

Detekcija kratkospojenih navojaka na polovima rotora hidrogeneratora primenom neuralnih mreža

Blagoje Babić^{1,2}, Nenad Kartalović², Aleksandar Žigić², Nikola Cakić², i Srđan Milosavljević²

¹Elektrotehnički fakultet, Univerzitet u Beogradu,
Bulevar kralja Aleksandra 73, 11000 Beograd, Srbija
blagoje.babic@ieent.org

² Elektrotehnički institut Nikola Tesla, Univerzitet u Beogradu,
Koste Glavinića 8a, 11000 Beograd, Srbija

Kratak sadžaj: Cilj dijagnostike industrijskih procesa je otkrivanje kvara, određivanje njegove vrste i lokacije i na kraju određivanje veličine i vremenski promenljivog ponašanja kvara. Rano otkrivanje otkaza koji se mogu pojavit omogućava preduzimanje bitnih preventivnih akcija i samim tim smanjuje ekonomski troškove koji bi nastali usled zaustavljanja proizvodnje, zamene delova itd. Osnovna ideja detekcije kratkospojenih navojaka na polovima rotora hidrogeneratora primenom neuralnih mreža, a koja je detaljno opisano u radu, jeste da se generišu signali koji će predstavljati nedoslednost između nominalnog sistema i sistema sa otkazom. U slučaju kompleksnih sistema srećemo se sa problemom da ne postoji tačan ili barem dovoljno tačan matematički model samog procesa, zbog čega je korišćenje neuralnih mreža od posebnog interesa. Korišćena su dva tipa NARX (nonlinear autoregressive network with exogenous inputs) neuralnih mreža, sa jednim i sa tri skrivena sloja, sa sigmoidalnom transfer funkcijom, kako bi se testirala osetljivost mreže na otkaze. Izlazni neuron sadrži linearu aktivacionu funkciju. U oba slučaja jasno se može uočiti postojanje kratkospojenih navojaka na polu rotora hidrogeneratora.

Ključne reči: magnetni monitoring, neuralna mreža, kratak spoj, hidrogenerator

1. Uvod

Neuralne mreže su sistemi koji su konstruisani tako da koriste organizacione principe nalik onima iz ljudskog mozga. Neuralne mreže se koriste u zadacima kao što su: upoređivanje i klasifikacija podataka, aproksimacija funkcija, optimizacija i vektorska kvantizacija. Veštačke

neuralne mreže simuliraju način rada ljudskog mozga pri obavljanju datog zadatka.

Većina metoda u literaturi vezanoj za otkrivanje otkaza je zasnovana na linearnoj metodologiji ili egzaktnim modelima. Industrijske procese je često teško modelovati. Oni su kompleksni i ne do kraja poznati a do grešaka pri merenju dolazi zbog prisutnog šuma i nepouzdanosti senzora. Zato se kao alternativni način koriste veštačke neuralne mreže. Neuralne mreže mogu da filtriraju šum i poremačaje koji su prisutni. Jedna od prednosti neuralnih mreža je da nije potreban tačan model da bi se donosile odluke [1][2][3].

Veštačke neuralne mreže predstavljaju odlično matematičko sredstvo za rad sa nelinearnim problemima. Njihova bitna osobina je da se svaka kontinualna nelinearna relacija može aproksimirati sa proizvoljnom tačnošću koristeći neuralnu mrežu sa određenom arhitekturom i težinskim koeficijentima [4]. Još jedna od značajnih osobina je i mogućnost samoobučavanja.

Jedan od problema je odabir podataka za treniranje. Problem se može svesti i na problem mesta postavljanja senzora tako da se garantuje maksimalna tačnost estimacije parametara [5].

Problem robusnosti u detekciji otkaza se može definisati kao maksimizacija mogućnosti otkrivanja otkaza i istovremeno minimizacija nekontrolisanih efekata kao što su poremećaji, šumovi itd.

Iako postoji dosta obećavajućih simulacija neuralnih mreža u otkrivanju otkaza, stvarna primena je još uvek retka. U radu su prikazani *realni signali* promene magnetne indukcije tokom vremena, u međugvožđu jednog hidrogeneratora kao i vremenski odziv NARX neuralne mreže. Smanjenje magnetne indukcije na polu rotora hidrogeneratora tokom vremena je indikatora kratkospojenih navojaka i jasno se može detektovati korišćenjem NARX dinamičkih neuralnih mreža.

2. Sistem za detekciju i dijagnozu otkaza

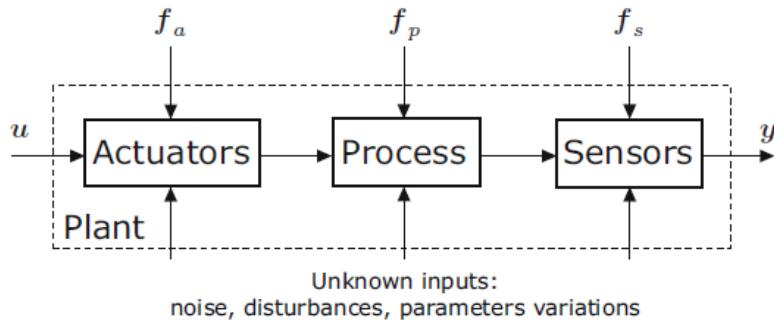
2.1. Problem detekcije i dijagnoze otkaza

Glavni cilj sistema za dijagnozu otkaza je određivanje lokacije i vremena nastajanja mogućih otkaza, zasnovano na pristupačnim podacima i znanju o ponašanju procesa, na primer korišćenjem matematičkih, kvantitativnih ili kvalitativnih modela. Napredne metode nadzora i dijagnoze otkaza treba da zadovolje sledeće zahteve:

1. Rana detekcija otkaza
2. Dijagnoza otkaza u aktuatorima, komponentama procesa ili senzorima
3. Nadzor procesa u tranzijentnom stanju

Cilj rane detekcije i dijagnoze otkaza je obezbeđivanje dovoljno vremena za eventualne remonte, popravke ili druge operacije.

Na slici 1 je dat sistem koji se sastoji od određenog broja podsistema kao što su aktuatori, komponente procesa i senzori. U svakom od ovih podsistema je moguće pojavljivanje otkaza koje bi vodilo do neželjenih performansi.



Slika 1. Šema sistema sa prisutnim otkazima, poremećajima i šumom [1]

Glavni cilj dijagnoze otkaza je detektovanje otkaza u svakom podsistemu i njegovih uzroka, dovoljno rano da bi se mogao izbeći kvar celog sistema.

Otkazi na slici 1 su predstavljeni kao ulazi:

f_a -otkazi aktuatora (primer: kvar na pneumatskom servo motoru u kontroli ventila)

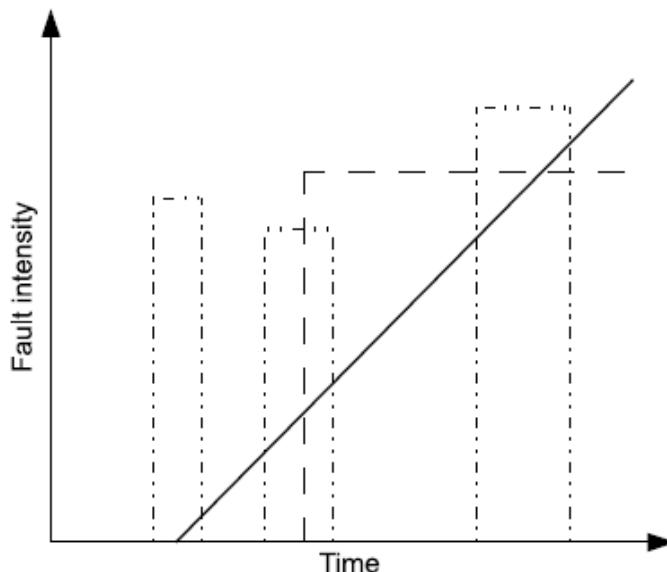
f_p -otkazi procesa (primer: curenje u gasnom cevovodu)

f_s -otkazi senzora (primer: velike varijacije merenja)

Poremećaji i šum su uvek prisutni i ne moraju kritično uticati na ponašanje sistema ali mogu uticati na detekciju otkaza.

Otkazi se takođe mogu klasifikovati ako se posmatra njihova vremenska promenljivost, slika 2. Na osnovu toga se mogu podeliti na one koji naglo nastaju, na one u početnom stanju nastajanja i na one koji se naizmenično pojavljuju.

Nagli otkazi predstavljaju naglu promenu parametara dok se oni u početnom stanju nastajanja postepeno razvijaju. Pod naizmeničnim otkazima se podrazumevaju oni koji nastaju i prestaju u više navrata.



Slika 2. Tipovi otkaza - nagli (isprekidana linija), u početnoj fazi nastajanja (neisprekidana linija) i naizmenični (isprekidana linija sa tačkama) [1]

Na osnovu gore navedenog, problem detekcije kratkospojenih navojaka na polovima rotora hidrogeneratora se može kvalifikovati kao problem detekcije otkaza procesa koji je u početnoj fazi nastajanja.

2.2. Sistem dijagnoze otkaza

Pristupi na osnovu modela su zasnovani na estimaciji parametara ili stanja. Pristup je zasnovan na činjenici da će otkazi izazvati promene određenih fizičkih parametara koji će dovesti do promena u nekim stanjima i parametrima modela. Kada se koristi ovaj pristup jako je bitno imati relativno tačan model procesa koji se razmatra.

Tehnološki procesi su često kompleksni dinamički sistemi opisani nelinearnim diferencijalnim jednačinama visokog reda. Za njihovo kvantitativno modelovanje radi generisanja reziduala (nedoslednost između nominalnog sistema i sistema sa otkazom), pojednostavljenja su neizbežna. Ovo najčešće obuhvata redukciju dinamičkog reda i linearizaciju.

Drugi problem potiče od nepoznatih ili vremenski promenljivih parametara procesa. Zbog svih ovih poteškoća konvencionalni analitički modeli su često nedovoljno precizni za generisanje reziduala. U ovom slučaju modeli zasnovani na znanju su jedina alternativa.

Za pristupe zasnovane na modelima, neuralna mreža zamenjuje analitički model koji opisuje proces pod normalnim uslovima rada. Obučavajući podaci

se mogu prikupiti direktno iz procesa, ukoliko je to moguće, ili iz modela simulacije koji je realističan koliko god je to moguće.

Treniranje neuralne mreže može biti off-line ili on-line, u zavisnosti od dostupnosti podataka. Posebno je zanimljiva mogućnost on-line treniranja mreže. Nakon treniranja neuralna mreža je spremna za on-line generisanje reziduala.

Da bi mogla da ustanovi dinamičko ponašanje sistema neuralna mreža mora da poseduje dinamičke osobine, na primer treba da bude rekurentna mreža.

Procena reziduala je proces donošenja odluke kojim se kvantitativno znanje transformiše u kvalitativno (ima ili nema otkaza). Takođe se može posmatrati kao problem klasifikacije.

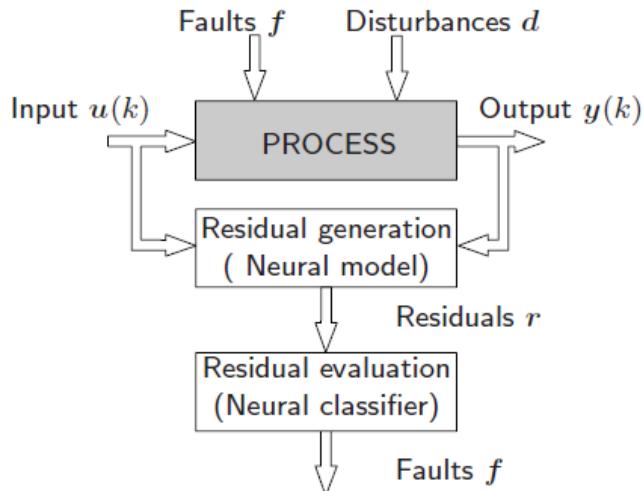
Kompletan sistem dijagnoze otkaza se sastoji iz dva dela (slika 3) :

1. Generisanja reziduala (nedoslednost između nominalnog sistema i sistema sa otkazom)
2. Procene reziduala

Generisanje reziduala, zasnovano na korišćenju neuralnih mreža, se zasniva na komparaciji izmerenih i estimiranih izlaza sistema.

Očekuje se da rezidual bude približno nula pod normalnim uslovima rada, ali se sa pojavljivanjem otkaza pojavljuje određeno odstupanje od nule.

Procenom reziduala vrši se analiza reziduala u cilju određivanja da li se otkaz zaista pojavio.



Slika 3. Sistem dijagnoze otkaza [1]

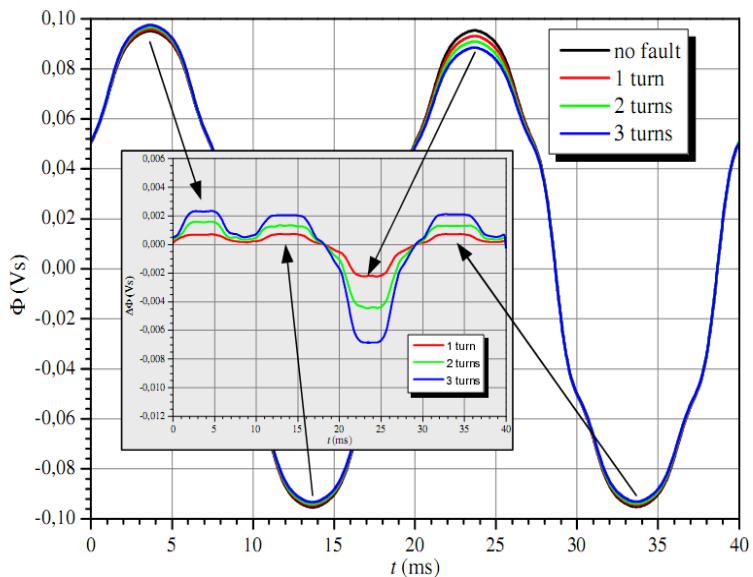
Ako ne postoji matematički model sistema ili kompleksnost dinamičkog sistema raste, analitički modeli se ne mogu primeniti i dati zadovoljavajuće

rezultate. U ovim slučajevima se razmatraju modeli zasnovani na podacima kao što su neuralne mreže, fuzzy skupovi ili njihova kombinacija.

3. Detekcija kratkospojenih navojaka na polovima rotora hidrogeneratora

Monitoring fluksa rotora uključuje merenje magnetnog fluksa u međugvožđu u generatorima da bi se utvrdilo da li postoje kratkospojeni navoči u namotajima pola rotora.

U mašinama sa istaknutim polovima, radikalni magnetni fluks svakog pola zavisi od aktivnog (MW) i reaktivnog (MVAR) opterećenja maštine, konstrukcije polova, prigušnih namotaja itd. Dakle radi se o kompleksnom sistemu, za čije se modelovanje mora pribeti velikom broju pojednostavljenja (npr. zanemarivanja uticaja prigušnih namotaja...). Neuralna mreža predstavlja jedinu alternativu primeni analitičkog modela. Svaka promena fluksa pola pri datom opterećenju mora biti zbog kratkospojenih navojaka. Svaka greška u polu smanjuje broj efektivnih amper navojaka datog pola i time takođe i pikove povezane sa tim polom (slika 4). Snimljeni podaci mogu onda biti analizirani da bi se pronašli polovi koji sadrže kratkospojene navoje [6] [7].

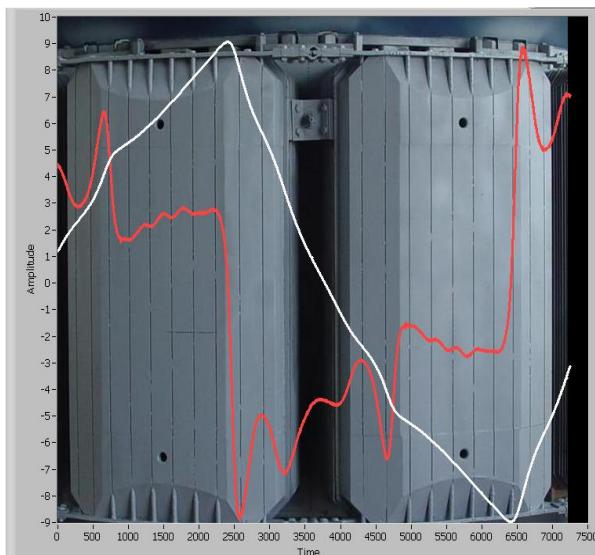


Slika 4. Promena magnetne indukcije u zavisnosti od broja kratkospojenih navojaka u odnosu na susedne polove, slučajevi sa 1, 2 i 3 kratkospojena navoja

Generalno, fluks se može meriti u toku normalnog rada mašine ili kada se otkrije povećanje nivoa vibracija ležaja (budući da to može biti znak kratkospojenih navojaka na polovima).

Slika 5. prikazuje tipičan signal sa jednog senzora sa fizičkim podudaranjem sa karakterističnim pozicijama polova. Signal sa senzora je elektromotorna sila tako da se ti podaci integrale kako bi se dobila vrednost proporcionalna ukupnom fluksu (indukciji).

Poseban metrološki problem je rezolucija sistema na otkrivanje kratkospojenih navojaka na polovima rotora generatora. Kod hidrogeneratora sa istaknutim polovima je relativno jednostavno odrediti potrebnu rezoluciju. Ako imamo 10 navojaka po polu onda kratkospojeni navojak dovodi do smanjenja magnetne indukcije za 10%. Tako visoke vrednosti promene mernog signala dopuštaju veće fluktuacije vrednosti merenih signala i veće vrednosti smetnji. Ako je pak broj navojaka po polu 50, onda jedan kratkospojeni navojak dovodi do pada magnetne indukcije za 2%. To je relativno malo i u tom slučaju zahteva se posebna pažnja kod samog koncepta merenja, kod odabira i ugradnje senzora, kod izrade algoritama itd.



Slika 5. Promena elektromotorne sile (normalizovano – crveno) i magnetne indukcije (belo) u odnosu na dva susedna pola, aktivna snaga 40MW, reaktivna snaga 17MVAR
(x-osa : ms, y-osa : Volts)

4. Primena NARX dinamičkih neuralnih mreža

Proces kreiranja neuralne mreže se sastojao iz sedam osnovnih koraka:

1. Prikupljanje podataka
2. Kreiranje mreže

3. Konfigurisanje mreže
4. Inicijalizacija težinskih koeficijenata i bajasa
5. Treniranje mreže
6. Validacija mreže
7. Korišćenje mreže

Tokom kreiranja neuralne mreže ulazni podaci su podeljeni slučajno u tri skupa i to:

1. Trening skup (70%)
2. Validacioni skup (15%)
3. Testirajući skup (15%)

Validacioni skup je služio za zaustavljanje treniranja mreže pre pojave overfitovanja tj. loših generalizacionih sposobnosti mreže. Trening neuralne mreže traje sve dok greška validacije ne počne da se povećava šest iteracija uzastopno što znači da se generalizaciona sposobnost neuralne mreže pogoršava.

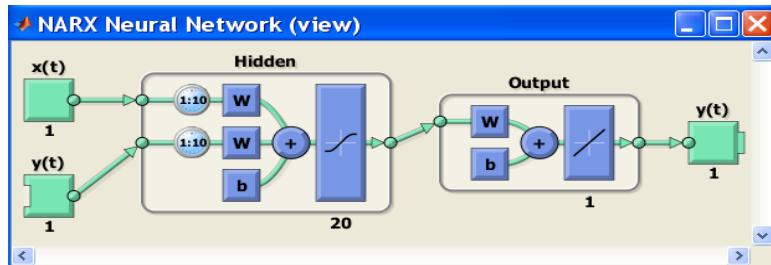
Prvo je korišćena NARX neuralna mreža (da bi se generisao reziduala sa slike 3) sa jednim skrivenim slojem od 20 neurona i izlaznim slojem od jednog neurona (Slika 6).

Na ulaz mreže se dovodi signal promene magnetne indukcije tokom vremena *za slučaj bez kratkospojenih navojaka* $u_1(k)$ dok je željeni izlaz mreže $y(k)$ takođe signal promene magnetne indukcije *za slučaj bez kratkospojenih navojaka* samo vremenski pomeren. Na ovaj način mreža postaje otporna na normalne fluktuacije magnetne indukcije. Testiranje se vrši tako što se na ulaz dovodi signal promene magnetne indukcije za slučaj sa postojanjem kratkospojenih navojaka $u_2(k)$ dok je željeni izlaz mreže $y(k)$ i dalje isti kao u prethodnom slučaju.

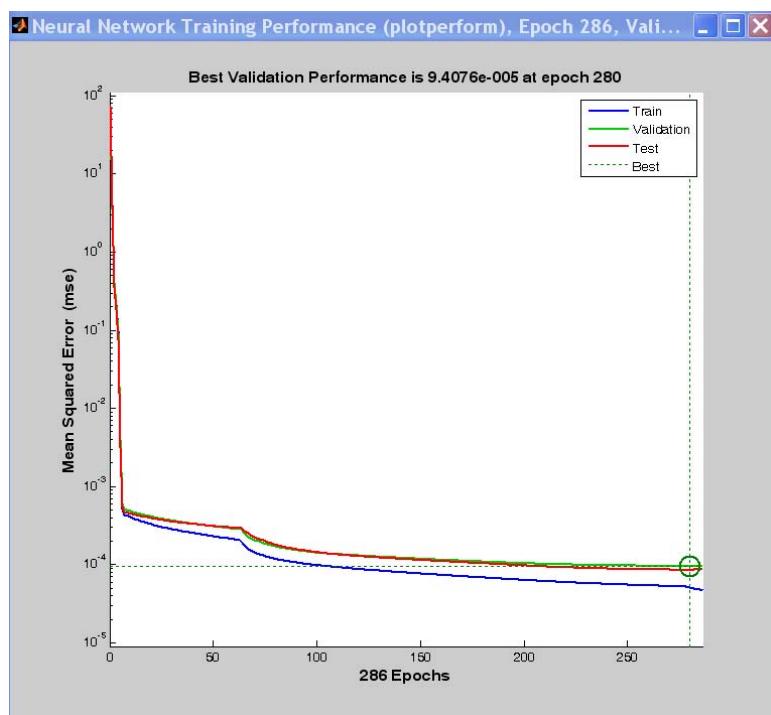
Na slici 7 su prikazane performanse mreže tokom treniranja, pri čemu se najbolji rezultati dobijaju pri 280-toj iteraciji. Pri treniranju mreže performance moraju biti sledeće:

1. Vrednost srednje kvadratne greške (srednja kvadratna razlika između izlaza i targeta) mora biti mala.
2. Test i validacioni skup moraju imati slične performance.

Jasno se uočava da su dati kriterijumi u pogledu performansi dostignuti, pa zbog toga nije moguće da dođe do preobučavanja neuralne mreže. U slučaju preobučavanja neuralne mreže, detekcija kratkospojenih navojaka nebi bila moguća jer je osetljivost neuralne mreže na promenu magnetne indukcije u slučaju loših performansi mreže tokom treniranja nedovoljna.



Slika 6. NARX neuralna mreža sa izlazom mreže $y(t)$



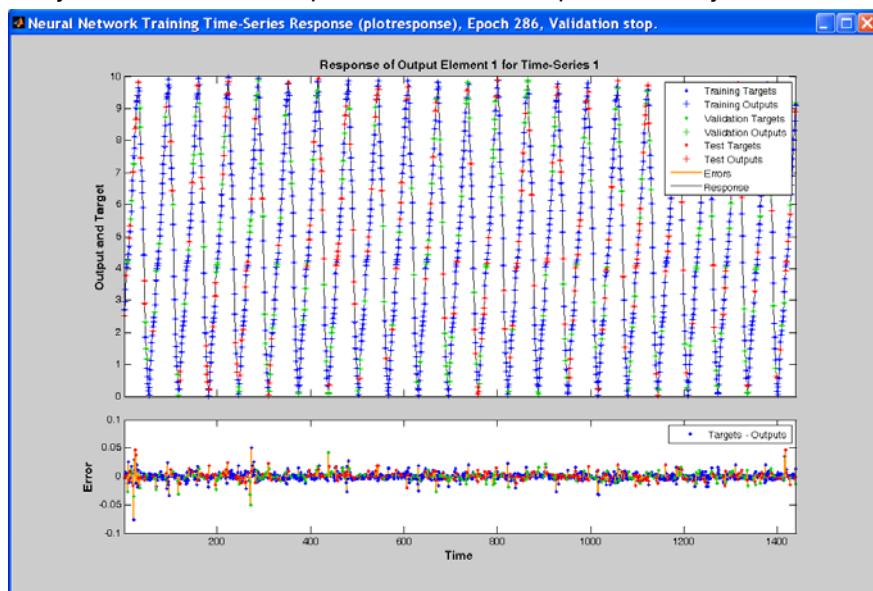
Slika 7. Performanse neuralne mreže tokom treniranja

Ukoliko je performansa trening skupa dobra ali je performansa testirajućeg skupa značajno lošija došlo je do preobučavanja mreže, što kod nas nije slučaj.

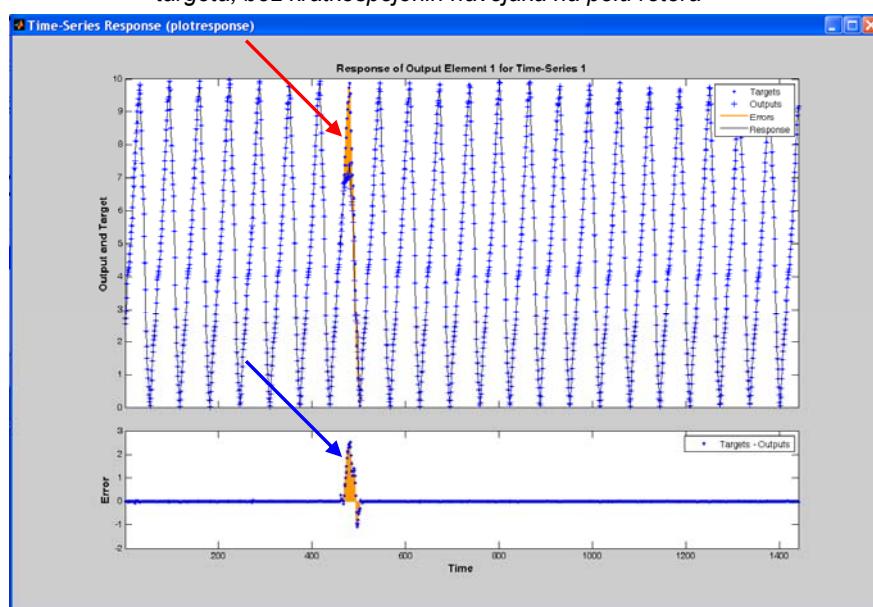
Na slikama 8 i 9 su prikazani vremenski odziv NARX neuralne mreže sa razlikom izlaza mreže i datih targeta (željenih izlaza) za slučajeve bez i sa kratkospojenih navojaka.

Pad magnetne indukcije (označen crvenom strelicom, slika9), koji je posledica kratkospojenih navojaka na polu rotora, se jasno uočava na generisanom signalu reziduala tj. razlike targeta i izlaza mreže (označeno sa plavom strelicom, slika 9).

Do eventualnog poboljšanja osteljivosti neuralne mreže, je moguće doći putem povećanja N broja neurona, strukturalnih izmena tj. povećanja složenosti mreže, povećanja broja ulaznih vrednosti, promene algoritma treniranja itd. Pri čemu treba paziti da ne dođe do preobučavanja mreže.

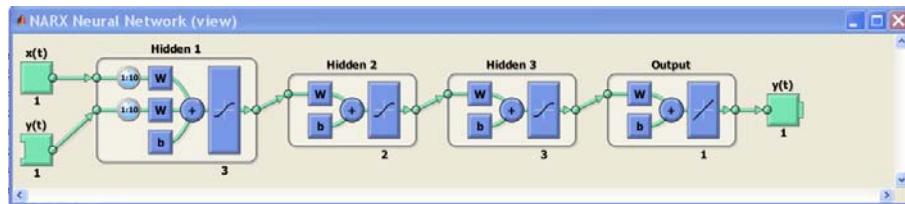


Slika 8. Vremenski odziv NARX neuralne mreže sa razlikom izlaza mreže i datih targeta, bez kratkospojenih navojaka na polu rotora



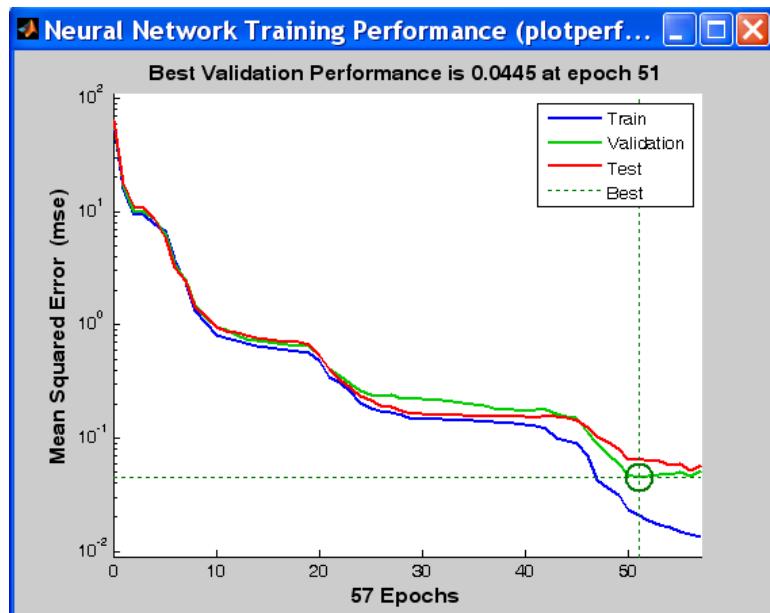
Slika 9. Vremenski odziv NARX neuralne mreže sa razlikom izlaza mreže i datih targeta, sa kratkospojenim navojcima na polu rotora

Strukturalnim promenama neuralne mreže, a kao što je prikazano na slici 10, povećana je složenost mreže i dobijena je NARX neuralne mreže sa tri skrivena sloja (sa po 3, 2 i 3 neurona).



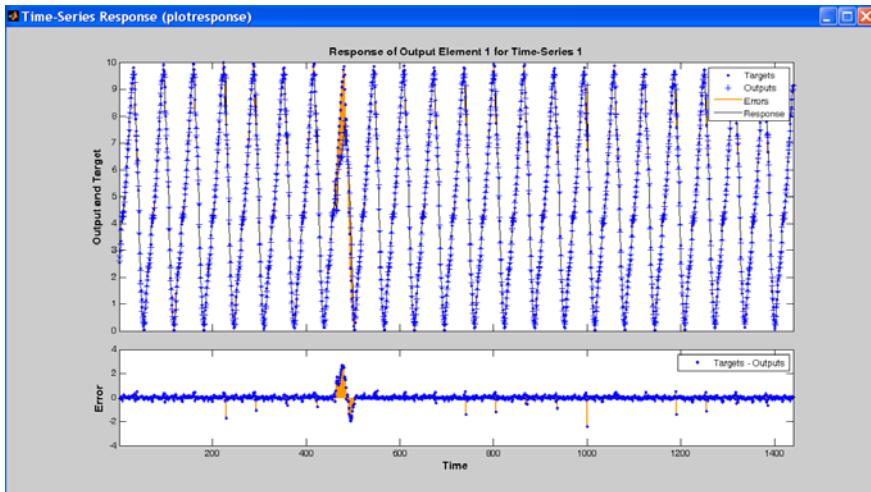
Slika 10. NARX neuralna mreža sa izlazom mreže $y(t)$

Performanse neuralne mreže tokom treniranja (slika 11), su zadovoljavajuće pri čemu je validacioni skup ima najbolje performanse u 51. iteraciji pa ćemo tada i zaustaviti proces treniranja mreže.



Slika 11. Performanse neuralne mreže tokom treniranja

Na slici 12 je prikazan vremenski odziv novo kreirane NARX neuralne mreže sa razlikom izlaza mreže i datih targeta, za slučaj sa kratkospojenim navojcima na polu rotora.



Slika 12. Vremenski odziv NARX neuralne mreže sa razlikom izlaza mreže i datih targeta, sa kratkospojenim navojcima na polu rotora

Kako je signal reziduala neznatno veći, u odnosu na slučaj NARX neuralne mreže sa jednim skrivenim slojem, osetljivost na promenu magnetne indukcije je povećana povećavanjem složenosti strukture neuralne mreže. Kratkospojeni navojci na polu rotora hidrogeneratora su opet uspešno detektovani.

5. Zaključak

U radu je prikazana sposobnost detekcije kratkospojenih navojaka na polovima rotora kod hidrogeneratora pomoću korišćenja dinamičkih neuralnih mreža.

Veštačke neuralne mreže zauzimaju jako važnu poziciju po pitanju modelovanja i identifikacije nelinearnih dinamičkih procesa i detekciji otkaza.

Mogućnost samoobučavanja i aproksimacije nelinearne funkcije obezbeđuju modelovanje nelinearnih sistema sa velikom fleksibilnošću.

Ustanovljeno je da korišćenjem NARX dinamičkih neuralnih mreža u modelovanju procesa i daljom observacijom reziduala možemo detektovati otkaze prilično pouzdano sa većim ili manjim brojem lažnih alarma.

Dalji rad treba posvetiti u sledećim pravcima:

1. Određivanje tačnog broja skrivenih slojeva u neuralnoj mreži i broja neurona u njima da bi se osigurao zahtevani nivo tačnosti aproksimacija.
2. Detaljnije ispitivanje mogućnosti drugih tipova dinamičkih neuralnih mreža.

3. Istraživanje u pravcu otkrivanja veoma osjetljivih robusnih procedura za detekciju otkaza.
4. Neuralne mreže je potrebno obučiti, povećavanjem trening skupa, i za druge vrednosti aktivne i reaktivne snage datog generatora.
5. Izradi aplikacije koja bi se izvršavala na programabilnom automatskom kontroleru NI CRIO 9074, proizvođača National Instruments, a koja bi u realnom vremenu detektovala kratkospojene navojke u namotajima pola rotora. Aplikacija bi pored akvizicije signala, primene odgovarajuće neuralne mreže obuhvatala i generisanje određenih alarma ukoliko vrednost dobijenog reziduala prelazi unapred zadatu vrednost.

Literatura

- [1] Krzysztof Patan, *Artificial Neural Networks for the Modelling and Fault Diagnosis of Technical Processes*, Springer-Verlag Berlin, 2008.
- [2] Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth, *Neural Network Toolboxtm 7 User's Guide*, 2010.
- [3] Chin-Teng Lin, C.S. George Lee, *Neural Fuzzy Systems- A Neuro-Fuzzy Synergism to intelligent Systems*, Prentice Hall, New Jersey, 1996.
- [4] Krzysztof Patan, Józef Korbicz, "Fault detection in catalytic cracking converter by means of probability density approximation", *Engineering Applications of Artificial Intelligence, Volume 20, Issue 7, October 2007, Pages 912-923*
- [5] Krzysztof Patan, Józef Korbicz, Gracjan Glowacki, "DC motor fault diagnosis by means of artificial neural networks", *International Conference on Informatics in Control, Automation and Robotics, 4th - ICINCO 2007*.
- [6] N. Kartalovic, B. Babic, Lj. Nikolic, D. Jovanovic, A. Miloševic, „Magnetni monitoring obrtnih elektrinih mašina u elektranama Elektroprivrede Srbije, II faza“, JP Elektroprivreda Srbije, Beograd 2011.
- [7] Nenad Kartalović, Blagoje Babić, "Magnetni monitoring generatora u elektranama EPS", *Zbornik radova, Elektrotehnički institut "Nikola Tesla"*, 2011, br. 21, str. 247-267

Abstract: Early diagnosis of faults that might occur in industrial processes makes it possible to perform important preventative actions and therefore avoid the heavy economic losses involved in production stoppages and the replacement of elements and parts. The main idea of detecting shorted turns on rotor poles in hydrogenerators using artificial neural networks is to generate signals that reflect inconsistencies between nominal and faulty system operating conditions. Two types of

nonlinear autoregressive networks with exogenous inputs (NARX) are used. In both cases one can successfully detect shorted turns on rotor poles.

Keywords: magnetic monitoring, neural networks, shorted turns, hydrogenerator

Detection of Shorted Turns on Rotor Poles in Hydrogenerators Using Artificial Neural Networks

Rad primljen u uredništvo 19.08.2014. godine
Rad prihvaćen 19.09. 2014. godine