

Modeliranje stanja uporabnikov z Markovskimi verigami

Simon Pestotnik¹, Andrej Košir¹

¹Univerza v Ljubljani, Fakulteta za elektrotehniko
E-pošta: andrej.kosir@fe.uni-lj.si

Modelling user states with Markov chains

This paper explores the application of Markov chains in modelling user affective in emotional states, focusing on the effectiveness of first-order Markov chains in capturing the dynamic of emotional transitions. The study uses two datasets, Wright (2017) and Rowland (2020), which contain time-series data on various emotional states of subjects. The analysis involves creating transition matrices, evaluating ergodicity, and calculating stationary distributions and return times to assess the suitability for modelling user emotional states. The findings indicate that while first-order Markov chains can provide valuable insights into emotional dynamics, there are limitations to their application. The research also examines the homogeneity of the data and classification of the Markov chain states. It contributes to the understanding of user emotional state modelling and provides a foundation for future research.

1 Uvod

Čustvena stanja so zapleten in dinamičen pojav, ki ga opredelimo kot subjektivno izkušnjo, ki jo posameznik doživlja v odnosu do sebe in okolja. Zaznava teh stanj je prepuščena posamezniku, kar pomeni, da je težko pričakovati, da bi se ljudje popolnoma strinjali o tem, kaj je čustveno stanje [1]. Kljub temu pa je pomembno razumevanje čustvenih stanj, saj imajo velik vpliv na našo motivacijo, vedenje in odločanje.

Predznak čustvenega stanja uporabnika pametnih sistemov je bistven dejavnik pri njegovem zaznavanju uporabniškega vmesnika in njegovi uspešnosti pri uporabi tega sistema. Uporabniki v negativnem čustvenem stanju pogosto zaznavajo iste naloge kot težje v primerjavi s tistimi v pozitivnem čustvenem stanju [2].

Ta članek se osredotoča na problem modeliranja stanja uporabnikov s pomočjo Markovskih verig. Natančneje, zanima nas, ali lahko z Markovsko verigo prvega reda dovolj dobro opišemo dinamiko stanj uporabnikov skozi čas. Cilj je zgraditi model, ki bo zajel prehode med stanji in omogočil napovedovanje prihodnjega stanja ter analizo osnovnih lastnosti modeliranega procesa. Poleg tega je namen tudi ovrednotiti Markovsko verigo kot metodo za modeliranje stanj uporabnikov ter oceniti ali izpolnjuje predpostavke Markovskih verig, kot je časovna

homogenost, ergodičnost in Markovska lastnost. Analizirali smo tudi dolgoročno obnašanje modela preko stacionarne porazdelitve ter povprečnih časov vračanja. S tem želimo ugotoviti, ali so Markovske verige primerne za razumevanje in napovedovanje stanj uporabnikov ter kakšne vpogleds lahko pridobimo iz takšnega modela.

2 Trenutno stanje

V tem poglavju so predstavljeni trije vidiki modeliranja stanja uporabnikov, in sicer: modeliranje uporabnikov v splošnem, uporaba Markovskih verig pri modeliranju uporabnikov ter Markovske verige in čustvena stanja.

2.1 Modeliranje stanja uporabnikov

Za učinkovito razumevanje in napovedovanje čustvenih stanj je potrebno uporabiti metode, ki omogočajo analizo dinamičnih sprememb skozi čas. V literaturi sta izpostavljena dva glavna pristopa za modeliranje: uporaba anketnih podatkov in podatkovno rudarjenje.

Prvi pristop temelji na zbiranju podatkov preko anket, kjer uporabniki neposredno ocenjujejo svoja čustvena stanja. Ena od uveljavljenih metod je uporaba Likertovih lestvic v kombinaciji z diferencialno čustveno skalo (DES) [3] [4]. Ta metoda omogoča kvantitativno oceno čustvenih stanj, ki jih uporabniki poročajo sami.

Drugi pristop se poslužuje obsežnih podatkovnih zbirk o vedenju uporabnikov, kjer s pomočjo podatkovnega rudarjenja skušamo odkriti vzorce in napovedati nadaljna dejanja ali stanja. Metode, kot so uporaba nevronskih mrež ter odločitvenih dreves, lahko iz teh podatkov izluščijo vzorce in dejavnike, ki vplivajo na čustvena stanja [5].

Čeprav ima vsak od pristopov svoje prednosti, rezultati kažejo, da so modeli, zgrajeni na osnovi anketnih podatkov, v splošnem natančnejši pri napovedovanju namer uporabnikov v primerjavi s tehnikami podatkovnega rudarjenja [6].

2.2 Uporaba Markovskih verig pri modeliranju

Markovske verige so eno od orodij za modeliranje vedenja uporabnikov v različnih domenah. Uporabljajo se za analizo sprememb v ocenah relevantnosti pri iskanju informacij [7] ter za napovedovanje nakupnega vedenja v spletni trgovini [8]. Zanimiv primer je uporaba za napovedovanje porabe zemlje [9]. Markovske verige so pri-

Ijubljene za te naloge, ker lahko zajamejo verjetnostne odvisnosti med stanji, hkrati pa ohranjajo enostavnost in računsko učinkovitost.

2.3 Markovske verige in čustvena stanja

V obstoječi literaturi so Markovske verige uporabno orodje za modeliranje čustvenih stanj uporabnikov. V članku [10] so jih uporabili neposredno pri modeliranju verjetnosti čustvenih stanj pogajalcev, pri čemer so ocenjevali "čustveno razdaljo". V drugem članku pa so uporabili homogene Markovske verige za klasifikacijo čustvenih stanj pri različnih interakcijah med človekom in računalnikom [11]. V članku [12] so s pomočjo fizioloških senzorjev razvili metodo za napovedovanje čustvenih stanj s pomočjo Russell-ovega dvodimenzionalnega čustvenega prostora.

3 Podatki in metode

3.1 Opis podatkov

V naslednjih dveh podpoglavjih je opisan izvor ter oblika podatkov.

3.1.1 Podatki Wright 2017

Podatki so povzeti iz članka [13], ki je zajel ambulantne paciente z osebnostnimi motnjami ter njihove partnerje. Študija je obsegala 222 oseb, ki so 33 dni večkrat dnevno ocenjevali svoj trenutni afekt z uporabo 25 različnih čustvenih pridevnikov. Ocene so podajali po socialnih interakcijah, pri čemer je vsak udeleženec v povprečju prispeval štiri ocene dnevno.

3.1.2 Podatki Rowland 2020

Podatki so povzeti iz študije čuječnosti [14], kjer je 125 študentov šestkrat dnevno 40 dni poročalo o svojem trenutnem afektu preko pozivov na pametnem telefonu poslanih v naključnem času. Podatki vključujejo osem čustvenih stanj, ocenjenih od 0 do 1000 ob vsakem pozivu.

3.2 Markovske verige

3.2.1 Definicija

Diskretna Markovska veriga je stohastični proces, ki prehaja med različnimi stanji v diskretnem času, pri čemer je verjetnost prihodnjega stanja odvisna le od trenutnega stanja in ne od preteklih stanj, ter je ta verjetnost neodvisna od časa. Matematično jo lahko definiramo na naslednji način:

$$\begin{aligned} P[X_{n+1} = x_{n+1} | X_n = x_n, \dots, X_0 = x_0] \\ = P[X_{n+1} = x_{n+1} | X_n = x_n]. \end{aligned}$$

Verjetnosti prehodov med stanji so podane s prehodno matriko P , kjer je element P_{ij} verjetnost prehoda iz stanja i v stanje j ,

$$P_{ij} = P[X_{n+1} = j | X_n = i].$$

3.2.2 Postopek analize ter definicije ključnih pojmov

Podatki navedenih podatkovnih množic so podani v obliki CSV datoteke in jih je potrebno pretvoriti v ustrezen format za nadaljnjo uporabo. Prvi korak analize vključuje izdelavo prehodne matrike prvega reda, ki jo pridobimo s štetjem prehodov med različnimi stanji. Dobljeno matriko nato normaliziramo, da dobimo verjetnosti prehodov.

Za preverjanje primernosti podatkov za modeliranje z Markovskimi verigami uporabimo prehodno matriko drugega reda, ki prikazuje verjetnosti prehodov glede na prejšnji dve stanji. Če se te verjetnosti ne razlikujejo bistveno od verjetnosti prehodov prvega reda, lahko sklepamo, da je naslednje stanje neodvisno od prejšnjih dveh.

Dolgoročno obnašanje sistema analiziramo s stacionarno porazdelitvijo, ki predstavlja verjetnost, da se sistem nahaja v določenem stanju v neskončnosti. Če je veriga ergodična, stacionarno porazdelitev dobimo z iterativnim množenjem prehodne matrike, dokler se vrednosti ne stabilizirajo.

Časovno homogenost podatkov preverjamo z izračunom prehodnih matrik za manjše vzorce in primerjavo z matriko celotnih podatkov. Če se razlike zmanjšujejo z dodajanjem podatkov, so podatki časovno homogeni.

Povprečen čas vračanja opisuje povprečno število korakov za vrnitev v določeno stanje.

Srednjo kvadratno napako (MSE - Mean Squared Error) izračunamo kot povprečje kvadratov razlik med istoležnimi elementi matrike.

Za analizo lastnosti Markovske verige, kot so ergodičnost, regularnost in absorpcija, ter za klasifikacijo stanj smo uporabili knjižnico PyDTMC.

Ustreznost modela modela preverimo kot razlike med prehodnimi matrikami, dobljenimi na podvzorcih. Poleg tega preverjamo ergodičnost verige ter smiselnost klasifikacije stanj na povrnjljiva, minljiva in absorpcijska.

3.3 Python knjižnica PyDTMC

Za analizo lastnosti Markovske verige uporabljamo knjižnico PyDTMC (Python Discrete-Time Markov Chains) [15]. Ta omogoča preverjanje ključnih lastnosti, kot so ergodičnost, regularnost in absorpcija. Z njo lahko preverimo, ali je veriga ergodična (konvergira k enotni stacionarni porazdelitvi) in regularna (vsebuje samo stabilna stanja). PyDTMC omogoča tudi klasifikacijo stanj na povrnjljiva (pozitivno ali ničelno), prehodna in absorpcijska. Za pozitivno povrnjljiva stanja lahko določimo povprečen čas vračanja.

4 Eksperimentalni rezultati

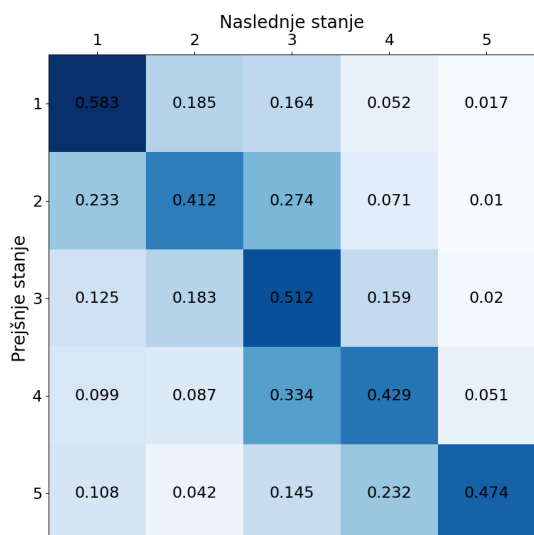
Rezultati so navedeni po posameznih testnih množicah.

4.1 Testna množica Wright (Attentive)

Predobdelava podatkov je vključevala izločitev stolpca za stopnjo pozornosti, ki vsebuje časovno zaporedje čustvenih stanj. Pri tem so bili upoštevani le prehodi med stanji znotraj istega dne in za istega subjekta. Prav tako niso bili upoštevani prehodi z manjkajočimi vrednosti. S

tem smo zagotovili, da so analizirani podatki odražali realne prehode med čustvenimi stanji.


Po predobdelavi je bila izdelana prehodna matrika, vidna na sliki 1, ki kaže, da subjekti z največjo verjetnostjo ostanejo na isti stopnji pozornosti vsaj dva zaporedna vzorca, kar nakazuje na čustveno stabilnost na krajših časovnih obdobjih. Verjetnosti prehodov na sosednja stanja so nekoliko višje kot na bolj oddaljena stanja.



Slika 1: Prehodna matrika Markovske verige čustvenih stanj množice Wright.

Prehodna matrika prehodov v dveh korakih kaže, da pretekla stopnja nekoliko vpliva na prihodnje stanje, vendar razlike niso velike, kar potrjuje ustreznost Markovske verige prvega reda.

Stacionarna porazdelitev na sliki 2 kaže, da imajo subjekti na dolgi rok stopnjo pozornosti med 1 in 3.



Slika 2: Stacionarna porazdelitev stanj.

Časovno homogenost smo preverili z večanjem vzorca, rezultati v tabeli 1 pa kažejo, da je predpostavka o časovni homogenosti izpolnjena.

Analiza z uporabo knjižnice PyDTMC pokaže, da je veriga ergodična, vsa stanja so pozitivno povrnjiva in aperiodična, brez absorpcijskih ali prehodnih stanj. Povprečni časi vračanja za stanja 1, 2, 3, 4, 5 so po vrsti 3, 76, 4, 74, 3, 06, 6, 34, 24, 79 in kažejo da je pozornost pri subjektih večinoma nizka.

4.2 Testna množica Rowland (Anxious)


Podatki so strukturirani podobno kot pri množici Wright, le da smo podatke na lestvici 0-100 prilagodili na lestvico 1-5, pri čemer smo vrednostim 0-19 priredili 1 in tako dalje. Vrednost 100 je dobila 5. Po tej prilagoditvi je sledila

Št. vzorcev	Največja razlika	MSE
1000	0,140913	0,004052
2000	0,133429	0,003008
3000	0,134048	0,002427
4000	0,106931	0,001956
5000	0,095162	0,001638
6000	0,091342	0,001385
7000	0,070402	0,001111

Tabela 1: Največja razlika ter srednja kvadratna napaka v odvisnosti od števila vzorcev.

izločitev prehodov, ki niso vsebovali veljavnih vrednosti ali niso bili v istem dnevu ali pri istem subjektu. Izbrano čustveno stanje tukaj je bila tesnoba.


Po predobdelavi smo ocenili prehodno matriko na sliki 3, ki kaže, da je verjetnost ohranitve stanja 1 največja, vendar so razlike v prehodih manjše, kar nakazuje na kratkotrajnost povečane tesnobe.



Slika 3: Prehodna matrika Markovske verige množice Rowland.

Prehodna matrika prehodov v dveh korakih razkriva, da so podatki pogosto odvisni od prejšnjega stanja, še posebej pri višjih stopnjah tesnobe.

Stacionarna porazdelitev na sliki 4, dobljena po šestih iteracijah množenja prehodne matrike nakazuje, da imajo subjekti na dolgi rok stopnjo tesnobe 1 (77%).



Slika 4: Stacionarna porazdelitev stanj.

Podatki so v tem primeru nekoliko manj homogeni in konvergirajo šele pri kasnejšem vzorcu, kar je vidno v tabeli 2.

Št. vzorcev	Največja razlika	MSE
1000	0,140913	0,004052
5000	0,255537	0,006253
8000	0,192667	0,004818
10000	0,15387	0,003155
16000	0,09719	0,000869

Tabela 2: Največja razlika ter srednja kvadratna napaka v odvisnosti od števila vzorcev.

Markovska veriga je ergodična, pozitivno povrnjiva in aperiodična, kar pomeni da lahko tesnoba prosto prehaja med vsemi nivoji. Povprečni časi vračanja za stanja 1, 2, 3, 4, 5 so po vrsti 1, 31, 7, 70, 35, 39, 21, 76, 39, 69, potrjujejo daljše čase vračanja v višje nivoje tesnobe v primerjavi z nižjimi.

5 Razprava in zaključek

Rezultati so pokazali, da lahko z Markovsko verigo prvega reda dovolj dobro opišemo dinamiko čustvenih stanj oseb skozi čas. Analiza prehodnih matrik in stacionarnih porazdelitev je pokazala, da subjekti z največjo verjetnostjo ostanejo na isti stopnji pozornosti in testnosti vsaj dva zaporedna vzorca, kar nakazuje na čustveno stabilnost v krajših časovnih obdobjih.

Ugotovili smo, da je časovna homogenost podatkov pomembna za uporabo Markovskih verig. Predpostavka o časovni homogenosti je upravičena za testno množico Wright, saj se največja razlika zmanjša na 0,095 že pri 4000 vzorcih, nekoliko težje pa jo upravičimo za testno množico Rowland, kjer se razlika zmanjša na 0,097 šele po 16000 vzorcih.

Povprečni časi vračanja prav tako kažejo na razlike med podatkovnima množicama. Pri Wright je najkrajši čas vračanja 3,06 za stanje 3, najdaljši pa 24,79 za stanje 5. Pri Rowland je najkrajši čas vračanja 1,31 za stanje 1, najdaljši pa 39,69 za stanje 5. Te ugotovitve kažejo, da je tesnoba bolj spremenljiva in manj stabilna v primerjavi s pozornostjo.

Omejitve študije so vključevale le uporabo dveh testnih množic ter omejitev na prehodno matriko prvega reda, kar lahko ne zajame vseh dejavnikov čustvenih dinamik.

V nadaljevanju bi lahko bile uporabljene druge metode za modeliranje čustvenih stanj, kot so že omenjene nevronske mreže ali druge metode strojnega učenja.

Boljše razumevanje modeliranja z Markovskimi verigami lahko vodi v izboljšanje razumevanja in upravljanja interakcij s pametnimi napravami, optimizacijo učnih procesov, saj lahko boljše ocenimo trajanje različnih čustvenih stanj v različnih interakcijah. Modeliranje čustvenih stanj uporabnikov z Markovskimi verigami je uporabno pri določanju časovno odvisnega konteksta uporabnikov pri uporabi pametnih sistemov kot so pametni domovi in avtonomna vozila.

Zahvala

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

Literatura

- [1] T. Justin, "Umetno tvorjenje čustvenega slovenskega govora z uporabo prikritih markovovih modelov." Doktorska disertacija, Univerza v Ljubljani, 2016.
- [2] A. D. Rowe and J. Fitness, "Understanding the Role of Negative Emotions in Adult Learning and Achievement: A Social Functional Perspective," *Behavioral Sciences*, vol. 8, p. 27, Feb. 2018.
- [3] G. J. Boyle, "Reliability and validity of izard's differential emotions scale," vol. 5, pp. 747–750.
- [4] A. Joshi, S. Kale, S. Chandel, and D. Pal, "Likert scale: Explored and explained," vol. 7, pp. 396–403.
- [5] E. Frias-Martinez, S. Chen, and X. Liu, "Survey of data mining approaches to user modeling for adaptive hypermedia," vol. 36, pp. 734–749.
- [6] C. Baumann, G. Elliott, and S. Burton, "Modeling customer satisfaction and loyalty: Survey data versus data mining," vol. 26, pp. 148–157.
- [7] M. Zhitomirsky-Geffet, J. Bar-Ilan, and M. Levene, "A markov chain model for changes in users' assessment of search results," vol. 11, no. 5, p. e0155285.
- [8] A. Jandera and T. Skovranek, "Customer behaviour hidden markov model," vol. 10, p. 1230.
- [9] C. Liping, S. Yujun, and S. Saeed, "Monitoring and predicting land use and land cover changes using remote sensing and GIS techniques—a case study of a hilly area, jiangle, china," vol. 13, no. 7, p. e0200493. Publisher: Public Library of Science.
- [10] J. Clempner, "Shaping emotions in negotiation: a nash bargaining solution," vol. 12.
- [11] D.-m. Yu, Y. Tang, J. Fang, Y.-p. Zhou, and M.-y. Sun, "Homogeneous markov chain for modeling emotional interactions," in *2008 10th International Conference on Advanced Communication Technology*, vol. 1, pp. 265–269. ISSN: 1738-9445.
- [12] Y. Wu, M. Arevalillo Herráez, S. Katsigiannis, and N. Ramzan, "On the benefits of using hidden markov models to predict emotions," in *Proceedings of the 30th ACM Conference on User Modeling, Adaptation and Personalization, UMAP '22*, pp. 164–169, Association for Computing Machinery.
- [13] "Indicators of affect dynamics: Structure, reliability, and personality correlates - leon p. wendt, aidan g.c. wright, paul a. pilkonis, william c. woods, jaap j.a. denissen, anja kühnell, johannes zimmermann, 2020."
- [14] Z. Rowland and M. Wenzel, "Mindfulness and affect-network density: Does mindfulness facilitate disengagement from affective experiences in daily life?," vol. 11.
- [15] T. Belluzzo, "PyDTMC documentation," 2024. <https://pydtmc.readthedocs.io/>, Dostopano: 22.07.2024.