

Terezija Matijašević
Fakultet elektrotehnike i računarstva
terezija.matijasevic@fer.hr

Tomislav Capuder
Fakultet elektrotehnike i računarstva
tomislav.capuder@fer.hr

Tomislav Antić
Fakultet elektrotehnike i računarstva
tomislav.antic@fer.hr

OD PAMETNIH BROJILA DO BUDUĆIH GUBITAKA – PRISTUP STROJNOG UČENJA

SAŽETAK

U najvećem broju slučajeva, instalirana napredna brojila koriste se isključivo za prikupljanje i pohranu agregiranih podataka o potrošnji krajnjih korisnika s ciljem naplate potrošnje. Iako napredna brojila u distribucijskoj mreži prikupljaju i procesne podatke koji uključuju naponska mjerenja po fazama, dodatne mogućnosti nisu u potpunosti iskorištene, čime su otežane analize, kao što je predviđanje potrošnje i estimacija stanja mreže.

Zbog kompleksnih značajki prikupljenih vremenskih podataka, tradicionalne metode i korišteni modeli više nisu pogodni za proračune te je potrebna implementacija kompleksnijih algoritama, često baziranih na strojnom učenju. U ovom radu prikazani su algoritmi koji iz dostupnih podataka o faznim naponskim mjerenjima i agregiranoj potrošnji krajnjih korisnika određuju ispravnu faznu pripadnost krajnjih korisnika i njihovu faznu potrošnju. Nakon što je određena fazna potrošnja, generirana su predviđanja fazne potrošnje i faznih gubitaka u promatranoj niskonaponskoj mreži. Ovakve analize, osim što su pogodne za određivanje dodatnih značajki iz dostupnih podataka, služe kao temelj za detekciju anomalija te tehničkih i netehničkih gubitaka u distribucijskim mrežama.

Ključne riječi: distribucijska mreža, napredna brojila, strojno učenje, osmotrivost, detekcija faza, predviđanje potrošnje

FROM SMART METERS TO FUTURE NETWORK LOSSES – MACHINE LEARNING APPROACH

SUMMARY

In most of the cases, currently installed smart meters are being used only to collect and store data on aggregated end-user consumption for billing purposes. Although smart meters in the distribution network also collect processing data that include phase voltage measurements, additional possibilities are not completely utilized, which makes analyzes such as consumption forecasting and distribution network state estimation even more difficult to carry out.

Due to the complex features of the collected time series data, the traditional methods and applied models are no longer suitable for network analyses, and the implementation of more complex algorithms, often based on machine learning, is required. This paper presents algorithms that determine the accurate

phase connectivity of end-users and calculate their phase consumption distributed by phases from the collected phase voltage measurements and aggregated end-user consumption. After the phase consumption is determined, consumption and losses forecasting in the observed low-voltage network is performed. Such analyses, in addition to being suitable for determining additional features from the available data, serve as a basis for detecting anomalies and technical and non-technical losses in distribution networks.

Key words: distribution network, smart meters, machine learning, observability, phase identification, consumption forecasting

1. UVOD

Klimatske promjene koje se javljaju posljednjih godina utječu na porast potreba za integracijom obnovljivih izvora energije i drugih niskougličnih tehnologija u elektroenergetski sustav, a posebice na distribucijsku razinu. Tranziciji iz konvencionalnih sustava prema 'zelenom', ugljično-neutralnom sustavu doprinosi i smanjenje cijena tehnologija te povećanje cijena energenata. Uz veću dostupnost niskougličnih tehnologija, investiranje u fotonaponske elektrane, električna vozila i toplinske pumpe postaje profitabilnije za krajnje korisnike, a integracija novih entiteta praćena je instalacijom sve većeg broja naprednih brojila i pripadajuće komunikacijske infrastrukture.

Unatoč brojnim pozitivnim tehno-ekonomskim prednostima, integracija niskougličnih tehnologija je u najvećem broju slučajeva nekoordinirana što uzrokuje tehničke poteškoće u planiranju i vođenju distribucijske mreže, što posljedično može dovesti do zagušenja u distribucijskoj mreži te pojave harmonijskih izobličenja, narušavanja stabilnosti te brojnih drugih, neželjenih događaja. Iz tog razloga od operatora sustava se očekuje planiranje i vođenje sustava koje može pravovremeno odgovoriti na izazove koji se mogu javiti u distribucijskim mrežama, gdje veliku ulogu u osiguravanju takvog pogona u stvarnom vremenu imaju velike količine dostupnih podataka koje se prikupljaju s naprednih brojila.

U Republici Hrvatskoj instalirano je svega 16% naprednih brojila što bitno smanjuje osmotrivost distribucijskih mreža, ali i otežava daljnje analize i proračune [1]. Napredna brojila se najčešće koriste za prikupljanje informacija o kumulativnoj potrošnji krajnjih korisnika u svrhu naplate, dok se potencijal prikupljanja ostalih mjerenja ne iskorištava. Takav manjak podataka dodatno otežava analize u već kompleksnim distribucijskim mrežama, poput proračuna faznih gubitaka te ostalih sličnih proračuna potrebnih za uravnoteženje i nesmetan rad distribucijskih sustava. Kao odgovor na te probleme javljaju se metode strojnog učenja, koje su za razliku od tradicionalnih matematičkih algoritama, pogodne za rad nad većim količinama podataka bez upotrebe kompleksnih i vremenski zahtjevnih modela.

Kako bi se postiglo predviđanje opterećenja po fazama distribucijske mreže, a time i estimacija budućih faznih gubitaka te aktivacija krajnjih korisnika s ciljem pružanja usluga fleksibilnosti, u ovom radu kreirani su modeli temeljeni na algoritmima strojnog učenja kako bi iz dostupnih mjernih podataka prikupljenih sa brojila odredili raspodjelu opterećenja svakog korisnika po fazama, a potom iz povijesnih podataka predvidjeli buduća fazna opterećenja sustava i posljedično gubitke u distribucijskom sustavu. Budući da trenutno instalirana brojila u Republici Hrvatskoj na promatranoj pilot lokaciji prikupljaju naponska mjerenja po fazama za svako obračunsko mjerno mjesto, u prvom koraku kreiran je algoritam koji prikupljena mjerenja grupira te određuje faznu pripadnost svakog krajnjeg korisnika. Iz informacija o faznoj pripadnosti i agregiranoj potrošnji, moguće je odrediti raspodijeljenu potrošnju po fazama za svakog korisnika. Koristeći raspodijeljenu potrošnju po fazama moguće je provoditi proračune poput predviđanja opterećenja i gubitaka po fazama distribucijske mreže. Predloženi model testiran je na sintetičkoj i različitim stvarnim distribucijskim mrežama, a ovakav kombinirani model, osim što operatorima sustava može dati uvid u buduće gubitke sustava, također omogućava buduće analize poput detekcije anomalija i identifikacije tehničkih i ne-tehničkih gubitaka.

2. PREDLOŽENA METODOLOGIJA

Trenutno instalirana brojila služe za prikupljanje obračunskih podataka u svrhu naplate potrošnje krajnjih korisnika, dok je procesna osmotrivost distribucijskih mreža vrlo ograničena. Tako se naprednim

brojilima prikupljaju samo informacije o agregiranoj potrošnji, a na ponekim mjestima i mjerenja napona, čime su smanjene mogućnosti analiza i proračuna potrebnih za utvrđivanje gubitaka distribucijskih sustava. Stoga se metodologija predstavljena u ovom radu fokusira na određivanje i predviđanje fazne potrošnje i gubitaka djelatne snage u distribucijskim mrežama iz trenutno dostupnih podataka. Taj proces podijeljen je u tri dijela: iz dostupnih mjerenja napona po čvorištima promatrane mreže određena je fazna pripadnost krajnjih korisnika. Takva pripadnost potom služi za raspodjelu agregirane potrošnje svakog korisnika po fazama mreže iz čega se zatim može odrediti buduća potrošnja i posljedično fazni gubici u distribucijskim mrežama.

2.1. Algoritam za detekciju faza

Razvijeni model za detekciju faza temelji se na činjenici da postoji korelacija između iznosa napona krajnjih korisnika i napona mjerenih na NN sabirnici transformatorske stanice. Zbog kompleksnosti ovog problema, predloženi model za detekciju fazne pripadnosti temelji se na algoritmima strojnog učenja, prvenstveno zbog njihove mogućnosti rada sa većim skupovima podataka bez vremenske zahtjevnosti. Kako bi se pronašli uzorci u dostupnim mjerenjima te iz njih odredila pripadnost, potrebno je primijeniti algoritam temeljen na nenadziranom strojnom učenju, odnosno algoritme pogodne za grupiranje podataka. Njihov glavni cilj je grupiranje objekata sa sličnim značajkama u jedinstvenu grupu (odnosno klaster), dok se objekti sa različitim značajkama klasificiraju u druge, različite grupe.

Mnogo radova bavi se problemom identifikacije fazne pripadnosti u distribucijskim mrežama, a najčešće korišteni algoritmi temelje se na K-Means metodi, koja nastoji podijeliti podatke u K broj klastera minimizirajući razliku između podataka u pojedinoj grupi. Tako su autori u [2] primijenili K-Means algoritam zajedno s analizom glavnih komponenti (eng. *Principal Component Analysis*, PCA) kako bi iz naponskih mjerenja odredili faznu pripadnost jednofaznih krajnjih korisnika u niskonaponskoj mreži. Sličan pristup razvijen je i u [3] gdje je fazna pripadnost određena iz analize mjerenja potrošnje krajnjih korisnika. Nažalost, glavni nedostatak ove metode je nemogućnost postavljanja početnih centroida te potreba za ručnim odabirom broja klastera. Osim toga, prethodno spomenuti i slični radovi ([4]-[5]) nisu se bavili problemom pojave trofaznih i jednofaznih korisnika u niskonaponskim mrežama. Zbog tih problema, u ovom radu prikazana je modificirana K-Means metodologija, koja je pogodna za analizu u distribucijskim mrežama s trofazno i jednofazno priključenim korisnicima.

Ulazi:
M_i : mjerenja napona sa transformatorske stanice za fazu i
V_j : naponska mjerenja za j krajnjeg korisnika
Izazi:
C_k : klasteri sa pridruženim krajnjim korisnicima
Parametri:
$k = 1, 2, 3$; indeksi za klaster
$i = 1, 2, 3$; indeksi za mjerenja prikupljena sa transformatorske stanice
$j = 1, 2, \dots, N$; indeksi za krajnje korisnike, gdje N označava ukupan broj korisnika u mreži
c_k : centroid klastera k
Korak 0) Obrada podataka
Korak 1) Inicijalizacija centroida, $c_k = M_i$
Korak 2) Izračun udaljenosti, $D_{jk} = f(x_j, c_k)$
Korak 3) Minimalna udaljenost, $\min(D_{jk})$
Korak 4) Promjena centroida

Slika 1: Metodologija algoritma za detekciju faza

S obzirom na pogreške u mjerenjima naprednih brojala, potrebno je prije same analize ukloniti neočekivane vrijednosti, a one koje nedostaju interpolirati. Kako bi se smanjio utjecaj ulaznih vrijednosti na rezultate algoritma, prikupljena mjerenja su normalizirana tako da je srednja vrijednost cijelog promatranog seta jednaka nuli, a standardna devijacija iznosi jedan. Nakon prvotne obrade, podaci su prikladni za daljnje analize. Budući da je u samom centru algoritma za detekciju faza ideja da su naponska mjerenja krajnjih korisnika povezana sa mjerenjima napona na pripadajućoj transformatorskoj stanici, prvi korak predloženog

algoritma je postavljanje mjerenja prikupljenih sa transformatorske stanice kao početnih centroida K-Means algoritma, a potom se određuje pripadnost svakog korisnika (M_i) prema svakom od centroida. Takva korelacija može se odrediti pomoću Euklidske udaljenosti:

$$udaljenost_E = \sqrt{\sum_{i=1}^m (V_j - M_i)^2} \quad (1)$$

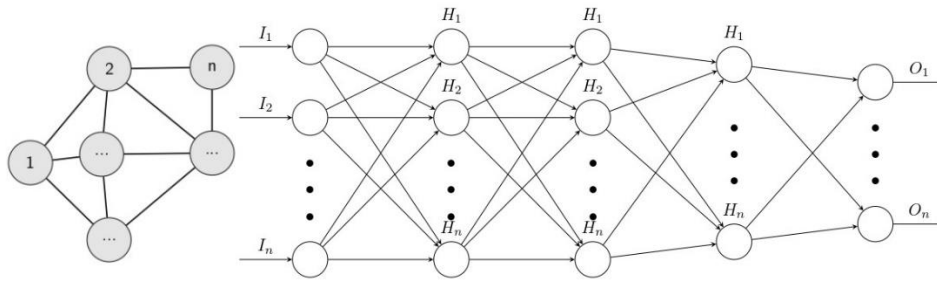
gdje se nastoji odrediti udaljenost $udaljenost_E$ korisnika i do centroida j . Nakon što se odredi udaljenost, odnosno korelacija svih korisnika prema svim centroidima, krajnji korisnici su pridruženi odgovarajućim klasterima uzimajući u obzir minimalnu udaljenost. Prilikom grupiranja trofazno spojenih krajnjih korisnika, potrebno je uzeti u obzir činjenicu da svako od mjerenja takvih korisnika može biti spojeno samo na jednu fazu. Nakon što su svi krajnji korisnici pridruženi odgovarajućim klasterima, centriodi se mijenjaju na način da se traži srednja vrijednost svih korisnika grupiranih u promatrani centroid. Ovakav način grupiranja je iterativan, a koraci 2-4 (Slika 1) ponavljaju se sve dok se minimalne udaljenosti ne prestanu mijenjati, odnosno proces klasteriranja se zaustavlja ukoliko u posljednje dvije iteracije nema promjene u iznosima centroida.

2.2. Algoritam za raspodjelu potrošnje po fazama

Iako je većina uređaja krajnjih korisnika jednofazno priključena na mrežu, sami korisnici mogu biti višefazno povezani na mrežu što otežava raspodjelu ukupne registrirane (agregirane) potrošnje po fazama. Budući da postoji nelinearna povezanost opterećenja pojedine faze i faznih napona, a s ciljem olakšavanja proračuna i omogućavanja daljnjih analiza, razvijen je model temeljen na neuronskim mrežama koji iz dostupnih faznih mjerenja napona te agregirane potrošnje svakog krajnjeg korisnika nastoji izračunati raspodjelu opterećenja po svakoj fazi. Ulazni podaci u model su fazna mjerenja napona svakog korisnika mreže, dok izlazni set podataka sadrži agregiranu potrošnju svakog korisnika. Oba seta podataka predstavljaju stanje promatrane niskonaponske mreže kroz određeni vremenski period te su dimenzije izražene kao $T \times N \times 3$, gdje T predstavlja ukupan broj vremenskih trenutaka, N je ukupan broj korisnika, a 3 odgovara broju faza u distribucijskoj mreži. Iako se radi o vremenskim serijama, važno je naglasiti kako veza između opterećenja pojedinog korisnika i iznosa napona nije promatrana kao funkcija vremena, odnosno svaki vremenski trenutak je pojedinačno promatran.

U razvijenom modelu neuronske mreže, osim ulaznog sloja, dodan je skriveni sloj koji je potpuno povezan s prethodnim slojem, dok izlazni sloj sadrži tri neurona koja označavaju opterećenje svake faze krajnjih korisnika. Budući da razvijeni model mora biti pogodan za rad s mrežama koje imaju jednofazno i višefazno priključene korisnike, u funkciju gubitaka potrebno je dodati ograničenje koje će osigurati da estimirana potrošnja svakog korisnika po fazama odgovara prikupljenoj agregiranoj potrošnji. Ovakav pristup je odabran kako bi se osiguralo ispravno postavljanje hiperparametara neuronske mreže koji ovise o ulaznim i izlaznim podacima, a istovremeno omogućilo određivanje opterećenja pojedine faze za dana ulazna mjerenja napona.

Nadalje, predloženi model proširen je uzimajući u obzir topologiju promatrane mreže te je radi toga potrebno promijeniti i konfiguraciju neuronske mreže kako bi bila pogodna za rad s topološkim podacima. Graf neuronske mreže (eng. *Graph Neural Networks*, GNN) idealan su alat za spomenuti problem, gdje je osim standardnih slojeva neuronske mreže potrebno nadodati slojeve koji mogu raditi s podacima u obliku grafova (Slika 2).



Slika 2: Shematski prikaz GNN modela

Uz podatke koji uključuju naponska mjerenja i mjerenja agregirane potrošnje, u ovakav model integrirani su dodatni podaci, koji odgovaraju matrici admitancija promatrane mreže s dimenzijama $3K \times 3K$, gdje K predstavlja ukupan broj čvorova u promatranoj distribucijskoj mreži. Nažalost, ona se ne može upotrijebiti u izvornom obliku kao ulazni podatak u GNN model, nego je potrebno odrediti Laplaceovu matricu kao:

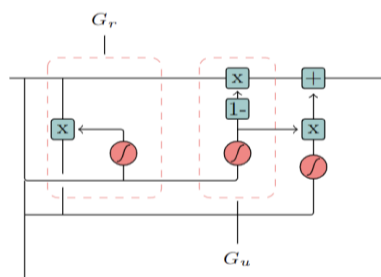
$$L = I - D^{-\frac{1}{2}}MD^{-\frac{1}{2}} \quad (2)$$

gdje I predstavlja matricu identiteta, a matrica D je matrica stupnjeva.

2.3. Algoritam za predviđanje potrošnje i gubitaka djelatne snage po fazama

Nakon što je iz prikupljenih podataka sa naprednih brojila određena fazna pripadnost krajnjih korisnika te njihova potrošnja po fazama, uklonjeni su svi problemi koji su onemogućavali analize poput određivanja faznih gubitaka i buduće potrošnje u distribucijskim mrežama. Tradicionalne metode predviđanja oslanjaju se na upotrebu nadomjesnih krivulja, ponajviše zbog pasivnosti krajnjih korisnika te nepostojanja različitih entiteta koji bi mijenjali prilike u mrežama (poput električnih vozila, distribuirane proizvodnje, dizalica topline i sličnih). Sa većom integracijom naprednih brojila i pojavom novih sudionika, operatori sustava nastoje bolje odrediti trenutno i buduće stanje sustava, čime ranije upotrijebljene nadomjesne krivulje postaju nedostatne. Problem predviđanja potrošnje temelji se na određivanju nelinearnih veza između povijesnih mjerenja i drugih faktora (temperatura, vremenski period itd.) te se istraživanje tog problema sve više kreće u smjeru pristupa baziranih na strojnom učenju [6].

Neuronske mreže su jedan od boljih alata za određivanje nelinearne povezanosti između ulaznih i izlaznih vrijednosti, te je stoga kreiran model temeljen na takvim algoritmima kako bi se generirala predviđanja potrošnje krajnjih korisnika za sljedeći dan. U središtu modela nalaze se GRU jedinice (eng. *Gated Recurrent Units*) – mehanizmi za upravljanje tokom informacija, čija najveća prednost leži u mogućnosti rada sa vremenskim serijama podataka, gdje dolazi do upotrebe kratkotrajne memorije kako bi se dobila točnija predviđanja sljedećih vrijednosti. GRU jedinice sastoje se od dva tipa vrata: vrata za ponovno postavljanje (G_r) koja služe za određivanje utjecaja svakog elementa na sekvencu podataka i vrata za ažuriranje vrijednosti (G_u) koja mijenjaju vrijednosti u ovisnosti o vrijednosti elementa na vratima. Zbog takvog dizajna, GRU jedinice su jednostavnije i brže od ostalih mehanizama povratnih neuronskih mreža (Slika 3).

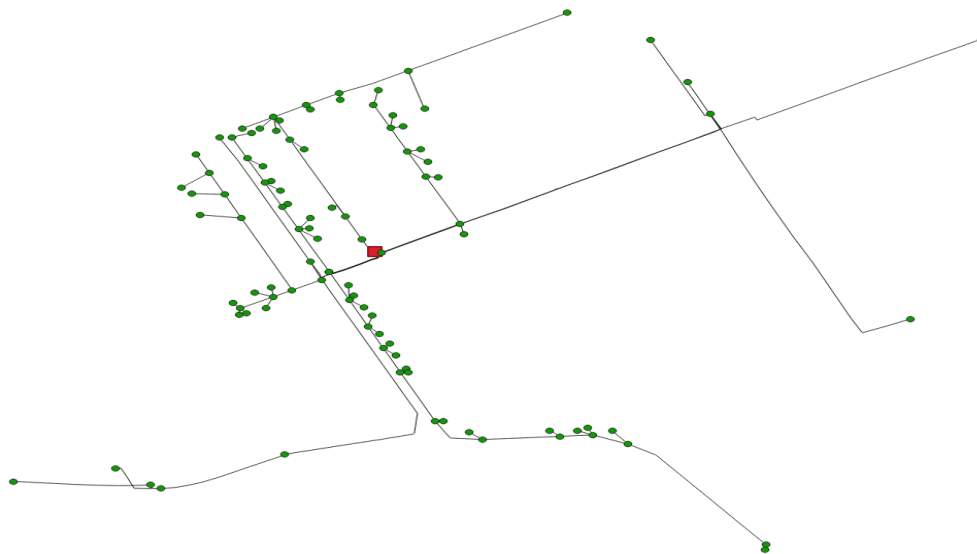


Slika 3: Shematski prikaz GRU jedinice

Gubici u distribucijskim mrežama mogu se definirati kao razlika opterećenja na sabirnici sekundara transformatorske stanice i ukupnog opterećenja svih krajnjih korisnika te se mogu odrediti iz proračuna tokova snaga ili direktno iz modela za predviđanje opterećenja. U prvom slučaju, potrebno je posjedovati točnu informaciju o svim elementima mreže i poznavati topologiju u svakom vremenskom trenutku, što nažalost često nije dostupno u distribucijskim mrežama. Iz tog razloga kreirani model za predviđanje opterećenja korisnika dodatno je proširen kako bi se odredilo opterećenje NN sabirnice transformatorske stanice i odredili gubici distribucijske mreže bez oslanjanja na podatke o elementima mreže.

3. REZULTATI MODELA

Algoritmi opisani u poglavlju 2 primijenjeni su na jednu i/ili dvije od sljedećih mreža: prva mreža je jednostavnija sintetička mreža koja služi za verifikaciju razvijenih modela [7], dok je druga mreža temeljena na stvarnoj distribucijskoj mreži. Sintetička mreža sastoji se od 55 jednofazno priključenih korisnika i više od 100 čvorišta mreže te je upotrijebljena samo za verifikaciju modela za detekciju fazne pripadnosti krajnjih korisnika. Budući da su korisnici originalno priključeni samo na jednu fazu, prije same analize nekoliko njih je nasumično odabrano te su pretvoreni u trofazno spojene korisnike. Umjesto samo jedne, razvijeni algoritmi su testirani na različitim stvarnim distribucijskim mrežama, ovisno o dostupnosti podataka potrebnih za verifikaciju modela. Jedna takva distribucijska mreža sadrži više od 80 krajnjih korisnika od čega ih je gotovo 90% trofazno priključeno na distribucijsku mrežu (prikazana na Slici 4) te je upotrijebljena za validaciju algoritma za identifikaciju faza, dok je u drugoj distribucijskoj mreži nešto manje korisnika trofazno priključeno na mrežu (njih 66 od 151 korisnika), a ostali su jednofazno priključeni po fazama.



Slika 4: Topološki prikaz stvarne distribucijske mreže

Mjerenja napona i potrošnje krajnjih korisnika sintetičke mreže dobivena su koristeći *pandapower* alat za simulacije tokova snaga, dok su stvarni podaci prikupljeni sa naprednih brojlja instaliranih u promatranoj mreži preko SQL relacijske baze podataka. Ti stvarni podaci upotrijebljeni su za verifikaciju algoritma za detekciju faza, dok su sintetički podaci korišteni za ostala dva modela zbog nepostojanja točnih stvarnih podataka kojima bi se postigla validacija.

3.1. Algoritam za detekciju faza

Za verifikaciju razvijenog algoritma na sintetičkoj mreži korišten je set koji uključuje naponska mjerenja krajnjih korisnika po fazama u periodu od dva tjedna i u 15-minutnoj rezoluciji dobivena iz simulacija tokova snaga, a osim toga, upotrijebljena su i mjerenja napona na sekundarnoj sabirnici

transformatorske stanice. Sintetička mreža sadrži samo jednofazno priključene korisnike te je nasumično odabrano nekoliko korisnika čija fazna pripadnost je promijenjena. Budući da mjerenja prikupljena sa stvarnih naprednih brojila često zbog ljudske pogreške ne odgovaraju redosljedu faza na sekundaru transformatora, prilikom modeliranja sintetičke mreže i njenih korisnika osigurana je takva raznovrsnost, a potom su informacije o pripadnostima svih korisnika pohranjene u vanjsku bazu podataka. Testiranje algoritma na sintetičkoj mreži i podacima rezultira u 100% točnosti gdje su svi krajnji korisnici ispravno pridruženi odgovarajućim klasterima.

Podaci prikupljeni sa naprednih brojila sadrže mnogo ne-kontinuiranih perioda, a interpolacija takvih mjerenja može narušiti njihovu prvobitnu distribuciju čime bi se dodatno utjecalo na točnost razvijenog modela. Kako bi se izbjegle takve situacije, identifikacija fazne pripadnosti krajnjih korisnika vršena je samo na onim danima koji sadrže sve kontinuirane vrijednosti. Nakon uklanjanja neočekivanih vrijednosti i brojila sa pogreškama u mjerenju, za promatrani period od dva mjeseca podataka sa polusatnom rezolucijom, ukupno je 38 dana koji odgovaraju zadanom kriteriju. Budući da se radi o više isprekidanih setova vremenskih serija, identifikacija faza je provedena u dva smjera. Prvi smjer uključuje istovremeni rad nad cijelim setom podataka, gdje se iz takvog 'nadograđenog' seta nastoje odrediti pripadnosti krajnjih korisnika. Nasuprot tome, u drugom pristupu korištena su dnevna naponska mjerenja te se za svaki dan određuje fazna pripadnost. Budući da se radi o 38 dana, ovaj način rezultira sa 38 setova faznih pripadnosti (odnosno, radi se o 38 seta sa po tri klastera). Iz toga se zatim određuju konačni klasteri na način da se promatra učestalost pojavljivanja korisnika u pojedinom klasteru te ukoliko se korisnik pridružuje određenom klasteru u više od 50% promatranih dana može se sa velikom sigurnošću pridružiti konačnom klasteru. Ovdje je također uzeto u obzir ograničenje da trofazno spojeni korisnici moraju biti priključeni na tri različite faze distribucijske mreže.

Jedno od glavnih ograničenja distribucijskih mreža je nepoznavanje fazne pripadnosti, a u slučaju promatrane mreže, poznate su fazne pripadnosti za nešto više od 75% krajnjih korisnika. Identifikacija faza krajnjih korisnika provedena je na cijelom setu ulaznih podataka, dok je verifikacija provedena uzimajući u obzir dostupne informacije o pripadnostima. Razvijeni model rezultira u 98.08% točnoj klasifikaciji mjerenja krajnjih korisnika, gdje je 59 trofazno priključeni (od ukupnih 70) i 9 jednofazno priključenih (od ukupnih 11) krajnjih korisnika ispravno klasificirano sa svim njihovim mjerenjima.

3.2. Algoritam za raspodjelu potrošnje po fazama

Točno određen raspored fazne pripadnosti korisnika preduvjet je za implementaciju algoritma za raspodjelu potrošnje krajnjih korisnika po fazama. Budući da za ranije promatranu distribucijsku mrežu ne postoje potpuno točne informacije o faznim pripadnostima niti mjerenja opterećenja krajnjih korisnika po fazama koja su potrebna za verifikaciju točnosti, za učenje i pripremu modela upotrijebljena je druga stvarna distribucijska mreža sa 151 krajnjim korisnikom. Setovi podataka koji su potrebni za rad razvijenog modela, mjerenja napona po fazama svakog krajnjeg korisnika te agregirana (odnosno fazna) potrošnja krajnjih korisnika, nisu dostupni za promatranu mrežu te su generirani koristeći pandapower alat za simulacije tokova snaga.

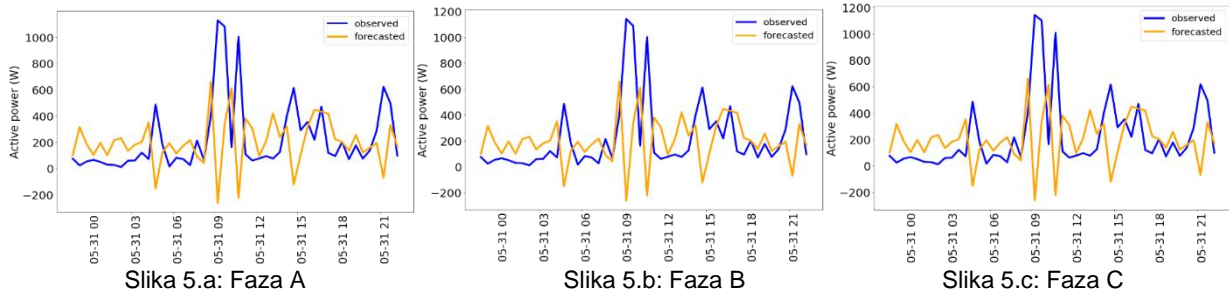
Kako bi predloženi model bio primjenjiv na distribucijske mreže u kojima su korisnici priključeni na jednu i na tri faze, učenje modela se odvija na mreži gdje su svi korisnici jednofazno priključeni, dok se model testira na mreži koja sadrži i trofazno i jednofazno priključene korisnike. Tako je za trening i validaciju modela nasumično odabrana pripadnost svakog korisnika pojedinoj fazi, dok je faza testiranja provedena na stvarnoj distribucijskoj mreži. Samo učenje i testiranje modela provedeno je na četiri, odnosno dva tjedna za NN, odnosno GNN model.

Parametri NN modela su prikazani u Tablici I.

Tablica I. Hiperparametri NN modela

neuroni (skriveni sloj)	8
aktivacijska funkcija (skriveni sloj)	tanh funkcija
aktivacijska funkcija	linearna funkcija
batch veličina	100
optimizacijski algoritam	RMSprop
stopa učenja	0.0001
epohe	1500

Validacijski gubici ovog modela iznose 0.014, dok srednja kvadratna pogreška (eng. *Mean Squared Error*, MSE) na setu od 48 vrijednosti iznosi 0.029671. Krivulje raspodjele potrošnje jednog krajnjeg korisnika po fazama za NN model prikazane su na Slici 5.

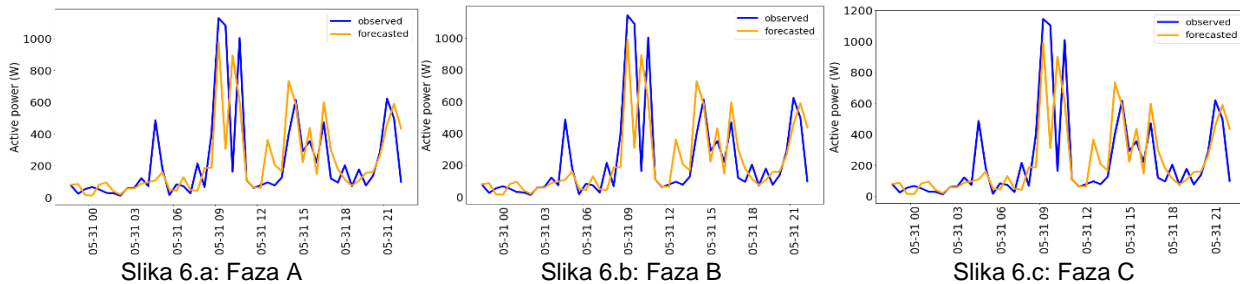


Drugi model, GNN model, uz mjerenja faznih napona i agregirane potrošnje svih krajnjih korisnika koristi i informacije o mrežnoj topologiji, koji su izraženi pomoću matrice admitancija promatrane mreže. Parametri drugog modela, GNN modela, prikazani su u Tablici II.

Tablica II: Hiperparametri GNN modela

neuroni (GConv slojevi)	3
aktivacijska funkcija (GConv slojevi)	tanh funkcija
neuroni (FCL sloj)	3
aktivacijska funkcija (FCL sloj)	tanh funkcija
batch veličina	50
optimizacijski algoritam	RMSprop
stopa učenja	0.0001
epohe	500

Validacijski gubici ovog modela iznose 0.0059, dok srednja kvadratna pogreška (eng. *mean Squared Error*, MSE) na setu od 48 podataka iznosi 0.00621. Slično kao i za prethodni model, krivulje distribucije potrošnje krajnjeg korisnika prikazane su na Slici 6.

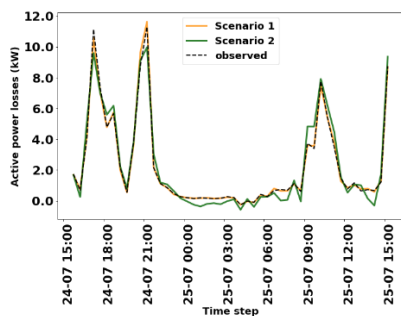


3.3. Algoritam za predviđanje potrošnje i gubitaka djelatne snage po fazama

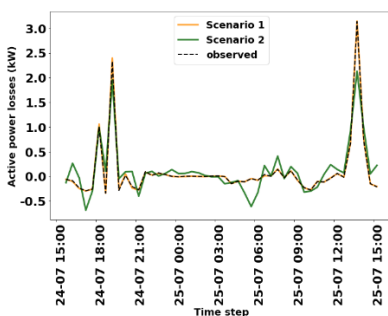
Glavni preduvjeti za omogućavanje predviđanja potrošnje i faznih gubitaka djelatne snage su poznavanje pripadnosti krajnjih korisnika te posjedovanje povijesnih mjerenja njihove fazne potrošnje. Niska osmotrivost distribucijskih mreža otežava fazna predviđanja i analize, te je stoga potrebno aktivirati modele za identifikaciju fazne pripadnosti i distribucije potrošnje kako bi se osigurali potrebni preduvjeti. Zbog problema nepostojanja točnih informacija kojima bi se validirali rezultati razvijenog modela, potrebni setovi podataka o povijesnoj potrošnji dobiveni su iz vremenskih simulacija tokova snaga koristeći *pandapower* alat. Osim povijesne potrošnje krajnjih korisnika, određeno je i povijesno opterećenje sekundarne sabirnice transformatorske stanice, koje se koristi kao dodatni ulazni parametar.

Kao što je ranije spomenuto, model je razvijen kako bi omogućio određivanje budućih gubitaka u distribucijskim mrežama sa i bez poznavanja mrežne topologije i parametara. Tako je za učenje prvog modela upotrijebljena povijesna potrošnja krajnjih korisnika sa 30-minutnom rezolucijom, dok je za drugi model prethodni ulazni set proširen sa povijesnim opterećenjima NN sabirnice promatrane transformatorske stanice.

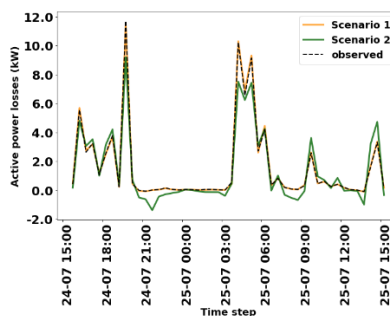
Učenje oba modela odvija se kroz 1500 epoha sa deset koraka po epohi. Nakon treninga, rezultati prvog modela integriraju se u alat za simulacije tokova snaga kako bi se odredila opterećenja na sekundarnoj sabirnici, a konačno i budući gubici djelatne snage po fazama kao razlika ukupne potrošnje i dobivenog opterećenja transformatorske stanice. Za razliku od toga, drugi model koristi podatke krajnjih korisnika i mjerenja prikupljena sa sekundarne sabirnice TS za trening i određivanje budućeg opterećenja te se budući gubici računaju kao razlika dobivenih predviđanja. Komparativni prikaz oba modela (Scenarij 1 i Scenarij 2) te stvarnih gubitaka prikazan je na Slici 7.



Slika 7.a: Faza A



Slika 7.b: Faza B



Slika 7.c: Faza C

Kao što se može primijetiti, model koji koristi topologiju (Scenarij 1) uspješno prati krivulju stvarnih gubitaka u distribucijskoj mreži, gdje maksimalno odstupanje predviđenih i stvarnih gubitaka iznosi 0.872 kW, 0.077 kW i 0.296 kW za faze A, B i C. U slučaju drugog modela dolazi do većih devijacija, koje iznose 1.548 kW, 1.004 kW i 2.709 kW za faze A, B i C, a razlog leži u upotrebi mjerenja sa transformatorske stanice. Prilikom implementacije modela iz Scenarija 1, opterećenje NN sabirnice TS dobiveno je kao rezultat idealno simuliranih tokova snaga, dok je u Scenariju 2 opterećenje određeno iz prediktivnog modela koji unosi dodatne nesigurnosti i odstupanja. S druge strane, ovako razvijeni model nadilazi probleme vezane uz manjak informacija o topologiji i elementima promatrane mreže te istovremeno reducira kompleksnost modela za određivanje budućih gubitaka djelatne snage sustava.

4. ZAKLJUČAK

Posljednjih godina dolazi do značajnijeg porasta broja novih entiteta u distribucijskim sustavima, poput električnih vozila i distribuirane proizvodnje. Razlog tome leži u padu cijena ovih tehnologija, ali i u brojnim zakonskim odredbama i regulativama kojima Europska unija nastoji provoditi 'zelenu' politiku te osigurati klimatsku neutralnost. Promjene u ponašanjima krajnjih korisnika te pojava novih sudionika potiču operatore sustava na bolju osmotrivost distribucijske mreže u svakom trenutku. Nažalost, trenutno instalirana napredna brojila još uvijek služe samo za prikupljanje i pohranu kumulativnih podataka o potrošnji krajnjih korisnika s ciljem naplate potrošnje, dok se na ponekim mjestima u distribucijskoj mreži prikupljaju i procesni podaci koji uključuju naponska mjerenja. Brojne druge mogućnosti koje ti mjerni uređaji pružaju nisu iskorištene što smanjuje osmotrivost te dodatno otežava provođenje analiza, kao što je predviđanje potrošnje i estimacija stanja mreže, a koje su potrebne za planiranje i vođenje pogona distribucijskih mreža.

Radi omogućavanja predviđanja budućeg opterećenja sustava, ali i daljnjih analiza poput aktivacije krajnjih korisnika s ciljem pružanja usluga fleksibilnosti te optimalne rekonfiguracije distribucijske mreže, u ovom radu predstavljeni su modeli koji iz dostupnih podataka s naprednih brojila nastoje odrediti faznu pripadnost krajnjih korisnika i njihovu buduću potrošnju. Budući da se radi o većim setovima podataka sa

kompleksnim i nelinearnim korelacijama, razvijeni modeli temelje se na algoritmima strojnog učenja koji imaju sve veću primjenu u problemima distribucijskih mreža.

Prvi model temeljen je na K-Means klasteriranju te iz dostupnih faznih mjerenja napona određuje točnu faznu pripadnost krajnjih korisnika. Model je testiran na sintetičkoj IEEE mreži gdje je pokazao 100% točnost, dok verifikacija na stvarnoj distribucijskoj mreži rezultira pogreškom od 2%. Dobiveni izračuni potom se mogu koristiti kao ulazni parametar u model neuronskih mreža za raspodjelu agregirane potrošnje krajnjih korisnika po fazama. Osim točne fazne pripadnosti, model koristi mjerenja napona po fazama za svakog korisnika te njihovu agregiranu potrošnju kako bi se izračunala fazna potrošnja koja služi za određivanje buduće potrošnje krajnjih korisnika te gubitaka djelatne snage u distribucijskim mrežama. Posljednja dva modela verificirana su na sintetičkim podacima zbog nepostojanja mjerenja sa naprednih brojila te oba rezultiraju zadovoljavajućom točnosti. Nadalje, oba modela su razvijena za distribucijske mreže s poznatim/nepoznatim mrežnim parametrima i topologijom te oba modela daju bolje rezultate prilikom integracije topoloških informacija.

Ovakav kombinirani model, osim što operatorima sustava omogućava bolje poznavanje trenutnog stanja mreže, bez potrebe za instalacijom dodatnih mjernih uređaja, također postavlja dobar temelj za daljnje analize poput detekcije anomalija i identifikacije tehničkih i netehničkih gubitaka.

ZAHVALA

Rad je sufinanciran projektom FLEXIGRID (Sporazum o dodjeli sredstava br.854579) iz istraživačkog i razvojnog programa Europske unije Horizon 2020. Ovaj rad odražava stajalište FLEXIGRID konzorcija i Europska komisija nije odgovorna za bilo kakvo korištenje na temelju informacija koje rad sadrži. Zaposlenje T. Matijašević u potpunosti je financirano uz potporu Hrvatske zaklade za znanost (HRZZ) unutar programa DOK-2021-02.

5. LITERATURA

- [1] „HEP ODS – Godišnje izvješće 2021.“ [Online]. Dostupno na: https://www.hep.hr/ods/UserDocsImages//publikacije/godisnje_izvjesce//godisnje2021.pdf
- [2] A. Simonovska and L. F. Ochoa, "Phase Grouping in PV-Rich LV Feeders: Smart Meter Data and Unconstrained k-Means," 2021 IEEE Madrid PowerTech, Madrid, Spain, 2021, pp. 1-6, doi: 10.1109/PowerTech46648.2021.9495097.
- [3] Z. S. Hosseini, A. Khodaei and A. Paaso, "Machine Learning-Enabled Distribution Network Phase Identification," in IEEE Transactions on Power Systems, vol. 36, no. 2, pp. 842-850, March 2021, doi: 10.1109/TPWRS.2020.3011133.
- [4] L. Blakely, M. J. Reno and W.-c. Feng, "Spectral clustering for customer phase identification using AMI voltage timeseries", 2019 IEEE Power and Energy Conference at Illinois (PECI), pp. 1-7, 2019.
- [5] V. A. Jimenez, A. Will and S. Rodriguez, "Phase identification and substation detection using data analysis on limited electricity consumption measurements", *Electric Power Systems Research*, vol. 187, pp. 106450, 2020.
- [6] Hadjout, D., Torres, J. F., Troncoso, A., Sebaa, A., & Martínez-Álvarez, F. (2022). Electricity consumption forecasting based on ensemble deep learning with application to the Algerian market. *Energy*, 243, 123060.
- [7] Khan, M.A. and Hayes, B.P., 2022, July. A reduced electrically-equivalent model of the IEEE european low voltage test feeder. In 2022 IEEE Power & Energy Society General Meeting (PESGM) (pp. 1-5). IEEE.