

Emotivne lastnosti latentnih faktorjev v priporočilnih sistemih za slike

Marko Tkalčič, Andrej Košir, Štefan Dobravec, Jurij Tasič

Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana, Slovenija
E-pošta: marko.tkalcic@fe.uni-lj.si

Povzetek. V tem prispevku smo analizirali povezavo med latentnimi faktorji, ki nosijo največ variance in emotivnimi lastnostmi teh faktorjev v bazi priporočilnega sistema za slike. S pomočjo matričnega razcepa smo poiskali dva najpomembnejša faktorja v matriki ocen. S pomočjo emotivnih oznak vsebin smo poiskali emotivne lastnosti vsebin, ki ležijo na ekstremih prvih dveh faktorjev. Rezultati so pokazali, da je prvi faktor močno koreliran z valenco in dominanco, vzbujenje pa nima očitne povezave s prvim faktorjem. Drugi faktor ne izkazuje relacije z nobeno od treh dimenzij emocij.

Ključne besede: priporočilni sistemi, emotivno računalništvo, matrični razcep, latentni faktorji

Emotional properties of latent factors in an image recommender system

In this paper we analyze the relations between the latent factors with high variance description and affective parameters in an image recommender system. Using the matrix factorization approach we identify the main two factors in the user-item rating database. We exploit the affective metadata related to each item to identify relations between the main factors and the affective metadata. Results show that the first latent factor is strongly related with the valence and dominance while the arousal does not appear to be related. The second factor, however, shows no relation with the affective parameters.

1 UVOD

Priporočilni sistemi za multimedijske vsebine so sistemi, ki na podlagi poznavanja uporabnikovih nagnjenj (profil uporabnika) in poznavanja lastnosti multimedijskih vsebin (profil vsebine) predlagajo omejen nabor multimedijskih vsebin po okusu uporabnika. Ti sistemi so že prerasli testna okolja in si utrlji pot v tržne aplikacije. Spletni portal Amazon, na primer, uporablja tovrstne rešitve za priporočanje izdelkov v svoji spletni trgovini [5]. Razvoj priporočilnih sistemov poteka predvsem v dveh smereh: (i) razvoj in izboljšava postopkov priporočanja in (ii) iskanje značilk, ki kar najbolj predstavijo objekte in subjekte v priporočilnih sistemih.

Prvi postopki priporočanja so bili preprosti vsebinski (ang. content-based recommenders - CBR) [6] in skupinski (ang. collaborative filtering - CF) [1]. Na natečaju Netflix (<http://www.netflixprize.com/>) pa se je izkazalo, da postopek matričnega razcepa privede do bistveno boljših rezultatov kot drugi pristopi v priporočilnih sistemih [2], [3]. Trenutno pristop z uporabo matričnega

razcepa velja za najboljšega v primerih, ko je učna množica dovolj velika.

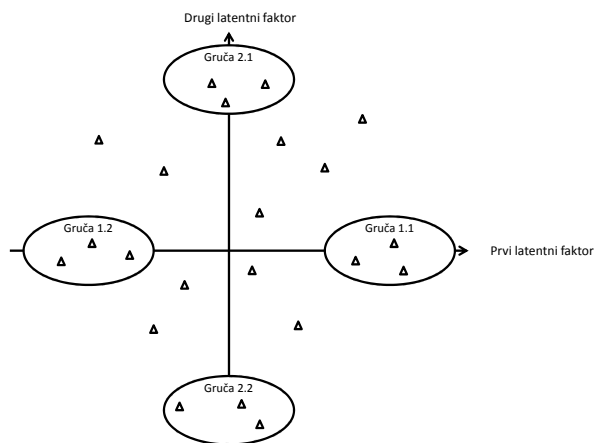
Po drugi strani pa je bila predmet raziskav tudi nadgradnja profila uporabnika in profila vsebin z novimi značilkami, ki nosijo kar največ informacije za uspešno napoved relevantnih vsebin. Kot prve značilke so se uporabljali generični metapodatki, na primer žanr, igralska zasedba, režiser itn. [7], [1]. Postopki priporočanja so se hitro razvili to te mere, da so te metapodatke popolnoma izkoristili, zato so se raziskave usmerile k iskanju drugačnih značilk, ki bi izboljšale učinkovitost priporočilnih sistemov. V naših predhodnih raziskavah smo pokazali, da emotivni metapodatki pojasnijo znaten del variance v uporabniških podatkih in s tem izboljšajo uspešnost vsebinskega priporočilnega sistema [10].

Uvedba pristopa z uporabo postopka matričnega razcepa je pomenila zamenjavo predhodno človeku razumljivih značilk (kot je na primer žanr) z latentnimi značilkami, ki običajno niso človeku razumljive. Tako se je za podatkovni nabor Netflix izkazalo, da prva latentna faktorja pomenita delitev glede na intelektualnost oziroma moškost/ženskost [3], [2]. Tak postopek, torej interpretacija lastnosti glavnih latentnih faktorjev, je raziskovalno zanimiv pristop, saj odpira drugačen pogled na uporabnikova nagnjenja in njihovo modeliranje.

1.1 Predstavitev problema

Glavni cilj prispevka je raziskava lastnosti glavnih latentnih faktorjev nabora podatkov priporočilnega sistema z vidika emocij, ki jih vsebine vzbudijo v končnih uporabnikih. Problem, predstavljen v prispevku, temelji na dveh predpostavkah: (i) da postopek matričnega razcepa identificira glavne latentne faktorje, ki opisujejo varianco ocen, ki so jih uporabniki pripisali vsebinam, ter (ii) da se emotivni parametri vsebin (parametri, ki opisujejo emocijo, vzbujeno v uporabniku) spreminjajo


vzdolž glavnih osi, določenih z latentnimi faktorji. Na podlagi danih predpostavk želimo s pomočjo eksplanatorne faktorске analize identificirati emotivne parametre, ki predstavljajo vsebine na skrajnih koncih osi, kot je to predstavljeno v sliki 1. Gručam teh vsebin smo dodelili oznake $G_{1.1}$, $G_{1.2}$, $G_{2.1}$ in $G_{2.2}$. Rezultat je vizualizacija in interpretacija teh parametrov.



Slika 1: Vsebine (predstavljene s trikotniki) so razpršene v prostoru, določenem z latentnimi faktorji. V gruče vsebin $G_{1.1}$, $G_{1.2}$, $G_{2.1}$ in $G_{2.2}$ so združene vsebine na skrajnih koncih osi dveh glavnih latentnih faktorjev.

2 POSKUS

Potek poskusa je prikazan na sliki 2. V fazi pridobivanja podatkov smo pripravili matriko ocen, ki so jih realni uporabniki prisodili izbranim vsebinam. S postopkom matričnega razcepa smo nato izločili glavne latentne faktorje. Sledila je statistična obdelava vsebin, ki so se nahajale na skrajnih oseh ravnine, določene z dvema glavnima latentnima faktorjema.



Slika 2: Potek poskusa

2.1 Nabor podatkov

Pripravili smo polno matriko ocen (ponazorjena v tabeli 1). V postopku je sodelovalo 52 uporabnikov, označenih z $u \in \{1 \dots 52\}$, ki so ocenili 70 slik, označenih z $i \in \{1 \dots 70\}$. Ocen, ki jo je uporabnik u prisodil sliki i , smo označili kot $r(u, i) \in \{1 \dots 5\}$. Slike

so bile izbrane iz veliko večjega nabora slik IAPS [4], v katerem so slike označene z metapodatki, ki opisujejo emocijo, vzbujeno v uporabniku. Emocije smo označili z razširjenimi in pogosto uporabljenimi parametri: valenca (ang. valence), vzburjenje (ang. arousal) in dominanca (ang. dominance) [8]. Valenca loči emocije na pozitivne (npr. veselje) in negativne (npr. žalost), vzburjenje opisuje intenzivnost opazovane emocije, dominanca pa ovladovanje (npr. pomirjenost) oziroma neovladovanje (npr. močna jeza) emocije. Vsaki sliki i je bila tako pripisano povprečje valence, vzburjenja in dominanca, ki jih je vzbudila naboru uporabnikov, kot trojica vrednosti $md(i) = \{\bar{v}, \bar{a}, \bar{d}\}$. Pri tem se nabor uporabnikov, uporabljen za izračun povprečij, razlikuje od nabora uporabnikov, ki so sliki prisodili oceno. Podrobnejše informacije o naboru podatkov so na voljo v virih [11].

$u \backslash i$	1	2	3	...	70
1	$r(1, 1)$	$r(1, 2)$	$r(1, 3)$		$r(1, 70)$
2	$r(2, 1)$	$r(2, 2)$	$r(2, 3)$		$r(2, 70)$
3	$r(3, 1)$	$r(3, 2)$	$r(3, 3)$		$r(3, 70)$
...					
52	$r(52, 1)$	$r(52, 2)$	$r(52, 3)$		$r(52, 70)$

Tabela 1: Matrika ocen vsebin: vsebuje ocene $r(u, i) \in \{1 \dots 5\}$, ki so jih uporabniki $u \in \{1 \dots 52\}$, prisodili vsebinam $i \in \{1 \dots 70\}$.

2.2 Matrični razcep

Pristop z uporabo matričnega razcepa identificira prostor latentnih faktorjev, v katerem se vhodni podatki opišejo na bolj zgoščen način. V našem primeru so vhodni podatki združeni v matriko ocen vsebin (glej tabelo 1). Čeprav je metoda singularnih vrednosti (ang. singular value decomposition - SVD) bolj priljubljena, je za uporabo v priporočilnih sistemih neuporabna iz dveh razlogov: (i) redke posejanosti podatkov ter (ii) velikosti prostora podatkov (veliko uporabnikov in vsebin). Zato smo glavne latentne faktorje izračunali s pogosto uporabljenim stohastičnim gradientnim postopkom (ang. stochastic gradient descent algorithm) [2], [3], [9]. Pri postopku matričnega razcepa je vsak uporabnik opisan z vektorjem latentnih faktorjev uporabnika p_u , prav tako je vsaka vsebina opisana z vektorjem latentnih faktorjev vsebine q_i .

Profil uporabnika, ki opisuje uporabnikova nagnjenja, je tako v obliki vektorja latentnih lastnosti p_u . Vrednosti v vektorju odsevajo stopnjo uporabnikovega nagnjenja k ustrezni latentni značilki. V podatkovnem naboru Netflix, na primer, prvi latentni faktor kaže na (ne)intelektualnost. Visoka vrednost prvega faktorja profila uporabnika bi tako pomenila nagnjenost uporabnika k intelektualnim vsebinam.

Po enakem razmisleku vrednosti v profilu vsebine q_i odsevajo stopnjo prisotnosti ustrezne latentne lastnosti v dani vsebini. V podatkovnem naboru Netflix bi tako visoka vrednost prvega faktorja v profilu vsebine pomenila, da gre za intelektualno vsebino.

gruča	število vsebin v gruči
$G_{1.1}$	31
$G_{1.2}$	13
$G_{2.1}$	15
$G_{2.2}$	24

Tabela 2: Število vsebin v vsaki od štirih opazovanih gruč

Vektorja imata enako dolžino F , ki pomeni število uporabljenih značilk. Naloga priporočilnega sistema je, da predvidi oceno, ki bi jo izbrani uporabnik u dodelil določeni vsebini i . Napoved ocene $\hat{r}(u, i)$ je izračunana kot skalarni produkt obeh vektorjev $\hat{r}(u, i) = p_u \cdot q_i^T$. V fazi učenja stohastični gradientni postopek uči vrednosti značilk v vektorjih p in q z minimizacijo srednje kvadratične napake (ang. root mean square error - RMSE) med pravo oceno $r(u, i)$ in napovedano oceno $\hat{r}(u, i)$:

$$\operatorname{argmin}_{u, i} \sum (r(u, i) - p_u \cdot q_i^T) + \lambda(\|q_i\|^2 + \|p_u\|^2) \quad (1)$$

kjer je λ regularizacijski faktor, ki služi preprečevanju prekomernega prilaganja (ang. overfitting). Stohastični gradientni postopek smo izvedli v večjem številu zaporednih učnih ciklov.

Uspešnost napovedi ocen z vidika RMSE smo opazovali ob uporabi različnega števila značilk $F \in \{1 \dots 300\}$ in različnega števila učnih ciklov $e \in \{1 \dots 500\}$.

Pri določitvi dveh glavnih latentnih faktorjev smo uporabili opisani postopek matričnega razcepa z uporabo dveh faktorjev $F = 2$ in $e = 2000$ učnimi cikli. Vsak uporabnik in vsaka vsebina je tako predstavljena z vektorjem dveh značilk, na podlagi katerih izračunamo napovedano oceno

$$\hat{r}(u, i) = (q_{i,1}, q_{i,2}) \cdot (p_{u,1}, p_{u,2}), \quad (2)$$



kjer vrednosti značilk $q_{i,1}, q_{i,2}, p_{u,1}$ in $p_{u,2}$ pomenijo vrednosti prvih dveh latentnih faktorjev uporabnika u in vsebine i .

2.3 Razporejanje v gruče

V vsako gručo vsebin smo razporedili tiste vsebine, ki so imele vrednost ustrezne značilke nad 70 % maksimalne vrednosti za gruči $G_{1.1}$ in $G_{2.1}$ ter manj kot 30 % maksimalne vrednosti za gruči $G_{1.2}$ in $G_{2.2}$. Tak pristop je v gruče razporedil različno število vsebin, kot je prikazano v tabeli 2.

3 REZULTATI

Kot zanimiv stranski rezultat poskusa smo najprej opazovali uspešnost postopka matričnega razcepa (v smislu RMSE) v odvisnosti števila uporabljenih značilk F (glej sliko 3) ter v odvisnosti od števila učnih ciklov e

Slika 3: RMSE (y os) kot funkcija števila uporabljenih značilk F (x os) pri izbranem številu učnih ciklov $e \in \{10, 50, 100, 500\}$ Slika 4: RMSE (y os) kot funkcija števila učnih ciklov e (x os) pri izbranem številu uporabljenih značilk ($F = 100$)


(glej sliko 4). Uporabili smo desetkratno navzkrižno preverjanje.

Slike od 5 do 7 prikazujejo porazdelitev emotivnih parametrov valenca, vzburjenje in dominanca v štirih opazovanih gručah v obliki grafikona kvantilov. Na vsakem grafikonu kvantilov so prikazani: srednja oznaka, ki pomeni mediano, robova okvirja, ki pomenita percentili 25 in 75, zunanja kraka, ki sta skrajni vrednosti brez upoštevanja zunanjih točk (ang. outliers), ter zunanje točke, ki so prikazane individualno z oznako +.


4 SKLEP

Rezultati kažejo, da sta parametra valenca in dominanca vezana na prvi latentni faktor, ki pojasnjuje večino variance v ocenah uporabnikov. Ugotovimo lahko tudi, da parameter vzburjenje dosega visoke vrednosti v gruči $G_{1.2}$, medtem ko so v gruči $G_{1.1}$ vrednosti enakomerno porazdeljene. Izkaže pa se, da med drugim latentnim faktorjem (gruči $G_{2.1}$ in $G_{2.2}$) in emotivnimi parametri ni vidne povezave.


V prispevku smo prepoznali emotivne lastnosti vsebin, ki ležijo na skrajnih delih osi, določenih z glavnima latentnima faktorjema, ter pojasnjujejo večino variance v ocenah uporabnikov.



Slika 5: Porazdelitev parametra valenca v štirih opazovanih gruĉah



Slika 7: Porazdelitev parametra vzburjenj v štirih opazovanih gruĉah



Slika 6: Porazdelitev parametra vzburjenj v štirih opazovanih gruĉah

ZAHVALA

Delo je bilo izvedeno s podporo Javne agencije za raziskovalno dejavnost Republike Slovenije po pogodbi P2-0246. Avtorji se zahvaljujejo dijaku in osebju Gimnazije Poljane za sodelovanje pri pripravi nabora podatkov, ter sodelavcem iz Laboratorija za digitalno obdelavo podatkov, slik in videa za pomoĉ pri izvedbi poskusa.

LITERATURA

- [1] Gediminas Adomavicius and A. Tuzhilin. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6):734–749, June 2005.
- [2] Simon Funk. Netflix Update: Try This at Home, 2006.

- [3] Yehuda Koren, Robert Bell, and Chris Volinsky. Matrix Factorization Techniques for Recommender Systems. *Computer*, 42(8):30–37, August 2009.
- [4] Peter J Lang, M M Bradley, and B N Cuthbert. International affective picture system (IAPS): Affective ratings of pictures and instruction manual. Technical Report A-8. Technical report, University of Florida, 2005.
- [5] G. Linden, B. Smith, and J. York. Amazon.com recommendations: item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1):76–80, January 2003.
- [6] Matevz Pogacnik, Jurij Tasic, Marko Meza, and Andrej Kosir. Personal Content Recommender Based on a Hierarchical User Model for the Selection of TV Programmes. *User Modeling and User-Adapted Interaction: The Journal of Personalization Research*, 15(5):425–457, 2005.
- [7] Matevz Pogacnik, Jurij Tasiĉ, and Andrej Košir. Optimization of Multi-attribute User Modeling Approach. *AEU - International Journal of Electronics and Communications*, 58(6):402–412, 2004.
- [8] Jonathan Posner, James a Russell, and Bradley S Peterson. The circumplex model of affect: an integrative approach to affective neuroscience, cognitive development, and psychopathology. *Development and psychopathology*, 17(3):715–34, January 2005.
- [9] Yue Shi, Martha Larson, and Alan Hanjalic. Mining mood-specific movie similarity with matrix factorization for context-aware recommendation. *Proceedings of the Workshop on Context-Aware Movie Recommendation*, pages 34–40, 2010.
- [10] Marko Tkalĉiĉ, Urban Burnik, and Andrej Košir. Using affective parameters in a content-based recommender system for images. *User Modeling and User-Adapted Interaction: The Journal of Personalization Research*, pages 1–33–33, September 2010.
- [11] Marko Tkalĉiĉ, J Tasiĉ, and Andrej Košir. The LDOS-PerAff-1 Corpus of Face Video Clips with Affective and Personality Metadata. *Proceedings of Multimodal Corpora: Advances in Capturing, Coding and Analyzing Multimodality (Malta, 2010), LREC*, page 111, 2009.

Marko Tkalĉiĉ je raziskovalec na Fakulteti za elektrotehniko Univerze v Ljubljani. Raziskovalna podroĉja obsegajo emotivno raĉunalništvo, uporabniško modeliranje, priporoĉilne sisteme in interakcija ĉlovek-raĉunalnik.

Andrej Košir je izredni profesor na Fakulteti za elektrotehniko Univerze v Ljubljani.

Štefan Dobravec je raziskovalec na Fakulteti za elektrotehniko Univerze v Ljubljani.

Jurij Tasiĉ je redni profesor na Fakulteti za elektrotehniko Univerze v Ljubljani.