

Primena autoenkoderskih neuralnih mreža za dijagnostiku stanja energetskih transformatora

Milica Vlaisavljević

Energetika/Katedra za elektroenergetske sisteme
Univerzitet u Beogradu Elektrotehnički fakultet
Beograd, Srbija
milica.vlaisavljevic97@gmail.com

Mileta Žarković, Zlatan Stojković

Energetika/Katedra za elektroenergetske sisteme
Univerzitet u Beogradu Elektrotehnički fakultet
Beograd, Srbija
miletazarkovic@etf.rs, zstojkovic@etf.rs

Sažetak— Energetski transformator je sa ekonomске strane najskuplji, a sa inženjerske najkompleksniji element elektroenergetskog sistema. U njemu se sustiću termički, mehanički, hemijski i električni procesi i svi su podjednako važni. Zbog kopleksnosti energetskog transformatora, njegov monitoring i dijagnostika su veoma složeni procesi. Pri *off-line* i *on-line* monitoringu energetskog transformatora, u toku eksploatacije, se prikuplja veliki broj podataka. Baza podataka formirana na taj način može poslužiti za primenu mašinskog učenja u cilju dijagnostikovanja opasnih radnih stanja energetskog transformatora. U ovom radu predstavljen je algoritam primene autoenkoderskih neuralnih mreža pomoću programskog alata MATLAB. Dobijeni rezultati mogu poslužiti za objektivnu ocenu stanja energetskih transformatora zasnovanu na numeričkim vrednostima parametara monitoringa.

Ključne reči – energetski transformator; dijagnostika; autoenkoderske neuralne mreže;

I UVOD

Elektroenergetski sistem (EES) je veoma bitan današnjem društvu. Smanjenje pouzdanosti EES-a dovodi do značajnih poremećaja u životu stanovništva, ali i poremećaja i ekonomskih gubitaka u industriji [1]. Pouzdan EES je onaj koji ima minimalno neisporučene energije, samim tim i minimalan broj kvarova i havarija. Kako bi se izbegla stanja kvarova i havarija, bitno je vršiti redovan monitoring i dijagnostiku *off-line* i *on-line* metodama.

Ubrzan razvoj tehnologije polako potiskuje tradicionalne metode periodičnog održavanja (*Time Based Maintenance* – TBM), a sve više uvodi metode preventivnog održavanja prema stanju (*Condition-based maintenance* – CBM) i metodu održavanja na bazi rizika (*Risk Based Maintenance* – RBM). CBM metoda omogućava efikasno planiranje održavanja, jer je kroz kontinualni monitoring moguće u svakom trenutku imati podatke o celom elementu ili delu elementa EES-a. EES je veoma kompleksan sistem, a njegovi elementi nemaju isti prioritet održavanja. RBM metod podržava kontinualan monitoring, ali u kombinaciji sa značajem posmatranog elementa u EES-u. Značaj elementa se može ogledati u prenetoj energiji kroz posmatrani element ili kroz uticaj elementa na pouzdanost ostalih delova EES-a.

Energetski transformator (ET) je statički element sa dva ili više namotaja koji elektromagnetskom indukcijom transformiše sistem naizmeničnog napona i struje u drugi sistem napona i struje, obično različitih vrednosti i iste frekvencije [2]. Namotaji ET-a najčešće imaju različit broj navojaka, zbog toga se naponi na izlazima razlikuju, ali proizvod struje i napona ostaje približno isti. Smanjenje napona, praćeno je povećanjem struje i obrnuto.

Sa stanovišta značaja elemenata u EES-u, visokonaponski ET-i su vodeći elementi. Njihova ekonomска vrednost je veoma velika. Najčešće se ET-i velikih snaga namenski konstruišu i proizvode prema zahtevima naručioca. Praksa je da za ET-e velikih snaga ne postoji rezerva, s toga je veoma bitno imati pravovremeni uvid u stanje postojećeg ET-a. Potrebno je vršiti redovan monitoring i dijagnostiku stanja, jer je proces proizvodnje visokonaponskih ET-a veoma dugačak.

U radu je predstavljen način dijagnostike stanja ET-a, nazivnog napona 400kV, pomoću programa koji radi na principu autoenkoderskih neuralnih mreža. Autoenkoderske neuralne mreže su veoma dobar način obrade velike količine podataka (baza podataka) ili podataka u realnom vremenu u cilju otkrivanja anomalija, tj. neispravnih radnih stanja ET u ovom slučaju.

II IDENTIFIKATORI STANJA ENERGETSKIH TRANSFORMATORA

ET je najkompleksniji element EES-a, što implicira da je broj metoda za monitoring veliki, a broj kombinacija metoda za dijagnostiku stanja još veći. U ovom radu su razmatrani sledeći parametri ET:

- Indeks polarizacije (IP)

Vrednost IP se dobija kao razlika merene desetominutne i jednominutne vrednosti izolacionog otpora ET-a. Otpornosti izolacije su veoma velike kod novih i suvih ET-a, veće od nekoliko stotina mega omu. Na vrednosti otpora izolacije utiču temperatura, vlažnost, ispitni napon i veličina transformatora i drugih osobina ET-a. Vrednosti pomenutih izolacionih otpornosti se dobijaju U-I metodom pomoću jednosmernog napona. Sve izmerene vrednosti otpornosti je potrebno svesti na referentnu temperaturu 20°C [3].

- dielektrični gubici u namotajima ($\operatorname{tg}\delta_{\text{nam}}$),
- dielektrični gubici u prolaznim izolatorima ($\operatorname{tg}\delta_{\text{pi}}$) i
- dielektrični gubici u ulju ($\operatorname{tg}\delta_{\text{ulja}}$).

Faktor dielektričnih gubitaka je parametar na osnovu kog se utvrđuje stanje izolacije. Pomoću njega se vrši i provera rezultata dobijenih merenjem otpora izolacije. Na vrednosti $\operatorname{tg}\delta$ utiču vlažnost, temperatura, veličina transformatora, nazivni napon, itd. Vrednost $\operatorname{tg}\delta$ je potrebno svesti na temperaturu od 20°C [3].

- Induktivnost usled rasipanja (L_γ)

Indikator promene geometrije namotaja je impedansa kratkog spoja, tj. induktivnost usled rasipanja (L_γ). Merenjem L_γ i upoređivanjem sa vrednostima $L_{\gamma FAT}$ sa prijemnih ispitivanja dobijaju se informacije o deformacijama namotaja unutar ET-a. Odstupanje L_γ od $L_{\gamma FAT}$ će u daljem tekstu biti označavano kao ΔL_γ .

- Sadržaj vlage u čvrstoj izolaciji (C_p)

Merenjem sadržaja vlage u čvrstoj izolaciji se utvrđuje stanje čvrste izolacije nadziranog ET-a.

- Životni vek (Z_v)

Iako na prvi pogled manje bitan parametar od svih prethodno nabrojanih, životni vek ET-a kao parametar je izuzetno bitan. Prema iskustvu elektroprivrednih preduzeća, on se kreće između 42 i 50 godina, što dovodi do zaključka, da se ET-i koji su stariji od pomenutih vrednosti moraju nadzirati češće [4], [5].

U tabeli I su prikazane granične vrednosti parametara za normalno, sumnjivo i loše stanje ET-a.

TABELA I PRIPAK GRANIČNIH VREDNOSTI ZA PARAMETRE

	Normalno stanje	Sumnjivo stanje	Loše stanje
IP	> 2	$1,25 \geq \text{IP} > 1,10$	< 1
$\operatorname{tg}\delta_{\text{nam}}$	< 0,45	$0,45 \leq \operatorname{tg}\delta_{\text{nam}} < 0,60$	$\geq 0,60$
$\operatorname{tg}\delta_{\text{PI}}$	$\leq 0,70$	$0,70 < \operatorname{tg}\delta_{\text{PI}} \leq 0,80$	$> 0,80$
$\operatorname{tg}\delta_{\text{ulja}}$	$\leq 0,005$	$0,005 < \operatorname{tg}\delta_{\text{ulja}} \leq 0,02$	$> 0,02$
ΔL_γ	$\leq 2 \%$	$2 \% < \Delta L_\gamma \leq 4 \%$	$> 6 \%$
C_p	$\leq 0,5 \%$	$0,5 \% < C_p \leq 2 \%$	$> 2 \%$

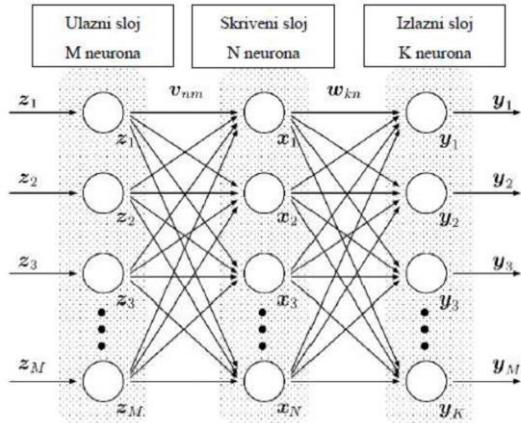
MONITORINGA ET-A [3]

III AUTOENKODERSKE NEURALNE MREŽE

Veštačke neuralne mreže (*Artificial Neural Network – ANN*) ne predstavljaju matematički model stvarnih neuralnih mreža, već su one skup neurona koji su povezani biološki inspirisanim arhitekturom. Sve ANN su organizovane u nekoliko slojeva. Veštački neuroni se modeluju kao spoj za sumiranje ulaza i jedinice za delinearizaciju. Jedan veštački neuron je neupotrebljiv, ali njegova upotreba vrednost se

povećava povezivanjem više njih. Skup više veštačkih neurona je veštačka neuralna mreža [6].

U veštačkim neuralnim mrežama se neuroni grupišu u slojeve, svaki sloj čini niz nezavisnih neurona. Najčešće se koriste troslojne ANN, tj. mreže sa ulaznim, skrivenim i



Slika 1 Troslojna ANN [9]

izlaznim slojem Sl. 1.

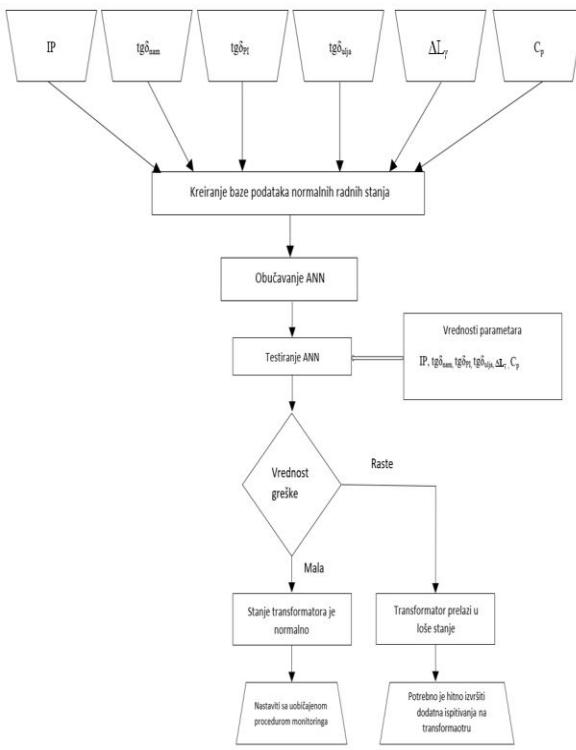
Anautoenkoderske ANN jesu vrsta neuronske mreže koja je obučena da približno, ali ne potpuno, svoj ulazni sloj preslikava u izlazni sloj. Pomenuta vrsta ANN-e se može podeliti na deo koji je enkoder i deo koji je dekoder. Enkoder predstavlja funkciju $p = f(x)$ koja preslikava ulaz x u reprezentaciju p , a dekoder predstavlja funkciju $g(p)$ koja pokušava da vrati reprezentaciju p u ulaz x . Kada bi ovakva mreža bila obučena da nađe baš svako x i verno ga preslikava u funkciju $g(f(x))=x$ takva mreža ne bi bila upotrebljiva. Autoenkoderi su zbog toga dizajnirani da nemaju mogućnost da nauče domen x savršeno, što implicira da će se uvek ulaz i izlaz razlikovati za neku malu vrednost [7], [8]. U sledećim radovima se mogu pročitati detaljnije informacije o autoenkoderskim ANN, kao i drugim vrstama ANN [6], [7], [8].

Projektovanje autoenkoderske ANN se sastoji iz nekoliko koraka:

- sakupljanje podataka,
- predobrada podataka,
- formiranje ANN,
- obučavanje ANN i
- testiranje ANN.

Na Sl. 2 prikazan je algoritam programa za dijagnostiku stanja ET-a koji pomoću autoenkoderskih ANN vrši dijagnostiku stanja ET-a.

Najpre je formirana baza podataka normalnih radnih stanja pomoću parametara odabranih za monitoring ET-a. U tabeli I su prikazani svi parametri i njihove granične vrednosti za normalna stanja. U formiranju baze podataka normalnih radnih stanja figurisalo je pedeset hiljada merenja ET-a čiji je svaki od parametara bio u granicama normalnog radnog stanja.



Slika 2 Algoritam programa za dijagnostiku stanja ET-a

Obučavanje autoenkoderske ANN je izvršeno sa formiranim bazom podataka normalnih radnih stanja ET-a. Ovim korakom formirani su funkcionalni delovi autoenkoderske ANN (enkoder i dekoder), pomoću kojih se vršiti kopiranje ulaza na izlaz. Ekonomer i dekonomer se formiraju tako da ukoliko ulaz u toku testiranja budu vrednosti parametara ET-a koji oslikavaju normalno radno stanje, autoenkoderska ANN će ulazne parametre preslikati na izlaz sa malom srednjom kvadratnom greškom. Dok ukoliko na ulazu ipak bude jedan od parametara koji nije u granicama normalnog radnog stanja iz tabele I, već je parametar koji oslikava sumnjivo ili loše stanje srednja kvadratna greška će biti veća. Što su odstupanja jednog parametra od normalnog radnog stanja veća, veća će biti greška. Takođe, ukoliko više parametra odstupa od normalnog radnog stanja, to će se odraziti i na rast srednje kvadratne greške.

Ukoliko je vrednost srednje kvadratne greške mala, stanje ET-a je normalno i potrebno je nastaviti sa uobičajenom procedurom monitoringa. Rast srednje kvadratne greške ukazuje na to da ET prelazi u stanje koje nije normalno radno stanje i potrebno je hitno izvršiti dodatna ispitivanja na ET-u, kako bi se utvrdilo koji je uzrok pogoršanja stanja.

IV REZULTATI

Testovi predstavljeni tabelom II prikazuju ponašanje programa za dijagnostiku stanja ET-a. Testovi su izvedeni tako

što su vrednosti svih parametara osim $tg\delta_{nam}$ fiksirani na vrednosti koje imaju ET-i koji su u normalnom radnom stanju, dok je $tg\delta_{nam}$ menjana u širokom opsegu.

TABELA II REZULTATI PROGRAMA ZA DIJAGNOSTIKU STANJA ET-A – VARIJABILNOST GREŠKE U ODNOŠU NA PROMENU JEDNOG

Redni broj testa	IP	$tg\delta_{nam}$	$tg\delta_{pi}$	$tg\delta_{ujia}$	ΔL_γ	C_p	Z_v	Greška
1.	3	0.1	0,6	0,004	1	0,3	30	0.01
2.	3	0.15	0,6	0,004	1	0,3	30	0.01
3.	3	0.2	0,6	0,004	1	0,3	30	0.01
4.	3	0.25	0,6	0,004	1	0,3	30	0.01
5.	3	0.3	0,6	0,004	1	0,3	30	0.01
6.	3	0.35	0,6	0,004	1	0,3	30	0.02
7.	3	0.4	0,6	0,004	1	0,3	30	0.02
8.	3	0.45	0,6	0,004	1	0,3	30	0.02
9.	3	0.5	0,6	0,004	1	0,3	30	0.03
10.	3	0.55	0,6	0,004	1	0,3	30	0.03
11.	3	0.6	0,6	0,004	1	0,3	30	0.03
12.	3	0.65	0,6	0,004	1	0,3	30	0.04
13.	3	0.7	0,6	0,004	1	0,3	30	0.04
14.	3	0.75	0,6	0,004	1	0,3	30	0.05
15.	3	0.8	0,6	0,004	1	0,3	30	0.06
16.	3	0.85	0,6	0,004	1	0,3	30	0.07
17.	3	0.9	0,6	0,004	1	0,3	30	0.08
18.	3	0.95	0,6	0,004	1	0,3	30	0.09
19.	3	1	0,6	0,004	1	0,3	30	0.10
20.	3	2	0,6	0,004	1	0,3	30	0.46
21.	3	3	0,6	0,004	1	0,3	30	1.11

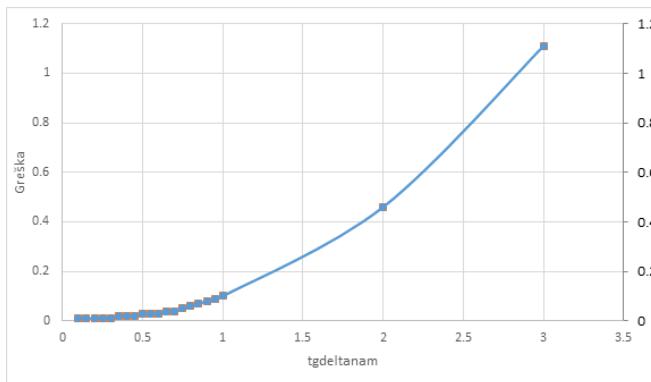
PARAMETRA

U tabeli II prikazana je i greška za svaki od testova. Greška predstavlja srednju kvadratnu grešku koja je kod lošeg stanja ET-a sve veća, jer je odstupanje parametra od normalnog radnog stanja veće. U testovima od 1-8 svi ulazni parametri su u dozvoljenim granicama (granicama normalnog radnog stanja), pa su i greške manje. Testovi 9 i 10 su stanja ET-a u kojima su svi parametri sem $tg\delta_{nam}$ u dozvoljenim granicama, dok vrednosti parametara $tg\delta_{nam}$ ukazuju na to da je stanje ET-a sa strane izolacije namotaja sumnjivo. Ukupan pregled stanja, tj. ukupna greška se razlikuje, ali ne mnogo od prethodnih testova, jer još uvek ukupno stanje ET-a nije sumnjivo.

Treba imati u vidu, da i IP faktor prikazuje stanje izolacije, te da bi u realnim okolnostima u ovom slučaju i on bio povišen, pa bi i posmatrana greška bila veća. Ostali testovi predstavljaju testove na ET-u kome je izolacija namotaja u lošem stanju.

Može se zaključiti da što je veća vrednost $tg\delta_{nam}$, stanje je lošije, ali je i greška veća.

Na Sl. 3 je prikazana zavisnost rasta greške od pogoršavanja stanja izolacije namotaja, tj. od povećanja vrednosti $tg\delta_{nam}$.



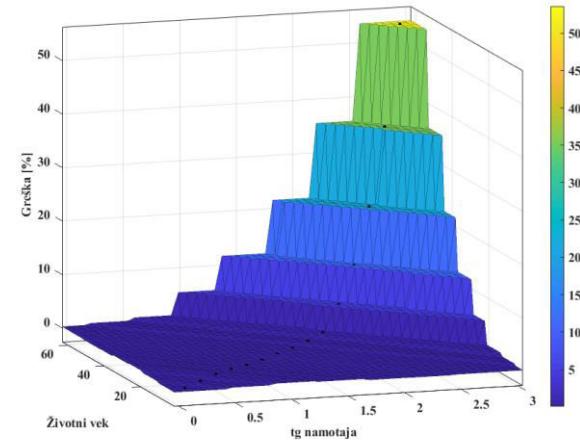
Slika 3 Zavisnost greške ANN od vrednosti $tg\delta_{nam}$

U tabeli III predstavljeno je petnaest testova kod kojih su vrednosti svih parametara, sem $tg\delta_{nam}$ i životnog veka, fiksirani na vrednosti koje se nalaze u granicama normalnog radnog stanja ET-a. Vrednosti parametara $tg\delta_{nam}$ i životni vek su varirani od vrednosti koje predstavljaju normalno stanje ET-a, do veoma lošeg stanja ET-a. Variranjem parametara došlo je i do variranja greške, koja je prikazana u tabeli, ali i grafički na Sl. 4. Na Sl. 4 se može primetiti i da srednja kvadratna greška pri promeni dva parametra istovremeno varira i do 50%.

TABELA III
REZULTATI PROGRAMA ZA DIJAGNOSTIKU STANJA ET-A
- VARIJABILNOST GREŠKE U ODNOSU NA PROMENU DVA PARAMETRA

Redni broj testa	IP	$tg\delta_{nam}$	$tg\delta_{pi}$	$tg\delta_{ulja}$	ΔL_γ	C_p	Z_v	Greška
1.	3	0.1	0.6	0.004	1	0.3	4	0.0228
2.	3	0.3	0.6	0.004	1	0.3	8	0.2669
3.	3	0.5	0.6	0.004	1	0.3	12	0.5391
4.	3	0.7	0.6	0.004	1	0.3	16	0.4075
5.	3	0.9	0.6	0.004	1	0.3	20	0.1659
6.	3	1.1	0.6	0.004	1	0.3	24	0.1413
7.	3	1.3	0.6	0.004	1	0.3	28	0.231
8.	3	1.5	0.6	0.004	1	0.3	32	0.2758
9.	3	1.7	0.6	0.004	1	0.3	36	0.5951
10.	3	1.9	0.6	0.004	1	0.3	40	1.159
11.	3	2.1	0.6	0.004	1	0.3	44	5.37
12.	3	2.3	0.6	0.004	1	0.3	48	11.69
13.	3	2.5	0.6	0.004	1	0.3	52	21.57
14.	3	2.7	0.6	0.004	1	0.3	56	35.46
15.	3	2.9	0.6	0.004	1	0.3	60	53.61

Radi dodatnog testiranja programa učitani su i realni podaci iz eksploatacije različitih ET-a, tabela IV. U tabeli IV je prikazana i primena CBM i RBM metodologije. Može se uočiti da se ove dve metodologije razlikuju, jer RBM metoda uzima u obzir i značaj ET-a u sistemu. Značaj ET, u tabeli IV, je predstavljen njegovom nominalnom snagom. Veća nominalna snaga predstavlja i veći značaj ET-a u sistemu. Dok je rizik koji se koristi za poređenje u RBM proračunat kao proizvod greške i snage, takođe prikazano u tabeli IV. Što je viši rizik to je potrebna hitnija intervencija na određenom ET-u prema RBM.



Slika 4 Zavisnost greške ANN od vrednosti $tg\delta_{nam}$ i životnog veka

TABELA IV
REALNI PODACI ET-A IZ EKSPLOATACIJE

Broj ET-a	Izmereni parametri							Snaga [MVA]	Greška	CBM	RBM
	IP	$tg\delta_{nam}$	$tg\delta_{pi}$	$tg\delta_{ulja}$	ΔL_γ	C_p	Z_v				
1.	1.08	1.04	0.73	20.1	1.08	0.1	65	6.3	137.8	4	8
2.	1.08	1	0.72	18	3.82	0.3	42	2.25	47.11	8	10
3.	1.13	0.37	0.2	0.2	0.06	0.15	15	40	88.06	7	5
4.	5.79	2	0.42	50.7	0.84	1.25	40	360	370.2	1	1
5.	6.03	0.39	0.18	1.5	0.23	1.7	43	420	3.71	10	7
6.	7.47	0.6	0.55	1.6	0.38	1.2	8	2.5	163.5	3	9
7.	7.97	0.38	0.23	1.3	0.91	0.5	25	48	43.74	9	6
8.	25.3	0.64	0.13	1.4	0.18	0.3	4	112	277.4	2	2
9.	26	0.753	0.22	2.2	1.34	0.5	59	31.5	127.5	6	3
10.	2.31	0.444	0.29	28.3	0.8	0.5	30	27.55	133.1	5	4

V ZAKLJUČAK

U cilju direktnе primene CBM i RBM kao dva dominantna načina donošenja odluka o održavanju u bilo kom tehničkom sistemu, potrebno je imati pouzdane programe koji bi vršili dijagnostiku u realnom vremenu. Monitoringom i prikupljanjem procesnih podataka sa ET-a formira se ogromna baza podataka formirane na taj način inženjer

nije u mogućnosti da isprati u realom vremenu, bez pauze i bez greške. Zbog toga su bitni algoritmi mašinskog učenja, koji bi ovaj postupak skratili i uprostili.

Prikazan algoritam primene ANN može se koristiti za *on-line* dijagnostiku stanja ET-a u realnom vremenu. Dovoljno je da se prati vrednost greške u realnom vremenu, da bi se dobila objektivna slika stanja ET-a zasnovana na prikupljenim numeričkim vrednostima monitoringa. Takvi rezultati mogu biti primenjeni u CBM i RBM metodama. Algoritam može poslužiti i za TBM, metodu planiranja održavanja, pri čemu bi se manuelno unosile vrednosti parametara. Prikazan algoritam se može primeniti i na ostale elemente EES-a. U daljem radu autori će razmotriti primenu i uporednu analizu drugih algoritama mašinskog učenja.

LITERATURA

- [1] G.F. Kovalev, L.M. Lebedeva : "Reliability of Power Systems", Power Systems, p. 1–35, 2019.
- [2] International standard IEC 60050-421, International Electrotechnical Vocabulary, Chapter 421 : Power transformers and reactors, first edition, 1990.
- [3] Miletta D. Žarković: Monitoring i dijagnostika razvodnog postrojenja na bazi fazi modela stanja visokonaponske opreme, p. 26–40, 2017.
- [4] H. Gea and S. Asgarpoorb, "Parallel Monte Carlo simulation for reliability and cost evaluation of equipment and systems," Electric Power Systems Research, vol. 81, p. 347–356, 2011.
- [5] P. Tamilselvan and P. Wang, "Failure diagnosis using deep belief learning based health state classification," Reliability Engineering and System Safety, vol. 115, p. 124–135, 2013
- [6] Nabamita Benerjee Roy, Kesab Bhattacharva: Application of signal processing tools and artificial neural network in diagnosis of power system faults, 2022.
- [7] Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep Learning. MIT Press, 2016.
- [8] Miloš Mandić : Smanjenje dimenzionalnosti prostornih podataka pomoću veštačkih neuronskih mreža, Beograd, 2018.
- [9] T. Isokawa, H. Nishimura i N. Matsui: Quaternionic Multilayer Perceptron with Local Analyticity,Information-an International Interdisciplinary Journal, t. 3, br. 4,str. 756-770, 2012.

ABSTRACT

The power transformer is the most expensive from the economic point of view, and from the engineering point of view the most complex element of the power system. Thermal, mechanical, chemical and electrical processes meet in it and they are all equally important. Due to the complexity of the power transformer, its monitoring and diagnostics are very complex processes. During the off-line and on-line monitoring of the power transformer, during exploitation, a large amount of data is collected. The database formed in this way can be used for the application of machine learning in order to diagnose dangerous operating conditions of the power transformer. In this paper, the algorithm of application of autoencoder neural networks using the MATLAB software tool is presented. The obtained results can be used for an objective assessment of the state of power transformers based on the numerical values of the monitoring parameters.

APPLICATION OF AUTOENCODER NEURAL NETWORKS FOR DIAGNOSTICS OF THE STATE OF POWER TRANSFORMERS

Milica Vlaisavljević,
Miletta Žarković,
Zlatan Stojković.