

Analiza napovedovanja porabe in izkoriščanje prožnosti flote električnih vozil v projektu OPENTUNITY

Janez Gregor Golja

Univerza v Ljubljani, Fakulteta za elektrotehniko, Laboratorij za energetske strategije
janezgregor.golja@fe.uni-lj.si

Klemen Peter Kosovinc

Kolektor sETup
klemen.kosovinc@kolektor.com

Miha Valentinič

Avantcar
miha.valentincic@avantcar.si

Tomi Medved

Univerza v Ljubljani, Fakulteta za elektrotehniko, Laboratorij za energetske strategije
tomi.medved@fe.uni-lj.si

POVZETEK

Sektor mobilnosti doživlja preobrazbo, saj električna vozila (EV) postopoma nadomeščajo tradicionalne motorje z notranjim zgorevanjem. K temu prehodu močno prispevajo tudi ključne politike Evropske Unije, med njimi uvedba prepovedi prodaje novih avtomobilov s emisijami CO₂ do leta 2035. V tem spreminjajočem se okolju je storitev souporabe električnih vozil, kot jo ponuja Avantcar, postala privlačna in trajnostna alternativa lastniškemu vozilu za več kot 50.000 uporabnikov. Kljub uspehu pa ostaja neizkoriščen celoten potencial njihove flote električnih vozil, zlasti na področju upravljanja energije za polnjenje in posledično operativne učinkovitosti. Nova mobilnostna infrastruktura, ki vključuje vozila in polnilne postaje pa ponuja izjemen dodaten potencial na področju energetike. Z napovedovanja porabe in izkoriščanja prožnosti flote EV lahko upravljalec flote optimizira delovanje, hkrati pa pripomore k večji stabilnosti elektroenergetskega omrežja ter tako aktivno prispeva k zelenemu prehodu. V okviru projekta OPENTUNITY, ki je financiran s strani programa Obzorje Evrope (angl. Horizon Europe), je z uporabo inovativnih metodologij in napredne, interoperabilne programske opreme cilj podpreti energetske akterje, vključno z operaterji omrežij in aktivnimi odjemalci. Del projekta se osredotoča na izkoriščanje prožnosti iz različnih virov, kamor spada tudi flota EV. V sklopu le-tega smo izvedli integracijo polnilnih postaj na agregacijsko platformo in uporabili zbrane podatke za analizo, ki vključuje prepoznavo vzorcev porabe tako na ravni posamezne polnilne lokacije kot tudi flote. Temu je sledil postopek čiščenja in priprave podatkov ter njihova uporaba za učenje strojnih modelov za napovedovanje porabe. Na podlagi izvedene analize smo definirali algoritme za določanje prožnosti. V prispevku je predstavljena celovita analiza podatkov polnilnih postaj, ki obsega opis uporabljenih metodologij, od čiščenja in priprave podatkov do naprednih metod napovedovanja časovnih vrst ter predstavitev rezultatov uporabljenih napovednih modelov.

Ključne besede: flota električnih vozil, napovedovanje porabe, prožnost, strojno učenje

1 Uvod

Elektrifikacija različnih sektorjev, zlasti mobilnosti, prinaša velike spremembe v elektroenergetskem omrežju. Prehod na električna vozila (EV) omogoča zmanjšanje emisij toplogrednih plinov in izboljšanje trajnosti, a hkrati uvaja izzive za stabilnost omrežja. Polnilne postaje in vozni parki EV lahko povzročajo konične obremenitve in težave z napetostjo (Srivastava, Manas, & Dubey, 2024), kar še dodatno otežuje njihovo integracijo zaradi omejenih omrežnih kapacitet. To pogosto vodi do potreb po dragih nadgradnjah omrežja, predvsem v že obremenjenih območjih.

Pametno upravljanje z izrabo prožnosti, lahko bistveno olajša integracijo EV v obstoječo infrastrukturo. Prilagajanje časa polnjenja pomaga pri zmanjševanju konic in uravnoteženju obremenitev, s čimer se izognemo dragemu razširjanju omrežja. Poleg tega lahko EV s sodelovanjem na trgih prožnosti pripomorejo k bolj varnem in stabilnem obratovanju omrežja.

2 Projekt OPENTUNITY

Evropski projekt OPENTUNITY (OPENTUNITY, 2024), sofinanciran s strani programa Obzorje Evrope (*Horizon Europe*), je zasnovan za podporo različnih akterjev v energetskega ekosistemu, kot so agregatorji, operaterji omrežij in aktivni odjemalci. Glavni cilj projekta je razvoj inovativnih rešitev za učinkovito izrabo prožnosti, pri čemer je ključno orodje za »optimalno izbiro prožnosti« (angl. *Optimal Selection of Available Flexibility*), ki bo omogočilo izbiro najboljših virov prožnosti za različne trge.

V prvi fazi projekta smo se osredotočili na zbiranje in analizo podatkov o porabi polnilnih postaj, kar je temelj za oblikovanje napovednih modelov. Napovedovanje porabe omogoča natančnejše načrtovanje uporabe prožnosti, s čimer operaterji in agregatorji optimizirajo delovanje omrežij ter omogočajo večjo stabilnost z vključevanjem EV v energetske sistem.

3 Napovedovanje porabe: metode in pristopi

Napovedovanje porabe temelji na analizi zgodovinskih podatkov in igra ključno vlogo pri učinkovitem upravljanju EV polnilnic. V kontekstu napovedovanja časovnih vrst gre za napovedovanje podatkovnih točk, ki so časovno urejene, pri čemer sta časovno zaporedje in prepoznavanje vzorcev ključna za natančne napovedi.

Metode za napovedovanje časovnih vrst razdelimo v tri glavne kategorije:

- **Statistične metode**, kot so ARIMA in avtokorelacijski modeli, so primerne za stabilne vzorce, vendar imajo omejitve pri kompleksnih in spremenljivih vzorcih.
- **Metode strojnega učenja** so prilagodljivejše in bolj primerne za spremenljive vzorce porabe, omogočajo bolj natančne napovedi pri kompleksnih časovnih vrstah.
- **Metode globokega učenja**, kot je LSTM (Long Short-Term Memory), so še posebej uporabne za podatke z dolgoročnimi odvisnostmi, kjer pretekli dogodki vplivajo na prihodnje vrednosti.

Na podlagi pregleda literature in analize podatkov smo izbrali dve metodi:

- **LSTM:** LSTM nevronske mreže so posebej prilagojene za časovne vrste, saj lahko ohranjajo dolgoročne odvisnosti. Študije, kot je (Van Kriekinge, De Cauwer, Sapountzoglou, Coosemans, & Messagie, 2021), so pokazale, da je LSTM izjemno učinkovit pri napovedovanju porabe energije EV.
- **XGBoost:** Gre za metodo gradientnega izboljševanja, ki temelji na odločilnih drevesih in izboljšuje natančnost napovedi. Učinkovitost XGBoost pri napovedovanju potreb po polnjenju EV flot je dokazala študija (Frendo, Graf, Gaertner, & Stuckenschmidt, 2020).

4 Zbiranje in priprava podatkov

Za uspešno napovedovanje porabe EV polnilnic je ključno zbrati kakovostne podatke in jih ustrezno pripraviti. V okviru projekta OPENTUNITY smo na agregatorsko platformo integrirali 72 EV polnilnic, ki so namenjeni storitvi souporabe vozil (angl. *car-sharing*), kjer se podatki o polnjenju zbirajo v enominutnih intervalih. Skupaj smo zbrali štirimesečne podatke, ki so bili agregirani po lokacijah (vsaka lokacija vsebuje od 2 do 10 polnilnic).

Po zbiranju so bili podatki očiščeni – odstranili smo manjkajoče vrednosti in neustrezne podatke (npr. nan vrednosti). S tem smo zagotovili, da so časovne serije, združene glede na lokacijo, primerne za napovedovanje. Poleg tega smo definirali ključne spremenljivke, ki so bile vključene v modele:

1. **Čas dneva** (angl. *Time-of-day*): Ta spremenljivka zajema dnevne vzorce, pri čemer smo jo pretvorili v sinusne in kosinusne vrednosti, saj gre za krožno spremenljivko. To pomaga modelom prepoznati ponavljajoče se vzorce, ki se ciklično pojavljajo.
2. **Tip dneva**: Vikendi in delovni dnevi imajo različne vzorce uporabe, zato smo dodali to spremenljivko, da model loči med temi dvema vrstama dni.
3. **Zamaknjene vrednosti** (angl. *lag features*): Zamaknjene vrednosti predstavljajo pretekle podatke o porabi, ki so ključni za zajemanje odvisnosti skozi čas. Uporabili smo vrednosti porabe iz prejšnjega dne (24-urni zamik), kar omogoča modelu, da prepozna povezavo med preteklimi in prihodnjimi vrednostmi porabe.

Podatke smo normalizirali ter razdelili na dva dela: učni sklop (train dataset) in testni sklop (test dataset). Učni sklop je obsegal 70 % podatkov iz začetka časovne vrste in je bil uporabljen za učenje modelov. S tem postopkom modeli analizirajo zgodovinske podatke, identificirajo ključne vzorce in optimizirajo parametre, ki bodo uporabljeni za napovedovanje. Testni sklop, ki vsebuje preostalih 30 % najnovejših podatkov, je bil uporabljen za validacijo modelov, kar omogoča preverjanje natančnosti napovedi pri podatkih, ki jih model še ni videl. Ta postopek je ključnega pomena za realno oceno delovanja modelov.

5 Rezultati in analiza

V tem poglavju predstavljamo rezultate napovednih modelov za porabo EV polnilnic. Za primerjavo natančnosti napovedi smo uporabili dva ključna kazalnika uspešnosti:


- **Koren povprečne kvadratne napake (RMSE)** meri povprečno razliko med napovedanimi in dejanskimi vrednostmi. Ker kvadrira napake, bolj kaznuje večja odstopanja. Nižja vrednost RMSE pomeni bolj natančno napoved.
- **Simetrična absolutna odstotkovna napaka (sMAPE)** izraža odstotek razlike med napovedjo in dejanskimi vrednostmi, pri čemer enako obravnava precenjene in podcenjene napovedi.

RMSE omogoča natančno merjenje večjih napak, medtem ko sMAPE ponuja primerjavo napak v relativnih odstotkih. Poleg numeričnih kazalnikov so rezultati prikazani tudi grafično, kar omogoča primerjavo natančnosti modelov (v našem primeru LSTM in XGBoost) glede na dejansko porabo EV polnilnic. Analizirali smo dva primera: napovedi za eno lokacijo in agregirano floto polnilnic, pri čemer vsaka slika prikazuje napovedi za en teden.

5.1 Polnilna lokacija z devetimi polnilnimi postajami

Slika 1 prikazuje primerjavo med pravimi vrednostmi porabe (modra črta) in napovedmi dveh modelov, LSTM (rdeča prekinjena črta) in XGBoost (zelena prekinjena črta), za posamezno lokacijo. Lokacija ima stabilne dnevne vzorce z jasnimi vrhovi porabe čez dan in nizko porabo ponoči.

Slika 1: Primerjava pravih in napovedanih vrednosti za posamezno lokacijo



LSTM model ustvari bolj gladko krivuljo, ki je bližje povprečju porabe, a ne dosega vrhov obremenitve, kar je razvidno 26. in 29. marca. XGBoost pa včasih bolje zadene konice, kot na primer 26. marca, vendar je bolj nagnjen k nihanjem, kar povečuje napake.

Tabela 1: Kazalnika za primer posamezne lokacije


	LSTM	XGBoost
RMSE [kW]	8,51	9,92
sMAPE [%]	2,47	2,49

Kazalnika RMSE in sMAPE kažeta, da je LSTM model natančnejši pri napovedovanju splošnega trenda porabe, medtem ko XGBoost bolje zajame konice, vendar s pogostejšimi napakami. Pomembno je omeniti, da sta kazalnika izračunana le za delovne dni (ponedeljek–petek). Med vikendom (30. in 31. marca) je zaradi manjše aktivnosti napoved obeh modelov manj natančna.

5.2 Agregirana flota EV polnilnic

Pri agregiranih podatkih (Slika 2), ki predstavljajo skupno porabo vseh polnilnic, opazimo, da sta oba modela v povprečju boljša pri napovedovanju. Agregacija podatkov zmanjšuje naključna nihanja in omogoča modeloma, da bolje sledita splošnemu trendu porabe.

Slika 2: Primerjava pravih in napovedanih vrednosti za celotno floto



LSTM ponovno izkaže bolj gladko krivuljo in stabilno napoveduje splošni potek porabe, medtem ko XGBoost še vedno bolj natančno zajema konice, vendar z večjo stopnjo nihanja. Oba modela dobro sledita osnovni obliki porabe, a je še vedno nekaj odstopanj zaradi sporadičnih sprememb v porabi, ki jih težko zajameta.

Tabela 2: Kazalnika za primer celotne flote

	LSTM	XGBoost
RMSE [kW]	29,53	33,02
sMAPE [%]	2,06	2,16

Agregirani podatki omogočajo bolj natančne napovedi, saj vzorci postanejo bolj stabilni z večjim številom polnilnic. LSTM je ponovno boljši pri sledenju splošnemu trendu (nižji RMSE in sMAPE), medtem ko XGBoost uspe bolje zaznati večje spremembe, vendar z večjimi odstopanji.

Sporadične spremembe, ki jih oba modela težko zajameta, so največji izziv pri natančnem napovedovanju porabe EV polnilnic. To je posebej izrazito pri manjšem številu polnilnic, kjer je napovedovanje bistveno težje. Z večjim številom polnilnic se natančnost napovedi izboljša, še posebej na lokacijah, kjer so vzorci polnjenja relativno stabilni.

Kljub temu da napovedi niso popolnoma natančne, so ključne za kasnejše načrtovanje prilagajanja časa polnjenja ter izkoriščanje prožnosti EV polnilnic. Različne možnosti uporabe prožnosti so predstavljene v naslednjem poglavju.

6 Možnosti uporabe prožnosti EV flote

Prožnost EV flote ponuja pomembne priložnosti za ekonomsko optimizacijo ter izboljšanje delovanja elektroenergetskih omrežij. Prilagodljivost pri porabi lahko pomaga pri zmanjšanju koničnih obremenitev in uravnoteženju omrežja. Spodaj so predstavljene ključne možnosti izrabe prožnosti EV.

6.1 Optimizacija časa polnjenja (glede na ceno električne energije)

Ena izmed ključnih možnosti za izrabo prožnosti EV flote je optimizacija polnjenja glede na spreminjajoče se cene električne energije (Vuelas, Ruiz, & Gruosso, 2019). S prilagajanjem časa polnjenja se lahko flota EV izogne obdobjem visokih cen (npr. med večernimi konicami) in izkoristi cenejša obdobja (npr. ponoči ali sredi dneva, ko je veliko obnovljivih virov energije).

Na primer, polnilnice lahko izkoristijo nižje nočne cene elektrike (22:00–06:00) ter ugodne opoldanske intervale (12:00–14:00), ko je cena pogosto zelo nizka ali celo negativna. Polnjenje se tako lahko ustavi med 17:00 in 20:00, ko so cene najvišje. Hkrati je pomembno upoštevati napolnjenost baterij in potrebe uporabnikov, da so vozila pripravljena za uporabo ob predvidenem času.

6.2 Sistemske storitve

EV flote lahko prispevajo k stabilnosti elektroenergetskega sistema s sodelovanjem v sistemskih storitvah (Janjic & Velimirovic, 2015). S prilagajanjem polnjenja lahko EV polnilnice pomagajo uravnati frekvenco v omrežju. V obdobjih presežka proizvodnje lahko povečajo porabo, medtem ko lahko v primeru primanjkljaja upočasnijo ali začasno ustavijo polnjenje. Dvosmerno polnjenje (V2G) omogoča še večjo prožnost, saj lahko EV vračajo energijo nazaj v omrežje.

6.3 Lokalni trgi prožnosti

V prihodnosti bodo lokalni trgi prožnosti, ki jih bodo upravljali distribucijski operaterji, igrali pomembno vlogo pri upravljanju preobremenitev v omrežjih. Polnilnice EV bodo lahko na teh trgih nudile prožnost, ki bo omogočala zmanjšanje obremenitev v realnem času. (Gonzalez, Petit, & Yannick, 2020) Ko bo operater zaznal preobremenitev, bo lahko sprožil dražbo za

prožnost, kjer bodo polnilnice z odlogom polnjenja pomagale pri zmanjšanju obremenitev brez potrebe po dragih infrastrukturnih nadgradnjah.

7 Zaključek

Elektrifikacija mobilnosti in povečana uporaba EV prinaša pomembne izzive za elektroenergetska omrežja, predvsem zaradi povečanih koničnih obremenitev in vpliva na stabilnost omrežja. Kljub temu rezultati napovednih modelov LSTM in XGBoost kažejo, da lahko učinkovito predvidimo splošne trende porabe EV polnilnic, kar omogoča boljše načrtovanje prilagajanja časa polnjenja ter optimizacijo delovanja omrežij. Pri večjem številu polnilnic so napovedi natančnejše, kar še dodatno potrjuje pomen večjih flot pri stabilizaciji napovedi. Možnosti uporabe prožnosti EV flote, kot so optimizacija polnjenja, sodelovanje v sistemskih storitvah in uporaba na lokalnih trgih prožnosti, ponujajo obsežne priložnosti za boljše obvladovanje omrežnih obremenitev in zmanjšanje stroškov. Širša uvedba tehnologij, kot je dvosmerno polnjenje (V2G), in lokalni trgi prožnosti bodo v prihodnosti ključni za uspešno integracijo EV v elektroenergetski sistem.

Literatura

- Frendo, O., Graf, J., Gaertner, N., & Stuckenschmidt, H. (2020). Data-driven smart charging for heterogeneous electric vehicle fleets. *Energy and AI*.
- Gonzalez, F., Petit, M., & Yannick, P. (2020). Quantifying the participation of EV fleets in local flexibility tenders. *CIREN Berlin Workshop*.
- Janjic, A., & Velimirovic, L. (2015). Optimal Scheduling of Utility Electric Vehicle Fleet Offering Ancillary Services. *ETRI Journal*, 37.
- OPENTUNITY. (2024). *OPENTUNITY project website*. Retrieved from <https://opentunityproject.eu/the-project/>
- Srivastava, A., Manas, M., & Dubey, R. (2024). Integration of power systems with electric vehicles: A comprehensive review of impact on power quality and relevant enhancements. *Electric Power Systems Research*.
- Van Krieking, G., De Cauwer, C., Sapountzoglou, N., Coosemans, T., & Messagie, M. (2021). Day-Ahead Forecast of Electric Vehicle Charging Demand with Deep Neural Networks. *World Electr. Veh. J.*
- Vuelvas, J., Ruiz, F., & Gruosso, G. (2019). Price Based Optimization for Electrical Vehicle Charging Scheduling. *2019 IEEE Vehicle Power and Propulsion Conference (VPPC)*.