

# Primjena algoritama strojnog učenja u vođenju naprednih distribucijskih mreža

Matijašević Terezija

Zavod za visoki napon i energetiku

Fakultet elektrotehnike i računarstva


Sveučilište u Zagrebu

# Sadržaj

- Uvod
- Motivacija
- Priprema podataka
- Detekcija faza
- Raspodjela potrošnje po fazama
- Predviđanje gubitaka
- Daljnji razvoj
- Zaključak

# Uvod

- Trenutno stanje distribucijskih mreža – neosmotriva mreža, pojava novih LC tehnologija traži bolji uvid u stanje mreže
- Nove tehnologije pružaju brojne mogućnosti operatorima sustava – promjena koncepta pogona i planiranja distribucijskih mreža
- Poželjno iskoristiti velike tokove podataka (dostupne) u distribucijskim mrežama – *machine learning*\*



Tradicionalna distribucijska mreža

Nove tehnologije


Planiranje pogona

Usluge fleksibilnosti

Pogon u stvarnom vremenu

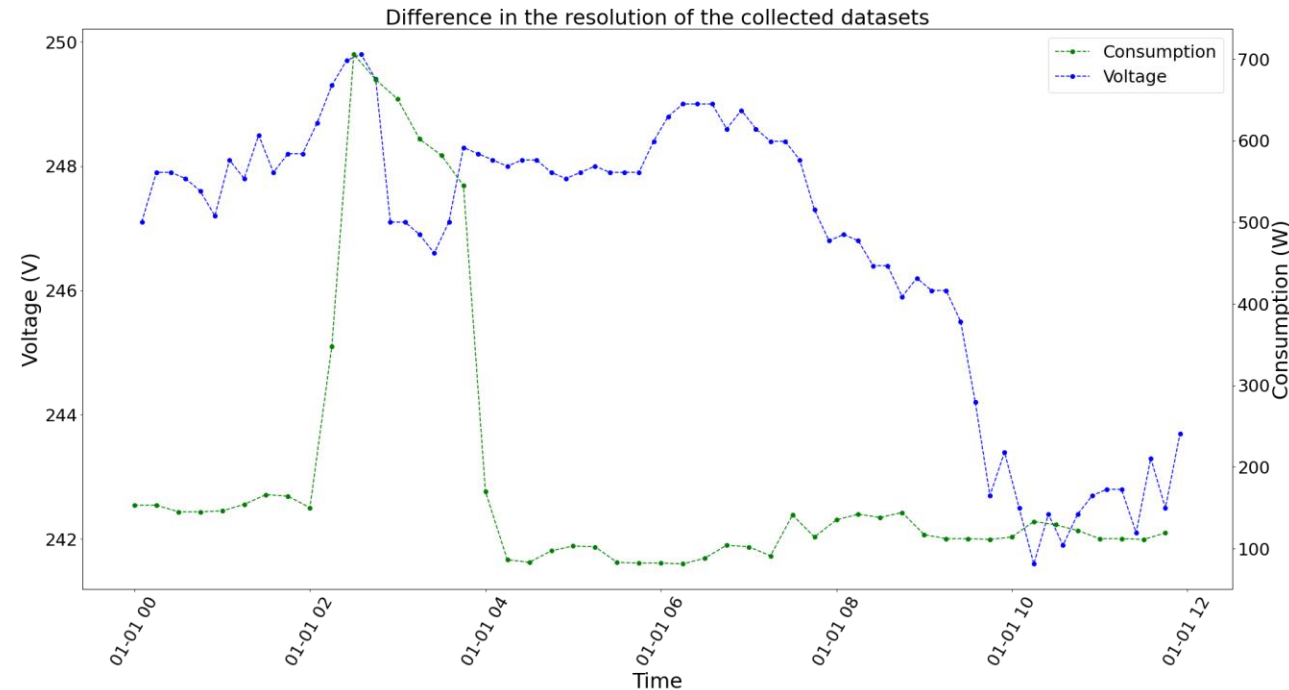
# Motivacija

- Instalirana brojila služe u svrhu naplate – prikupljanje kumulativne potrošnje korisnika
- Predviđanje fazne potrošnje ograničeno je prikupljenim podacima → smanjenje mogućnosti daljnjih analiza u mreži
- **CIJ** – razvoj modela predviđanja gubitaka u tri faze
  - identifikacija fazne pripadnosti krajnjih korisnika
  - distribucija potrošnje po fazama
  - predviđanje faznih gubitaka u distribucijskoj mreži



# Priprema podataka

- Stvarni podaci prikupljeni sa pametnih brojila pohranjeni u bazu – krivulja kumulativne radne energije i fazna naponska mjerenja
- Nesavršeni podaci:
  - prazne (*missing*) vrijednosti – vrijednosti prethodnog dana, prethodnog sata i prethodnog tjedna
  - nule i odstupanja – linearna interpolacija
- Razlika u rezoluciji podataka
  - podaci svedeni na 30-minutni interval

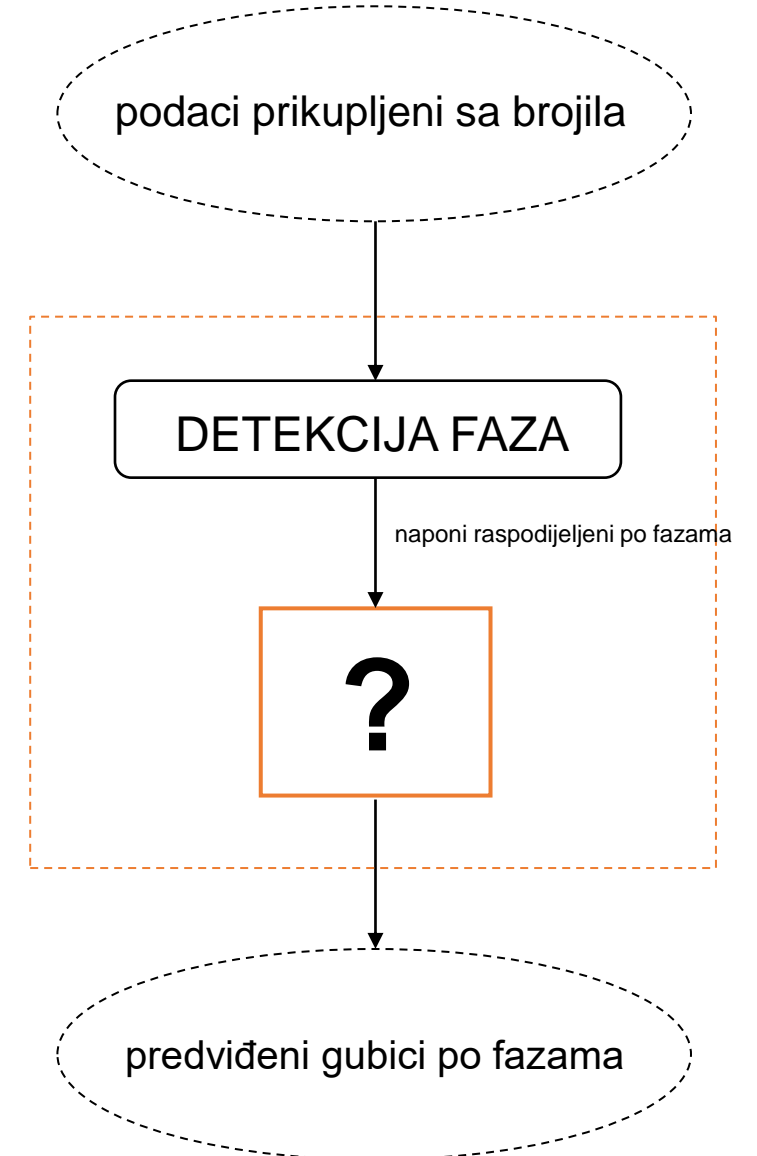


Slika 1: Naponska mjerenja i mjerenja potrošnje prikupljena sa pametnih brojila

# Detekcija faza\*

- ulaz: mjerenja napona po fazama svih krajnjih korisnika, mjerenja prikupljena sa TS
- izlaz modela: naponi raspodijeljeni po fazama
- iterativan model temeljen na grupiranju korisnika po sličnosti – *K-Means* klasteriranje
- algoritam testiran na većim i manjim sintetičkim mrežama (100% točnost) te na stvarnoj mreži (Vinkovci, odstupanje od 10-ak %)

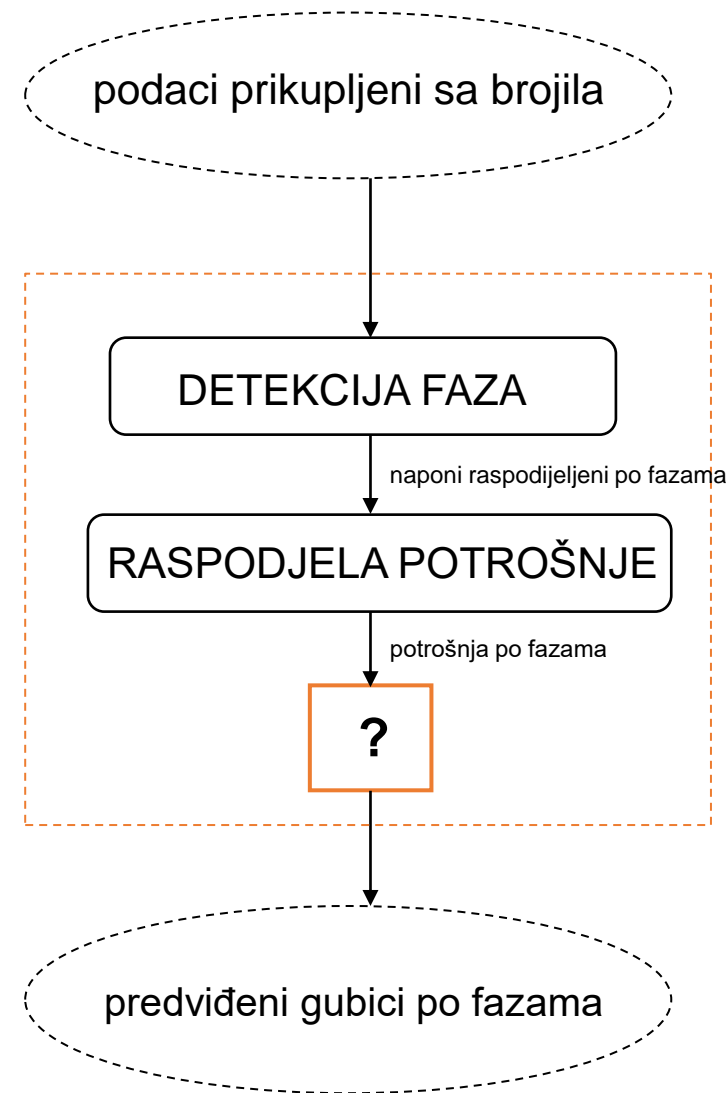
6



\* Matijašević T., Antić T., Capuder T., „Voltage-based Machine Learning Algorithm for Distribution of End-users Consumption Among the Phases”, MIPRO Proceedings, ISSN: 1847-3946, pp.1115-1120

# Raspodjela potrošnje po fazama\*

- ulaz: mjerenja napona raspodijeljena po fazama, agregirana potrošnja krajnjih korisnika
- izlaz modela: potrošnja krajnjih korisnika raspodijeljena po fazama
- model temeljen na neuronskim mrežama
- nadogradnja modela uključuje i informaciju o topologiji mreže → GNN model
  - primjenjiv u slučaju kada mreža ne postoji ili u slučaju nepotpunih podataka o topologiji mreže



7


\* Matijašević T., Antić T., Capuder T., „On the value of distribution network topology information in the identification of end-user phase consumption: A Graph Neural Network approach”, CEN 2022

# Raspodjela potrošnje po fazama


- Stvarna niskonaponska mreža – 151 krajnji korisnik
- Dva modela: neuronske mreže i GNN – oba modela primjenjiva na problem raspodjele potrošnje po fazama

Tablica 1: Usporedba rezultata za oba modela


model	MSE / veći testni set	MSE / manji testni set
neuronska mreža	0.04924	0.01244
GNN	0.00621	$9.385 \times 10^{-19}$



Slika 2.a: faza 1



Slika 2.b: faza 2



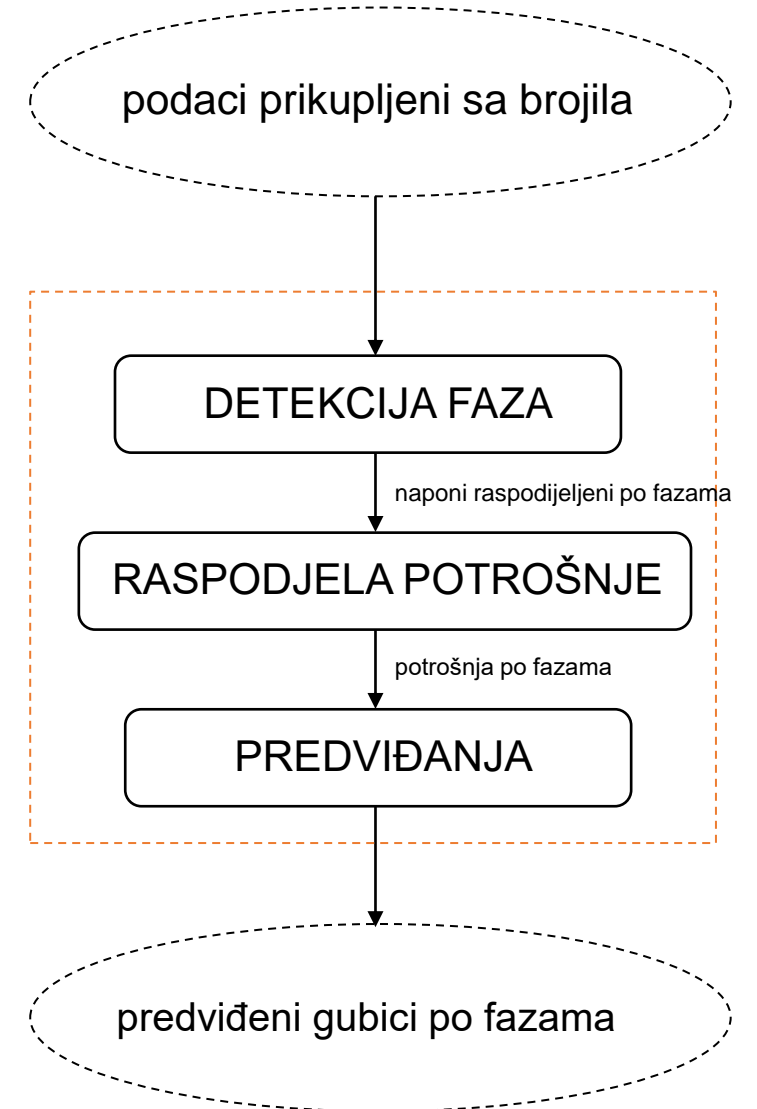
Slika 2.c: faza 3



# Predviđanje gubitaka\*

- ulaz: potrošnja krajnjih korisnika raspodijeljena po fazama
- izlaz modela: predviđanja gubitaka za dan unaprijed
- model temeljen na neuronskim mrežama
  - predviđanje potrošnje krajnjih korisnika i predviđanje opterećenja TS
  - izračun gubitaka po formuli:


$$gubici = opterećenje_{TS} - \sum potrošnja_{krajnji\ korisnici}$$



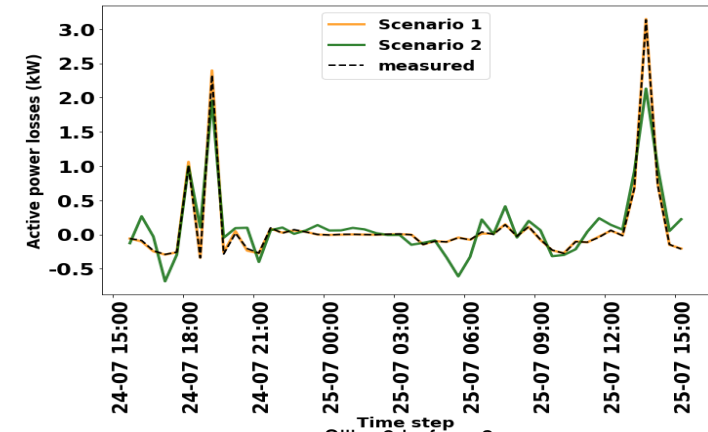
\* Matijašević T., Antić T., Capuder T., „Machine learning-based forecast of secondary distribution network losses calculated from the smart meters data”, 2022 7th International Conference on Smart and Sustainable Technologies (SpliTech). IEEE, 2022.

# Predviđanje gubitaka


- Niskonaponska mreža – 151 krajnji korisnik (trofazno i jednofazno spojeni na mrežu)
- model A: određivanje mrežnih gubitaka koristeći dodatne alate za simulaciju tokova snaga
  - predviđanje potrošnje krajnjih korisnika
  - analiza tokova snaga (*pandapower*)
  - izračun mrežnih gubitaka
- model B: određivanje mrežnih gubitaka koristeći samo predviđanja potrošnje i opterećenja TS
  - predviđanje potrošnje i predviđanje opterećenja
  - izračun mrežnih gubitaka



Slika 3.a: faza 1



Slika 3.b: faza 2



Slika 3.c: faza 3

# Daljnji razvoj

- Identifikacija topologije i uklopnog stanja mreže – linearna regresija, zahtjevnije ML metode
- Detekcija tehničkih i netehničkih gubitaka
- Nadogradnje postojećih modela
  - Testiranja modela na nepoznatim mrežama
  - Istraživanje utjecaja reaktivnih snaga i kutova napona
  - Analiza nad mrežama sa značajnom količinom integriranih niskougljičnih tehnologija
  - Automatizacija modela
  - ...

# Zaključak

- Veliki tokovi podataka utječu na promjenu aspekta planiranja i vođenja distribucijskih mreža
- Iz agregirane potrošnje krajnjih korisnika moguće doći do predviđanja gubitaka po fazama u distribucijskoj mreži
- Svaki od modela unosi dodatna odstupanja u konačni model predviđanja gubitaka
- Daljnji razvoj baziran na integraciji algoritama strojnog učenja

# Bibliografija

- Matijašević, T., Antić, T., Capuder, T. (2022). „A systematic review of machine learning applications in the operation of smart distribution systems”, *Energy Reports*, 8 (međunarodna recenzija, članak, znanstveni)
- Matijašević T., Antić T., Capuder T. (2022). „Voltage-based Machine Learning Algorithm for Distribution of End-users Consumption Among the Phases”, *MIPRO Proceedings* (predavanje, međunarodna recenzija, cjeloviti rad)
- Matijašević T., Antić T., Capuder T. (2022). „On the value of distribution network topology information in the identification of end-user phase consumption: A Graph Neural Network approach”, CEN 2022 (predavanje, međunarodna recenzija)
- Matijašević T., Antić T., Capuder T. (2022). „Machine learning-based forecast of secondary distribution network losses calculated from the smart meters data”, *SpliTech Proceedings* (predavanje, međunarodna recenzija, cjeloviti rad)



## Hvala na pozornosti

Ovaj rad su sufinancirali Hrvatska zaklada za znanost i HEP Operator distribucijskog sustava d.o.o. projektom IMAGINE – Inovativni modeli i laboratorijski testirana rješenja za sljedeću generaciju distribucijskih mreža (PAR-2018).