

Situacijsko zavedanje pametnega doma na podlagi porabe energije naprav

Leon Ciglar¹, Andrej Košir²

^{1,2}Fakulteta za elektrotehniko, Univerza v Ljubljani
E-pošta: ¹lc3882@student.uni-lj.si, ²andrej.kosir@fe.uni-lj.si

Smart homes situational awareness based on energy consumption of smart home devices

In this study, we developed an unsupervised classification-based algorithm that determines the presence of a certain situation, in our case: the presence of a person at home, based on power consumption data from smart home devices. We adapted the unsupervised learning method hierarchical clustering to analyze the usage patterns of the different devices. The result is a time function that shows the presence of a person over time. The ground truth data was manually determined and used to evaluate the results using supervised learning.

The results are promising and show that this is a difficult problem, as the data on the power consumption of the devices can be quite unexpected and the input data is ambiguous in terms of determining presence.

1 Uvod

V zadnjih letih je tehnologija pametnih domov močno napredovala, kar je omogočilo večjo avtomatizacijo in optimizacijo vsakodnevnih opravil. Pametni domovi vključujejo različne naprave in sisteme, ki izboljšujejo upravljanje energije, avtomatizacijo, udobje ter omogočajo integracijo naprednih storitev kot je tehnološka podpora oskrbe starejših. Podrobnejši pregled tehnologij pametnega doma z utemeljitvijo vloge in pomena razpoznavanja stanja uporabnikov prinaša pregledni članek [1]. Izzive na tem področju podaja članek [2], ki so cena pametnih sistemov, zmožnosti in zanesljivost, ter situacijsko zavedanje. Slednje podaja okvir tega članka.

Ključna komponenta pametnega doma je situacijsko zavedanje, ki omogoča prilagajanje sistema trenutnim razmeram in potrebam uporabnikov. Prvi sistemi za situacijsko zavedanje so bili opisani že zelo zgodaj [3]. Primerjavo metod pokriva delo [4], situacijsko zavedanje z upoštevanjem fizičnega prostora obravnava članek [5], ki ugotavlja, da je situacijsko zavedanje ključno za napredne storitve pametnega doma kot je aktivna podpora starejšim ipd.

Situacijsko zavedanje prinaša prednosti, kot so avtomatizacija, boljša uporabniška izkušnja in optimizacija omrežij, kar vodi k učinkovitejši porabi energije in zmanjšanju stroškov. Še pomembneje je situacijsko zavedanje omogoča nove napredne storitve s področja oskrbe starejših in varnosti. Pametne naprave zbirajo podatke o

porabi energije, uporabniških vzorcih in okoljskih pogojih ter sprejemajo odločitve, ki izboljšujejo učinkovitost sistema. Na primer, pametni termostati prilagajajo temperaturo glede na prisotnost oseb, pametne luči prilagajajo svetilnost glede na naravno svetlobo in pametne vtičnice izklopijo naprave, ko niso v uporabi, s čimer se zmanjšajo stroški energije in vpliv na okolje.

V zadnjem času se na področju situacijskega zavedanja uporabljajo kompleksni algoritmi kot je spodbujevalno učenje (angl. reinforcement learning) [6]. Kompleksnost problema kaže že osnovna konfiguracija spodbujevalnega učenja, ki vključuje prostorsko in časovno dimenzijo, različne tipe podatkov (nastavitve pametnega doma, stanje aktuatorjev) ter obnašanje uporabnikov pametnega doma.

Cilj tega članka je razviti algoritem, ki na osnovi podatkov o porabi energije določi časovno funkcijo prisotnosti dogodka, kot je prisotnost osebe doma. Analizirali smo vzorce porabe energije različnih naprav in uporabili metode nenadzorovanega učenja za identifikacijo vzorcev. Končni cilj je predstaviti rezultate kot časovno funkcijo prisotnosti izbranega dogodka, kar omogoča optimizacijo delovanja naprav in boljše prilagajanje pametnih sistemov trenutnim razmeram ter potrebam uporabnikov. Odločili smo se za pristop nenadzorovanega učenja klasiifikacije, ki ga ovrednotimo ob ročno določeni pravi vrednosti. Te prave vrednosti smo določili ročno na podlagi razumevanja vloge posamezne naprave v pametnem domu. Od tod tudi motivacija za uporabo nenadzorovanega strojnega učenja.

2 Trenutno stanje

V zadnjih letih je bilo opravljenih veliko raziskav na področju pametnih domov in situacijskega zavedanja na podlagi porabe energije. Kot navaja raziskava [7] lahko s pomočjo analize podatkov o porabi posameznih naprav zaznavamo vedno bolj kompleksne situacije kot so staranje ali poslabšanje zdravstvenega stanja. Njihova raziskava se je osredotočila v razvoj okvirja, ki se zaveda razmer (angl. situation-aware framework) in omogoča zmanjšanje porabe energije.

Pomen situacijskega zavedanja pametnega doma so raziskovalci prepoznali zelo zgodaj. Raziskava [3] poudarja dinamičnost razvoja situacijskega zavedanja pametnega doma ter njegov odnos do uporabnikov pametnega

doma.

Avtorja raziskave [8] poudarjata, da proizvajalci opreme za pametne domove posvečajo preveč pozornosti nadgratnji tehnologiji in premalo dejanskim potrebam in vrednostim, ki bi jih pametni dom lahko prinesel uporabnikom. Zavedanje konteksta je "teoretično jedro pametnega doma"[8] in prinaša zmožnost zagotavljanja ustreznih informacij in digitalnih storitev za uporabnike v realnem času. Pogled na situacijsko zavedanje z vidika senzorskih naprav podaja [9].

V zadnjem času na pomenu pridobiva opdrtokodna pobuda Home Assistant (<https://www.home-assistant.io/>), ki enostaven vpogled v stanje pametnega doma in ga podpira vedno več komercialnih sistemov. Poleg tega omogoča tudi integracijo realne 3D slike pametnega doma, v kateri je na voljo trenutno stanje pametnega doma. Podpira tudi strojno opremo za enostavno integracijo senzorskih naprav (<https://www.home-assistant.io/green/>).

Celovit pregled stanja na področju tehnologij pametnega doma prinaša pregledni članek [1], ki vključuje tako pregled algoritmov strojnega učenja kot tudi dostopnih testnih množic za razvoj novih algoritmov. Pri tem poudarja bistven vidik modeliranja pametnega doma, ki je spreminjanje vseh karakteristik pametnega doma skozi čas, kar neposredno vpliva na strojno učenje modelov za oceno situacije.

Kompleksnost problema določanja konteksta pametnega doma podaja delo [5], ki ta problem obravnava v okviru širokega okvira kibernetsko fizičnih sistemov in omrežij ter varovanja osebnih podatkov. Sam pregled različnih tipov napadov kaže, da obstajajo resne omejitve glede razpoložljivosti podatkov, kar neposredno vpliva na uporabnost posameznih metod.

3 Pristop k reševanju in metode

Problem, ki ga obravnavamo, je določitev prisotnosti oseb v pametnem domu na podlagi podatkov o porabi energije domačih naprav. Formalno, naj bo T množica časovnih žigov, D množica naprav v domu, $P_d(t)$ pa poraba energije naprave $d \in D$ v času $t \in T$. Cilj je določiti indikatorsko funkcijo $F : T \rightarrow \{0, 1\}$, ki podaja prisotnost oseb v domu, kjer $F(t) = 1$ pomeni, da je vsaj ena oseba prisotna, in $F(t) = 0$, da ni prisotna nobena oseba.

Uporabili bomo metode nenadzorovane klasifikacije, za analizo vzorcev v podatkih $P_d(t)$ in s tem določanjem funkcije $F(t)$. Privzemimo, da je znana prava vrednost pristotosti v domu $B : T \rightarrow \{0, 1\}$ (v našem primeru določena ročno), in funkcija $a(|\cdot|)$ označuje ploščino absolutne vrednosti razlike funkcije.

Problem opišemo kot brezpogojno optimizacijo

$$\operatorname{argmin}_F a(|F - B|). \quad (1)$$

ki minimizira napako napovedi prisotnosti oseb na podlagi podatkov $P_d(t)$.

Neposredno lahko preverimo, da za natančnost, kot jo vpeljemo v poglavju 3.2, veljajo naslednje trditve:

1. Če je ploščina $a(|F - B|) = 0$, potem je natančnost $A = 1$;

2. Če ploščina $a(|F - B|)$ naraste, potem se natančnost A ne more zmanjšati.

Od tod sklepamo, da rešitev optimizacijskega problema (1) pomeni rešitev visoke natančnosti.

3.1 Metode nenadzorovanega učenja razvrščanja

Reševanja problema določanja prisotnosti oseb v pametnem domu smo se lotili s pomočjo nenadzorovanega učenja razvrščanja (angl. clustering). Uporabili smo metodo aglomerativnega grozdenja (angl. Agglomerative Clustering) [10], ki postopoma združuje podatkovne točke v grozde (angl. cluster). Metoda na začetku vsako podatkovno točko obravnava kot svoj grozd, nato pa postopoma združuje najbližje grozde, dokler ne ostane en sam grozd ali dokler ne dosežemo želenega števila grozdov. To združevanje poteka na različne načine, v sklopu raziskave smo uporabili Wardovo metodo, ki združuje podatkovne točke na način, ki minimizira vsoto kvadratov razlik znotraj grozdov, kar zagotavlja kompaktne in enakomerno velike grozde. Običajno je smiselno število grozdov nekje med 2 in 10.

Za namen določanja števila grozdov smo si pomagali z dendrogramom – gre za drevesni prikaz razporeditve grozdov [11]. Ker želimo določiti prisotnost oseb v pametnem domu, smo se osredotočili na električne porabnike, ki so neposredno odvisni od prisotnosti uporabnika (npr. mikrovalovna pečica, garažna vrata, poraba v dnevni sobi).


Okvir postopka za določanja časovne funkcije prisotnosti dogodka je naslednji:

1. Iz podatkov o porabi energije naprav izberemo relevantne porabnike;
2. Normiramo in binariziramo podatke glede na določene prage;
3. Uporabimo Wardovo metodo za hierarhično grozdenje;
4. Ustvarimo dendrogram za vizualizacijo grozdov;
5. Določimo število grozdov na podlagi dendrograma;
6. Opravimo grozdenje in vizualiziramo rezultate;

3.2 Merjenje uspešnosti

Uspešnost rešitve merimo z natančnostjo identifikacije prisotnosti oseb v domu. Glavni indikator uspešnosti je pravilnost klasifikacije, ki bi jo lahko merili s pomočjo kriterijske funkcije, kot je stopnja točnosti (angl. accuracy), ki primerja napovedane prisotnosti oseb z dejanskimi podatki. Koncept merjenja uspešnosti prikazuje slika 1.

Pravi položaj razpoznanega konteksta se razpenja v časovnem intervalu $I_t = [t_{ts}, t_{te}]$, algoritem pa je razpozna interval $I_r = [t_{rs}, t_{re}]$. Vpeljati je potrebno tudi časovni interval opazovanja I_o , ki je interval, v katerem opazujemo celoten proces razpoznavne in je odvisen od aplikacije (npr. znotraj dneva, znotraj dopoldneva ipd).



Slika 1: Koncept ovrednotenja algoritma razpoznavanja konteksta v pametnem domu. Na časovno os je umeščen izbran kontekst (resnično v modrem) in rezultat algoritma določanja konteksta (razpoznano v oranži barvi). V enakih barvah sta dodani indikatorski funkciji kot v formulaciji optimizacijskega problema (1) v poglavju 3.

Od tod iz dolžin intervalov, označenih z $|\cdot|$, določimo vrednosti resnično pozitivno $TP = |I_r \cap I_t|$ (angl. true positive), resnično negativno $TN = |I_o \setminus I_r|$ (angl. true negative), lažno pozitiven $FP = |I_r \setminus I_t|$ (angl. false positive) in lažno negativen $FN = |I_t \setminus I_r|$ (angl. false negative). Od tod na klasičen način izračunamo natančnost $A = \frac{TP+TN}{TP+TN+FP+FN}$ (angl. accuracy).

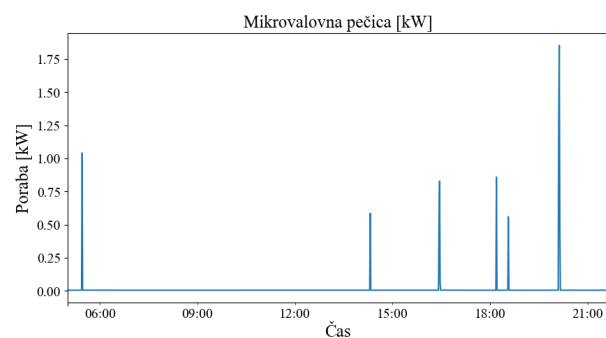
V sklopu raziskave bomo uspešnost algoritma ovrednotili z vizualizacijo časovne funkcije prisotnosti dogodkov in vizualno primerjavo z dejanskimi vzorci porabe iz katerih sklepamo prisotnosti.

4 Eksperimentalni rezultati

4.1 Testni podatki

Testni podatki zbrani v standardni tabeli, ki vsebuje odčitke porabe hišnih naprav v kW iz pametnega števca v časovnem razponu 365 dni za en sam pametni dom, vzorčna frekvenca 1 vzorec na minuto, glejte [12]. Na voljo so podatki za 18 naprav in prostorov (npr. mikrovalovna pečica, garažna vrata ipd in dnevna soba ipd) ter 14 kontekstnih podatkov (temperatura, vlažnost, ...). Podatki o številu uporabnikov ali njihovi dinamiki bivanja niso na voljo. Za našo izbrano situacijo se bomo osredotočili na naslednje porabnike: mikrovalovna pečica, garažna vrata in poraba v dnevni sobi (angl. Microwave, Garage door, Living room).

Primer podatkov za mikrovalovno pečico za prvih 1000 vzorcev (približno 16 ur) je prikazan na sliki 2.



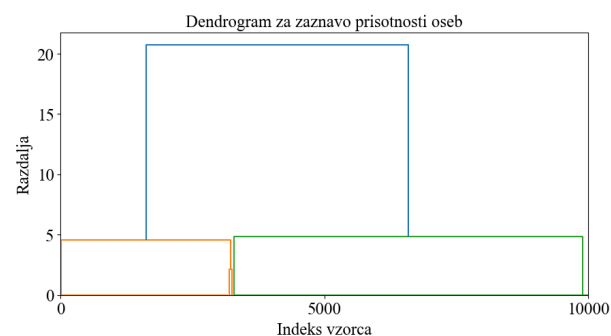
Slika 2: Primer vhodnega podatka: porabe električne energije za mikrovalovno pečico v kW za prvih 1000 vzorcev

Podatkom smo dodali še prave vrednosti, ki smo jih

določili ročno.

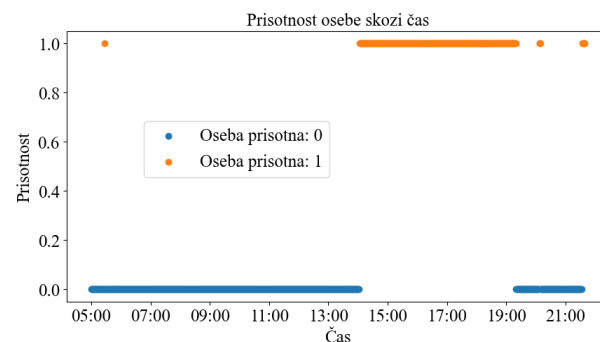
4.2 Predobdelava in nenadzorovano razvrščanje

Iz podatkov najprej odstranimo šum na merilni napravi. To storimo tako, da vizualno in s pomočjo histograma določimo prag in podatke binariziramo, to je dobimo indikatorske funkcije za posamezno napravo. Te rezultate za izbrane naprave smo združili in uporabili v Wardovi metodi hierarhičnega grozdenja. Rezultate lahko prikazemo kot dendrogram, ki ga prikazuje slika 3.



Slika 3: Rezultat Wardove metode hierarhičnega grozdenja v obliki dendrograma, prikazujemo le zgodnji del dendrograma.

Na podlagi dendrograma določimo število grozdov. Smiselno število grozdov bi lahko bilo 4 (kjer je razdalja približno 3) ali 2 (razdalja približno 10). Ker določamo indikator prisotnosti, ki ima dve vrednosti, smo izbrali 2 grozda. Nato izvedemo aglomerativno grozdenje in rezultate predstavimo kot časovno funkcijo prisotnosti osebe doma v odvisnosti od časa, glejte sliko 4.




Slika 4: Rezultat algoritma, kot časovna funkcija prisotnosti osebe v domu, kjer vrednost 1 pomeni, da je oseba prisotna, vrednost 0 pomeni, da oseba ni prisotna.

Rezultati kažejo, da predlagani algoritem za prvih 1000 vzorcev (prvih 16 ur) identificira prisotnost oseb v domu med 14:15 in 19:15 uro. Rezultate lahko primerjamo z realnimi vrednostmi in ročno določenimi pravimi vrednostmi v tem obdobju, kar vidimo na sliki 5.

Na podlagi dobljenih rezultatov smo določili matriko razvrščanja (Tabela 1) in natančnost $A = 0.792$.

Na podlagi izračunane vrednosti natančnosti lahko zaključimo, da naš algoritem na izbranem primeru relativno uspešno detektira prisotnost oseb v domu.



Slika 5: Časovna funkcija prisotnosti osebe iz slike 4 in ročno določenih pravih vrednosti (črna črtkana črta) ter binarnih vrednosti izbranih porabnikov skozi čas.

		Resnične vrednosti	
		Pozitivno	Negativno
Napovedane vrednosti	Pozitivno	327	0
	Negativno	208	465

Tabela 1: Tabela klasifikacij

5 Zaključki in razprava

V raziskavi smo razvili enostaven algoritem za določanje časovne funkcije prisotnosti oseb v pametnem domu na podlagi podatkov o porabi energije različnih naprav. S pomočjo aglomerativnega grozdenja smo obravnavali vzorce električne porabe naprav in identificirali prisotnost oseb v domu. Razviti algoritem omogoča učinkovitejše prilagajanje pametnih sistemov trenutnim razmeram in potrebam uporabnikov, kar lahko prispeva k večji energetski učinkovitosti in udobju v pametnih domovih. Ugotovitve niso posplošljive na celotno paleto tehnologij pametnih domov.

Predlagani postopek je razširljiv na večje število naprav – predvsem tistih, ki so neposredno odvisne od prisotnosti uporabnika (npr. klimatska naprava, televizor, računalnik, radio, fen). Prav tako je razširljiva na večje vzorčne frekvence. Omogoča vključitev kontekstov kot so temperatura in vlaga ipd. V sklopu nenadzorovanega učenja bi lahko vključili še dodatne metode strojnega učenja in nato kombinirali rezultate v hibridni sistem.

Dovolj natančno avtomatsko določena prisotnost uporabnikov v pametnem domu prinaša prednosti za uporabnike, saj izboljšuje uporabniško izkušnjo in energetsko učinkovitost pametnega doma. Uporabna je tudi za izboljšanje učinkovitosti storitev pametnega doma.

Nadaljnje delo vključuje razvoj hibridnega sistema določanja prisotnosti oseb z več algoritmi in integracijo večjega števila pametnih naprav.

Zahvala

Raziskavo je podprl program P2-0246 ICT4QoL - Informacijske in komunikacijske tehnologije za kakovost življenja

Literatura

- [1] Giovanni Diraco, Gabriele Rescio, Pietro Siciliano, and Alessandro Leone. Review on Human Action Recognition in Smart Living: Sensing Technology, Multimodality, Real-Time Processing, Interoperability, and Resource-Constrained Processing. *Sensors*, 23(11):5281, June 2023.
- [2] Mohamed Sultan and Khaled Nabil. Smart to Smarter: Smart Home Systems History, Future and Challenges. 2016.
- [3] Hojun Jaygarl, Katsunori Oyama, Jinchun Xia, and Carl K. Chang. HESA: A Human-Centric Evolvable Situation-Awareness Model in Smart Homes. In Sumi Helal, Simanta Mitra, Johnny Wong, Carl K. Chang, and Mounir Mokhtari, editors, *Smart Homes and Health Telematics*, volume 5120, pages 153–160. Springer Berlin Heidelberg, Berlin, Heidelberg, 2008. ISSN: 0302-9743, 1611-3349 Series Title: Lecture Notes in Computer Science.
- [4] Renato D. Costa, Celso M. Hirata, and Victor U. Pugliese. A Comparative Study of Situation Awareness-Based Decision-Making Model Reinforcement Learning Adaptive Automation in Evolving Conditions. *IEEE Access*, 11:16166–16182, 2023.
- [5] Muhammad Nouman Nafees, Neetesh Saxena, Alvaro Cardenas, Santiago Grijalva, and Pete Burnap. Smart Grid Cyber-Physical Situational Awareness of Complex Operational Technology Attacks: A Review. *ACM Computing Surveys*, 55(10):1–36, October 2023.
- [6] Nicole Merkle and Ralf Mikut. Context-Aware Composition of Agent Policies by Markov Decision Process Entity Embeddings and Agent Ensembles, August 2023. arXiv:2308.14521 [cs].
- [7] Richard O. Oyeleke, Pranav Parekh, Sophia DiCuffa, and Andrew Quinlan. Situation-aware framework for energy saving in unattended activities of daily living in smart home environments. In Kim Jongbae, Mounir Mokhtari, Hamdi Aloulou, Bessam Abdulrazak, and Lee Seungbok, editors, *Digital Health Transformation, Smart Ageing, and Managing Disability*, pages 38–50. Springer Nature Switzerland.
- [8] Lin Zhao and Zhihao Peng. Analysis and design of a context-aware smart home system. In *2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)*, pages 716–719.
- [9] Shu-Yun Lee and Fuchun Joseph Lin. Situation awareness in a smart home environment. In *2016 IEEE 3rd World Forum on Internet of Things (WF-IoT)*, pages 678–683, Reston, VA, USA, December 2016. IEEE.
- [10] scikit-learn developers. Agglomerativeclustering. Dosegljivo: <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.AgglomerativeClustering.html>. [Dostopano: 22. 7. 2024].
- [11] Wikipedia. Dendrogram. Dosegljivo: <https://en.wikipedia.org/wiki/Dendrogram>. Page Version ID: 1195077958.
- [12] Taranveer Singh Anttal. Smart home dataset with weather information. Dosegljivo: <https://www.kaggle.com/datasets/taranveer-smart-home-dataset-with-weather-newlineinformation/data>. [Dostopano: 22. 7. 2024].