Napovedovanje porabe električne energije odjemalca: primerjava različnih modelov za napovedovanje časovnih vrst

Jakob Tomas Bolta, Malik Romanić, Lenart Golob, Matej Meža, Marko Meža

Fakulteta za elektrotehniko, Tržaška cesta 25, Ljubljana, Slovenija
E-pošta: marko.meza@fe.uni-lj.si

Forecasting customer electricity consumption: a comparison of different time series forecasting models

Abstract. *This article compares four popular time series forecasting models: Prophet, LightGBM, and two variants of Chronos-Bolt, Tiny and Base. Accurate energy consumption forecasting is essential for efficient energy management systems, especially at the household level, where consumption patterns are highly variable yet also seasonally structured, influenced by daily, weekly, and annual cycles. The aim of this study is to evaluate the performance of models in terms of forecasting accuracy and practical applicability. Using real-world consumption data, we evaluate the model performance with standard metrics such as MAE, MAPE, RMSE, and nRMSE.*

1 Uvod

Natančna napoved porabe električne energije je ključna za učinkovito upravljanje virov in stroškov v pametnih omrežjih. Posebno zahtevno je napovedovanje na ravni gospodinjstev zaradi visoke volatilnosti in večnivojske sezonskosti, ki izhaja iz dnevnih ritmov, tedenskih rutin ter vremensko pogojenih nihanj.

Za napovedovanje takšnih časovnih vrst je potrebna uporaba modelov, ki uspešno zaznavajo trende ter uravnotežijo natančnost, interpretabilnost in računsko učinkovitost. V prispevku so primerjani štirje enodimenzionalni (ang. univariate) modeli: Prophet [1], LightGBM [2] ter Chronos-Bolt v različicah Tiny in Base [3]. Analiza je usmerjena na napovedno natančnost in računske značilnosti posameznih pristopov.

Namen prispevka je določiti, kateri izmed modelov dosega najboljše rezultate pri napovedovanju porabe gospodinjstev glede na kompleksnost, čas učenja in točnost napovedi.

2 Ozadje

2.1 Klasično napovedovanje časovnih vrst (Time series prediction)

Za napovedovanje časovnih vrst obstaja več pristopov, od klasičnih statističnih metod do sodobnih modelov, ki temeljijo na strojnem in globokem učenju.

Klasični modeli, kot je Prophet, za napovedovanje časovnih vrst uporabljajo zgodovinske podatke ter so priljubljeni zaradi enostavne interpretacije ter stabilnega obnašanja. Glavni cilj je identificirati vzorce, kot so trend, sezonskost in avtokorelacija, z uporabo matematičnih modelov.

Najpogostejše klasične metode vključujejo: AR (AutoRegressive): napoved temelji na preteklih vrednostih iste spremenljivke, MA (Moving Average): modelira vrednost kot linearno kombinacijo preteklih napak, ARMA (AutoRegressive Moving Average): kombinacija AR in MA za modeliranje stacionarnih časovnih vrst, ARIMA (AutoRegressive Integrated Moving Average): integrated pomeni, da omogoča modeliranje nestacionarnih časovnih vrst z uporabo diferenciranja, SARIMA (Seasonal ARIMA): razširitev ARIMA z možnostjo upoštevanja sezonskih komponent [4].

2.2 Moderni modeli za napovedovanje časovnih vrst

Sodobni modeli, kot sta LightGBM in Chronos, učinkovito zaznavajo nelinearne vzorce ter uporabljajo koledarske in zamikovne atribute, kar pogosto prinese boljše rezultate ob manjši potrebi po predobdelavi podatkov. Chronos-Bolt je natreniran na velikem številu podatkov časovnih, kar mu omogoča zelo kratek čas učenja – zgolj nekaj milisekund. Namesto dolgotrajnega dodatnega učenja model potrebuje le kratek kontekst naše časovne vrste. Na podlagi tega konteksta in svojega predtreniranega znanja takoj izračuna napoved. Posledično model ne zahteva časa za učenje, temveč zgolj za nalaganje pred-naučenih uteži v delovni pomnilnik.

3 Metodologija

3.1 Pregled zasnove študije

Cilj je oceniti delovanje modelov za napovedovanje časovnih vrst urne porabe elektrike za gospodinjstva. V raziskavi so bili uporabljeni podatki o dvoletni porabi za eno odjemno mesto v obdobju od 2024 do 2025. Podatki za odjemno mesto vsebujejo časovno značko meritve in energijo v časovnem obdobju 15 minut. Primerjana je bila napovedna natančnost posameznih modelov ter zahtevnost njihove uporabe glede na porabo sistemskih virov.

3.2 Predobdelava podatkov

Izhodiščni podatki o porabi električne energije, zajeti v 15-minutnih intervalih, so bili za namene analize agregirani na urni nivo. Naloga je bila definirana kot napoved porabe za naslednjih 24 ur, pri čemer je vsak

model v evalvacijskem postopku generiral 24 zaporednih urnih napovedi (multi-step forecast). Podatki so bili pretvorjeni iz CSV v optimiziran Parquet format, kar je pospešilo nadaljnjo analizo.

4 Evalvacija

4.1 Opis evalvacijskega postopka

Za oceno stabilnosti in prilagodljivosti modelov ob različnih količinah razpoložljivih podatkov je bila uporabljena walk-forward validacija, ki posnema realno zaporedno napovedovanje. Napovedni horizont je bil fiksno nastavljen na 24 ur. Pri tem je bil uporabljen pristop drsečega okna (ang. sliding window) [5].

4.2 Drseče okno

Pri tej metodi je bil model treniran na fiksnem obdobju podatkov, na primer šest mesecev, z namenom napovedi vrednosti za naslednji dan. Po vsaki napovedi je bilo drseče okno premaknjeno za en dan in postopek ponovljen.

Delovanje metode ponazarja primer šestmesečnega okna za leto 2024: modeli so bili najprej trenirani na podatkih od 1. januarja do 30. junija, s čimer so napovedali vrednost za 1. julij. Nato se drseče okno premakne za en dan (trenirano na podatkih od 2. januarja do 1. julija) in izvede se napoved za 2. julij. Enak postopek je bil uporabljen tudi za okna dolžine treh mesecev, enega meseca in 14 dni.

Takšen pristop zagotavlja uporabo svežih podatkov za treniranje ter omogoča oceno napovedne sposobnosti modela za vsak naslednji dan skozi celotno leto 2024.

4.3 Izbrane metrike

Za celovito analizo delovanja modelov so bile uporabljene štiri metrike. Skupaj omogočajo oceno tako povprečne napake (MAE), občutljivosti na večja odstopanja (RMSE), relativne napake (MAPE) kot tudi primerljivosti napak med različnimi časovnimi obdobji (nRMSE).

MAE (Mean Absolute Error) meri povprečno absolutno razliko med napovedanimi in dejanskimi vrednostmi.

RMSE (Root Mean Squared Error) meri kvadratni koren povprečja kvadratov razlik med napovedanimi in dejanskimi vrednostmi. Ta metrika poudari večje napake, saj jih zaradi kvadriranja poveča, kar omogoča boljšo zaznavo velikih odstopanj v napovedih.

MAPE meri povprečni odstotek napake med napovedanimi in dejanskimi vrednostmi, kar omogoča primerjavo med različnimi nizi podatkov. Njena slabost se pokaže pri zelo nizkih vrednostih porabe, kjer majhne absolutne napake povzročijo nesorazmerno visoke odstotke [6].

nRMSE je normirana oblika RMSE, ki omogoča primerjavo med nizi podatkov z različnimi skalami. V tej študiji je bila izračunana z normalizacijo glede na razpon dejanskih vrednosti (Y) v testnem obdobju, kot prikazuje enačba (1):

$$nRMSE = \frac{RMSE}{Ymax - Ymin} \quad (1)$$

V nasprotju z MAPE ostaja nRMSE stabilna tudi pri nizki ali skoraj ničelni porabi, saj simetrično obravnava vse napake.

Model	Velikost parametrov	Čas učenja (avg)	Čas napovedi (avg)
Prophet	~100	2.8s	0.004s
LightGBM	- 12K	1.0s	0.15s
Chronos-Bolt-Tiny	9M	0.0055s	0.04s
Chronos-Bolt-Base	205M	0.004s	0.27s

Tabela 1: Prikaz računske zahtevnosti. Chronos-Bolt modeli učijo najhitreje. LightGBM je učinkovit, a počasnejši pri napovedih, medtem ko Prophet hitro napoveduje, a počasneje uči.

4.4 Programska in strojna oprema

Projekt je zasnovan kot Python (3.11) knjižnica z enostavnim CLI vmesnikom, ki omogoča zagon posameznih modelov in eksperimentov. Ključna programska oprema, uporabljena v projektu, vključuje knjižnice: pandas (2.2), numpy (1.26), matplotlib (3.8) za obdelavo podatkov in vizualizacijo, tqdm (4.66), pyarrow (14.0), lightgbm (4.3), mlforecast (0.8), prophet (1.1), chronos-forecasting (1.2.0) in torch (2.0.0).

Testiranja so potekala izključno na CPU, brez uporabe grafičnih procesorjev. Konfiguracija prenosnega računalnika: Intel i7-10750H @ 2,6 GH, 16 GB RAM-a.

5 Primerjava modelov

5.1 Prophet

Prophet je napovedni model za časovne vrste, ki temelji na aditivni strukturi, kjer skupno napoved sestavljajo dolgoročni trend, sezonskost in vpliv praznikov. Model je zasnovan za zajem kompleksnih nelinearnih vzorcev s poudarkom na dnevni, tedenski in letni sezonskosti.

Enačba (2) predstavlja napoved vrednosti časovne vrste kot vsoto več ključnih komponent, ki skupaj zajemajo različne vplive na podatke:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (2)$$

kjer so: g(t): dolgoročni trend (npr. linearen ali logističen), s(t): sezonski vzorci (dnevni, tedenski, letni), modelirani s Fourierjevo transformacijo, h(t): vpliv praznikov ali posebnih dogodkov (določenih z uporabnikom), ε_t: napaka (ostanek).

Slabše se odziva na nenadne spremembe, kar se je v našem primeru pokazalo kot slabša zmogljivost v primerjavi z modeloma Chronos in LightGBM.

5.2 LightGBM

Je model strojnega učenja, ki temelji na gradnji množice odločilnih dreves (ang. gradient boosting) in je znan po svoji učinkovitosti, hitrosti učenja in dobri natančnosti na strukturiranih podatkih. Izstopa po hitrem učenju in nizki računski zahtevnosti, kar omogoča učinkovito obdelavo tudi večjih podatkovnih množic. Model je pregledno nastavljiv, z možnostjo enostavne analize pomembnosti značilnosti. V primerjavi z globokimi modeli je bistveno lažji za uporabo. Njegova omejitev je napoved po posameznih točkah, kar oteži večdnevne napovedi. Kljub temu je dosegel dobre rezultate, zlasti pri daljših drsečih oknih.

5.3 Chronos-Bolt-Tiny

Je lažja različica iz družine modelov Chronos. Model omogoča izjemno hitro napovedovanje brez dodatnega učenja, saj deluje na že naučenih utežeh. Slabost je nekoliko nižja natančnost zaradi manj parametrov in plasti, kar omejuje zaznavo kompleksnih vzorcev. Uporabnik mu lahko poda poljubno dolg odsek preteklih meritev (denimo nekaj tednov ali mesecev). Glede na ta kontekst in svoje prednaučeno znanje model nato izdela napoved za poljubno izbran horizont (v našem primeru 24 ur).

5.4 Chronos-Bolt-Base

Deluje po enakih načelih kot Tiny, vendar je kompleksnejši, vsebuje več uteži (Tiny ima približno 9 milijonov uteži, Base pa 205 milijonov) in ima s tem tudi večjo sposobnost zaznavanja dolgoročnih povezav v podatkih. Vsebuje več plasti in ima večjo dimenzijo skritih slojev, kar omogoča boljšo natančnost napovedi. V primerjavi z drugimi pristopi je ta model v našem eksperimentu dosegel najboljšo povprečno natančnost, a zaradi večje zahtevnosti ni vedno najbolj praktičen za hitro analizo ali delovanje v omejenih okoljih.

6 Rezultati

Rezultati, pridobljeni z validacijo z drsečim oknom, so pokazali, da deep-learning modeli (Chronos) ohranjajo natančnost tudi pri krajših drsečih oknih, kjer statistični in klasični strojno-učeči pristopi občutneje degradirajo. Chronos-Bolt-Base je dosegel najnižjo povprečno napako (MAE), vendar ob nekoliko višji časovni zahtevnosti, kar je razvidno iz Tabele 2. Chronos-Bolt-Tiny pa se je izkazal kot optimalen kompromis med natančnostjo in hitrostjo – z izjemno hitrim učenjem in napovedovanjem. Prophet je bil enostaven za uporabo in hiter pri napovedi, a manj stabilen, zlasti ob nižji porabi, kar je razvidno iz Tabele 3. LightGBM je nudil dobro ravnotežje, vendar je bil občutljiv na količino podatkov in manj primeren za dolge nize ničelne porabe.

Model	MAE	RMSE	MAPE (%)	nRMSE
Prophet	1.196	1.572	247.65	0.534
LightGBM	0.972	1.511	161.95	0.512
Chronos-Bolt-Tiny	0.837	1.353	142.29	0.354
Chronos-Bolt-Base	0.821	1.354	128.31	0.318

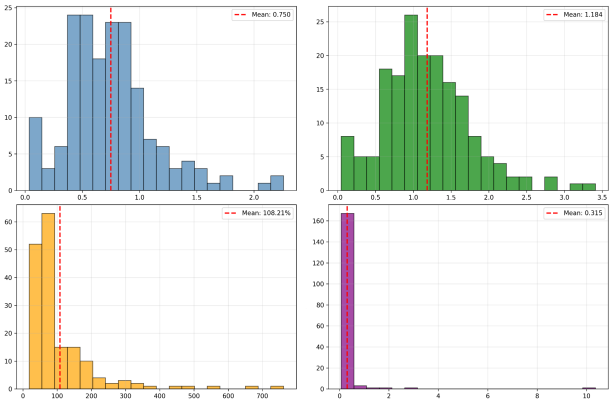
Tabela 2: Primerjava rezultatov 1 meseca. Chronos-Bolt-Base dosega najboljšo natančnost, sledi LightGBM ter Prophet, ki ima visoke napake – zlasti MAPE, kar kaže na težave pri nizki porabi.

Model	MAE	RMSE	MAPE (%)	nRMSE
Prophet	1.199	1.587	232.18	0.554
LightGBM	0.935	1.467	133.83	0.505
Chronos-Bolt-Tiny	0.838	1.357	119.86	0.346
Chronos-Bolt-Base	0.817	1.351	108.11	0.304

Tabela 3: Primerjava rezultatov 6 mesecev. Chronos-Bolt modela ostajata najnatančnejša. LightGBM se izboljša z daljšim učenjem, Prophet pa ostaja manj zanesljiv. MAPE se zniža pri vseh, kar kaže na boljšo prilagoditev pri več podatkih.

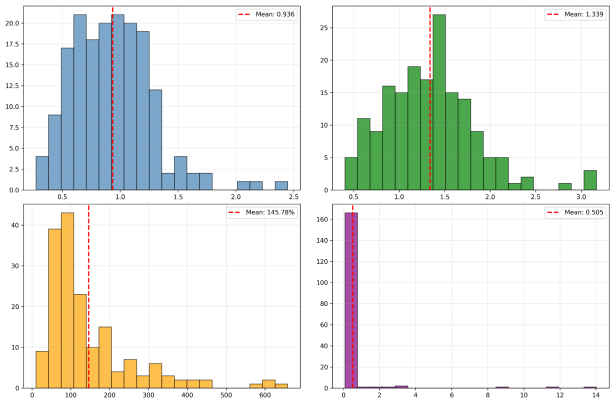
Model	MAE	RMSE	MAPE (%)	nRMSE
Prophet	1.061	1.405	196.65	0.783
LightGBM	0.936	1.339	145.78	0.505
Chronos-Bolt-Tiny	0.762	1.193	113.55	0.388
Chronos-Bolt-Base	0.750	1.184	108.21	0.315

Tabela 4: Primerjava rezultatov celotnega testnega obdobja. Chronos-Bolt-Base in Tiny ohranjata najboljšo natančnost. LightGBM je konkurenčen, a občutljiv na dolge nize ničel. Prophet ima najvišji nRMSE, kar kaže na težave pri skrajnih vrednostih.

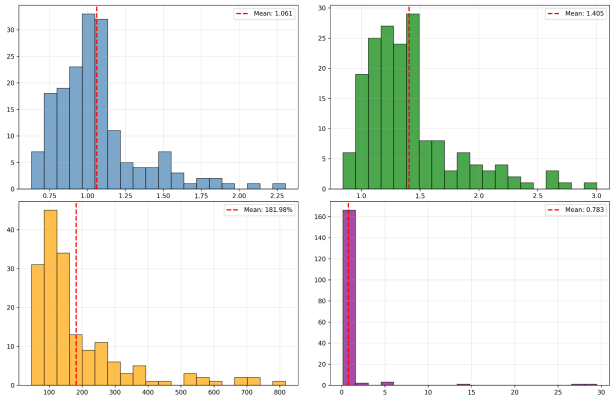


Slika 1: Metrike Chronos-Bolt-Base za obdobje 500 dni. Postavitev: MAE (zgoraj levo), RMSE (zgoraj desno), MAPE (spodaj levo), nRMSE (spodaj desno), os Y na grafih predstavlja frekvenco, os X pa časovno obdobje. Metrike so stabilne z nizkimi napakami in minimalnimi nihanji.

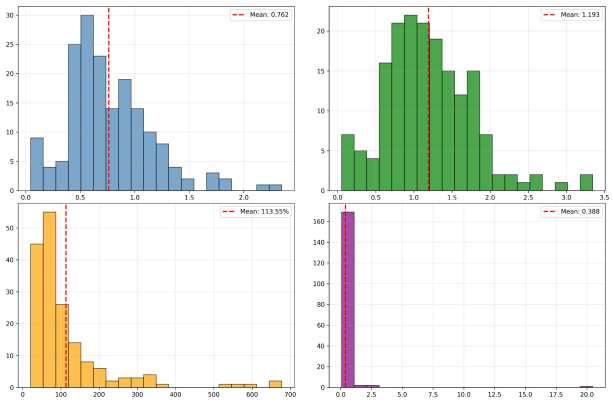
MAPE (100–130 %) potrjuje njegovo primernost za gospodinjske napovedi. Vir: lasten arhiv



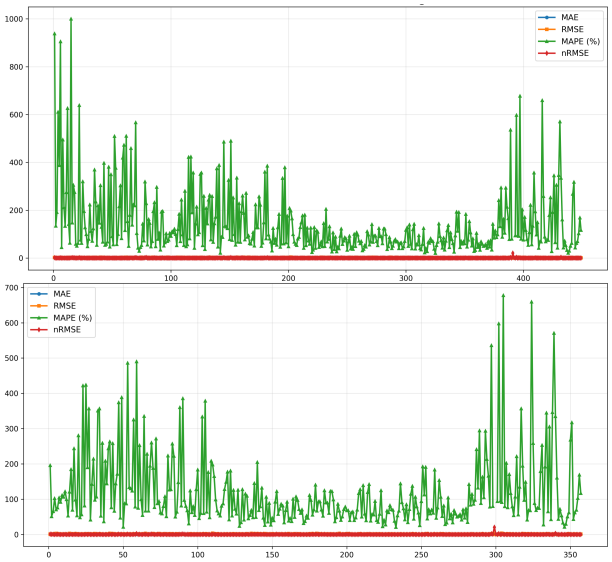
Slika 2: Metrike LightGBM za obdobje 500 dni (postavitev kot na sliki 1). Napovedi so natančne, a z več nihanji kot Chronos-Bolt. MAPE kaže večjo občutljivost na spremembe v porabi. Vir: lasten arhiv



Slika 3: Metrike Prophet za obdobje 500 dni (postavitev kot na sliki 1). Model ima višje napake (npr. MAPE) in slabše deluje pri nizkih, nestabilnih vrednostih. Kljub hitrosti je manj primeren za kompleksne vzorce. Vir: lasten arhiv



Slika 4: Metrike Chronos-Bolt-Tiny za obdobje 500 dni (postavitev kot na sliki 1). Dosega podobno natančnost kot Base, a z manjšo računsko zahtevnostjo. RMSE ostaja nizek (~1.2), MAPE med 110–140 % – primeren za omejena okolja. Vir: lasten arhiv



Slika 5: Prikaz napak modela Chronos-Bolt-Base pri Drsečem oknu skozi testna obdobja 3 mesecev (graf zgoraj) in 6 mesecev (graf spodaj). Os X predstavlja število dni, zajetih v oknu, os Y pa vrednost metrike na točki zajetega dne. Vir: lasten arhiv

7 Zaključek

Modela Chronos-Bolt sta izkazala visoko stabilnost in natančnost tudi pri krajših drsečih oknih. Model Chronos-Bolt-Tiny je dosegal skoraj enake rezultate kot večji model Bolt-Base, ob tem pa je bil čas izvajanja bistveno krajši, kar je posledica minimalnih zahtev po učenju.

V prihodnjih raziskavah je predvidena razširitev vhodnih podatkov z zunanjimi viri, kot so solarni indeks, vremenski podatki in urnik porabe, ter testiranje verjetnostnih modelov za izračun intervalov zaupanja. Namen je izboljšanje napovedne natančnosti in preverjanje delovanja modelov na podatkih različnih gospodinjstev, zlasti tistih brez sončnih elektrarn.

Literatura

[1] C. Duong: Prophet GitHub Repository, (dostopano 26. 6. 2025). https://github.com/facebook/prophet

[2] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye in T. Liu: LightGBM - A Highly Efficient Gradient Boosting Decision Tree, (dostopano 26. 6. 2025). https://proceedings.neurips.cc/paper_files/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf

[3] A. Ansari, L. Stella, C. Turkmen, et al. (2024). Chronos: Learning the Language of Time Series. arXiv preprint, arXiv:2403.07815

[4] C. Liu, S. C. Hoi, P. Zhao in J. Sun (2016). Online ARIMA Algorithms for Time Series Prediction. AAAI.

[5] S. J. Taylor in B. Letham, (2018). Forecasting at scale. The American Statistician, 72(1), 37-45

[6] M. Makovec. Features and Models for Short-term Household Energy Consumption Forecast, Zbornik mednarodne Elektrotehniške in računalniške konference (2022) Str. 498-501