

Marko Valčić
Mr.sc. Julije Skenderović
Pomorski fakultet u Rijeci
Rijeka, Studentska 2

Pregledni članak
UDK: 004.032.26
004.891
629.5.03

Primljeno: 24. lipnja 2004.
Prihvaćeno: 02. srpnja 2004.

INTELIGENTNI SUSTAVI NADZORA I DIJAGNOSTIKE KVAROVA TEMELJENI NA UMJETNIM NEURONSKIM MREŽAMA

Razvoj i primjena novih računalnih tehnologija temeljenih na algoritmima umjetne inteligencije, mogu uvelike poboljšati kvalitetu i performanse sustava za nadzor rada i dijagnostiku kvarova brodskih pogonskih postrojenja. Rad je strukturno podijeljen u tri gotovo nezavisna dijela. Prvi dio predstavlja kratki uvod u umjetne neuronske mreže kako bi se ta tematika približila studentima i inženjerima pomorskog prometa koji se tijekom svog školovanja s njom gotovo i ne susreću. U drugom su dijelu analizirani postojeći, većinom ekspertni, sustavi nadzora i dijagnostike kvarova koje koriste vodeći svjetski proizvođači brodskih motora. Treći dio predstavlja mogućnosti poboljšanja postojećih sustava implementiranjem novih tehnologija poput umjetnih neuronskih mreža, neizrazite logike i njihovih kombinacija, a sve u svrhu povećanja sigurnosti i pouzdanosti u radu brodskih pogonskih postrojenja.

Ključne riječi: umjetne neuronske mreže, neizrazita logika, ekspertni sustavi, dijagnostika kvarova, upravljanje

1. UVOD

Sve veća inicijativa za smanjenjem broja članova posade u brodskoj strojarnici, traži u novije vrijeme od projekatana iznimno visok stupanj automatizacije kako glavnog brodskog motora, tako i većine ostalih komponenti koje zajedno čine vrlo kompleksan brodski pogonski sustav. Kako bi se takva inicijativa uistinu i mogla ostvariti, potrebno je zadovoljiti nekoliko preduvjeta koje konvencionalni sustavi automatizacije ne mogu omogućiti. Među njima, jedan od najvažnijih je mogućnost da sustav nadzora i upravljanja bez kontrole operatera može sam donositi brze i ispravne odluke čak i u najkritičnim situacijama. Takav bi sustav također trebao

biti i tolerantan na kvarove, čime bi mu se omogućila odgovarajuća autonomija kako u samoj dijagnostici kvarova, tako i rješavanju problema koje kvarovi mogu izazvati. Postojeći ekspertni sustavi predstavljaju veliki korak prema tom cilju, ali tek implementiranjem novih, inteligentnih računalnih tehnologija mogu se očekivati dovoljno kvalitetni rezultati. Osnovna ideja takvih tehnologija počiva na bazi znanja s mogućnošću kontinuiranog praćenja i nadopunjavanja. Početno znanje takvom inteligentnom sustavu mogu omogućiti eksperti, operateri, proizvođači samih motora, rezultati testiranja i simuliranja itd. Korištenje i primjenu takvog znanja mogu realizirati sustavi temeljeni na algoritmima umjetne inteligencije. Neizrazita logika omogućuje akcije takvog sustava koje su najbliže čovjekovu načinu razmišljanja, te kombiniranjem s umjetnim neuronskim mrežama čini temelj inteligentnog sustava za nadzor i upravljanje tolerantan na kvarove, koji bi trebao biti dostojna zamjena za čovjeka. Umjetne neuronske mreže imaju mogućnost da uče u realnom vremenu, da se prilagode novim i nepredvidivim situacijama, te da iznimno brzo procesiraju veliki broj informacija. Sve su to razlozi koji ih čine najboljim izborom u rješavanju većine problema s područja dijagnostike kvarova u on-line režimu rada.

U nastavku rada je dan kratki pregled teorije umjetnih neuronskih mreža, kako bi se lakše mogla pratiti analiza postojećih i novih sustava koji su na njima temeljeni.

2. UMJETNE NEURONSKE MREŽE

Originalna ideja umjetne neuronske mreže (engl. artificial neural network) nastala je iz niza pokušaja modeliranja fiziologije ljudskog mozga, s ciljem razumijevanja i objašnjenja kako isti funkcionira. Ta ideja podrazumijeva kreiranje modela sposobnog da prihvaća, obrađuje, generira, pohranjuje i prenosi informacije, analogno aktivnostima mozga. Formalizaciju aktivnosti umjetnog neurona, osnovanoj na tvrdnjama W. Jamesa, dali su McCulloch i Pitts 1943. godine, predloživši jednostavan model umjetnog neurona koji je i do danas ostao osnova za razvoj novih neuronskih mreža. Pritom se umjetne neuronske mreže međusobno razlikuju po strukturi veza među neuronima, te po metodologiji određivanja intenziteta tih veza, što predstavlja proces učenja mreže. Danas su opće prisutna dva, u biti različita, pristupa modeliranja umjetnih neuronskih mreža. Prvi pristup ima za cilj realizirati modele koji dovoljno točno oponašaju aktivnosti mozga, što bi u perspektivi trebalo rezultirati sustavima umjetne inteligencije. Drugi pristup podrazumijeva razvoj umjetnih neuronskih mreža s velikim računarskim sposobnostima, koje bi trebale rješavati konkretne i vrlo precizno definirane praktične probleme (neuroračunala).

Osnovne su prednosti neuroračunala nad klasičnim serijskim von Neumannovim računalima u masivnom paralelizmu pri procesiranju informacija. Naime, kod klasičnih

računala proces računanja se odvija u serijskim sekvencama, gdje se sljedeća sekvenca izvrši tek kad prethodna završi, što značajno usporava ukupni proces računanja. Nadalje, velike prednosti neuroračunala leže i u njihovim mogućnostima adaptivnosti, te u sposobnosti učenja.

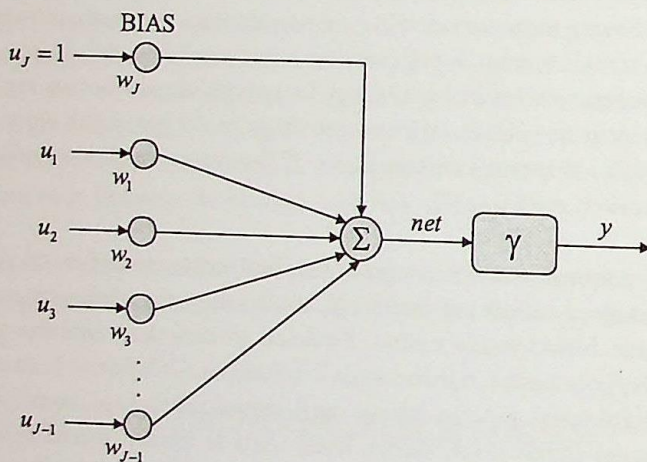
Danas se pretpostavlja da će umjetne neuronske mreže moći oponašati funkcije mozga. Da bi se to omogućilo, moraju se razumjeti sve funkcije i organizacija rada mozga, što je jedan od najvećih izazova i ciljeva u svijetu znanosti, koji vjerojatno neće biti potpuno ostvaren u skoroj budućnosti. Postojeće neuronske mreže se grade na osnovi iznimno pojednostavljenih modela, koji ne uzimaju u obzir većinu poznatih funkcija mozga. Razlog tome treba tražiti u nemogućnosti da se poznate kompleksne funkcije mozga transformiraju u odgovarajući matematički model. U tom smislu, pristup preko koncepta neizrazite logike (engl. fuzzy logic) dosta obećava već u skoroj budućnosti. Ponajviše se očekuje od kombiniranja pomoću genetičkih algoritama [2, str. 539], neizrazitih i ekspertnih sustava [2, str. 523] sa sustavima koji su temeljeni na umjetnim neuronskim mrežama [1].

Umjetna neuronska mreža je u pravilu složeni sustav, sastavljen od elemenata (neurona) koji stoje u određenoj interakciji, međusobno i s okolinom sustava, te na taj način grade funkcionalnu cjelinu. Paralelno složeni skup neurona gradi sloj neuronske mreže, koja može biti jednoslojna ili višeslojna. Uobičajeno je da višeslojne mreže imaju ulazni (engl. input) i izlazni (engl. output) sloj (engl. layer), a između njih su tzv. skriveni slojevi (engl. hidden layer). Ako se slojevi mreže povežu tako da signali putuju samo u jednom smjeru, od ulaza prema izlazima mreže, onda su to unaprijedne (engl. feedforward) umjetne neuronske mreže. Ukoliko postoji barem jedna povratna petlja, u kojoj se pojavljuje suprotni smjer signala, riječ je o povratnim (engl. feedback; recurrent) umjetnim neuronskim mrežama. U odnosu na vrijeme, razlikujemo vremenski kontinuirane i vremenski diskretne neuronske mreže. S obzirom na primjene, razlikujemo perceptronske, asocijativne, dvostruko asocijativne, adaptivne, kognitorske i neokognitorske umjetne neuronske mreže. Neke se umjetne neuronske mreže nazivaju prema metodama koje se koriste za njihovo učenje, pa razlikujemo povratno propagirane (engl. back-propagation), suprotno propagirane (engl. counter-propagation), statističke neuronske mreže itd. Neki se pak modeli umjetnih neuronskih mreža nazivaju prema njihovim autorima, poput Elmanove, Kohonenove ili Hopfieldove neuronske mreže. Umjetne neuronske mreže možemo također podijeliti i s obzirom na način njihova učenja. Tako razlikujemo mreže s učiteljem (uz nadzor) kod kojih "učitelj" promatra ponašanje mreže korigirajući istu dok se ne dobije željeno ponašanje, te mreže bez učitelja (bez nadzora) kod kojih se neuronska mreža sama organizira.

Najpoznatija i najčešće korištena vrsta umjetnih neuronskih mreža je diskretna statička neuronska mreža s povratnim rasprostiranjem pogreške (engl. error back-propagation), iako se u posljednje vrijeme sve češće predlaže i cijeli niz drugih neuronskih mreža, ovisno o problemu koji se nastoji riješiti.

2.1. Model statičkog neurona

Standardni model statičkog neurona je prikazan na slici 1. Ulazni podaci u_1, u_2, \dots, u_{j-1} predstavljaju skup uzoraka koji se redom množe s težinskim koeficijentima w_1, w_2, \dots, w_{j-1} .



Slika 1. Model statičkog neurona

Izvor: [3, str. 21]

U sumatoru Σ se tako dobiveni produkti zbrajaju prema izrazu

$$net = \sum_{j=1}^J w_j u_j.$$

Svrha tog množenja je utjecaj na izlaz neurona variranjem težinskih koeficijenata. Dobivena suma se dovodi na ulaz aktivacijske funkcije γ , koja na svom izlazu daje izlaz neurona


$$y = \gamma(net).$$

Aktivacijskom funkcijom postiže se normiranje, tj. svodenje vrijednosti izlaza neurona na unaprijed određeni skup vrijednosti. Ovisno o toj vrijednosti, mijenjaju se (adaptiraju) težinski koeficijenti pojedinih neurona, što u suštini predstavlja proces učenja (treniranja) neuronske mreže formirane njihovim međusobnim povezivanjem. Za vrijeme učenja neki neuroni mogu trajnije ostati neadaptirani. Kako bi se to izbjeglo, svakom se neuronu dodaje još jedan poseban ulaz jedinične vrijednosti koji

se u strukturi mreže ostvaruje vezom sa zasebnim neuronom oznake Bias.

Za aktivacijsku se funkciju (engl. activation function) obično odabire neka od monotono rastućih funkcija sa zasićenjem, poput unipolarne sigmoidalne aktivacijske funkcije (slika 2.) čija je jednadžba

$$y = \frac{1}{1 + e^{-net}} = \frac{e^{net}}{e^{net} + 1}$$



Slika 2. Unipolarna sigmoidalna aktivacijska funkcija

2.2. Građa umjetne neuronske mreže

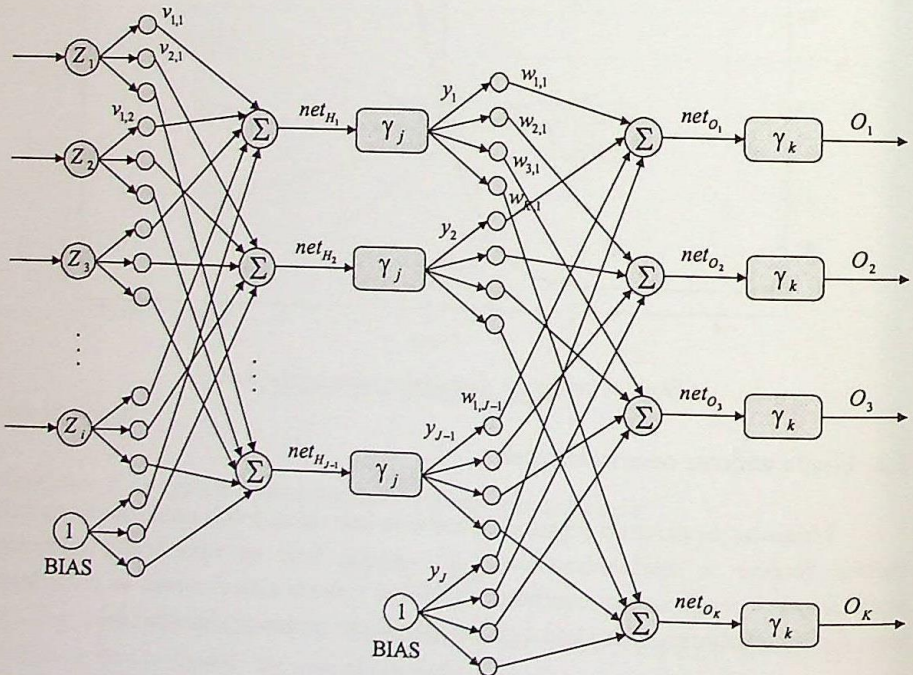
Neurone je potrebno organizirati u slojeve kako bi se dobila struktura neuronske mreže. Slojevi se međusobno povezuju vezama koje su opterećene težinskim koeficijentima (engl. weight coefficients). Ulazni i izlazni slojevi mreže su u direktnoj interakciji s okolinom, a sloj koji nema te interakcije naziva se skriveni sloj.

Najčešće korištena vrsta umjetne neuronske mreže je statička unaprijedna višeslojna neuronska mreža, prikazana u općem obliku na slici 3. Na njoj ćemo opisati osnovne principe po kojima neuronska mreža funkcionira.

Ulazi neurona ulaznog sloja Z_i su ujedno i ulazi u mrežu. Ulazni je sloj povezan sa skrivenim slojem pomoću veza koje su opterećene težinama v_{ji} . Svi su slojevi neuronske mreže potpuno umreženi, odnosno svaki je neuron promatranog sloja povezan sa svakim neuronom prethodnog sloja, pri čemu su izuzetak neuroni Bias koji uvijek imaju vrijednosti izlaza jednake jedinici. Izlazni sloj neurona definira

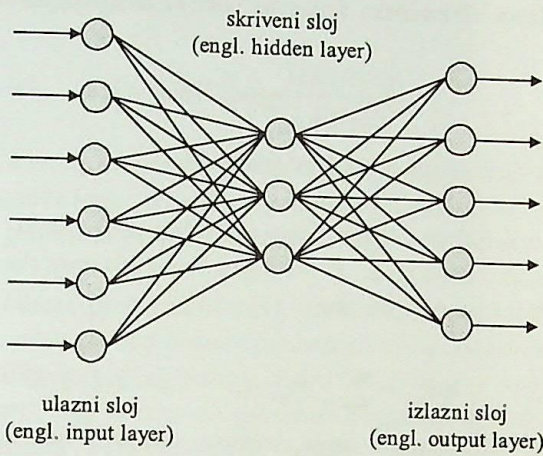
izlaze neuronske mreže O_k , a povezan je sa skrivenim slojem neurona težinskim koeficijentima w_{kj} .

Neuronska mreža je preslikavanje kod kojeg je broj nezavisnih varijabli jednak broju ulaznih neurona, a broj zavisnih varijabli je jednak broju izlaznih neurona. Drugim riječima, neuronska mreža je operator koji vektoru, čija je dimenzija jednaka broju ulaznih neurona, pridružuje vektor dimenzije jednake broju izlaznih neurona. Broj neurona u skrivenom sloju, kao i broj takvih slojeva, nije točno određen. Međutim, dokazano je da se svaka kontinuirana funkcija može dobro aproksimirati već s jednim skrivenim slojem neurona, a broj neurona u tom sloju mora biti dovoljno velik. Odgovarajući broj neurona ovisi o složenosti funkcije koju se želi aproksimirati, te ga je potrebno ispitati na zadanom slučaju.



Slika 3. Opći oblik statičke unaprijedne višeslojne neuronske mreže

Slika 4. prikazuje pojednostavljeni oblik iste mreže, za slučaj da neuronska mreža ima šest ulaznih ili nezavisnih varijabli te pet izlaznih ili zavisnih varijabli. Prikazani primjer neuronske mreže ima tri neurona u skrivenom sloju.



Slika 4. Pojednostavljeni prikaz statičke unaprijedne višeslojne neuronske mreže

2.3. Učenje umjetne neuronske mreže

U unaprijednoj se fazi učenja iz skupa za učenje uzimaju vrijednosti ulaznog vektora Z , te se pomoću njih izračunavaju komponente izlaznog vektora O . Za taj je proračun potrebno postaviti početne vrijednosti težinskih koeficijenata u matricama v (skriveni sloj) i w (izlazni sloj). Za skriveni se sloj te vrijednosti računaju generatorom slučajnih brojeva (engl. random function). Težine izlaznog sloja se također mogu računati na spomenuti način, iako se time ne osigurava brzi početak učenja neuronske mreže. Jedan od načina rješavanja ovog problema može biti postavljanje polovice početnih vrijednosti koeficijenata izlaznih neurona u jedinicu, a drugu polovicu u minus jedan. Umjesto da početne vrijednosti težinskih koeficijenata skrivenog sloja neurona budu potpuno slučajno odabrane vrijednosti, moguće ih je računati i posebnim postupcima koji uzimaju u obzir zadani broj neurona u tom sloju, broj ulaznih varijabli, te najveće i najmanje vrijednosti koje poprima svaka od ulaznih varijabli. Jedna od tih metoda je metoda po Nguyenu i Widrowu, a njena primjena omogućava kraći postupak učenja neuronske mreže u odnosu na učenje s potpuno slučajno postavljenim vrijednostima težinskih koeficijenata.

Prema oznakama na slici 3., funkcija sume net neurona skrivenog sloja H dobiva prvi indeks oznake sloja net_H , a za svaki j -i neuron dobiva drugi indeks, te se računa na sljedeći način:

$$net_{Hj} = \sum_{i=1}^I v_{ji} Z_i, \quad (j = 1, 2, \dots, J-1; i = 1, 2, \dots, I)$$

pri čemu je I broj ulaznih neurona uvećan za jedan, a J broj neurona u skrivenom sloju također uvećan za jedan (zbog Biasa). Ukoliko se u skrivenom sloju postavi

unipolarna sigmoidalna aktivacijska funkcija, tada se izlazi skrivenog sloja neurona računaju prema

$$y_j = \frac{1}{1 + e^{-net_{jy}}}, \quad j = 1, 2, \dots, J-1$$

$$y_J = 1 \quad (\text{Bias}).$$

Izračunate vrijednosti izlaza neurona skrivenog sloja preko težinskih koeficijenata w_{kj} spojene su na ulaze K svakog neurona izlaznog sloja O_k . U izlaznom je sloju funkcija *net* zapisana u obliku:

$$net_{ok} = \sum_{j=1}^J w_{kj} y_j, \quad k = 1, 2, \dots, K.$$

Ukoliko se i u izlaznom sloju neurona odabere unipolarna sigmoidalna aktivacijska funkcija, na izlazu neuronske mreže dobiva se :

$$O_k = \frac{1}{1 + e^{-net_{ok}}}, \quad k = 1, 2, \dots, K.$$

U povratnoj se fazi učenja umjetne neuronske mreže na temelju izračunatih izlaza mreže O i željenih (referentnih) izlaza R izračunavaju pogreške učenja E . Na temelju tih pogrešaka korigiraju se vrijednosti težinskih koeficijenata veza između pojedinih slojeva neurona. Čitav postupak se ponavlja za svaki od N ulazno-izlaznih parova podataka iz skupa za učenje, sve dok se ne postigne pogreška manja ili jednaka od dozvoljene koju, ovisno o problemu koji se rješava određuje učitelj.

Uobičajena statistička metoda regresijske analize, suma kvadrata pogreške, kao mjera odstupanja izlaza mreže od željene vrijednosti izlaza, najčešće je korištena funkcija cilja

$$E = \frac{1}{2} \sum_{n=1}^N (R_n - O_n)^2,$$

pri čemu je N broj elemenata u skupu za učenje.

Na temelju odabrane funkcije cilja E , mijenjaju se vrijednosti težinskih koeficijenata \mathfrak{G} pomoću nekog od algoritama nelinearnog programiranja. Nakon n -tog koraka učenja, nove će se vrijednosti težinskih koeficijenata $\mathfrak{G}(n+1)$ u $(n+1)$ -om koraku izračunavati iz prethodnih vrijednosti $\mathfrak{G}(n)$ i veličine promjene težinskih koeficijenata $\Delta\mathfrak{G}(n)$ prema izrazu:

$$\mathfrak{G}(n+1) = \mathfrak{G}(n) - \eta \nabla E(\mathfrak{G}(n)), \quad (\diamond)$$

pri čemu je η koeficijent brzine učenja i predstavlja mjeru promjene pogreške, dok je

gradijent pogreške $E(\vartheta(n))$ dan izrazom:

$$\nabla E(\vartheta(n)) = \frac{\partial E(\vartheta(n))}{\partial \vartheta(n)}$$

Izraz (♦) je u teoriji umjetnih neuronskih mreža poznat kao algoritam povratnog rasprostiranja pogreške (engl. error back-propagation algorithm) i jedan je od najčešće korištenih načina promjene parametara učenja.

Kako bi se ubrzao postupak učenja pomoću algoritma povratnog rasprostiranja pogreške, odnosno smanjio broj potrebnih koraka iteracije za traženu točnost, razvijene su različite modifikacije tog algoritma. Jedna od njih je i upotreba momentuma (momenta tromosti), koji u izraz za proračun pogreške $\Delta\vartheta(n)$ uvodi i promjenu težinskih koeficijenata u prethodnom koraku, $\Delta\vartheta(n-1)$. Promjena težinskih koeficijenata će se ovom metodom izračunavati prema izrazu kojeg ovdje bez izvoda navodimo samo u konačnom obliku, a on glasi:

$$\vartheta(n+1) = \vartheta(n) - \eta \nabla E(\vartheta(n)) + \alpha \Delta\vartheta(n-1),$$

pri čemu se vrijednost momenta tromosti α određuje proizvoljno unutar intervala $(0, 1)$. Primjenom momenta tromosti u algoritmu povratnog rasprostiranja pogreške, brzina učenja se povećava i do deset puta.

Kod povratne faze učenja povratnim prostiranjem pogreške, promjena parametara učenja odvija se od izlaznog ka ulaznom sloju mreže, pri čemu se promjena težinskih koeficijenata između izlaznog i skrivenog sloja ($\vartheta = w_{kj}$) odvija prema izrazu :

$$w_{kj}(n+1) = w_{kj}(n) - \eta \nabla E(w_{kj}(n)) + \alpha \Delta w_{kj}(n-1),$$

kojeg nakon određenih transformacija u slučaju unipolarne aktivacijske funkcije pišemo u konačnom obliku

$$w_{kj}(n+1) = w_{kj}(n) + \eta O_k(R_k - O_k)(1 - O_k)y_j + \alpha \Delta w_{kj}(n-1).$$

Nakon promjene svih težina w_{kj} izlaznog sloja, slijedi promjena težina skrivenog sloja $\vartheta = v_{ji}$. Algoritam promjene tih težinskih koeficijenata je definiran izrazom kojeg ovdje također dajemo samo u konačnom obliku, bez izvoda

$$v_{ji}(n+1) = v_{ji}(n) + \eta y_j(1 - y_j)Z_i \sum_{k=1}^K \delta_{ok} w_{kj} + \alpha \Delta v_{ji}(n-1),$$

pri čemu je

$$\delta_{ok} = O_k(R_k - O_k)(1 - O_k)$$

koeficijent koji predstavlja karakterističnu vrijednost samog algoritma.

Konačne jednadžbe za promjene težinskih koeficijenata u izlaznom i skrivenom sloju vrijede jedino za model neuronske mreže koji je prikazan na slici 3., te za odabrane aktivacijske funkcije neurona u izlaznom i u skrivenom sloju.

Ukoliko bi se u neuronsku mrežu postavio još jedan skriveni sloj neurona, numerički postupak za proračun promjena težinskih koeficijenata bio bi analogan. Svaki novi skriveni sloj neurona teoretski omogućava uspješnije učenje i sposobnost generalizacije, ali zahtjeva i dulje vrijeme proračuna. Također, odziv neuronske mreže s više skrivenih slojeva neurona je sporiji od mreže s jednim skrivenim slojem.

Opisani nadzirani način učenja neuronske mreže predstavlja postupak koji se najčešće koristi kod dijagnostičkih i regulacijskih sustava. Uz nadzirani, postoje još i samoorganizirajući, pojačani, slučajni i kombinirani zakoni učenja. Kod samoorganizirajućeg načina učenja, mreži se daje samo ulazni uzorak na temelju kojeg ona bez nadzora oblikuje reakcije na isti. Postupak se temelji na konkurentskom ponašanju pojedinih procesnih jedinica koje mijenjaju svoje težinske koeficijente, ako ih ulazni uzorak najjače pobuđuje. Drugim riječima, za vrijeme učenja određene procesne jedinice generiraju samoodlučujuće razrede uzoraka i ujedno postaju senzori uzoraka. Pojačani (engl. reinforcement) zakon učenja u biti predstavlja verziju nadziranog učenja s razlikom da se u ovom slučaju ne daje izlazni uzorak, već se umjesto toga za svaki izvedeni postupak izvrši vrednovanje u obliku skalarne vrijednosti što predstavlja kriterij kvalitete. Kod slučajnog zakona učenja, neuronska mreža ima slobodu da metodom pokušaja i pogrešaka sama traži rješenje. Za promjenu jačine veza u mreži koriste se slučajni procesi, razdiobe vjerojatnosti, te primjereno definirano stanje mreže kao cjeline. Slučajni zakon učenja u kombinaciji s gradijentnim postupkom najčešće se koristi u rješavanju regulacijskih problema. Svi opisani zakoni učenja većinom rade na načelu prilagođavanja težinskih koeficijenata, iako postoje i zakoni koji rade na načelu prilagođavanja mrežne strukture.

2.4. Normiranje podataka za umjetnu neuronsku mrežu

Oblik u kojem su ulazni podaci predstavljeni ulaznim neuronima umjetne neuronske mreže ima vrlo važan utjecaj na uspješnost učenja i na sposobnost generalizacije neuronske mreže. Osim toga, oblik ulaznih podataka utječe na vrijeme potrebno za proračun težinskih koeficijenata do zadane razine točnosti.

Postupak prilagodbe ulaznih i/ili izlaznih podataka za neuronsku mrežu naziva se normiranje podataka i najčešće se svodi na transformaciju svih ulaznih i/ili izlaznih vrijednosti unutar skupa $\{-1,1\}$ ili $\{0,1\}$. Ukoliko se za aktivacijsku funkciju neurona u izlaznom sloju neuronske mreže odabere neka od monotono rastućih funkcija sa zasićenjem, izlazne je podatke nužno normirati unutar područja vrijednosti koje ta

funkcija poprima. Stoga, kako bi se u fazi učenja neuronske mreže mogle ispravno izračunavati razlike između izračunatih izlaza mreže O_n i referentnih izlaza R_n , nužno je i referentne izlaze normirati u skup vrijednosti koje poprimaju izračunati izlazi mreže.

2.5. Ocjena uspješnosti algoritma učenja

Za procjenu točnosti algoritma učenja, tj. njegove uspješnosti u rješavanju postavljenog zadatka, potrebno je definirati mjeru točnosti. Najčešće se koriste sljedeće tri mjere točnosti algoritma učenja:

1. Srednja kvadratna pogreška, MS (engl. mean square error), definirana izrazom

$$MS = \frac{1}{N} \sum_{n=1}^N (R_n - O_n)^2,$$

pri čemu je N ukupan broj referentnih izlaza R_n ili ukupan broj izračunatih izlaza mreže O_n .

2. Korijen srednje kvadratne pogreške, RMS (engl. root mean square error), definiran izrazom:

$$RMS = \sqrt{MS} = \sqrt{\frac{1}{N} \sum_{n=1}^N (R_n - O_n)^2}.$$

3. Normalizirani korijen srednje kvadratne pogreške, $NRMS$ (engl. normalised root mean square error), definiran izrazom

$$NRMS = \frac{RMS}{\sigma_{R_n}} = \frac{1}{\sigma_{R_n}} \sqrt{\frac{1}{N} \sum_{n=1}^N (R_n - O_n)^2},$$

pri čemu je σ_{R_n} standardna devijacija referentnih izlaza mreže.

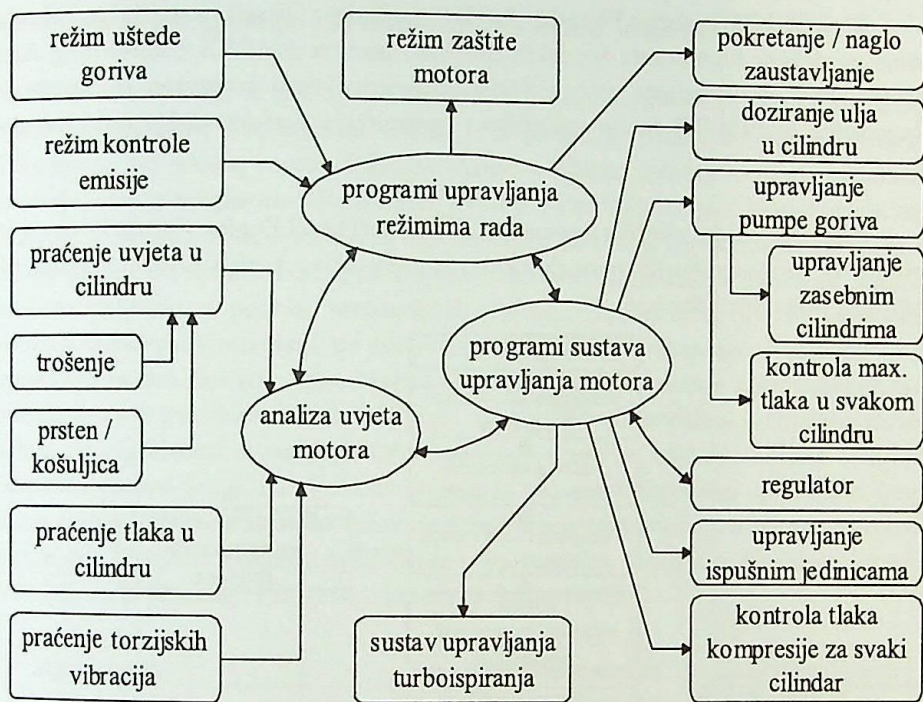
3. METODE I TEHNIKE U DIJAGNOSTICI KVAROVA DIZELSKIH MOTORA

Vodeći svjetski proizvođači brodskih motora (MAN B&W, Wärtsilä - NSD, S.E.M.T. Pielstick, ...) posljednjih dvadesetak godina vode oštru borbu kako bi poboljšali radne karakteristike brodskih dizelskih motora. Danas se još uvijek ponajviše radi na razvoju konstrukcijskih i tehnoloških noviteta, iako se u posljednje vrijeme sve više pažnje posvećuje razvoju sustava dijagnostike, nadzora i upravljanja u realnom vremenu, a sve u svrhu povećanja pouzdanosti, sigurnosti i ekonomičnosti. Ako tome pridodamo i nagli razvoj modernih brodskih plinskih turbina (GE, Rolls Royce, Kawasaki, Mitsubishi, ...) koje svojim radnim karakteristikama sve manje zaostaju za dizelskim motorima, sasvim je jasno kako će konkurentnost prisiliti sve proizvođače na još intenzivnija istraživanja u cilju implementacije novih tehnologija u postojeće sustave.

Glavni ciljevi u svrhu poboljšanja koji se postavljaju pred projektante brodskih motora su:

- veća adaptivnost zahtjevima propulzije u različitim režimima plovidbe
- pouzdanost pogona
- manja potrošnja goriva i ulja
- ispunjavanje ISO normi kod emisije štetnih spojeva (NO_x , SO_x , ...)
- automatski sustav upravljanja čime se smanjuje broj članova posade u stroju.

Kako bi se ti ciljevi ostvarili u što boljoj mjeri, najnoviji trendovi su usmjereni prema razvoju tzv. "inteligentnog motora" koji bi između ostalog imao mogućnost kontinuiranog praćenja, dijagnostike i upravljanja svim relevantnim procesima (slika 5). Takav sustav kontinuirano izvještava operatera o stanju i poteškoćama u radu uz dijagnozu nastalog kvara, te s preporukama za rad motora dok se ne uspostave normalni radni uvjeti. Prvi takav sustav je implementiran 1998. godine u brodski motor MAN B&W 6L60MC [5, str. 51] i prema podacima proizvođača pokazao je vrlo dobre rezultate.



Slika 5. Koncept inteligentnog motora

Izvor: [5, str. 52]

3.1. Ekspertni sustavi u dijagnostici i nadzoru dizelskih motora

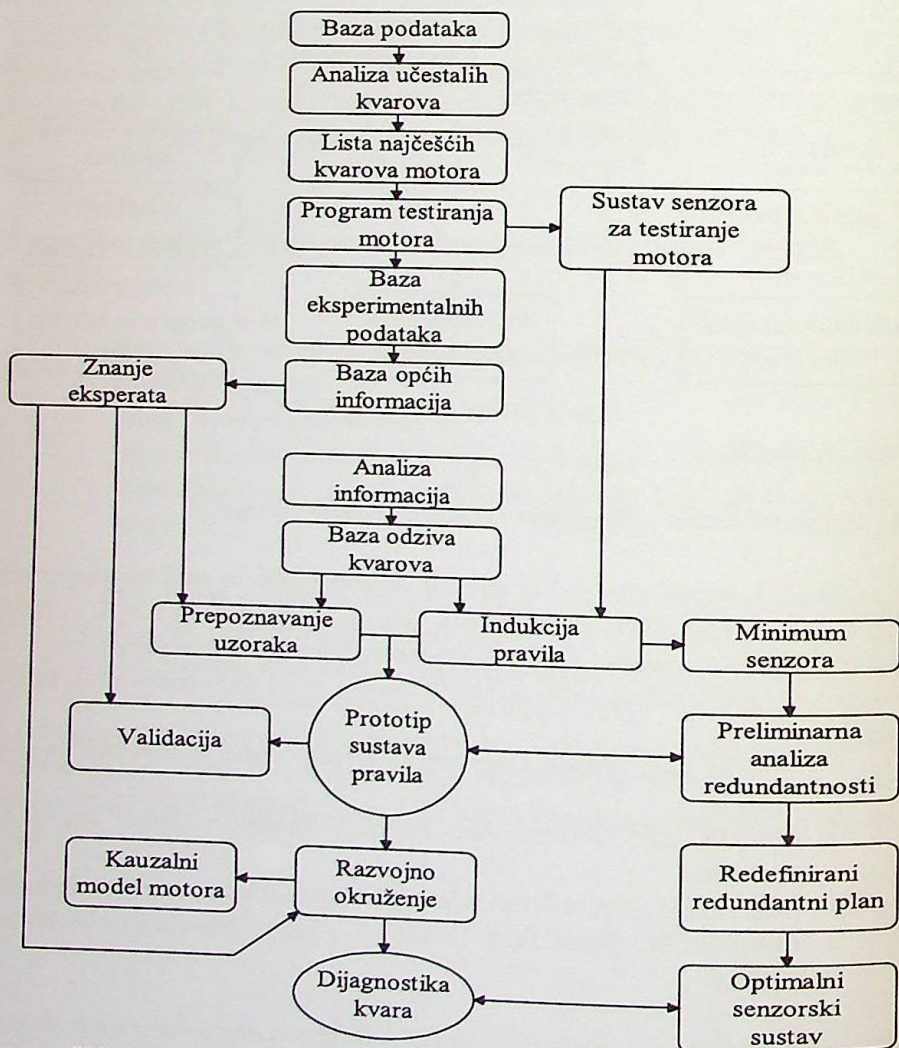
Najveći svjetski proizvođači brodskih motora razvili su cijeli niz ekspertnih sustava tijekom posljednjih desetak godina. Tako su MAN B&W i S.E.M.T. Pielstick u kooperaciji razvili sustav COCOS (COMputer COntrolled Surveillance) koji je u upotrebi na brodovima od 1998. godine [6]. Sastoji se od četiri glavna programska modula:

- COCOS EDS (Engine Diagnostics System) - sustav za dijagnostiku rada sustava
- COCOS MPS (Maintenance Planning System) - sustav planiranja održavanja
- COCOS SPO (Spare Parts Ordering) - sustav narudžbi rezervnih dijelova
- COCOS SPC (Spare Parts Catalogue) - sustav identifikacije rezervnih dijelova

EDS sustav dijagnostike rada motora dobiva podatke u realnom vremenu iz sustava nadzora u kojeg je integriran te na temelju njih i baze znanja o motoru obavlja odgovarajuću dijagnostiku.

Bivši SULZER, danas Wärtsilä - NSD (New Sulzer Diesel), razvio je i primijenio sustav za dijagnostiku stanja brodskih dizelskih motora MAPEX (Monitoring And Performance enhancement with EXpert knowledge) koji integriran sa sustavom dijagnostike SIPWA-TP pruža mogućnost optimiranja performansi u radu motora [7].

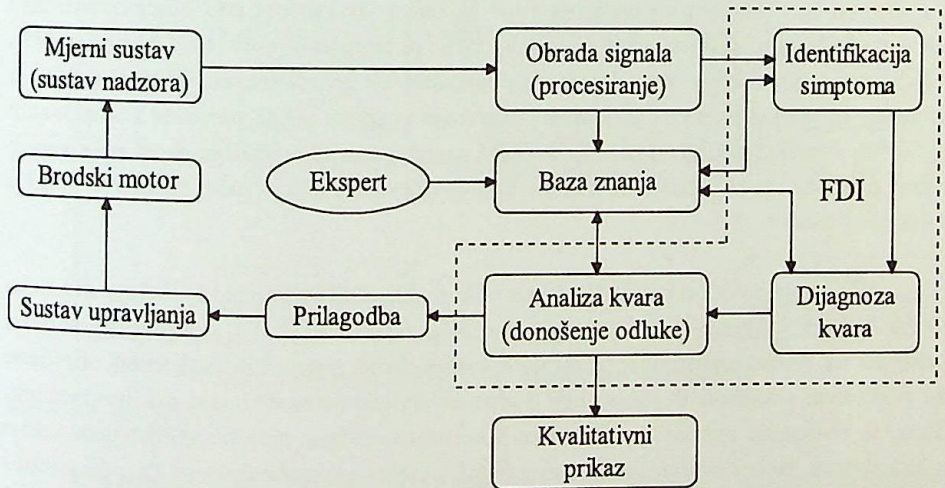
Razvojni proces ekspertnog sustava DEEDS (Diesel Engine Expert Diagnostic System) za dijagnostiku kvarova dizelskih motora, kojeg koristi Loyd's Register of Shipping, prikazuje slika 6.



Slika 6. Razvojni proces ekspertnog sustava za dijagnostiku kvarova DEEDS

3.2. O novim inteligentnim sustavima nadzora i dijagnostike kvarova

Osnovna ideja u razvoju inteligentnih sustava upravljanja leži u korištenju logike zaključivanja i donošenja odluka, što je karakteristika svojstvena čovjeku. Također se od takvog sustava očekuje dobro vladanje tijekom vođenja procesa u nepredvidivim situacijama. Prema tome, jasno je da su takvi sustavi zasnovani na bazi znanja o procesu i da upravo o njoj najviše ovise. Izvori za izgradnju baze znanja su mnogobrojni: od tehničkih podataka samih proizvođača, podataka dobivenih tijekom probnih puštanja u pogon, simulacijskih modela, podataka dobivenih iz sustava nadzora u realnom vremenu, pa sve do znanja i iskustva eksperata i operatera koji upravljaju samim postrojenjem. Nakon što se prikupljeno znanje sistematski obradi, potrebno ga je transformirati u oblik koji je najpovoljniji za daljnu računalnu obradu nekim od algoritama u realnom vremenu. U tu se svrhu najčešće koriste neizraziti ekspertni sustavi (engl. fuzzy expert systems), neizraziti algoritmi upravljanja (engl. fuzzy control), FDI (Fault Detection and Identification) sheme, umjetne neuronske mreže itd. Osnovni koncept upravljanja i dijagnostike brodskog dizelskog motora, temeljen na bazi znanja i sustavu nadzora, prikazuje slika 7.



Slika 7. Sustav upravljanja i dijagnostike kvarova temeljen na bazi znanja

Izvor: [5, str. 56]

U dijagnostici kvarova posebno važnu ulogu imaju izlazni signali iz senzora. Neposredno mjereni u realnom vremenu, najčešće su kontaminirani šumom koji je redovno prisutan u brodskim postrojenjima. Kako bi ih se što kvalitetnije moglo iskoristiti, potrebno ih je dodatno obraditi. Konvencionalni, uobičajeni način obrade signala temelji se na matematičkom modelu, poznatijem kao DSP (Digital Signal Processing), u kojem je definirana funkcionalna veza između ulaznih i izlaznih vrijednosti mjerenih signala. Sensorima se mjeri konačan broj varijabli sustava, a proces

obrade osigurava potrebna saznanja o ponašanju samog sustava koja su potrebna za odgovarajuću dijagnostiku. U brodskim postrojenjima često je nemoguće postaviti precizne matematičke modele kojima bi doveli u vezu ulazne i izlazne vrijednosti (više varijabli) dobivene senzorskim mjerenjima. Upravo u tu svrhu, kada je potrebno povezati kompleksne višedimenzionalne informacije u jednu jednoznačnu sliku, pogodno je koristiti se umjetnim neuronskim mrežama, ali i ostalim inteligentnim tehnikama poput neizrazite logike, ekspertnih sustava, Kalmanovih filtera itd.

Konvencionalni automatski sustavi čija je namjena da u kritičnim situacijama zaštite pojedine radne komponente ili čak cijeli sustav, a bez gubitka radnih performansi, zahtijevaju odgovarajuću hardversku redundantnost (engl. hardware redundancy) koja omogućuje korištenje više od jednog uređaja ili sklopa za ostvarivanje istog cilja. Taj je cilj u ovom slučaju automatski prijelaz rada s neispravne na ispravnu komponentu, od kojih su u pravilu dvije ili više njih paralelno umrežene. Time je omogućeno popravljjanje ili zamjena neispravne komponente, bez gubitka performansi u radu postrojenja. S druge strane, sustav upravljanja tolerantan na kvarove (engl. Fault Tolerant Control System, FTC System) omogućuje analitičku i programsku redundantnost u postrojenju i u sustavu automatskog upravljanja čime se ostvaruje nadzor nad komponentama i ostalim dijelovima sustava pomoću inteligentne programske podrške. Kvarovi se brzo lokaliziraju, nakon čega se poduzimaju odgovarajuće pravovremene akcije koje imaju za funkciju spriječiti da nastali kvarovi uzrokuju potpuni otkaz pojedine komponente ili cijelog sustava. Globalna strategija FTC sustava sastoji se u ideji da se postrojenje održi u visokom radnom režimu, uz prihvatljivo smanjenje performansi u slučaju kritičnih kvarova.

FTC sustav radi u on-line režimu rada u realnom vremenu. U slučaju detekcije kvara diskretni signal obavještava operatera o nastalom kvaru i odmah se aktivira podrška za poduzimanje odgovarajućih akcija, koje mogu biti unaprijed određene za svaki kvar posebno ili mogu biti poduzete temeljem analize u realnom vremenu. Time je realiziran sustav za dijagnozu i neovisni nadzor nad kontroliranjem stanja s kvarovima. Rekonfiguracija sustava (engl. system reconfiguration) će prilagoditi i promijeniti relacijske veze između postrojenja i sustava upravljanja s obzirom na vrstu i težinu kvara. Takva će prilagodba uzrokovati promjene parametara u upravljačkim modulima (kontroleri, regulatori, ...), ali neće mijenjati sklopovsku podršku i interakcijsku vezu između sustava upravljanja i postrojenja.

Glavne ciljeve inteligentne dijagnostike kvarova možemo podijeliti u tri osnovne skupine:

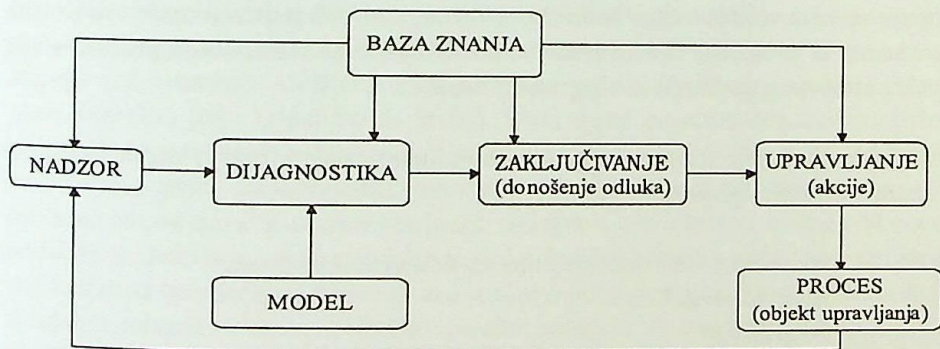
- ▶ *otkrivanje kvara* (engl. fault detection) - ima za funkciju detektirati poremećaj, tj. uočiti razliku između normalnog i neispravnog rada
- ▶ *lokalizacija kvara* (engl. fault isolation) - ima za funkciju klasificirati nastale

kvarove, odrediti mjesto i vrijeme nastanka te vrstu kvara

- ▶ *analiza i estimacija kvara* (engl. fault analysis and estimation) - ima za funkciju odrediti veličinu i uzroke kvara, kao i moguće posljedice. Prema potrebi se procjenjuje vrijeme nastanka kvara.

Možemo reći da je postavljena odgovarajuća dijagnostika kvara, ako su ispunjena najmanje prva dva cilja.

Kako bi se znatno povećale mogućnosti konvencionalnih sustava dijagnostike kvarova brodskih dizelskih motora, mora im se omogućiti prilagodba na nastale kvarove uz minimalne promjene u performansama rada motora. To se uz kvalitetan sustav nadzora i upravljanja može ostvariti primjenom on-line dijagnostike kvarova koja omogućuje određivanje reziduala (indikatora kvara) u realnom vremenu. Kada su dinamičke karakteristike sustava poznate s prihvatljivim stupnjem točnosti, model FTC sustava se koristi za generiranje estimiranih željenih izlaznih vrijednosti. Razlike između estimiranih i mjenjenih izlaznih signala predstavljaju primarne reziduale koji asimptotski teže k nuli.



Slika 8. Shematski prikaz on-line sustava dijagnostike

Izvor: [5, str. 107]

Načini generiranja reziduala, kao razlike između mjenjenih vrijednosti na realnom i izračunatih vrijednosti na nominalnom sustavu, predstavljaju uzroke prema kojima sustave dijagnostike možemo podijeliti u sljedeće tri skupine:

- ▶ sustavi dijagnostike koji reziduale određuju pomoću mjenjenih signala
- ▶ sustavi dijagnostike koji reziduale određuju pomoću matematičkih modela
- ▶ sustavi dijagnostike koji reziduale određuju pomoću znanja eksperata

Nakon pojave, otkrivanja i lokalizacije kvara, sustav upravljanja tolerantan na kvarove mora omogućiti rekonfiguraciju odgovarajućih dijelova sustava kako bi isti mogao nastaviti s radom bez značajnih gubitaka u performansama. Upravo u takvim slučajevima fuzija senzorskih informacija može imati vrlo važnu ulogu, posebno

kod sustava kod kojih je predviđeno korištenje više od jednog, ne nužno identičnog, načina za rješavanje istog problema pomoću modela u analitičkom obliku (analitička redundantnost). Osnovne komponente sustava upravljanja i dijagnostike čine:

- ▶ senzori – mjerni pretvornici, izvori informacija o sustavu
- ▶ regulatori – upravljački moduli koji odlučuju koje će se radnje poduzeti
- ▶ aktuatori – izvršne komponente, obavljaju odgovarajuće radnje
- ▶ proces – objekt upravljanja na kojeg se radnje primjenjuju.

Ukoliko se kvar dogodi na samom procesu ili među aktuatorima, prilagodba klasičnih sustava upravljanja u pravilu se sastoji u zamjeni neispravne komponente ispravnom. Međutim, sustav upravljanja tolerantan na kvarove omogućuje odgovarajuće promjene u algoritmima upravljanja tijekom radnog režima u realnom vremenu čime se mogu umanjiti ili čak potpuno spriječiti eventualne negativne posljedice po sam sustav uz nastavak rada. U slučaju kvarova na sensorima ili regulatorima, sustav upravljanja tolerantan na kvarove razvojem novih računalnih tehnologija omogućuje rekonfiguraciju sustava upravljanja. Time je omogućen normalan nastavak rada do eventualne zamjene neispravne komponente. Sposobnost umjetnih neuronskih mreža da uče tijekom režima rada u realnom vremenu, koristeći se primjerima i arhiviranim podacima iz prošlosti, čini ih ponajboljim izborom za modeliranje procesa s više načina rješavanja problema u dijagnostici kvarova.

Najznačajnije karakteristike umjetnih neuronskih mreža u svrhu kvalitetne obrade mjerenih signala su:

- sposobnost samoučenja pomoću arhiviranih podataka
- masivni paralelizam
- adaptivnost
- dobro vladanje u nelinearnim sustavima
- sposobnost tolerancije kvarova.

Postupak brzog i pouzdanog otkrivanja kvara u radnom režimu predstavlja preduvjet za odgovarajuću prilagodbu na nastali kvar. R. Antić u [5, str. 139] predlaže jednu takvu mogućnost uz primjenu logike adaptivnog praga i zaključivanja pomoću umjetnih neuronskih mreža. Simuliran je kvar senzora – davača tlaka u cilindru motora zbog visokih temperatura, pri čemu je korišten Widrow-Hoffov algoritam učenja [4, str. 4-13]. Ostvareno vrijeme detekcije kvara (~3,5 s) u simuliranom slučaju osigurava mogućnost pravovremenog djelovanja prije nego dođe do kvara samog senzora.

Adaptivni pragovi prilagođavaju se na promjene radnih uvjeta procesa na unaprijed očekivane poremećaje, dok im neuronske mreže svojim karakteristikama mogu bitno unaprijediti korištenje u detekciji kvarova. Osnovna prednost primjene

neuronskih mreža u detekciji i identifikaciji kvarova jest njihova sposobnost učenja i prilagodbe u realnom vremenu, dok u kombinaciji s neizrazitim ekspertnim sustavima povećavaju mogućnost sustava upravljanja kada je riječ o toleranciji i prilagodbi na kvarove.

Senzori, kao mjerni pretvornici, predstavljaju izvor informacija o trenutnom stanju procesa u propulzijskom sustavu i time čine oslonac u pravovremenom donošenju ispravnih odluka u različitim kritičnim situacijama. Njihova nerijetko visoka cijena od projektanata traži upotrebu optimalnog broja senzora koji se moraju razmjestiti na pažljivo odabranim mjestima brodskog porivnog sustava. Kvar već samo jednog senzora, bez obzira na njegovu funkciju, može stvoriti velike probleme kako sustavu za nadzor i dijagnostiku, tako i samim operaterima u donošenju ispravne odluke. Tom se problemu može kvalitetno doskočiti fuzijom senzorskih informacija, čime se omogućava estimacija izgubljenog signala temeljem ostalih mjerenih signala, a time i nastavak upravljanja i rada sustava.

U [8, str. 25] autori su predložili učinkovitu metodu za estimaciju signala brzine [rad/s] brodskog dizelskog motora MAN B&W 5L90MC pomoću modela temeljenog na umjetnim neuronskim mrežama. Model se sastoji iz dva stupnja. U prvom se stupnju vrši estimacija korištenjem tri neovisna signala (moment propelera [Nm], poriv propelera [N] i brzina broda [m/s]). Svaki signal posebno obrađuje po jedna unaprijedna neuronska mreža, nakon čega se u drugom stupnju vrši fuzija dobivenih informacija pomoću samoorganizirajuće neuronske mreže (engl. self-organising map), pri čemu izlazni signal predstavlja najbolje estimirani broj okretaja motora. Skupovi podataka za treniranje mreže su odabrani za četiri radna režima u vožnji i svi dobiveni rezultati su zadovoljavajući, posebno kad je riječ o praktičnoj primjeni koja ne iziskuje apsolutnu točnost. Ostvarene razlike između podataka za treniranje i onih koji su služili u svrhu testiranja mogu se objasniti nedovoljno velikim skupom podataka u procesu treniranja.

U nastavku citiranog rada, autori su predložili upotrebu Elmanove dvoslojne rekurentne neuronske mreže [4, str. 9-3] s povratnim djelovanjem za brzu detekciju promjene položaja ručice brodskog strojnog telegrafa. Povratna veza od izlaza prvog sloja na ulaz, uz pohranjivanje informacija za kasnije korištenje, omogućuje da se Elmanova neuronska mreža uči i trenira za otkrivanje i generiranje vremenski ili prostorno promjenjivih uzoraka signala. Simulacijski rezultati su u ovom slučaju pokazali sposobnost Elmanove mreže da vrlo brzo detektira promjenu položaja ručice brodskog telegrafa, uz sasvim dobre mogućnosti generiranja odgovarajućeg signala komande brzine, uzrokovanim promjenom u režimu rada motora.

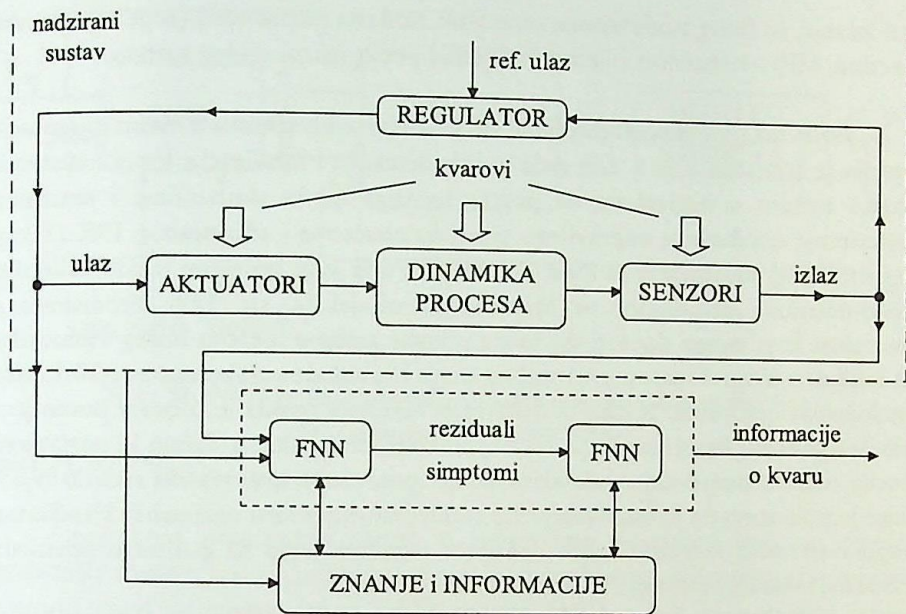
Još jedan zanimljivi primjer predstavlja proces izgaranja goriva u motoru s unutrašnjim izgaranjem. To je nelinearan dinamički proces koji je u dijelovima

stohastičkog karaktera i kojeg je vrlo teško matematički modelirati. Razloge tome treba tražiti u činjenici da fenomen procesa izgaranja još nije u potpunosti objašnjen i definiran do kraja. Međutim, tlak u cilindru motora s unutrašnjim izgaranjem predstavlja vrlo pouzdanu i izravnu mjeru kvalitete izgaranja. Uzmemo li u obzir i znanje o ostalim radnjama u cilindru tijekom izgaranja (poput otvaranja i zatvaranja ventila, raspršivanja goriva, ...), vrijednost tlaka u cilindru može biti vrlo korisna pomoć u otkrivanju anomalija u procesu izgaranja. Te su činjenice iskoristili autori u [11] predloživši način na koji bi sustav za dijagnostiku kvarova trebao detektirati nepravilnosti u procesu izgaranja na temelju podataka o tlakovima u pojedinim cilindrima. Obradene podatke autori su prikupili tijekom rada četverotaktnog, dvocilindričnog, zrakom hlađenog dizel motora Lister Petter, izlazne snage 10.4 kW pri 3000 min⁻¹. Podaci su pažljivo odabrani tijekom normalnog rada motora uz namjerno odabrane i dvije pogreške (propuštanje ispušnog ventila i nekvalitetno raspršenje goriva kroz sapnice rasprskavača). Za analizu korištenih podataka, autori su se služili unaprijednom umjetnom neuronskom mrežom s jednim skrivenim slojem. Pri učenju mreže korišten je algoritam povratnog rasprostiranja, dok je za aktivacijsku funkciju odabrana unipolarna sigmoidalna funkcija s tri neurona u izlaznom sloju (normalan rad, nepravilni rad ispušnog ventila, nepravilni rad rasprskavača). Nakon različitih modula simulacije, pokazano je da se bolji rezultati ostvaruju ako se koristi kombinacija više neuronskih mreža, slično kao i u prethodno navedenom primjeru estimacije broja okretaja motora (Antonić i dr.).

Zaključak ovih autora, gotovo je identičan zaključcima cijelog niza radova s područja ove tematike (poput [8], [9], [10], [11], [12], [13], [14], [16], [29]). Umjetne neuronske mreže predstavljaju snažan temelj novih inteligentnih sustava za nadzor i dijagnostiku kvarova, bez obzira koristile se one u analizi samo jedne komponente brodskog porivnog sustava ([8], [9], [10], [11], [12], [29]) ili u analizi sustava u cijelosti ([13], [14], [15], [16], [18], [26], [27]). On-line režim rada takvih sustava omogućava brzu detekciju i najmanjih nepravilnosti u radu pojedinih komponenti s mogućnošću pohrane takvih specifičnih situacija u svrhu daljnjeg korištenja pri prilagodbi, ukoliko se slični problemi ponovno pojave u radu postrojenja.

3.3. Kombinirani neuro-neizrastiti pristup u svrhu dijagnostike kvarova

U posljednje vrijeme sve se više istražuju dijagnostičke sheme temeljene na kvalitativnom, heurističkom modelu i znanju eksperata, te njihova primjena u kombinaciji s kvantitativnim modelima. Pri tome se intenzivno koriste prednosti novih računalnih tehnologija poput neuronskih mreža, neizrastite logike, genetičkih algoritama, itd. Slika 9. ilustrira princip u kojem se kombinira neuro-neizrastiti (engl. neuro-fuzzy) pristup (FNN) temeljen na on-line informacijama iz sustava nadzora i znanju eksperata iz baze znanja, pri čemu se promjenom upravljačkog algoritma ili djelovanjem na sam proces vrši rekonfiguracija sustava upravljanja u realnom vremenu.



Slika 9. Kombinirani neuro-neizraziti pristup u dijagnostici i prilagodbi na kvar

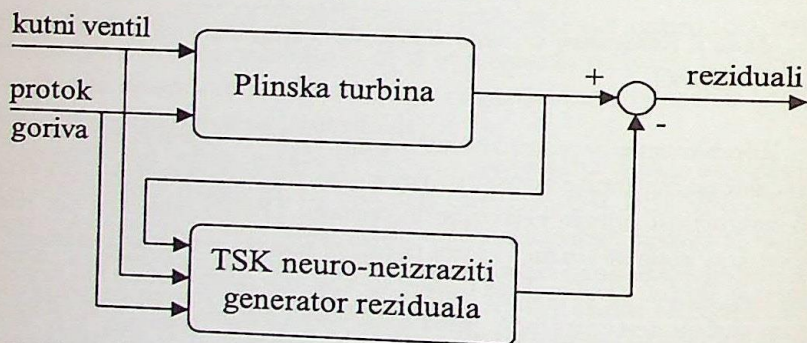
Izvor: [5, str. 146]

Kombiniranje neuro-neizrazitih sustava može se napraviti na dva načina. U prvom slučaju, neizrazite neuronske mreže čine baznu metodologiju, pri čemu one imaju mogućnost obrade neizrazitih informacija. Obično posjeduju tzv. neizrazite neurone kod kojih su ulazni i izlazni podaci te težinski koeficijenti, elementi nekog neizrazitog skupa. Jasno je da će i operacije koje vrše takvi neuroni biti neizrazite. U drugom slučaju neizrazita logika predstavlja baznu metodologiju, dok joj neuronske mreže omogućavaju učenje, prilagodbu i masivni paralelizam (neuro-neizraziti sustavi). Moduli bazirani na umjetnim neuronskim mrežama mogu raditi u paralelnim ili serijskim konfiguracijama s modulima baziranim na neizrazitoj logici na način da se međusobno potpomažu. U nekim pristupima, neuronska mreža (primjerice Kohonenova) može izvršiti pre-procesiranje informacija za primjenu u neizrazitim sustavima na način da klasterizira podatke ili da im jednostavno ukloni šum. Međutim, češća je primjena da u FDI dijagnostičkim shemama neizraziti sustav izvrši pre-procesiranje ulaznih podataka za neuronsku mrežu koja onda lokalizira kvar.

Neuro-neizraziti sustavi kombiniraju prednosti neizrazitih sustava kada je riječ o ekspertnom načinu zaključivanja, te naučenih i dobro istreniranih umjetnih neuronskih mreža kad govorimo o impliciranju tog znanja u konkretnim problemima. Mogućnost neuronske mreže da uči, predstavlja kvalitetnu alternativu u smislu nadopune ekspertnog znanja, automatskog podešavanja novih neizrazitih pravila u

bazi znanja, te finog podešavanja pojedinih funkcija pripadnosti (engl. membership function, MF) s konačnim ciljem poboljšanja performansi cijelog sustava.

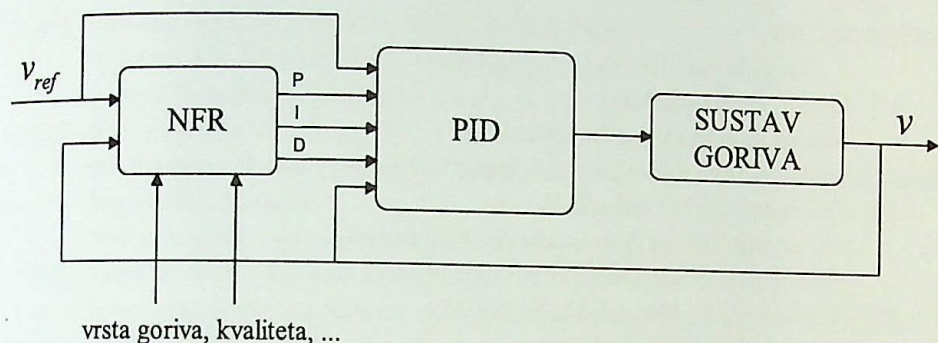
Jedna od mogućnosti primjene neuro-neizrazitih tehnika u svrhu dijagnostike kvarova je iznesena u [20]. Cilj rada je bila detekcija i lokalizacija kvara industrijske plinske turbine s naglaskom na pojave kvarova među aktuatorima i sensorima. Generiranje reziduala je napravljeno pomoću naučenog i adaptiranog TSK (Takagi-Sugeno-Kang) neizrazitog modela [2, str. 162], dok je za procjenu reziduala korišten neuro-neizraziti klasifikator za Mamdanijev model [2, str. 162]. Promatrana su dva stanja koja mogu dovesti do kvara plinske turbine tijekom dužeg vremenskog razdoblja: trošenje aktuatora goriva zbog trenja i kontaminacija kompresorskih lopatica nataloženim česticama. Kvaliteta dobivenih rezultata ovisila je o broju postavljenih pravila u procesu fuzzyfikacije [2, str. 25]. Tako je, primjerice, u slučaju 12 postavljenih pravila, točnost neuro-neizrazite klasifikacije spomenutih kvarova bila veća od 99,6 %. Time je pokazano da je odgovarajućim modeliranjem neuro-neizrazitih klasifikatora, moguće ostvariti iznimno zadovoljavajuće rezultate kako na području generiranja reziduala, tako i u detekciji i lokalizaciji samih kvarova.



Slika 10. Schematski prikaz generatora reziduala temeljenog na TSK neuro-neizrazitom modelu
Izvor: [20, str. 4]

Iako nije tema ovoga rada, svakako valja na kraju naglasiti da se neuro-neizrazita tehnologija može iskoristiti ne samo u sustavima za dijagnostiku kvarova, već i u klasičnim sustavima upravljanja, pri čemu se najbolji rezultati ostvaruju u njihovom kombiniranju s postojećim konvencionalnim sustavima automatizacije. Slika 11. ilustrira primjer kada se neuro-neizraziti regulator (engl. neuro-fuzzy regulator, NFR) koristi za primjenu i podešavanje postavnih vrijednosti konvencionalnog PID regulatora.

Ova shema je povoljna za proces čije se ulazne karakteristike mijenjaju tijekom vremena, što je primjerice slučaj u regulaciji viskoziteta dizelskog goriva za motor, pri upotrebi različitih vrsta i kvaliteta goriva.



Slika 11. NFR za prilagođavanje postavnih vrijednosti konvencionalnog PID reglulatora viskoziteta goriva

Izvor: [5, str. 160]

Upotrebom neuronskih mreža u neizrazitim sustavima teži se ostvariti regulacijske sustave koji će raditi vrlo brzo sa sposobnošću adaptacije. Po mnogim ocjenama takvi će sustavi imati velike mogućnosti i mogli bi u obliku jeftinih implementacija dovesti do revolucionarnih promjena na području automatizacije procesa.

4. ZAKLJUČAK

U novije vrijeme sve se više brodova trgovačke mornarice gradi s potpuno automatiziranom strojarnicom za koju je predviđeno da radi 24 sata bez posade. Da bi takvo brodsko pogonsko postrojenje uistinu i moglo funkcionirati u različitim režimima rada, bez nazočnosti operatera čak i u kritičnim situacijama, potrebno je u sustav za nadzor i upravljanje implementirati inteligentne programske module koji će mu omogućiti određenu autonomiju i tolerantnost na kvarove uz prihvatljivi gubitak performansi u radu. Takav inteligentan sustav dijagnostike kvarova, koji će brzo detektirati i lokalizirati kvar uz odgovarajuću rekonfiguraciju samog sustava, mogu omogućiti nove računalne tehnologije poput umjetnih neuronskih mreža, neizrazite logike, FDI shema, genetičkih algoritama itd. Za očekivati je da će najbolje rezultate u ne tako dalekoj budućnosti ponuditi njihovo kombiniranje s postojećim ekspertnim sustavima koji se već koriste posljednjih desetak godina.

LITERATURA

- [1] Müller, B.; Reinhardt, J.
Neural networks, An Introduction
Springer-Verlag, Berlin Heidelberg, 1990.
- [2] Tsoukalas, L.H.; Uhrig, R.E.
Fuzzy and Neural Approaches in Engineering
John Wiley & Sons, Inc., New York, 1997.
- [3] Novaković, B.; Majetić, D.; Široki, M.
Umjetne neuronske mreže
FSB, Zagreb, 1998.
- [4] Demuth, H.; Beale, M.
Neural Network Toolbox For Use with MATLAB
The MathWorks, Inc., 2002.; <http://www.mathworks.com>
- [5] Antonić, R. Na kvarove tolerantan sustav upravljanja sporohodnim dizelskim motorom za brodsku propulziju
Doktorska disertacija, FER, Zagreb, 2002.
- [6] The COCOS Family – Problem solving; <http://www.manbw.com>
- [7] MAPEX Family - The Engine Fitness Systems
<http://www.wartsila.com/english/img/service/pdf/mapex.pdf>
- [8] Antonić, R.; Munitić, A.; Kezić, D.
Umjetne neuronske mreže u obradi senzorskih signala brodskih dizelskih motora Naše More, 1-2, Brodostrojstvo, 21-29, 2003.
- [9] Šarić, T.; Majdandžić, N.
Primjena neuronske mreže za dijagnostiku stanja ležaja
HDO, 8. međunarodno savjetovanje - Održavanje 2002, Opatija, 26.-28. lipnja 2002.
- [10] Li, B.; Chow, M.Y.; Hung, J.C.
Neural-Network-Based Motor Rolling Bearing Fault Diagnosis
IEEE Transactions on Industrial Electronics, vol. 47, no. 5, 1060-1069, 2000.
- [11] Chandroth, G.O.; Sharkey, A.J.C.; Sharkey, N.E.
Artificial Neural Nets and Cylinder Pressures in Diesel Engine Fault Diagnosis
In Proceedings of INMARCO98, Mumbai, India, 1998.
- [12] Chandroth, G.O.; Sharkey, A.J.C.; Sharkey, N.E.
Cylinder Pressures and Vibration in Internal Combustion Engine Condition Monitoring <http://www.dcs.shef.ac.uk/research/groups/neural/>
- [13] Isermann, R.; Müller, N. Modeling and Adaptive Control of Combustion Engines with Fast Neural Networks
http://www.eunite.org/eunite/events/eunite2001/look_back/13373_P_Isermann.pdf

- [14] Sharkey, A.J.C.; Chandroth, G.O.; Sharkey, N.E.
A Multi-Net System for the Fault Diagnosis of a Diesel Engine
Neural Computing and Applications, 9, 152-160, 2000.
- [15] Vachtsevanos, G.; Wang, P.
A Wavelet Neural Network Framework for Diagnostics of Complex Engineered Systems
<http://icsl.marc.gatech.edu/publication/peng/paper7.doc>
- [16] Sharkey, A.J.C.; Sharkey, N.E.; Gopinath, O.C.
Diverse neural net solutions to a fault diagnosis problem
Neural Computing and Applications, 4, 218-227, 1996.
- [17] Karakuzu, C.; Öztürk, S.
A comparison of fuzzy, neuro and classical control techniques based on an experimental application
Journal of Qafqaz University, 6, 2000.
- [18] Wang, P.; Propes, N.; Khiripet, N.; Li, Y.; Vachtsevanos, G.
An integrated approach to machine fault diagnosis
<http://icsl.marc.gatech.edu/publication/peng/paper4.pdf>
- [19] Groves, S. A Statistical Analysis of Marine Machinery Failures The RTS (Richards Technical Services) Machinery Failure Database, 2000.
- [20] Palade, V.; Patton, R.J.; Uppal, F.J.; Quevedo, J.; Daley, S.
Fault Diagnosis of An Industrial Gas Turbine using Neuro-Fuzzy Methods
http://web.comlab.ox.ac.uk/oucl/work/vasile.palade/papers/Palade_CongresIFAC2002.pdf
- [21] Howlett, R.J.
Monitoring and Control of an Internal Combustion Engine Air-Fuel Ratio using Neural and Fuzzy Techniques Conference on the Engineering of Intelligent Systems, EIS'98., Spain, 1998.
- [22] Anabtawi, A.L.; Howlett, R.J.
Detection of blade contamination in turbine flowmeters using neural networks <http://rjhowlett.complexnet.co.uk/papers/2000-10.pdf>
- [23] Vianna, G.K.; Thomé, A.C.G.
Neuro-Fuzzy System for Diagnosis of Engines, Based on Oil Samles Analysis
http://www.labic.nce.ufrj.br/downloads/isas_2000_2.pdf
- [24] Li, L.; Deng, Z.; Zhang, B.
A Fuzzy Elman Neural Network
<http://www.cs.caltech.edu/~ling/pub/97fenn.pdf>
- [25] Minca, E.; Racoceanu, D.; Zerhouni, N.
Monitoring Systems Modeling and Analysis Using Fuzzy Petri Nets
Studies in Informatics, Vol. 11, No. 4, 2002.
- [26] Gopinath, O.C.
A neural net solution for diesel engine fault diagnosis

MSc Thesis, University of Sheffield, 1994.

- [27] Blanke, M.; Zamanabadi, R.I.; Lootsma, T.F.
Fault Monitoring and Reconfigurable Control for a Ship Propulsion Plant
Journal of Adaptive Control and Signal Processing, 671-688, 1998.
- [28] Vukić, Z.; Ožbolt, H.; Paveković, D.
Application of Expert Systems, Fuzzy Algorithms and Neural Networks to
Fault Diagnosis in Control Systems Brodogradnja, 47/1, 41-49, 1999.
- [29] Gu, F.; Jacob, P.J.; Ball, A.D.
A RBF neural network model for cylinder pressure reconstruction in internal combustion engines
MTZ Worldwide, 1996.

Summary

INTELLIGENT SYSTEMS OF CONTROL AND FAULT DIAGNOSIS BASED ON ARTIFICIAL NEURAL NETWORKS

The development and application of new computer technologies based on algorithms of artificial intelligence could do to a great extent improve the quality and performance of monitoring control systems and fault diagnosis of marine propulsion engines. The paper is structurally divided into three almost independent parts. The first part represents a brief introduction to the artificial neural networks so as to thematically familiarize students and engineers of marine traffic with the subject since they have practically barely encountered it during their training. The second part presents an analysis of existing, mainly expert, systems for monitoring and fault diagnosis that the world's leading engine manufacturers use. The third part deals with the possibilities of enhancing the existing systems through implementation of new technologies such as artificial neural networks, fuzzy logic and its combinations, and all this for the purpose of increasing the safety and reliability of marine propulsion engine operation.

Key words: artificial neural networks, fuzzy logic, expert systems, fault diagnosis, control

Faculty of Maritime Studies Rijeka
Studentska 2, 51000 Rijeka
Croatia