Izazovi naprednih mreža

Izv. prof. dr. sc. Tomislav Capuder
Zavod za visoki napon i energetiku
Fakultet elektrotehnike i računarstva
Sveučilište u Zagrebu

/Zavod za visoki napon
i energetiku

Uvod

- Dekarbonizacija
- Liberalizacija
- Decentralizacija
- Elektrifikacija

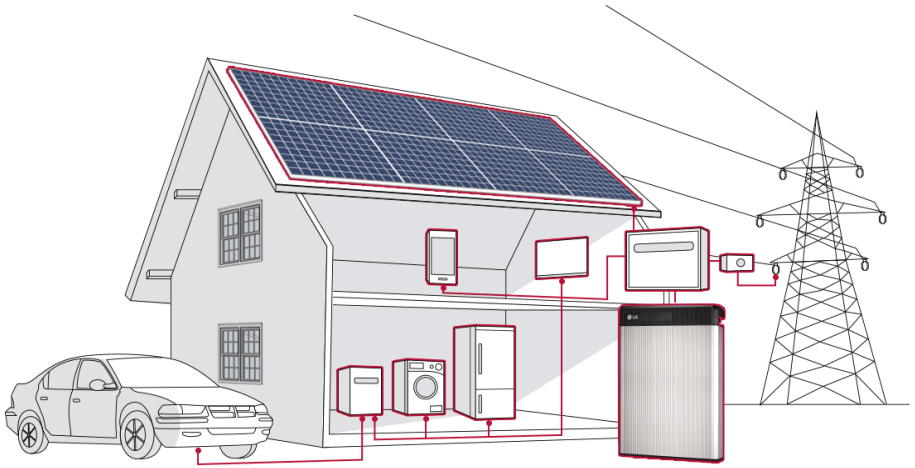

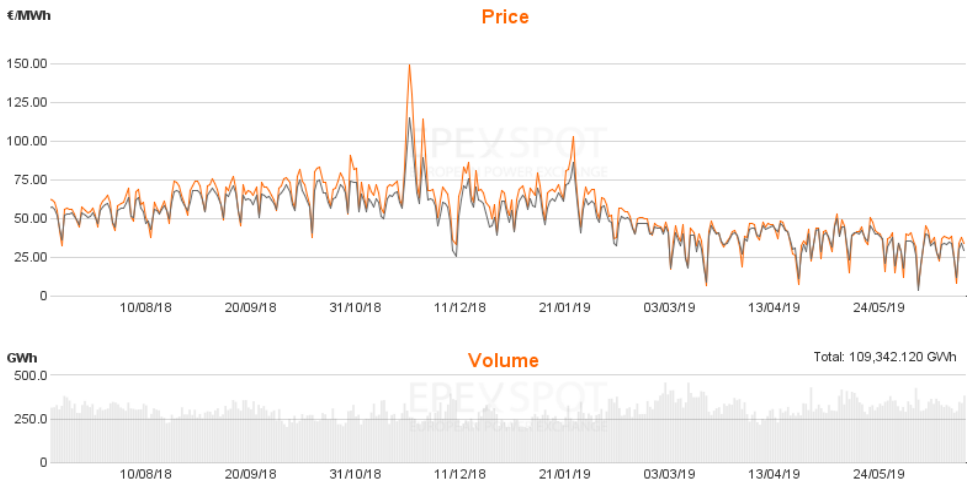

2

/Zavod za visoki napon i energetiku

OIE i fleksibilnost

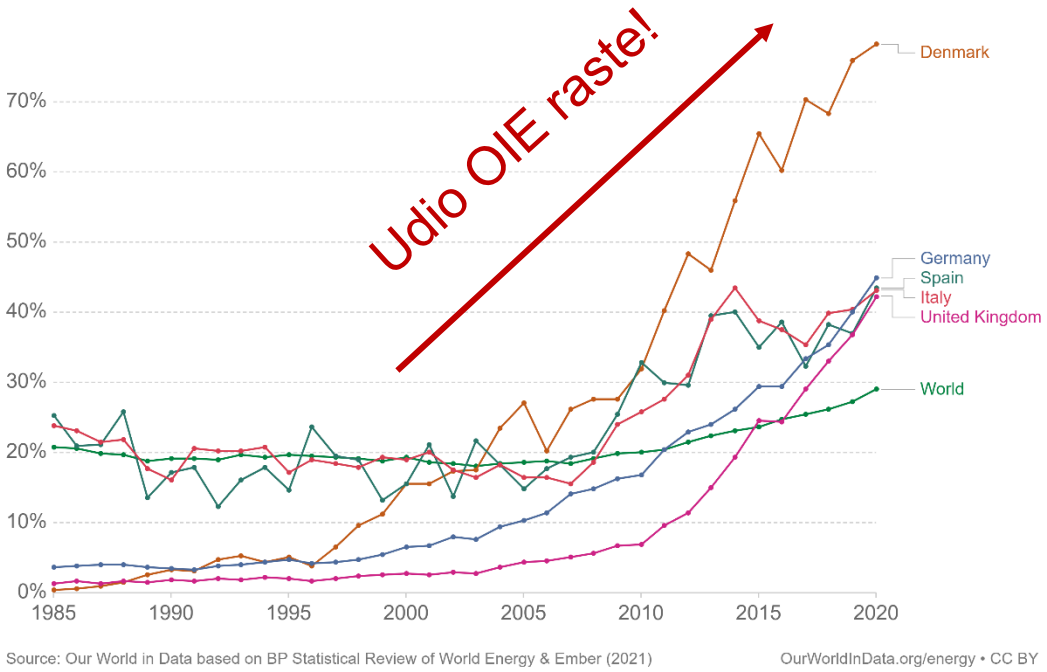

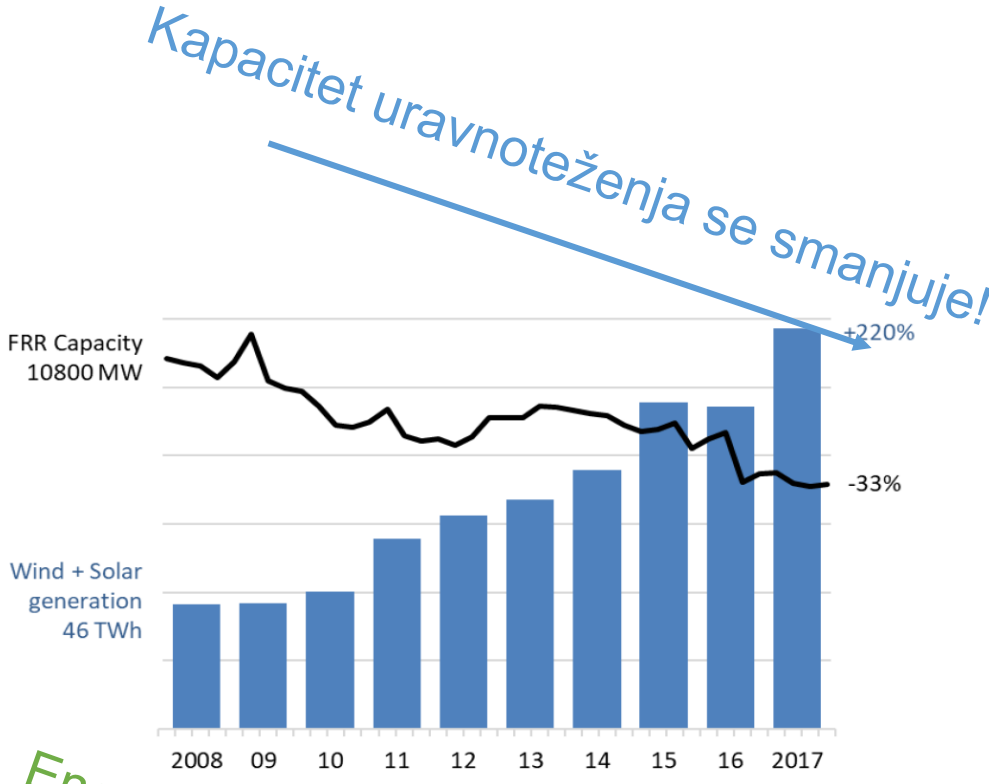

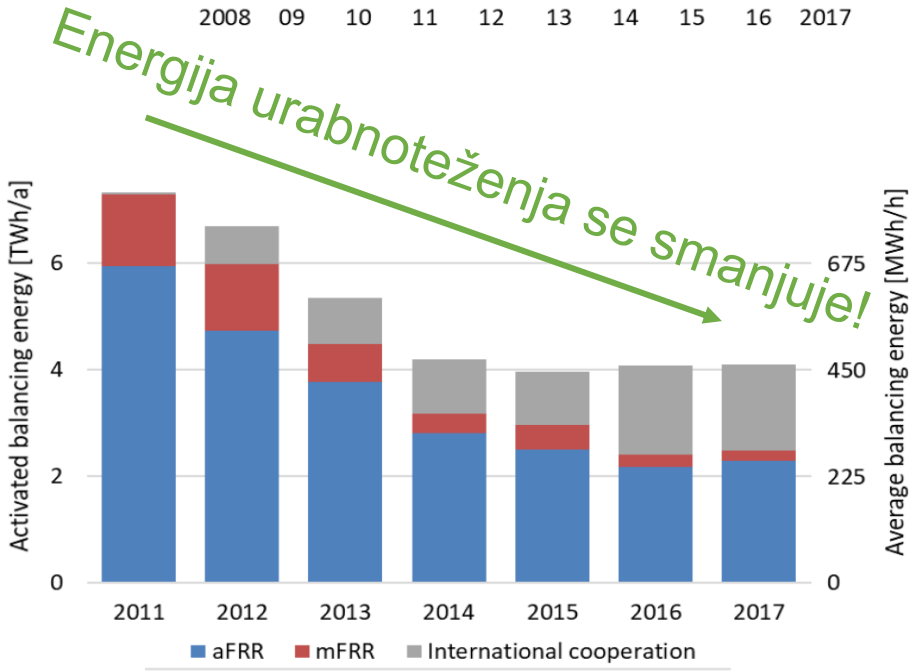

Njemački paradoks uravnoteženja

Razlozi?

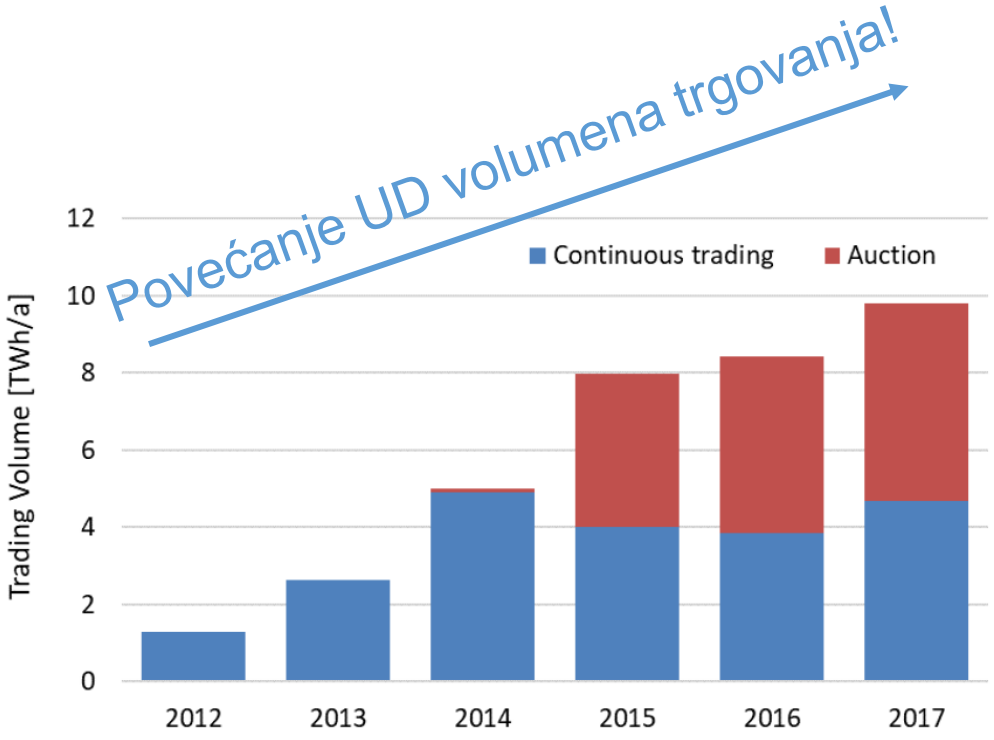

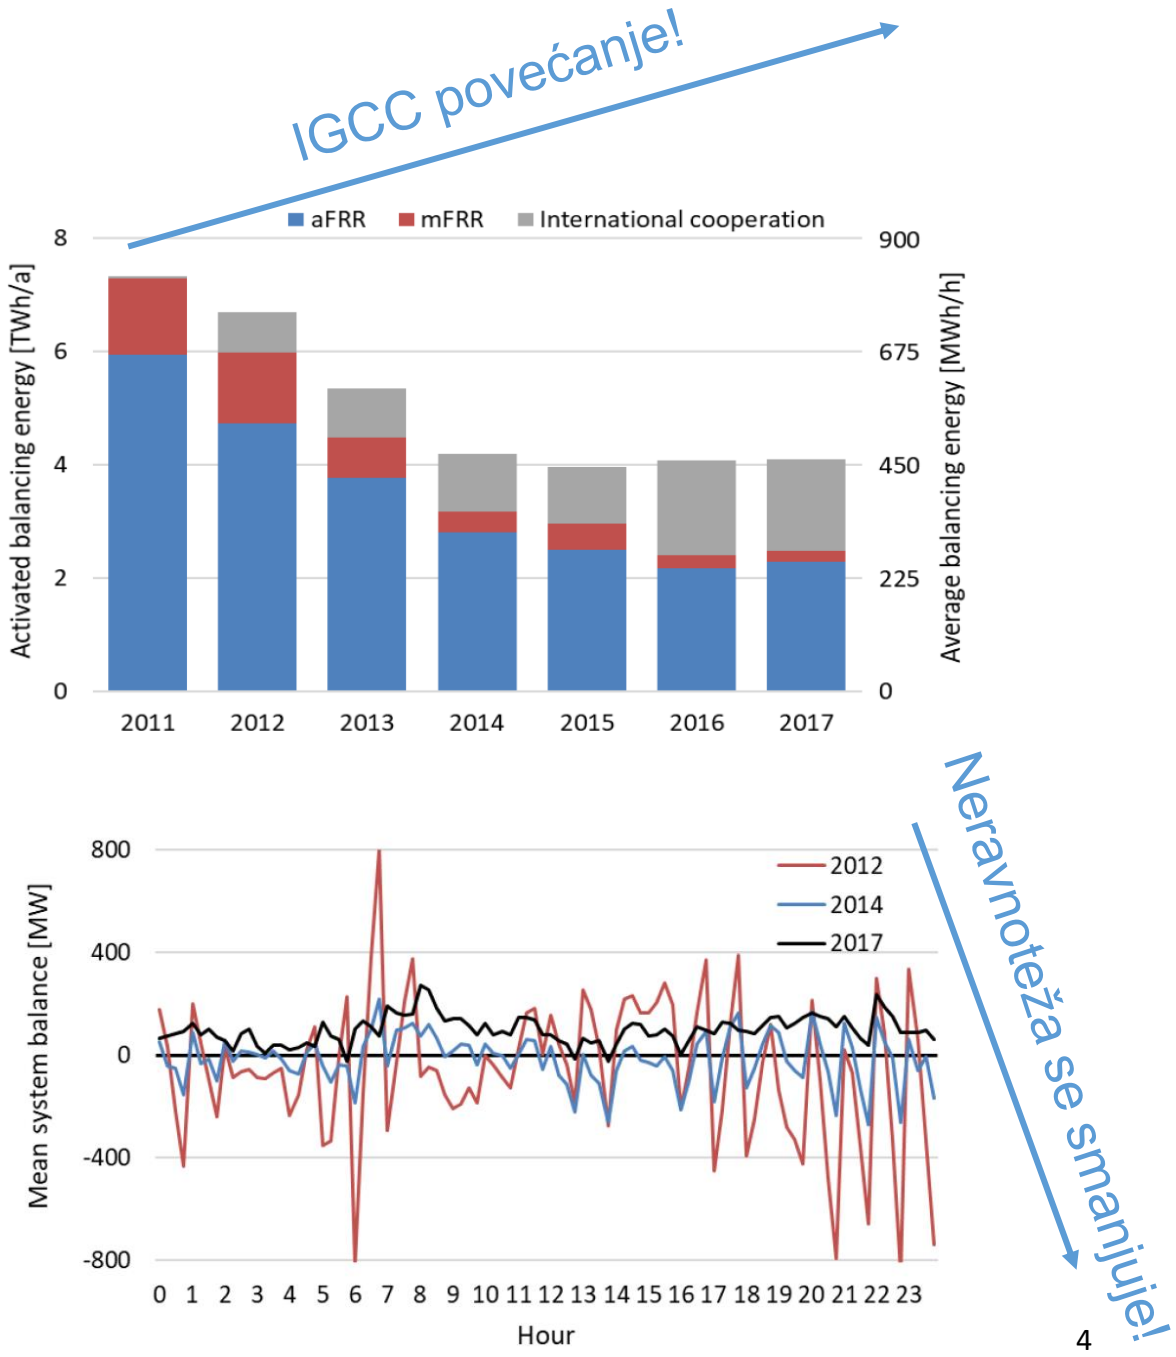

4

Nova tržišta

Coupling

Nova pravila

Novi tržišni/sustavni dionici/entiteti

/Zavod za visoki napon i energetiku

Novi sudionici u EESu

- Baterije
- EV
- DI
- OIE

68% ukupne FCR u Njemačkoj

603 MW

Ukupni FCR zahtjev

415 MW

Baterije pružaju FCR

EV potvrđeni pružatelji usluga

Prosječan DR na FR BM

727 MW

2018

878 MW

2019

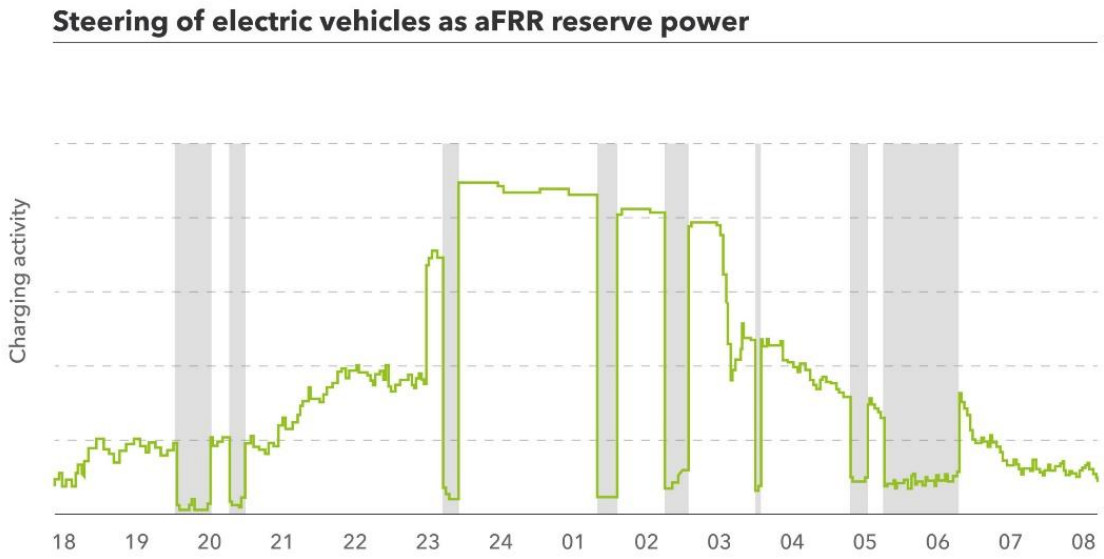

Nizozem aFRR: Jedlix & Next Kraftwerke

Razvoj rješenja za napredne mreže

	Smart Grid	Baterije/spremnici	Novi tržišni/poslovni modeli	Električna vozila
Horizon 2020	FARCROSS FLEXIGRID ATTEST	FLEXIGRID CROSSBOW FLEXGRID	CROSSBOW ATTEST uGRIP	FlexChEV
Interreg	3Smart	3Smart	3Smart	
Erasmus	SHVET		SHVET	
HRZZ	IMAGINE WINDLIPS SIREN	SUCCESS SIREN ANIMATION	FENISG SUCCESS IMPACT	EVBASS
IRI/UZI	SUPER RESdata Smagrilos	BatEVCharg RASCO USBSE	SUPER FLEXIBASE USBSE	BatEVCharg bigEVdata FLEXIBASE

Izazovi naprednih EEM

- Priključenje velikog broja novih korisnika (niskougljičnih tehnologija) u slabo osmotrivu niskonaponsku distribucijsku mrežu -> razvoj alata i analize: gubitci, naponi, nesimetrije, harmonici itd.
- Novi korisnici -> razvoj alata i analiza: predviđanje njihovog ponašanja u svrhu učinkovitijeg vođenja mreže/sustaa
- Novi korisnici koji aktivno sudjeluju na tržištu -> razvoj alata: agregatori i pružanje usluga operatorima sustava.
- Nesigurnosti uslijed OIE i izazovi za operatore prijenosne i distribucijske mreže -> razvoj alata temeljenih na upravljanju tokovima snaga: VVC, TSO-DSO koordinacija

Energetska tranzicija -> svi u NN

- OIE na priključcima krajnjih korisnika -> iza brojila?
- Elektrifikacija grijanja -> više od 50% EE potrošnje
- Elektrifikacija mobilnosti -> veće priključne snage
- Potreba prediktivnih i sustavnih analiza ponašanja novih korisnika u NN -> veliki broj scenarija i analiza koje treba razmatrati
  - Razvijen dodatak PandaPoweru (dodatak alata razvijenom na Fraunhofer-Gesellschaft https://github.com/e2nIEE/pandapower/blob/harmonics/AUTHORS),
  - Veliki broj analiza nesimetričnih tokova snaga, harmoničkih analiza i nesimetričnih harmoničkih analiza
  - Različiti scenariji -> način priključka (1f, 3f)
  - Različiti slučajevi -> različite tehnologije i obrasci ponašanja

T. Antić, T. Capuder, and M. Bolfek, "A Comprehensive Analysis of the Voltage Unbalance Factor in PV and EV Rich Non-Synthetic Low Voltage Distribution Networks" Energies, vol. 14, no. 1, p. 30, 2021.

Energetska tranzicija -> svi u NN

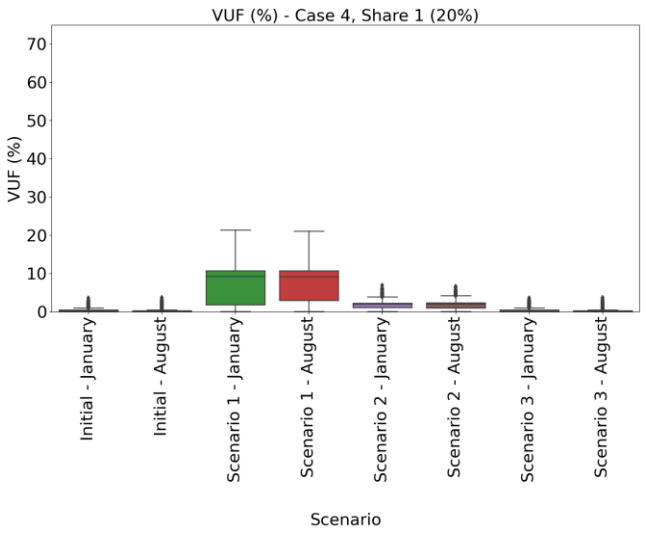

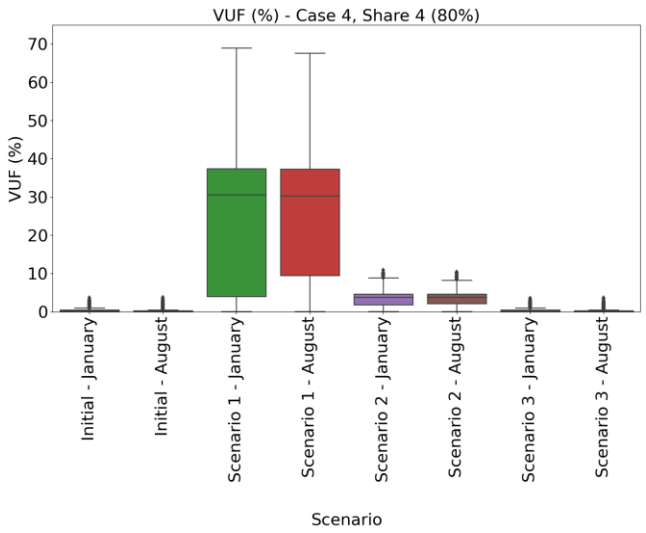

Slika 1. Naponska nesimetrija (%), slučaj 4, udio 20% i 80%

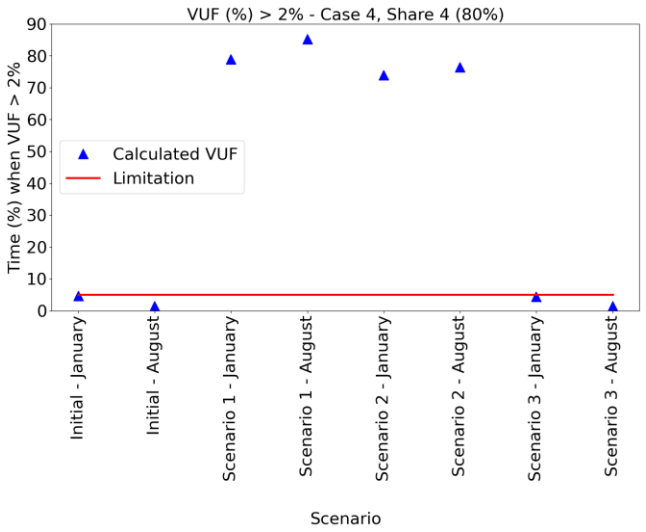

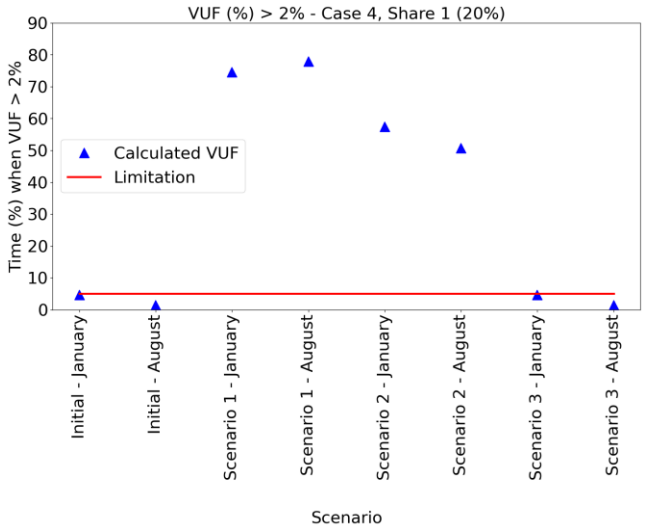

Slika 2. Naponska nesimetrija > 2%, slučaj 4, udio 20% i 80%

T. Antić, T. Capuder, and M. Bolfek, "A Comprehensive Analysis of the Voltage Unbalance Factor in PV and EV Rich Non-Synthetic Low Voltage Distribution Networks" Energies, vol. 14, no. 1, p. 30, 2021.

Rad financiran je od strane Hrvatske zaklade za znanost i u suradnji s Operatorom distribucijskog sustava (HEP ODS d.o.o.) unutar projekta IMAGINE (PAR2018-12).

Energetska tranzicija -> svi u NN

- Najveći udio distribuiranih izvora na mrežu je spojen uređajima energetske elektronike -> nesinusoidalne struje i napone te uzrokuju strujno i naponsko harmoničko izobličenje
- Analiza podataka o opterećenju tijekom zatvaranja uzrokovanog pandemijom koronavirusa pokazuje promjenu ponašanja krajnjih korisnika i porast opterećenja tijekom najvećeg djela dana - > povećani THD

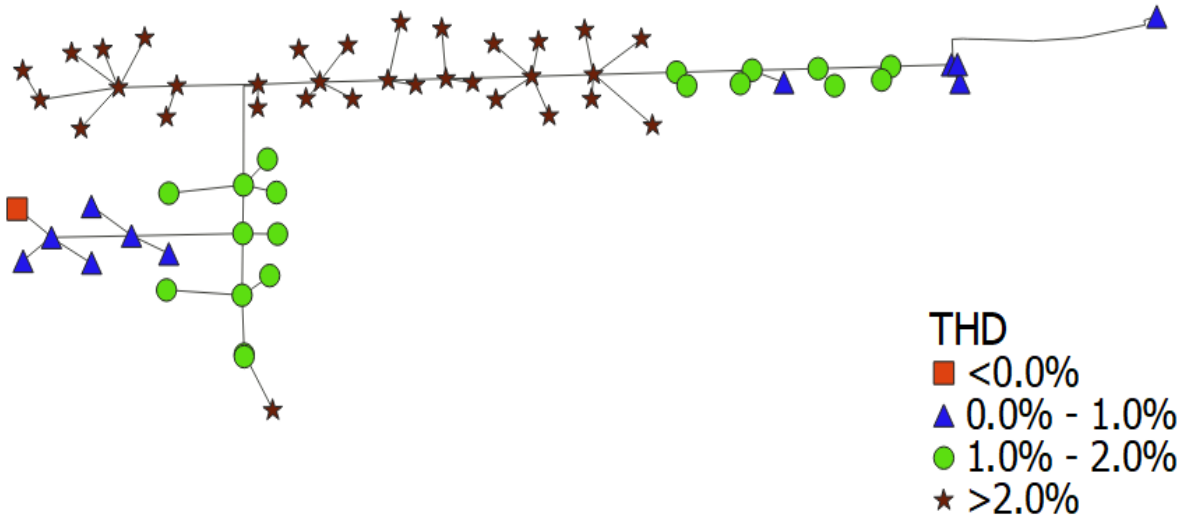

Slika 3. Vizualizacija promjene iznosa THD-a tijekom zatvaranja uzrokovanog pandemijom

Rad financiran je od strane Hrvatske zaklade za znanost i u suradnji s Operatorom distribucijskog sustava (HEP ODS d.o.o.) unutar projekta IMAGINE (PAR2018-12).

Predvidjeti = učinkovitije vođenje

- Razvoj prediktivne analitike nad podatcima preduvjet je učinkovitog vođenja,
- Primjer: razvoj alata za potrebe mreže punionice HEP d.d. kroz projekt bigEVdata (BigEVData)
- Razvijeno i implementirano 6 alata u stvarnom okruženju HEP-ove mreže punionica
  - Snimanje svih sesija punjenja u periodu od 3 godine
  - Snimanje specifičnosti ponašanja i tijekom „lockdown" perioda
  - Predviđanje potrošnje dan-unaprijed, korekcija unutardnevno
  - Razrada mogućih tarifa koje potiču učinovitije punjenje (premještanje u „povoljnije trenutke")
  - Razrada modela anomalija i detekcija „prevara"
  - Interakcija s krajnjim korisnicima kako bi se prikupile adekvatne informacije
  - Izrađena aplikacija za registraciju na punionicama -> buduća nadogradnja s mogućnostima personaliziranog pristupa krajnjem korisniku/vlasniku EV

Rad financiran je od strane Europskih strukturnih i investicijskih fondova (partneri HEP d.d. i NEOS) unutar projekta KK.01.2.01.0077 ***bigEVdata.***

bigEVdata projekt

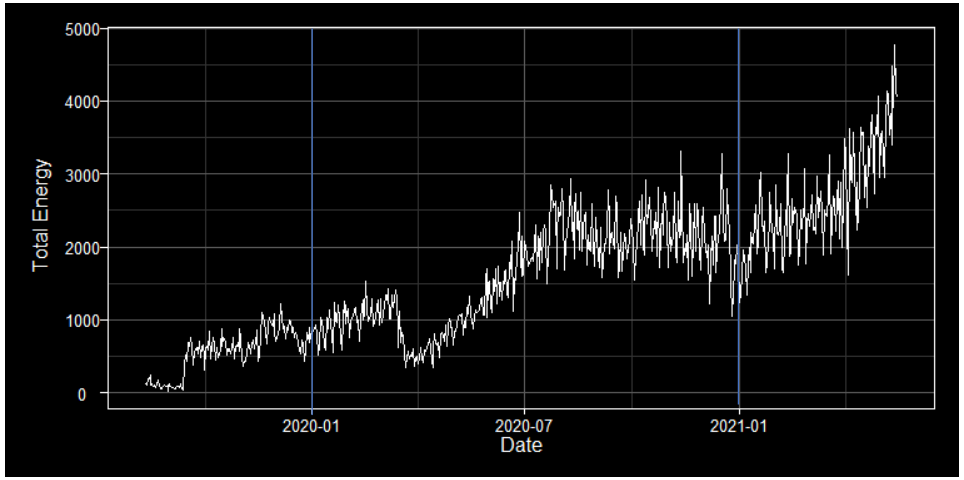

1. RAZVOJ PREDIKTIVNOG PRISTUPA
2. INTEGRACIJA U POSTOJEĆI PROCES
3. SKALABILNOST NA ŠIRU SLIKU POSLOVNIH JEDINICA

Poslovni ciljevi **bigEVdata projekta**

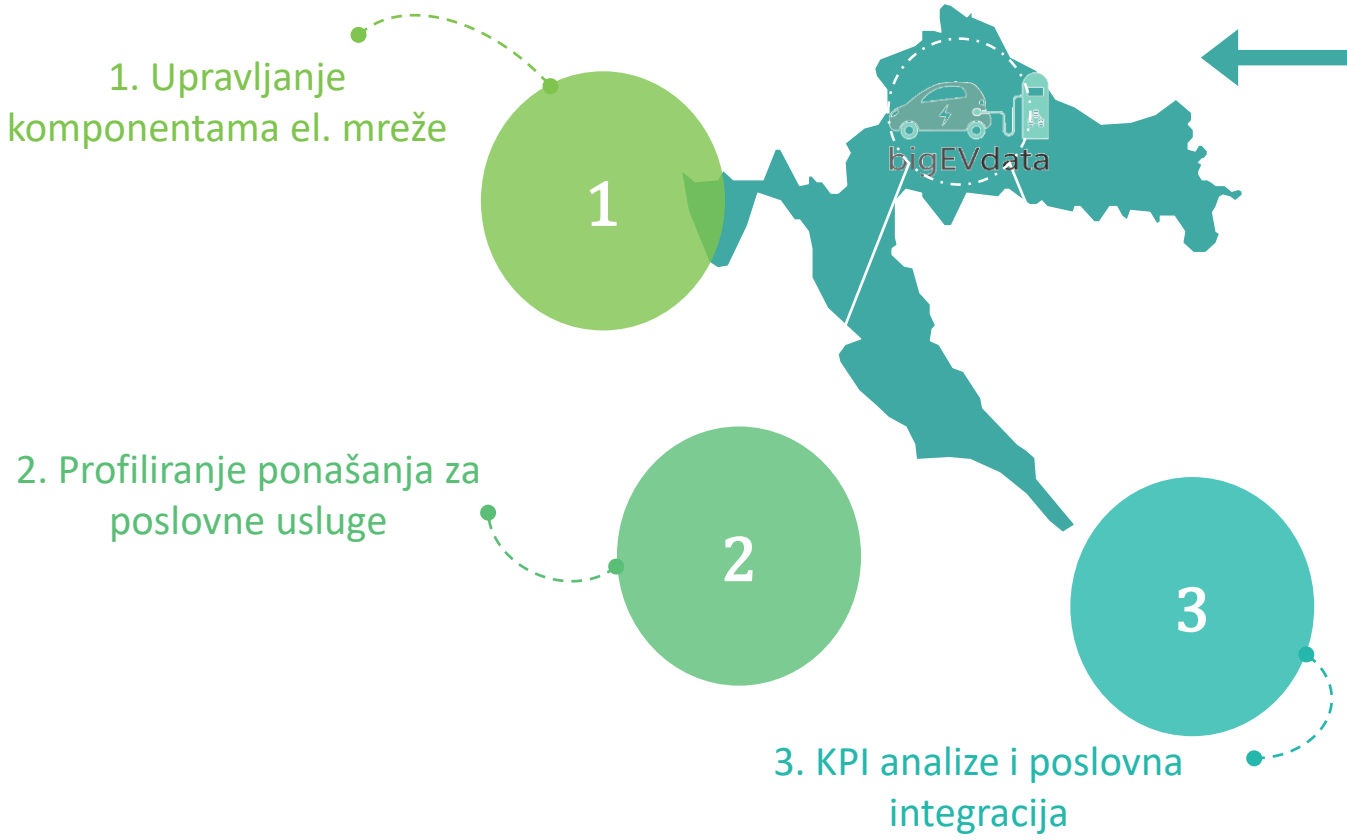

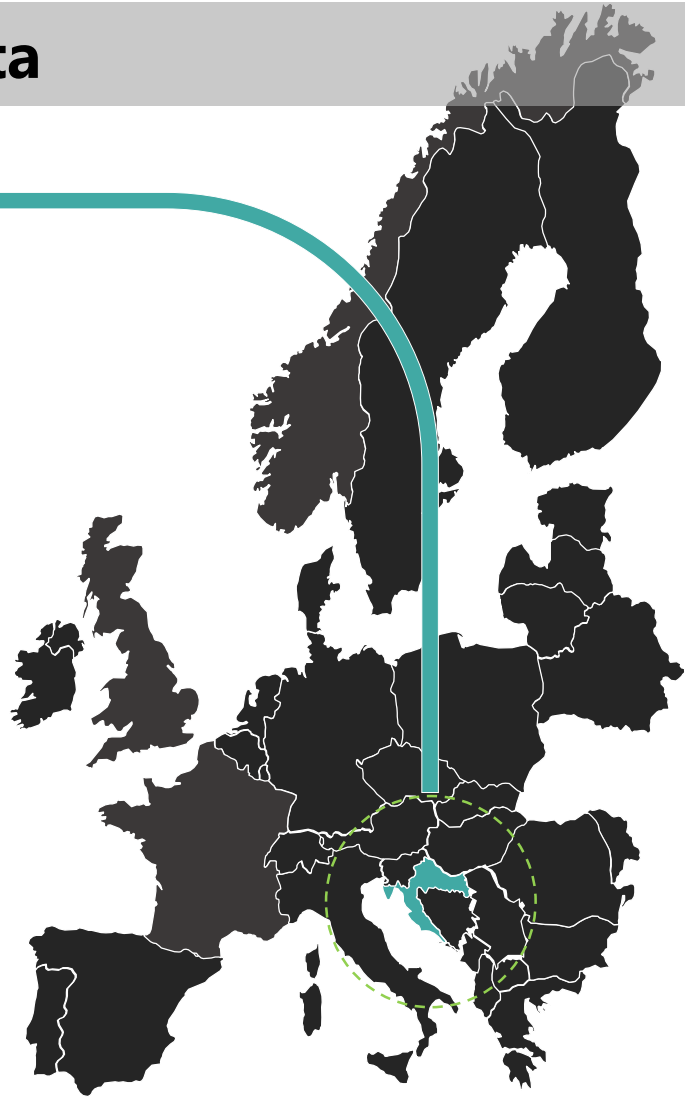

bigEVdata projekta

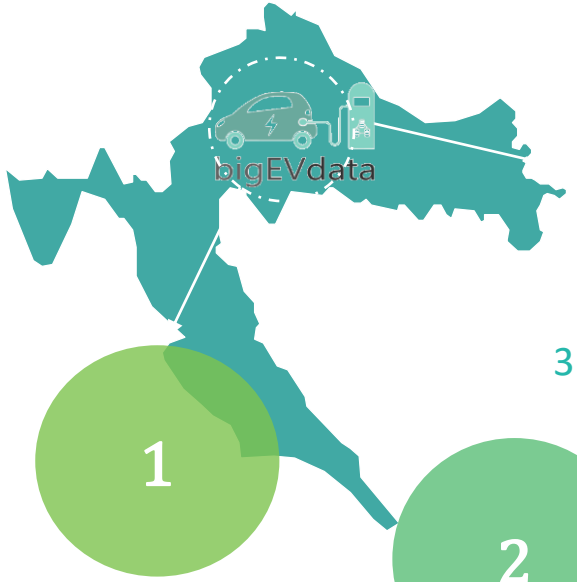

3

3. KPI analize i poslovna integracija

1

1. Upravljanje komponentama el. mreže

2

2. Profiliranje ponašanja za poslovne usluge

1. Framework za upravljanje infrastrukturom za punjenje

2. Tarife – strukture i opcije

3. Planiranje isporuke el. energije

4. Analiza ponašanja – nove usluge i proizvodi

5. Sezonalnosti punjenja – „Smart Charging"

6. Detekcije prijevara u sustavu - FRAUD

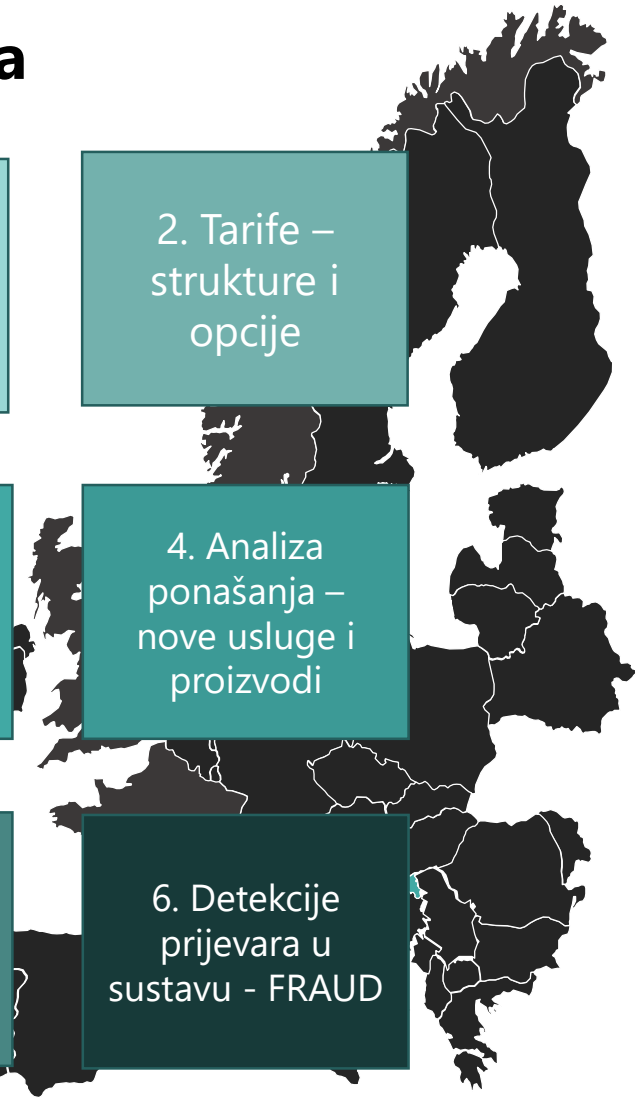

Istraživačke komponente **bigEVdata projekta**

1. Upravljanje infrastrukturom	2. Tarife	3. Isporuke el. energije	4. Analiza ponašanja	5. Smart Charging	6. FRAUD

Razrađene modularne komponente unutar bigEVdata projekta

Predviđanje "day-ahead" el. energije	Predviđanje br. vozila u sustavu	Globalne sezonalnosti EV mreže	Analiza tarifa susjednih zemalja	Predikcije lokacijskih područja	Detekcije anomalija sustava
Predviđanje satnog ponašanja EV mreže	Analiza ponašanja preference klijenata	Profili punionica – agregatne karakteristike	Smart Charging Tarifa - koncept	Risk profil ponašanja el. mreže	Adaptivne anomalije EV mreže
Profili dolaska-odlaska	Profili iskorištenosti punionica	Profili odstupanja sesija punjenja	Anomalije individualnih ponašanja	Odstupanje dolazaka na punionice	Anomalije punjenja pojedinih sesija

Šta smo razradili unutar **bigEVdata projekta?**

Globalni pristup analize

- Predikcije **ukupne energije EV mreže** u sljedećem danu?

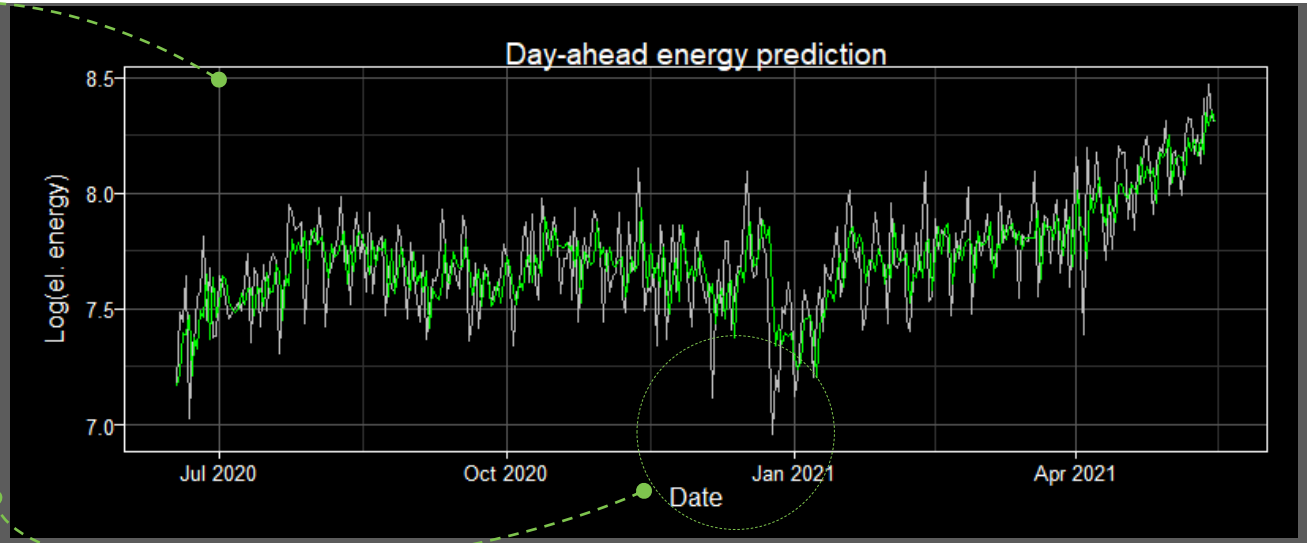

- **Detekcije odstupanja** od očekivanog ponašanja EV mreže?
- Detekcija iznenadne potražnje ili **odljeva klijenata** prema konkurentima?

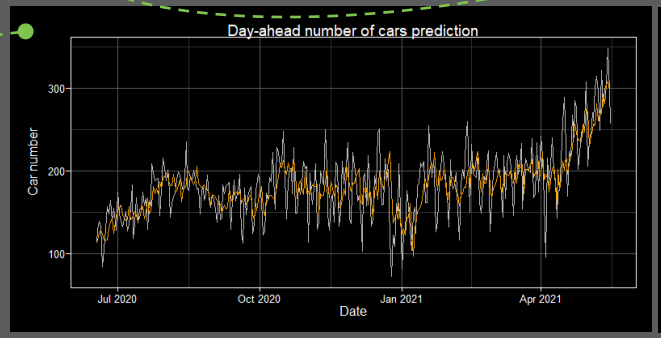

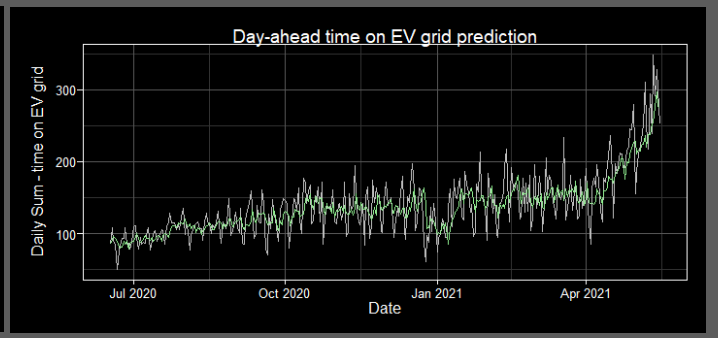

Operativni nadzor EV mreže na dnevnoj razini

Sustav predikcija EV mreže

Šta smo razradili unutar **bigEVdata projekta?**

Globalni pristup analize

- **Aktivno praćenje** i predikcije potrošnje EV mreže te same **konzistentnosti ponašanja** tijekom dana

3. Planiranje isporuke el. energije

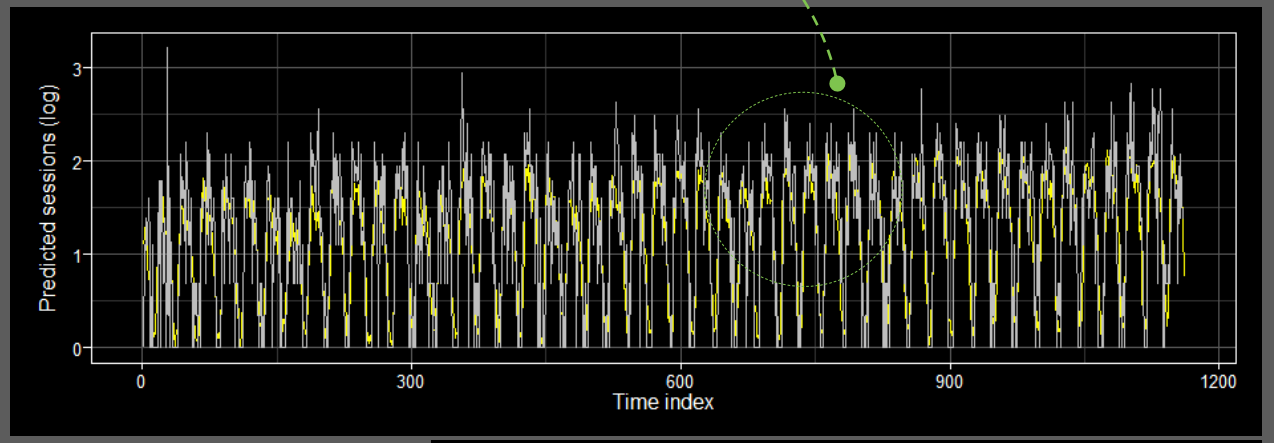

- **Aktivno praćenje** i predikcije potrošnje EV mreže – višestruka odstupanja konzistentno rade indikaciju na problem u EV mreži

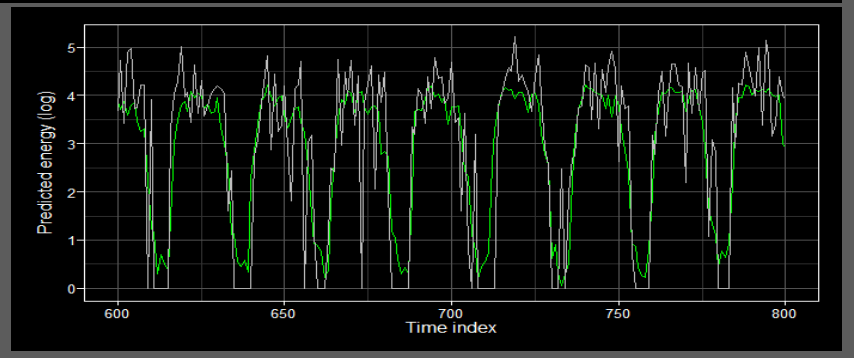

Live „HOURLY" tracking modul ponašanja EV mreže

Fleksibilni korisnici u naprednim EEM

- Agregator kao novi entitet koji „otključava” fleksibilnost krajnjih korisnika -> traži tržišne prilike, nudi fleksibilnost, stvara dodatnu vrijednost za sustav potičući krajnjeg korisnika na promjenu ponašanja
- Koristi za operatore sustava -> kroz pomoćne usluge (usluge fleksibilnosti)

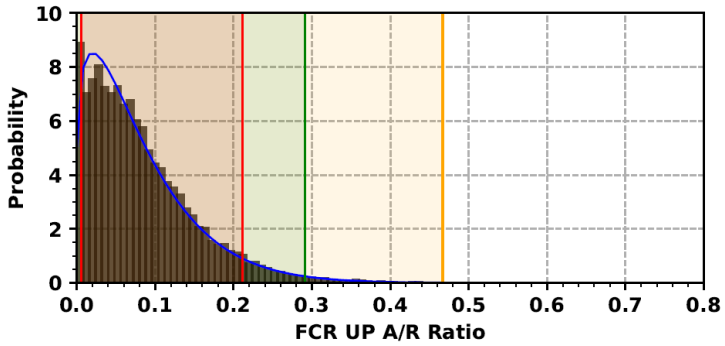

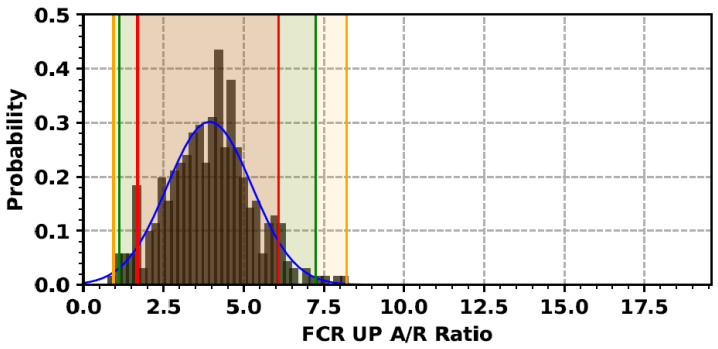

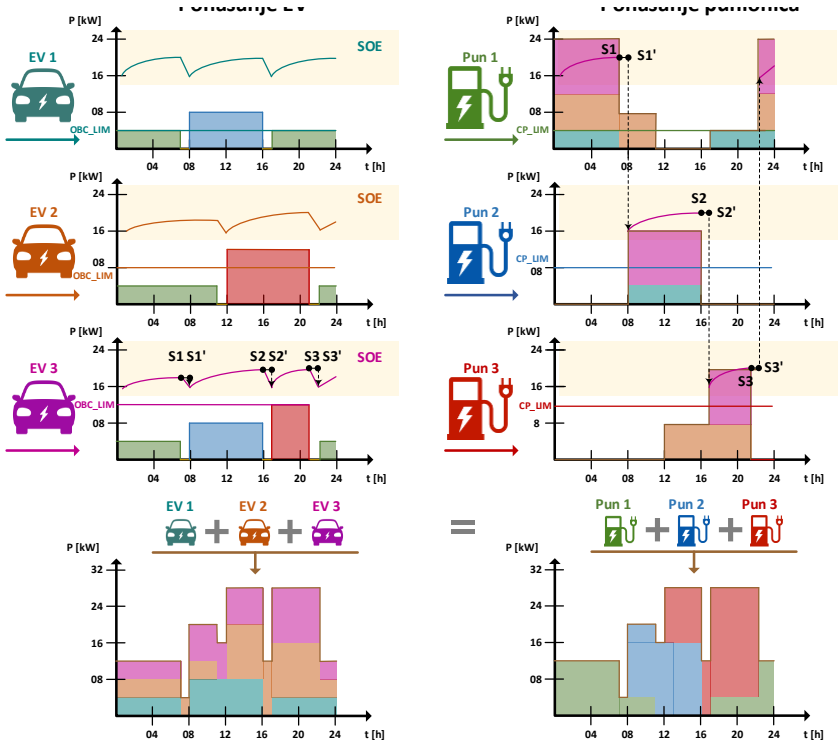

Novi alati za učinkovito vođenje

- Razvoj alata za napredno vođenje prijenosne i distribucijske mreže uz koordinaciju operatora sustava -> nužnost analize mogućnosti pružanja usluga fleksibilnosti od strane agregatora, ali i potreba operatora sustava u volatilnom okruženju niskuogljičnog sustava
- Temelje se na optimalnim tokovima djelatnih i jalovih snaga -> točni, nekonveksni modeli

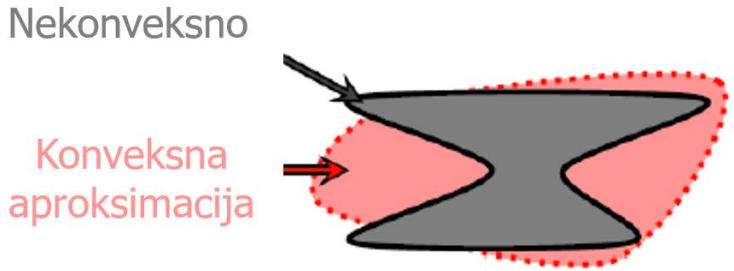

- Primjer: razvijen i implementiran alat za podešenja VVC funkcije u HOPSu -> in-house razvoj, jedan kod za sve solvere. Rezultati pokazuju i kraće vrijeme izvođenja i učinkovitije rezultate u kontekstu napona, gubitaka itd.

K. Šepetanc and H. Pandžić, "Convex Polar Second-Order Taylor Approximation of AC Power Flows: A Unit Commitment Study," IEEE Trans. Power Syst., vol. 36, no. 4, pp. 3585–3594, July 2021.

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

DU nabava pomoćnih usluga u distribucijskoj mreži

- Alat za minimizaciju operativnih troškova koji uzima u obzir troškove odstupanja OIE od planiranog rasporeda, troškove redispeča radne i jalove snage te troškove pružanja pomoćnih usluga za potrebe kontrole napona i lokalnog zagušenja u distribucijskoj mreži
- Stohastički viševremenski cjelobrojno mješoviti nelinearni model → dvorazinska dekompozicija

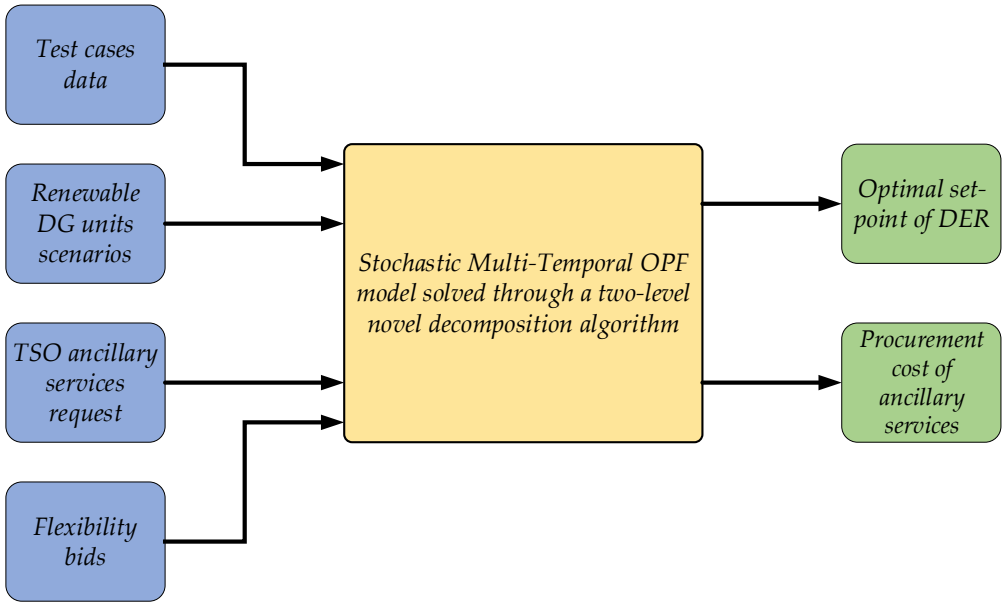

- Spremnici energije
- OLTC transformatori
- Fleksibilni tereti
- Ograničenje proizvodnje OIE
- Upravljanje javlovom snagom iz distribuiranih izvora

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

DU nabava pomoćnih usluga u prijenosnoj mreži

- Nabava pomoćnih usluga od strane OPS-a za kontrolu napona i upravljanje zagušenjima, osiguravanje N-1 kriterija u stvarnom vremenu te smanjenje nesigurnosti varijabilne proizvodnje OIE
- Stohastički viševremenski sigurnosno ograničen AC proračun optimalnih tokova snaga

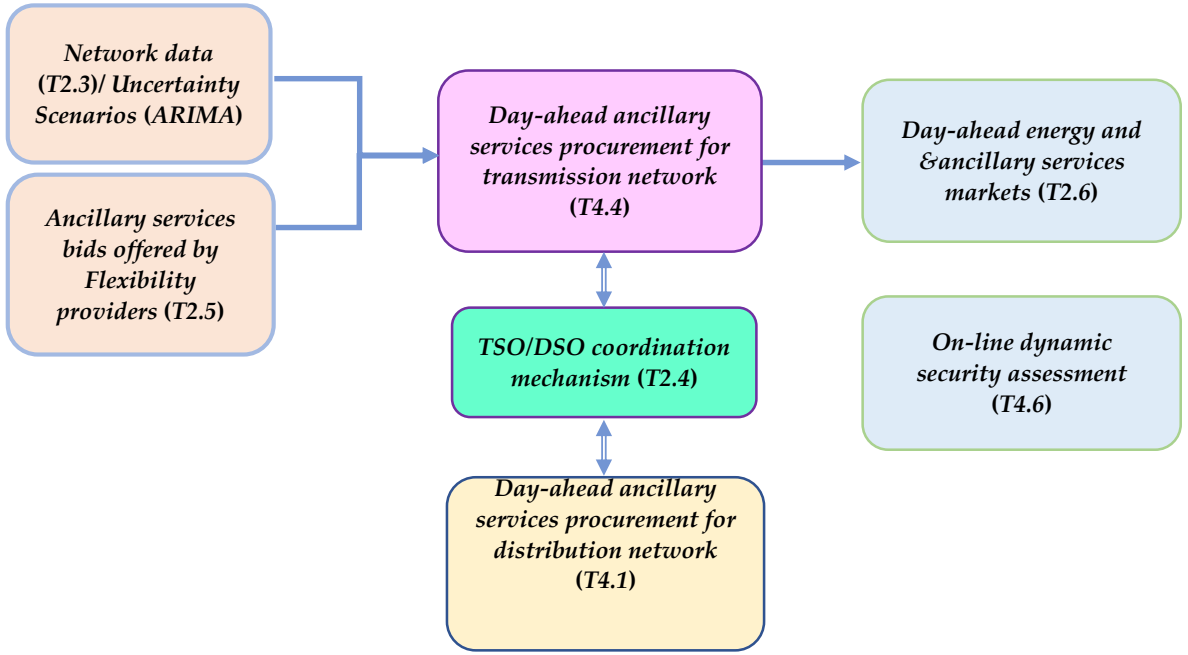

- Fleksibilni tereti i spremnici spojeni direktno na prijenosnu mrežu
- Fleksibilnost na OPS/ODS interkonekciji
- Dvorazinski model: radna snaga za upravljanje zagušenjima u prvom koraku te jalova snaga za kontrolu napona u drugom

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

Koordinacija operatora sustava

- Pružanje usluga od strane distribuiranih izvora zahtijeva koordinaciju između operatora sustava kako bi se izbjeglo aktiviranje suprotnih usluga te osiguralo zadovoljenje svih ograničenja u mreži
- Podijeljena u dvije faze: dan-unaprijed rezervacija pomoćnih usluga i aktivacija u stvarnom vremenu
- Usluge vezane za radnu i jalovu snagu su podijeljene u dva koraka zbog složenosti cjenovnih mehanizama
- OPS ima prednost pri rezervaciji usluga te je dužan nadokanditi ODS-u suboptimalno vođenje mreže s financijske strane

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

DU rezervacija pomoćnih usluga

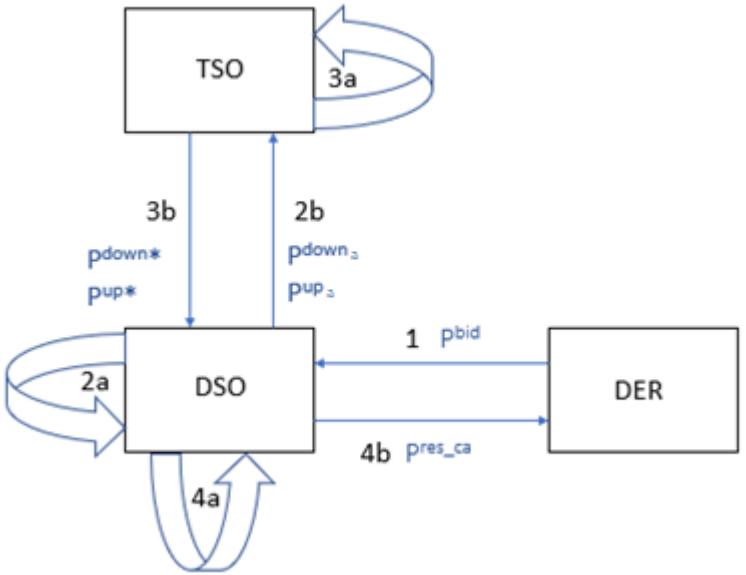

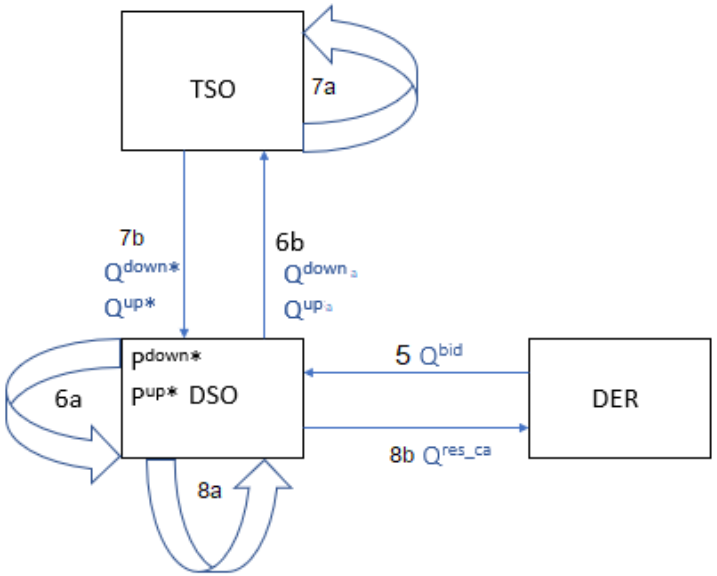

- Distribuirani izvori predaju svoje ponude ODS-u koji provjerava narušava li njihova aktivacija ograničenja u distribucijskoj mreži
- Ponude koje su prošle fazu prekvalifikacije predaju se globalnom tržištu kojim upravlja OPS
- OPS čisti globalno tržište (AC OPF) te šalje povratnu informaciju ODS-u rezervirajući potrebne distribuirane izvore
- ODS čisti lokalno tržište uzimajući u obzir zahtjev od strane OPS-a
- U drugom koraku postupak se ponavlja za jalovu snagu pri čemu je unaprijed rezervirana rezerva djelatne snage fiksna

Aktivacija u stvarnom vremenu

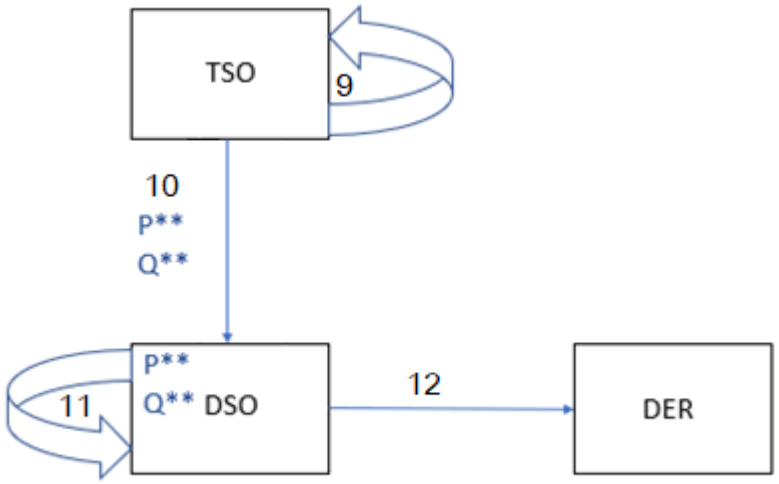

- Na temelju SC-AC OPF-a OPS šalje zahtjev za aktivacijom pomoćnih usluga ODSu
- ODS s fiksnim vrijednostima P** i Q** izvršava AC OPF u distribucijskoj mreži i određuje potrebnu aktivaciju rezerve za rješavanje problema lokalnog zagušenja ili odstupanja napona

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

Aktivacija PU u realnom vremenu u distribucijskoj i prijenosnoj mreži

- Alat za aktivaciju pomoćnih usluga u distribucijskoj mreži zaprima zahtjev od prijenosne mreže kako bi aktivirao potrebne izvore fleskibilnosti istovremeno zadovaljavajući ograničenja na razini distribucije
- Alat za aktivaciju pomoćnih usluga u prijenosnoj mreži aktivira se u slučaju odstupanja od dan-unaprijed plana, nakon kvara ili u slučaju primitka signala od strane alata za online procjenu sigurnosti koji detektira nesigurno pogonsko stanje

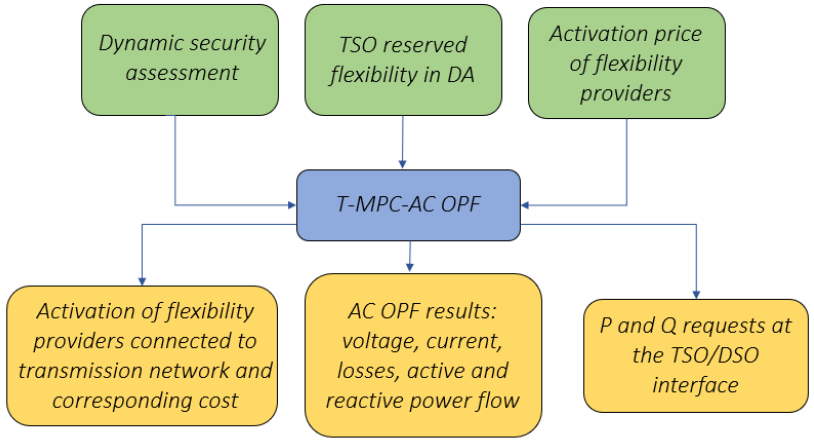

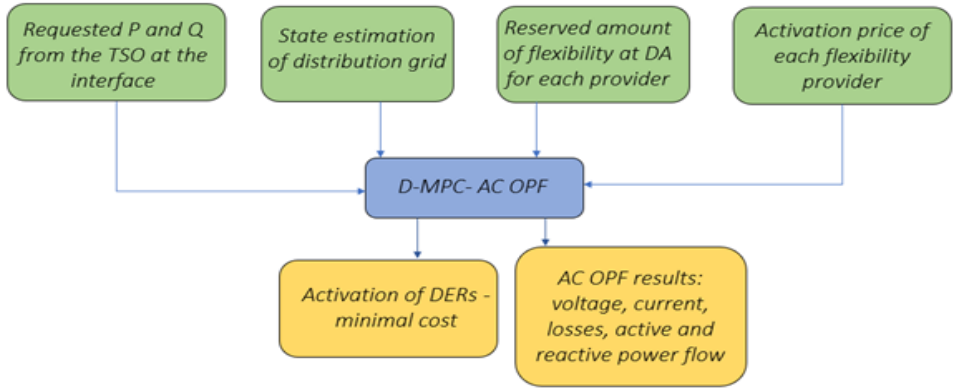

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

Aktivacija PU u realnom vremenu u distribucijskoj i prijenosnoj mreži

- AC OPF modeli koriste modelno-prediktivo upravljanje s ciljem minimizacije odstupanja od dan-unaprijed predviđene aktivacije pomoćnih usluga osiguravajući zadovoljenje svih mrežnih ograničenja, a samim time i siguran rad elektroenergetskog sustava.
- Stohastički MPC pristup:
  - scenarij visoke potrošnje i scenarij niske potrošnje
  - MPC uzima u obzir 4 vremenska trenutka, jedan sadašnji (podaci dolaze od estimatora stanja) i tri uzastopna 15-minutna intervala → nadolazeći vremenski trenutci modeliraju potrošnju množeći trenutni iznos s rastućom vrijednosti faktora potrošnje

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

Estimator stanja

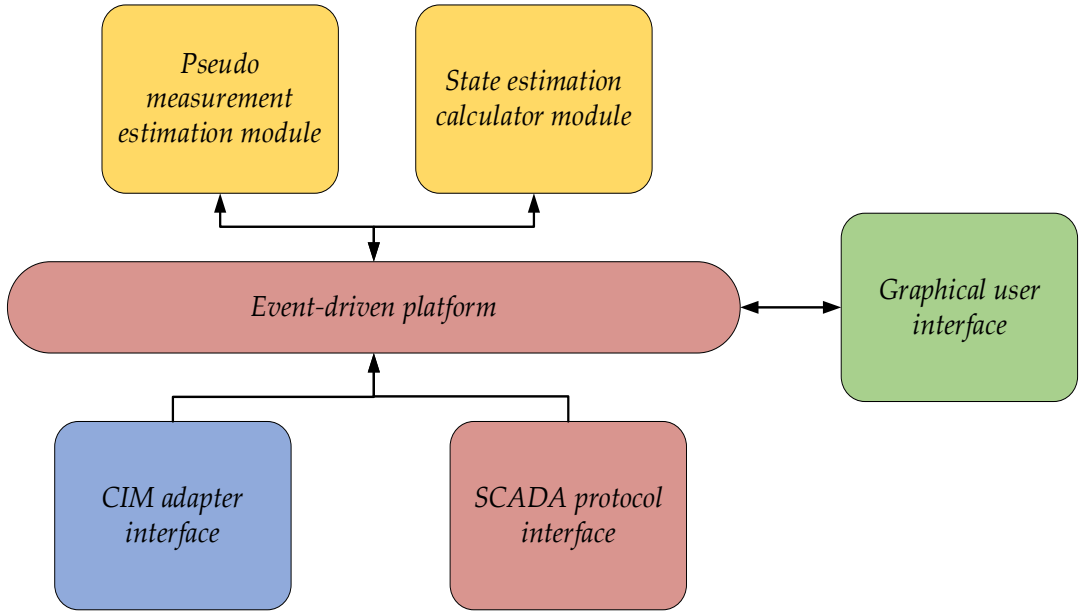

- Estimacija stanja predstavlja proračun najvjerojatnijeg stanja u mreži na temelju prikupljenih podataka iz stvarnog sustava
- Kod distribucijskih mreža glavni je problem nedostatak stvarnih mjerenja → vrlo važna uloga same estimacije
- U SN mrežama koristi se tzv. kalibracija potrošnje (predviđanje injekcija jalove i djelatne snage na čvorištima terete na temelju postojećih podataka o mreži)
- Platforma razvijena od strane Končara – podržava komunikacijkse protokole koji dohvaćaju "žive" podatke iz SCADA sustava

Rad financiran je od strane Obzor 2020 unutar projekta No 864298 (projekt ATTEST).

Online procjena sigurnosti

- Off-line konvencionalan pristup za dnevne operacije vrlo spor
- Dinamička procjena sigurnosti
  - Uzima se prikaz trenutnog stanja sustava te se radi detaljna analiza sigurnosti u skoro realnom vremenu → automatska kontrola

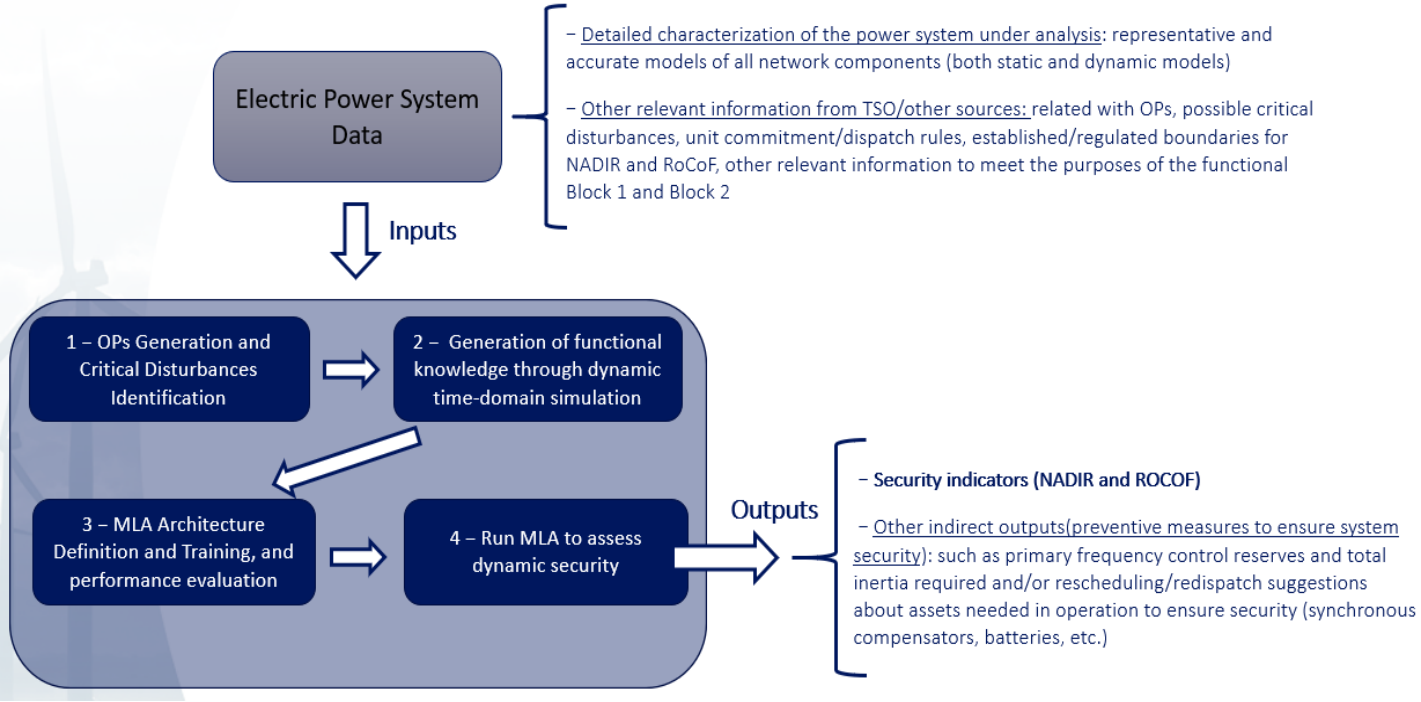

- Alat se temelji na metologiji umjetne inteligencije te će davati ulazne podatke za upravljanje sustavom u realnom vremenu od strane OPS-a
- Definirat će potreban volumen inercije i rezervu za primarnu regulaciju frekvencije

Testiranje razvijenih koordiniranih alata operatora sustava

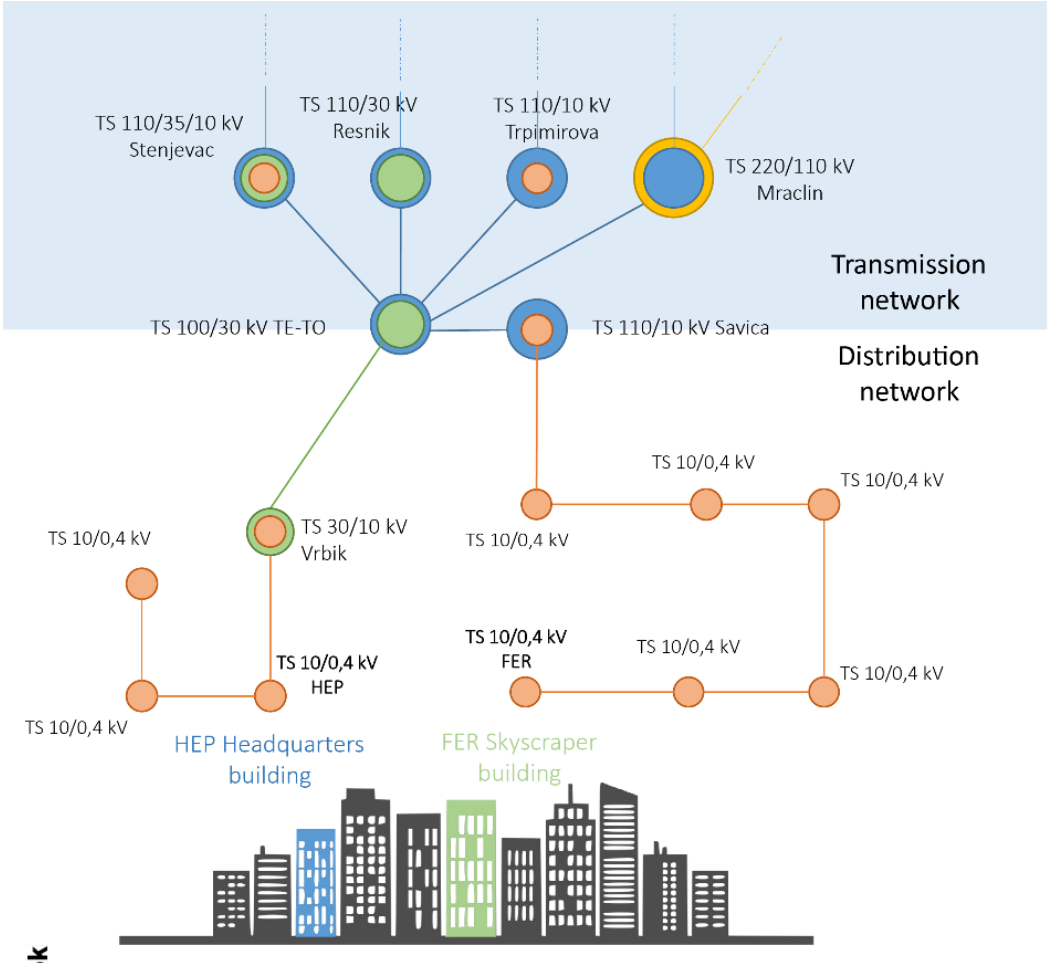

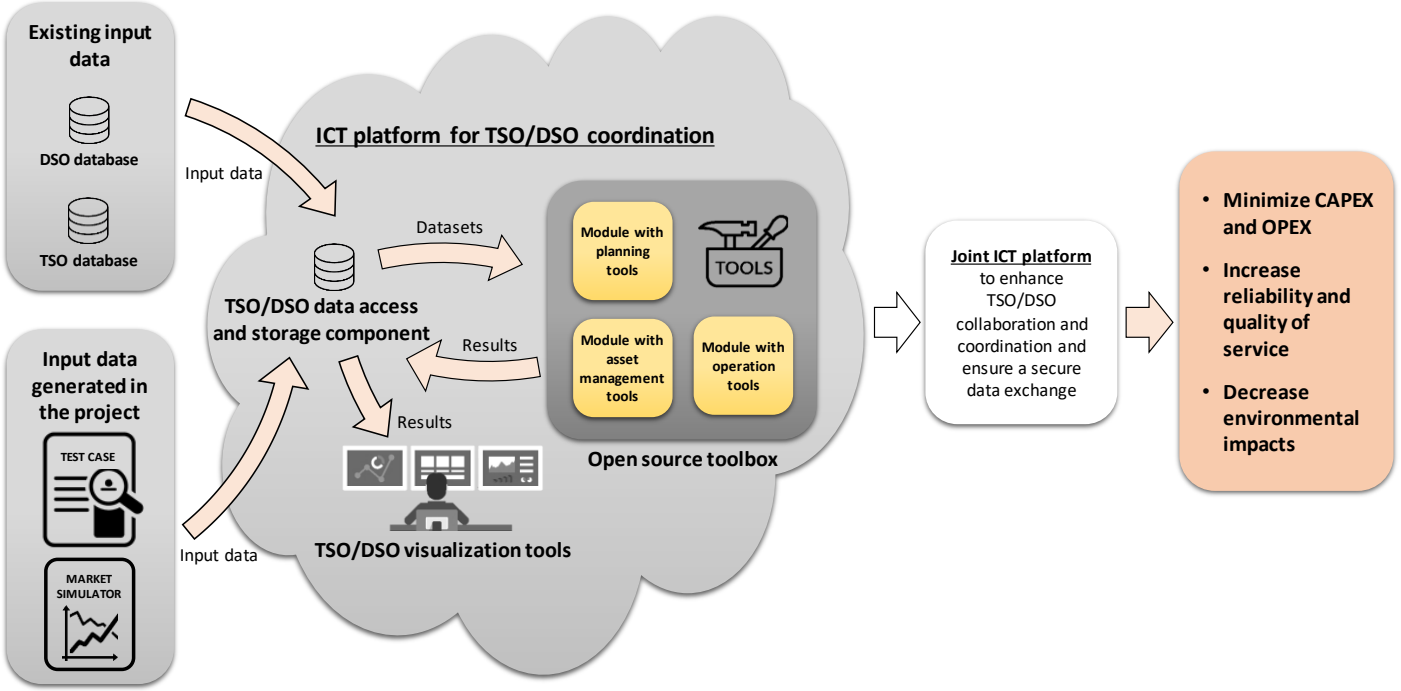

/Zavod za visok i energetiku

Hvala na pozornosti

tomislav.capuder@fer.hr