligenciji, implementaciju dijagnostičkih sustava, napredne tehnike i izazove s kojima se suočava primjena ovih sustava u pomorskoj industriji.


2. KLASIFIKACIJA KVAROVA U BRODSKIM ELEKTRIČNIM STROJEVIMA

Povijest dijagnostike i zaštite od kvarova u električnim strojevima seže do samih početaka upotrebe strojeva. U početku, proizvođači i korisnici strojeva oslanjali su se na osnovne mjere zaštite kao što su zaštita od prekomjerne struje i previsokog napona kako bi osigurali siguran rad. Međutim, s razvojem složenijih strojeva i povećanjem ovisnosti industrije o pouzdanosti ovih sistema, evoluirala je i tehnologija dijagnostike kvarova. Danas, rana dijagnoza kvarova postala je ključna za sprječavanje velikih zastoja i financijskih gubitaka [7].

Glavni kvarovi na električnim strojevima mogu se kategorizirati u nekoliko osnovnih grupa:

1. Kvarovi statora uključujući otvaranje ili kratki spoj namotaja.
2. Problemi s rotorom poput slomljenih šipki ili pukotina na prstenima.
3. Mehanički kvarovi kao što su kvarovi ležajeva i mjenjača.
4. Ekscentričnost, uključujući statičke i dinamičke nepravilnosti zračnog razmaka.

Simptomi ovih kvarova uključuju neuravnotežene naponske i strujne uvjete, povećane pulsacije i gubitke momenta, te prekomjerno zagrijavanje, što ukazuje na potrebu za naprednim tehnikama dijagnostike [15]. Napredak u tehnologiji, posebno integracija umjetne inteligencije i metoda strojnog učenja, transformirala je pristupe dijagnostici, omogućujući mnogo bržu i precizniju detekciju problema prije nego što dovedu do ozbiljnih posljedica [15]. Razvoj Internet of Things (IoT) tehnologija i računalstva na rubu (eng. edge computing) omogućuje bolju integraciju dijagnostičkih alata direktno u operativne procese, što dalje poboljšava sposobnost predviđanja i sprječavanja kvarova [24].



Slika 1. Dijelovi elektromotora

Izvor: <https://strojarskaradionica.wordpress.com/2018/05/08/6-najcescih-kvarova-elektromotora/>

2.1. Kvarovi ležajeva

Većina električnih strojeva koristi kuglične ili valjkaste ležajeve koji se sastoje od dvije prstenaste komponente – unutarnje i vanjske, s kuglicama ili valjcima koji se okreću unutar staza ovih prstenova. Iako su ležajevi dizajnirani da izdrže visoka opterećenja i vibracije tijekom normalnog rada, postoji nekoliko ključnih faktora koji mogu dovesti do njihovog kvara:

1. **Materijalni zamor:** Redovita opterećenja mogu uzrokovati materijalni zamor, što rezultira ljuštenjem ili odlamanjem dijelova ležaja, čime se povećava razina vibracija i buke. Proces zamora materijala može biti ubrzan neadekvatnom podmazanošću ili prekomjernim opterećenjem, što dovodi do prijevremenog otkazivanja ležajeva [15].
2. **Kontaminacija i korozija:** Tvrdi i abrazivni čestici, kao i korozivni učinci vode i kiselina, mogu oštetiti ležajeve. Kontaminacija, čak i mikroskopskih razmjera, može uzrokovati značajnu abraziju i ubrzati trošenje staza ležajeva, posebno u okruženjima s visokim zahtjevima za čistoćom kao što su prehrambena industrija i zdravstvo [12].
3. **Neppravilna podmazanost:** Neppravilna podmazanost, koja uključuje i prekomjerno i nedovoljno podmazivanje, može uzrokovati zagrijavanje i abraziju. Ovo se često javlja zbog korištenja neodgovarajućeg tipa maziva ili pogrešaka u intervalima podmazivanja [7].
4. **Neppravilna instalacija:** Neusklađenost tijekom instalacije može uzrokovati stvaranje udubljenja na stazama ležajeva (poznato kao brinelling), što dodatno degradira performanse. Precizna instalacija je ključna za dugotrajnost ležajeva, a greške pri montaži mogu uzrokovati nepopravljiva oštećenja [2].

Statistike pokazuju da gotovo 40%-50% svih kvarova motora može biti povezano s problemima ležajeva. Napredne tehnike dijagnostike, kao što su analiza vibracija i termografsko snimanje, omogućavaju rano otkrivanje znakova kvarova ležajeva prije nego što dovedu do ozbiljnijih problema u radu stroja [15]. Korištenje ovih metoda može pomoći u optimizaciji planova održavanja i produžiti vijek trajanja opreme.



Slika 2. Pukotina u ležaju zbog zamora materijala

Izvor: https://cdn.skfmediahub.skf.com/api/public/0901d1968013be94/pdf_preview_medium/0901d1968013be94_pdf_preview_medium.pdf , str 309

2.2.Kvarovi na statoru ili armaturi

Kvarovi na statoru ili armaturi električnih motora često su rezultat problema s izolacijom i obično se manifestiraju kao kvarovi između faze i zemlje ili između faza. Vjeruje se da ovi kvarovi počinju kao neotkriveni kvarovi između zavoja, koji s vremenom eskaliraju u veće probleme, pri čemu gotovo 30% do 40% svih prijavljenih kvarova na asinkronim motorima pripada ovoj kategoriji [7]. Izolacija na statoru može zakazati iz više razloga, uključujući visoke temperature jezgre statora ili namota koje mogu oslabiti ili oštetiti izolaciju i dovesti do kratkih spojeva. Drugi uzroci uključuju labave laminacije jezgre, klizne klinove i spojeve koji mogu stvoriti lokalne vruće točke, kao i labavo osiguranje završnih namota koje može uzrokovati vibracije ili pomicanje. Kontaminacija uljem, vlagom i prljavštinom može smanjiti dielektričnu čvrstoću izolacije, a kratki spojevi ili naprezanja pri pokretanju mogu generirati prekomjerne elektromagnetske sile koje oštećuju izolaciju [12].

Za velike generatore i motore s namotima nominalne vrijednosti 4 kV i više, online metode testiranja parcijalnih pražnjenja pružaju vrlo pouzdane rezultate [10]. Međutim, za motore niskog napon, postupci za detekciju kvarova na statoru još nisu standardizirani. Detekcija se može izvesti analizom aksijalne komponente magnetskog toka stroja koristeći veliku zavojnicu omotanu koncentrično oko osovine stroja [10]. Napredne tehnike kao što su analiza frekvencija

vibracija i analiza struja stroja (MCSA) koriste se za identifikaciju specifičnih problema povezanih s izolacijom, pružajući sredstva za rano otkrivanje i sprječavanje ozbiljnih kvarova prije nego što uzrokuju veće operativne probleme [4, 7].

Detekcija kvarova na statoru ili armaturi uključuje niz sofisticiranih tehnika koje se koriste za identificiranje i analiziranje problema prije nego što eskaliraju u veće kvarove. Za velike generatore i motore sa statorskim namotima nominalne vrijednosti 4 kV i više, pouzdane rezultate pružaju online metode testiranja parcijalnih pražnjenja [10]. Također, postoji prenosivi instrument za testiranje poznat kao TGA-B, specifično dizajniran za ovu svrhu [10].

Za motore niskog napona, međutim, procedure za detekciju kvarova na statoru još uvijek nisu u potpunosti standardizirane. Napredne tehnike, kao što su analiza aksijalne komponente magnetskog toka stroja pomoću velike zavojnice omotane oko osovine, koriste se za detektiranje kvarova između zavoja. Postavljanje četiri zavojnice simetrično u četiri kvadranta motora omogućava preciznu lokalizaciju kvara. Frekvencije koje se koriste u ovoj analizi određene su formulom za frekvenciju klizanja [5]:

$$f_s = (k + n(1 - s)) \frac{p}{f}$$

gdje je:

- f_s = frekvencija klizanja (Hz)
- k = broj parova polova statora
- f = osnovna frekvencija mreže (Hz)
- s = klizanje
- n = red harmonika
- p = broj parova polova rotora

Ova tehnika detekcije pokazuje dobre rezultate čak i u prisutnosti harmonika napajanja, što je često kod asinkronih motora pogonjenih VSI (pretvarač naponskog izvora) [5].

Istraživanja Nandi i sur. [7] pokazala su kako kvarovi mogu uzrokovati asimetriju u impedanciji stroja, dovodeći do povlačenja nebalansirane struje faze. Osim toga, kvarovi mogu biti posljedica nebalansa napona, zasićenja stroja i drugih faktora. Kliman i sur. [4] razvili su modele koji uključuju asimetrije instrumenata, a te modifikacije omogućile su čak i detekciju

pojedinačnih kratkih spojeva iz ukupno 648 zavoja. Primjena tehnike dekompozicije snage (PDT) također se pokazala korisnom za smanjenje učinaka harmonika i negativno-sekvencijske reaktancije, što je važno za precizno mjerenje struje negativnog niza.

Dodatno, tehnike statističke kontrole procesa (SPC) primijenjene su za detekciju kvarova na statoru [5], dok su modeli za procjenu i detekciju kratkih spojeva zavoja na statoru u vremenskoj domeni razvijeni i dokumentirani. Razvijen je i fuzzy detektor kvarova koji koristi Concordia uzorke za detekciju neravnoteže i otvorenih kvarova na statoru, koristeći transformaciju trofazne u dvofaznu struju u stacionarnim koordinatama [5].

Tehnike temeljene na analizi struje stroja (MCSA) za otkrivanje kvarova na statoru između zavoja bile su predmet izvještaja u literaturi. Te tehnike pokazuju prisutnost komponenti niske i visoke frekvencije, sličnih onima koje se javljaju kod kvarova povezanih s ekscentričnošću [4]. Međutim, fizikalna objašnjenja za postojanje tih komponenti nisu jasno objašnjena. Također, nisu riješena pitanja kao što su neravnoteža napona i konstrukcijske nepravilnosti koje proizvode slične učinke. Detekcija kvarova na statoru pomoću ubrizgavanja vanjskog signala raspravlja se u literaturi [7].

Praćenje kutne promjene vektora struje statora koristi se za detekciju kvarova na statoru i rotoru. Varijacije faza analizirane su u frekvencijskoj domeni, a Goertzelov algoritam koristi se za stvarno-vremensku implementaciju. Također se može naći jaka komponenta trećeg harmonika u liniji struje kod kvarova statora između zavoja. Praćenje promjena u struji pozitivne sekvence korištenjem teorije višestrukih referentnih okvira također je predloženo za detekciju [14].

Nandi i Toliyat primijetili su da kratko spojeni zavoji statora djeluju kao osjetna zavojnica koja detektira harmonike elektromotornih sila rotora u strojevima sa kavezom rotorom [7]. Iako analiza struje stroja (MCSA) može detektirati ove komponente, one se ponekad mogu zamijeniti s neravnotežom napona u nekim strojevima. Srećom, te komponente se mogu detektirati na terminalnim naponima stroja odmah nakon njegovog isključivanja [7].

Dizajn i proizvodnja kavez rotora za asinkrone motore mijenjali su se tijekom godina, za razliku od dizajna statora. Kao rezultat toga, kvarovi rotora sada čine otprilike 5% do 10% ukupnih kvarova asinkronih motora. Postoje dvije vrste kavez rotora: lijevani i izrađeni. Ranije su se lijevani rotori koristili samo u manjim strojevima, ali s razvojem tehnologije lijevanja sada se koriste i za rotore strojeva snage do 3000 kW. Izrađeni rotori se obično nalaze u većim ili

specijaliziranim strojevima. Iako su lijevani rotor i izdržljiviji od izrađenih, gotovo ih je nemoguće popraviti nakon što se razviju kvarovi poput puknutih ili slomljenih rotor šipki [3].

Lom rotorskih šipki i prstenova može nastati zbog različitih razloga, uključujući toplinska, magnetska, ostatna, dinamička, okolišna i mehanička naprezanja [4, 5]. Toplinska naprezanja javljaju se uslijed toplinskog preopterećenja i neravnoteže, vrućih točaka ili prekomjernih gubitaka, kao i iskrenja, što je posebno izraženo kod izrađenih rotora. Magnetska naprezanja nastaju zbog elektromagnetskih sila, nebalansiranih magnetskih vuča, elektromagnetske buke i vibracija. Ostatna naprezanja mogu biti rezultat problema u proizvodnji, dok dinamička naprezanja proizlaze iz okretnog momenta osovine, centrifugalnih sila i cikličkih naprezanja. Okolišna naprezanja nastaju zbog kontaminacije i abrazije materijala rotora uslijed kemikalija ili vlage. Konačno, mehanička naprezanja mogu biti posljedica labavih laminacija, istrošenih dijelova, kvara ležajeva i sličnih problema [4, 5].

Kliman i suradnici koristili su analizu spektra struje stroja (MCSA) za otkrivanje kvarova slomljenih šipki. Istraživali su komponente bočnih traka oko osnovne frekvencije za otkrivanje kvarova slomljenih šipki [4].

Formula:

$$f_b = (1 \pm 2s)f$$

gdje je:

- f_b = frekvencija bočnih traka (Hz)
- s = klizanje motora
- f = osnovna frekvencija napajanja (Hz)

predstavlja frekvenciju bočnih traka koja je posebno povezana s prekidima na rotorskim šipkama. Niža bočna traka specifično je posljedica slomljene šipke, dok je gornja bočna traka uzrokovana oscilacijama brzine koje slijede. Prema istraživanju koje je prikazano u [4], prekid na rotorskim šipkama zapravo uzrokuje niz takvih bočnih traka opisanih formulom:

$$f_b = (1 \pm 2ks)f$$

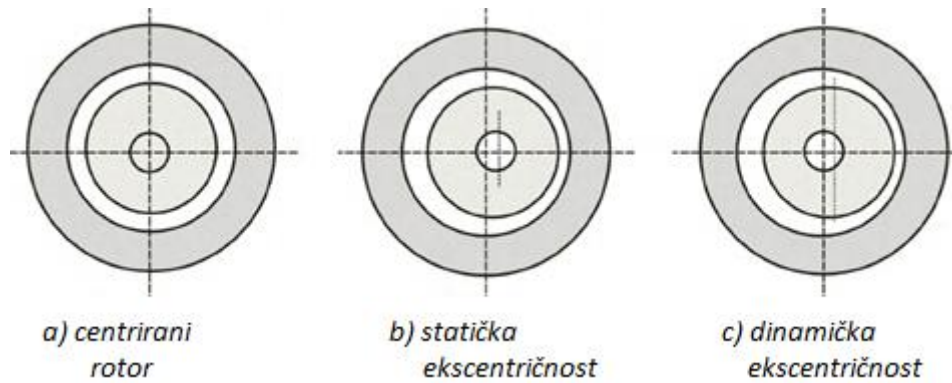
Haji i Toliyat [3] istražuju detekciju oštećenih šipki rotora koristeći tehniku prepoznavanja uzoraka. Inercija opterećenja motora također utječe na veličinu bočnih traka koje se formiraju

zbog kvarova u rotoru. Ostale spektralne komponente koje se mogu promatrati u struji statora opisane su od strane Klimana i sur. [4] i Nandi, Toliyat i Li [7]. Prema Klimanu i sur. [4], međušipkaste struje prisutne su u neizoliranim rotorima sa šipkama gdje je kontakt između jezgre rotora i šipki dobar. Te struje smanjuju magnetsku neravnotežu uzrokovanu slomljenim šipkama, što otežava detekciju prekinutih šipki, posebno u ranoj fazi. Značajna međušipkasta struja prisutna je čak i u asinkronim motorima s dvostrukim kavezom [5]. Spektri aksijalnih vibracija također se mogu koristiti za dijagnosticiranje kvarova na šipkama rotora [6]. Aksijalne vibracije nastaju zbog aksijalne sile koja se generira interakcijom međušipkaste struje i statorskog toka. Eksperimentalni rezultati su prikazani za rotore s bakrenim kavezima s jednom slomljenom šipkom.

2.3. Kvarovi povezani s ekscentričnošću

Kvarovi povezani s ekscentričnošću odnose se na stanje kada postoji nejednaka zračna praznina između statora i rotora. Kada ekscentričnost postane velika, rezultirajuće neuravnotežene radijalne sile (poznate i kao neuravnoteženi magnetski povlatak ili UMP) mogu uzrokovati trenje između statora i rotora, što može rezultirati oštećenjem oba dijela [1].

Postoje dvije vrste ekscentričnosti zračnog razmaka: statička ekscentričnost zračnog razmaka i dinamička ekscentričnost zračnog razmaka. U slučaju statičke ekscentričnosti, pozicija minimalne radijalne duljine zračnog razmaka je fiksirana u prostoru. Statička ekscentričnost može biti uzrokovana ovalnošću jezgre statora ili nepravilnim pozicioniranjem rotora ili statora u fazi puštanja u pogon. Ako je sklop rotora i osovine dovoljno čvrst, razina statičke ekscentričnosti se ne mijenja. U slučaju dinamičke ekscentričnosti, središte rotora nije u središtu rotacije i pozicija minimalnog zračnog razmaka rotira zajedno s rotorom. Ovo pomicanje može biti uzrokovano nekoliko faktora, kao što su savijena osovina rotora, trošenje ili nepravilno poravnanje ležaja, mehanička rezonanca pri kritičnoj brzini itd. Dinamička ekscentričnost kod novih strojeva kontrolira se pomoću ukupnog indiciranog očitavanja (TIR) ili „iskretanja“ rotora. Dopuštena je ekscentričnost zračnog razmaka do 10%. Međutim, proizvođači obično održavaju razinu ukupne ekscentričnosti čak i nižu kako bi minimizirali UMP i smanjili vibracije i buku [2].



Slika 3. Kvarovi povezani s ekscentričnošću

Izvor: https://www.researchgate.net/figure/Types-of-eccentricity-faults-a-centric-rotor-b-static-eccentricity-and-c-dynamic_fig1_287577527 ., Uredio student.

U praksi, statička i dinamička ekscentričnost obično koegzistiraju. Inherentna razina statičke ekscentričnosti postoji čak i u novo proizvedenim strojevima zbog metoda proizvodnje i montaže, kako je prijavljeno od strane Dorrell i sur. [17]. To uzrokuje stalni UMP u jednom smjeru. S upotrebom, to može dovesti do savijene osovine rotora, trošenja ležaja itd., što može rezultirati određenom razinom dinamičke ekscentričnosti. Ako se ne detektira rano, ovi učinci mogu eskalirati u veći kvar, što može dovesti do ozbiljnog kvara stroja [17].

Prisutnost statičke i dinamičke ekscentričnosti u strojevima može se detektirati korištenjem analize potpisa struje motora (MCSA), koja analizira frekvencijske komponente prisutne u struji motora. Specifične frekvencijske komponente povezane s ekscentričnošću detaljno su opisane formulama koje opisuju odnos između osnovne frekvencije napajanja f , broja utora rotora R , klizanja s , broja parova polova p i reda vremenskih harmonika statora prisutnih u napajanju motora.

Za statičku ekscentričnost, formula povezuje red ekscentričnosti s frekvencijskim komponentama:

$$f_e = f[(kR \pm n_d) \left(\frac{1-s}{p} \pm v \right)]$$

Gdje je:

f_e = frekvencija ekscentričnosti (Hz)

f = osnovna frekvencija napajanja (Hz)

k=cijeli broj koji označava harmonik ili red oscilacije

R= broj utora rotora

n_d =indeks harmonika

s=klizanje

p=broj parova polova statora

v=indeks uzdužnog vala

Ova formula pomaže identificirati specifične harmonične komponente u struji motora zbog statičke ekscentričnosti [2,8].

Dinamička ekscentričnost uključuje slične proračune, ali se fokusira na uvjete kada središte rotora nije u središtu rotacije, uzrokujući da se minimalni zračni razmak rotira s rotorom. Ovo stanje je pod utjecajem mehaničkih faktora kao što su savijena osovina rotora, trošenje ležajeva ili neusklađenost [2].

Odnosi između parova polova i broja utora rotora znatno utječu na to jesu li frekvencijske komponente zbog ekscentričnosti jake ili slabe. Strojevi s određenim konfiguracijama parova polova i broja utora rotora pokazat će izražene frekvencijske komponente povezane s ekscentričnošću, posebno pod uvjetima kada postoje i statička i dinamička ekscentričnost. Ovi uvidi podržani su modeliranjem i eksperimentalnim rezultatima koji mogu potvrditi teorijsku analizu temeljenu na propusnosti ili funkciji obrnutog zračnog razmaka. Ova vrsta analize je ključna za održavanje zdravlja i operativne učinkovitosti motora, jer omogućava rano otkrivanje potencijalnih problema koji bi mogli dovesti do ozbiljnijih mehaničkih kvarova [3].

Signali vibracija također se mogu pratiti za detekciju kvarova povezanih s ekscentričnošću. Komponente visokofrekventnih vibracija za statičku ili dinamičku ekscentričnost daju se pomoću jednadžbe slične prethodno navedenoj, ali s drugačijim vrijednostima frekvencija. U slučaju mješovite ekscentričnosti, komponente vibracija statora niske frekvencije daju se formulom:

$$f_v = 2f \pm f_r$$

gdje je:

f_v =frekvencija vibracija (Hz)

f =osnovna frekvencija napajanja (Hz)

f_r =frekvencija rotacije rotora (Hz)

Međutim, pretvornici za vibracije su osjetljivi i skupi. Također imaju posebne zahtjeve za instalaciju kako bi se izbjeglo oštećenje zbog udaraca i vibracija [4].

Drugi pristupi, poput praćenja statorskog napona i struje Parkovog vektora (Cardoso i Saraiva [2]) za otkrivanje ekscentričnosti u asinkronom motoru, također se mogu naći u literaturi. Toliyat i Al-Nauim [11] pružili su simulacijske i eksperimentalne rezultate za sinkrone strojeve s kvarovima povezanim s dinamičkom ekscentričnošću. Potpisi kvarova ekscentričnosti mogu se izvući iz podataka o okretnom momentu [8] korištenjem TSDM u kombinaciji s TSCFE-SS. Induktancije ekscentričnog asinkronog stroja [9] računaju se kombiniranjem WFA i magnetskog ekvivalentnog kruga (MEC). Učinci neravnoteže opterećenja, kutnog (horizontalnog) neusklađivanja i radijalnog (vertikalnog) neusklađivanja na bočnoj traci struje malog asinkronog stroja proučavani su u [10].

Metode konačnih elemenata s vremenskim koracima nedavno su korištene za usporedbu simuliranih rezultata s eksperimentalno dobivenim komponentama statičke ekscentričnosti u struji. Treba napomenuti da se ekscentričnost treba modelirati koristeći modificirani pristup funkciji namotaja (MWFA). Korištenje pristupa funkciji namotaja (WFA) rezultira nejednakim međusobnim induktancijama, što dovodi do netočnih rezultata [11][12].

2.4. Kvarovi sustava napajanja i elektronike i ostali mehanički i električni kvarovi specifični za brodske uvjete

Električni sustavi na brodovima uključuju složene mreže napajanja i kontrolne elektronike koje su ključne za ispravan rad brodskih električnih strojeva. Kvarovi u ovim sustavima mogu značajno utjecati na pouzdanost i sigurnost broda. Preopterećenje i kratki spojevi mogu dovesti do ozbiljnih oštećenja komponenata električnog sustava. Prekomjerno strujno opterećenje može uzrokovati pregrijavanje vodiča, izolacije i elektroničkih komponenata, što često rezultira kvarovima. Ovi kvarovi mogu uzrokovati prekide u radu strojeva, što može imati ozbiljne posljedice za brodske operacije i sigurnost [13]. Elektronički kvarovi uključuju probleme s kontrolnim sustavima, sensorima i aktuatorima. Na primjer, kvarovi na upravljačkoj elektronicima mogu uzrokovati nepravilnosti u radu strojeva ili čak njihovo potpuno zaustavljanje. Problemi s elektronikom često su povezani s neispravnim komponentama, lošim spojevima ili softverskim greškama. Moderni brodovi koriste sve sofisticiranije elektroničke sustave za

upravljanje i kontrolu, pa su stoga ranjivi na kvarove uzrokovane složenim hardverom i softverom [23]. Kablovi i konektori su podložni starenju, koroziji i mehaničkim oštećenjima, osobito u zahtjevnim morskim uvjetima. Izloženost vlazi, soli i promjenama temperature može uzrokovati koroziju i oksidaciju, što dovodi do povećanog električnog otpora i mogućih kvarova. Redovito održavanje i zamjena oštećenih dijelova ključni su za sprječavanje ovih problema. Kvarovi na kablovima mogu uzrokovati neispravnosti u napajanju i komunikaciji između različitih sustava na brodu [13].

Osim specifičnih problema s napajanjem i elektronikom, brodski električni strojevi suočavaju se s jedinstvenim izazovima vezanim uz mehaničke i električne kvarove uzrokovane specifičnim brodskim uvjetima. Stalna izloženost vodi i soli može uzrokovati koroziju metalnih dijelova, što može dovesti do mehaničkih kvarova i smanjenja električne vodljivosti. Korozija može ozbiljno oštetiti električne spojeve, terminale i kućišta komponenata, čime se smanjuje njihova pouzdanost i funkcionalnost. Na primjer, korodirani spojevi mogu uzrokovati povećani električni otpor, što dovodi do pregrijavanja i potencijalnih kvarova [14]. Brodovi su stalno izloženi vibracijama i udarcima zbog morskih valova i rada strojeva. Ove vibracije mogu uzrokovati labave spojeve, pukotine u mehaničkim komponentama i ubrzano trošenje ležajeva i drugih dijelova. Pravilno dizajnirana montaža i redovito održavanje mogu pomoći u ublažavanju ovih problema. Vibracije također mogu uzrokovati zamor materijala, što može dovesti do pukotina i lomova u ključnim komponentama [13].

Ekstremne temperaturne promjene, posebno u polarnim i tropskim uvjetima, mogu uzrokovati termička naprezanja u materijalima strojeva. Termička ekspanzija i kontrakcija mogu dovesti do pukotina, deformacija i degradacije izolacije, što može uzrokovati električne kvarove i smanjiti učinkovitost strojeva. Na primjer, termički ciklusi mogu oslabiti spojeve i uzrokovati mikropukotine u izolacijskim materijalima, što dovodi do probijanja izolacije i kratkih spojeva [7]. Kombinacija ovih faktora čini brodske uvjete posebno izazovnim za održavanje električnih strojeva. Redovito održavanje, korištenje specijaliziranih materijala otpornih na koroziju, vibracije i ekstremne temperature, kao i napredne dijagnostičke tehnike, ključni su za osiguranje pouzdanosti i dugovječnosti brodskih električnih sustava.

3. TEHNIKE I METODE DIJAGNOSTIKE KVAROVA

3.1. Analiza struje stroja (MCSA)

Analiza struje stroja (MCSA) je dijagnostička tehnika koja se koristi za otkrivanje kvarova u električnim motorima putem analize strujnih signala. Ova metoda je posebno učinkovita jer omogućuje otkrivanje različitih vrsta kvarova bez potrebe za razgradnjom stroja, što je izuzetno važno za brodske sustave gdje je pristup komponentama često ograničen. MCSA se temelji na mjerenju i analizi struje motora tijekom njegovog rada. Strujni signali se analiziraju kako bi se identificirale frekvencijske komponente koje ukazuju na specifične vrste kvarova. Ključne komponente uključuju osnovnu frekvenciju napajanja, harmonike i bočne trake, koje se javljaju kao posljedica različitih vrsta kvarova.

Kvarovi statora, poput oštećenja izolacije ili kratkog spoja između zavoja, mogu se otkriti analizom promjena u harmonijskim komponentama struje [16]. Ovi kvarovi često uzrokuju pojavu dodatnih frekvencijskih komponenti koje se mogu detektirati pomoću MCSA (Motor Current Signature Analysis). Slomljene šipke rotora i pukotine u krajnjim prstenovima stvaraju specifične frekvencijske signale poznate kao bočne trake. Ove bočne trake se javljaju simetrično oko osnovne frekvencije i mogu se identificirati pomoću spektralne analize struje [15]. Problemi s ležajevima uzrokuju vibracije koje se prenose na električni signal struje motora [15]. Statička i dinamička ekscentričnost uzrokuju neravnomjernu raspodjelu magnetskog polja, što rezultira pojavom specifičnih frekvencijskih komponenti u struji motora. MCSA može detektirati ove komponente i identificirati prisutnost ekscentričnosti [15].

Prednosti MCSA uključuju nisku cijenu, jer koristi postojeće strujne senzore i zahtijeva minimalne dodatne troškove za implementaciju. Također, metoda je neinvazivna i ne zahtijeva zaustavljanje stroja ili demontažu, što je posebno važno za brodske operacije. MCSA može otkriti različite vrste kvarova, uključujući električne i mehaničke probleme, te može biti integrirana u sustave za daljinsko praćenje i kontrolu, omogućujući kontinuirano praćenje stanja motora.

Implementacija MCSA uključuje nekoliko koraka:

1. Postavljanje strujnih senzora na napajanje motora za kontinuirano praćenje strujnih signala.
2. Prikupljanje podataka o struji tijekom rada motora.
3. Korištenje softverskih alata za spektralnu analizu prikupljenih strujnih signala kako bi se identificirale karakteristične frekvencijske komponente.
4. Interpretacija rezultata analize kako bi se identificirali potencijalni kvarovi.

MCSA je moćna tehnika za dijagnostiku kvarova u brodskim električnim strojevima koja omogućava rano otkrivanje problema, smanjujući rizik od ozbiljnih kvarova i produžujući vijek trajanja strojeva. Integracijom MCSA u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti.



Slika 4. Analiza struje stroja (MCSA)

Izvor: <https://www.rokaderototechniks.com/motor-current-signature-analysis.html>

3.2. Analiza vibracija

Analiza vibracija je još jedna ključna tehnika koja se koristi za dijagnostiku kvarova u brodskim električnim strojevima. Ova metoda omogućuje rano otkrivanje mehaničkih problema koji mogu dovesti do ozbiljnih kvarova i skupih popravaka.

Analiza vibracija temelji se na mjerenju vibracijskih signala koje emitira stroj tijekom rada. Vibracijski senzori se postavljaju na kritične točke na stroju, poput ležajeva, osovina i kućišta,

kako bi se prikupljali podaci o amplitudama i frekvencijama vibracija. Ovi podaci se zatim analiziraju kako bi se identificirale karakteristične frekvencijske komponente koje ukazuju na specifične vrste kvarova.

Kvarovi ležajeva mogu se otkriti analizom vibracijskih signala koji pokazuju specifične frekvencijske komponente povezane s oštećenjem ležajeva. Na primjer, nepravilnosti u unutarnjoj ili vanjskoj stazi ležajeva, kuglicama ili kavezu mogu stvoriti karakteristične frekvencije koje se mogu detektirati analizom vibracija [15]. Ekscentričnost, bilo statička ili dinamička, također može biti otkrivena pomoću analize vibracija. Statička ekscentričnost uzrokuje konstantnu vibraciju na određenim frekvencijama, dok dinamička ekscentričnost stvara promjenjive vibracijske signale koji se mogu identificirati analizom [17]. Pukotine u rotorima i problemi sa šipkama rotora mogu se otkriti putem specifičnih vibracijskih signala koji se javljaju zbog neravnoteže i promjene u dinamici rotacije. Ovi kvarovi uzrokuju pojavu vibracija na harmonijskim frekvencijama koje se mogu detektirati i analizirati [15]. Također, analiza vibracija može otkriti probleme poput labavih spojeva, savijenih osovina i drugih mehaničkih nepravilnosti koje uzrokuju abnormalne vibracije.


Prednosti analize vibracija uključuju visoku osjetljivost na mehaničke kvarove, mogućnost otkrivanja širokog spektra problema, te neinvazivnost metode koja omogućava kontinuirano praćenje bez potrebe za zaustavljanjem stroja. Analiza vibracija je također vrlo učinkovita u kombinaciji s drugim dijagnostičkim tehnikama, kao što je analiza struje stroja (MCSA), što omogućava sveobuhvatniju dijagnostiku [15]. Implementacija analize vibracija uključuje postavljanje vibracijskih senzora na ključne točke stroja, kontinuirano prikupljanje podataka o vibracijama, korištenje softverskih alata za spektralnu analizu prikupljenih vibracijskih signala, te interpretaciju rezultata analize kako bi se identificirali potencijalni kvarovi. Redovita analiza vibracija može pomoći u prediktivnom održavanju, smanjujući rizik od neplaniranih zastoja i povećavajući pouzdanost brodskih sustava [15]. Analiza vibracija je ključna tehnika za dijagnostiku kvarova u brodskim električnim strojevima koja omogućava rano otkrivanje mehaničkih problema, smanjujući rizik od ozbiljnih kvarova i produžujući vijek trajanja strojeva. Integracijom analize vibracija u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti [15].

3.3. Termografska analiza

Termografska analiza je dijagnostička tehnika koja se koristi za otkrivanje kvarova u brodskim električnim strojevima putem analize toplinskih uzoraka. Ova metoda omogućuje rano otkrivanje problema koji uzrokuju abnormalno zagrijavanje, što može dovesti do ozbiljnih kvarova ako se ne otkrije na vrijeme.

Termografska analiza temelji se na upotrebi infracrvenih kamera koje snimaju toplinske slike strojeva tijekom njihovog rada. Ove slike prikazuju temperaturne profile različitih dijelova stroja, omogućujući identifikaciju područja s abnormalno visokim temperaturama. Analiza toplinskih uzoraka može otkriti različite vrste kvarova, uključujući električne, mehaničke i izolacijske probleme.

Kvarovi statora, poput oštećenja izolacije ili kratkog spoja između zavoja, često uzrokuju lokalizirano zagrijavanje koje se može detektirati pomoću termografske analize. Abnormalno visoke temperature u određenim dijelovima statora mogu ukazivati na probleme s izolacijom ili prekomjerno strujno opterećenje, što je opisano u literaturi o parametrima i dijagnostici električnih strojeva [12]. Kvarovi rotora, poput slomljenih šipki ili pukotina u krajnjim prstenovima, također uzrokuju neravnomjerno zagrijavanje rotora koje se može identificirati termografijom [3].



Slika 5. Toplinska slika asinkronog elektromotora s dvije slomljene šipke rotora

Izvor: https://www.researchgate.net/figure/Thermal-image-of-the-three-phase-induction-motor-with-two-broken-bars_fig5_311549453

Problemi s ležajevima, kao što su nedostatak podmazivanja, trošenje ili oštećenje, često dovode do povećanog trenja i zagrijavanja ležajeva. Termografska analiza može otkriti ove probleme putem identifikacije vrućih točaka na ležajevima [15]. Kvarovi sustava napajanja i elektronike, poput labavih spojeva, loših kontakata i kratkih spojeva, također mogu uzrokovati lokalizirano zagrijavanje koje se može detektirati pomoću termografskih kamera [15].

Prednosti termografske analize uključuju mogućnost brzog i neinvazivnog pregleda širokog područja stroja, visoku osjetljivost na temperaturne promjene te mogućnost otkrivanja različitih vrsta kvarova. Ova metoda je posebno korisna za redovito preventivno održavanje, omogućujući identifikaciju potencijalnih problema prije nego što postanu ozbiljni kvarovi. Implementacija termografske analize uključuje korištenje infracrvenih kamera za snimanje toplinskih slika strojeva tijekom rada, analizu prikupljenih slika pomoću softverskih alata za identifikaciju vrućih točaka i abnormalnih temperaturnih uzoraka, te interpretaciju rezultata kako bi se identificirali potencijalni kvarovi. Termografska analiza se često koristi zajedno s drugim dijagnostičkim tehnikama, poput analize struje stroja (MCSA) i analize vibracija, kako bi se dobila sveobuhvatna slika stanja stroja.

Termografska analiza je važna tehnika za dijagnostiku kvarova u brodskim električnim strojevima koja omogućava rano otkrivanje problema s zagrijavanjem, smanjujući rizik od ozbiljnih kvarova i produžujući vijek trajanja strojeva. Integracijom termografske analize u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti.

3.4. Akustična emisija

Akustična emisija je dijagnostička tehnika koja koristi zvučne signale koje emitira stroj tijekom rada kako bi identificirala i analizirala kvarove. Ova metoda je posebno učinkovita za otkrivanje problema koji uzrokuju stvaranje abnormalnih zvučnih valova, kao što su pukotine, trenje, udarci i druge mehaničke nepravilnosti. Akustična emisija se temelji na upotrebi senzora za prikupljanje zvučnih signala koje emitira stroj. Ovi senzori mogu detektirati visokofrekventne zvučne valove koji su često izvan raspona ljudskog sluha. Analiza tih signala omogućuje identifikaciju karakterističnih uzoraka koji ukazuju na specifične vrste kvarova.

Kvarovi ležajeva mogu se otkriti pomoću akustične emisije jer oštećenja ležajeva stvaraju karakteristične zvučne signale. Na primjer, pukotine na kuglicama ili stazama ležajeva uzrokuju visokofrekventne impulse koji se mogu detektirati i analizirati [15]. Kvarovi statora, poput

oštećenja izolacije, također mogu stvoriti zvučne signale zbog električnih pražnjenja i mikroiskrenja, što se može detektirati pomoću akustične emisije [7, 15]. Slomljene šipke rotora i problemi s krajnjim prstenovima mogu uzrokovati neravnomjerno kretanje rotora, stvarajući karakteristične zvučne valove koji se mogu detektirati i analizirati [19]. Akustična emisija također može otkriti probleme s ekscentričnošću, jer nejednak zračni razmak između rotora i statora uzrokuje neravnomjerno stvaranje zvučnih signala [18].

Prednosti akustične emisije uključuju visoku osjetljivost na mehaničke kvarove, mogućnost otkrivanja širokog spektra problema te neinvazivnost metode koja omogućava kontinuirano praćenje bez potrebe za zaustavljanjem stroja. Akustična emisija je također vrlo učinkovita u kombinaciji s drugim dijagnostičkim tehnikama, kao što su analiza struje stroja (MCSA) i analiza vibracija, što omogućava sveobuhvatniju dijagnostiku [4, 14]. Implementacija akustične emisije uključuje postavljanje akustičnih senzora na ključne točke stroja, kontinuirano prikupljanje zvučnih signala, korištenje softverskih alata za analizu prikupljenih zvučnih signala kako bi se identificirali karakteristični uzorci, te interpretaciju rezultata analize kako bi se identificirali potencijalni kvarovi. Redovita akustična analiza može pomoći u prediktivnom održavanju, smanjujući rizik od neplaniranih zastoja i povećavajući pouzdanost brodskih sustava. Akustična emisija je ključna tehnika za dijagnostiku kvarova u brodskim električnim strojevima koja omogućava rano otkrivanje mehaničkih problema, smanjujući rizik od ozbiljnih kvarova i produžujući vijek trajanja strojeva. Integracijom akustične emisije u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti.

3.5. Analiza parcijalnih pražnjenja

Analiza parcijalnih pražnjenja (PD) je dijagnostička tehnika koja se koristi za otkrivanje kvarova u izolacijskim sustavima brodskih električnih strojeva. Parcijalna pražnjenja su lokalizirani električni ispadi unutar izolacijskog materijala koji ne prelaze cijelu izolaciju, ali mogu uzrokovati degradaciju materijala i eventualne kvarove ako se ne detektiraju na vrijeme. Ova metoda koristi se za identifikaciju problema unutar izolacijskih sustava statora i rotora, što je ključno za dugovječnost i pouzdanost električnih strojeva. Parcijalna pražnjenja nastaju zbog nepravilnosti u izolacijskom materijalu, kao što su praznine, pukotine, kontaminacija i degradacija materijala. Principi analize parcijalnih pražnjenja temelje se na mjerenju visokofrekventnih impulsa koji nastaju tijekom parcijalnih pražnjenja. Ovi impulsi se prikupljaju pomoću specijaliziranih senzora i analiziraju kako bi se identificirali karakteristični

uzorci koji ukazuju na prisutnost i lokaciju parcijalnih pražnjenja. Kvarovi statora mogu se otkriti analizom impulsa parcijalnih pražnjenja koji nastaju unutar izolacijskog materijala. Ovi impulsi mogu ukazivati na prisutnost praznina, pukotina ili kontaminacija koje uzrokuju parcijalna pražnjenja [10]. Kvarovi rotora, iako manje učestali, također se mogu identificirati pomoću PD analize, posebno u uvjetima gdje je rotor izložen visokom naponu.

Prednosti analize parcijalnih pražnjenja uključuju visoku osjetljivost na probleme u izolacijskom sustavu, mogućnost ranog otkrivanja problema prije nego što postanu ozbiljni kvarovi, te neinvazivnost metode koja omogućava kontinuirano praćenje bez potrebe za zaustavljanjem stroja. Analiza PD je posebno korisna za velike generatore i motore sa statorskim namotima nominalne vrijednosti 4 kV i više, gdje pruža vrlo pouzdane rezultate [10].

3.6. Spektralne analize (FFT, HOS)

Spektralne analize, uključujući brzu Fourierovu transformaciju (FFT) i spektar višeg reda (HOS), ključne su tehnike za dijagnostiku kvarova u brodskim električnim strojevima. Ove metode omogućuju detaljnu analizu frekvencijskih komponenti strujnih i vibracijskih signala, pomažući u identifikaciji različitih vrsta kvarova. FFT je matematička transformacija koja pretvara vremenske signale u njihove frekvencijske komponente. Korištenjem FFT-a moguće je analizirati spektralne karakteristike signala i identificirati specifične frekvencije povezane s kvarovima. Ova metoda je široko primijenjena zbog svoje jednostavnosti i učinkovitosti u otkrivanju problema poput slomljenih rotor šipki, ekscentričnosti, kvarova ležajeva i problema s namotima statora [15]. Kvarovi statora, poput oštećenja izolacije ili kratkih spojeva, često uzrokuju pojavu dodatnih harmonijskih frekvencija u spektru struje. Ove harmonijske komponente mogu se lako identificirati pomoću FFT analize, omogućujući rano otkrivanje problema [15]. Slomljene rotor šipke stvaraju karakteristične bočne trake oko osnovne frekvencije, koje se također mogu detektirati pomoću FFT-a [18].

HOS uključuje analizu viših redova spektra, kao što su bispektar i trispektar. Ove metode omogućuju otkrivanje nelinearnih interakcija i faznih informacija koje nisu vidljive u konvencionalnom spektru. HOS se koristi za poboljšanje dijagnostičke točnosti u složenim situacijama gdje su prisutni višestruki izvori frekvencijskih komponenti ili gdje su signali kontaminirani šumom [7].

Spektralne analize omogućuju identifikaciju specifičnih frekvencijskih komponenti koje ukazuju na prisutnost različitih vrsta kvarova. Na primjer, problemi s ležajevima često stvaraju vibracije na određenim frekvencijama koje se mogu detektirati i analizirati pomoću FFT-a i HOS-a [14, 15]. Ekscentričnost, bilo statička ili dinamička, uzrokuje pojavu dodatnih harmonijskih komponenti koje se mogu identificirati spektralnom analizom [18]. Prednosti spektralnih analiza uključuju visoku osjetljivost na promjene u frekvencijskom spektru, mogućnost otkrivanja širokog spektra kvarova, te relativnu jednostavnost implementacije i analize. FFT je posebno učinkovit za otkrivanje osnovnih harmonijskih i bočnih traka, dok HOS pruža dodatne informacije o nelinearnim efektima i faznim interakcijama, poboljšavajući dijagnostičku točnost [7, 15]. Implementacija spektralnih analiza uključuje prikupljanje strujnih i vibracijskih signala pomoću senzora, primjenu FFT ili HOS algoritama za analizu prikupljenih podataka, te interpretaciju rezultata kako bi se identificirali potencijalni kvarovi. Redovita spektralna analiza može pomoći u prediktivnom održavanju, smanjujući rizik od neplaniranih zastoja i povećavajući pouzdanost brodskih sustava [15]. Spektralne analize su ključne tehnike za dijagnostiku kvarova u brodskim električnim strojevima koje omogućuju detaljnu analizu frekvencijskih komponenti signala, rano otkrivanje problema i produžuju vijek trajanja strojeva. Integracijom spektralnih analiza u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti [7, 15].

4. PRAĆENJE STANJA STROJA I DIJAGNOSTIKA KVAROVA TEMELJENO NA UMJETNOJ INTELIGENCIJI

Do nedavno, prevladavajuća tehnika otkrivanja kvarova bila je analiza struje stroja (MCSA). Reference [7] i [19] pružaju dobar pregled tehnika temeljenih na MCSA. Osim tehnika temeljenih na brzom Fourierovoj transformaciji (FFT) primijenjenoj na struju, kvarovi slomljenih šipki, kvarovi statora i kvarovi dinamičke ekscentričnosti također se mogu detektirati koristeći spektar višeg reda (HOS), posebno bispektar i trispektar, iz jednog mjerenja senzora radijalne EM vibracije [14]. Testirani su strojevi pokretani linijom i inverterom.

4.4. Umjetne neuronske mreže (ANN)

Umjetne neuronske mreže (ANN) su moćna tehnika za dijagnostiku kvarova u brodskim električnim strojevima. ANN su inspirirane biološkim neuronskim mrežama i sastoje se od slojeva međusobno povezanih čvorova (neurona) koji zajedno obrađuju podatke i donose odluke. Koriste se za prepoznavanje uzoraka i klasifikaciju podataka, što ih čini idealnim za dijagnostiku kvarova gdje je potrebno prepoznati složene obrasce u podacima.

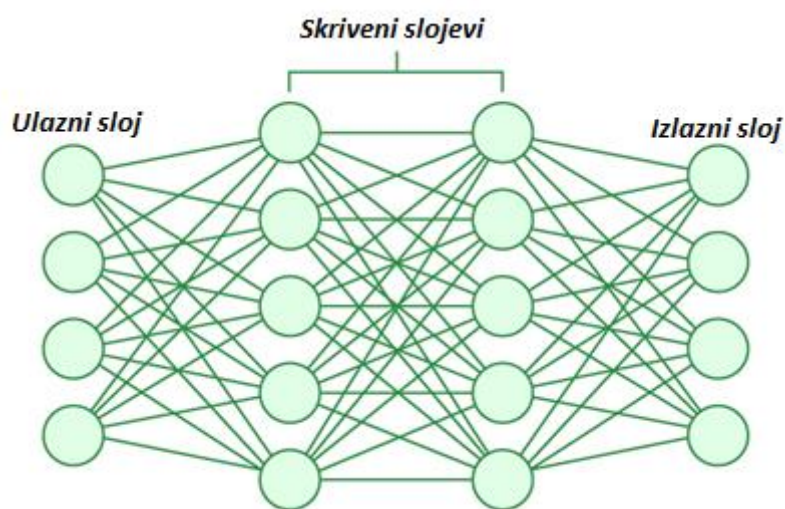
ANN se sastoje od ulaznog sloja, jednog ili više skrivenih slojeva i izlaznog sloja. Svaki neuron u mreži prima ulazne podatke, množi ih s odgovarajućim težinama, prolazi kroz aktivacijsku funkciju i prenosi rezultat dalje. Proces učenja ANN uključuje prilagodbu težina na temelju ulaznih podataka i odgovarajućih izlaza kako bi se minimizirala razlika između predviđenih i stvarnih vrijednosti.

Primjena ANN u dijagnostici kvarova električnih strojeva uključuje nekoliko koraka. Prvo, prikupljaju se podaci o radu stroja, poput strujnih, naponskih i vibracijskih signala. Ovi podaci se zatim obrađuju kako bi se izdvojile relevantne značajke koje se koriste kao ulazi za neuronsku mrežu. Prema Bellini i suradnicima [15], ANN se trenira na skupu podataka koji sadrži primjere normalnog i abnormalnog rada stroja, što omogućava mreži da nauči prepoznati obrasce povezane s različitim vrstama kvarova.

Jedna od glavnih prednosti ANN je njihova sposobnost da prepoznaju složene i nelinearne odnose u podacima, što je posebno korisno u dijagnostici kvarova gdje su uzorci često kompleksni i teško ih je identificirati tradicionalnim metodama. Kako navode Nandi i Toliyat

[7], ANN se mogu koristiti za detekciju različitih vrsta kvarova, uključujući slomljene rotor šipke, ekscentričnost, kvarove ležajeva i probleme s namotima statora. Korištenje ANN omogućava visok stupanj točnosti u dijagnostici kvarova jer su mreže sposobne učiti iz velikih količina podataka i prilagoditi se novim informacijama. Ovo je posebno korisno u industrijskim primjenama gdje se uvjeti rada mogu mijenjati, a sustavi za dijagnostiku moraju biti fleksibilni i prilagodljivi. Prema LeCun, Bengio i Hinton [21], ANN se također mogu kombinirati s drugim dijagnostičkim tehnikama, poput spektralnih analiza (FFT, HOS) i analize vibracija, kako bi se poboljšala točnost i pouzdanost dijagnostike.

Implementacija ANN uključuje nekoliko ključnih koraka. Prvo, prikupljaju se i predprocesiraju podaci o radu stroja. Zatim se odabire arhitektura neuronske mreže, uključujući broj slojeva i neurona u svakom sloju. ANN se zatim trenira korištenjem skupa podataka za obuku, nakon čega se potvrđuje na neovisnom skupu podataka kako bi se procijenila njezina točnost. Konačno, trenirana mreža se implementira u stvarnom sustavu za kontinuirano praćenje i dijagnostiku kvarova. ANN su moćan alat za dijagnostiku kvarova u brodskim električnim strojevima, omogućavajući rano otkrivanje problema, smanjujući rizik od ozbiljnih kvarova i produžujući vijek trajanja strojeva. Integracijom ANN u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti.



Slika 6. Umjetne neuronske mreže

Izvor: <https://www.geeksforgeeks.org/artificial-neural-networks-and-its-applications/>, Uredio student

4.2. Fuzzy logika

Fuzzy logika je dijagnostička tehnika koja koristi matematičke modele za rješavanje problema koji uključuju nesigurnost i nepreciznost, čineći je izuzetno korisnom za dijagnostiku kvarova u brodskim električnim strojevima. Za razliku od klasične logike koja radi s jasnim i preciznim vrijednostima (npr. istina ili laž), fuzzy logika omogućuje rad s nejasnim, približnim informacijama, što je često slučaj u stvarnim industrijskim uvjetima. Fuzzy logika se temelji na konceptu fuzzy skupova, gdje elementi imaju stupanj pripadnosti između 0 i 1, umjesto da budu jednostavno uključeni ili isključeni iz skupa. Ovaj pristup omogućuje modeliranje složenih sustava gdje su varijable često neprecizne ili djelomično poznate.

Primjena fuzzy logike u dijagnostici kvarova električnih strojeva uključuje nekoliko koraka. Prvo se definiraju fuzzy skupovi i pripadne funkcije za ulazne varijable koje predstavljaju različite mjerene parametre, poput struje, napona, vibracija i temperature. Zatim se koriste fuzzy pravila za donošenje odluka na temelju ovih ulaznih varijabli. Pravila su obično izražena u obliku „Ako-onda“ izjava, na primjer: „Ako je temperatura visoka i vibracije su velike, onda postoji rizik od kvara ležaja“ [14]. Jedna od glavnih prednosti fuzzy logike je njezina sposobnost da rješava probleme s nesigurnim i nepreciznim podacima, što je posebno korisno u dijagnostici kvarova gdje su mjerene vrijednosti često podložne varijacijama i šumu. Fuzzy logika može integrirati različite izvore podataka i pružiti sveobuhvatan pristup dijagnostici kvarova [15].

Kvarovi statora, poput oštećenja izolacije, mogu se detektirati pomoću fuzzy logike koja analizira promjene u struji i temperaturi. Na primjer, fuzzy sustav može identificirati abnormalna stanja kombiniranjem informacija o porastu temperature i povećanoj harmonijskoj distorziji struje [14]. Slično tome, fuzzy logika može otkriti kvarove rotora analizom promjena u strujnim signalima i vibracijama koje ukazuju na slomljene rotor šipke ili probleme s krajnjim prstenovima.

Fuzzy logika također može biti korištena za dijagnostiku kvarova ležajeva. Na primjer, kombiniranjem informacija o visokofrekventnim vibracijama i promjenama u akustičnoj emisiji, fuzzy sustav može detektirati prisutnost pukotina ili habanja u ležajevima [16]. Također, problemi s ekscentričnošću mogu se otkriti analizom promjena u harmonijskim komponentama struje i vibracija [7].

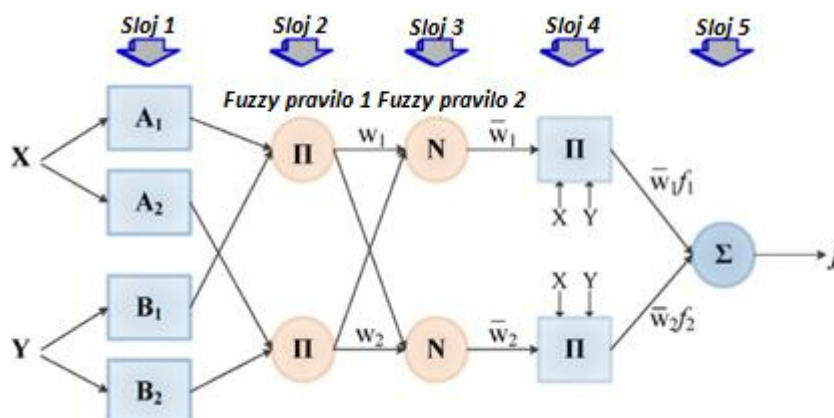
Implementacija fuzzy logike uključuje definiranje fuzzy skupova i pripadnih funkcija za sve relevantne ulazne varijable, formuliranje fuzzy pravila za dijagnostiku te razvoj sustava za donošenje odluka koji koristi ove informacije za identifikaciju potencijalnih kvarova. Fuzzy sustavi se mogu lako integrirati s drugim dijagnostičkim tehnikama, kao što su umjetne neuronske mreže (ANN) i spektralne analize, kako bi se poboljšala točnost i pouzdanost dijagnostike [23].

4.3. Neuro fuzzy sustavi

Neuro-fuzzy sustavi kombiniraju prednosti umjetnih neuronskih mreža (ANN) i fuzzy logike kako bi pružili moćan alat za dijagnostiku kvarova u brodskim električnim strojevima. Ovi sustavi koriste sposobnost ANN za učenje iz podataka i prepoznavanje obrazaca te fleksibilnost fuzzy logike u rukovanju nejasnim i nesigurnim informacijama. Rezultat je sustav koji je sposoban za visoko preciznu dijagnostiku i donošenje odluka u složenim i promjenjivim uvjetima. Neuro-fuzzy sustavi rade na način da neuronske mreže uče pravila fuzzy logike na temelju prikupljenih podataka. To omogućava adaptivno podešavanje fuzzy pravila kako bi sustav mogao bolje prepoznati i klasificirati kvarove. Ključne komponente neuro-fuzzy sustava uključuju ulazni sloj, sloj fuzzifikacije, sloj pravila, sloj defuzzifikacije i izlazni sloj. Primjena neuro-fuzzy sustava u dijagnostici kvarova uključuje nekoliko koraka. Prvo, prikupljaju se podaci o radu stroja, poput strujnih, naponskih, vibracijskih i temperaturnih signala. Ovi podaci se zatim koriste za treniranje neuronske mreže koja uči prepoznati obrasce povezane s normalnim i abnormalnim radom stroja. Fuzzy logika se zatim koristi za definiranje pravila koja opisuju ove obrasce i omogućuju donošenje odluka [14]. Jedna od glavnih prednosti neuro-fuzzy sustava je njihova sposobnost adaptivnog učenja i prilagodbe promjenjivim uvjetima. Ovo je posebno korisno u dijagnostici kvarova gdje se uvjeti rada često mijenjaju, a sustavi za dijagnostiku moraju biti fleksibilni i prilagodljivi. Neuro-fuzzy sustavi mogu se koristiti za detekciju različitih vrsta kvarova, uključujući slomljene rotor šipke, ekscentričnost, kvarove ležajeva i probleme s namotima statora [15].

Kvarovi statora, poput oštećenja izolacije, mogu se detektirati pomoću neuro-fuzzy sustava koji kombinira informacije o struji i temperaturi te adaptivno uči prepoznati obrasce povezane s ovim kvarovima. Na primjer, sustav može identificirati abnormalna stanja kombiniranjem informacija o porastu temperature i povećanoj harmonijskoj distorziji struje [16]. Slično tome,

neuro-fuzzy sustavi mogu otkriti kvarove rotora analizom promjena u strujnim signalima i vibracijama koje ukazuju na slomljene rotor šipke ili probleme s krajnjim prstenovima. Neuro-fuzzy sustavi također mogu biti korišteni za dijagnostiku kvarova ležajeva. Kombiniranjem informacija o visokofrekventnim vibracijama i promjenama u akustičnoj emisiji, sustav može detektirati prisutnost pukotina ili habanja u ležajevima. Također, problemi s ekscentričnošću mogu se otkriti analizom promjena u harmonijskim komponentama struje i vibracija [15]. Implementacija neuro-fuzzy sustava uključuje definiranje fuzzy skupova i pripadnih funkcija za sve relevantne ulazne varijable, formuliranje fuzzy pravila za dijagnostiku te treniranje neuronske mreže kako bi naučila prepoznati obrasce u podacima. Sustav se zatim potvrđuje na neovisnom skupu podataka kako bi se procijenila njegova točnost. Konačno, trenirani neuro-fuzzy sustav se implementira u stvarnom sustavu za kontinuirano praćenje i dijagnostiku kvarova. Neuro-fuzzy sustavi su moćan alat za dijagnostiku kvarova u brodskim električnim strojevima, omogućavajući rano otkrivanje problema, smanjujući rizik od ozbiljnih kvarova i produžujući vijek trajanja strojeva. Integracijom neuro-fuzzy sustava u sustave za održavanje brodova moguće je postići visoku razinu pouzdanosti i operativne učinkovitosti.



Slika 7. Neuro fuzzy sustavi

Izvor: https://www.researchgate.net/figure/Neuro-Fuzzy-system-for-prediction-adapted-from-233_fig4_279520307., Uredio student.

4.4. Strojno učenje (Machine Learning) i duboko učenje (Deep Learning)

Strojno učenje (Machine Learning) i duboko učenje (Deep Learning) su napredne tehnike koje koriste algoritme za analizu podataka i donošenje odluka te imaju značajnu primjenu u dijagnostici kvarova brodskih električnih strojeva. Ove metode omogućuju automatsko učenje

iz podataka bez eksplicitnog programiranja pravila, što ih čini izuzetno fleksibilnim i učinkovitim za rješavanje složenih dijagnostičkih problema.

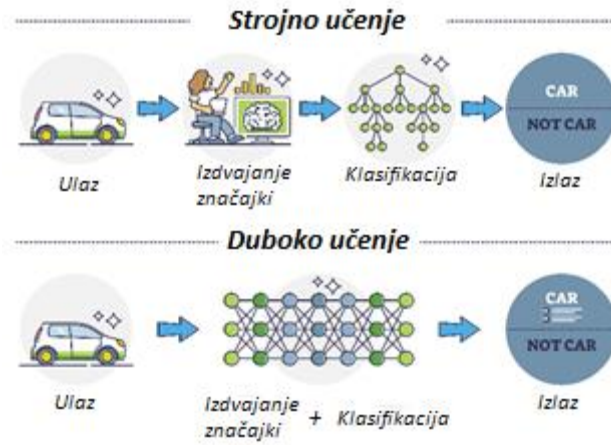
Strojno učenje koristi algoritme koji analiziraju podatke i prepoznaju obrasce kako bi donijeli predikcije ili odluke. U dijagnostici kvarova, strojno učenje može se koristiti za analizu različitih senzorskih podataka poput struje, napona, vibracija i temperature kako bi se identificirali abnormalni obrasci koji ukazuju na kvarove. Algoritmi strojnog učenja, kao što su logistička regresija, podržavajući vektorski strojevi (SVM), K-najbliži susjedi (KNN) i stablo odluke, mogu se trenirati na povijesnim podacima kako bi naučili razlikovati normalne i abnormalne uvjete rada. Jednom trenirani, ovi algoritmi mogu analizirati dolazne podatke u stvarnom vremenu i identificirati potencijalne kvarove s visokim stupnjem točnosti [14].

Primjena strojnog učenja u dijagnostici kvarova uključuje nekoliko koraka. Prvo, prikupljaju se podaci o radu stroja i predprocesiraju kako bi se izdvojile relevantne značajke. Zatim se algoritmi strojnog učenja treniraju na skupu podataka koji sadrži primjere normalnog i abnormalnog rada. Trenirani modeli se zatim koriste za analizu novih podataka i donošenje odluka o prisutnosti kvarova [15].

Duboko učenje je podskup strojnog učenja koji koristi višeslojne neuronske mreže, poznate kao duboke neuronske mreže (DNN), za analizu podataka. DNN su posebno učinkovite u prepoznavanju složenih obrazaca u velikim količinama podataka, što ih čini idealnim za dijagnostiku kvarova u brodskim električnim strojevima. Duboko učenje koristi složene arhitekture kao što su konvolucijske neuronske mreže (CNN) i rekurentne neuronske mreže (RNN) za analizu podataka. CNN su posebno učinkovite za analizu slika i signala, dok su RNN prikladne za analizu sekvencijalnih podataka poput vremenskih serija [21].

Primjena dubokog učenja u dijagnostici kvarova uključuje slične korake kao i strojno učenje, ali s većom složenošću u modeliranju. Podaci se prvo prikupljaju i predprocesiraju, a zatim se koriste za treniranje dubokih neuronskih mreža. Ove mreže mogu automatski naučiti značajke iz podataka bez potrebe za ručnim izdvajanjem značajki. Trenirani modeli se zatim koriste za analizu novih podataka i identifikaciju kvarova [22].

Implementacija strojnog učenja i dubokog učenja uključuje prikupljanje i predprocesiranje podataka, odabir i treniranje odgovarajućih algoritama te validaciju modela na neovisnom skupu podataka kako bi se procijenila njihova točnost. Jednom implementirani, ovi modeli mogu se koristiti za kontinuirano praćenje i dijagnostiku kvarova u stvarnom vremenu.



Slika 8. Srojno učenje i duboko učenje

Izvor: <https://www.turing.com/kb/ultimate-battle-between-deep-learning-and-machine-learning>

Uredio student

5. IMPLEMENTACIJA SUSTAVA ZA DIJAGNOSTIKU KVAROVA NA BRODOVIMA

5.1. Hardverska arhitektura sustava za dijagnostiku

Hardverska arhitektura sustava za dijagnostiku brodskih električnih strojeva ključna je za osiguranje pouzdanosti, točnosti i učinkovitosti dijagnostičkih procesa. Ova arhitektura uključuje razne komponente koje zajedno omogućuju prikupljanje, obradu i analizu podataka kako bi se pravovremeno otkrili kvarovi.

Senzori su temeljna komponenta svakog dijagnostičkog sustava jer omogućuju prikupljanje podataka o radu strojeva. Postoji nekoliko vrsta senzora koji se koriste u dijagnostici brodskih električnih strojeva:

- **Strujni senzori** mjere struju koja prolazi kroz električne komponente stroja i koriste se za analizu strujnih signala (MCSA) [15].
- **Naponski senzori** mjere napon u sustavu i koriste se za detekciju abnormalnosti poput prenapona ili padova napona [15].
- **Vibracijski senzori** mjere vibracije stroja i koriste se za analizu vibracija radi otkrivanja mehaničkih kvarova [15].
- **Temperaturni senzori** mjere temperaturu različitih dijelova stroja, što je ključno za termografsku analizu i detekciju pregrijavanja [15].
- **Akustični senzori** prikupljaju zvučne signale za analizu akustične emisije i detekciju kvarova [15].

Sustavi za prikupljanje podataka (DAQ) prikupljaju signale sa senzora i pretvaraju ih u digitalni format prikladan za daljnju obradu. DAQ sustavi uključuju analogno-digitalne pretvarače (ADC) koji pretvaraju analogne signale iz senzora u digitalne podatke. Ovi sustavi također osiguravaju sinkronizaciju signala i omogućuju prikupljanje podataka u stvarnom vremenu. Procesorske jedinice obrađuju prikupljene podatke kako bi se identificirali potencijalni kvarovi. Uključuju centralne procesorske jedinice (CPU) i grafičke procesorske jedinice (GPU) koje omogućuju brzu obradu velikih količina podataka. GPU-ovi su posebno korisni za primjenu dubokog učenja (Deep Learning) jer omogućuju paralelnu obradu podataka [22].

Sustavi za dijagnostiku zahtijevaju značajne kapacitete za pohranu podataka kako bi se spremili povijesni i trenutni podaci o radu strojeva [12]. Ovi podaci su ključni za treniranje modela strojnog učenja (Machine Learning) i dubokog učenja (Deep Learning), kao i za analizu povijesnih trendova i predikciju budućih kvarova [12].

Komunikacijski moduli omogućuju prijenos podataka između različitih dijelova sustava za dijagnostiku, kao i između dijagnostičkog sustava i centralnih kontrolnih sustava broda. Ovi moduli koriste različite protokole, uključujući Ethernet, Wi-Fi i druge bežične tehnologije, kako bi osigurali pouzdan prijenos podataka u stvarnom vremenu [23]. Prikaz i korisničko sučelje omogućuju operaterima i inženjerima pregled i analizu dijagnostičkih podataka. Grafička sučelja prikazuju podatke u obliku grafova, tablica i upozorenja, što olakšava prepoznavanje abnormalnosti i donošenje odluka. Ova sučelja također omogućuju interakciju s dijagnostičkim sustavom, kao što je konfiguracija senzora, pokretanje analiza i pregled rezultata [23].

Sustavi za dijagnostiku moraju imati pouzdano napajanje kako bi osigurali kontinuirani rad. Redundantni sustavi napajanja, poput baterijskih sustava i generatora, ključni su za osiguranje da dijagnostički sustavi ostanu funkcionalni čak i u slučaju gubitka primarnog napajanja. Redundantnost je također važna za ostale komponente sustava kako bi se osigurala pouzdanost i otpornost na kvarove [12]. Hardverska arhitektura sustava za dijagnostiku brodskih električnih strojeva sastoji se od raznih komponenti koje omogućuju pouzdano prikupljanje, obradu i analizu podataka. Integracijom ovih komponenti, sustavi za dijagnostiku mogu pravovremeno identificirati kvarove, smanjujući rizik od ozbiljnih kvarova i povećavajući pouzdanost i operativnu učinkovitost brodskih sustava [12].

5.2. Softverski algoritmi za obradu podataka i donošenje odluka

Hardverska arhitektura sustava za dijagnostiku brodskih električnih strojeva ključna je za osiguranje pouzdanosti, točnosti i učinkovitosti dijagnostičkih procesa. Ova arhitektura uključuje razne komponente koje zajedno omogućuju prikupljanje, obradu i analizu podataka kako bi se pravovremeno otkrili kvarovi. Senzori su temeljna komponenta svakog dijagnostičkog sustava jer omogućuju prikupljanje podataka o radu strojeva.

Postoji nekoliko vrsta senzora koji se koriste u dijagnostici brodskih električnih strojeva:

- Strujni senzori mjere struju koja prolazi kroz električne komponente stroja i koriste se za analizu strujnih signala (MCSA) [7].
- Naponski senzori mjere napon u sustavu i koriste se za detekciju abnormalnosti poput prenapona ili padova napona [15].
- Vibracijski senzori mjere vibracije stroja i koriste se za analizu vibracija radi otkrivanja mehaničkih kvarova [15].
- Temperaturni senzori mjere temperaturu različitih dijelova stroja, što je ključno za termografsku analizu i detekciju pregrijavanja [15].
- Akustični senzori prikupljaju zvučne signale za analizu akustične emisije i detekciju kvarova [18].

Sustavi za prikupljanje podataka (DAQ) prikupljaju signale sa senzora i pretvaraju ih u digitalni format prikladan za daljnju obradu. DAQ sustavi uključuju analogno-digitalne pretvarače (ADC) koji pretvaraju analogne signale iz senzora u digitalne podatke. Ovi sustavi također osiguravaju sinkronizaciju signala i omogućuju prikupljanje podataka u stvarnom vremenu.

Procesorske jedinice obrađuju prikupljene podatke kako bi se identificirali potencijalni kvarovi. Uključuju centralne procesorske jedinice (CPU) i grafičke procesorske jedinice (GPU) koje omogućuju brzu obradu velikih količina podataka. GPU-ovi su posebno korisni za primjenu dubokog učenja (Deep Learning) jer omogućuju paralelnu obradu podataka [21].

Sustavi za dijagnostiku zahtijevaju značajne kapacitete za pohranu podataka kako bi se spremili povijesni i trenutni podaci o radu strojeva. Ovi podaci su ključni za treniranje modela strojnog učenja (Machine Learning) i dubokog učenja (Deep Learning), kao i za analizu povijesnih trendova i predikciju budućih kvarova [9].

Komunikacijski moduli omogućuju prijenos podataka između različitih dijelova sustava za dijagnostiku, kao i između dijagnostičkog sustava i centralnih kontrolnih sustava broda. Ovi moduli koriste različite protokole, uključujući Ethernet, Wi-Fi i druge bežične tehnologije, kako bi osigurali pouzdan prijenos podataka u stvarnom vremenu [24].

Prikaz i korisničko sučelje omogućuju operaterima i inženjerima pregled i analizu dijagnostičkih podataka. Grafička sučelja prikazuju podatke u obliku grafova, tablica i upozorenja, što olakšava prepoznavanje abnormalnosti i donošenje odluka. Ova sučelja također

omogućuju interakciju s dijagnostičkim sustavom, kao što je konfiguracija senzora, pokretanje analiza i pregled rezultata [23].

Sustavi za dijagnostiku moraju imati pouzdano napajanje kako bi osigurali kontinuirani rad. Redundantni sustavi napajanja, poput baterijskih sustava i generatora, ključni su za osiguranje da dijagnostički sustavi ostanu funkcionalni čak i u slučaju gubitka primarnog napajanja. Redundantnost je također važna za ostale komponente sustava kako bi se osigurala pouzdanost i otpornost na kvarove [12].

5.3. Integracija sustava u brodske operacije i održavanje

Integracija sustava za dijagnostiku kvarova u brodske operacije i održavanje ključna je za osiguranje pouzdanosti, sigurnosti i učinkovitosti brodskih električnih strojeva. Ova integracija omogućuje kontinuirano praćenje stanja strojeva, pravovremeno otkrivanje kvarova i provođenje preventivnog i prediktivnog održavanja, smanjujući rizik od neplaniranih zastoja i skupih popravaka [13]. Prvi korak u integraciji sustava za dijagnostiku je instalacija senzora na ključne točke strojeva. Ovi senzori prikupljaju podatke o struji, naponu, vibracijama, temperaturi i akustičnim emisijama. Prikupljeni podaci se zatim šalju u sustave za prikupljanje podataka (DAQ) koji ih pretvaraju u digitalni format prikladan za daljnju obradu [7]. Nakon prikupljanja podataka, sljedeći korak je obrada i analiza tih podataka pomoću softverskih algoritama. Algoritmi strojnog učenja i dubokog učenja analiziraju podatke kako bi prepoznali obrasce koji ukazuju na prisutnost kvarova. Ovi algoritmi mogu biti implementirani na centralnim procesorskim jedinicama (CPU) ili grafičkim procesorskim jedinicama (GPU) brodskih sustava [21]. Integracija sustava za dijagnostiku u brodske operacije također zahtijeva učinkovitu komunikaciju između dijagnostičkog sustava i drugih brodskih sustava. Komunikacijski moduli omogućuju prijenos podataka između različitih dijelova sustava za dijagnostiku i centralnih kontrolnih sustava broda [24].

Redovito održavanje i ažuriranje sustava za dijagnostiku ključni su za osiguranje njihove pouzdanosti i točnosti. To uključuje provjeru i kalibraciju senzora, ažuriranje softverskih algoritama i provjeru integriteta podataka [12]. Implementacija prediktivnog održavanja temeljenog na rezultatima dijagnostičkih sustava može značajno smanjiti rizik od neplaniranih zastoja i produžiti vijek trajanja strojeva [17].

6. NAPREDNE TEHNIKE I BUDUĆI TRENDVI U DIJAGNOSTICI KVAROVA NA BRODOVIMA

6.1. Internet stvari (IoT) i dijagnostika u stvarnom vremenu na brodovima

Internet stvari (IoT) revolucionira način na koji se provodi dijagnostika kvarova i održavanje brodskih električnih strojeva, omogućujući prikupljanje i analizu podataka u stvarnom vremenu. Integracija IoT tehnologija u brodske sustave donosi mnoge prednosti, uključujući povećanu pouzdanost, učinkovitost i sigurnost operacija. IoT se temelji na umrežavanju fizičkih uređaja opremljenih sensorima, softverom i poveziivošću koja omogućuje prikupljanje i razmjenu podataka. Na brodovima, IoT senzori mogu biti postavljeni na kritične točke električnih strojeva kako bi kontinuirano pratili stanje i performanse tih strojeva. Ti senzori prikupljaju podatke o struji, naponu, vibracijama, temperaturi i drugim relevantnim parametrima [6].

Podaci prikupljeni sa senzora prenose se putem bežičnih ili žičanih mreža do centralnih sustava za obradu podataka. Ovi sustavi koriste napredne algoritme strojnog učenja (Machine Learning) i dubokog učenja (Deep Learning) za analizu podataka u stvarnom vremenu, prepoznavanje obrazaca i otkrivanje abnormalnosti koje ukazuju na prisutnost kvarova [21]. Jedna od ključnih prednosti korištenja IoT tehnologija je mogućnost dijagnostike kvarova u stvarnom vremenu. To omogućuje pravovremenu identifikaciju i otklanjanje problema prije nego što se razviju u ozbiljne kvarove koji bi mogli uzrokovati neplanirane zastoje i skupe popravke. Na primjer, sustavi za analizu vibracija mogu otkriti povećane razine vibracija koje ukazuju na trošenje ležajeva, omogućujući pravovremenu zamjenu oštećenih dijelova [15]. IoT također omogućuje prediktivno održavanje, što je ključno za povećanje pouzdanosti i smanjenje operativnih troškova. Analizom povijesnih podataka i korištenjem modela predikcije, sustavi za održavanje mogu identificirati potencijalne probleme i planirati intervencije prije nego što dođe do kvara. To uključuje zamjenu dijelova na temelju stvarnog stanja, a ne prema fiksnim rasporedima, čime se optimizira uporaba resursa i smanjuje nepotrebno održavanje [7].

Implementacija IoT sustava na brodovima uključuje nekoliko ključnih koraka. Prvo, potrebno je odabrati i instalirati odgovarajuće senzore na kritične točke strojeva. Zatim se uspostavlja mrežna infrastruktura za prijenos podataka do centralnih sustava za obradu. Ti sustavi koriste napredne algoritme za analizu podataka i donošenje odluka u stvarnom vremenu. Konačno,

rezultati analize prikazuju se putem korisničkih sučelja koja omogućuju operaterima i inženjerima da brzo i učinkovito reagiraju na identificirane probleme [6]. Osim tehničkih aspekata, važno je osigurati sigurnost i zaštitu podataka u IoT sustavima. To uključuje implementaciju enkripcije, autentifikacije i drugih sigurnosnih mjera kako bi se spriječio neovlašteni pristup i osigurala integritet prikupljenih podataka. Sigurnost je posebno važna u brodskim aplikacijama gdje kvarovi i pogreške mogu imati ozbiljne posljedice za sigurnost plovidbe i okoliša [13].

Primjeri primjene IoT tehnologija na brodovima uključuju sustave za praćenje stanja motora, generatora, pumpi i drugih kritičnih komponenti. Na primjer, sustavi za praćenje stanja generatora koriste senzore za prikupljanje podataka o temperaturi, vibracijama i struji, koji se zatim analiziraju za otkrivanje abnormalnosti. Pravovremena identifikacija problema omogućuje planiranje održavanja tijekom redovnih zaustavljanja, smanjujući potrebu za hitnim intervencijama i popravcima [24].

6.2. Prediktivno održavanje u pomorskoj industriji

Prediktivno održavanje predstavlja napredni pristup održavanju brodskih električnih strojeva, omogućujući pravovremenu identifikaciju i otklanjanje potencijalnih kvarova prije nego što se dogode ozbiljni problemi. Ovaj pristup koristi analizu podataka i napredne algoritme kako bi se predvidjeli kvarovi na temelju stvarnog stanja opreme, čime se optimiziraju resursi i smanjuju operativni troškovi. Jedan od ključnih elemenata prediktivnog održavanja je prikupljanje podataka u stvarnom vremenu pomoću senzora postavljenih na kritične točke strojeva. Ovi senzori prikupljaju podatke o struji, naponu, vibracijama, temperaturi i drugim parametrima koji se zatim analiziraju kako bi se prepoznali obrasci koji ukazuju na prisutnost kvarova [6]. Korištenje Interneta stvari (IoT) omogućuje kontinuirano praćenje stanja opreme i prijenos podataka do centralnih sustava za obradu.

Analiza prikupljenih podataka provodi se pomoću naprednih algoritama strojnog učenja (Machine Learning) i dubokog učenja (Deep Learning). Ovi algoritmi mogu prepoznati složene obrasce u podacima i predvidjeti kvarove na temelju povijesnih i trenutnih podataka. Na primjer, algoritmi mogu analizirati vibracije motora kako bi otkrili abnormalne frekvencijske komponente koje ukazuju na trošenje ležajeva ili druge mehaničke probleme [21].

Implementacija prediktivnog održavanja uključuje nekoliko ključnih koraka. Prvo, potrebno je identificirati kritične komponente strojeva i instalirati odgovarajuće senzore za prikupljanje podataka. Zatim se podaci prikupljeni sa senzora prenose do centralnih sustava za obradu gdje se analiziraju pomoću naprednih algoritama. Na temelju rezultata analize, sustavi za održavanje mogu planirati intervencije prije nego što dođe do stvarnog kvara, čime se smanjuje rizik od neplaniranih zastoja i skupih popravaka [15].

Prediktivno održavanje donosi brojne prednosti u pomorskoj industriji. Prvo, omogućuje optimizaciju resursa održavanja smanjenjem nepotrebnih intervencija i produljenjem vijeka trajanja opreme. Pravovremeno identificiranje i otklanjanje problema također smanjuje rizik od ozbiljnih kvarova koji bi mogli uzrokovati dugotrajne zastoje i skupe popravke. Osim toga, povećava se pouzdanost i sigurnost brodskih operacija jer se kvarovi otkrivaju i rješavaju prije nego što dovedu do opasnih situacija [7]. Primjeri primjene prediktivnog održavanja u pomorskoj industriji uključuju praćenje stanja motora, generatora, pumpi i drugih kritičnih komponenti. Na primjer, sustavi za praćenje stanja motora mogu koristiti senzore za prikupljanje podataka o temperaturi, vibracijama i struji, koji se zatim analiziraju za otkrivanje abnormalnosti. Pravovremena identifikacija problema omogućuje planiranje održavanja tijekom redovnih zaustavljanja, smanjujući potrebu za hitnim intervencijama i popravcima [12]. Jedan konkretan primjer je praćenje stanja glavnih motora na teretnim brodovima. Senzori postavljeni na motore prikupljaju podatke o radu motora, uključujući vibracije, temperaturu i razine buke. Analiza ovih podataka pomoću algoritama strojnog učenja omogućuje identifikaciju abnormalnih obrazaca koji ukazuju na prisutnost trošenja ili oštećenja. Na temelju ovih informacija, tim za održavanje može planirati zamjenu dijelova ili druge intervencije prije nego što dođe do ozbiljnog kvara, čime se povećava pouzdanost i smanjuju operativni troškovi. Uvođenje prediktivnog održavanja zahtijeva ulaganje u tehnologiju i obuku osoblja, ali dugoročne koristi nadmašuju početne troškove. Korištenjem naprednih tehnologija za prikupljanje i analizu podataka, pomorske tvrtke mogu značajno poboljšati učinkovitost i pouzdanost svojih operacija, smanjujući rizik od zastoja i produžujući vijek trajanja opreme. Integracija prediktivnog održavanja u pomorsku industriju donosi značajne prednosti, uključujući optimizaciju resursa, povećanje pouzdanosti i smanjenje operativnih troškova. Korištenjem naprednih senzora, algoritama strojnog učenja i dubokog učenja, moguće je pravovremeno otkriti i otkloniti kvarove, čime se osigurava visoka razina operativne učinkovitosti i sigurnosti.

6.3. Digitalni blizanci i simulacije za brodske sustave

Digitalni blizanci predstavljaju virtualne modele fizičkih sustava koji repliciraju stvarne uvjete rada u stvarnom vremenu. U pomorskoj industriji, digitalni blizanci omogućuju detaljno praćenje i simulaciju brodskih sustava, pružajući vrijedne uvide za održavanje, optimizaciju i dijagnostiku kvarova. Ova tehnologija koristi senzore za prikupljanje podataka o stvarnim sustavima, koji se zatim koriste za ažuriranje i validaciju digitalnog blizanca. Primjena digitalnih blizanaca u brodskoj industriji uključuje stvaranje virtualnih modela motora, generatora, pumpi i drugih kritičnih komponenti broda. Ti modeli omogućuju simulaciju rada pod različitim uvjetima, predviđanje performansi i identifikaciju potencijalnih problema prije nego što se dogode. Na primjer, digitalni blizanac glavnog motora može simulirati različite scenarije opterećenja i uvjeta rada kako bi se identificirali kritični dijelovi koji su podložni trošenju ili kvarovima [23]. Jedan od ključnih benefita digitalnih blizanaca je mogućnost provođenja složenih simulacija bez rizika za stvarnu opremu. To omogućuje inženjerima da testiraju različite strategije održavanja, optimiziraju operativne parametre i unaprijede dizajn sustava. Digitalni blizanci također omogućuju integraciju podataka u stvarnom vremenu, što znači da se model neprestano ažurira stvarnim podacima prikupljenim sa senzora, osiguravajući točnost i relevantnost simulacija [24].

U pomorskoj industriji, digitalni blizanci mogu se koristiti za optimizaciju rute, smanjenje potrošnje goriva i poboljšanje učinkovitosti rada broda. Na primjer, simulacije mogu pomoći u pronalaženju optimalne brzine i putanje broda kako bi se smanjila potrošnja goriva i emisije štetnih plinova. Također, digitalni blizanci mogu pomoći u planiranju održavanja identificiranjem kritičnih točaka koje zahtijevaju pažnju [24]. Digitalni blizanci donose značajne prednosti za održavanje i operativnu učinkovitost brodova, uključujući smanjenje rizika, optimizaciju resursa i poboljšanje sigurnosti. Integracijom digitalnih blizanaca u brodske operacije, pomorske tvrtke mogu povećati pouzdanost svojih sustava i smanjiti operativne troškove.

6.4. Integracija s pametnim brodskim sustavima i industrijom 4.0

Industrija 4.0, koja uključuje digitalizaciju i integraciju pametnih tehnologija u industrijske procese, donosi značajne promjene i u pomorskoj industriji. Integracija pametnih brodskih sustava s tehnologijama kao što su IoT, umjetna inteligencija (AI), strojno učenje (ML) i

digitalni blizanci omogućuje naprednu dijagnostiku, optimizaciju i automatizaciju brodskih operacija. Pametni brodski sustavi koriste IoT senzore za prikupljanje podataka u stvarnom vremenu o svim aspektima rada broda, uključujući motore, navigaciju, sustave za gorivo i druge kritične komponente. Ovi podaci se zatim analiziraju pomoću AI i ML algoritama kako bi se identificirali obrasci i predvidjeli potencijalni kvarovi prije nego što se dogode. Integracija s pametnim sustavima omogućuje automatsko donošenje odluka i provođenje korektivnih mjera u stvarnom vremenu [9]. Jedan primjer primjene pametnih sustava u brodskoj industriji je optimizacija potrošnje goriva. Korištenjem podataka prikupljenih sa senzora i analize putem AI algoritama, sustav može optimizirati brzinu i rutu broda kako bi se smanjila potrošnja goriva i emisije CO₂. Također, pametni sustavi mogu automatski prilagoditi radne parametre motora kako bi se povećala učinkovitost i smanjilo trošenje [23].

Industrija 4.0 također omogućuje napredne mogućnosti održavanja, kao što je prediktivno održavanje koje koristi analizu podataka za planiranje intervencija prije nego što dođe do kvara. Integracija pametnih sustava s digitalnim blizancima omogućuje kontinuirano praćenje i simulaciju rada brodskih sustava, pružajući precizne i ažurirane informacije za donošenje odluka o održavanju [15]. Integracija s pametnim brodskim sustavima također donosi poboljšanja u sigurnosti. Korištenjem naprednih senzora i AI algoritama, moguće je pratiti stanje kritičnih sustava u stvarnom vremenu i automatski detektirati i reagirati na opasne situacije, poput curenja goriva, pregrijavanja ili abnormalnih vibracija. To povećava sigurnost posade i smanjuje rizik od ozbiljnih incidenata na moru [24].

Primjeri primjene pametnih brodskih sustava uključuju automatsko praćenje stanja trupa broda pomoću senzora za detekciju korozije i strukturalnih oštećenja te korištenje AI za optimizaciju teretnog prostora kako bi se maksimalno iskoristio kapacitet broda uz minimalnu potrošnju goriva. Ovi sustavi također mogu integrirati podatke iz različitih izvora, uključujući meteorološke podatke, podatke o prometu na moru i druge relevantne informacije, kako bi se optimizirale operacije broda u stvarnom vremenu [24].

6.5. Tehnička ograničenja i složenost sustava u brodskom okruženju

Implementacija naprednih dijagnostičkih sustava na brodovima suočava se s tehničkim ograničenjima i složenošću. Brodsko okruženje karakteriziraju ekstremni uvjeti, poput vibracija, visokih temperatura, vlage i slanosti, koji mogu utjecati na performanse i

dugovječnost senzora i drugih elektroničkih komponenti [14]. Osim toga, brodski sustavi često uključuju složene i međusobno povezane komponente, što otežava integraciju i sinkronizaciju senzorskih mreža. Primjerice, instalacija senzora za vibracije i temperature zahtijeva pažljivo planiranje kako bi se osigurala njihova funkcionalnost i otpornost na teške uvjete. Isto tako, prikupljanje i obrada podataka u stvarnom vremenu zahtijevaju pouzdanu mrežnu infrastrukturu koja može biti izazovna za implementaciju na brodu zbog ograničenog prostora i dostupnih resursa [24].

Pouzdanost i točnost dijagnostičkih metoda ključni su za njihovu učinkovitost. U pomorskim uvjetima, gdje su strojevi izloženi ekstremnim uvjetima, osiguranje visoke pouzdanosti senzora i točnosti podataka može biti izazovno. Pogreške u prikupljanju i analizi podataka mogu dovesti do lažnih alarma ili propuštanja stvarnih kvarova, što može imati ozbiljne posljedice [20]. Primjena naprednih algoritama strojnog učenja i dubokog učenja može poboljšati točnost dijagnostičkih sustava, ali zahtijeva kvalitetne podatke za treniranje modela. Ograničeni pristup povijesnim podacima i varijacije u operativnim uvjetima mogu utjecati na performanse ovih algoritama. Stoga je važno kontinuirano prikupljati i analizirati podatke kako bi se poboljšala točnost i pouzdanost dijagnostičkih metoda [17].

Sigurnost i privatnost podataka ključni su aspekti u implementaciji sustava za dijagnostiku kvarova na brodovima. Prikupljeni podaci o radu strojeva i dijagnostički rezultati mogu biti osjetljivi i zahtijevaju odgovarajuću zaštitu od neovlaštenog pristupa i kibernetičkih prijetnji [13]. Implementacija sigurnosnih mjera, poput enkripcije podataka, autentifikacije korisnika i sigurnosnih protokola, ključna je za zaštitu podataka. Osim toga, potrebno je razviti politike i procedure za upravljanje podacima kako bi se osigurala privatnost i integritet podataka. Brodovi koji koriste IoT tehnologije i povezane sustave posebno su ranjivi na kibernetičke napade, što zahtijeva dodatnu pažnju i resurse za zaštitu mrežne infrastrukture [13]. Primjeri iz prakse pokazuju da su mjere zaštite podataka ključne za uspješnu implementaciju dijagnostičkih sustava. Na primjer, na jednom teretnom brodu implementirane su napredne sigurnosne mjere za zaštitu podataka prikupljenih sa senzora, uključujući enkripciju podataka i redovite sigurnosne provjere kako bi se osigurala pouzdanost i sigurnost sustava [24]. Iako sustavi za dijagnostiku kvarova donose brojne prednosti za brodsku industriju, suočavaju se s izazovima i ograničenjima. Tehnička složenost, visoki troškovi implementacije, pouzdanost i točnost dijagnostičkih metoda te sigurnost podataka ključni su aspekti koje je potrebno naglasiti kako bi se osigurala uspješna primjena ovih sustava na brodovima [24].

7. ZAKLJUČAK

Dijagnostika kvarova na brodskim električnim strojevima ključna je za osiguranje sigurnih, pouzdanih i ekonomičnih brodskih operacija. Integracija naprednih dijagnostičkih sustava omogućuje pravovremeno otkrivanje i otklanjanje kvarova, optimizaciju resursa za održavanje i produljenje vijeka trajanja opreme. Iako postoje izazovi u implementaciji i održavanju ovih sustava, prednosti koje donose značajno nadmašuju troškove, čineći ih neophodnim alatom za suvremenu pomorsku industriju.

Napredni dijagnostički sustavi, poput analize struje stroja (MCSA), analize vibracija, termografske analize i akustične emisije, pružaju detaljan uvid u stanje brodskih električnih strojeva. Tehnologije temeljene na umjetnoj inteligenciji, poput umjetnih neuronskih mreža, fuzzy logike i strojnog učenja, dodatno poboljšavaju točnost i učinkovitost dijagnostike. Korištenjem ovih tehnologija, moguće je predvidjeti kvarove prije nego što do njih dođe, čime se smanjuje rizik od neplaniranih zastoja i produžuje vijek trajanja opreme.

Nastavak istraživanja i razvoja u ovom području bit će ključan za daljnje unapređenje održavanja i operativne učinkovitosti brodova u budućnosti. Usvajanjem novih tehnologija i naprednih algoritama, pomorska industrija može postići značajna poboljšanja u pouzdanosti, sigurnosti i ekonomičnosti brodskih operacija. Digitalni blizanci i Internet stvari (IoT) predstavljaju posebne prilike za inovacije, omogućujući stvaranje detaljnih virtualnih modela brodskih sustava koji mogu simulirati stvarne uvjete rada u stvarnom vremenu. Ovo omogućava inženjerima da testiraju različite scenarije i strategije održavanja bez rizika za stvarnu opremu.

Također, kontinuirano prikupljanje i analiza podataka te razvoj prediktivnih modela pridonijet će boljem razumijevanju i upravljanju radom brodskih sustava, čime će se povećati ukupna efikasnost i smanjiti rizici povezani s kvarovima. Korištenje naprednih senzora za prikupljanje podataka o struji, naponu, vibracijama, temperaturi i drugim parametrima omogućuje stvaranje sveobuhvatne baze podataka koja se može koristiti za kontinuirano poboljšanje algoritama dijagnostike.

Sigurnost i privatnost podataka također su ključni aspekti koje je potrebno uzeti u obzir pri implementaciji ovih sustava. Prikupljeni podaci moraju biti adekvatno zaštićeni od neovlaštenog pristupa i kibernetičkih prijetnji kako bi se osigurala cjelovitost i pouzdanost dijagnostičkih sustava. Implementacija sigurnosnih mjera, poput enkripcije, autentifikacije i sigurnosnih protokola, ključna je za zaštitu osjetljivih informacija.

Ekonomski aspekti implementacije naprednih dijagnostičkih sustava također zahtijevaju pažnju. Iako početna ulaganja mogu biti značajna, dugoročne koristi u smislu smanjenih troškova održavanja, povećane pouzdanosti i produženog vijeka trajanja opreme opravdavaju te troškove. Posebno je važno razviti strategije koje omogućuju manjih brodarskim tvrtkama s ograničenim financijskim resursima da usvoje ove tehnologije.

Zaključno, dijagnostika kvarova na brodskim električnim strojevima predstavlja ključni element za osiguranje sigurne, pouzdane i ekonomične brodske operacije. Daljnji razvoj i implementacija naprednih dijagnostičkih tehnologija, uz rješavanje tehničkih i ekonomskih izazova, omogućit će pomorskoj industriji da postigne značajna poboljšanja u održavanju i operativnoj učinkovitosti, osiguravajući održiv rast i konkurentnost u budućnosti.

LITERATURA

1. Bianchi, N., 2005. *Electrical Machine Analysis Using Finite Elements*. CRC Press, pp. 25-45.
2. Cardoso, A.J.M. & Saraiva, E.S., 1998. Computer-aided detection of airgap eccentricity in operating three-phase induction motors by Park's vector approach. *IEEE Transactions on Industry Applications*, 34(5), pp. 1189-1196.
3. Haji, M. & Toliyat, H.A., 2001. Pattern Recognition - A Technique for Induction Machines Rotor Broken Bar Detection. *IEEE Transactions on Energy Conversion*, 16(4), pp. 312-317.
4. Kliman, G.B. & Stein, J., 1990. Methods of motor current signature analysis. *Electric Machines and Power Systems*, 19(5), pp. 855-867.
5. Lipo, T.A., Introduction to AC Machine Design. Unpublished manuscript.
6. Nguyen, H. P., Nguyen, P. Q. P., Nguyen, D. K. P., Bui, V. D., & Nguyen, D. T. Application of IoT Technologies in Seaport Management. Academy of Politics Region II, Ho Chi Minh City, Vietnam; PATET Research Group, Ho Chi Minh City University of Transport, Ho Chi Minh City, Vietnam; Faculty of Business Administration, HUTECH University, Ho Chi Minh City, Vietnam.
7. Nandi, S., Toliyat, H.A. & Li, X., 2005. Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review. *IEEE Transactions on Energy Conversion*, 20(4), pp. 719-729.
8. S. Nandi, R. M. Bharadwaj and H. A. Toliyat, "Performance analysis of a three-phase induction motor under mixed eccentricity condition," in *IEEE Transactions on Energy Conversion*, vol. 17, no. 3, pp. 392-399, Sept. 2002.
9. Yu, T., & Wang, X. (2020). Real-Time Data Analytics in Internet of Things Systems. In *Handbook of Real-Time Computing* (pp. 1-28). Springer, Singapore.
10. Tanaka, T., 1986. Partial Discharge Measurement and Its Applications. *IEEE Transactions on Electrical Insulation*, 21(6), pp. 899-905.
11. Toliyat, H.A. & Al-Nauim, A., 1999. Simulation and Detection of Dynamic Air-Gap Eccentricity in Salient-Pole Synchronous Machines. *IEEE Transactions on Industry Applications*, 35(1), pp. 103-112.
12. Vas, P., 1999. *Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines*. Oxford University Press.

13. Williams, D., 2021. Cybersecurity in Maritime Operations. *International Journal of Maritime Engineering*, 163(4), pp. 455-467.
14. Tang, W., & Haque, M. M. (2021, September). A review on Deep Learning theory and its application to fault diagnosis of electric motors. *Shaanxi University of Science and Technology*.
15. Bellini, A., Filippetti, F., Tassoni, C. & Capolino, G.A., 2008. Advances in Diagnostic Techniques for Induction Machines. *IEEE Transactions on Industrial Electronics*, 55(12), pp. 4109-4120.
16. Sakhi, A., El Hossaini, H., & Touati, M. (2016). A neuro-fuzzy inference system for fault diagnosis in electrical machines. *International Journal of Electrical Power & Energy Systems*, 79, 500-505.
17. Dorrell, D.G., et al., 1997. Analysis of Airgap Eccentricity in Brushless DC Motors Using Finite Element Methods. *IEEE Transactions on Magnetics*, 33(5), pp. 4209-4212.
18. Thomson, W.T. & Stewart, C., 1997. On-line Current Monitoring to Detect Airgap Eccentricity in Large Squirrel-Cage Induction Motors. *IEE Proceedings - Electric Power Applications*, 144(2), pp. 155-160.
19. Elkasabgy, N.M., et al., 1992. Detection of Broken Bars in the Cage Rotor of an Induction Motor Using Complex Wavelet Transform. *IEEE Transactions on Industry Applications*, 28(1), pp. 165-171.
20. Hong, J., Lee, S. B., Kral, C., & Haumer, A. (2011, October). Detection of Airgap Eccentricity for Permanent Magnet Synchronous Motors Based on the d-Axis Inductance. In *Proceedings of the 2011 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics & Drives (SDEMPED)* (pp. 378-384).
21. LeCun, Y., Bengio, Y., & Hinton, G., 2015. Deep learning. *Nature*, 521(7553), pp. 436-444.
22. Goodfellow, I., Bengio, Y., & Courville, A., 2016. *Deep Learning*. MIT Press.
23. Kaštelan, N., Vidan, P., Assani, N., & Miličević, M. (2024). Digital Horizon: Assessing Current Status of Digitalization in Maritime Industry. *University of Split, Faculty of Maritime Studies, Split, Croatia*.
24. Aslam, S., Herodotou, H., Garro, E., Martínez-Romero, Á., Burgos, M. A., Cassera, A., Papas, G., Dias, P., & Michaelides, M. P. (2023). IoT for the Maritime Industry: Challenges and Emerging Applications. In *Proceedings of the 18th Conference on Computer Science and Intelligence Systems* (pp. 855–858). *ACSIS*, 35.

POPIS ILUSTRACIJA

Slika 1. Dijelovi elektromotora	2
Slika 2. Pukotina u ležaju zbog zamora materijala	4
Slika 3. Kvarovi povezani s ekscentričnošću	9
Slika 4. Analiza struje stroja (MCSA).....	14
Slika 5. Toplinska slika asinkronog elektromotora s dvije slomljene šipke rotora	16
Slika 6. Umjetne neuronske mreže.....	22
Slika 7. Neuro fuzzy sustavi.....	25
Slika 8. Srojno učenje i duboko učenje	27