

Mape prioriteta održavanja elektroenergetske opreme na bazi mašinskog učenja

Mileta Žarković, Zlatan Stojković

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

Milan Đorđević

Služba za unapredjenje tehničkog sistema elektrana
Javno preduzeće Elektroprivreda Srbije
Beograd, Srbija
djordjevic.milan@eps.rs

Sažetak—Rad opisuje inovativnu metodologiju formiranja mape prioriteta održavanja ključne elektroenergetske opreme u tehničkim sistemima elektrana. Inovativnost metodologije se ogleda u korišćenju velikih skupova podataka kroz metode mašinskog učenja kako bi se unapredili planovi održavanja prema trenutnom stanju opreme (*Condition Based Maintenance–CBM*) i prema riziku i pouzdanosti (*Reliability Centered Asset Management – RCAM*). U radu je razmatran prioritet održavanja 90 generatora i 93 energetska transformatora u proizvodnim jedinicama Elektroprivrede Srbije (EPS). Pri tome su korišćeni veliki skupovi podataka, prikupljeni iz sistemâ monitoringa generatora i transformatora. Na skupovima podataka primenjene su veštačke neuralne mreže iz domena mašinskog učenja. Razvijena metodologija omogućava automatizovano formiranje mapa rizika za potrebe određivanja prioriteta održavanja u elektranama.

Ključne reči — plan održavanja; generator; energetska transformator; mašinsko učenje

I. UVOD

Pouzdanu i kvalitetnu isporuku električne energije predstavlja osnovni zahtev koji pred elektroneenergetskim sistemom (EES) postavljaju korisnici električne energije. Ispunjene ovog cilja podrazumeva minimizaciju broja otkaza elemenata EES-a, kao i minimizaciju neisporučene električne energije u slučaju da do otkaza ipak dođe. Da bi EES adekvatno funkcionisao i ispunjavao osnovne zadatke, potrebno je na pravilan i pravovremenim način održavati elemente EES-a. U cilju povećanja raspoloživosti opreme i pouzdanosti proizvodnih jedinica, pored tradicionalne metode periodičnog održavanja (*Time Based Maintenance–TBM*), uvedene su i metode preventivnog održavanja prema stanju (CBM) i održavanje na bazi pouzdanosti (RCAM). CBM metodologija se primenjuje onda kada sistemi za kontinualni monitoring pogonskog rada visokonaponske opreme ukažu na potrebu za time. RCAM metodologija koristi kombinaciju trenutnog stanja opreme i njenog značaja u postrojenju. Svrha primene CBM i RCAM metodologijâ jeste pravovremeno i pravilno donošenje odluka u vezi sa održavanjem proizvodnih jedinica i visokonaponske opreme u njima. Za formiranje mape prioriteta održavanja na osnovu obe metodologije neophodno je proceniti stanje elektroenergetske opreme. Dakle, stanje i performanse elektroenergetske opreme neophodno je predstaviti numeričkom

vrednošću. Numerička vrednost, kao pokazatelj stanja opreme, može se generisati primenom različitih metoda mašinskog učenja.

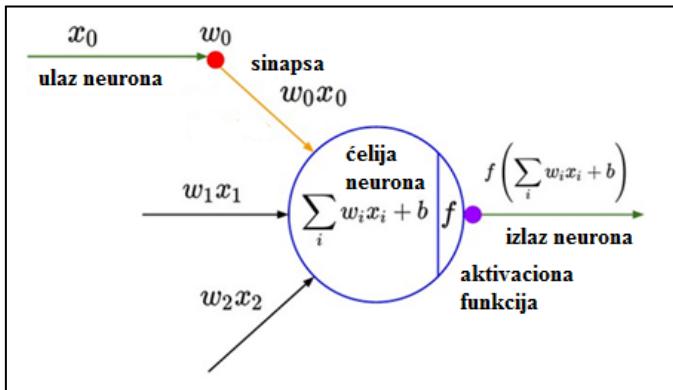
U [1]-[4] je objašnjena primena Fazi logike za generisanje verovatnoće kvara. Od strane korisnika, eksperta i na bazi standarda realizuju se svi potrebni koraci Fazi logike: fazifikacija, formiranje baze pravila i defazifikacija. Tako formirani Fazi ekspertske sistemi za nove ulazne podatke monitoringa određuju verovatnoću kvara. Dakle, rad Fazi ekspertske sistema se bazira kako na znanju i iskustvu eksperta tako i neposrednih korisnika opreme (npr. inženjera održavanja).

Za razliku od primene Fazi logike, metode mašinskog učenja koriste zakonitosti i relacije koje postoje između izmerenih vrednosti u bazi podataka prikupljenih iz sistemâ monitoringa. Primena mašinskog učenja u dijagnostici stanja i performansi elektroenergetske opreme razmatrana je u [5] i [6]. Rezultat koji se koristi za donošenje odluka o prioritetu održavanja je godina životnog veka opreme koja se određuje na osnovu monitoringom izmerenih parametara i primenom veštačkih neuralnih mreža iz domena nadgledanog mašinskog učenja. U ovom radu neuralne mreže su primenjene na bazama podataka monitoringa 93 energetska transformatora i 90 generatora u proizvodnim jedinicama EPS. Baze podataka su formirane tako da set ulaznih obeležja predstavlja parametre monitoringa, a izlaz je estimirana starost opreme (broj godina eksploracije opreme). Estimirana starost opreme se upoređuje sa stvarnom starošću ina taj način se dobija informacija o ubrzanim starenju, preopterećenju i postojanju kvara na opremi. Na osnovu takvih podataka moguće je primeniti CBM metodologiju i formirati mapu prioriteta održavanja. U radu se dalje uvodi mera značaja opreme kroz njenu instalisanu snagu i generisanu ili transformisalu energiju (energiju plasiranu u EES). Na osnovu toga realizuje se i RCAM metodologija. Rezultati za sve uređaje su predstavljeni na mapama rizika, prikazanim u poglavljiju IV.

II. NEURALNE MREŽE

Veštačke neuralne mreže (*Artificial Neural Networks, ANN*), predstavljaju novu generaciju sistema za informaciono procesiranje koje pokazuju osobinu učenja i generalizacije na osnovu podataka kojima se obučavaju [7]. Ove mreže se sastoje od velikog broja gusto povezanih procesorskih elemenata, takozvanih neurona, koji su organizovani po nekim regularnim

arhitekturama. Razvoj neuralnih mreža je nastao motivacijom da se modeluje ponašanje neurona u mozgu čoveka. Ovde je razmatrano kako one funkcionišu za problem superviziranog učenja, gde postoji baza podataka sa ulazima x i tačnim vrednostima za izlaze y , koje neuralna mreža modeluje. U problemu analiziranom u ovom radu ulazi su rezultati monitoringa energetskih transformatora i generatora, a izlaz je estimirana starost opreme. Na osnovu baze podataka vrši se podešavanje težinskih faktora svih neurona, u kojima je skladišteno „znanje“ mreže, tako da se što bolje modeluje zavisnost izlaza od ulaznih podataka. Nakon toga, za nove ulaze, koji nemaju pridružen izlaz, neuralna mreža može da vrši predikciju izlaza. Na Sl. 1 je predstavljen matematički model neurona.



Slika 1. Matematički model neurona

Kao što se može primetiti, prvo se nad ulazom vrši primena linearne transfer funkcije:

$$net = \sum_{i=0}^{n-1} w_i x_i + b, \quad (1)$$

gde su w_i težine - promenljivi parametri vezani za komponente ulaza, dok je b promenljivi parametar koji predstavlja slobodan član, a x predstavlja ulaz neurona. Neke od drugih mogućnosti za transfer funkciju su kvadratna, polinomijalna i sferična. Dalje, rezultat transfer funkcije se propusti kroz aktivacionu funkciju $y=f(net)$ kako bi se formirali finalni izlazi neurona. Neke od najpopularnijih aktivacionih funkcija trenutno su: linearna, sigmoid, tangens hiperbolički, relu i cureći relu. Linearna aktivaciona funkcija ima oblik

$$f(net) = net. \quad (2)$$

Sigmoid aktivaciona funkcija ima oblik:

$$f(net) = \frac{1}{1 + e^{-net}}. \quad (3)$$

Tangens hiperbolički aktivaciona funkcija ima oblik:

$$f(net) = \tanh(net). \quad (4)$$

Relu aktivaciona funkcija ima oblik:

$$f(net) = \max(0, net), \quad (5)$$

Povezivanjem više definisanih neurona formira se *feedforward* ANN. Jedan sloj neurona je skup više neurona koji imaju isti ulaz, ali svaki neuron primenjuje svoje težinske parametre na taj ulaz. Svaka *feedforward* ANN se sastoji od ulaznog sloja, skrivenih slojeva i izlaznog sloja. Ulazni sloj prima podatak koji je doveden na neuralnu mrežu. Dalje, skriveni slojevi kao ulaz imaju izlaze neurona iz prethodnog sloja, i njihov izlaz se koristi kao ulaz u sledeći sloj neurona. Izlazni sloj je poslednji sloj u ANN koji treba da formira predikciju na osnovu podatka koji je doveden na ulaz.

U slučaju da se rešava problem regresije – predikcija realne vrednosti, na izlazni neuron se obično stavlja linearna aktivacija. U slučaju da je binarna klasifikacija, može se koristiti izlazni neuron sa *sigmoid* aktivacijom, gde će vrednost izlaza simulirati verovatnoću da neuron pripada prvoj klasi, dok će verovatnoća pripadnosti u nultoj klasi biti kada se od jedinice oduzme vrednost izlaza. U slučaju višeklasne klasifikacije, postoji generalizacija *sigmoid* neurona, tako što se formira k neurona sa linearnom aktivacijom u izlazom sloju, gde je k broj klasa. Onda se nad svim neuronima primeni *softmax* funkcija [8], kako bi transformisala izlaze u brojeve koji simuliraju verovatnoće pripadnosti svakoj klasi.

$$\hat{p}_m = P(Y = m | X = x^{(i)}) = \frac{e^{\text{net}_k^{(i)}}}{\sum_{j=1}^k e^{\text{net}_j^{(i)}}}. \quad (6)$$

Neuralna mreža skladišti svoje „znanje“ u težinama W , i zbog toga je potrebno pronaći dobar skup vrednosti težinskih parametara za problem koji se rešava. W je skup težinskih faktora koji se podešava pri običavanju ANN. To se radi tako što se prepostavi funkcija gubitka $L(W)$, koja kada ima veliku vrednost znači da mreža ima loše performanse nad nekim skupom podataka, dok mala vrednost označava dobre performanse. Dalje se pronađe skup parametara W , za koji je funkcija gubitka $L(W)$ najmanja. Za problem regresije koristi se linearan izlazni sloj i kriterijum srednje kvadratne greške.

$$L(W) = \frac{1}{N} \sum_{i=1}^N L_i(f(x^{(i)}, W), y^{(i)}), \quad (7)$$

$$L_i = (\hat{y}^{(i)} - y^{(i)})^2, \quad (8)$$

$$\hat{y}^{(i)} = \text{net}^{(i)} = f(x^{(i)}, W). \quad (9)$$

Jednačina (7) predstavlja opšti oblik funkcije gubitka. Može se videti da svaki podatak $(x^{(i)}, y^{(i)})$ iz nekog skupa, nad kojim se računa funkcija gubitka, daje svoj doprinos. U ovom slučaju daje doprinos tako što se računa srednja kvadratna greška između izlaza mreže $\hat{y}^{(i)}$ i stvarne vrednosti izlaza $y^{(i)}$. Što je srednja kvadratna greška veća, to je gubitak veći i vrednost performanse na posmatranom skupu podataka je lošija. Za regresiju se koriste različite vrste greške, apsolutna i druge, a kompletni proces minimizacije funkcije gubitaka se vrši u velikom broju iteracija koje su računarski zahtevne. Kod *feedforward* neuralnih mreža dovoljan je jedan prolazak unapred i jedan prolazak unazad. Ova procedura se zove algoritam propagacije greške unazad, i on je implementiran u svim bibliotekama programskih jezika, koje služe za implementaciju.

Obično se na početku rešavanja problema neuralnim mrežama, ili bilo kojim algoritmom mašinskog učenja, odvoji deo raspoložive baze podataka da bude testirajući skup, dok se

ostali podaci koriste za treniranje. Testirajući skup se ne koristi sve do samog kraja projektovanja, i na kraju se finalna verzija modela iskoristi nad podacima testirajućeg skupa kako bi se dobila realna estimacija performansi projektovanog modela. Česta preporuka za podelu je da se, ako 20% ide na testirajući skup, preostali podaci podeli tako da se 60% koristi za treniranje i 20% za validaciju, ali ni ovde nema nekih strogih pravila za proporciju podele [8]. Dok se testirajući podaci ne koriste do kraja projektovanja, validacioni podaci služe za učenje hiperparametara modela. Kao što se nad trenirajućim podacima uče najbolji promenljivi parametri mreže W , na validacionim podacima se uče najbolji hiperparametri: arhitektura mreže, tipovi aktivacionih funkcija, optimalan trenutak za kraj obučavanja, itd. Za učenje hiperparametara se ne može koristiti testirajući skup, jer bi se oni preobučili na njemu i ne bi dobili pouzdanu estimaciju performansi mreže. Procedura učenja hiperparametara se zove krosvalidacija i ona funkcioniše tako što se mreža istrenira za više različitih kombinacija hiperparametara na trenirajućim podacima, dok se performanse mere na validacionim podacima. Ona kombinacija hiperparametara koja daje najbolje rezultate na validacionim podacima proglašava se optimalnom i usvaja se.

III. PRIMENA ANN

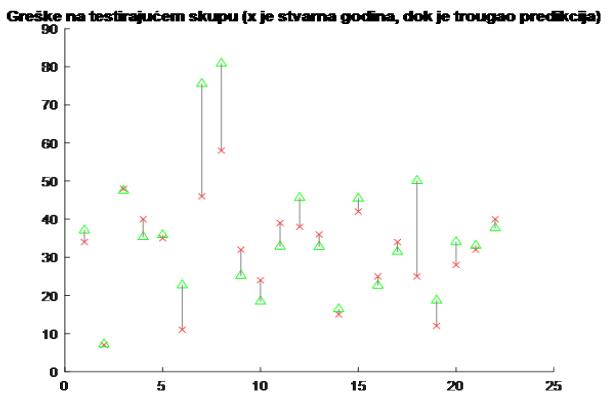
ANN je primenjena na bazi energetskih transformatora koja sadrži sledeće podatke: U_n (naznačeni napon), S_n (naznačena snaga), R_{60}° (jednominutna vrednost izolacione otpornosti), $tg\delta_{nam}$ (vrednost tg namotaja), N_I (indeks polarizacije), X , Y , Z , O_2 (rezultati hromatografske DGA (*Dissolved gas-in-oil analysis*) analize $X=CH_4/H_2$, $Y=C_2H_2/C_2H_4$, $Z=C_2H_4/C_2H_6$) i broj godina eksploracije. Ova baza sadrži 1.384 seta podataka o stanju razmatrana 93 energetska transformatora. Na ovoj bazi podataka sprovedeno je obučavanje, pri čemu je 20% podataka iskorišćeno za testiranje i validaciju rada obučene neuralne mreže. Preostali podaci su podeljeni u $k=5$ disjunktnih podskupova kako bi se izvršila tehnika krosvalidacije za pronalaženje hiperparametara. Isprobane su brojne kombinacije hiperparametara u potrazi za najboljom. Kao optimalne su usvojene sledeće vrednosti:

- tri skrivena sloja sa po 10 neurona,
- *Tansig* aktivaciona funkcija u svim skrivenim slojevima,
- parametar regularizacije $\alpha=0,02$, gde je kriterijumska funkcija ugrađena u biblioteke korišćenih softverskih alata,
- za dužinu treniranja je izabrano 35 epoha.

Mreža je zatim istrenirana sa ovim hiperparametrima na skupu koji se dobije kada se spoje svih $k=5$ podskupova. Na takvu mrežu su dovedeni podaci za testiranje, koji su u početku ostavljeni sa strane, i srednja apsolutna greška (*Mean Absolute Error*, MAE) između predikcija neuralne mreže i stvarne starosti energetskih transformatora iznosi 12,77 godina. Na Sl. 2 su prikazani rezultati obučene neuralne mreže i mogu se uočiti razlike u predviđanju neuralne mreže. Formirana neuralna mreža za rezultate monitoringa estimira starost energetskih transformatora na osnovu iskustva koje je stekla obučavanjem na bazi podataka. Tako formiranoj neuralnoj mreži kao ulazni

podaci su importovani aktuelni rezultati monitoringa 93 ET-a koji oslikavaju njihovo trenutno stanje.

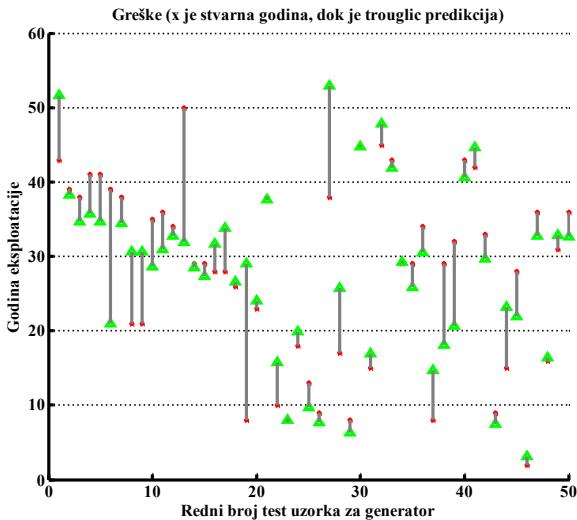
$$L(W) = (1 - \alpha) \left(\frac{1}{N} \sum_{i=1}^N (\hat{y}^{(i)} - y^{(i)})^2 \right) + \alpha \left(\frac{1}{N_W} \sum W^2 \right) \quad (10)$$



Slika 2. Rezultati testiranja ANN za bazu stanja energetskih transformatora

ANN je na osnovu svih dostupnih rezultata monitoringa, baze podataka, procenila njihovu starost (G_{ann}), koja se poredi sa stvarnom starošću (G). Razlika stvarne i procenjene starosti (ΔG) ukazuje na to da li razmatrani ET ubrzano stari ili je njegovo stanje bolje u odnosu na njegovu starost i druge uređaje. Sto je veća pozitivna razlika to znači da razmatrani ET ubrzano stari i da treba da ima prioritet pri održavanju u odnosu na druge ET-e. Negativne vrednosti ΔG ukazuju na to da su oni „noviji“ u odnosu na njihovu stvarnu starost.

Baza podataka za 90 generatora sadrži 1.263 seta podatka, merenja: broj godina eksploracije, N_I , $R_{60}^{\circ rot}$ (jednominutna vrednost otpornosti izlojacije rotorskog namotaja), X (maksimalno odstupanje otpornosti izolacije među fazama statorskog namotaja), $\Delta tg\delta_{P-K}$, $(\Delta tg\delta_{0,2-0,6})max$, $(\Delta tg\delta_{0,6-1,0})max$ i $(tg\delta_{0,2})max$ (maksimalna vrednost i priraštaji faktora dielektričnih gubitaka za različite napone ispitivanja). Najbolja kombinacija hiperparametara je slična, s tim što sada postoji 11 neurona u tri skrivena sloja, a dužina treniranja je 80 epoha. Postupak treniranja i testiranja je isti kao kod energetskih transformatora, a *MAE* iznosi 4,885 godina. Na Sl. 3 su prikazani rezultati obučene ANN i mogu se uočiti razlike u predviđanju. Na datoj slici se mogu uočiti stvarne starosti generatora označene crvenom tačkom, kao i predikcije ANN označene zelenim trougljovima, za 50 testirajućih podataka. Može se primetiti da ANN u dosta slučajeva relativno blisko predviđa starost generatora, dok na nekim primerima pravi vrlo velike greške. S obzirom na raspoloživu količinu podataka za treniranje, nije bilo očekivano da se ANN bolje ponaša. Rezultati ovakve analize sa prioritetima održavanja su prikazani u narednom odeljku.



Slika 3. Rezultati testiranja ANN za bazu stanja generatora

IV. MAPA PRIORITETA ODRŽAVANJA

Rezultati primene ANN direktno ukazuju na razliku stvarne i procenjene starosti uređaja (ΔG) na osnovu koje je moguće doneti odluku, u okviru CBM metodologije, o prioritetu održavanja. U cilju realizacije RCAM metodologije uvedena je instalisana snaga kao pokazatelj značaja energetskih transformatora i generatora u proizvodnim jedinicama. U okviru RCAM metodologije potrebno je izračunati rizik kao proizvod značaja opreme i njegovog stanja. Pri tome je stanje opreme neophodno izraziti kao verovatnoću kvara. Zbog toga je formiran indeks verovatnoće kvara HI narednom formulom:

$$HI_i = \frac{\Delta G - \Delta G_{min}}{|\Delta G_{max} - \Delta G_{min}|} 100\%. \quad (11)$$

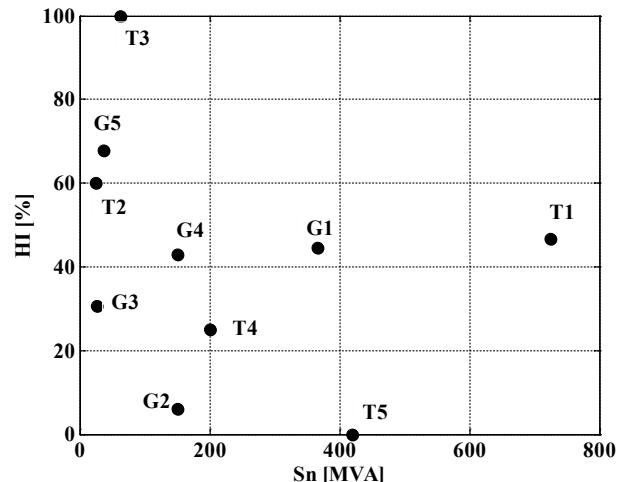
Dalje R , rizik se računa kao

$$R = HI \times S_n. \quad (12)$$

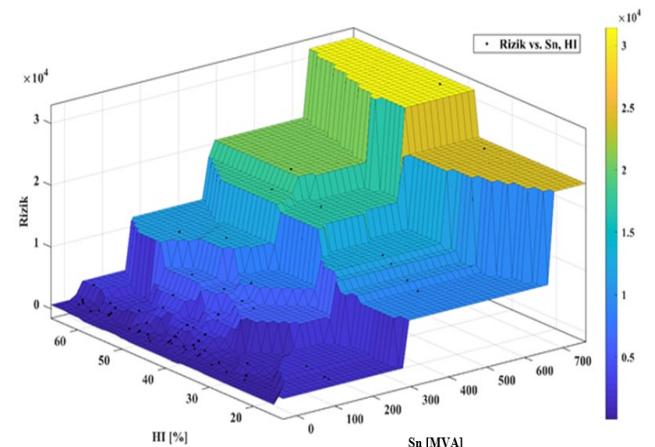
TABELA I. REZULTATI PRIMENE ANN I FORMIRAN PLAN ODRŽAVANJA PREMA CBM I RCAM

Redni Br.	S_n [MVA]	G	G_{ANN}	ΔG	CBM	R	RCAM
T1	725	30	33,4	3,4	4	33769	1
T2	25	31	39,5	8,5	3	1500	7
T3	63	10	33,7	23,7	1	6300	4
T4	200	41	36,2	-4,8	8	5000	5
T5	420	46	31,7	-14,3	10	0	10
G1	367	42	44,6	2,6	5	16321	2
G2	150	31	19,0	-12	9	907	8
G3	27,55	36	33,3	-2,7	7	841	9
G4	150	34	36,0	2,0	6	6434	3
G5	37	2	13,5	11,5	2	2512	6

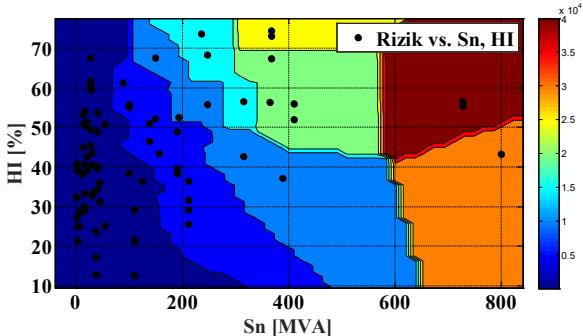
Rangiranje ključne elektroenergetske opreme primenom metoda CBM samo na bazi verovatnoće kvara predstavljeno je u tabeli. Kao rezultat prikazan je i rizik svakog uređaja, izračunat na osnovu (11) i na osnovu njega je izvršeno rangiranje opreme u okviru RCAM metode. U cilju što boljeg grafičkog prikaza rezultata uvodi se pojam mape rizika. Mapa rizika je veoma korisna i praktična za vizuelizaciju prioriteta održavanja elemenata poroizvodnih jedinica [9]. Svaka tačka na mapi rizika predstavlja jedan razmatrani uređaj proizvodnih jedinica (Slika 4). Za svaku tačku sa Slike 4 može se definisati krajnji rezultat R u vidu izlazne ocene mape rizika. Na Sl. 5 je prikazana 3-D mapa rizika, gde je na z-osi prikazan rizik. Na takvoj mapi rizika je izvršena interpolacija tako da se jasno vide prioriteti prilikom donošenja odluke za održavanje razmatrana 93 energetskih transformatora. Na Sl. 6 su predstavljeni rezultati za 90 razmatranih generatora, ali su prikazane i konture oblasti gde pojedini uređaji pripadaju. Ovakav prikaz rezultata može biti koristan kod velikog broja uređaja, jer ih grupiše u konture koje obuhvataju uređaje prema sličnoj potrebi za održavanjem. Unošenjem novih rezultata omogućava se upoređivanje i sagledavanje prioriteta održavanja sa već postojećim stanjem uređaja u sistemu.



Slika 4. Mapa rizika za Tabelu I



Slika 5. Trodimenzionalna mapa rizika za prioritet održavanja 93 energetskih transformatora



Slika 6. Konturna mapa rizika za prioritet održavanja 90 generatora

V. ZAKLJUČAK

Rad prikazuje mogućnosti primene ANN iz domena mašinskog učenja na postojećim realnim bazama podataka monitoring sistemâ elektroenergetske opreme u proizvodnim jedinicama. Suštinska prednost primene ANN je što ona uči o zavisnostima parametara dobijenih sa monitoring sistemâ opreme i starosti opreme. Dakle, što je veća baza podataka ANN funkcioniše bolje i iz tog razloga ona je primenljivija i na rezultatima *on-line* monitoringa. S obzirom na savremeni trend ugradnje uređaja za *on-line* monitoring, kako na postojećim, a pogotovo na novim elementima EES, biće neophodno ispratići ekspanziju količine novih podataka sa monitoringa stanja opreme odgovorajućim metodama za obradu podataka, kako bi prikupljeni podaci što bolje bili upotrebljeni i interpretirani. Dakle, porastom količine informacija i ugradnjom uređaja za *on-line* monitoring doći će do ograničenja u pogledu toga da čovek neće moći da efikasno prati toliko veliki skup podataka, pogotovo u smislu praćenja razvoja kvarova/poremećaja koji sporo evoluiraju, i da će biti neophodno razviti alat koji će ekspertima pomoći da što adekvatnije koriste velike količine podataka. Očekivano je da će se algoritmi predstavljenih metodologija mašinskog učenja uspešnije obučavati i u budućnosti vršiti sve tačniju predikciju na bazama podataka koje se svakodnevno uvećavaju. Predstavljeni rezultati ukazuju na prioritete održavanja energetskih transformatora i generatora.

ZAHVALNICA

Autori zahvaljuju JP EPS na saradnji u razvoju i primeni metoda ocene stanja ključne elektroenergetske opreme u proizvodnim jedinicama u sklopu Studije „Primena savremenih metoda Fuzzy logike i Data Mining u dijagnostici i održavanju ključne elektroenergetske opreme (energetskih transformatora i generatora)“.

LITERATURA

- [1] Žarković M., Stojković Z. : "Artificial intelligence based thermographic approach for high voltage substations risk assessment", IET Generation, Transmission & Distribution Vol. 9, Issue 14, p. 1935-1945, November 2015.
- [2] Žarković M., Stojković Z. : "Analysis of artificial intelligence expert systems for power transformer condition monitoring and diagnostics", Electric Power Systems Research Vol. 149, p. 125-136, Avgust 2017.
- [3] Žarković M., Stojković Z. : "Fuzzy logic and artificial neural network based thermography approach for monitoring of high voltage equipment", International Journal of Electrical Engineering Education, Vol. 52, Issue 1, p. 81-96, February 2015.
- [4] Žarković M., Stojković Z. : "Model fuzzy ekspertskega sistema za procenu performansi elektroenergetskega sistema", 33. Savetovanje CIGRE Srbija, Ref. R C4-09, Zlatibor, 6 – 8. jun 2017.
- [5] Žarković M., Stojković Z., Marković M., Simonović A. : "Primena veštačke inteligencije za ocenjuvanje performansi energetskih transformatora", 33. Savetovanje CIGRE Srbija, Ref. R C4-10, Zlatibor, 6 – 8. jun 2017.
- [6] Apostolović S., Žarković M., Stojković Z. : "Analiza performansi energetskog transformatora u toku životnog veka", 33. Savetovanje CIGRE Srbija, Ref. R C4-11, Zlatibor, 6 – 8. jun 2017.
- [7] Chin-Teng Lin, C. S. George Lee: Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems, Prentice Hall, 1996.
- [8] I. Goodfellow, Y. Bengio, A. Courville: Deep Learning, MIT Press, 2016
- [9] M. Žarković, Monitoring and Diagnostics of Substation Based on Fuzzy Model of High Voltage Equipment Condition (Ph.D. dissertation), Dept., Power systems, Serbia, Belgrade Univ., Belgrade, Serbia, 2018.

ABSTRACT

The paper describes an innovative methodology for the formation of a maintenance priority plan of key power equipment in the technical systems of power plants. The innovative methodology uses large datasets through machine learning methods to advance maintenance plans according to the current Condition Based Maintenance (CBM) and to Risk Centered Asset Management (RCAM). The maintenance plan for 90 generators and 93 power transformers in the production units of Electric Power Industry of Serbia (EPS) has been considered in the paper. Big sets of generators' and transformers' monitoring data has been used. Artificial neural networks (ANN) from the domain of machine learning have been applied to the datasets. The developed methodology enables the automatic creation of risk maps for the maintenance priority plan of the power plants.

MAINTENANCE PRIORITY MAPS FOR ELECTRICAL EQUIPMENT BASED ON MACHINE LEARNING

Mileta Žarković, Zlatan Stojković, Milan Đorđević