

DOI: [10.46793/CIGRE37.B2.11](https://doi.org/10.46793/CIGRE37.B2.11)

B2.11

PRIMENA NEURALNIH MREŽA ZA UNAPREĐENJE ROBUSNOSTI NADZEMNIH VODOVA

A NEURAL NETWORK APPROACH FOR ENHANCED OVERHEAD LINE RESILIENCE

Aleksandar Terzić, Mileta Žarković, Boško Nikolić

Kratak Sadržaj: Globalna tranzicija ka proizvodnji energije sa nultom emisijom ugljenika zahteva fundamentalnu transformaciju elektroenergetskih mreža i primenu inovativnih strategija za povećanje njihove robusnosti. Nadzemni vodovi, kao kritična komponenta elektroenergetske infrastrukture, suočavaju se sa sve većim operativnim izazovima usled ekstremnih vremenskih uslova. Ovaj rad predstavlja novi pristup za unapređenje robusnosti, žilavosti nadzemnih vodova kroz integraciju povezanog mehaničko-meteorološkog modela sa sistemom za detekciju događaja baziranim na veštačkim neuralnim mrežama. Oslanjajući se na okvir CIGRE Paris 2024, sesija B2-10884 [1], koji dinamički simulira ponašanje nadzemnih vodova pod promenljivim vremenskim uslovima, ovaj rad spaja teorijsko modelovanje i operativne podatke iz realnog sistema. Predložena metodologija koristi prediktivne mogućnosti multifizičkog modela i neuralnih mreža za prepoznavanje kritičnih događaja u elektroenergetskom sistemu, kao što su galopiranje provodnika, prekomerna opterećenja usled nagomilavanja leda i uticaj nepovoljnih vremenskih uslova na performanse nadzemnih vodova. Metodologija uključuje prikupljanje podataka od operatora prenosnog sistema, obučavanje neuralnih mreža za prepoznavanje obrazaca, detekciju događaja u realnom sistemu i validaciju performansi kako bi se obezbedila tačnost predloženog rešenja. Očekuje se da ovaj pristup doprinese povećanoj robusnosti elektroenergetskog sistema, optimizovanom upravljanju infrastrukturom i donošenju odluka zasnovanih na podacima. Integracijom modelovanja nadzemnih vodova i veštačke inteligencije, ovaj rad predstavlja rešenje za očuvanje stabilnosti elektroenergetskih sistema (EES) usled ekstremnih vremenskih uslova.

Ključne reči: Održavanje, veštačke neuralne mreže, nadzemni vodovi, modelovanje ambijentalnih uslova.

Abstract: The global transition to carbon-neutral energy necessitates a fundamental transformation of power grids, requiring innovative strategies to enhance system resilience. Overhead transmission lines (OHLs), a critical component of power infrastructure, face increasing operational challenges due to extreme weather conditions. This paper presents a novel approach to improving OHL resilience by integrating a coupled mechanical-meteorological model with an artificial neural network (ANN)-based event detection system. Building upon the OHL Multiphysics Modelling framework (CIGRE Paris 2024, session B2-10884), which simulates OHL behavior under dynamic weather conditions, this research

* Aleksandar Terzić, EMS AD, aleksandar.terzic@ems.rs

** Mileta Žarković, Boško Nikolić, Univerzitet u Beogradu - Elektrotehnički fakultet, mileta@etf.rs; nbosko@etf.bg.ac.rs; nbosko@etf.bg.ac.rs

bridges the gap between theoretical modeling and real-world operational data. The proposed system leverages the predictive capabilities of multiphysics simulations and the learning capacity of ANNs to identify critical grid events, such as conductor galloping, excessive tensile loads due to ice accretion, and adverse weather impacts on OHL performance. The methodology includes data acquisition from transmission system operators (TSOs), ANN training for pattern recognition, real-time event detection, and performance validation to ensure accuracy and adaptability. The expected contributions of this research include enhanced grid resilience, optimized asset management, and data-driven decision-making for TSOs. By integrating advanced modeling with AI, this paper provides a solution for ensuring power grid stability in the era of extreme weather conditions.

Keywords: *Asset Management, Artificial Neural Networks, Overhead Transmission Lines (OHLs), Weather Modeling.*

1 UVOD

Dalekovodi predstavljaju osnovni element elektroenergetskog sistema. U prenosnoj elektroenergetskoj mreži, zbog velike dužine dalekovoda njegovi elementi su izloženi različitim vremenskim uslovima i različitim tipovima terena koji u kombinaciji značajno utiču na verovatnoću pojave kvara duž trase dalekovoda. Veliki broj kvarova koji se dešava, može se sa velikom sigurnošću pripisati vremenskim uslovima, a njihov potencijalni uticaj se kreće od prolaznog kvara bez oštećenja pa do trajne havarije koja bitno utiče na rad EES-a. Operator prenosnog EES vode evidenciju ovih događaja koja služi za kasniju analizu i planiranje preventivnih mera pa i novih investicija u mrežu. Pored oznake dalekovoda, evidentira se tip kvara, vreme nastanka kvara kao i rastojanje delovanja distantne relejne zaštite od postrojenja, što omogućava precizno definisanje mikrolokacije kvara. Za potrebe ovog rada korišćeni su ovi podaci za vremenski period od 2014. – 2024. gde su pored geografske prezentacije lokacije kvara, podaci korišćeni u kombinaciji sa meteorološkim parametrima za treniranje veštačke neuralne mreže sa ciljem klasifikacije tipova kvarova za slučaj kada je priroda kvara nepoznata. Motivacija za rad jeste kreiranje modela baziranog na veštačkoj inteligenciji koji će omogućiti detektovanje određenih anomalija i njihovo uvezivanje sa parametrima koji utiču na njihovu pojavu. Drugo poglavlje ovog rada bavi se analizom postojećih ulaznih podataka, treće poglavlje obrađuje predloženu arhitektura veštačke neuralne mreže i prezentuje dobijene rezultate, četvrto poglavlje obrađuje analizu dobijenih rezultata kao i predlaže dalje smerove razvoja prikazanog postupka.

2 ULAZNI PODACI

Podaci o lokaciji kvara evidentiraju se kao rastojanje u [km] koje se očitava sa sistema distantne relejne zaštite. U zavisnosti od dalekovoda, tipa zaštitne opreme, tipa kvara i konfiguracije mreže, može se desiti da uređaj detektuje samo stepen delovanja distantne zaštite (I, II, III stepen) ili da se rastojanje uopšte i ne očitava. Kako format u kome se podaci upisuju u izveštajima u dispečerskom centru Akcionarskog društva „Elektromreža Srbije“ - EMS AD nije pogodan za direktnu analizu, jer se veliki broj numeričkih podataka unose u formi teksta, za potrebe ovog rada neophodno je bilo prilagoditi ove podatke, a one događaje koji nemaju neophodne podatke (tačna lokacija delovanja distantne zaštite, datum i vreme delovanja i naziv dalekovoda) isključiti iz dalje analize. Inicijalni set podataka za definisan period obradio je ukupno 11606 događaja.

Da bi se ulazni podaci što bolje iskoristili u prvoj fazi obrade ulaznih podataka potrebno je korišćenjem tehnika prepoznavanja obrazaca unošenja teksta izvući informaciju o lokaciji kvara i uzroku kvara i formirati poseban tip podataka sa postojećim podacima. Ovo je postignuto delimičnom automatizacijom i to prepoznavanjem obrazaca unošenja tipa: „*D=xx.x km*” ili „*L=xx.x km*” ili „*lok. xx.x km*” i slično gde su vrednosti *xx.x* rastojanja u [km] od početne tačke dalekovoda (visokonaponsko potrojenje).

Tabela I - Kategorija kvarova

oznaka	Uzrok kvara	oznaka	Uzrok kvara
1	Naraslo ili palo drvo	11	Zaštitno uže
2	IL-preskok bez prekida	12	Životinje ili ptice
3	Grmljavina-atmosf.prenap.	13	Strujni most otklon
4	IL-preskok sa prekidom	14	Jak vetar
6	Požar	15	Stub lom ili pad
7	Fazni provodnik prekid	16	Magla
8	Jaka kisa	17	Rosa
9	Led	18	Strujni most-prekid
10	Sneg	100	Normalni pogon

Sličan postupak je primenjen i za podatke o uzroku kvara gde je radi pojednostavljenja nekoliko sličnih tipova kvarova grupisano zajedno imajući u vidu da se planirana arhitektura neuralne mreže naslanja i na meteorološke podatke koji imaju ograničenu mogućnost diferenciranja između sličnih meteoroloških pojava. Tako se mogu grupisati podaci kada je uzrok kvara: ledena kiša i led, kiša i rosa, jak vetar, palo drvo i slično. Tipovi kvarova koji su analizirani nalaze se u sledećoj tabeli:

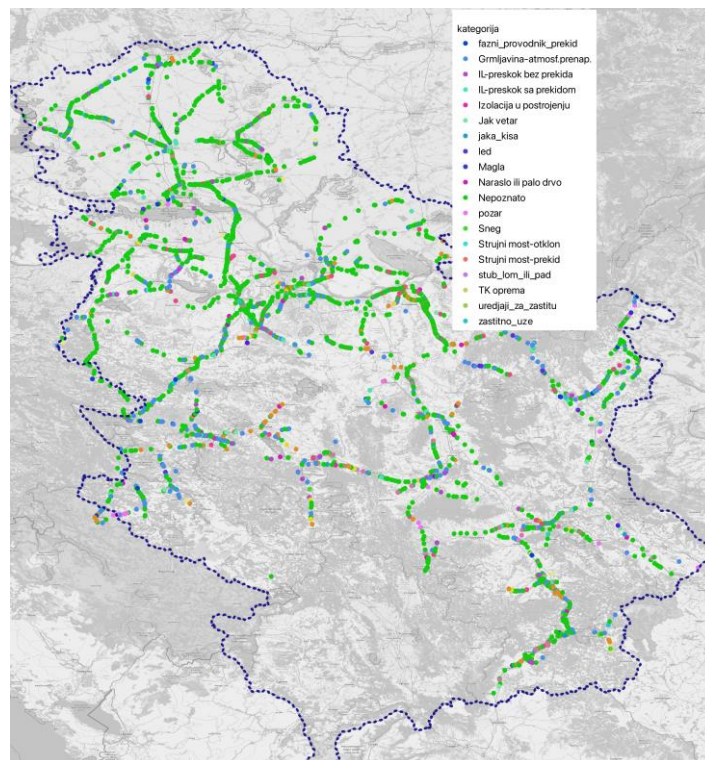
U drugoj fazi obrade ulaznih podataka svakoj lokaciji kvara su dodeljeni tehnički parametri dalekovoda i to: naponski nivo dalekovoda i oblik najbližeg stuba posmatranog dalekovoda. Na ovaj način u kasnijoj fazi, mogu se logički grupisati događaji na sličnim dalekovodima, što može da doprinese tačnosti celog modela predikcije. Baza podataka se može podeliti kako bi se moglo formirati više manjih modela sa elementima sličnih karakteristika. Ovaj proces se odvija automatski korišćenjem „*Spatial query*“ funkcionalnosti „python“ biblioteke *geopandas* [2]. Podaci o dalekovodnim stubovima su preuzeti iz baze podataka EMS AD.

U trećoj fazi obrade ulaznih podataka svakom događaju kvara dodeljeni su meteorološki parametri i podaci o kategoriji terena na mestu kvara. Meteorološki parametri preuzeti su sa servisa <https://cds.climate.copernicus.eu> [3] [4] gde su korišćene satne vrednosti podataka prostorne rezolucije od 10 km i to za sledeće parametre:

1. temperatura vazduha,
2. padavine,
3. vazdušni pritisak,
4. udarna brzina vetra i
5. brzina vetra.

Za svaku lokaciju preuzeti su podaci koji su prethodili trenutku nastanka kvara i to prethodnih 10 časova. Da bi se dodatno istakao trenutak normalnog pogona (kada nema kvara) – kvar je posmatran samo sa prethodnih 5 časova (trenutak kvara do 5 časova) dok je prvih 5 časova posmatrano kao normalan pogon. Ovakva pretpostavka je opravdana jer je u praksi pojava meteoroloških uslova za nastanak kvara kratkotrajne prirode. Korišćenje podataka o normalnim pogonskim uslovima pozitivno utiče na praktičnu primenu sistema jer se u praksi očekuje detekcija promene meteoroloških parametara ili druga okolnost koja će rezultirati pojavom kvara.

Kao dodatni ulazni podaci korišćeni su nadmorska visina na lokaciji kvara i kategorija terena. Procenjeno je da će ovi podaci pozitivno uticati na predikciju imajući u vidu da neke vrste kvarova zavise od ovih parametara. Za kategoriju terena korišćeni su podaci pribavljeni sa servera *ESA Climate Change Initiative – Land Cover project 2020 and EC C3S Land Cover* [5]. Ovaj skup podataka sastoji se od više od 40 kategorija terena, koje su za potrebe ovog rada grupisane u 5 kategorija u skladu sa opisom datom u standardu EN50341:2012 [6] koji je relevantan za ovu vrstu objekata. Nakon konačne obrade ulaznih podataka odabrano je ukupno 4916 događaja za koje su definisani svi neophodni podaci. Od ovih podataka vsta kvara je definisana za Geografski prikaz svih ovih kvarova za period od 2014. – 2024. prikazan je na sledećoj slici:



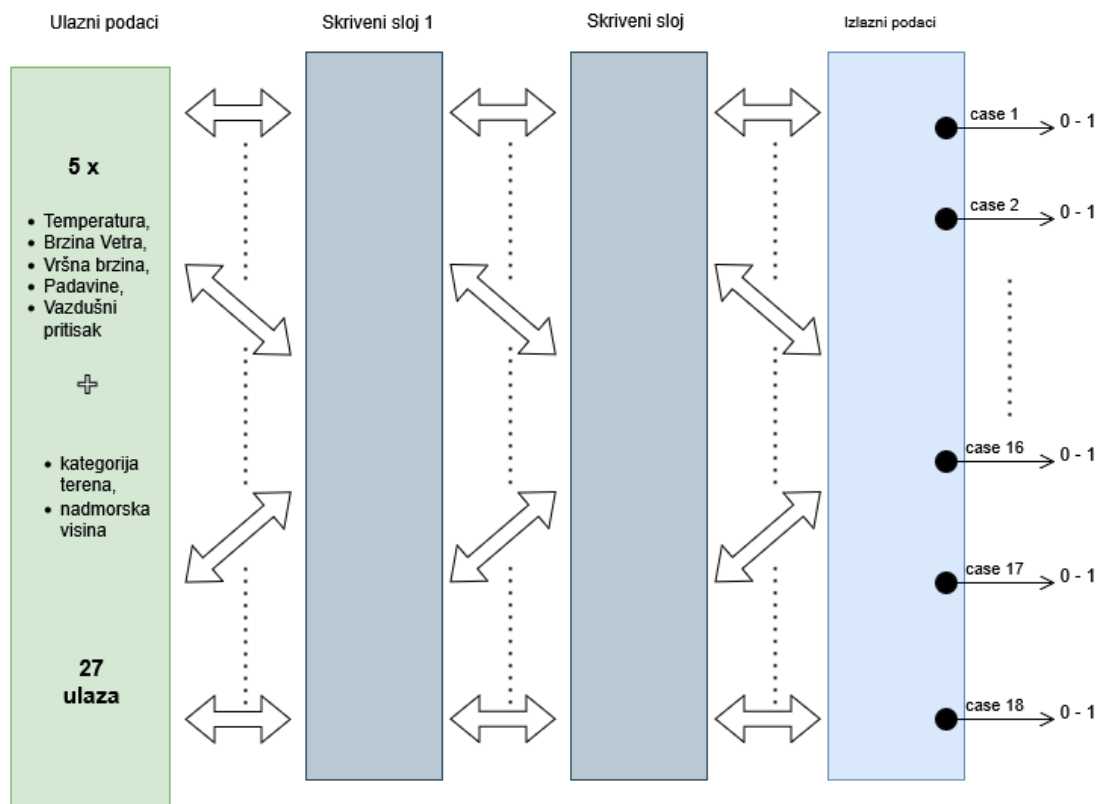
Slika 1 - Geografski prikaz kategorije kvarova

Na slici 1 prikazana je geografska raspodela događaja koji su analizirani generisano pomoću softvera QGIS [7]. Kao što je vidljivo sa slike, većina događaja je nepoznatog porekla – nije klasifikovana. Od 4916 detektovanih kvarova 980 se može smatrati jasno definisanim. Ovi podaci će se dalje koristiti za obučavanje (treniranje) veštačke neuralne mreže.

3 NEURALNA MREŽA

Veštačka neuralna mreža je osnova svih modernih sistema tzv. veštačke inteligencije. Za praktičnu primenu potreban je dovoljan broj ulaznih podataka i tačnih vrednosti izlaza da bi neuralna mreža mogla sa zadovoljavajućom tačnošću dati izlazne rezultate. Proces u kome se parametri neuralne mreže dovode do optimalnih vrednosti sa aspekta tačnosti naziva se učenje odnosno trening neuralne mreže. U zavisnosti od problema koji se analizira treba odabrati i odgovarajuću arhitekturu neuralne mreže. Arhitektura neuralne mreže ogleda se u slojevima (eng. „layers“) i njihovim međusobnim odnosima gde izlazni sloj predstavlja krajnji rezultat. Kako se problem odabira vrste kvara svodi na selekciju jednog iz grupe predefinisanih tipova kvara, problem definisanja tipa kvara na osnovu ulaznih parametara može se posmatrati kao klasifikacioni problem. U ovom slučaju neuralna mreža trebana osnovu vrednosti ulaznih podataka (meteorološki i tehnički podaci o dalekovodu) na izlazu formira verovatnoću određenog tipa kvara. Dakle, u ovom slučaju izlazni sloj ima ukupno izlaza koliko ima mogućih tipova kvarova, gde svaki izlaz ima vrednost u rasponu 0 – 1 što predstavlja verovatnoću pojave te vrste kvara i zbir svih izlaza uvek ima vrednost 1.

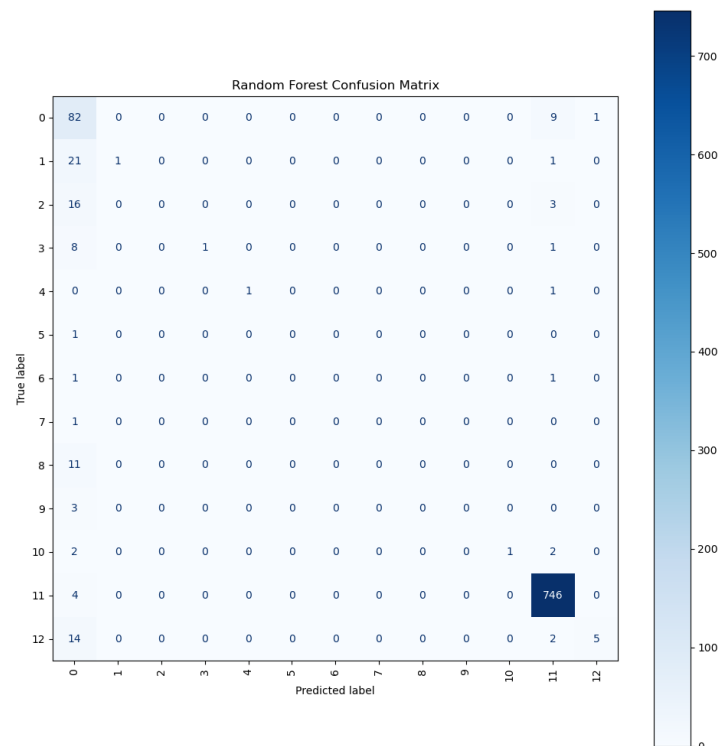
Sa druge strane, moguće je izlazni sloj prikazati samo jednim izlazom gde će vrednost izlaza predstavljati vrednost oznake kvara iz tabele 1 pa bi se u tom slučaju praktično problem sveo na regresioni problem. Pogodnim odabirom numeričke vrednosti oznake uzroka kvara može se postići bolja osetljivost celog modela. U konkretnom slučaju, slučaj sa normalnim pogonom dobio je vrednost 100, što za cilj ima isticanje ovog stanja mreže u odnosu na ostale tipove kvara. Na slici 2 prikazan je grafički prikaz opisanog modela sa klasifikacionim izlazom:



Slika 2 - Grafički prikaz neuralne mreže sa klasifikacionim izlazom

Veštačka neuralna mreža se jednostavno kreira pomoću softverskih paketa (matlab ili python biblioteke [8]), a postupak treniranja neuralne mreže odvija se na uzorku podataka sa tačnim

vrednostima ulaza i izlaza. U postupku treniranja, softver za određene ulazne meteorološke i geografske podatke na ulazu posmatra vrednost izlaza. Pošto je tačna vrednost izlaza poznata, u sledećoj iteraciji treniranja, menjaju se parametri aktivacije čvorova mreže kako bi se postigla što tačnija vrednost izlaza. Za treniranja neuralne mreže u konkretnom slučaju korišćen je set podataka sa 4696 tačno registrovanih događaja klasifikovanih u 18 kategorija kvarova. Na ovaj način postignuta je tačnost u predviđanju izlaznih podataka od 78%. U praksi to znači da je verovatnoća da će vrednost najveće verovatnoće izlaza koju daje izlazni sloj mreže biti tačna u 78% slučajeva. Da bi se dodatno analizirala struktura odlučivanja neuralne mreže na sledećoj slici prikazana je tzv. matrica odlučivanja („*confusion matrix*“):



Slika 3 - Matrica odlučivanja za klasifikacioni problem

Matrica prikazuje šablon odlučivanja neuralne mreže. Za ovu vrstu podataka odabran je „*random forest*“ algoritam treniranja neuralne mreže. Veliki broj grupa kvarova označenih sa „11“ (normalni pogon) mreža je uspešno prepoznala, dok postoje i druge vrste kvarova koje su pogrešno prepoznate. Obzirom da u setu ulaznih podataka postoji veliki broj događaja normalnog pogona, koji su naknadno dodati, ovo ponašanje mreže je očekivano, međutim za praktičnu primenu ovog sistema potreban je veći broj ulaznih podataka. Treba napomenuti da su za potrebe treniranja neuralne mreže neki od sličnih tipova kvara grupisani.

Analizirana je i druga vrsta arhitekture, gde je izlazni sloj prikazan sa samo jednim izlazom – regresioni model. U ovom slučaju do izražaja dolazi konkretna numerička vrednost dodeljena tipu kvara. Kod ovog modela, kao parametar koji definiše tačnost može se koristiti parametar *Mean Absolute Percentage Error* (MAPE) koji predstavlja standardni parametar za ovaj tip neuralne mreže i računa se prema formuli (1) :

$$MAPE = 100 \times \frac{1}{n} \sum_1^n \left| \frac{A_t - F_t}{A_t} \right| \quad (1)$$

primene dodatnih meteoroloških podataka. Očekuje se da dodatni ulazni paramteri mehaničkog modela doprinesu tačnosti modela veštačke inteligencije.

5 LITERATURA

- [1] A. Terzic, „OHL Multiphysics modelling B2-10884,“ CIGRE 2024, 2024.
- [2] Geopandas, „geopandas,“ geopandas, 08 04 2025. [Na mreži]. Available: <https://geopandas.org/en/stable/>. [Poslednji pristup 08 04 2025].
- [3] Copernicus Climate Change Service, „Climate Data Store,“ Copernicus, 08 April 2024. [Na mreži]. Available: <https://cds.climate.copernicus.eu#!/home>. [Poslednji pristup 08 April 2024].
- [4] ECMWF, „ECMWF reanalysis,“ ECMWF, 08 04 2024. [Na mreži]. Available: <https://www.ecmwf.int/en/forecasts/dataset/ecmwf-reanalysis-v5>. [Poslednji pristup 08 04 2024].
- [5] ESA, „ESA land cover,“ ESA, 08 04 2025. [Na mreži]. Available: <https://climate.esa.int/en/projects/land-cover/>. [Poslednji pristup 08 04 2025].
- [6] CENELEC, EN 50341-1:2012 - Overhead electrical lines exceeding AC 1 kV - Part 1: General requirements - Common specifications, CENELEC, 2012.
- [7] QGIS, „QGIS project,“ QGIS, 08 April 2024. [Na mreži]. Available: <https://qgis.org/en/site/>. [Poslednji pristup 08 April 2024].
- [8] scikit learn, „scikit learn nearest neighbors documentation,“ scikit learn developers, 08 April 2024. [Na mreži]. Available: <https://scikit-learn.org/stable/modules/neighbors.html>. [Poslednji pristup 08 April 2024].
- [9] K. V. M. Đurić, „Comparison of the equation of catenary state for mid-length spans and a mathematical model that is more accurate and intended for computer application,“ u CIGRE Yugoslavia 25th session, Herceg Novi, 2001.