

Sustav za dijagnostiku i predviđanje kvarova

Labaduk, Filip

Undergraduate thesis / Završni rad

2020

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:187:865378>

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

Download date / Datum preuzimanja: **2024-07-11**



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

FILIP LABAĐUK

SUSTAV ZA DIJAGNOSTIKU I PREDVIĐANJE KVAROVA

ZAVRŠNI RAD

Rijeka, 2020.

SVEUČILIŠTE U RIJECI

POMORSKI FAKULTET

SUSTAV ZA DIJAGNOSTIKU I PREDVIĐANJE KVAROVA

DIAGNOSTIC AND FAULT PREDICTION SYSTEM

ZAVRŠNI RAD

Kolegij: Održavanje elektroničkih sustava

Mentor: doc. dr. sc. Jasmin Čelić

Komentor: dr. sc. Robert Baždarić

Student: Filip Labađuk

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0135239733

Rijeka, rujan, 2020.

Student: Filip Labađuk

Studijski program: Elektroničke i informatičke tehnologije u pomorstvu

JMBAG: 0135239733

IZJAVA O SAMOSTALNOJ IZRADI ZAVRŠNOG RADA

Kojom izjavljujem da sam završni rad s naslovom *Sustav za dijagnostiku i predviđanje kvarova* izradio samostalno pod mentorstvom doc. dr. sc. Jasmina Čelića i komentorstvom dr. sc. Roberta Baždarića.

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 prafrazirajući naveo u završnom radu na uobičajen, standardan način citirao sam i povezo fusnotama i korištenim bibliografskim jedinicama, te nijedan dio rada ne krši bilo čija autorska prava. Rad je pisan u duhu hrvatskog jezika.

Suglasan sam s trajnom pohranom završnog rada u cjelovitom tekstu u mrežnom digitalnom repozitoriju Pomorskog fakulteta Sveučilišta u Rijeci te Nacionalnom repozitoriju Nacionalne i sveučilišne knjižnice.

Za navedeni rad dozvoljavam sljedeća prava i razinu pristupa mrežnog objavljivanja_

- a) rad u otvorenom pristupu
- b) pristup svim korisnicima znanosti i visokog obrazovanja RH
- c) pristup korisnicima matične ustanove
- d) rad nije dostupan.

Student:

__ Labađuk Filip _____

(potpis)

Ime i prezime studenta: Filip Labađuk

SAŽETAK

Umjetne neuronske mreže funkcioniraju na principu umjetne inteligencije koja imitira rad čovjeka. Prva ideja o neuronskim mrežama pojavila se sredinom 19. stoljeća, a danas ima velik značaj prilikom dijagnosticiranja kvarova u brodskom sustavu. Kvarovi su prisutni u svim sustavima, a karakterizira ih prestanak rada sustava ili ometanje normalnog rada istog. Dijagnostički sustav temeljem na neuronskim mrežama otkriva oštećenja, kvar ili zastoj na principu prikupljenih podataka koje obrađuje, i pokazuje ih kao informaciju. Postoje različite metode i strategije održavanja sustava, a najučestalije metode održavanja su: korektivno, preventivno i plansko održavanje. Odvijanje dijagnostičkog postupka temelji se na početku procesuiranja podataka, izvlačenju bitnih podataka, procjeni radnog stanja te predviđanju preostalog radnog vijeka bez kvarova. Značajno dostignuće u pomorskom sustavu su autonomni brodovi koji rade na principu umjetne inteligencije. Za ovu vrstu brodova je karakteristično da imaju već ugrađen sustav dijagnosticiranja, te da je održavanje istih značajno smanjeno nego što je to slučaj kod drugih brodova.

Ključne riječi: dijagnosticiranje kvarova, kvar, pomorski sustav, neuronske mreže, autonomni brodovi.

SUMMARY

Artificial neural networks function on the principle of artificial intelligence that mimics human work. The first idea of neural networks appeared in the mid-19th century, and today it is of great importance in diagnosing faults in the ship's system. Faults are present in all systems, and they are characterized by the termination of the system or interference with its normal operation. A neural network-based diagnostic system detects damage, malfunction, or downtime based on the principle of the data it processes, and displays it as information. There are different methods and strategies of system maintenance, and the most common maintenance methods are: corrective, preventive and planned maintenance. The conduct of the diagnostic procedure is based on the beginning of data processing, extraction of important data, assessment of the working condition and prediction of the remaining service life without failures. A significant achievement in the maritime system are autonomous ships operating on the principle of artificial intelligence. It is characteristic of this type of ship that they already have a built-in diagnostic system, and that their maintenance is significantly reduced than is the case with other ships.

Key words: fault diagnosis, failure, marine system, neural networks, autonomous ships.

SADRŽAJ

1. UVOD	1
1.1. Predmet i cilj rada.....	1
1.2. Metodologija rada.....	1
1.3. Analiza sadržaja.....	2
2. UMJETNA NEURONSKA MREŽA	3
2.1. Definicija i karakteristike umjetne neuronske mreže	4
2.2. Vrste umjetnih neurona	5
2.3. Višeslojna neuronska mreža.....	9
3. OSNOVNE ZNAČAJKE KVAROVA.....	13
3.1. Stanje sustava „u kvaru“	13
3.2. Podjela kvarova	14
4. VRSTE ODRŽAVANJA	15
4.1. Korektivno održavanje	15
4.2. Preventivno održavanje	16
4.3. Plansko održavanje	18
5. DIJAGNOSTIKA KVAROVA	20
5.1. Definicija dijagnostike.....	20
5.2. Sustav za dijagnostiku kvarova	20
6. SUSTAVI S NEURONSKIM MREŽAMA ZA NADZOR I DIJAGNOSTIKU KVAROVA.....	22
6.1. Opimizacija dijagnostičkog sustava neuronskih mreža	22
6.2. Eksperimentalni postav za dijagnostiku kvarova	25
7. ODRŽAVANJE NA AUTONOMNIM BRODOVIMA	26
7.1. Razvoj automatizacije na brodu	27
7.2. DNV GL Autonomni brodovi	29

8. ZAKLJUČAK.....	32
POPIS LITERATURE	33
POPIS SLIKA	35
POPIS TABLICA.....	36

1. UVOD

1.1. Predmet i cilj rada

Predmet završnog rada usmjeren je na analizu sustava za dijagnostiku i predviđanje kvarova u pomorstvu. Slijedom navedenog završni rad ima opće i specifične ciljeve. Opći ciljevi rada odnose se na detaljnu analizu teorijskog aspekta i to:

- definiciju, karakteristike i vrste umjetne neuronske mreže,
- osnovne značajke kvarova,
- podjelu kvarova,
- vrste održavanja i
- dijagnostiku kvarova.

Za potrebe realizacije specifičnog cilja rada analizirani su sustavi s neuronskim mrežama za nadzor i dijagnostiku kvarova te održavanje na autonomnim brodovima.

1.2. Metodologija rada

Sukladno definiranom predmetu i ciljevima istraživanja u završnom radu koristit će se različite metode, a to su:

- **Metoda dedukcije:** deduktivna metoda je sustavna i dosljedna primjena deduktivnog načina zaključivanja u kojemu se iz općih sudova izvode posebni i pojedinačni. Iz općih postavki dolazi se do konkretnih pojedinačnih zaključaka, iz jedne ili više tvrdnji izvodi se neka nova tvrdnja koja proizlazi iz prethodnih tvrdnji.
- **Metoda indukcije:** donošenje zaključaka o općem sudu na temelju pojedinačnih činjenica.
- **Metode analize:** postupak raščlanjivanja složenih misaonih tvorevina na jednostavnije sastavne dijelove.

- **Metoda sinteze:** postupak spajanja jednostavnih misaonih tvorevina u složene povezujući ih u jedinstvenu cjelinu.¹

1.3. Analiza sadržaja

Završni rad podijeljen je u osam poglavlja koji zajedno predstavljaju logički povezanu cjelinu. U uvodnom poglavlju definira se predmet, cilj, metodologija i sadržaj završnog rada. u drugom poglavlju govori se o umjetnoj neuronskoj mreži, odnosno o njezinim karakteristikama i vrstama umjetnih neurona. U trećem poglavlju analiziraju se osnovne značajke kvarova, dok se u četvrtom poglavlju naglasak stavlja na vrste održavanja (korektivno, preventivno i plansko održavanje). U petom poglavlju govori se o dijagnostici kvarova s aspekta definiranja dijagnostike i sustava za dijagnostiku kvarova. U šestom poglavlju analizira se princip rada sustava s neuronskim mrežama za nadzor i dijagnostiku kvarova, dok se u sedmom poglavlju govori o održavanju autonomnih brodova. Zaključak predstavlja sintezu svega iznesenog u radu, dok se na kraju rada nalazi popis relevantne literature, slika i tablica koje su korištene prilikom pisanja završnog rada.

¹ Zelenika, R. (2000). Metodologija i tehnologija izrade znanstvenog i stručnog djela; Sveučilište u Rijeci, Rijeka, str. 368.


2. UMJETNA NEURONSKA MREŽA

Umjetna inteligencija nastoji imitirati mozak živih bića, a pogotovo ljudski s obzirom da je to vrhunac inteligencije koju poznajemo. Čovjek ima sposobnost učenja koristeći različite strategije i metode, napreduje preko svojih iskustava te je izrazito kreativan i ima logiku odabira ispravnih hipoteza i sudova.

Učenje i obavljanje promjene nad samim sobom je jedan od najbitnijih aspekata umjetne inteligencije. S time možemo reći da je sustav koji može imitirati ljudski mozak jako inteligentan. Ljudski mozak se sastoji od velikog broja živčanih stanica ili neurona u kojima se obrađuje veliki broj informacija u isto vrijeme tj. paralelno. Bolje razumijevanje rada ljudskog mozga su nam omogućila neurofiziološka istraživanja koja nam ukazuju na to da je najbolji model mozga onaj koji može obrađivati različite podatke paralelno. Područje računarstva koje se bavi takvim načinom obrade podataka zove se neuro-računarstvo.²

Prva ideja o mogućnosti nastanka umjetnih neuronskih mreža (Slika 1.) potječe još iz 1940. godine, s fakulteta *Massachusetts Institute of Technology*, gdje su McCulloch i Pitts istražujući neurofiziološke karakteristike živih bića objavili matematički model neuronske mreže na temelju teorije automata. Tadašnji problem bio je u tome što računala nisu imala procesnu moć kako bi se uspjela realizirati umjetna neuronska mreža. Tek kasnih pedesetih godina prošlog stoljeća, pojavom LSI računala dolazi se do realizacije prvih praktičnih ostvarenja te je opet cijela ideja o nastanku umjetnih neuronskih mreža i umjetne inteligencije zaustavljena sve do 1990. godine.

² FliperWorld.org. (2019): Neuronske mreže: primjer, definicija, vrijednost, opseg, dostupno: <https://hr.flipperworld.org/pc/neuronske-mreze-primjer-definicija-vrijednost-opseg> (pristupljeno 15.08.2020.)



Slika 1. Vremenska lentu konceptualnog modela umjetne neuronske mreže od 1980. do 2010.

Izvor: <https://hr.flipperworld.org/pc/neuronske-mreze-primjer-definicija-vrijednost-opseg> (pristupljeno i preuzeto 15.08.2020.)


U današnje vrijeme umjetna inteligencija postala je nezaobilazan koncept pri ostvarivanju automatizacije i inteligentnih sustava. Zbog toga se rade posebna istraživanja na području arhitekture računala koja bi na bolji i učinkovitiji način realizirala umjetne neuronske mreže od konvencionalne Von Neumanove arhitekture računala.

2.1. Definicija i karakteristike umjetne neuronske mreže

Neuronska mreža je skup međusobno povezanih jednostavnih procesnih elemenata, jedinica ili čvorova, čija se funkcionalnost temelji na biološkom neuronu i koji služe distribuiranoj paralelnoj obradi podataka.³ Jedna od odlika neuronskih mreža je da su dobre u procjeni nelinearnosti, što znači da mogu raditi s nejasnim podacima koje mogu dobivati iz senzora, kamera i mikrofona. Stoga su otporne na greške u podacima za razliku od konvencionalnih metoda, gdje su greške u podacima fatalne. Mogu raditi s velikim brojem varijabli ili parametara te su sposobne prilagoditi se i formirati određeno znanje učeći iz iskustava koje dobivaju iz okoline. Neuronske mreže odlično rješavaju probleme klasifikacije i predviđanja,

³ Dalbello Bašić, B., Čupić, M., Šnajder, J. (2012). Umjetne neuronske mreže, Fakultet elektronike i računarstva Sveučilišta u Zagrebu, Zagreb, str. 8.

odnosno općenito sve probleme kod kojih postoji odnos između ulaznih i izlaznih varijabli, bez obzira na visoku složenost te veze.⁴ Jedna od odlika Umjetnih neuronskih mreža je jednostavnost upotrebe samog sustava, velika tolerancija na buku, te njezina široka primjena u raznim poljima kao što je logistika, poloprivreda, elektronika, medicina te razne vrste industrije. U današnje vrijeme sve je veći interes u primjeni umjetnih neuronskih mreža kao sustav za dijagnostiku kvarova koji predstavlja održivi matematički alat za rješavanje nelinearnih problema. Iako postoje mnoge vrste umjetnih neuronskih mreža, njegovo osnovno načelo je isto tj. slično, a mogu se smatrati univerzalnim aproksimatorima. Sastoji se od ulaznog sloja, izlaznog sloja i skrivenog sloja koji se nalazi između njih. Svaki sloj povezan je preko neurona ili čvorova koji sadrže težinski koeficijent koji utječe na cjelokupnu strukturu umjetne neuronske mreže.



Slika 2. Arhitektura Umjetne neuronske mreže

Izvor: <https://techvidvan.com/tutorials/artificial-neural-network/>


(pristupljeno i preuzeto 24.9.2020.)

2.2. Vrste umjetnih neurona

Model umjetnog neurona koji imitira funkcionalnost biološkog neurona ostvaren je pomoću McCulloch-Pitts modela koji se naziva Threshold Logic Unit ili skraćeno TLU. Model se bazira na sljedećem principu: ulazni signali opisani su brojevanim iznosom te se množe težinskim faktorom pomoću kojeg se opisuje jakost sinapsi. Signali koji su pomnoženi

⁴ Dalbelo Bašić, B., Čupić, M., Šnajder, J. (2012). Umjetne neuronske mreže, Fakultet elektronike i računarstva Sveučilišta u Zagrebu, Zagreb, str. 9.

težinskim faktorom zbrajaju se istovrsno zbrajanju potencijala u tijelu stanice. Ako se dobije iznos koji je iznad definiranog praga, taj umjetni neuron će dati izlazni signal (Slika 3.).



Slika 3. Model umjetnog neurona koji imitira funkcionalnost biološkog neurona


Izvor: Dalbello Bašić, B., Čupić, M., Šnajder, J. (2012). Umjetne neuronske mreže, Fakultet elektronike i računarstva Sveučilišta u Zagrebu, Zagreb, str. 8.

Umjetni neuron prikazan na Slici 2. može se razmatrati prema ugrađenoj prijenosnoj funkciji. Jedna od tih funkcija, ujedno i najčešći oblik, je aktivacijska funkcija:

$$f(net) = net$$

Takva vrsta aktivacijske funkcije specifična je za vrstu umjetnog neurona zvanog ADALINE (*eng.*). Težinska suma njegovih ulaza je upravo izlaz iz takve jedinice.

Korištenjem funkcije skoka ili praga dobiva se druga procesna jedinica, koja se naziva *Threshold Logic Unit* čime se dobiva Booleov izlaz, a isto je prikazano Slikom 4.




Slika 4. Threshold Logic Unit

Izvor: Dalbello Bašić, B., Čupić, M., Šnajder, J. (2012). Umjetne neuronske mreže, Fakultet elektronike i računarstva Sveučilišta u Zagrebu, Zagreb, str. 8.

Do sada se razmatralo kako umjetni neuron radi. U nastavku će se prikazati kako možemo umjetni neuron primjeniti u nekoliko Booleovih funkcija. Na ulazima ćemo imati Booleov ulaz te ćemo stoga imati i Booleov izlaz te u suštini će neuron učiti Booleove funkcije. Ovaj način učenja je koristan jer će preko Booleove funkcije neuron donositi odluke ovisno o ulaznim varijablama.

- I logička funkcija




Slika 5. I logička funkcija u umjetnom neuronu

Izvor: <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>

(pristupljeno i preuzeto 24.9.2020.)

Kod ove funkcije ćemo aktivirati funkciju praga ako su nam svi ulazi na visokoj razini tj. ako su svi ulazi upaljeni ili su jednaki binarnom broju 1. Stoga nam je funkcija praga $f(\text{net})=3$.

- ILI logička funkcija




Slika 6. ILI logička funkcija u umjetnom neuronu

Izvor: <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>

(pristupljeno i preuzeto 24.9.2020.)

Neuron logičke funkcije ILI će se aktivirati ako nam je bilo koji od ulaza x na visokoj razini te nam je funkcija praga izražena $f(\text{net})=1$.

- Funkcija s inhibicijskim ulazom



Slika 7. Funkcija s inhibicijskim ulazom u umjetnom neuronu

Izvor: <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>

(pristupljeno i preuzeto 24.9.2020.)

Kod ove vrste imamo jedan normalan ulaz x_1 i inhibicijski ulaz x_2 . U ovom slučaju je vidljivo da će nam na izlazu biti 0 tj. da se neće aktivirati funkcija praga kada god nam je inhibicijski ulaz x_2 jednak 1. Iz toga možemo zaključiti da će na izlazu biti 1 samo ako nam je inhibicijski ulaz jednak 0 što je vidljivo iz postavljene funkcije $x_1 \text{ AND } !x_2$.

- NE logička funkcija



Slika 8. NE logička funkcija u neuronu

Izvor: <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>

(pristupljeno i preuzeto 24.9.2020.)


Za Ne logičku funkciju na ulazu imamo inhibiciju i ako nam je na ulazu $x_1=1$ na izlazu ćemo dobiti 0, a za $x_1=0$ ćemo na izlazu dobiti 1. Stoga nam je funkcija praga kao što je vidljivo na slici jednaka 0.

2.3. Višeslojna neuronska mreža

Neuronske mreže ovisno o položaju, vrsti i načinu povezanosti svojih neurona ili čvorova može se odrediti njihova arhitektura. Stoga razlikujemo četiri osnovne vrste umjetnih neuronskih mreža:

- Aciklička mreža (engl. feedforward net)
- Mreža s povratnom vezom (engl. recurrent net)
- Hibridne mreže
- Rešetkasta mreža


Aciklička mreža je vrsta umjetne neuronske mreže u kojoj veze između neurona ili čvorova ne čine ciklus. Aciklična mreža je najjednostavniji oblik umjetne neuronske mreže jer se informacije obrađuju u samo jednom smjeru. Iako podaci mogu prolaziti kroz više skrivenih slojeva, oni se uvijek kreću u jednom smjeru te je propagacija signala jednosmjerna tj. nikada ne ide unatrag. Stoga se može zaključiti da nema povratnih veza između neurona. Aciklička neuronska mreža obično se u svom najjednostavnijem obliku vidi kao jednoslojni TLU perceptron. U ovom modelu niz ulaza ulazi i množi se s težinskim faktorom. Svaka se vrijednost tada zbraja da bi se dobio zbroj ulaznih vrijednosti. Ako je zbroj vrijednosti iznad određenog praga, obično postavljenog na nulu, proizvedena vrijednost je često 1, dok ako zbroj padne ispod praga, izlazna vrijednost je -1. Jednoslojni perceptron važan je model neuronskih mreža za prosljeđivanje i često se koristi u zadacima klasifikacije. Nadalje, jednoslojni perceptroni mogu sadržavati aspekte strojnog učenja. Koristeći svojstvo poznato kao delta pravilo, neuronska mreža može uspoređivati izlaze svojih čvorova s predviđenim vrijednostima, omogućavajući tako mreži da prilagođava svoje težinske faktore kroz trening kako bi proizvela preciznije izlazne vrijednosti. Ovaj proces treninga i učenja stvara oblik gradijentnog spuštavanja. U višeslojnim perceptronima postupak ažuriranja težinskih faktora gotovo je analogan, međutim postupak je preciznije definiran kao povratno širenje. U takvim se slučajevima svaki skriveni sloj unutar mreže podešava prema izlaznim vrijednostima koje stvara izlazni sloj.



Slika 9. Granica po dručja TLU perceptrona

Izvor: Dalbello Bašić, B., Čupić, M., Šnajder, J. (2012). Umjetne neuronske mreže, Fakultet elektronike i računarstva Sveučilišta u Zagrebu, Zagreb, str. 37.

Suprotno acikličkoj mreži je mreža s povratnom vezom kod koje su odrađeni čvorovi u ciklusu. Mreža s povratnom vezom vrsta je neuronske mreže koja sadrži petlje, omogućujući pohranjivanje informacija unutar mreže. Ukratko, mreže s povratnom vezom koriste svoja obrazloženja iz prethodnih iskustava kako bi informirale predstojeće događaje. Modeli s povratnom vezom dragocjeni su u svojoj sposobnosti sekvenciranja vektora, što otvara mogućnost za obavljanje složenijih zadataka. Mreže s povratnom vezom mogu smatrati nizom međusobno povezanih mreža. Često imaju lančanu arhitekturu, što ih čini primjenjivima za zadatke kao što su prepoznavanje govora, prijevod strojnog jezika itd. Mreža može biti dizajniran za rad u nizovima vektora na ulazu, izlazu ili oboje. Na primjer, sekvencirani ulaz može uzeti rečenicu kao ulaz i iznijeti pozitivnu ili negativnu vrijednost. Alternativno, sekvencirani izlaz može uzeti sliku kao ulaz i proizvesti rečenicu kao izlaz. Zamislamo da treniramo mrežu za riječ "happy", s obzirom na slova "h, a, p, y". Mreža će se obučavati na četiri zasebna primjera, svaki odgovara vjerojatnosti da će slova pasti u predviđeni slijed. Na primjer, mreža će biti osposobljena za razumijevanje vjerojatnosti da slovo "a" treba slijediti u kontekstu "h". Slično tome, slovo "p" trebalo bi se pojaviti nakon nizova "ha". Opet će se izračunati vjerojatnost za slovo "p" slijedeći slijed "hap". Postupak će se nastaviti dok se ne izračunaju vjerojatnosti kako bi se utvrdila vjerojatnost pada slova u predviđeni niz. Dakle, kako mreža prima svaki ulaz, ona će odrediti vjerojatnost sljedećeg slova na temelju vjerojatnosti prethodnog slova ili niza. Vremenom se mreža može ažurirati radi preciznijeg dobivanja rezultata.




Slika 10. Mreža s povratnom vezom

Izvor: <https://mc.ai/rnn-or-recurrent-neural-network-for-noobs/>

(pristupljeno i preuzeto 27.9.2020.)

Pojam hibridna neuronska mreža može imati dva značenja:

biološke neuronske mreže u interakciji s umjetnim neuronskim modelima, i umjetne neuronske mreže sa simboličkim dijelom (ili, obrnuto, simbolička izračunavanja s konekcionističkim dijelom). Što se tiče prvog značenja, umjetni neuroni i sinapse u hibridnim mrežama mogu biti digitalni ili analogni. Za digitalnu varijantu naponske stezaljke koriste se za praćenje membranskog potencijala neurona, za računalnu simulaciju umjetnih neurona i sinapsi i za poticanje bioloških neurona induciranjem sinaptika. Za analognu varijantu, posebno dizajnirani elektronički sklopovi povezuju se na mrežu živih neurona pomoću elektroda.



Slika 11. Hibridna Mreža

Izvor: https://link.springer.com/chapter/10.1007/978-3-319-40663-3_60

(pristupljeno i preuzeto 30.9.2020.)

Što se tiče drugog značenja, uključivanje elemenata simboličkog računanja i umjetnih neuronskih mreža u jedan model bio je pokušaj kombiniranja prednosti obje paradigme uz izbjegavanje nedostataka. Simbolički prikazi imaju prednosti u pogledu eksplicitne, izravne kontrole, brzog početnog kodiranja, dinamičkog vezanja varijabli i apstrakcije znanja. Prikazi umjetnih neuronskih mreža, s druge strane, pokazuju prednosti za biološku vjerodostojnost, učenje, robusnost (obrada tolerantna na kvarove i graciozno propadanje) i generalizaciju sličnih podataka. Od ranih 1990-ih činili su se mnogi pokušaji pomirenja dva pristupa.

3. OSNOVNE ZNAČAJKE KVAROVA

Kvar se manifestira kao neželjena promjena parametara ili odstupanje željenih parametara od stvarnih. Kvar koji je nastao u sustavu može prouzrokovati otežani rad, privremeni prestanak rada ili potpuni prestanak rada sustava. Da bi se smanjila vjerojatnost nastanka kvara, već u samom odabiru sustava trebaju se poznavati uvjeti ujedno i parametri u kojima će sustav raditi. Osim znanja koje se stekne u teorijskom dijelu važno je i iskustveno prepoznavanje kvarova te načini tj. situacije u kojima kvar nastaje i pod kakvim neprilikama može doći do nastanka kvara. Zbog toga je važno znati koje parametre gledati i pratiti prilikom rada sustava kako ne bi došlo do nastanka kvara te kako bi se olakšala njegova dijagnostika.

S teorijskog aspekta, sustav koji je dobro projektiran, montiran i održavan, ne bi se trebao kvariti tijekom svojeg rada, međutim u praksi je situacija drugačija. Sustavi konstantno rade, te što rezultira pojavom kvarova.

3.1. Stanje sustava „u kvaru“

Sustav kao cjelina sastoji se od puno različitih elemenata kako bi što brže i efikasnije obavljalo svoju funkciju u zadanom vremenskom periodu i to se zove radna sposobnost sustava. Sustav kao cjelina nalazi se u različitim stanjima između stanja „u radu“ i stanja „u kvaru“. Postoje tri osnovna načina stanja sustava, a to su:⁵

- **Oštećenje** (*engl. damage*) - promjena stanja tehničkog sustava ili njegovih dijelova koja još ne smeta funkcioniranje tehničkog sustava, a može se razviti u kvar.
- **Kvar** (*engl. failure*) - je promjena stanja tehničkog sustava ili njegovih dijelova koja bitno ometa ili onemogućava njegovo funkcioniranje.
- **Zastoj** (*engl. accidents*) - je teži oblik kvara tehničkog sustava kod kojega dolazi do njegovog potpunog oštećenja (ili do potpunog oštećenja vitalnih komponenti) i /ili dolazi do pogubnog utjecaja na sigurnost i na okoliš.

⁵ Bratić, K. (2016). Analiza primjene suvremenih strategija održavanja u pomorstvu, Pomorski fakultet Sveučilišta u Splitu, str. 11.

3.2. Podjela kvarova

Kvar je trenutak neispunjavanja funkcionalnih zahtjeva. Svaka funkcija može imati više izlaza i više modova kvara (*engl. failure mode*). Tako definiran kvar je događaj kada je tražena funkcija izašla izvan prihvatljivih granica.⁶

Kvarovi se dijele u nekoliko kategorija, odnosno:

- ***Kvarovi postrojenja*** - zbog nastanka kvara dolazi do promjene dinamičkih svojstva sustava. Ako pod utjecajem kvarova dođe do promjena u sustavu i te promjene se ne mogu riješiti upravljanjem onda se mora izmijeniti upravljačka struktura
- ***Kvarovi senzora*** – prilikom ove vrste kvara dolazi do prekida povezanosti između regulatora i uređaja tj. regulator dobiva neispravnu informaciju preko senzora koji mjere parametre. U takvoj situaciji primjenjuju se ručna i alternativna mjerenja.
- ***Kvarovi aktuatora*** - utjecaj na objekt upravljanja je promijenjen ili prekinut.

⁶ Šegulja, I., Bukša, A. (2006). Održavanje broskog pogona, Pomorski fakultet u Rijeci, str. 105-118.

4. VRSTE ODRŽAVANJA

Pod vrstama održavanja podrazumijeva se skup tehnika i metoda održavanja s ciljem smanjenja ili postizanja potpune eliminacije zastoja i otklanjanje kvara uz minimalne troškove. Postoji nekoliko stručnih pristupa i strategija za održavanje sustava, a to su:

- održavanje (*engl. Corrective Maintenance – CM*),
- preventivno održavanje (*engl. Preventive Maintenance – PM*),
- terotehnoški pristup održavanja (*engl. Terotechnology*),
- logistički pristup održavanja (*engl. Logistics Engineering*),
- održavanje po stanju (*engl. Condition based Maintenance*),
- plansko održavanje (*engl. Scheduled Maintenance*),
- potpuno cjelovito održavanje (*engl. Total Productive Maintenance – TPM*),
- održavanje usmjereno na pouzdanost (*engl. Reliability Centered Maintenance – RCM*),
- ekspertni sustavi (*engl. Expert Systems – ES*),
- model samoodržavanja (*engl. Self-Maintenance*).

Unatoč ranije navedenim strategijama otklanjanja kvarova, postoje tri osnovne, tradicionalne strategije koje se najčešće primjenjuju, a to su:

- korektivno održavanje,
- preventivno održavanje i
- plansko održavanje.

4.1. Korektivno održavanje

Pod korektivnim održavanjem (*engl. Corrective Maintenance - On Failure Maintenance*) podrazumijeva se obnavljanje i zamjena dijelova sustav odmah nakon otkrivanja kvara, a sve radi ponovnog osposobljavanje sustava za rad.

Primjena korektivnog održavanja je prividno najjeftinije metoda jer su troškovi tekućeg održavanja jednaki nuli, a kod ovog načina održavanja uređaj se upotrebljava sve dok ne

nastupi kvar, a potom se vrši popravak. Prednosti i nedostaci korektivnog održavanja sustava prikazani su Tablicom 1.

Tablica 1. Prednosti i nedostaci korektivnog održavanja sustava

PREDNOSTI	NEDOSTATCI
izuzetno niska cijena	nepouzdanost rada sustava zbog iznenadnog zastoja
kad nastupi kvar vrši se popravak	nemogućnost planiranja održavanja
potpuna iskoristivost elemenata tehničkog sustava	velika vjerojatnost da će doći do dužih zastoja izazvanih ovom metodom održavanja

Izvor: izrada autora

Korektivno održavanje sustava sastoji se od nekoliko zahvata s ciljem vraćanja sustava u radno stanje. U prošlosti se ova metoda održavanja sustava kontinuirano upotrebljavala, dok se danas koristi uglavnom za slučajeve kada kvar sustava može dovesti do sljedećih stanja:

- ugrožavanje sigurnosti,
- u slučaju težih pomorskih havarija i lomova,
- dugih zastoja.⁷

4.2. Preventivno održavanje

Preventivno održavanje u elektroničkim sustavima definira se kao održavanje koje je unaprijed isplanirano unutar nekog vremenskog perioda ili se temelji na nekim postavljenim kriterijima. Pomoću ove vrste održavanja se može na neki način predvidjeti sam kvar te se samo održavanje vrši prije nastanka kvara što daje na pouzdanosti i prevenciji nastanka kvara. Sam naziv ove vrste održavanja nam govori da omogućuje prevenciju nastanka kvara što nam je potrebno kako bi imali sustave koji se neće kvariti.

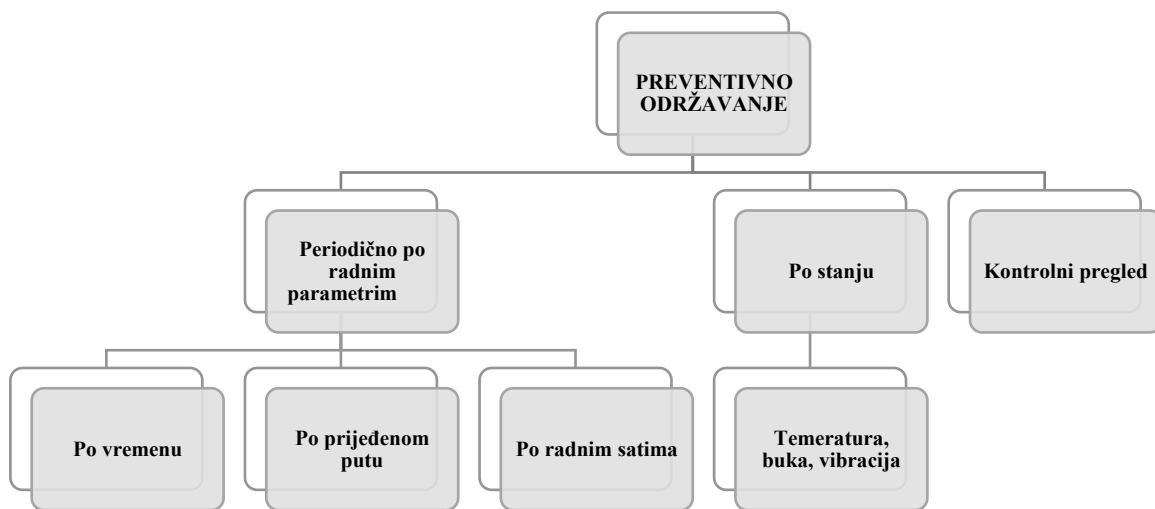
Stoga preventivno održavanje možemo podijeliti na:

- planirano održavanje,
- održavanje prema stanju sustava.

⁷ Bratić, K. (2016). Analiza primjene suvremenih strategija održavanja u pomorstvu, Pomorski fakultet Sveučilišta u Splitu, str. 11.

Planirano održavanje je vrsta preventivnog održavanja koja se temelji na već unaprijed postavljenom vremenskom periodu ili nakon određenog broja jedinica djelovanja samog sustava. Prema unaprijed postavljenom vremenskom periodu se izvršava održavanje svakih tjedan dana, mjesec dana ili par mjeseci. Dok održavanje nakon određenog broja jedinica djelovanja se vrši tako da ako je sustav odradio sto radnih sati dolazi do njegovog održavanja.⁸

Princip rada preventivnog održavanja sustava prikazan je Slikom 11.



Slika 12. Princip rada preventivnog održavanja

Izvor: izrada autora prema <https://www.pfst.unist.hr/hr/component/users/?view=login> pristupljeno 20.08.2020.)

Temeljna razlika između ova dva načina preventivnog održavanja je u tome što se održavanje kod već unaprijed postavljenom vremenskom periodu vrši bez obzira na broj radnih sati sustava. Npr. ako sustav odradi 80 radnih sati i nakon dva tjedna odradi još 20 radnih sati on će biti održavan bez obzira jeli odradio potrebnih 100 sati.

Pod preventivnim održavanjem smatramo redovite preglede, zamjenu dijelova za koje mjerenjem svojstava ili praćenjem degradacije se utvrdi da bi mogli otkazati, čišćenjem ili

⁸ Marišić, D. (2010). Uvod u održavanje – dijagnostika i održavanje uređaja, dostupno: http://www.ss-strukovna-vlatkovic-zd.skole.hr/images/pages/Nastavni_materijali/Spahic/DIOU/diou-1-uvod.pdf (pristupljeno 19.08.2020.)

kontrolu ispravnosti instrumenata. Sve preglede se može bilježiti na razne kontrolne liste.⁹ Održavanje prema stanju sustava ova vrsta preventivnog održavanja temelji se na nadzoru radnih karakteristika i parametara elektroničkog sustava.

4.3. Plansko održavanje

Pod planskim održavanjem podrazumijeva se planirano održavanje, određeno rasporedom i dokumentirano u svrhu provođenja održavanja prije nastanka kvara.¹⁰ Proces planiranja održavanja povećava učinkovitost zadataka održavanja i eliminira utjecaje održavanja na operativnost sustava. Plansko održavanje ili održavanje prema rasporedu se sastoji od niza aktivnosti koje se provode po pojedinom dijelu opreme ili sustava.¹¹ Ovakvo održavanje je unaprijed određen popravak koji izvodi kompetentno osoblje, te se na ovaj način utvrđuje ispravan rad opreme i izbjegava se bilo kakvo neodređeno, izgubljeno vrijeme u kvaru.

Planirano održavanje se stvara za svaki predmet posebno prema proizvođačevim preporukama ili registru. Planovi mogu biti zasnovani na podacima, na temelju radnih sati opreme, ili nekom drugom parametru, a krajnji cilj izrade planova je optimizacija korektivnog i preventivnog održavanja. Shematski prikaz planskog održavanja prikazan je Slikom 12.

⁹ Marišić, D. (2010). Uvod u održavanje – dijagnostika i održavanje uređaja, dostupno: http://www.ss-strukovna-vlatkovic-zd.skole.hr/images/pages/Nastavni_materijali/Spahic/DIOU/diou-1-uvod.pdf (pristupljeno 19.08.2020.)

¹⁰ Bratić, K. (2016). Analiza primjene suvremenih strategija održavanja u pomorstvu, Pomorski fakultet Sveučilišta u Splitu, str. 11.

¹¹ Tomas, V., Šegulja, I., Čišić, D. (2005). Mogućnosti i problemi primjene suvremenih strategija u pomorstvu, Pomorski fakultet u Rijeci, str. 29-41.



Slika 13. Shematski prikaz planskog održavanja

Izvor: izrada autora prema <https://www.pfst.unist.hr/hr/component/users/?view=login> pristupljeno 20.08.2020.)

5. DIJAGNOSTIKA KVAROVA

5.1. Definicija dijagnostike

Dijagnostika kvara je bitan proces u kojem se može otkriti i prevenirati nastanak kvara tj. otkazivanje rada sustava. Stoga dijagnostika kvara mora otkriti ili detektirati vrijeme nastanka kvara uz prisutne smetnje i poremećaje te je to ujedno i prvi korak pri utvrđivanju kvarova. Nakon detekcije slijedi drugi korak koji mora lokalizirati mjesto kvara, klasificirati različite kvarove ali najbitnije je da utvrdi i definira mjesto gdje je došlo do nastanka kvara. Poslije detekcije i lokalizacije slijedi treći korak koji mora analizirati određeni tip kvara, što ga je pod kojim uvjetima i zbog čega prouzročilo te odrediti veličinu nastalog kvara.¹²

Rezidual je pokazatelj kvara koji je jednak nuli ako je sustav funkcionalan tj. nije u stanju kvara dok kod pojave kvara dolazi do velikog odstupanja od nule. Metoda na kojem se temelji rezidual je odstupanje izmjerenih vrijednosti od vrijednosti i rezultata dobivenih na temelju modela.

Postupci po kojima se može izvršiti dijagnostika kvara su:

1. **Generiranje reziduala** - ovaj postupak dijagnostike koristi signale preko kojih će se moći detektirati kvar te ako se želi provesti lokalizacija kvara treba ispravno odabrati rezidualne.
2. **Procjena reziduala** - pomoću praćenja reziduala dolazi do lokalizacije i određivanju vremena nastanka kvara
3. **Analiza kvara** - ovim postupkom se određuje tip, veličina i uzrok nastalog kvara.


5.2. Sustav za dijagnostiku kvarova

Osnovna funkcija sustava za dijagnostiku je otkrivanje i predviđanje kvarova, drugim riječima sustav dijagnostike se primjenjuje u onom trenutku nakon što je nastao kvar sustava. Glavni koraci prilikom otkrivanja kvara su:

¹² Kondić, V., Horvat, M., Maroević, F. (2013). *Primjena dijagnostike kao osnove održavanja po stanju na primjeru motora i osobnog automobila*, Tehnički glasnik 7, Izd. 1., str. 35-41.

- proces transformacije sirovih ulaznih podataka dobivenih od ugrađenih senzora u sažetom prikazu koji sadrži relevantne informacije,
- radno stanje sustava procjenom vrijednosti višestrukih radnih parametara kroz dulje vremensko razdoblje u svrhu određivanja stupnja istrošenosti dijelova,
- predviđanje preostalog životnog vijeka pomoću matematičkih modela.¹³

Ključna karakteristika sustava za dijagnosticiranje kvarova je pretvaranje informacija koje govore o stupnju istrošenosti sustava, te koji dio treba zamijeniti. Proces dijagnosticiranja odvija se u realnom vremenu u četiri koraka, a isti su prikazani Slikom 13.



Slika 14. Odvijanje dijagnostičkog postupka

Izvor: izrada autora prema Knafelj, K. (2010). Sustavi za dijagnostiku i predviđanje kvarova, dostupno:

<https://strojarskaradionica.wordpress.com/2019/01/10/sustavi-za-dijagnostiku-i-predvidanje-kvarova/>

(pristupljeno 22.08.2020.)

¹³ Knafelj, K. (2010). Sustavi za dijagnostiku i predviđanje kvarova, dostupno: <https://strojarskaradionica.wordpress.com/2019/01/10/sustavi-za-dijagnostiku-i-predvidanje-kvarova/> (pristupljeno 22.08.2020.)

6. SUSTAVI S NEURONSKIM MREŽAMA ZA NADZOR I DIJAGNOSTIKU KVAROVA

Sustavi s neuronskim mrežama za nadzor i dijagnostiku kvarova su inteligentni sustavi koji rade na principu prikupljanja, obrade i prezentiranja podataka o kvaru sustava. Umjetne neuronske mreže su naročito pogodne za obradu signala kad je potrebno spojiti kompleksne višedimenzijske različite informacije u jednu jednoznačnu reprezentaciju, za filtriranje procesnih signala i ekstrakciju informacija za identifikaciju, prepoznavanje uzoraka (dijagnoza kvarova), te odlučivanje.¹⁴

Osnovne značajke sustava s neuronskim mrežama za nadzor i dijagnostiku kvarova su:

- sposobnost samoučenja temeljem podataka iz prošlosti (pohranjeni podaci),
- masivni paralelizam (masovna obrada podataka i informacija),
- mogućnost poopćavanja,
- prilagodljivost promjenama,
- dobre mogućnosti obrade nelinearnosti.¹⁵

6.1. Opzimizacija dijagnostičkog sustava neuronskih mreža

Postoje dvije vrste parametara s neuronskim mrežama a to su:

- Parametri koje mreža uči (*engl. learnable parameters*) i
- Hiperparametri (*engl. hyperparameters*).

Parametri koje mreža uči su varijable učene za slanje povratnih podataka i pravodobno reagiranja u slučaju pogreške ili kvara sustava.¹⁶ S druge strane, hiperparametri su varijable

¹⁴ Antonić, R., Munitić, A., Kezić, D. (2003). *Umjetne neuronske mreže u obradu senzornih signala brodskih dizelskih motora*. „Naše more“ (1-2) str. 21-31

¹⁵ Antonić, R., Munitić, A., Kezić, D. (2003). *Umjetne neuronske mreže u obradu senzornih signala brodskih dizelskih motora*. „Naše more“ (1-2) str. 21-31

¹⁶ Kežman, D. (2020). *Inteligentna dijagnostika kvarova rotacijske opreme male brzine vrtne*, Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu, Zagreb. str. 45.

koje su tvornički zadane, odnosno iste je potrebno odrediti prije nego se u neuronsku mrežu unesu podaci. Hiperparametri se dijele u tri kategorije, a to su:¹⁷

1. **Hiperparametri s kontinuiranim realnim brojevima:** karakterizira ih poprimanje bilo koje vrijednosti (stop učenja i parametar regularizacije),
2. **Hiperparametar s diskretnim vrijednostima:** u stručnoj teoriji ova kategorija parametara može poprimiti beskonačno mnogo vrijednosti (broj skrivenih slojeva, broj neuronskih mreža, broj epoha i slično),
3. **Hiperparametri koji su diskretna vrijednost:** sadrže konačan broj mogućnosti poput optimizatora, aktivacije funkcija, metoda smanjivanja stope učenja i slično.

U praksi se najčešće primjenjuju hiperparametri u konvolucijskim neuronskim mrežama. Hiperparametri u konvolucijskim neuronskim mrežama su:¹⁸

- broj jezgri,
- veličina jezgre,
- dopunjavanje (*engl. padding*),
- tzv. korak S
- redoslijed i broj slojeva i
- stopa učenja,
- aktivacijska funkcija,
- broje epoha,
- veličina mini grupe podataka (*engl. batch size*),
- parametri regularizacije,
- optimizacijska metoda,
- inicijalizacija težina (*engl. weight initialization methods*),
- funkcija gubitka,
- sloj sažimanja.

Kada je u pitanju broj jezgri u konvolucijskom sustavu bitno je istaknuti kako svaki konvolucijski sloj sadrži tvornički broj jezgri, a broj istih ovisi o mapama u svakom sloju. Težina mapa u jezgrama se mijenja sukladno primanju podataka odnosno učenju. Veličina jezgre je propisana širinom i visinom njezine matrice, odnosno u ovom slučaju jezgre su

¹⁷ Michelucci, U. (2018). Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Networks. Dübendorf, Švicarska: Apress

¹⁸ Michelucci, U. (2018). Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Networks. Dübendorf, Švicarska: Apress

kvadratne matice koje imaju uobičajene dimenzije 3x3 ili 5x5. Svako polje unutar jezgre predstavlja jednu težinu te se odabirom veličine jezgre odabire i broj težina u njoj. Težina jezgre dobiva se množenjem dimenzija pa bi tako jezgra dimenzija 3x3 imala težinu 9, dok bi jezgra dimenzija 5x5 imala težinu 25. Dopunjavanje je normalan proces, a predstavljanje povećanje dimenzijske ulazne matrice dodajući nulu oko rubova kako bi se dobila mapa značajki jednakih dimenzija kao i ulazna matrica. Tzv. korak S označava broj piksela koji su potrebni za pomak u vertikalnom smjeru, a primjenjuju se prilikom sažimanja obrađenih podataka. Empirijski se pokazalo kako redoslijed i broj slojeva zahtijevaju manji broje neurona kako bi se postigli isti rezultati. Stopa učenja je jedan od ključnih hiperparametara mreže, a o njemu ovisi konvergencija mreže. Najčešće se odabire iznos između 0,01 do 0,0001. Ovaj hiperparametar mreže je podložan promjenama, a mijenja se svakom inercijom.¹⁹

Aktivacijska funkcija koristi se kroz cijelu mrežu, a neke od najpoznatijih aktivacijskih funkcija su sigmoidalna, tangens hiporbolna aktivacijska funkcija, zglobna aktivacija funkcija i slično. Od epoha je sačinjen svaki prolaz neuronske mreže, te je svrha epohe uviđanje pogreške koju mreža daje. Preporučuje se da sustav ima što više epoha kako bi davanje informacija i obrada podataka bila to točnija.

O veličini mini grupe podataka ovisi koliko će uzoraka jednom proći kroz mrežu. Praksa je pokazala kako pravilan izbor veličine mini grupe ubrzava učenje mreže, pri čemu se ne gubi na njezinoj točnosti. Optimizacijska metoda ne koristi se uvijek za dijagnosticiranje kvarova, dok kod inicijalizirane težine potrebno je imati određenu dozu opreza kako ne bi došlo do spore konvergencije neuronske mreže u samom početku. Funkcija gubitka primjenjuje se ovisno o problemu, a najčešći se primjenjuje unakrsnom provjerom. Kada je riječ o sloju sažimanja važno je istaknuti kako se isti odabire prema značajkama mape i veličine matrice koja će vršiti sažimanje. Najčešće korištene metode sažimanja su: sažimanje maksimumom i sažimanje usrednjavanjem.²⁰

Sve ranije navedeno koristi se s ciljem dijagnosticiranja kvara i njegovo otklanjanje. Sustav s neuronskim mrežama koji je polučio dobre rezultate je eksperimentalni postav, a o istom se govori u sljedećem poglavlju.

¹⁹ Michelucci, U. (2018). Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Networks. Dübendorf, Švicarska: Apress

²⁰ Smolčić, D. (2015). Raspoznavanje objekata konvolucijskim neuronskim mrežama. Zagreb: Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva

6.2. Eksperimentalni postav za dijagnostiku kvarova


Sustav neuronskih mreža za dijagnosticiranje kvarova primjenjuje se praktički, a sastoji se od dvije faze:

1. prikupljanje kvarova na simulatoru kvarova u laboratoriju za održavanje,
2. priprema podataka, učenje i testiranje mreže.

Dijagnostika kvarova u ovom slučaju vrši se mjerenjem i analizom vibracija, a proces procjene stanja opreme vibrodijagnostikom se sastoji od sljedećih koraka:

- snimanje vibracije opreme (mjerni pretvornici (senzori)),
- konverzija vibracijskog u električni signal (analizator/konverteri),
- transformacija električnog signala,
- prikaz prikupljenih podataka i informacija (software),
- spremanje i dokumentiranje podataka i informacija,
- dijagnostika/inteligentna dijagnostika (ekspert/software).

Najučestaliji sustav dijagnostike kvarova koji radi na principu neuronskih mreža je SpectraQuest Simulator Expert prikazan Slikom 14.



Slika 15. SpectraQuest Simulator Expert

Izvor: <https://spectraquest.com/> (pristupljeno i preuzeto 29.08.2020.)

7. ODRŽAVANJE NA AUTONOMNIM BRODOVIMA

Prema dosadašnjim istraživanjima i mišljenju brojnih stručnjaka iz ovog područja poput Mikaela Makinena autonomni brodovi (Slika 15.) se smatraju budućnošću pomorske industrije, te su karakteristika slični kao i pametni telefoni.²¹



Slika 16. Izgled autonomnog broda

Izvor: <https://planet.hr/tehnologija/autonomni-brodovi/> (pristupljeno i preuzeto 01.09.2020.)

Karakteristika autonomnih brodova je mogućnost vođenja plovidbe bez posade, te samostalno donošenje odluka vezanih uz plovidbu. Autonomni brodovi funkcioniraju na principu umjetne inteligencije (*engl. Artificial intelligence*) koja doprinosi stupnju odlučivanja. Za razliku od ostalih brodova koji ne mogu funkcionirati bez posade, ovi brodovi mogu, ali i ne moraju imati posadu. S aspekta Međunarodne pomorske organizacije (*engl. International Maritime Organization*) autonomni brodovi se definiraju kao pomorski autonomni površinski brodovi.

Opći naziv za autonomni brod je MASS, koji se dalje dijeli u četiri kategorije:²²

- **Most potpomognut autonomijom** (*engl. Autonomy Assisted Bridge - AAB*): brodovi sa stalnom posadom. Na mostu ovoga broda cijelo vrijeme se nalazi posada broda koja

²¹ Baladauf, M., Mehdi, R.A., Fonseca T., Kitada, M. (2018). Conventional Vessels and Marine Autonomous Surface Ships – A Love Marriage?. World Maritime University, Geneva, Switzerland,

²² Rødseth, O.J., Nordahl, H. (2017). Definition for Autonomous Merchant Ships. Norwegian Forum for Autonomus Ships,

neposredno intervenira. Ova vrsta brodova neće dovesti do nekih posebnih regulatornih mjera osim, možda, novih standarda vezanih za performanse i nove funkcije na mostu.

- **Most koji je povremeno bez posade** (engl. *Periodically Unmanned Bridge - PUB*): ovi brodovi vrše svoja djelovanja bez posade na mostu u ograničenim vremenskim periodima, npr. na otvorenom moru za lijepog vremena. Posada se nalazi na brodu te može biti pozvana na most u slučaju problema.
- **Brodovi koji su povremeno bez posade** (engl. *Periodically Unmanned Ship - PUS*): ovakav brod vrši svoja djelovanja bez posade duži period vremena bez posade, npr. za vrijeme preoceanskog putovanja. Ukrcajni tim ili prateći brod prilaze brodu te preuzimaju upravljanje, npr. pri prilasku luci. Zakonodavni zahtjevi će vjerojatno biti slični kao i za iduću klasu brodova.
- **Brodovi bez posade** (engl. *Continuously Unmanned Ships - CUS*): ovi brodovi su dizajnirani za izvršavanje zadaća bez posade na mostu za cijelo vrijeme djelovanja, osim u nekim posebni slučajevima kao što je neposredna opasnost. To znači da nitko na brodu nije ovlašten da preuzme upravljanje na mostu, jer tada bi brod bio klasificiran kao PUB. Sve navedeno opet ne mora značiti da se na brodu ne nalaze osobe, npr. putnici ili posada zadužena za održavanje broda.

Održavanje autonomnih brodova je značajno olakšano nego što je to slučaj kod drugih brodova. Naime, posada je još uvijek zadužena za održavanje, ali učestalost održavanja autonomnih brodova je značajno smanjenja. Isto tako važno je istaknuti kako kod autonomnih brodova ima ugrađen sustav za prepoznavanje kvara, odnosno dijagnostika. S obzirom da autonomni brodovi funkcioniraju na principu umjetne inteligencije imaju izuzetno velik kapacitet pohrane podataka te brzinu njihove obrade.

7.1. Razvoj automatizacije na brodu

Dijelimo ih na četiri generacije:

- Prva generacija (1960-1980):
Ovu generaciju karakterizira automatska proizvodnja električne energije te upravljanje samog broda iz daljine pomoću daljinskog upravljanja. U sustavu su prisutne regulacije tlakova, razina, temperature i vodi se dnevnik stroja te nadgledanje. Kod

ove generacije je primjenjeno relejno upravljanje, analogna regulacija te nije moguć nadzor cijelog sustava s jednog mjesta.

- Druga generacija (1980-1990):

Ovu generaciju karakterizira upotreba mikroprocesora koja omogućuje digitalnu regulaciju, međutim i dalje je prisutno relejno upravljanje. Osim distribuiranog prikupljanja podataka upotrebom mikroprocesora dobiveno je pouzdanije rukovanje, jednostavnija regulacija parametara funkcija te poboljšana analiza stanja.

- Treća generacija (1990-1995):

Značajno svojstvo treće generacije je upotreba radnih stanica koje omogućuju:

1. Spremanje podataka na duži period te uzimanje ili dobivanje podataka starih nekoliko dana.
2. Poboljšani i detaljniji prikaz stanja te bolju procjenu
3. Funkciju održavanja: Pomoću prikupljenih podataka omogućuje lociranje i potrebu za održavanjem.
4. Poboljšano sučelje koje koristi operater za nadgledanje stroja
5. Integriranje pojedinih sustava u jednu cjelinu

- Četvrta generacija (1995-):

Ostvarena je 100% integracija sustava u kojem se operacije vrše iz daljine tj. preko monitora:

1. Visoka kvaliteta, efikasnost i korisnost sustava
2. Upotreba help funkcije koja omogućuje detaljniji prikaz neispravnosti
3. Pojednostavljeno održavanje pomoću zamjene modula
4. Veći kapacitet za pohranu podataka
5. Povezanost. Mogućnost korištenja podataka u drugim programima
6. Jednostavno sučelje koje je prilagođeno za lakši rad operatera.

7.2. DNV GL Autonomni brodovi

Sljedeća načela čine temelj DNV GL-a za procjenu autonomije brodova s daljinskim upravljanjem:

- Sigurnost
- Pristup zasnovan na riziku
- Operativni fokus
- Uvjeti minimalnog rizika
- Funkcionalni fokus
- Stupnjevi automatizacije i ljudske uključenosti
- Inženjering i integracija sustava
- Principi dizajna
- Softverski inženjering i ispitivanje
- Cyber zaštita

Za udaljena plovila, zbog ograničene prisutnosti ili odsustva posade za ručnu intervenciju, svi načini otkaza i incidenti koji bi ovisili o ručnoj intervenciji na konvencionalnim brodovima trebaju biti uključeni u procjene rizika i biti na odgovarajući način nadoknađeni suvišnošću, greškom tolerancija i automatskom funkcionalnosti u dizajnu. Također treba uzeti u obzir kvarove komponenata definiranih kao aktivne za udaljena plovila. Iznimka glavne klase pri razmatranju kvarova na određenim aktivnim komponentama (npr. Glavni motor, osovina) općenito nije primjenjivo za udaljena plovila, osim ako to nije opravdano kompenzacijskim mjerama kao što su npr. prisutnost odgovornog osoblja na brodu, poboljšane prediktivne dijagnostičke funkcije temeljene na stanju programa održavanja.



Slika 17. ReVolt DNV GL autonomni brod

Izvor: (<https://www.dnvgl.com/maritime/autonomous-remotely-operated-ships/index.html>)

(pristupljeno i preuzeto 29.09.2020)

Kako bi se udovoljilo principima dizajna kvarovi i incidenti koji se analiziraju u procjenama rizika su općenito podijeljeni u dvije kategorije:

1) Predviđeni kvarovi su kvarovi za koje se očekuje da će se dogoditi u budućnosti. Takvi kvarovi obično mogu biti zbog istrošenosti, začepljenja, varijacija ili slično. Nekonvencionalni aranžmani i sustavi te komponente koje imaju ograničenu evidenciju pouzdanog rada također treba uzeti u obzir podložan očekivanom kvaru.

Učinak takvih kvarova treba ublažiti dizajnom i ne bi trebao uzrokovati prestanak rada sustava. Brod bi trebao biti u mogućnosti nastaviti s radom i planiranim putovanjem, moguće smanjenom brzinom ili mogućnostima. Međutim, tolerancija kvarova sustava pogođenih kvarom može se u takvim slučajevima smanjiti, što zauzvrat može zahtijevati mjere za ublažavanje ili čak operativna ograničenja ovisno o načinu rada. Specifikacije za to trebale bi se utvrditi.

2) Potencijalni kvarovi su kvarovi koji su manje vjerojatni od predviđenih kvarova, ali se svejedno mogu dogoditi negdje tijekom operativnog vijeka plovidbe. Nakon takvog kvara, brod bi trebao moći ući i održavati sigurno stanje. Kvarovi u ovoj kategoriji koji mogu oštetiti funkcije potrebne za održavanje ta bi sposobnost trebala biti uključena u procjene rizika i potencijalno dovesti do boljeg dizajna i odvojenih aranžmana. Takvi kvarovi tada mogu

prouzročiti privremeno zaustavljanje funkcije koja se služi, ali ne bi trebao spriječiti obnavljanje sustavom.

Gornja načela vrijede i za autonomne i daljinski upravljane brodove. Međutim, veća automatizacija, poboljšano upravljanje upozorenjima i rigoroznija definicija sigurnog stanja trebao bi biti dio dizajna kako bi se nadoknadile smanjene mogućnosti za lokalnu ili ručnu intervenciju. Vrste načina otkaza koje treba razmotriti treba proširiti, a sustave dizajnirati s više sofisticirane dijagnostičke funkcije (npr. praćenje stanja, zdravlja) za otkrivanje novih stanja kvara. Uz to, treba razmotriti naknadne učinke kvara na povezane funkcije ili povezane sustave u procjeni rizika i nadoknađuje se shemama određivanja prioriteta ili automatski aktivacija upravljačkih kontrola te sigurnosne funkcije.

8. ZAKLJUČAK

Umjetne neuronske mreže funkcioniraju na principu umjetne inteligencije i oponašaju rad ljudskog mozga. Prva ideja o razvoju umjetnih neuronskih mreža nastala je 1940. godine. Osnovna karakteristika neuronskih mreža je primanje, pohrana i obrada podataka s ciljem davanja informacijska o stanju sustava. S obzirom da obrađuju veliku količinu podataka rad izuzeto velikom brzinom. Umjetne neuronske mreže koriste se i prilikom dijagnosticiranja kvarova u brodskom sustavu.

Pod kvarovima se podrazumijeva neželjena promjena parametara ili odstupanja željenih parametara od stvarnih. Sustavi koji dijagnosticiraju kvar su dobro projektirani, montirani i održavani, a mogu prepoznati oštećenja, kvar i zastoj. Kvarovi se dijele u tri osnovne skupine: kvarovi postrojenja, kvarovi senzora i kvarovi akumulatora. Koja će se metoda otklanjanja kvarova primjenjivati ovisi o vrsti kvara. Održavanje brodskog sustava podrazumijeva otklanjanje kvarova i zastoja različitim metodama, a najučestalije metode su: korektivna, preventivna i planska. Sve metode imaju svoje prednosti i nedostatke, a iste se primjenjuju ovisno o vrsti i stupnju kvara. Dijagnostika je uobičajen proces otkrivanja kvara, a osim kvara daje i jasne podatke o uzroku pojave kvare te eventualnim budućim kvarovima. Danas se sve češće primjenjuje dijagnosticiranje kvarova sustavima neuronskih mreža od kojih je najčešće korišten *SpectraQuest Simulator Expert*. Ovaj sustav funkcionira na principu snimanje vibracije opreme, prikazivanju i prikupljanju podataka te inteligentnoj dijagnostici.

Autonomni brodovi su budućnost pomorskog sustava, a osim modernog dizajna i izgleda, prednost ovih brodova je što su digitalizirani i rade na principu senzora. Dakle, za upravljanje autonomnim brodovima nije potrebna posada, a ovaj sustav ima ugrađen sustav neuronske mreže koja izuzetnom brzinom prikuplja i obrađuje podatke o potencijalnim kvarova i radu samog sustava.

POPIS LITERATURE

Antonić, R., Munitić, A., Kezić, D. (2003). *Umjetne neuronske mreže u obradu senzornih signala brodskih dizelskih motora*. „Naše more“ (1-2) str. 21-31

Baladauf, M., Mehdi, R.A., Fonseca T., Kitada, M. (2018). *Conventional Vessels and Marine Autonomous Surface Ships – A Love Marriage?*. World Maritime University, Geneva, Switzerland.

Bratić, K. (2016). Analiza primjene suvremenih strategija održavanja u pomorstvu, Pomorski fakultet Sveučilišta u Splitu, Split

Dalbelo Bašić, B., Čupić, M., Šnajder, J. (2012). Umjetne neuronske mreže, Fakultet elektronike i računarstva Sveučilišta u Zagrebu, Zagreb

FliperWorld.org. (2019). Neuronske mreže: primjer, definicija, vrijednost, opseg, dostupno: <https://hr.flipperworld.org/pc/neuronske-mreze-primjer-definicija-vrijednost-opseg> (pristupljeno 15.08.2020.)

Kežman, D. (2020). Inteligentna dijagnostika kvarova rotacijske opreme male brzine vrtne, Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu, Zagreb.

Knafelj, K. (2010). Sustavi za dijagnostiku i predviđanje kvarova, dostupno: <https://strojarskaradionica.wordpress.com/2019/01/10/sustavi-za-dijagnostiku-i-predvidanje-kvarova/> (pristupljeno 22.08.2020.)

Kondić, V., Horvat, M., Maroević, F. (2013). *Primjena dijagnostike kao osnove održavanja po stanju na primjeru motora i osobnog automobila*, Tehnički glasnik 7, Izd. 1., str. 35-41.

Marišić, D. (2010). Uvod u održavanje – dijagnostika i održavanje uređaja, dostupno: http://www.ss-strukovna-vvlatkovica-zd.skole.hr/images/pages/Nastavni_materijali/Spahic/DIOU/diou-1-uvod.pdf (pristupljeno 19.08.2020.)

Michelucci, U. (2018). *Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Networks*. Dübendorf, Švicarska: Apress

Rødseth, O.J., Nordahl, H. (2017). Definition for Autonomous Merchant Ships. Norwegian Forum for Autonomus Ships.

Smolčić, D. (2015). Raspoznavanje objekata konvolucijskim neuronskim mrežama. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb.

Šegulja, I., Bukša, A. (2006). Održavanje broskog pogona, Pomorski fakultet u Rijeci, Rijeka

Tomas, V., Šegulja, I., Čišić, D. (2005). Mogućnosti i problemi primjene suvremenih strategija u pomorstvu, Pomorski fakultet u Rijeci, str. 29-41.

Zelenika, R. (2000). Metodologija i tehnologija izrade znanstvenog i stručnog djela; Sveučilište u Rijeci, Rijeka

<https://towardsdatascience.com/recurrent-neural-networks-d4642c9bc7ce>

<https://deepai.org/machine-learning-glossary-and-terms/feed-forward-neural-network>

<https://www.dnvgl.com/maritime/autonomous-remotely-operated-ships/index.html>

POPIS SLIKA

Slika 1. Vremenska lenta konceptualnog modela umjetne neuronske mreže od 1980. do 2010.....	4
Slika 2. Arhitektura Umjetne neuronske mreže.....	5
Slika 3. Model umjetnog neurona koji imitira funkcionalnost biološkog neurona.....	6
Slika 4. Threshold Logic Unit.....	6
Slika 5. I logička funkcija u umjetnom neuronu	7
Slika 6. ILI logička funkcija u umjetnom neuronu.....	7
Slika 7. Funkcija s inhibicijskim ulazom u umjetnom neuronu	8
Slika 8. NE logička funkcija u neronu.....	8
Slika 10. Mreža s povratnom vezom.....	11
Slika 11. Hibridna Mreža	12
Slika 12. Princip rada preventivnog održavanja.....	17
Slika 13. Shematski prikaz planskog održavanja.....	19
Slika 14. Odvijanje dijagnostičkog postupka	21
Slika 15. SpectraQuest Simulator Expert	25
Slika 16. Izgled autonomnog broda	26
Slika 17. ReVolt DNV GL autonomni brod	30

POPIS TABLICA

Tablica 1. Prednosti i nedostaci korektivnog održavanja sustava **Error! Bookmark not defined.**