



KRATKOROČNA PROGNOZA REŽIMA DISTRIBUTIVNE MREŽE SHORT TERM FORECASTING OF THE DISTRIBUTION NETWORK STATE

Nikola Jerković, Fakultet tehničkih nauka, Novi Sad

Oblast – ELEKTROTEHNIKA I RAČUNARSTVO

Kratak sadržaj – Rad treba da proveri tačnost rezultat algoritma teorije vektora podrške koji se koristi za proračun prognoze opterećenja izvoda distributivne mreže i pokaže da se tako dobijeni rezultati koriste za kalibraciju potrošnje koja pripada tom izvodu i pokrene proračun tokova snaga i indeksa performansi u cilju otkrivanja najkritičnijih elemenata u mreži za svaki prognozirani trenutak.

Ključne reči: proračun prognoze, mašinsko učenje, teorija vektora podrške.

Abstract – The work needs to verify the accuracy of the result of the support vector machine algorithm used to calculate the load forecast of the distribution network and show that the results thus obtained are used to calibrate the consumption of that statement and trigger the load flow and performance index calculation in order to detect the most critical elements in the network for each forecasted moment.

Ključne reči: load forecast, machine learning, support vector machine.

1. UVOD

Privredni razvoj modernih zemalja usko je povezan sa dostupnošću električne energije. Pored uglja, drveta, nafte, prirodnog gasa i drugih energetika koji su kroz istoriju bili dominantni u industriji, električna energija kao najpogodniji vid energije za prenos i transformaciju u druge oblike zasluženo zauzima sve veći procenat upotrebe u industriji. Pored industrijskih potrošača električne energije značajnu ulogu čine i domaćinstva čija je potrošnja iznosila 51% od ukupne potrošene energije u Republici Srbiji 2017. godine [1]. Za njenu kontinualnu, pouzdanu i kvalitetnu isporuku zadužena su distributivna preduzeća koja se svakodnevno susreću sa izazovima kao što su održavanje mreže, otklanjanje kvarova, upravljanje opterećenjem, kupovina i prodaja električne energije. U modernim distributivnim preduzećima sve više se koriste softverska rešenja koja za cilj imaju da olakšaju posao dispečerima u svakodnevnom radu i uz to povećaju prihode i smanje rashode distributivnih preduzeća.

Danas je prognoza potrošnje električne energije važan proces u elektroenergetskim preduzećima sa primenom u nekoliko sektora, kao što su sektor za planiranje, operativu, prodaje itd. Potrebe za kvalitetnom prognozom potrošnje električne energije vezane su za sledeće aktivnosti preduzeća [2]:

NAPOMENA:

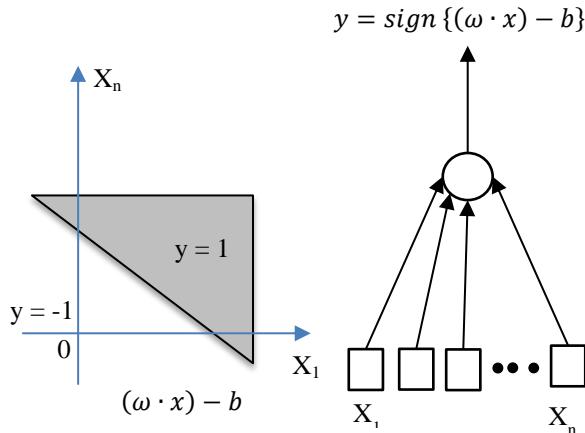
Ovaj rad proistekao je iz master rada čiji je mentor bio dr Goran Švenda, red. prof.

1. Kupovina energije. Prognoza potrošnje električne energije je osnova za proces kupovine energije, bez obzira da li taj proces obavlja samo preduzeće ili taj proces prepusta nekoj spoljnoj, nezavisnoj organizaciji. Preduzeće može da obavlja bilateralnu kupovinu sa obavezom na duži period od npr. 10 godina, može da rezerviše i kupuje na intervalima od jednog meseca do 3 godine unapred ili da prilagođava i kupovinu obavlja na tržištu za dan unapred.
2. Planiranje prenosa i distribucije. Preduzeća imaju potrebu za održavanjem i blagovremenim unapređenjem sistema kako bi se zadovoljile potrebe rasta potrošnje, obezbedilo stabilno snabdevanje i povećala pouzdanost sistema. Preduzeća moraju da planiraju i kupovinu zemljišta u budućnosti kako bi se stvorila mogućnost za izgradnju novih elektroenergetskih objekata. Planiranje prenosa i distribucije se u velikoj meri oslanja na prostornu prognozu potrošnje koja treba da pruži odgovore na pitanja koliko i gde će porasti potražnja za električnom energijom.
3. Održavanje i operativa. Na dnevnom nivou, dijagrami opterećenja dobijeni prognozom potrošnje, omogućuju dispečeru da donosi pravovremene odluke o manipulaciji i planira održavanje.
4. Upravljanje opterećenjem (eng. Demand side management – DSM). Iako većina aktivnosti DSM-a spada u dnevne aktivnosti, poželjno je odvojiti DSM kao poseban proces zbog njegovog značaja kod "smart grid" koncepta. Prognoza potrošnje električne energije pomaze donošenju pravih odluka kad su u pitanju regulacija opterećenja i smanjivanje napona. Takođe, pomaze da preduzeća sprovedu dugoročno planiranje bazirano na dobijenim karakteristikama opterećenja krajnjih korisnika tokom procesa prognoze [3].

2. OSNOVNI POJMOVI

Teorija vektora podrške (*Support Vector Machine – SVM*) je inicijalno razvijan sa ciljem da se unaprede neuronske mreže. Ona je bazirana na principu strukturnog smanjenja rizika (*Structural Risk Minimisation – SRM*), koji je u velikoj meri bolji od empirijskog smanjenja rizika (*Empirical Risk Minimisation – ERM*), koji se koristi kod neuronskih mreža. SRM minimizuje gornju granicu rizika, dok ERM minimizuje donju granicu rizika i grešku u trening podacima [4]. Osnovni princip rada ove metode je da se obučavanje vrši na osnovu datih podataka u vidu obučavajućeg skupa, koji se sastoji od skupa ulaznih i skupa izlaznih podataka. Zatim se, ovako obučena struktura, koristi za rešavanje problema klasifikacije i regresije. Ovu metodu je, sa saradnicima, početkom

devedesetih godina prošlog veka razvio Vapnik (Vladimir Naumovich Vapnik) [5]. Teorija mašinskog učenja svoj razvoj započinje pojmom koncepta perceptron, koji je predložio Rozenblat (Frank Rosenblatt) [6]. Njegov model rešava problem prepoznavanja, odnosno razdvajanja podataka u dve kategorije. Predloženi perceptron je za osnovu uzimao već razvijeni model veštačkog neurona. Razbijeni neuron je imao n ulaza i jedan izlaz iz skupa $\{-1, 1\}$, koji kao takav deli prostor ulaznih podataka na dva dela, Slika 1.



Slika 1. Perceptron

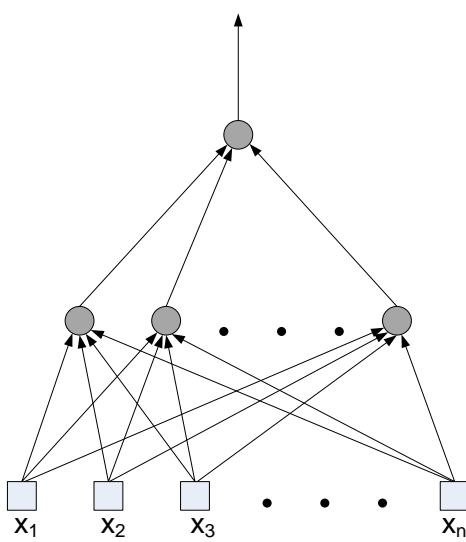
Funkcija zavisnosti izlaza od ulaza data je sa [4]:

$$y = \text{sign}\{(\omega \cdot x) - b\}, \quad (1)$$

gde je x vektor ulaznih podataka, b prag osetljivosti. Hiperravan koja razdvaja dva skupa podataka je sa:

$$(\omega \cdot x) - b = 0. \quad (2)$$

Model koji je napravio Rozenblat se sastojao od više neurona, raspoređenih po nivoima, tako da su izlazi jednog nivoa bili ulazi u sledeći nivo, Slika 2, dok se u poslednjem nivou nalazi samo jedan neuron čiji izlaz predstavlja izlaz cele mreže.



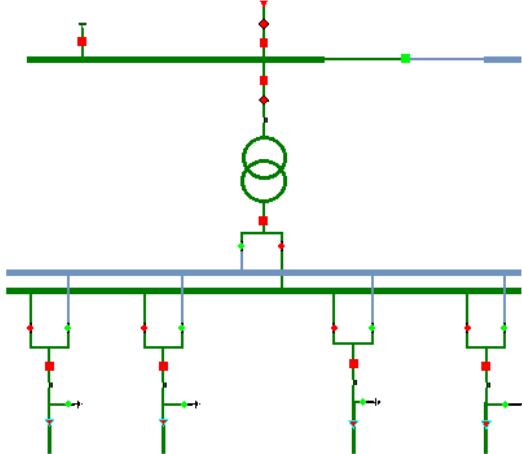
Slika 2. Model sa više neurona raspoređenih po nivoima

Gledano geometrijski, perceptron deli prostor x na dva dela, granicom razdvajanja koja može, ali i ne mora biti linearna. Podela se postiže obučavanjem mreže, što se u

stvari svodi na odabir pravih koeficijenata za neurone u mreži. Kako se javilo simultano menjanje koeficijenta neurona u perceptronu, predloženo je da se fiksiraju koeficijenti svih neurona osim poslednjeg, gde je cilj bio da se tokom procesa obuke pronađu koeficijenti poslednjeg neurona [6]. Ovim se prostor ulaznih podataka x transformiše u novi prostor z , u kojem se, na osnovu podatka iz obučavajućeg, konstruiše odgovarajuća hiperravan. Vektor ω se inicijalizuje na 0, a zatim ostaje isti ili se menja po određenom pravilu, u zavisnosti od toga da li je ω element obučavajućeg skupa dobro klasifikovan ili ne.

3. MATEMATIČKI MODEL

Za potrebe proračuna koristi se model mreže koji se sastoji od četiri izvoda, njihovog napojnog transformatora 110 / 20 kV snage 20 MVA i korena koji predstavlja kraj prenosne mreže, čiji je izgled dat na slici 3.



Slika 3. Test mreža

Pre početka proračuna potrebno je izabrati elemente mreže za koje će biti izvršen proračun, oni mogu biti: izvodi, transformatori, transformatorske stanice kao i celokupna mreža. Pored izbora elemenata potrebno je izabrati dužinu vremenskog intervala za proračun koji može biti između jednog i 24 sata, sa korakom od 15, 30 ili 60 minuta. Proračun počinje tako što se za sve izabrane elemente određe njihovi izvodi i za svaki pokrenuti proračun vektora podrške, za izabrani vremenski interval u budućnosti, koji je objasnjen u prethodnom poglavljiju. Ovaj proračun se koristi se za prognozu aktivne snage. Parametri koji se uzimaju kao ulazni za algoritam teorije vektora podrške su:

- Istoriski podaci o potrošnji za tri godine unazad.
- Istoriski podaci o vremenu za tri godine unazad i to za temperaturu, brzinu veta i oblačnost.
- Tipove dana za tri godine unazad i dva dana unapred – razlikuje se: radni dani, dani vikenda i praznični dani.
- Istoriski podaci o danim obeleženim kao neželjeni za tri godine unazad. Ovde se podrazumevaju dani koje se iz nekog razloga žele isključiti iz skupa za trening, npr. operater je svestan da tog dana merenja protoka nije bila validna za trening iz nekog razloga.

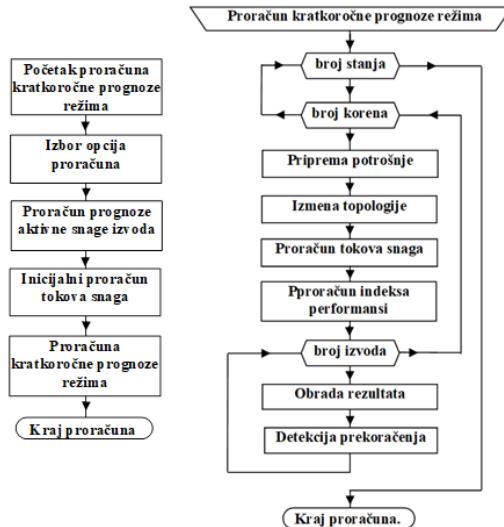
Rezultat ovoga proračuna sačinjavaju nizovi satnih vrednosti aktivne snage potrošnje po izvodu koji su spremni za dalju obradu.

Nakon završenog proračuna prognoze, rezultati aktivne snage izvoda se kalibracijom raspoređuju na njegove potrošače vodeći računa o tome koliki je izabrani korak. Obzirom da su rezultati prognoze aktivne snage izvoda uvek nizovi sa satnim vrednostima, kalibrisane snage potrošača za korake od 15 ili 30 minuta, biće dobijeni linearnom interpolacijom dva susedna satna rezultata. Tako da će u modelu uz svakog potrošača biti smešteni i niz vrednosti koje će opisivati promenu njegove potrošnje tokom izvršavanja proračuna.

Posle završene kalibracije pokreće se inicijalni proračun tokova snaga za svaki koren koji predstavlja ulaz u distributivnu mrežu, gde se za sve potrošače postavlja prva vrednost iz niza koji opisuje ponašanje potrošnje, u cilju provere konvergencije proračuna. Koreni za koje tokovi snaga ne konvergiraju neće se dalje razmatrati. Blok prikazan na Slici 4 (levo), predstavlja prethodno opisane etape pripreme za proračun kratkoročne prognoze režima.

Sam proračun kratkoročne prognoze režima počinje nakon završene pripreme i sastoji se od tri ugnježdene petlje koje omogućavaju da se prođe kroz sve vremenske intervale, a unutar svakog kroz sve korene za koje se izvršava proračun tokova snaga i indeksa performansi. Poslednja petlja prolazi kroz sve elemente za čiji je koren završen proračun tokova snaga i indeksa performansi i filtrira željene rezultate koji će biti izlaz iz proračuna.

Blok koji je zadužen za pripremu potrošnje treba za svaki potrošač u mreži postavi potrošnju aktivne snage na vrednost iz prethodno iskalibriranog niza na onu koja odgovara vremenskom trenutku za koji se izvršava proračun. Što je se ponavlja u svakoj iteraciji kroz stanja. U koliko u vremenskom trenutku za koji se vrši proračun prognoze postoji planirana prekidačka manipulacija njen efekat će se uvažiti promenom topologije mreže. Nakon pripremljene potrošnje i izmene topologije pokreće se proračun tokova snaga za korene, čime se dobija režim mreže za datu potrošnju i topologiju.



Slika 4. Algoritam proračuna kratkoročne prognoze režima mreže

Proračun indeksa performansi se oslanja na proračun tokova snaga i pokreće se nakon njega. Dobijeni rezultati daju detaljnije podatke vezane za elemente mreže kao što su: struja, napon, aktivna snaga, reaktivna snaga u relativnim i apsolutnim jedinicama. Pored toga za sve

elemente detektuju se prekoračenja limita napona, struje, aktivne snage, disbalansa opterećenja i obrnutog toka snage. Kada je izvršen proračun indeksa performansi, popunjavaju se podaci potrošnje, injektirane i generisane aktivne i reaktivne snage. Ukoliko postoje problemi sa prekoračenjima limita za bilo koji element u mreži, ta prekoračenja se alarmiraju za trenutak u kome će se desiti. Blok dijagrama algoritma prikazan je na slici 4.

4. VERIFIKACIJA REZULTATA

Verifikacija proračuna kratkoročne prognoze režima mreže je izvršena na četiri izvoda i za svaki je proračun pokrenut za četiri dana od kojih je svaki iz jedne godišnje sezone. Pokretanje proračuna je rađeno tako što je lokalno vreme na mašini vraćano u nazad na razmatrane karakteristične dane. Na taj način bilo je jednostavno uporediti prognozirane vrednosti i vrednosti iz istorije, odnosno utvrditi koliko je algoritam za prognoziranje tačan. Tačnost samog algoritma analizirana je na osnovu apsolutne srednje procentualne greške (*Mean Absolute Percentage Error – MAPE*) [7]:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|, \quad (4.1)$$

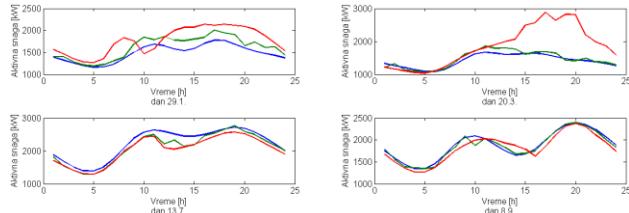
gde je sa n naznačen broj sati za koje se MAPE računa. Sa A_t su naznačene stvarne vrednosti, podaci iz istorijske baze, a sa F_t na osnovu algoritma izračunate vrednosti prognoze. Razlog za korišćenje ove tehnike je vrlo jednostavan, ljudima je lako da razumeju procente, čak i ako ne razumeju u potpunosti materiju koju procenti izražavaju, odnosno jednostavno mogu da ustanove kolika je greška proračuna. Što je veće vrednost za MAPE, to je veća greška proračuna. Tabele 1 predstavlja rezultate koji za ulaz koriste neposrednu istoriju dok u Tabeli 2 ulaz u proračun je dobijen algoritmom pretraživanja sličnih dana. Vrednosti prikazane u tabelama predstavljaju srednje apsolutne procentualne greške i maksimalne procentualne greške za četiri izvoda jedne transformatorske stanice za četiri karakteristična dana od kojih je svaki iz jedne godišnje sezone, dok su na slikama 5, 6, 7 i 8 grafički prikazani rezultati dva prethodno navedena proračuna. Plava linija predstavlja istorijske podatke sa kojima se vrši poređenje rezultata, crvenom linijom su predstavljeni rezultati proračuna dobijeni sa skorijom istorijom, a zelenom podaci dobijeni algoritmom sličnih dana.

Tabela 1. Vrednosti MAPE i maksimalne greške za period od 24 sata, rezultati dobijeni na osnovu bliske istorije

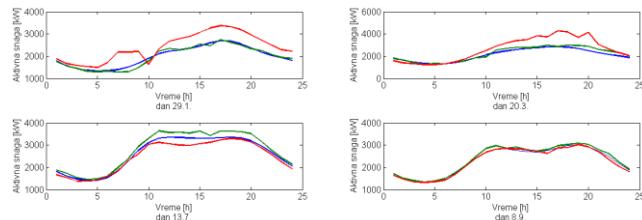
izvod	29.1.		20.3.		13.7.		8.9.	
	MAPE ₂₄	najveća greška [%]						
1	2,27	10,32	5,17	11,77	5,53	14,66	2,28	10,32
2	3,72	13,67	6,51	15,56	6,28	9,86	3,01	5,79
3	8,15	14,92	8,51	15,61	8,97	14,64	7,35	14,42
4	7,96	14,64	7,19	13,48	3,49	7,87	4,78	7,85

Tabela 2. Vrednosti MAPE i maksimalne greške za period od 24 sata, rezultati dobijeni algoritmom sličnih dana

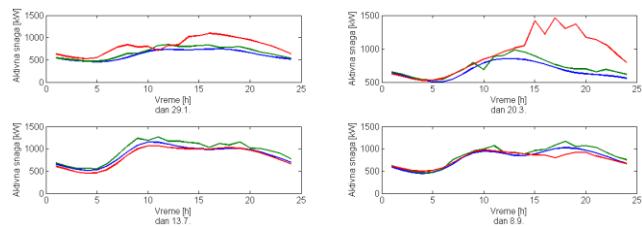
izvod	29.1.		20.3.		13.7.		8.9.	
	MAPE ₂₄	najveća greška [%]						
1	20,25	36,72	31,50	59,42	8,01	19,06	5,96	14,06
2	22,28	56,19	23,60	63,99	4,40	10,25	1,87	6,79
3	31,40	59,41	38,40	112,95	5,74	12,76	6,28	20,70
4	41,51	104,20	60,02	174,62	6,99	8,79	9,07	44,05



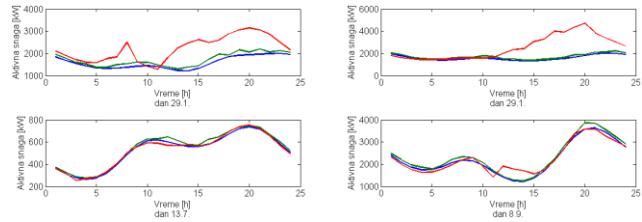
Slika 5. Rezultati za izvod 1 za četiri karakteristična dana



Slika 6. Rezultati za izvod 2 za četiri karakteristična dana



Slika 7. Rezultati za izvod 3 za četiri karakteristična dana



Slika 8. Rezultati za izvod 4 za četiri karakteristična dana

Analizom prikazanih rezultata može se uočiti da se primenom algoritma sličnih dana dobijaju znatno bolji rezultati. Primenom tog algoritma prevaziđen je problem pojave pikova prognoziranih veličina sa jako velikim greškama. Oblik dijagrama koji su dobijeni primenom algoritma sličnih dana ne odstupa od oblika istorijskih dijagrama (kao što je slučaj kod rezultata dobijenih algoritmom koji radi sa bliskom istorijom). Konačno, može se uočiti da je primenom algoritma sličnih dana značajno smanjena vrednost MAPE (za neke trenutke sa vrednosti šezdeset vrednosti ispod osam procenta), isto tako smanjena je i maksimalna greška (sa preko sto na ispod šesnaest procenata).

5. ZAKLJUČAK

Prednost korišćenja proračuna tokova snaga i indeksa performansi u kombinaciji sa SVM algoritmom je u tome što omogućava prognozu režima i obezbeđuje sve ključne podatke, kao što su: struja, napon, aktivna snaga, gubici aktivne snage itd. za sve elemente distributivne mreže. Pored svega prethodno navedenog, u okviru proračuna indeksa performansi, postoji i detekcija kritičnih elemenata sa njihovim prekoračenjima limita koji su dati u apsolutnim i relativnim vrednostima. Proračuni tokova snaga i indeksa performansi za svaki prognozirani vremenski trenutak otvaraju razne mogućnosti vezane za analizu, poboljšanje

performansi i angažovanja distribuiranih elektroenergetskih izvora mreže. Prednost ovog proračuna je ta što se uvažavaju i izmene topologije mreže određene planiranim prekidačkim manipulacijama i time se dodatno poveća uvid u ponašanje mreže. Proračun može da se proširi sa algoritmom koji određuje da li će određeni distribuirani elektroenergetski resurs moći da radi sa unapred definisanim krivom potrošnje, odnosno proizvodnje i kao rezultat vraćati krivu po kojoj treba da radi kako ne bi dolazio do problema u mreži. Potreba za poboljšanjem proračuna sva-kako postoji, iz razloga što postoje odstupanja u oblicima krivih koje se porede.

Neki od pravaca daljeg unapređenja algoritma su:

- Realizovati proračun u kratkim vremenskim intervalima, čime bi se češće osvežavali rezultati, odnosno smanjila greška procene.
- Omogućiti da se za različite sezone i oblike krive potrošnje primenjuju različiti algoritmi, npr. različite varijante SVM-a i neuronske mreže (za različite konfiguracije mreže, broja neurona, dubine mreže i metoda za obuku).
- Kao ulazni parametar proračuna prognoze koristiti i topologiju mreže, za koju je ostvarena potrošnja.
- Omogućiti da se prognoza radi istovremeno za više od jedne tačke na izvodu.

6. LITERATURA

- [1] Energetski bilans Republike Srbije za 2017. god.
- [2] T.Hong: *Short Term Electric Load Forecasting*, North Carolina State University, 2010.
- [3] M.M.Božić: *Kratkoročna prognoza potrošnje električne energije zasnovana na metodama veštacke inteligencije*, Univerzitet u Beogradu, Elektronski fakultet, Niš, 2014.
- [4] N.Turker, F.Gunes: A competitive approach to neural device modeling: Support vector machines, *Artificial Neural Networks – ICANN 2006. ICANN 2006. Lecture Notes in Computer Science*, Vol. 4132. Springer, Berlin, Heidelberg
- [5] B.E.Boser, I.Guyon, V.N.Vapnik: A training algorithm for optimal margin classifiers; *In Computational Learning Theory*, pp. 144-152, Pittsburgh, Pennsylvania, USA, July 27-29, 1992.
- [6] F.Reossenblat: The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, *Psychological Review*, Vol. 65, No.6, pp. 386-408, 1958.
- [7] S.Kim, H.Kim: A new metric of absolute percentage error for intermittent demand forecasts, *International Journal of Forecasting*, Vol. 32, No. 3, pp. 669-679, 2016.

Kratka biografija:



Nikola Jerković rođen je 26.10.1992. u Somboru. Srednju tehničku školu u Somboru završava 2011. iste godine upisuje Fakultet tehničkih nauka na kojem stiče zvanje diplomirani inženjer elektrotehnike i računarstva sa diplomskim radom na temu „Realizacija aplikacije na personalnom računaru za komunikaciju sa mikrokontrolerom“, godine 2016. Master rad brani u julu 2019. Živi i radi u Novom Sadu.