

## ***Analiza napovedovanja porabe in koriščenja prožnosti flote HEMS v projektu OPENTUNITY***

Janez Gregor Golja<sup>1</sup>, dr. Tomi Medved<sup>1</sup>, Tomaž Buh<sup>2</sup>, dr. Edin Lakić<sup>3</sup>

<sup>1</sup> – Univerza v Ljubljani, Fakulteta za elektrotehniko, Laboratorij za energetske strategije, Tržaška c. 25, 1000 Ljubljana  
[janezgregor.golja@fe.uni-lj.si](mailto:janezgregor.golja@fe.uni-lj.si), [tomi.medved@fe.uni-lj.si](mailto:tomi.medved@fe.uni-lj.si)

<sup>2</sup> – Amibit, energetski sistemi, d.o.o., Šaleška 2A, 3320 Velenje  
[tomaz.buh@reduxi.eu](mailto:tomaz.buh@reduxi.eu)

<sup>3</sup> – Inovacijsko-razvojni inštitut Univerze v Ljubljani, Kongresni trg 12, 1000 Ljubljana  
[edin.lakic@iri.uni-lj.si](mailto:edin.lakic@iri.uni-lj.si)

**Povzetek** – Pospešena elektrifikacija in rast deleža obnovljivih virov v distribucijskem omrežju predstavljata izziv za stabilnost omrežja, saj povečujeta konične obremenitve. Hkrati pa te tehnologije omogočajo prilagodljivo delovanje, kar je mogoče izkoristiti za optimizacijo stroškov in sodelovanje na energetskih trgih. Ključno vlogo pri tem imajo sistemi za upravljanje energije v gospodinjstvih (angl. *Home Energy Management Systems* – HEMS), ki omogočajo pametno upravljanje različnih naprav in izkoriščanje njihove prožnosti. Projekt OPENTUNITY z uporabo naprednih metodologij in interoperabilne programske opreme podpira energetske akterje, vključno z operaterji omrežij in aktivnimi odjemalci. Eden njegovih ključnih ciljev je izkoriščanje prožnosti različnih virov. V okviru slovenskega pilota so vključeni flota polnilnic za električna vozila (angl. *Electric Vehicles* – EVs) ter HEMS-sistemi podjetja Amibit, ki omogočajo povezovanje različnih naprav in optimizacijo njihove porabe. V prvi fazi projekta smo zbrane operativne podatke uporabili za razvoj naprednih napovednih modelov porabe in proizvodnje. Prispevek opisuje celoten proces – od zbiranja in priprave podatkov do uporabe naprednih napovednih metod. Poleg tega analizira rezultate dveh izbranih metod, jih primerja ter ocenjuje njihove možnosti za praktično uporabo.

**Ključne besede:** Napovedovanje porabe, sistem za upravljanje energije v domovih, strojno učenje, prožnost

## ***Analysis of load forecasting and flexibility utilization of the HEMS fleet in the OPENTUNITY project***

**Abstract** –The accelerated electrification and increasing share of renewable energy sources in the distribution grid present a challenge to grid stability, as they contribute to higher peak loads. However, these technologies also enable operational flexibility, which can be used to optimize costs and participate in energy markets. A key enabler in this process is the Home Energy Management System (HEMS), which facilitates smart control of various devices and thus unlocking their flexibility potential. The OPENTUNITY project supports energy stakeholders, including grid operators and active consumers, by employing advanced methodologies and interoperable software solutions. One of the key objectives of the project is to unlock and utilize flexibility from various sources. The Slovenian pilot includes a fleet of EV charging stations and vehicles, as well as Reduxi HEMS device by Amibit, which enable the integration of different devices and the optimization of their energy consumption. In the first phase of the project, collected operational data was used to develop forecasting models for energy consumption and production. This paper describes the entire process—from data collection and preparation to the application of advanced forecasting methods. Additionally, it analyses the results of two selected forecasting approaches, comparing their performance and exploring their practical applicability.

**Keywords:** Load forecasting, home energy management system, machine learning, flexibility

## 1 UVOD

Elektrifikacija različnih sektorjev, kot sta mobilnost (električna vozila - EV) in ogrevanje (toplotne črpalke - TČ), ter hitro naraščajoč delež razpršene proizvodnje, zlasti iz sončnih elektrarn (SE), povzročata velike spremembe v elektroenergetskem omrežju. Najbolj so pri tem prizadeti nizkonapetostni deli distribucijskih omrežij, kjer se pričakujejo pogostejše in intenzivnejše konične obremenitve ter težave pri ohranjanju napetosti znotraj dovoljenih mej [1]. V Sloveniji in drugih evropskih državah bo zato nujna obsežna nadgradnja distribucijskih omrežij, kar prinaša tako ekonomske kot logistične izzive. Države se na ta izzive odzivajo na različne načine – v Sloveniji je tako prišlo do uvedbe novega omrežninskega akta, ki bo operaterjem distribucijskega omrežja zagotovil dodatna finančna sredstva za potrebne nadgradnje omrežja. Kljub tem izzivom pa omenjene tehnologije ponujajo tudi nove priložnosti. Zaradi prilagodljivosti svojega delovanja oziroma prožnosti lahko prilagajajo delovanje glede na cenovne ali tržne signale, kar odjemalcem predstavlja možnost optimizacije njihove porabe in tako znižanja stroškov električne energije, operaterjem omrežja pa priložnost za stabilnejše delovanje omrežja.

## 2 PROJEKT OPENTUNITY

Evropski projekt OPENTUNITY [2], sofinanciran s strani programa Obzorje Evrope (angl. *Horizon Europe*) je zasnovan za podporo različnim akterjem v energetskem ekosistemu, kot so agregatorji, operaterji omrežja in aktivni odjemalci. Glavni cilj projekta je razvoj inovativnih rešitev, ki bodo testirane v štirih državah in različnih okoljih. Ena ključnih inovacij je razvoj orodja za »optimalno izbiro prožnosti« (angl. *optimal selection of available flexibility*), ki agregatorjem omogoča izbiro najprimernejših prožnih enot za aktivacijo. V okviru slovenskega pilota sta vključena dva vira prožnosti: flota EV in polnilnic podjetja Avantcar, ter flota sistemov za upravljanje energije (angl. *Home Energy Management Systems – HEMS*) Reduxi podjetja Amibit [3]. V prvi fazi projekta smo se osredotočili na integracijo naprav v agregacijsko platformo ter zbiranje in analizo podatkov, ki so bili uporabljeni za razvoj napovednih modelov porabe. Natančne napovedi omogočajo učinkovitejšo načrtovanje delovanja naprav ter optimizacijo uporabe prožnosti, kar prispeva k zmanjšanju stroškov in učinkovitejšemu upravljanju porabe energije. Poleg tega izboljšujejo stabilnost elektroenergetskega omrežja, saj omogočajo natančnejše usklajevanje proizvodnje in porabe v realnem času.

## 3 METODOLOGIJA

V tem poglavju je predstavljena uporabljena metodologija, ki zajema pregled različnih napovedovalnih metod, opis izbranih pristopov ter proces zbiranja in priprave podatkov za uporabo v napovednih modelih.

### 3.1. Napovedovanje porabe: metode in pristopi

Napovedovanje porabe je proces predvidevanja prihodnjih vrednosti na podlagi zgodovinskih podatkov [4] in zagotavlja ključne vpoglede za načrtovanje, sprejemanje odločitev in optimizacijo upravljanja energije. V energetiki napovedovanje pogosto temelji na časovnih vrstah, kjer so opazovanja zabeležena v zaporednih časovnih intervalih. Takšen pristop se razlikuje od drugih vrst napovedovanja, saj temelji na časovni odvisnosti, pri kateri so prihodnje vrednosti tesno povezane s preteklimi vzorci. Podatki časovnih vrst v energetskih sistemih prinašajo posebne izzive, kot so sezonskost, nestacionarnost ter občutljivost na zunanje dejavnike, kot so vremenske razmere ali vedenje uporabnikov. Napovedne metode lahko razdelimo v tri glavne skupine:

1. **Statistične metode** se pogosto uporabljajo za napovedovanje časovnih vrst zaradi svoje enostavnosti in razločljivosti. Sem spadajo metode, kot so ARIMA (angl. *autoregressive integrated moving average*), STL (angl. *seasonal-trend decomposition*) in eksponentno glajenje. Te metode temeljijo na predpostavki, da so prihodnje vrednosti linearno povezane s preteklimi, zaradi česar so primerne za stacionarne in sezonske podatke, manj pa za zajemanje nelinearnih vzorcev.
2. **Metode strojnega učenja** (angl. *machine learning - ML*) nadgrajujejo statistične pristope z zmožnostjo prepoznavanja nelinearnih odnosov in kompleksnih interakcijah v podatkih. Med najpogostejše uporabljene metode so podporni vektorski stroji (angl. *support vector machines*), naključni gozdovi (angl. *random forests*), in gradientno ojačevanje (angl. *gradient boosting machines*). Ti modeli pogosto zahtevajo obsežno pripravo značilk, pri čemer so ključni vhodni podatki, kot so časovne in vremenske spremenljivke.

3. **Globoko učenje** (angl. *deep learning*) je prineslo revolucionaren pristop k napovedovanju časovnih vrst, saj omogoča modelom učenje neposredno iz podatkov brez obsežne ročne priprave značilk. Povratne nevronske mreže (angl. *Recurrent Neural Networks* - RNN), dolge kratkoročne pomnilniške mreže (angl. *Long Short Term Memory* - LSTM) in časovno konvolucijske mreže (angl. *Temporal Convolutional Networks* - TCN) so široko uporabljene na različnih področjih v energetiki, saj odlično zajemajo časovne odvisnosti in zaporedne vzorce v podatkih.

### 3.2. Izbrani napovedni metodi

Na podlagi pregleda literature in analize podatkov sta bili za napovedovanje porabe izbrani dve metodi:

- **XGBoost** (angl. *extreme gradient boosting*) - predstavnik metod strojnega učenja,
- **LSTM** (angl. *long short-term memory*) - spada med metode globokega učenja.

#### LSTM – dolge kratkoročne pomnilniške mreže

LSTM je posebna vrsta povratnih nevronskih mrež (RNN), zasnovana za modeliranje dolgotrajnih časovnih odvisnosti v sekvenčnih podatkih. Razvila sta jo Hochreiter in Schmidhuber [5] kot rešitev za težave klasičnih RNN, ki zaradi izginjajočih ali eksplodirajočih gradientov težko ohranjajo dolgoročne informacije. Zaradi tega je LSTM še posebej primeren za napovedovanje časovnih vrst, kjer imajo pretekli dogodki dolgoročen vpliv na prihodnje vrednosti.

Osnova arhitekture LSTM je pomnilniška celica, ki shranjuje informacije skozi daljša obdobja, pri čemer njeno delovanje uravnavajo trije ključni vratni mehanizmi:

- **Vhodna vrata** določajo, katere nove informacije se dodajo v pomnilnik.
- **Pozabljiva vrata** odločajo, katere informacije se odstranijo, da se ohrani le relevantne podatke.
- **Izhodna vrata** nadzorujejo, katere informacije se uporabijo za napoved ali prenesejo naprej v mrežo.

Ti mehanizmi omogočajo selektivno shranjevanje in posodabljanje informacij, kar modelu omogoča zajemanje tako kratkoročnih nihanj kot dolgoročnih trendov. LSTM ohranja tudi skrito stanje, ki deluje kot kratkoročni pomnilnik in se posodablja na vsakem časovnem koraku.

#### XGBoost – ekstremno gradientno ojačevanje

XGBoost je optimizirana različica gradientnega ojačevanja, zasnovana za visoko zmogljivost, učinkovitost in prilagodljivost. Metodo sta razvila Chen in Guestrin [6], njena priljubljenost pa izhaja iz sposobnosti modeliranja kompleksnih, nelinearnih odnosov v strukturiranih podatkih, kar je posebej koristno za napovedovanje časovnih vrst. Model deluje s postopnim učenjem ansambla odločitvenih dreves, pri čemer vsako novo drevo popravlja napake prejšnjih. Algoritem uporablja gradientni spust za minimizacijo napake, pri čemer vključuje tudi drugi odvod, kar izboljša optimizacijo in pospeši konvergenco.

Ena ključnih prednosti modela XGBoost je vgrajena regularizacija, ki s kontroliranjem kompleksnosti dreves preprečuje prekomerno prileganje modela in s tem izboljšuje njegovo splošno sposobnost generalizacije. Poleg tega zagotavlja visoko računsko učinkovitost, saj podpira paralelno računanje in uporablja optimizirane podatkovne strukture. To omogoča hitrejšo izvajanje napovedi tudi pri velikih količinah podatkov. Zaradi teh lastnosti XGBoost predstavlja zmogljivo orodje za napovedovanje časovnih vrst, saj združuje visoko natančnost, odpornost na prekomerno prileganje in prilagodljivost raznolikim podatkovnim vzorcem.

### 3.3. Proces zbiranja in priprave podatkov

V začetni fazi projekta je po integraciji virov prožnosti potekalo zbiranje podatkov iz povezanih HEMS naprav. Skupno je bilo zajetih 51 HEMS naprav, ki so bile povezane z različnimi tipi priklopljenih naprav (EV, SE, TČ). Vsaka naprava je predstavljena kot ločena časovna vrsta, z lastnim identifikatorjem, časovno značko in izmerjeno vrednostjo, medtem ko so metapodatki vsebovali tudi informacijo o vrsti naprave.

Zaradi smernic splošne uredbe o varstvu podatkov (angl. *General Data Protection Regulation* – GDPR) so bili vsi podatki anonimizirani, kar pomeni, da lokacije posameznih HEMS enot niso bile na voljo. Posledično smo uvedli poenostavljeno obravnavo vremenskih podatkov – za vse naprave smo uporabili enake meteorološke podatke, pridobljene za Ljubljano, čeprav to ne zagotavlja popolne natančnosti za vsako posamezno lokacijo.

Po zbiranju so bili podatki prečiščeni, kar je vključevalo zapolnitev manjkajočih vrednosti in odstranitev odstopajočih podatkov (angl. *outliers*). Tako pripravljene podatke smo nato uporabili za učenje napovednih

modelov, pri čemer smo za vsako HEMS enoto in njene pripadajoče naprave modele trenirali izključno na podlagi njihovih zgodovinskih podatkov.

Takšen pristop omogoča natančne napovedi za vsako posamezno napravo, saj temelji izključno na njenih preteklih meritvah, ne da bi bilo treba poznati podrobnosti o povezanih napravah ali dodatne metapodatke, kot so nazivna moč ali orientacija. Ključni pogoj za zanesljivo napovedovanje pri tem pristopu je zadostna količina zgodovinskih podatkov za vsako napravo.

### 3.4. Napovedni modeli in uporabljene značilke

Za napovedovanje porabe in proizvodnje energije sta bila uporabljena modela LSTM in XGBoost, ki sta bila implementirana s pomočjo knjižnic TensorFlow [7], Keras [8] in XGBoost [9] v programskem jeziku Python. Modeli so bili trenirani na podlagi zgodovinskih podatkov o porabi oziroma proizvodnji ter ključnih zunanjih vplivnih dejavnikov.

Glavne vhodne značilke so opisane spodaj:

- **Čas dneva** (angl. *time-of-day* - ToD): Ključen vplivni dejavnik, saj vpliva na dnevne vzorce porabe. Zaradi cikličnosti časa je bilo to značilko potrebno transformirati v sinusno in kosinusno komponento:

$$ToD_{sin} = \sin\left(\frac{2\pi \cdot \text{hour}}{24}\right) \quad ToD_{cos} = \cos\left(\frac{2\pi \cdot \text{hour}}{24}\right)$$

- **Poraba izpred 24 ur** (angl. *lag feature*): za upoštevanje dnevnih vzorcev je bila dodana zamaknjeno vrednost porabe iz iste ure prejšnjega dne.

$$Lag_{24h} = Poraba(t - 24h)$$

- **Tip dneva**: Poraba energije se razlikuje glede na tip dneva, kjer ločimo delovni dan ali vikend/praznik v binarni obliki.
- **Zunanjia temperatura** (°C) in **globalno sončno obsevanje** (W/m<sup>2</sup>): podatki, pridobljeni iz ARSO Meteo [10], vplivajo na delovanje naprav (npr. na porabo TČ in proizvodnjo SE).

Za oceno natančnosti napovedi je bilo uporabljenih več kazalnikov, pri čemer je bila kot glavna metrika uporabljen kazalnik nMAPE (angl. *normalized Mean Average Percentage Error*), ki je definirana kot:

$$nMAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(y) - \min(y)}$$

Poleg nMAPE so bili uporabljeni še naslednji kazalniki:

- **RMSE** (angl. *Root Mean Square Error*), ki meri povprečno velikost napak, pri čemer bolj kaznuje večje odstopanja in je definiran kot:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- **MAE** (angl. *Mean Absolute Error*), ki izraža povprečno absolutno napako napovedi v enakih enotah kot podatki in je podan kot:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- **R<sup>2</sup>** (koeficient determinacije), ki meri, kako dobro model pojasnjuje variabilnost podatkov. Njegova vrednost se giblje med 0 in 1, kjer višja vrednost pomeni boljšo natančnost napovedi:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Kjer so  $y_i$  in  $\hat{y}_i$ , dejanska in napovedana vrednost,  $\bar{y}_i$  pa povprečna vrednost dejanskih podatkov.

Podatki so bili razdeljeni na učni in testni nabor v razmerju 80:20, pri čemer so bili uporabljeni podatki, zbrani v obdobju med marcem in avgustom.

#### 4 REZULTATI IN ANALIZA

V tem poglavju so predstavljeni rezultati napovednih modelov na primeru ene HEMS enote, pri čemer analiziramo naslednje naprave:

- celotna poraba (zabeležena s pametnim števcem)
- proizvodnja SE,
- poraba TČ.

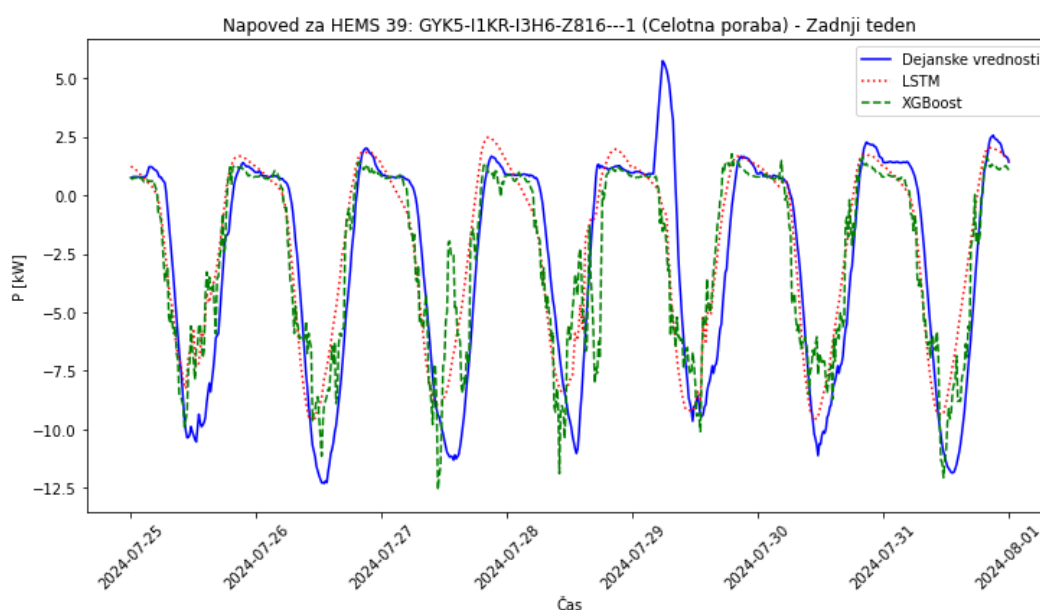
Rezultati so prikazani z uporabo kazalnika nMAPE za celotno testno obdobje ter v vizualni obliki, kjer primerjamo dejansko porabo/proizvodnjo z napovedmi obeh modelov za enotedensko obdobje.

##### 4.1. Rezultati napovedovanja celotne porabe

Celotna poraba, ki jo beleži pametni števec, vključuje tako porabo naprav prožnosti kot neprožnih bremen. Značilni dnevni vzorci kažejo negativne vrednosti v dnevnem času, kar je posledica proizvodnje SE, ter pozitivne vrednosti v večernih in nočnih urah. Slika 1 prikazuje napovedi za enotedensko obdobje, kjer oba modela (LSTM in XGBoost) dobro zajameta splošne vzorce porabe in sledita periodičnim spremembam, ki jih povzročata dnevni ritem uporabe električne energije.

Kljub temu so med modeloma opazne določene razlike. XGBoost se bolje obnese pri zajemanju nenadnih sprememb porabe, zlasti v obdobjih visoke obremenitve, saj uspešneje sledi ostrim vrhovom in hitrim prehodom. Nasprotno pa LSTM model generira bolj gladke in zvezne napovedi, kar pomeni, da manj natančno zajame hitre prehode in konične vrednosti.

Oba modela imata težave pri natančnem napovedovanju negativnih vrednosti (proizvodnje SE) v določenih obdobjih čez dan. To je najverjetneje posledica poenostavljenih vremenskih podatkov, saj so bile vse lokacije obravnavane enako, ne da bi upoštevali specifične vremenske pogoje vsakega gospodinjstva. Poleg tega noben model ni uspel natančno napovedati nenadnega porasta porabe v večernih urah 27. julija, kar kaže na nepričakovano vedenje v podatkih, ki ga modeli niso uspeli zajeti.



Slika 1: Primerjava napovedi celotne porabe gospodinjstva za en teden

Analiza kvantitativnih kazalnikov natančnosti (prikazani v Tabela 1) kaže, da je XGBoost nekoliko natančnejši od LSTM v smislu nMAPE, saj dosega vrednost 7,60 % v primerjavi s 7,74 % pri LSTM. Vrednosti RMSE so nekoliko nižje za LSTM, kar pomeni, da model povzroča manj izrazite napake v primerjavi z XGBoost, medtem ko je pri MAE nekoliko natančnejši XGBoost.

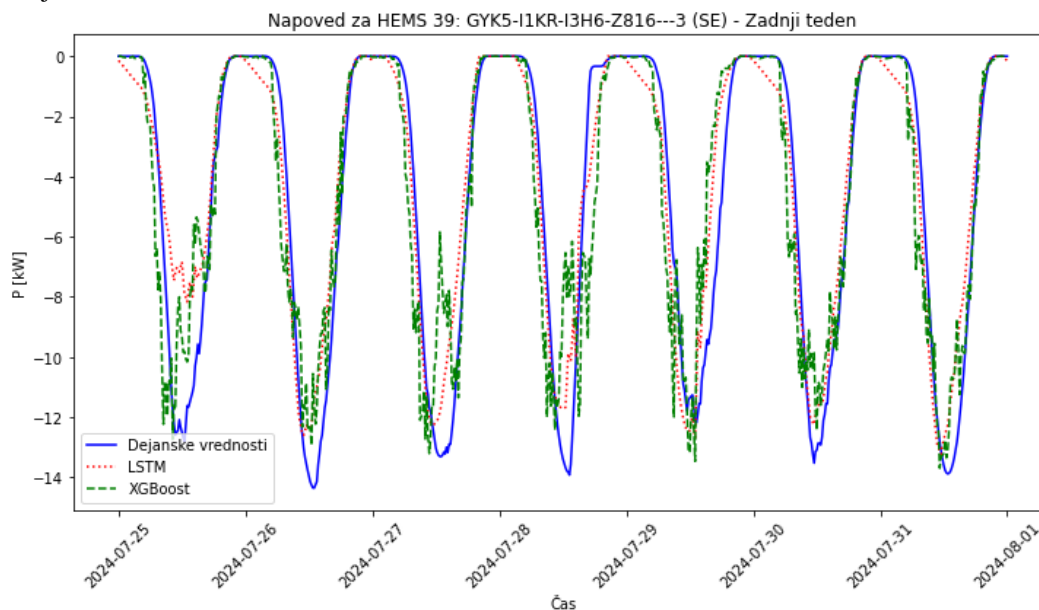
Koeficient determinacije  $R^2$ , ki meri, koliko variance dejanske porabe model pojasni, je pri obeh modelih podoben (0,71 pri LSTM in 0,70 pri XGBoost), kar kaže na podobno sposobnost napovedovanja dolgoročnih trendov.

Tabela 1: Primerjava uspešnosti napovedi za celotno porabo gospodinjstva

	<b>LSTM</b>	<b>XGBoost</b>
<b>nMAPE (%)</b>	7,74	7,60
<b>RMSE (kW)</b>	2,39	2,44
<b>MAE (kW)</b>	1,70	1,67
<b><math>R^2</math></b>	0,71	0,70

## 4.2. Rezultati napovedovanja SE

Slika 2 prikazuje primerjavo dejanske proizvodnje SE z napovedmi, pridobljenimi z modeloma LSTM in XGBoost, za zadnji teden testnega obdobja. Oba modela uspešno sledita dnevnim vzorcem proizvodnje, vključno z izrazitimi vrhovi sredi dneva. Kljub splošni dobri natančnosti obstajajo določene razlike: XGBoost občasno preceni vrhove in uvaja manjše oscilacije v prehodnih obdobjih (zjutraj in zvečer). V nočnih urah XGBoost pravilno napoveduje ničelno proizvodnjo, medtem ko model LSTM včasih zaradi učinka glajenja nepravilno napove majhne vrednosti.



Slika 2: Primerjava napovedi proizvodnje SE za en teden

Primerjava kazalnikov (Tabela 2) kaže, da LSTM presega XGBoost pri vseh metrikah. Zlasti izstopa nMAPE (8,75 % pri LSTM in 10,1 % pri XGBoost) in RMSE, kjer LSTM prav tako dosega nižje vrednosti (1,87 kW proti 2,25 kW). Koeficient determinacije  $R^2$  pri LSTM (0,85) kaže, da model bolje pojasni variabilnost dejanske proizvodnje.

Tabela 2: Primerjava uspešnosti napovedi za proizvodnjo SE

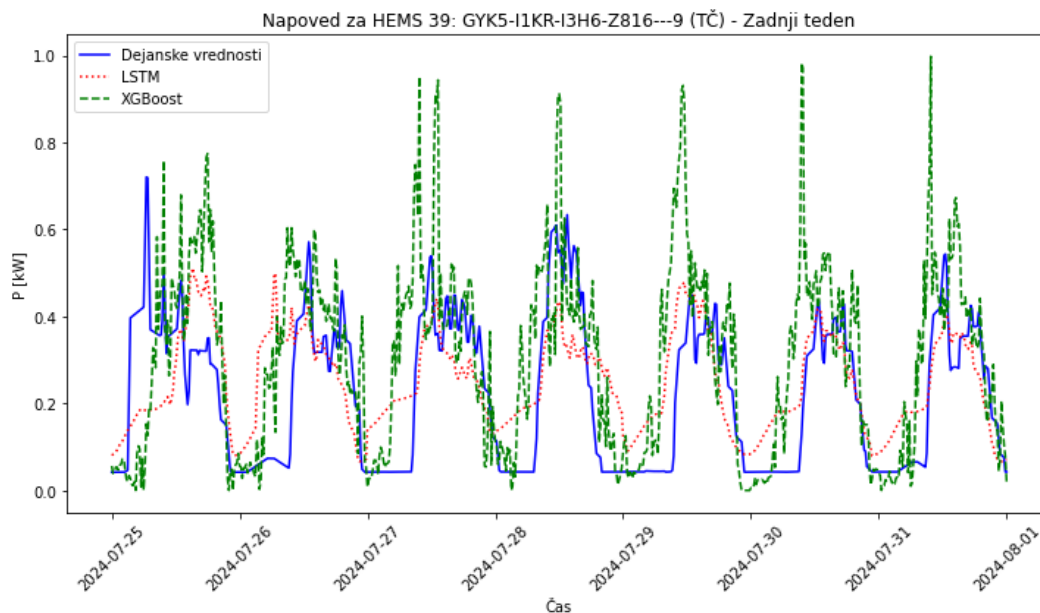
	<b>LSTM</b>	<b>XGBoost</b>
<b>nMAPE (%)</b>	8,75	10,1
<b>RMSE (kW)</b>	1,87	2,25
<b>MAE (kW)</b>	1,26	1,45
<b><math>R^2</math></b>	0,85	0,77

Kljub temu XGBoost ostaja konkurenčen zaradi hitrejšega učenja in enostavnejše razlage napovedi. Za nadaljnje izboljšave bi kombinirali oba modela, zlasti s prilagajanjem napovedi v nočnem času, da bi zagotovili ničelno proizvodnjo. Poleg tega bi natančnejši vremenski podatki lahko dodatno izboljšali rezultate.

### 4.3. Rezultati napovedovanja TČ

Napovedovanje delovanja TČ je tesno povezano z zunanjo temperaturo, ki določa potrebo po ogrevanju ali hlajenju. Slika 3 prikazuje rezultate napovedi za enotedensko obdobje v poletnem času, ko je moč TČ razmeroma nizka.

Kljub majhni porabi oba modela uspešno zajameta splošne trende. XGBoost pogosto preceni konične vrednosti porabe, zlasti v obdobjih visoke obremenitve, medtem ko LSTM natančneje sledi osnovnim vzorcem delovanja TČ, čeprav v določenih primerih napove višje vrednosti v nočnih urah, ko je naprava večinoma neaktivna.



Slika 3: Primerjava napovedi porabe TČ za en teden

Rezultati kažejo, da LSTM dosega boljšo splošno natančnost pri vseh kazalnikih. Vrednosti RMSE in MAE so za obe metodi relativno nizki (zaradi nizke porabe TČ v toplejših mesecih), a tudi tu dosega LSTM boljše rezultate. Prav tako LSTM bolje razloži variabilnost podatkov, kar je razvidno iz večje vrednosti kazalnika  $R^2$ .

Tabela 3: Primerjava uspešnosti napovedi za porabo TČ

	<b>LSTM</b>	<b>XGBoost</b>
<b>nMAPE (%)</b>	15,08	16,27
<b>RMSE (kW)</b>	0,22	0,25
<b>MAE (kW)</b>	0,17	0,18
<b><math>R^2</math></b>	0,29	0,13

Vendar je potrebno poudariti, da so ti rezultati omejeni na poletno obdobje, ko je potreba po ogrevanju oziroma hlajenju manjša in je delovanje TČ pogosto zmanjšano ali prekinjeno. Za bolj celovito oceno bi bilo smiselno vključiti daljše obdobje, ki bi zajemalo tudi hladnejše in prehodne mesece, da bi ocenili, kako se modeli obnesejo v različnih temperaturnih pogojih.

## 5 MOŽNOSTI IZRABE NAPOVEDI

Natančne napovedi porabe in proizvodnje omogočajo boljše načrtovanje delovanja virov prožnosti ter prilagajanje njihovega obratovanja za doseganje določenih ciljev, kot so znižanje stroškov in učinkovita vključitev v energetske trge. To omogoča, da se prožnost iz enot HEMS in nanje priključenih naprav uporabi na več načinov.

### 5.1. Potencialne možnosti uporabe prožnosti HEMS enot

### 1. Trg sistemskih storitev

Ta trg je namenjen regulaciji frekvence, kjer tradicionalno sodelujejo večje enote (agregati, generatorji, velike baterije). Z agregacijo manjših virov prožnosti, kamor spadajo tudi HEMS naprave, bi bilo mogoče sodelovati na tem trgu in nuditi sistemskim operaterjem prilagodljive zmogljivosti.

### 2. Optimizacija cene električne energije (sodelovanje na trgih za dan vnaprej in znotraj dneva)

Sodelovanje na veleprodajnih trgih za dan vnaprej (angl. *Day-ahead* - DA) in znotraj dneva (angl. *Intraday* - ID) omogoča končnim uporabnikom optimizacijo cen električne energije. Na podlagi napovedanih gibanj cene na DA trgu se lahko prilagodi urnik delovanja virov, s čimer se zmanjšajo stroški električne energije.

### 3. Optimizacija glede omrežnine

Pri prehodu na nov omrežninski sistem imajo HEMS enote ključno vlogo. S spremljanjem podatkov v realnem času in nadzorom porabe lahko HEMS sistemi prilagodijo obratovanje naprav, kar pomaga uporabnikom ostati znotraj vnaprej določenih mej moči in tako znižati stroške omrežnine.

### 4. Sodelovanje na lokalnih trgih prožnosti

Lokalni trgi prožnosti, osredotočeni na reševanje omrežnih izzivov, kot so preobremenjenost in težave z napetostjo, predstavljajo potencialno priložnost za manjše enote prožnosti, vključno s HEMS napravami. Čeprav so ti trgi trenutno omejeni zaradi regulativne negotovosti in nizke likvidnosti, bodo v prihodnosti verjetno postali pomembno orodje za distributerje pri zmanjševanju potreb po nadgradnjah omrežja.

V naslednji fazi projekta bomo nadaljevali z delom na osnovi razvitih napovednih modelov, pri čemer je cilj določiti pristop za optimalno izbiro prožnosti, ki vključuje dva ključna vidika:

- **Določanje ustreznosti trga za prožnost:**

Napovedi omogočajo oceno razpoložljivih virov in njihovo tehnično ter ekonomsko primernost za posamezne trge. Pri tem je ključno upoštevati operativne omejitve naprav, značilnosti trgov in donosnost različnih strategij. Analiza napovedanih vzorcev porabe in proizvodnje bo odločilna pri ugotavljanju, katera naprava je primerna za zagotavljanje prožnosti na določenem trgu.

- **Algoritem optimalne izbire (disagregacija):**

Ko je prožnost sprejeta na določenem trgu, mora agregator določiti, katere vire aktivirati in pri kakšnih nastavitvah, da izpolni zahteve sprejete ponudbe. Ta proces, znan kot disagregacija, vključuje razporeditev zahtevanih sprememb porabe ali proizvodnje med različne naprave v agregiranem portfelju. Učinkovitost tega postopka je odvisna predvsem od natančnosti napovednih modelov in razpoložljivosti prožnosti v realnem času, saj imajo lahko nekatere naprave specifične operativne omejitve.

## 6 ZAKLJUČKI

V obdobju velikih sprememb v energetskih omrežjih postaja natančno napovedovanje porabe in proizvodnje izjemno pomembno – tako za operaterje, ki se zanašajo na te podatke za učinkovito načrtovanje in obratovanje, kot tudi za agregatorje in ponudnike storitev prožnosti. Nove tehnologije, kot so električna vozila (in polnilnice za EV), naprave za ogrevanje in hlajenje, baterijski hranilniki in SE, ne le odpirajo številne priložnosti za zaslužek, ampak ponujajo tudi možnost stabilizacije elektroenergetskih omrežij s prilagodljivim obratovanjem.

V okviru projekta OPENTUNITY smo na podlagi podatkov, zbranih iz HEMS naprav, razvili napredne napovedne modele z uporabo metod LSTM in XGBoost. Rezultati kažejo, da je možno uspešno zajeti vzorce delovanja naprav, kljub izzivom, kot je pomanjkanje natančnih informacij o lokaciji posameznih sistemov HEMS.

Med obema pristopoma se je LSTM izkazal za nekoliko natančnejšega, medtem ko je XGBoost dosegel nekoliko slabše rezultate, a nudi prednosti hitrejšega učenja in enostavnejše interpretacije rezultatov. Natančne napovedi tako omogočajo učinkovitejše načrtovanje obratovanja in izrabo prožnosti za cilje, kot so optimizacija cen električne energije ter sodelovanje na lokalnih trgih prožnosti.

## ZAHVALA

Predstavljene rešitve so del raziskovalnih aktivnosti v projektu OPENTUNITY, ki se financira iz Okvirnega programa Evropske unije za raziskave in inovacije Obzorje Evrope (*Horizon Europe*) v okviru sporazuma o dodelitvi sredstev št.101096333.

## REFERENCE

- [1] E. J. Coster, J. M. A. Myrzik, B. Kruimer in W. L. Kling, „Integration Issues of Distributed Generation in Distribution Grids,“ *Proceedings of the IEEE*, 2011.
- [2] HE project OPENTUNITY, [Elektronski]. Available: <https://opentunityproject.eu>.
- [3] Amibit, „Reduxi systems,“ [Elektronski]. Available: <https://www.amibit.si/en/solution/redux-systems/>.
- [4] R. J. Hyndman in G. Athanasopoulos, *Forecasting: Principles and Practice* (3rd ed), 2021.
- [5] S. Hochreiter in J. Schmidhuber, „Long short-term memory,“ *Neural Computation*, 1997.
- [6] T. Chen in C. Guestrin, „XGBoost: A Scalable Tree Boosting System,“ *KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
- [7] „TensorFlow,“ [Elektronski]. Available: <https://www.tensorflow.org>.
- [8] „Keras,“ [Elektronski]. Available: <https://keras.io>.
- [9] „xgboost,“ [Elektronski]. Available: <https://xgboost.readthedocs.io/en/stable/python/index.html>.
- [10] „ARSO METEO,“ [Elektronski]. Available: <https://meteo.arso.gov.si>.