

# Primjena umjetne inteligencije u elektroenergetskom sustavu

Doc. dr. sc. Adrian Satja Kurdija

Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva

17



**SAVJETOVANJE HRO CIGRE**  
**HRO CIGRE SESSION**  
ŠIBENIK, 9.-12. STUDENOGA 2025./NOVEMBER 9-12, 2025



# AI i energetika: usporedni razvoj

Period	Računarstvo i AI	Energetika	Primjene
1970-e i 1980-e	Ekspertni sustavi: programiranje pravila (ako ..., onda ...)	Rana automatizacija elektroenergetskih mreža	Dijagnostika kvara Raspodjela opterećenja Koordinacija zaštite
1990-e i 2000-e	Strojno učenje Optimizacijski algoritmi	SCADA nadzorno-upravljački sustav EMS/DMS sustavi	<i>Data-driven</i> odlučivanje za planiranje proizvodnje i stabilnost napona
2010-e	Duboko učenje Analitika velikih podataka ( <i>Big Data</i> )	Integracija obnovljivih izvora Mikromreže	Predviđanje opterećenja i proizvodnje iz vjetrova/sunca Prediktivno održavanje
2020-e	<i>Cloud/edge computing</i> Generativna AI	Internet stvari (IoT) Pametni senzori 5G komunikacija Električna vozila	Upravljanje u stvarnom vremenu Adaptivna potrošnja Distribuirano upravljanje resursima

# Paradigme strojnog učenja

## Nadzirano učenje

- Algoritmi se treniraju (automatski podešavaju) na parovima *ulaz, izlaz*

### Primjeri ulaza:

SCADA mjerenja - podaci iz trafostanica, dalekovoda i postrojenja  
PMU mjerenja - fazorski podaci (napon, struja, faza)  
AMI mjerenja - pametna brojila  
Podaci o vremenskim uvjetima

### Primjeri izlaza:

Prognoza potrošnje i opterećenja  
Prognoza energije iz obnovljivih izvora  
Dinamička prognoza cijene  
Klasifikacija stanja (*benigno, kvar, krađa, napad...*)  
Postavke napona i reaktivne snage (volt/VAR optimizacija)

# Paradigme strojnog učenja

## Nenadzirano učenje

- Algoritam sam prepoznaje odnose među podacima
- Primjeri:
  - Segmentacija (razvrstavanje) potrošača prema ponašanju
    - → optimizacija upravljanja potrošnjom (*demand response*)
  - Rekonstrukcija topologije mreže
  - Otkrivanje anomalija
    - Rani znakovi kvara
      - prediktivno održavanje
    - Kibernetički napadi
    - Krađa energije


# Paradigme strojnog učenja

## Podržano učenje

- Agent uči metodom pokušaja i pogreške
- Okruženje → **akcija** → nagrada/kazna
- Prilagođava parametre na temelju povratnih informacija u stvarnom vremenu
- Primjeri:
  - Zatvoreni sustav upravljanja potrošnjom
  - Raspored proizvodnje u mikromrežama
  - Upravljanje punjenjem/praznjenjem pohrane
  - Optimalan tok snage pod varijabilnim obnovljivim izvorima
  - Dinamičko određivanje cijena

# Primjer AI algoritma


- U širokoj uporabi od sredine 2010-ih
- XGBoost: *eXtreme Gradient Boosting*
- Kombinira veći broj *stabala odlučivanja*
- Hvata nelinearne odnose
- Brz, učinkovit, robustan
- Interpretabilnost: analiza važnosti ulaznih varijabli
- Primjene:
  - Prognoza potrošnje i proizvodnje, posebno za solar i vjetar
  - Prediktivno održavanje (vjerojatnost kvara)
  - Tržišne prognoze



Izvor: Öztornaci, Burak & Ata, Baris & Kartal, Serkan. (2024). Analysing Household Food Consumption in Turkey Using Machine Learning Techniques. *Agris on-line Papers in Economics and Informatics*. 16. 97-105. 10.7160/aol.2024.160207.

# Duboko učenje

- Različite arhitekture za različite vrste podataka
- Konvolucijske neuronske mreže (CNN)
  - Prepoznaju **prostorne** strukture: topologiju i spregnutost vodova
- Rekurentne neuronske mreže (RNN, LSTM)
  - Modeliraju **vremenske** obrasce
- Transformerske neuronske mreže
  - Razumiju odnose u **nizovima** podataka



# Transformerske neuronske mreže

- Koriste mehanizam pozornosti (*attention*)
  - Uče koliko je svaki podatak u nizu važan u odnosu na svaki drugi
- Jezični modeli (GPT-x)
  - Razumiju odnose među riječima u tekstu
- Moguće ih je prilagoditi da pretvaraju namjere operatera u pozive funkcija
  - Upiti nad podacima
  - Dijagnostika
  - Verificirane kontrolne naredbe
  - “Smanji naponska odstupanja na distribucijskom vodu 7 prije vršnog opterećenja”

# Temporal Fusion Transformer (TFT)

- Transformerska neuronska mreža za vremenske nizove
- Predviđa varijable u više budućih koraka (*multi-horizon*)
- Istovremeno obrađuje više izvora raznovrsnih podataka
- Interpretabilnost: identificira varijable koje najviše utječu na rezultat
- Može naučiti:
  - kako promjena temperature ujutro utječe na potrošnju popodne
  - kako oblačnost u 10h smanjuje solar u 12h
  - kako dan u tjednu mijenja obrasce potrošnje.

# Sigurnosni izazovi

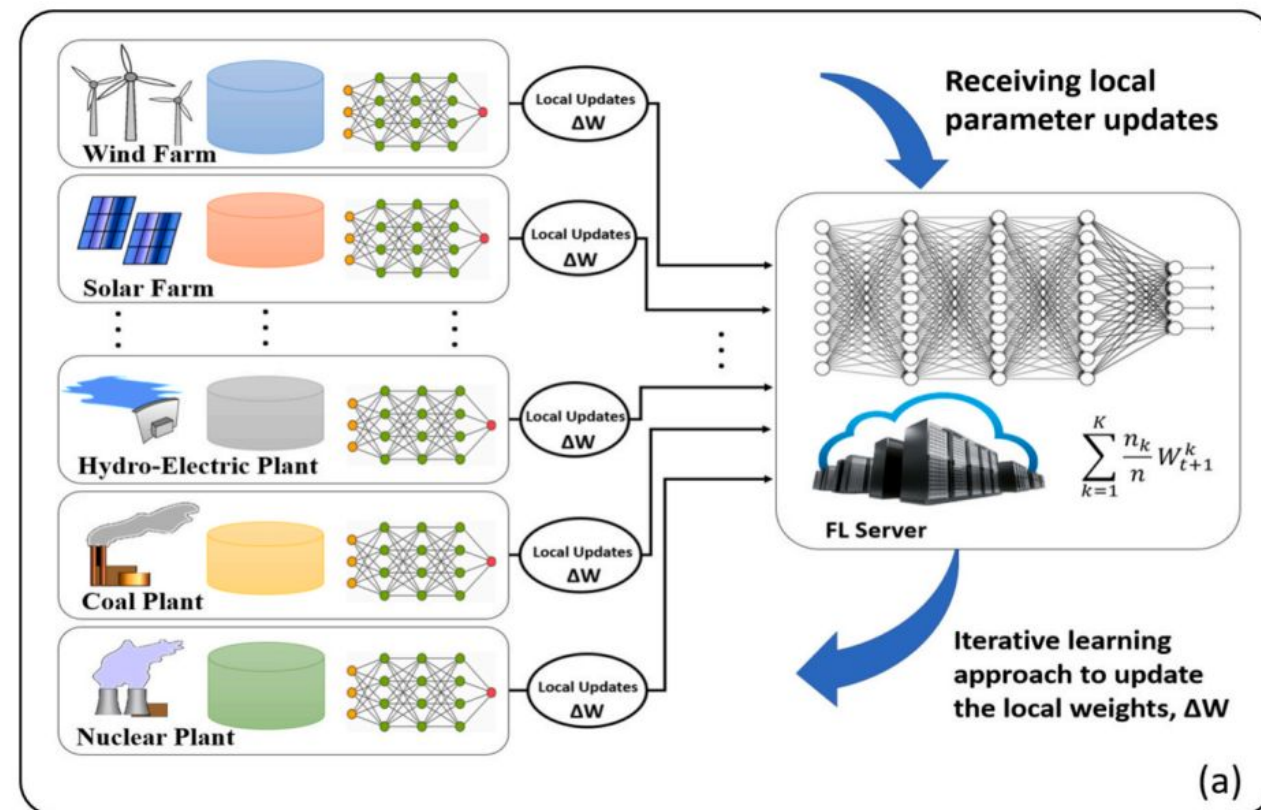
- AI sustavi moraju biti izolirani od kritičnih operativnih mreža kako bi se spriječili kibernetički napadi
- AI modeli integriraju se putem API sučelja sa SCADA/EMS sustavima za davanje preporuka u stvarnom vremenu
- Zahtjeva se standardizirani API i ograničeni pristup
- Princip *human-in-the-loop*: konačne odluke donose ljudi, posebno u kritičnim situacijama
- Redoviti testovi otpornosti i simulacije incidenata
- Integracija s AMI zahtijeva anonimizaciju i agregaciju podataka radi zaštite privatnosti

# MLOps – upravljanje AI modelima

- Modeli se razvijaju u sandbox okruženjima i tek nakon validacije prelaze u operativno (MLOps) okruženje
- Uključuje verzioniranje modela, nadzor performansi, automatsko ponovno treniranje i rollback mogućnosti
- Sustavi prate točnost modela, ulazne podatke i promjene u distribuciji podataka (*data drift*, zastarjeli podaci)
- Svi pristupi i promjene nad modelima moraju se bilježiti u audit logovima
- Alarmi se pokreću kada model počne davati pogrešne ili nepredvidive rezultate

# Federalno učenje

- *Kako osigurati točno predviđanje i upravljanje čuvajući privatnost i sigurnost podataka?*
- Učenje je decentralizirano
- Kopije modela ažuriraju se na lokalnim podacima
- Server ne vidi lokalne podatke
- Razmjenjuju se samo parametri modela



Izvor: Banad, Yaser & Sharif, Sarah & Rezaei, Zahra. (2025). Artificial intelligence and machine learning for smart grids: from foundational paradigms to emerging technologies with digital twin and large language model-driven intelligence. Energy Conversion and Management: X. 28. 101329. 10.1016/j.ecmx.2025.101329.

# Digitalni blizanac

- Engl. *Digital Twin* (DT)
- Virtualna replika fizičkog sustava
- Podaci se sinkroniziraju u stvarnom vremenu
- Omogućuje:
  - podatkovnu integraciju više sustava kroz otvorene standarde (npr. OPS-ODS)
  - koordinirano praćenje i upravljanje
  - simulacije (što-ako) i optimizacije

# Regulatorni okvir

- **EU AI Act:** puna primjena od kolovoza 2026.
- Opskrba i upravljanje kritičnom infrastrukturom (energetika) spadaju u visokorizične AI sustave
- Podliježe zahtjevima za upravljanje rizicima, dokumentaciju, klasifikaciju, testiranja i stalni nadzor
- Svi AI sustavi moraju imati dokumentaciju o upotrebi i kvaliteti podataka, uključujući tehničke detalje, praćenje izvora podataka i mjerenje energetske učinkovitosti modela

# Regulatorni okvir

- **NIS2: direktiva EU o kibernetičkoj sigurnosti**
- Energetski sektor klasificiran je kao “ključan” te su na snazi najstroži zahtjevi za kibernetičku sigurnost, upravljanje incidentima, izvješćivanje i otpornost sustava
- Nacionalni nadzor: Hrvatska energetska regulatorna agencija (HERA)
- AI rješenja koja obrađuju **osobne podatke** moraju biti u skladu s **GDPR**-om: privatnost po dizajnu, ograničavanje obrade i transparentnost prema korisnicima

# Regulatorni okvir

- **ENTSO-E** (Europska mreža operatora prijenosnih sustava za električnu energiju, uključuje HOPS)
- Dokument od 7. studenog 2025.: *Response to the European Commission Call for Evidence on the Strategic Roadmap for Digitalisation and Artificial Intelligence*
- Navodi osam prioriteta u kontekstu digitalizacije i umjetne inteligencije za siguran i učinkovit energetska sustav
  - Izgradnja operativnog europskog energetska podatkovnog prostora
  - Federirani digitalni blizanci za upravljanje sustavom i otpornost
  - Siguran i odgovoran AI u energetska operacijama
  - Digitalna infrastruktura: data centri i visokoučinkovito računarstvo
  - ...

Hvala na  
pažnji!

17



**SAVJETOVANJE HRO CIGRE**  
**HRO CIGRE SESSION**  
ŠIBENIK, 9.-12. STUDENOGA 2025./NOVEMBER 9-12, 2025

