

# Uporaba emotivno pogojenega računalništva v priporočilnih sistemih

Marko Tkalčič, Andrej Košir, Jurij Tasič

<sup>1</sup>Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana, Slovenija

<sup>2</sup>Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Tržaška 25, 1000 Ljubljana, Slovenija

E-pošta: avtor@naslov.com

**Povzetek.** V članku predstavljamo rezultate treh raziskav, vezanih na izboljšanje delovanja multimedijskih priporočilnih sistemov s pomočjo metod emotivno pogojenega računalništva (ang. affective computing). Vsebinski priporočilni sistem smo izboljšali s pomočjo metapodatkov, ki opisujejo emotivne odzive uporabnikov. Pri skupinskem priporočilnem sistemu smo dosegli značilno izboljšanje v območju hladnega zagona z uvedbo nove mere podobnosti, ki temelji na osebnostnem modelu velikih pet (ang. five factor model). Razvili smo tudi sistem za neinvazivno označevanje vsebin z emotivnimi parametri, ki pa še ni zrel za uporabo v priporočilnih sistemih.

**Ključne besede:** priporočilni sistemi, emotivno pogojeno računalništvo, strojno učenje, uporabniški profil, emocije

## Uporaba emotivnega računalništva v priporočilnih sistemih

In this paper we present the results of three investigations of our broad research on the usage of affect and personality in recommender systems. We improved the accuracy of content-based recommender system with the inclusion of affective parameters of user and item modeling. We improved the accuracy of a content filtering recommender system under the cold start conditions with the introduction of a personality based user similarity measure. Furthermore we developed a system for implicit tagging of content with affective metadata.

## 1 UVOD

Uporabniki (porabniki) multimedijskih (MM) vsebin so v čedalje težjem položaju, saj v veliki količini vsebin težko najdejo zanje primerne. Pomagajo si s priporočilnimi sistemi, ki na podlagi osebnih preferenc uporabnikov izberejo manjšo količino relevantnih MM vsebin, med katerimi uporabnik lažje izbira. Noben danes znan priporočilni sistem ne zadošča v celoti potrebam uporabnikov, saj je izbor priporočenih vsebin običajno nezadovoljive kakovosti [10]. Cilj tega članka je predstaviti metode *emotivno pogojenega računalništva* (ang. *affective computing* - glej [12]) za izboljšanje kakovosti priporočilnih sistemov in utrditi za slovenski prostor novo terminologijo.

### 1.1 Opis problema

Za izboljšanje kakovosti priporočilnih sistemov sta na voljo dve poti: (i) optimizacija algoritmov ali (ii) uporaba boljših značilk, ki bolje razložijo neznano

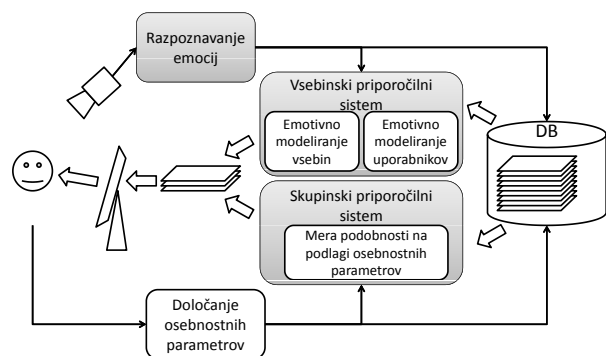
varianco [8]. V tem članku predstavljamo izboljšanje priporočilnih sistemov z uporabo novih značilk, ki temeljijo na emotivnih odzivih uporabnikov in na njihovih osebnostnih lastnostih. Te značilke razložijo velik del uporabnikovih preferenc, ki se izražajo v obliki ocen posameznih vsebin (npr. Likertova lestvica, binarne ocene itd.). Ocene vsebin se pri priporočilnih sistemih zajemajo eksplicitno (ocena) ali implicitno, pri čemer o oceni sklepamo na podlagi opazovanj (npr. čas gledanja kot indikator všečnosti [7]).

Izboljšanja učinkovitosti priporočilnih sistemov smo se lotili na treh področjih: (i) uporaba emotivnega modeliranja uporabnikov v vsebinskem priporočilnem sistemu, (ii) neinvazivna (implicitna) detekcija emocij za emotivno modeliranje in (iii) uporaba osebnostne mere podobnosti v skupinskem priporočilnem sistemu. Slika 1 prikazuje arhitekturo emotivnega priporočilnega sistema in mesta, kjer smo vnesli opisane izboljšave.

Preostanek članka je strukturiran tako: v razdelku 2 je predstavljen zajem podatkov. V razdelku 3 je predstavljen vsebinski priporočilni sistem z emotivnimi metapodatki. V razdelku 4 je predstavljen skupinski priporočilni sistem, ki uporablja mero podobnosti na podlagi osebnosti, v razdelku 5 pa algoritem za razpoznavo emocij. Vsak od teh razdelov je sestavljen iz opisa eksperimenta in predstavitev rezultatov. V razdelku 6 so predstavljeni sklepi.

### 1.2 Sorodno delo

Najbolj groba delitev priporočilnih sistemov je na vsebinske, skupinske ter hibridne sisteme [1]. Z izjemo vsebinskih priporočilnih sistemov, ki sta ga razvila Arapakis [2] in Tkalčič [14], sorodnega dela na področju emotivno pogojenih priporočilnih sistemov takorekoč ni. Pantić in



Slika 1: Arhitektura emotivnega priporočilnega sistema.

Vinciarelli priporočata označevanje multimedijskih vsebin z uporabo neinvazivnih metod za zajem emotivnih stanj [11]. Obstaja vrsta priporočilnih sistemov na podlagi generičnega modeliranja, ki so opisani v preglednem članku [1]. Veliko raziskav se ukvarja z detekcijo emocij iz različnih modalnosti (obraz, fiziološki senzorji ipd.) [17]. TV Anytime standard je že predvideval emotivne metapodatke [13].

## 2 ZAJEM PODATKOV

Za izvedbo eksperimentalne verifikacije pravilnosti hipotez je potrebna ustrezna podatkovna baza. Kljub obstoju baz s posnetki, opremljenimi z emotivnimi parametri (npr. baza Kanade-Cohn [6] ali baza AvID [5]), le-te niso povezane s priporočilnimi sistemi in smo morali ustrezno bazo zgraditi sami. Zahteve za novo bazo so bile naslednje: (i) nabor MM-vsebin z generičnimi in emotivnimi metapodatki, (ii) vzorec testnih uporabnikov s podatki o osebnostnih lastnosti po sistemu velikih pet (ang. *FFM - Five Factor Model*) [9], (iii) video posnetki uporabnikov med porabo MM-vsebin ter (iv) eksplicitne ocene uporabnikov za MM-vsebine.

Za nabor MM-vsebin smo izbrali barvne slike iz baze IAPS [3], ki so opremljene z emotivnimi metapodatki o odzivih uporabnikov v prostoru za zapis emocij VAD (ang. *valence-arousal-dominance*, valenca-vzburljenje-dominanca). Izbrali smo nabor 70 slik in vsako sliko ročno označili z žanrom. Izbrane slike so predstavljale emotivne stimuluse za uporabnike. Zajem podatkov smo izvedli s pomočjo aplikacije, ki je uporabniku prikazala sliko, ta pa je doživel emotivni odziv, ki smo ga posneli s spletno kamero, nameščeno nad zaslonom. Vsaki sliki je uporabnik dal še eksplicitno oceno s petstopenjske Likertove lestvice. Ta eksperimentalni pristop se imenuje indukcija emocij (ang. *emotion induction* ali *emotion elicitation*) [4]. Pri zajemu je sodelovalo 52 uporabnikov, ki so, poleg interakcije z računalniško aplikacijo, izpolnili tudi vprašalnik IPIP (<http://ipip.ori.org>) za oceno osebnostnih parametrov velikih pet. Tako smo za vsakega uporabnika dobili vektor petih skalarnih vrednosti, ki opisujejo pet osebnostnih

lastnosti: sprejemljivost, vestnost, odprtost, nevroticizem in ekstravertiranost (ang. *Agreeableness, Conscientiousness, Openness, Neuroticism, Extraversion*).

Bazo smo poimenovali LDOS-PerAff-1 [15] in je dosegljiva vsem zainteresiranim raziskovalcem. Pogoji uporabe so določeni na spletni strani <http://slavnik.fe.uni-lj.si/PerAff>.

## 3 VSEBINSKI PRIPOROČILNI SISTEM Z UPORABO EMOTIVNIH METAPODATKOV

V vsebinskih priporočilnih sistemih so vsebine (npr. filmi, glasba, slike ipd.) opisane z metapodatki (npr. žanr, igralci, tema ipd.). Podatkovna struktura, ki vsebuje metapodatke o eni vsebini, to označimo s  $h$ , se imenuje *profil vsebine* (ang. *item profile*) in ga označimo z  $md(h)$ . Vsebinski priporočilni sistem izbere uporabniku primerne vsebine na podlagi nagnjenj, ki jih ima uporabnik, tega označimo z  $u$ , do določenih vrednosti metapodatkov (npr. uporabnik ima rad žanr znanstvene fantastike). Uporabnikove preference se shranjujejo v podatkovni strukturi, ki jo imenujemo *uporabniški profil* (ang. *user profile*) in jo označimo z  $up(u)$ . Ključen element pri načrtovanju vsebinskega priporočilnega sistema je dobra izbira metapodatkov za profile vsebin in uporabnikov. Ti metapodatki morajo vsebovati dovolj informacije za uspešno ločevanje primernih vsebin od neprimernih za vsakega uporabnika. Ocene, ki jih uporabniki dajo vsebinam, označimo z  $e(u, h)$ , in predstavljajo osnovo za določanje primernih in neprimernih vsebin.

Predlagana rešitev za izboljšanje ločevanja primernih in neprimernih vsebin je uporaba emotivnih metapodatkov. Predpostavljamo, da nosijo emotivni parametri več informacije o varianci ocen uporabnikov, saj naj bi se uporabniki med seboj razlikovali v tem, katera emotivna stanja zasledujejo pri porabi multimedijskih vsebin. Na primer, znani sliki Edvarda Muncha in Clauda Moneta, prikazani na sliki 2, zbujejo v gledalcih zelo različna emotivna stanja. Vsaka ima svoje privrženke, kar je odraz zgoraj opisane predpostavke. Hipotezo smo preverili tako, da smo zgradili vsebinski priporočilni sistem za barvne slike, opremljene z emotivnimi parametri.



a. E. Munch



b. C. Monet

Slika 2: Dve znani sliki, ki izzoveta različna emotivna odziva (vir: wikipedia.org).

Primerjali smo kakovost priporočenih vsebin na podlagi generičnih metapodatkov (GM) in emotivnih metapodatkov (EM). Generična metapodatka sta bila žanr

$g$  in povprečni čas gledanja  $\bar{t}_w$ . Emotivni metapodatki pa so bili povprečje in standardna deviacija zajetih emotivnih odzivov uporabnikov na posamezne vsebine.

Emotivni odziv uporabnikov lahko zapišemo na več načinov: v obliki osnovnih emocij, z dimenzionalnim modelom in s cirkumpleksnim modelom [14]. Najpreprostejši način zapisa emocij je v obliki šestih nominalnih oznak: veselje, jeza, gnus, strah, žalost in presenečenje. V dimenzionalnem modelu vsako emocijo zapišemo s tremi skalarnimi dimenzijami: valenca, vzburjenje in dominanca (ang. VAD - valence, arousal, dominance). Cirkumpleksni model pa povezuje osnovne emocije z dimenzionalnim modelom, saj vsaki osnovni emociji pripiše področje v dimenzionalnem modelu (največkrat v ravnini valenca-vzbujenje).

V naši raziskavi smo uporabili dimenzionalni model za zapis emotivnega odziva uporabnika  $u$  na vsebino  $h$ . Emotivni odziv smo označili z  $er(u, h) = (v, a, d)$ , kjer so  $v$ ,  $a$ , in  $d$  vrednosti valence, vzburjenosti in dominanc. Skupino uporabnikov, ki je porabila vsebino  $h$ , označimo z  $U_h$ , njihove emotivne odzive pa z  $ER_h = \{er(u, h) : u \in U_h\}$ . Predlagamo uporabo profila vsebin v obliki prvih dveh statističnih momentov (povprečne vrednosti in standardnega odklona) za vsako od dimenzij  $v$ ,  $a$ , in  $d$ . Tak profil vsebin vsebuje šest metapodatkov:

$$\mathcal{V} = (\bar{v}, \sigma_v, \bar{a}, \sigma_a, \bar{d}, \sigma_d).$$

Uporabnike smo modelirali z uporabo metod strojnega učenja, ki so navedene v naslednjem razdelku. Vsak uporabniški profil  $up(h)$  je sestavljen iz vrednosti parametrov naučenega algoritma strojnega učenja. Podatkovna struktura uporabniškega modela je torej močno odvisna od metode strojnega učenja, ki smo jo uporabili.

Na podlagi uporabniškega modela smo s pomočjo ustrezne metode strojnega učenja ocenili uporabniške ocene za vsebine, ki jih uporabnik še ni ocenil. Te ocene označimo z  $\hat{e}(u, h)$ . Tako eksplicitne ocene uporabnikov  $e(u, h)$  kot ocenjene  $\hat{e}(u, h)$  lahko zavzamejo dve vrednosti,  $C_0$  ali  $C_1$ , ki pomenijo neprimerne oz. primerne (relevantne) vsebine.

### 3.1 Eksperiment

Z eksperimentom smo preverjali hipotezo, da je kakovost priporočenih vsebin z emotivnimi metapodatki boljša kot z generičnimi metapodatki. Zato smo izvedli simulacijo vsebinskega priporočilnega sistema tako, da smo ocenjevali uporabniške ocene vsebin s profili na podlagi generičnih in nato na podlagi emotivnih metapodatkov. V obeh primerih smo ocenjene vrednosti primerjali z dejanskimi ocenami, ki so jih podali uporabniki, in jih zapisali v tabelo pravilno in napačno razvrščenih ocen (ang. confusion matrix). Iz te tabele smo nato izračnali mere uspešnosti precision  $P$ , recall  $R$  in  $F$  mero. Simulacije vsebinskega priporočilnega sistema smo izvedli s štirimi različnimi postopki strojnega učenja: Bayesov razvrščevalnik, razvrščevalnik

AdaBoost, drevesni razvrščevalnik C4.5 in metoda podpornih vektorjev. Simulacijsko skripto smo izvedli v Matlabu, razvrščevalne algoritme pa smo poganjali s paketom Weka (<http://www.cs.waikato.ac.nz/ml/weka/>). Uporabili smo navzkrižno preverjanje.

### 3.2 Rezultati

Rezultati so prikazani v tabeli 1. Izvedli smo Pearsonov  $\chi^2$  test, ki je pokazal, da so vrednosti v matrikah razvrščanja značilno različni za generične in emotivne metapodatke. Izračunali smo tudi mero kakovosti posameznih emotivnih metapodatkov za uporabo v priporočilnem sistemu. Rezultati so pokazali, da je prvi statistični moment valence ( $\bar{v}$ ) najprimernejši metapodatek za ločevanje primernih vsebin od neprimernih. Metode strojnega učenja so pokazale različne rezultate, najbolje pa se je odrezala metoda podpornih vektorjev.

metapodatki	razvrščevalnik	P	R	F
$\mathcal{A}$	$\gamma$			
	AdaBoost	0.57	0.42	0.48
	C4.5	0.60	0.46	0.52
	NaiveBayes	0.58	0.58	0.58
$\mathcal{A} \times \mathcal{V}$	SVM	0.61	0.55	0.58
	AdaBoost	0.63	0.56	0.59
	C4.5	0.64	0.57	0.60
	NaiveBayes	0.57	0.64	0.61
$\mathcal{V}$	SVM	0.65	0.61	0.63
	AdaBoost	0.64	0.56	0.60
	C4.5	0.62	0.54	0.58
	NaiveBayes	0.57	0.60	0.58
	SVM	0.68	0.55	0.61

Tabela 1: Mere P, R in F za tri nabore metapodatkov in štiri razvrščevalnike. Nabor  $\mathcal{V}$  je sestavljen iz povprečja in standardne deviacije zajetih vrednosti VAD.

## 4 MERA PODOBNOSTI UPORABNIKOV NA PODLAGI OSEBNOSTNIH PARAMETROV

Skupinski priporočilni sistemi delujejo tako, da uporabniku predlagajo vsebine, ki so bile vseh podobnim uporabnikom. Ključni element takega sistema je mera podobnosti uporabnikov. Večina sistemov podobnost med uporabniki določi tako, da primerja ocene istih vsebin. Uporabniki, ki so podobno ocenjevali iste vsebine, so sosedi. Iz ocen sosedov se nato izračuna predikcija vsečnosti neke vsebine opazovanemu uporabniku. Problem pa nastane, ko neki uporabnik začne uporabljati sistem in še ni posredoval dovolj ocen, na podlagi katerih bi se poiskali dobri sosedi. To imenujemo problem novega uporabnika (ang. *new user problem*) kot poseben primer problema hladnega zagona (ang. *cold start problem*). Za rešitev tega problema predlagamo uporabo osebnostnih parametrov za izračun mer podobnosti uporabnikov.

Osebnost uporabnikov najpogosteje opisujemo s sistemom petih faktorjev (ang. FFM - five factor model), imenovanim tudi velikih pet. Osebnost vsakega uporabnika

je zapisana s petimi skalarnimi vrednostmi, ki opisujejo naslednje osebnostne lastnosti: ekstravertnost, prijetnost, vestnost, nevroticizem in odprtost. Ti faktorji pojasnjujejo varianco v človekovem razmišljanju, občutjih, motivaciji in obnašanju [9]. Motivacija za izbiro osebnosti za mero podobnosti je predpostavka, da imajo ljudje s podobno osebnostjo podobne okuse in bodo posledično podobno ocenjevali vsebine.

#### 4.1 Eksperiment

Simulacijo hladnega zagona smo izvedli tako, da smo upoštevali le prve  $s$  ocen uporabnika, kjer smo  $s$  povečevali od 1 do števila vseh ocen  $J$ . Nato smo izvedli isti priporočilni sistem in namesto mere podobnosti na podlagi ocen uporabili mero podobnosti na podlagi osebnosti.

S pomočjo ustrezne mere podobnosti smo za vsakega uporabnika določili  $k$  najbližjih sosedov, kjer smo izbrali  $k = 7$ . Nato smo s pomočjo enačbe

$$\hat{e}(u, h) = \alpha \bar{e}^{NN}(u, h) + (1 - \alpha) \bar{e}^P(u, h) \quad (1)$$

izračunali predikcijo neocenjene vsebine  $\hat{e}(u, h)$ . Podobno kot pri vsebinskem sistemu smo tudi tu izračunali matriko pravilno in napačno razvrščenih vsebin (ang. confusion matrix). Za mero podobnosti na podlagi ocen smo uporabili Evklidovo mero podobnosti.

Predlagano mero podobnosti na podlagi osebnosti smo dobili takole: najprej smo za vsakega uporabnika določili osebnostni vektor  $\vec{b} = (b_1, \dots, b_5)$ , kjer skalarni elementi vektorja  $b_l \in [0, 1]$  predstavljajo stopnje faktorjev osebnostnega modela. Vrednosti  $\vec{b}$  smo določili s pomočjo vprašalnika IPIP, opisanega v razdelku 2. Nato smo kot mero podobnosti med dvema uporabnikoma  $u_i$  in  $u_j$  uporabili uteženo evklidovo razdaljo med vektorjema  $\vec{b}_i$  in  $\vec{b}_j$

$$d_W(\vec{b}_i, \vec{b}_j) = \sqrt{\sum_{l=1}^5 w_l (b_{il} - b_{jl})^2} \quad (2)$$

#### 4.2 Rezultati

Primerjava F mer, prikazana v sliki 3, je pokazala, da je kakovost priporočenih vsebin s predlagano osebnostno mero podobnosti značilno boljše kot pri standardni meri osebnosti v primerih, ko je število ocen, ki smo jih upoštevali pri računanju sosedov  $s < 50$ . Ta rezultat pomeni, da je predlagana mera podobnosti uporabnikov primerna za odpravo težav hladnega zagona pri skupinskih priporočilnih sistemih. Slabost predlagane mere je v tem, da je težavno določanje osebnostnih parametrov, saj je le to zamudno, postavlja pa se tudi vprašanje varovanja osebnih podatkov.

## 5 ALGORITEM ZA RAZPOZNAVANJE EMOCIJ IZ VIDEOPOSNETKOV OBRAZOV SPONTANIH IZRAZOV

Vsebinski priporočilni sistem, ki smo ga predstavili v tem članku, bi v realnem svetu zahteval impliciten, neintruziven zajem emotivnih odzivov uporabnikov. Razpoznavanje emocij lahko poteka prek ene ali več modalnosti (glas, videoposnetek obraza, videoposnetek drže telesa, fiziološki odzivi - npr. prevodnost kože ipd.) [17]. Mi smo se odločili za razpoznavanje emocij iz videoposnetkov obraza, saj se intuitivno zdi to najprimernejši način v našem scenariju porabe multimedijskih vsebin.

V sorodnem delu avtorji navajajo dva različna pristopa: na igranih bazah in na spontanah bazah. Pri igranih bazah igralci odigrajo vnaprej dogovorjen emotivni odziv. Pri spontanah bazah se uporablja metoda indukcije emocij, kjer se uporabnik spontano odzove na neko vzbujanje.

#### 5.1 Eksperiment

Uporabili smo metodo indukcije emocij. Za vzbujanje emocij smo uporabili nabor 72 slik iz baze IAPS, kjer je vsaka slika označena s povprečjem in standardnim odklonom emotivnih odzivov na samo sliko v prostoru VAD. Uporabnike smo snemali s spletno kamero, podatke o povprečnem emotivnem odzivu pa uporabili kot referenco za učenje sistema za razpoznavanje emocij.

Za primerjavo smo razviti sistem testirali še na znani igrani bazi Kanade-Cohn.


Prostor VAD smo razdelili na osem razredov tako, da smo vsako os ( $v$ ,  $a$  in  $d$ ) razdelili na pol. Ker nekateri razredi niso imeli predstavnikov v naši bazi, smo razpoznavanje emocij izvajali s šestimi razredi.

Videoposnetke obrazov smo najprej razrezali na posnetke odzivov na eno vzbujanje. Tako smo dobili pare videoposnetek- $(v, a, d)$ , ki so primerni za učenje sistema. Na vseh slikah v videoposnetkih smo najprej izločili obraz uporabnika s pomočjo algoritma Viola-Jones [16]. Nato smo obraze registrirali in normirali (glej sliko 4).



Slika 4: Predobdelava slik obrazov.

Emocije smo razpoznavali tako, da smo primerjali sliko obraza v polni izraznosti in nevtralno sliko obraza. Pri igrani bazi Kanade-Cohn smo uporabili prvo in zadnjo sliko sekvence, vezane na en emotivni odziv. Pri bazi LDOS-PerAff-1 pa smo najprej določili nevtralno sliko tako, da smo izračunali povprečje vseh slik enega uporabnika.



Slika 3: Porazdelitev  $F$  mer za različne vrednosti hladnega zagona  $s$ . Skrajno leva porazdelitev (pri indeksu  $s = 0$ ) predstavlja  $F$  mere pridobljene s predlagano osebnostno mero podobnosti uporabnikov. Vsak pravokotnik predstavlja porazdelitev  $F$  mer za različne uporabnike med 25im in 75im percentilom pri fiksnem indeksu  $s$ .

Nato smo izločili nizkonivojske značilke nevtralne in maksimalne slike obraza s pomočjo Gaborjevega filtriranja. Uporabili smo algoritem kNN za učenje in razpoznavanje. Učinkovitost algoritma smo ocenili s pomočjo matrike pravilno in napačno razvrščenih vzorcev in skalarne mere natančnosti (ang. accuracy).

## 5.2 Rezultati

Natančnost algoritma na igrani bazi Kanade-Cohn je bila 92% , pri spontani bazi LDOS-PerAff-1 pa 62% (tabela 2 prikazuje pravilno in napačno razvrščene vzorce), kar je primerljivo s sorodnimi raziskavami.

razvrščeno kot	1	2	3	4	5	6
1	15	3	0	4	5	6
2	4	456	18	19	107	48
3	0	57	98	10	51	29
4	2	42	3	156	41	13
5	2	101	19	28	477	64
6	1	82	11	21	104	240

Tabela 2: Matrika pravilno in napačno razvrščenih videoposnetkov v šest emotivnih razredov za bazo spontanih videoposnetkov LDOS-PerAff-1.

Povzamemo lahko, da je predstavljena metoda za razpoznavanje emotivnega stanja iz videoposnetkov obraza uporabnikov neprimerna za neintruzivno zaznavo in uporabo pridobljenih rezultatov pri profiliranju vsebin in uporabnikov v priporočilnih sistemih.

## 6 SKLEP

Predstavljena pristopa za izboljšanje priporočilnih sistemov sta se izkazala kot uspešna. Uporaba emotivnih metapodatkov v vsebinskem priporočilnem sistemu je dala značilno boljše rezultate kot uporaba generičnih metapodatkov. Predlagana mera podobnosti uporabnikov na podlagi osebnosti je dala značilno boljše rezultate skupinskega priporočilnega sistema kot navadna mera, ki temelji na preteklih ocenah. Žal pa je algoritem za razpoznavo emocij na spontanih videoposnetkih še pre slab, da bi ga lahko uporabili za implicitno označevanje vsebin pri vsebinskem priporočilnem sistemu.

Da bi se emotivni priporočilni sistemi lahko uporabili v praksi, je torej ključnega pomena izboljšati metode razpoznave emocij za implicitno označevanje multimedijskih vsebin.

## ZAHVALA

Delo je nastalo v okviru programa P2-0246, ki ga financira ARRS. Avtorji se zahvaljujejo dijakom in zaposlenim na Gimnaziji Poljane, ker so omogočili zajem podatkov, potrebnih za to raziskavo. Hvaležni smo tudi kolegom, ki so pomagali pri izvedbi eksperimenta.

## LITERATURA

- [1] G. 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, 2005.
- [2] I. Arapakis, Y. Moshfeghi, H. Joho, R. Ren, D. Hannah, J.M. Jose, and L. Gardens. Integrating facial expressions

- into user profiling for the improvement of a multimodal recommender system. In *Proc. IEEE Int'l Conf. Multimedia & Expo*, pages 1440–1443, 2009.
- [3] Margaret M. Bradley and Lang. *The International Affective Picture System (IAPS) in the Study of Emotion and Attention*, chapter 2. Series in Affective Science. Oxford University Press, 198 Madison Avenue, 2007.
- [4] J.A. Coan and J.J.B. Allen. *Handbook of emotion elicitation and assessment*. Oxford university press, 2007.
- [5] R. Gajšek, V. Štruc, F. Mihelič, A. Podlesek, L. Komidar, G. Socan, B. Bajec, and P. Methodology. Multi-Modal Emotional Database: AvID. *Informatika*, 33:101–106, 2009.
- [6] T. Kanade, J.F. Cohn, and Y. Tian. Comprehensive database for facial expression analysis. In *Proceedings of the fourth IEEE International conference on Automatic Face and Gesture Recognition*, page 46, 2000.
- [7] Y.S. Kim, B.J. Yum, J. Song, and S.M. Kim. Development of a recommender system based on navigational and behavioral patterns of customers in e-commerce sites. *Expert Systems with Applications*, 28(2):381–393, 2005.
- [8] Michael S. Lew, Nicu Sebe, Chabane Djeraba, and Ramesh Jain. Content-based multimedia information retrieval: State of the art and challenges. *ACM Transactions on multimedia computing*, 2(1):1–19, February 2006.
- [9] Robert R. McCrae and Oliver P. John. An introduction to the five-factor model and its applications. *Journal of Personality*, 60(2):p175 – 215, 06 1992.
- [10] Leavitt Neal. Recommendation technology: Will it boost e-commerce. *IEEE Computer*, 39(5):13–16, May 2006.
- [11] M. Pantic and A. Vinciarelli. Implicit Human-Centered Tagging. *IEEE Signal Processing Magazine*, 26(6):173–180, 2009.
- [12] Rosalind W. Picard. *Affective Computing*. MIT Press, 2000.
- [13] Skip Pizzi, Ronald Tol, Henry Chadwick, and Masahito Kawamori. Tvariant system description (informative with normative appendix b). Technical report, TV Anytime, 2003.
- [14] Marko Tkalčič, Urban Burnik, and Andrej Košir. Using affective parameters in a content-based recommender system. *User Modeling and User-Adapted Interaction: The Journal of Personalization Research*, 20(4):?–?5, 2010. ?
- [15] Marko Tkalčič, Jurij Tasič, and Andrej Košir. The LDOS-PerAff-1 Corpus of Face Video Clips with Affective and Personality Metadata. In Michael Kipp, editor, *Proceedings of the LREC 2010 Workshop on Multimodal Corpora: Advances in Capturing, Coding and Analyzing Multimodality*, 2010.
- [16] Paul Viola and Michael Jones. Robust real-time face detection. *International Journal of Computer Vision*, 57(2):137–154, 2004.
- [17] Zhihong Zeng, Maja Pantic, Glenn I. Roisman, and Thomas S. Huang. A survey of affect recognition methods: Audio, visual, and spontaneous expressions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 31(1):39–58, Jan. 2009.

**Marko Tkalčič** je raziskovalec na Fakulteti za elektrotehniko v Ljubljani. Ukvarja se z uporabo emotivnih parametrov za personalizacijo uporabniških vmesnikov.

**Andrej Košir** je izredni profesor na Fakulteti za elektrotehniko v Ljubljani. Področje njegovega raziskovalnega dela obsega postopke analize slik in videa z namenom modeliranja uporabnikov, personalizacijo in modeliranje uporabnikov, statističnih metod in operacijskih raziskav v telekomunikacijah.

**Jurij Tasič** je redni profesor na Fakulteti za elektrotehniko Univerze v Ljubljani in predstojnik Laboratorija za digitalno obdelavo signalov. Ožja področja njegovega raziskovalnega dela so digitalna obdelava podatkov, obdelava slik, adaptivni sistemi, paralelne strukture in telekomunikacije.