

arnes 
povezujemo znanje



MREŽA ZNANJA

Ljubljana, 3.–5. december 2024

Napovedovanje časovnih vrst v sistemih upravljanja z energijo

Niko Uremović
UM, FERİ

Uvod

V aplikacijah strojnega učenja moramo modele pogosto namestiti na manj zmogljive sisteme.

- Učenje lahko izvajamo na visoko zmogljivih računalniških sistemih.
- Pogosto ni problematično, saj je učenje veliko zahtevnejše od samega izvajanja napovedi.
- Težave nastopijo, ko moramo modele v produkcijskem okolju do-učiti ali prilagoditi na spremembe.
- V življenjski dobi modela pogosto potrebno posodobiti model.
- Vsi postopki zaželeno avtomatizirani.



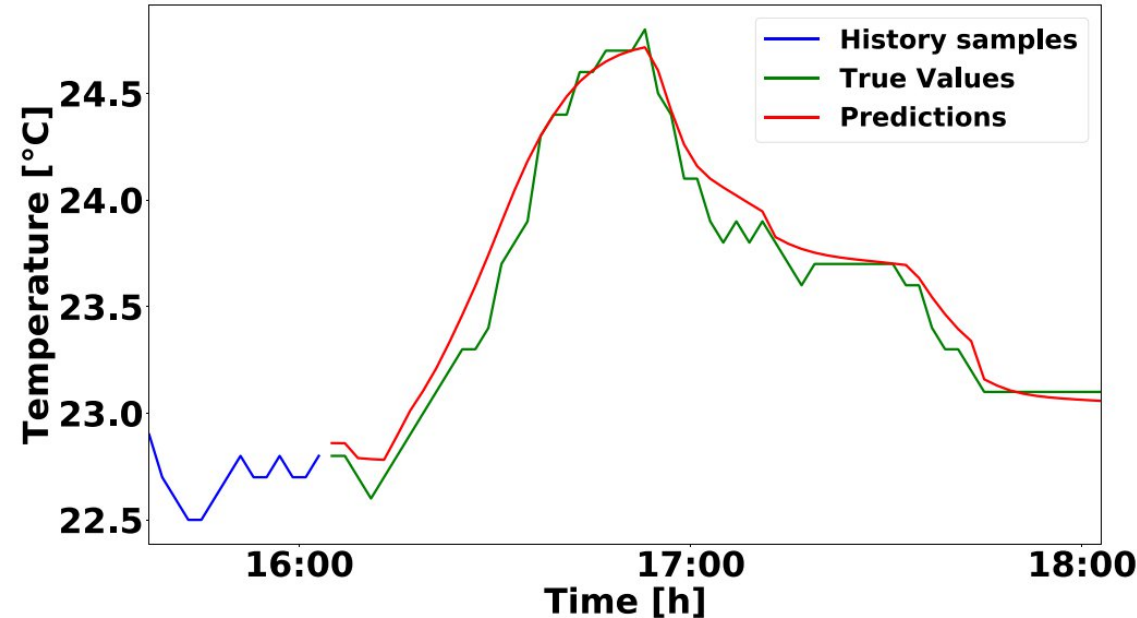
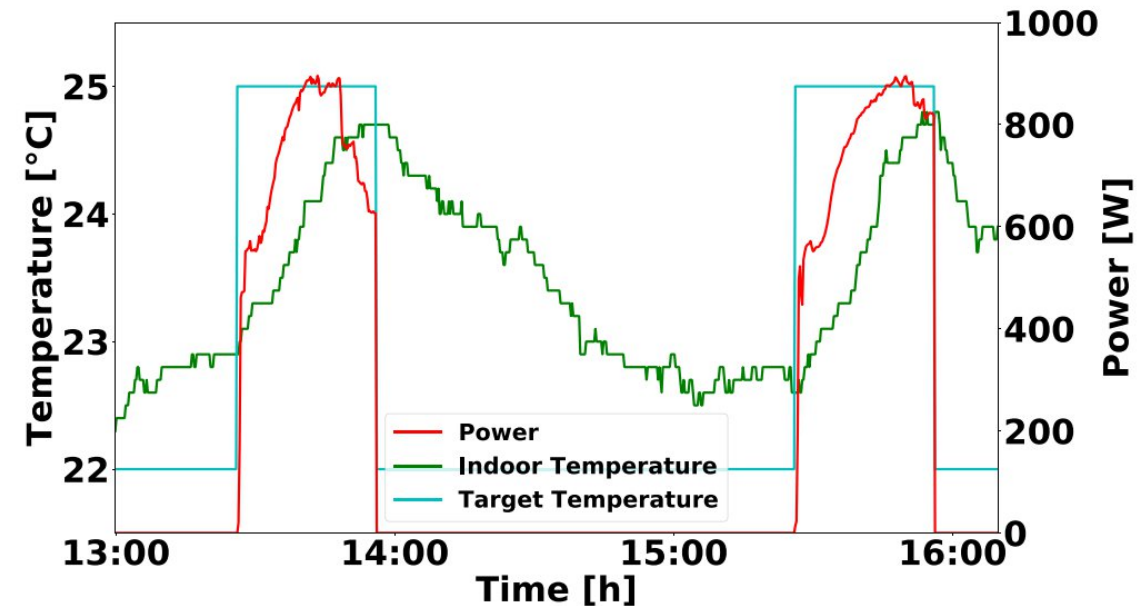


Sistemi upravljanja z energijo

- Skupek strojne opreme in algoritmov za optimizacijo porabe in proizvodnje električne energije.
 - Sodelovanje s ponudniki el. energije v storitvah fleksibilnosti
 - Razvrščanje vklopov naprav
- Napovedni modeli nepogrešljivi
 - Sklepanje odločitev in dogovorov v prihodnost
 - Napovedi stanja naprav, fotovoltaike, praznjenja baterije, itd.
- Ne smemo povzročati nevšečnosti uporabniku ali ogrožati varnosti naprav.

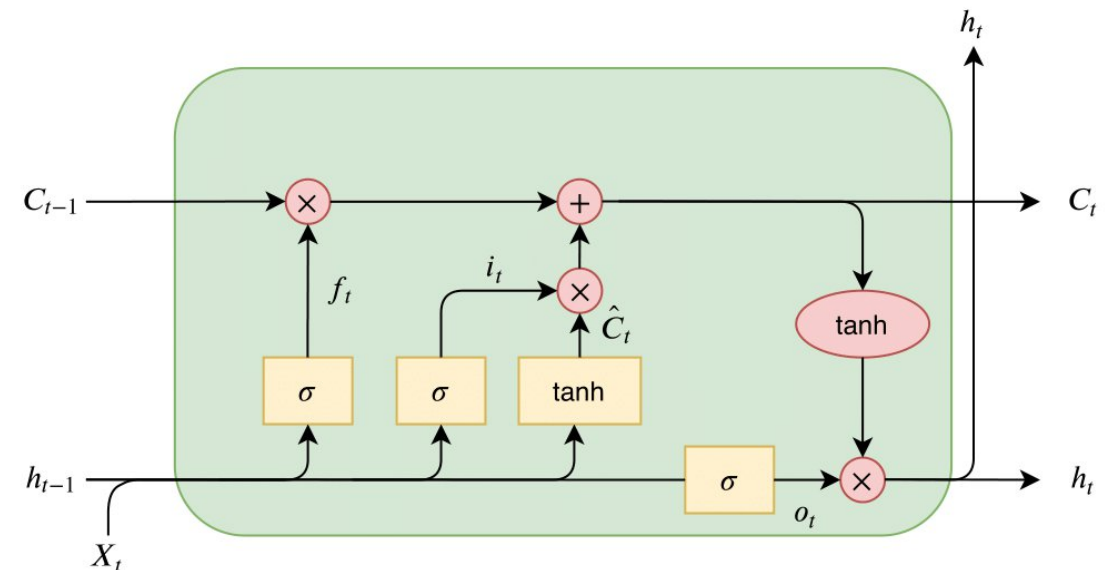

Napovedni modeli v sistemih upravljanja z energijo

- Pri namestitvi moramo prilagoditi modele na specifične posameznih naprav in okolja.
- Sistem potrebno vzpostaviti čimprej.
 - ▶ Malo podatkov
- Obnašanje naprave ali sistema se lahko spremeni.
 - ▶ Potrebno prilagajanje
- Potrebna učinkovitost in avtomatizacija vseh postopkov.



Razvoj napovednih modelov

- Arhitektura LSTM
- Optimizacija hiperparametrov z grid search
- 2x GeForce RTX 4090
- CUDA, Pytorch
 - ▶ `model = nn.DataParallel(model)`



Prilagajanje napovednih modelov v produkcijskem okolju

Razvili smo učinkovit algoritem prilagajanja napovednih modelov na spremembe.

- Ko model začne delovati slabo, ga moramo do-učiti na novih podatkih.
- Prilagajanje na nove vzorce slabo ohranja staro znanje
 - ▶ Nadprileganje
 - ▶ Pozabljanje prejšnjih vzorcev
- Ponovno učenje na celotni množici računsko prezahtevno
 - ▶ Dodatne zahteve po hrambi podatkov
 - ▶ „togost“ modela



Algoritem prilagajanja modela in izbire vzorcev

- Model prilagajamo na nove vzorce z dodanim manjšim delom zgodovinskih vzorcev.
- Iz obdobja zgodovine izberemo pomembne vzorce
 - ▶ Večino časa naprave ne delujejo
 - ▶ Proizvodnja fotovoltaike je ponoči nična
 - ▶ Itd.
- Različni načini delovanja naprav zastopani enakovredno

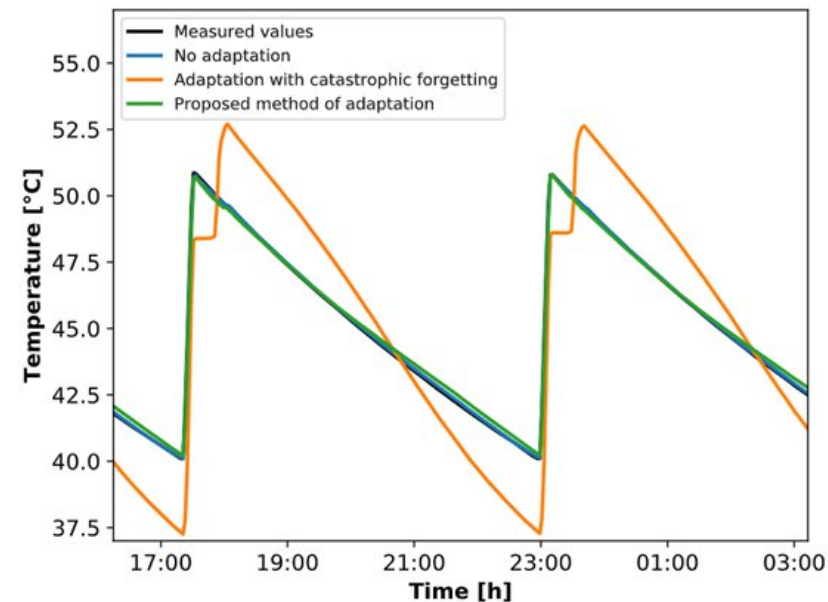


Fig. 4. Comparison of the different adaptation modes based on historical data (old patterns)

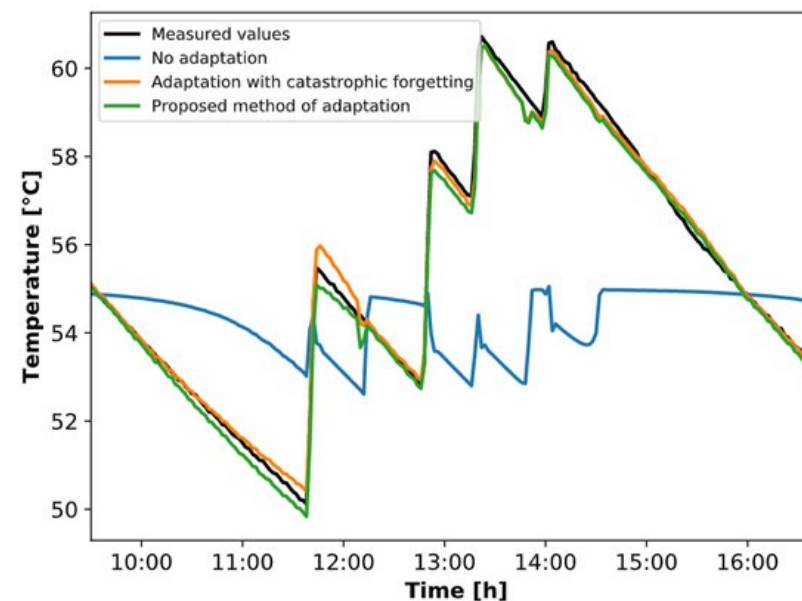


Fig. 5. Comparison of different adaptation modes based on recent data (new patterns)



Financiranje

Projekt EuroCC 2 financira Evropska unija. Financiran je s sredstvi Skupnega podjetja za evropsko visokozmogljivo računalništvo (EuroHPC JU) ter Nemčije, Bolgarije, Avstrije, Hrvaške, Cipra, Češke republike, Danske, Estonije, Finske, Grčije, Madžarske, Irske, Italije, Litve, Latvije, Poljske, Portugalske, Romunije, Slovenije, Španije, Švedske, Francije, Nizozemske, Belgije, Luksemburga, Slovaške, Norveške, Turčije, Republike Severne Makedonije, Islandije, Črne gore in Srbije v okviru sporazuma o dodelitvi sredstev št. 101101903.

Delovanje Nacionalnega kompetenčnega centra SLING sofinancira Ministrstvo za visoko šolstvo, znanost in inovacije.

Medijski sponzor

**Računalniške
novice**

www.racunalske-novice.com



**Co-funded by
the European Union**



**REPUBLIKA SLOVENIJA
MINISTRSTVO ZA VISOKO ŠOLSTVO,
ZNANOST IN INOVACIJE**