

Univerzitet u Sarajevo  
Elektrotehnički Fakultet Sarajevo  
Odsjek Računarstva i Informatike

Kandidat: mr.sci.Bakir Karahodža dipl.ing.el.

Akademski saradnik na definiranju teme: Vanr.prof.dr.Dženana Đonko dipl.ing.el.

Sarajevo, 25.05.2015.god.

## Prijedlog teme doktorske disertacije

<b>1</b>	<b>Radni naslov teme.....</b>	<b>2</b>
<b>2</b>	<b>Obrazloženje teme i motivacija.....</b>	<b>2</b>
2.1	<i>Sistemi za preporučivanje kao odgovor na potrebe za personalizacijom.....</i>	2
2.2	<i>Eksplisitne i implicitne informacije o sklonostima korisnika.....</i>	2
2.3	<i>Mjerenje korisnosti sistema.....</i>	3
2.4	<i>Metode u sistemima za preporučivanje.....</i>	4
2.5	<i>Vrijeme kao kontekstualna informacija .....</i>	4
2.6	<i>Evolucija sklonosti korisnika .....</i>	5
<b>3</b>	<b>Pregled stanja u oblasti istraživanja.....</b>	<b>5</b>
<b>4</b>	<b>Opis problema.....</b>	<b>10</b>
<b>5</b>	<b>Cilj istraživanja .....</b>	<b>11</b>
<b>6</b>	<b>Metode i plan istraživanja .....</b>	<b>11</b>
<b>7</b>	<b>Očekivani rezultati i izvorni naučni doprinos.....</b>	<b>12</b>
<b>8</b>	<b>Literatura .....</b>	<b>12</b>

## 1 Radni naslov teme

Opća tema istraživanja je otkrivanje i modeliranje kratkoročnih i dugoročnih sklonosti korisnika u sistemima za preporučivanje i njihovo iskorištavanje za povećanje korisnosti sistema u smislu tačnosti predikcije, diverzifikacije i noviteta preporuka. Istraživanje pripada oblastima: Sistemi za preporučivanje, Data mining, Pretraživanja informacija.

Predloženi naslov teme je:

“Modeliranje promjena u sklonostima korisnika u sistemima za preporučivanje.”

“Modeling of changes in user preferences in recommender systems.”

## 2 Obrazloženje teme i motivacija

### 2.1 Sistemi za preporučivanje kao odgovor na potrebe za personalizacijom

Sposobnost ljudi da usvajaju i koriste različite informacije koje su im na raspolaganju se narušava sa rastom obima informacija, stvarajući na taj način efekat preopterećenja informacijama. Prilikom korištenja velikih repozitorija informacija, bilo da se radi o različitim web sadržajima, vijestima, istraživačkim radovima, e-commerce katalogima, filmovima, informacijama o putovanjima i slično, korisnici se suočavaju sa izborom za njih relevantnih informacija iz velikog i stalno rastućeg skupa podataka.

Jedan od odgovora na ove probleme je pojava sistema za preporučivanje koji korisniku sugerišu personalizirane sadržaje. Preporučivanje se vrši na osnovu znanja o sklonostima i ukusima korisnika, kao i njegovim prethodno zabilježenim aktivnostima. Sistemi za preporučivanje identificiraju objekte preporuke za svakog pojedinačnog korisnika na bazi ograničenog skupa informacija kojima mogu pristupiti. Ovi sistemi predstavljaju popularnu oblast tehnika personaliziranja koje su rezultat stalnog povećanjem broja istraživanja u akademskoj i industrijskoj zajednici. Između ostalih rezultata, ova istraživanja su postavila temelje za definiranje različitih problema i zadataka preporučivanja [1], algoritamskih pristupa [2] [3], te evaluacijske metrike i metodologije [4] [5]. Primjenjuju se u različitim sistemima, namjenama i u velikom broju popularnih komercijalnim aplikacija, najčešće online sistema za preporučivanje proizvoda i usluga.

Opći zadatak preporučivanja je formaliziran u [1] pretpostavljajući funkciju korisnosti  $R$  koja mjeri korisnost nekog predmeta  $i \in I$  za korisnika  $u \in U$  kao  $U \times I \rightarrow R$ , gdje je  $R$  potpuno uređen skup brojeva unutar određenog opsega. Prema tome, zadatak sistema za preporučivanje je da za svakog pojedinačnog korisnika identificira takve predmete slijedeći neke od apstraktnih ciljeva kao što su maksimiziranje korisničke korisnosti, povećanje stope online konverzije ili optimiziranje trajanja korisnosti. Tako se u stvari zadatak preporučivanja definira kao pronalaženje predmeta  $i_j$  koji maksimizira zadatu korisničku korisnost [1] [6].

### 2.2 Eksplicitne i implicitne informacije o sklonostima korisnika

Ključni indikatori za modeliranje sklonosti korisnika prema predmetima, kao i najvažnije informacije za personaliziranje preporuka su podaci nastali iz interakcije korisnika sa sistemom. Rezultat te interakcije su eksplicitne i implicitne povratne informacije zabilježene u sistemu. Eksplicitne informacije su podaci o ocjenama korisnika za svaki pojedinačni predmet. Obično se pružaju u obliku skale ocjenjivanja od 1 do 5, 1 do 10 i

slično ili se korisniku pruža binarna skala u obliku izbora “Sviđa mi se/Ne sviđa mi se”. Osim skala sa ocjenjivanjem, neki sistemi korisniku pružaju mogućnost i ostavljanja slobodnog opisa iskustva konzumiranja predmeta, kao što su Amazon, Ebay i slično. Implicitne informacije o sklonostima korisnika se preuzimaju iz podataka o konzumiranju pojedinačnog predmeta ili usluge, tako da se svako konzumiranje pretvara u binarnu vrijednost koja pokazuje da korisnika ima sklonost prema određenom predmetu, dok se izostanak konzumiranja tog predmeta može, ali i ne mora pretvoriti u indikator da korisnik nema sklonost prema tom predmetu [7].

Ovi indikatori se na podesan način koriste prema tipu aplikacije za koji sistem za preporučivanje (SP) generira preporuke. Implicitne povratne informacije se najčešće koriste u prikupljanju sklonosti korisnika prema online vijestima, istraživačkim radovima, različitim web sadržajima i drugim tekstovima, gdje se svaka posjeta online sadržaju smatra konzumiranjem tog predmeta. Druga vrlo česta i vrijedna primjena je u e-commerce sistemima gdje se svaka narudžba korisnika za pojedini predmet također pretvara u implicitnu informaciju o sklonosti prema tom predmetu [8] [9].

Eksplisitne informacije su poželjniji oblik prikupljanja sklonosti korisnika, jer korisnik osim narudžbe i konzumacije predmeta daje i ličnu ocjenu korisnosti i vrijednosti predmeta poslije konzumacije, a u nekim aplikacijama i slobodan tekstualni opis svog iskustva. Primjeri takvih sistema su online narudžbe filmova i knjiga, ocjene smještaja i dodatnih kapaciteta prilikom putovanja, zatim ocjene restorana i slično. Korisnost eksplicitnih informacija je predmet različitih rasprava i dokaza koji pokazuju da se u mnogim slučajevima ove informacije moraju uzeti pod određenom rezervom zbog ne samo promjene sklonosti, nego i promjene načina na koji korisnici vrijednuju predmet, kao što je i pokazano u [5] i [9].

### 2.3 Mjerenje korisnosti sistema

Korisnost sistema za preporučivanje se najčešće opisuje performansama sistema i mjeri se na različite načine. Jedan od načina je poređenje dobijenih preporuka sa testnim skupom koji sadrži poznate ocjene korisnika. Koristi se metrike tačnosti predikcije sistema kao što su *Mean Absolute Error* (MAE) i *Root Mean Absolute Error* (RMSE) [5]. Ove standardne metrike sve preporučene [11] predmete posmatraju kao jednako važne, ne uzimajući u obzir njihovu poziciju na listi preporuka koje sistem generiše za svakog pojedinačnog korisnika. Da bi se bolje izmjerila korisnost, odnosno kvalitet preporuka, potrebno je uključiti i relativnu poziciju predmeta na listi preporuka, odnosno identifikaciju predmeta koji se korisniku sviđaju naspram predmeta koji se ne sviđaju korisniku. Zbog toga su preuzimaju mjere korisnosti poznate iz tehnika pretraživanja informacija koje prave razliku između predmeta dijeleći ih na “relevantne” i “nerelevantne” predmete. Takve mjere korisnosti su [5] [11]: *Precision*, *Recall*, *Area under the ROC Curve*, zatim *F1-measure*, *Half-life utility*, itd.

Pokrivenost preporuka (eng. *Coverage*) [5] je mjera korisnosti sistema koja se odnosi na relativan broj preporuka koji je sistem u stanju ili nije u stanju pružiti zbog različitih ograničenja kao što su nedostatak informacija, algoritamski ili metodološki nedostaci, itd. Obično se mjeri u kombinaciji sa tačnošću preporuka (MAE i RMSE) da se ne bi dozvolilo da metoda koji pokazuje vrlo visoku tačnost ne daje istovremeno i nisku pokrivenost preporuka. Ovo je čest slučaj sa metodama i algoritmima koji za generiranje preporuka zahtijevaju veliki broj ulaznih podataka o ocjenama, te nisu u mogućnosti pružiti preporuke za pojedinačne predmete ili korisnike zbog nekompletnosti takvih podataka.

Mjere korisnosti sistema koje se često izostavljaju su diverzifikacija i novitet preporuka [4] [5], koje pokazuju učešće različitosti i noviteta predmeta u ukupnoj listi preporuka koja je ponuđena korisniku. Kako je istraživanje u [10] pokazalo, korisnici su u ponudi ocjene kvaliteta preporuka između tačnosti, diverzifikacije i noviteta preporuka naveli da su im važnija diverzifikacija i novitet nego tačnost.

## 2.4 Metode u sistemima za preporučivanje

SP se razlikuju prema tipu znanja kojeg koriste, odnosno znanja o proizvodima, zatim domenske ekspertске heuristike ili drugih strategija koje koriste [1]. Uobičajene metode u SP su [1] [6]:

- Sadržajno *bazirano preporučivanje* (engl. *Content-based recommendation - CB*), koje preporučuje predmete slične onima koje je korisnik već koristio u prošlosti,
- Preporučivanje sa *kolaborativnim filteringom* (engl. *Collaborative filtering recommendation - CF*), koje preporučuje predmete na osnovu sklonosti sličnih korisnika, bilo da se radi o predmetno baziranom (eng. *Item-based - IB-CF*) ili korisnički baziranom (engl. *User-based - UB-CF*) filteringu, i
- *Hibridno preporučivanje* koje kombinira CB i CF u cilju prevazilaženja pojedinačnih ograničenja ovih pristupa.

Posmatrajući podjelu SP u odnosu na navedene metode i njihovo korištenje u istraživačkim radovima i industrijskoj praksi, primat su preuzele metode bazirane na kolaborativnom filteringu, te različite hibridne metode. U komercijalnoj upotrebi su SP počeli sa sadržajno-baziranim metodama gdje su preuzeli postojeće modele, pristupe i algoritme iz općih sistema za pretraživanje informacije. Bez obzira na mnogostruke prednosti ovih metoda kao što su jednostavnost, relativno mali resursni zahtjevi, sposobnost za pružanje preporuka sa ograničenim skupom informacija, u svojoj čistoj formi su vremenom su pokazali i određena ograničenja. Obzirom na rastuće zahtjeve korisnika na korisnost sistema u ubliku noviteta i diverzifikacije preporuka, ove metode nisu mogle odgovoriti na takve zahtjeve. Primjeri takvih preporučivanja u kojima sadržajno-bazirane metode ne mogu zadovoljavajuće odgovoriti su preporučivanje istih i/ili sličnih predmeta u aplikacijama online kupovine: preporuke sličnih automobila, brodova, potrošačke elektronike ili predmeta široke potrošnje sa istom namjenom, ali od drugog proizvođača.

Iako i metode kolaborativnog filteringa (CF) također imaju određene nedostatke, njihova primjena i sposobnost odgovora na nove zahtjeve korisnika se stalno povećavaju. Njihova osnovna ideja je da ukoliko se korisnici slično ponašali u prošlosti, također će se slično ponašati i u budućnosti [3] [12]. Najčešće spominjani nedostatak CF metoda je problem hladnog starta (eng. *cold-start*) koji se pojavljuje zbog nedostatka količine zapisa na osnovu kojih se može odrediti sličnost između korisnika koja se koristi u računanju predikcije ocjenjivanja. Integracija CF i CB koje koriste hibridne metode pružaju neka od rješenja za ove nedostatke, pošto uzimaju u obzir sadržaj predmeta i osobine korisnika, te tako popunjavaju nedostatak informacija o sklonostima korisnika [13].

Česta podjela sistema za preporučivanje posmatra posebno memorijske, odnosno heuristički bazirane sisteme i sistema bazirane na modelima [1] [4]. Heuristički bazirani pristupi računaju vrijednost predikcije iz ukupnog skupa korisničkih profila u smislu određene heuristike, odnosno direktno iz poznatih ocjena koristeći određeni matematski izraz. Ovim pristupima pripadaju CB i CF metode. Najvažniji faktor u ovim metodama je računanje sličnosti između korisnika, odnosno predmeta, za koji se koristi neka od mjera sličnosti kao što su Pearsonov korelacijski koeficijent [4], te vektorska i kosinusna sličnost [5]. Za razliku od memorijski baziranih sistema, pristupi bazirani na modelu pružaju aproksimaciju predikcije na osnovu skupa poznatih ocjena. Ovako postavljena ciljna funkcija koja uključuje prethodno učenje modela obezbjeđuje generisanje predikcija uz bolji odziv sistema u trenutku preporučivanja.

## 2.5 Vrijeme kao kontekstualna informacija

Unutar ukupnog broja istraživanja iz oblasti sistema za preporučivanje, jedan broj metoda i tehnika preporučivanja uzima u obzir dodatne kontekstualne informacije kao što su vrijeme, lokacija, trenutni ciljevi korisnika, raspoloženje, prisustvo drugih ljudi, tipovi korisničkog uređaja i slično [6]. Ova istraživanja su poboljšala performanse sistema u obliku tačnosti predikcija, te se kontekst počinje prepoznavati kao neizostavno pitanje u različitim

primjenama SP-a.

Među postojećim kontekstualnim dimenzijama, kontekst vremena, tj. kontekstualni atributi povezani sa vremenom kao što su trenutno vrijeme i datum, zatim vremenski zapisi općenito, sedmica, mjesec ili godina se mogu smatrati kao najkorisniji [6]. Prikupljanje vremenskih informacija ne zahtijeva dodatni napor od strane korisnika, niti nameće nove resursne zahtjeve na sistem. U standardnim implementacijama sistema za preporučivanje se uz podatke o sklonostima korisnika u obliku eksplicitnih i implicitnih ocjena pridružuje i vremenska oznaka (eng. *timestamp*). Ta oznaka se može koristiti za modeliranje vremenskih informacija kao kontinualne ili kategoričke varijable. Kontinualna varijabla pruža prostu informaciju o vremenu i datumu nekog događaja, najčešće o trenutku kada se desila pojedinačna ocjena korisnika, pojava novog korisnika ili predmeta u sistemu, itd. Kategoričke varijable pružaju informacije o mogućim ponavljajućim obrascima sklonosti korisnika za određene predmete u toku nekog perioda – sedmice, mjeseca, godine, itd. Iako se ovi vremenski zapisi jednostavno zapisuju i prikupljaju, koriste se kao ključni ulaz za značajno poboljšanje tačnosti preporuka [15] [16].

## 2.6 Evolucija sklonosti korisnika

Osnovna motivacija za razvoj novih metoda preporučivanja koje uzimaju u obzir vremensku dimenziju ocjenjivanja je činjenica da se sklonosti korisnika mijenjaju, odnosno evoluiraju tokom vremena, posebno ako se posmatraju kroz duži vremenski period. Prisustvo ovih promjena je poznato kao konceptualni otklon (eng. *concept drift*) ukoliko se promjene dešavaju postepeno [17], a u naglašenijim slučajevima kada korisnik potpuno gubi interesovanje za predmet kao konceptualna promjena (eng. *Concept shift*) [15]. Ponašanje korisnika se sastoji od različitih konceptualnih otklona i promjena koje se dešavaju u različitim vremenskim intervalima i u različitim smjerovima. Konceptualni otklon proizilazi iz činjenice da se obrasci ponašanja koji se mogu otkriti analizom podataka neprestano mijenjaju, te iz toga proizilazi da se sklonosti, ukusi i potrebe korisnika u sistemima za preporučivanje neprestano mijenjaju.

Vremenske promjene u sklonostima korisnika se mogu pojaviti zbog različitih razloga. Na primjer, u online sistemu za preporučivanje proizvoda, interesovanje korisnika se mijenja zbog pojave novog proizvoda ili usluge u katalogu [9]. Između ostalih, drugi razlozi koji mogu utjecati na promjene sklonosti korisnika su [14] [15] [18]:

- starost proizvoda,
- starost i/ili razvoj korisnika,
- promjene osobine proizvoda,
- stanje zajednice kojoj korisnik pripada,
- preporuke koje same po sebi utječu na razvoj korisnika,

S druge strane, kategoričke varijable otkrivaju drugu vrstu promjena koji uključuju sezonske promjene u toku godine ili mjeseca, zatim dolazak posebnih praznika i slično. Na primjer, tokom radnih dana u sedmici korisnik želi da čita vijesti iz svoje profesije, dok tokom vikenda želi da čita vijesti o svom hobi. Drugi ekstremniji primjer je da tokom ljetnjeg odmora korisnik želi preporuke za odmor ljetovalištima, dok tokom zimskog odmora želi preporuke za zimovališta.

Prisustvo ovih faktora koji utječu na promjene u sklonostima korisnika su izvor motivacije za različite pristupe, modele i algoritme koji uključivanjem vremenske dinamike u sisteme za preporučivanje pokušavaju povećati korisnost takvih sistema.

## 3 Pregled stanja u oblasti istraživanja

Relevantni radovi koji se bave istraživanjem vremenske dinamike u promjenama sklonosti korisnika se mogu podijeliti na nekoliko načina. Prema obliku i strukturi vremenske varijable se dijele na radove koji tretiraju kontinualne i kategoričke varijable, kako su već objašnjene u prethodnim poglavljima, a mogu uključivati i obje prezentacije. Prema vrsti

algoritamskih pristupa se mogu podijeliti na memorijske i model-bazirane pristupe. Sistemi se mogu podijeliti i prema načinu uključivanja vremenskog zapisa o ocjenjivanju u predikcijsku funkciju  $F$ . Tako se dijele na sisteme koji uključuje ciljano vrijeme preporučivanja, odnosno procjenjuju korisnost predmeta u vremenu  $t$ , i na sisteme koji samo koriste vremenske informacije da bi podešavali parametre prema nekim karakterističnim promjenama nad tim podacima.

Sistemi za preporučivanje i drugi sistemi s kojima mogu raditi u sprezi generiraju različite vremenske informacije od kojih je najčešće korištena vrijeme ocjenjivanja. Iako je u [19] dokazano da korisnici teže da ocijene predmete neposredno poslije konzumiranja, ovo se ipak uzima sa rezervom u slučajevima kada se vremenski kontekst koji se modelira uključuje kratke intervale, npr. periode u toku dana.

Prvi pristupi u SP koji su tretirali problem promjena u sklonostima korisnika su prilagođavali metode kolaborativnog filteringa tako da su na određeni način davali veću težinu novijim ocjenama, a manju težinu starijim ocjenama da bi naglasili trend i trenutne sklonosti korisnika. Takvi pristupi uključuju nekoliko različitih tehnika, od kojih je većina bazirana na kontinualnoj opadajućoj vremenskoj funkciji ili diskretnim vremenskim prozorima.

Rad sa kontinualnom opadajućom funkcijom u CF je predstavljen u [20] u IB-CF algoritmu u koraku preporučivanja koristeći monotono opadajuću vremensku funkciju u obliku  $w(t) = \exp(-\lambda t)$ , gdje je  $t$  vrijeme ocjenjivanja, a  $\lambda$  parametar koji kontrolira stopu opadanje funkcije u odnosu prema vremenu ocjenjivanja. Ovdje su također posmatrani odvojeni koncepti kratkoročnih i dugoročnih sklonosti, te su tako za njih i predložene različite težinske šeme da bi se integrirala oba tipa profila. U sljedećem radu [21] isti autor također koristi težišni faktor, ali ga sada ne veže eksplicitno za vrijeme ocjenjivanja, nego računajući samo devijaciju između najnovije ocjene od svih susjednih korisnika i ocjene aktivnog susjeda. Dok je u ova dva rada monotona opadajuća funkcija korištena samo u koraku predikcije, u [22] je korištena i u koraku računanja sličnosti korisnika, samo sa različitim vrijednostima parametara  $\lambda$  i  $\beta$  koji kontroliraju stopu opadanja funkcije. Pošto se također radi o IB-CF metodi, pretpostavljeno je da sličnost između dva predmeta opada što su njihove ocjene starije, te je u koraku računanja sličnosti korištenjem kosinusne mjere sličnosti davana manja vrijednost takvim ocjenama. Parametri  $\lambda$  i  $\beta$  se koriste za finije podešavanje performansi modela u smislu tačnosti predikcije. Vremensko težište se u [23] koristi za procjenu sličnosti između predmeta koje konzumira korisnika, pretpostavljajući da korisnik konzumira slične predmete u relativno kratkim vremenskim periodima. Na sličan način se korištenjem mjere sličnost podaci u potpunosti odbacuju u [24], ukoliko je vrijeme ocjenjivanja starije od nekog određenog datuma.

Primjeri korištenja vremenski ovisne funkcije u sistemima za preporučivanje sa implicitnim povratnim informacijama su [25] i [16], gdje se informacija o online narudžbi transformira u eksplicitno ocjenjivanje sa pridruživanjem težišta korištenjem neke vremensko ovisne funkcije. Ovdje se također koriste različite vremenske varijable. U [25] i [27] je ta funkcija određena na osnovu starosti narudžbe, slično kao što je sa ocjenjivanjem iz eksplicitnih informacija urađeno u prethodno spomenutim radovima, ali također i starosti proizvoda, odnosno vremena kada se proizvod pojavio na tržištu. Interesantno je da ovdje autor daje veće težište novijim proizvodima na tržištu i na taj način promovirajući novitet preporuka. Alternativan pristup je dat u [26] gdje je predložen algoritam sa mašinskim učenje baziran na osobinama predmeta. Ovaj pristup kreira i održava profile predmeta od interesantnih sadržaja i ažurira njihove vremenske karakteristike, npr. popularnost i novitet u realnom vremenu. Za razliku od ovih pristupa koji uključuju vrijeme kao kontinualnu varijablu, u [16] je vrijeme posmatrana kao kategorička varijabla u sistemu za preporučivanje muzike. Autori su korisnički profil  $u$  podijelili na mikropofile  $\{u_1, u_2, \dots, u_n\}$  koji na najbolji odabrani način predstavljaju korisnika u pojedinačnom vremenskom opsegu, kao što su jutro, poslijepodne, vikend, mjesec, ljeto, itd. Ova podjela je izvršena na individualnoj razini za svakog korisnika otkrivanjem jedne takve racionalne i objašnjive vremenske particije koja se bazira na ponavljajućem vremenskom ciklusu. U [28] je predložen sistem baziran na sekvencijalnim paternima koji predviđa vremenski promjenljivo korisničko ponašanje, ali

istovremeno koristi i efekat sa vremensko opadajućim težištem. Interesantno je da je u [29] dokazano da stariji podaci imaju negativan utjecaj na tačnost preporuka u slučaju sistema sa korisnički generisanim sadržajem.

Za razliku od navedenih algoritama sa kontinualnom opadajućom funkcijom koji su korišteni sa IB-CF metodom, u [30] smo koristili UB-CF metodu i dobili značajno poboljšanje tačnosti preporuka u određenim uvjetima. U težišnoj funkciji  $w(t) = \exp(-\lambda t)$  smo posmatrali vremensku razliku  $\Delta t$  između posljednjeg ocjenjivanja od svih najbližih susjeda i vremena ocjenjivanja aktivnog korisnika, a zatim je ta težina korištena u koraku predikcije. Naglasili smo različit uspjeh poboljšanja u korištenim data setovima koji se razlikuju po ukupnom vremenskom periodu u kojima su prikupljene ocjene korisnika, s tim da je veći uspjeh bio nad podacima koji su sadržavali kraći vremenski interval, naspram lošijim rezultatima u podacima sa više ocjena iz dužeg vremenskog perioda.

Iako donekle slični navedenim algoritmima sa monotonom opadajućom funkcijom koji smanjuju težinu podataka sa njihovom starošću, algoritmi sa pomjerajućim vremenskim okvirom (engl. *Sliding time-window*) se razlikuju po količini podataka koje uzimaju u obzir. Ovi algoritmi uključuju samo one podatke koji se nalaze u određenom vremenskom okviru i koji sadrži najmanje  $N$  instanci ocjena, npr. 2000 ocjena ili podatke koji se nalaze u određenom vremenskom intervalu, npr. 24 sata i slično. Tako su u [31] korisničke ocjene podijeljene u nekoliko perioda koji su zatim kvantificirani po pojedinačnim interesima korisnika da bi vremenski okvir ukazao na trenutnu sklonost korisnika.

U [32] je predložen UB-CF algoritam koji koristi pomjerajući vremenski okvir sa fiksnim broj takvih instanci iz zapisa web klikova. Algoritam zatim računa sličnosti između posljednjih korisničkih sesija koje se sastoje od ocjena korisnika datih u kratkom vremenskom intervalu od 1h ili slično, prije nego ih preda kao ulaz u kNN algoritam koji treba da računa predikciju. Korištenje vremenskih intervala je predloženo i u [33] u IB-CF algoritmu koji dinamički podešava broj susjeda u koraku predikcije za svakog pojedinačnog korisnika. Algoritmi se treniraju u fiksnim vremenskim intervalima od 7 dana, te se nadgledanjem izabire algoritam sa najmanjom greškom za predikciju ocjenjivanja. Na sličan način je ovaj rad proširen u [34] predlažući model sa ažurnim vremenskim preporučivanjima korištenjem koncepta moderne kontrolne teorije.

U radovima koji se vode sadržajem, odnosno osobinama predmeta, osim sekvencijalnih vremenskih serija se kreiraju i dodatne vremenske serije povezane sa osobinama predmeta da bi se prepoznao trenutni interes korisnika, te se tako kreiraju hibridne metode. Tako autori u [35] prvo grupišu ocjene prema kategorijama predmeta i kreiraju po jednu vremensku seriju za svaku kategoriju, a zatim korištenjem autokorelacijske funkcije prepoznaju vremenski period gdje je došlo do promjene u sklonostima korisnika prema određenoj kategoriji. Na sličan način u [36] su kreirane pojedinačne vremenske serije za svakog korisnika uzimajući u obzir sličnost između predmeta, a zatim su vremenske serije uspoređene sa predefinisanim vremenskih paternima da bi se prepoznale nagle promjene u sklonostima korisnika. U [9] je korištena hijerarhijska taksonomija predmeta s ciljem prepoznavanja i formaliziranja dugoročnih sklonosti korisnika, a zatim je identificirana određena faza u kojoj se nalazi korisnik kao ulaz u CF algoritam. Predložen je za sistem sa implicitnim informacijama u online kupovini, a vrijednovan sa realnim podacima.

Osobine predmeta su također korištene u [37] u obliku formalizirane semantike tako da se povezuju predmeti i njihove osobine sa vremenskim funkcijama koje se korriguju uz pomoć vremenskih krivi kreiranih na osnovu konzumerskih stereotipa u koje se korisnik najbolje uklapa. Drugi pristup vođen adaptacijom vremenskih serija za pojedinačne korisnike je predložen u [38] korištenjem klasifikacijskog algoritma CVFDT koji se automatski prilagođava promjenama u sklonostima korisnika. Algoritam kreira korisničko stablo odlučivanja za svaki predmet i na taj način predviđa ocjene korisnika za druge slične predmete sa kojima postoji visoka korelacija. Autor tvrdi da ukoliko postoji i hijerarhija između predmeta koja koristi unaprijed određenu semantiku, tada algoritam očekivano postiže i dodatno poboljšanje tačnosti. U [39] je razvijen algoritam Eigenstate koji posmatra promjene u sklonostima korisnika tražeći sljedeći predmet preporuke po bilježenju svake pojedinačne ocjene, a zatim mijenja redoslijed na osnovu najnovijih ocjena.

U [40] smo kao nastavak rada iz [30] koristili promjene nad grupnim sklonostima korisnika u UB-CF metodi korištenjem vremenske opadajuće funkcije, a za mjeru sličnosti između susjednih korisnika smo modificirali Personov korelacijski koeficijent koji je uključivao mjerenje sličnosti između kategorija predmeta. Na taj način smo uključili vezu između predmeta preporuke i kategorija kojima pripada, koja je pokazala dobre rezultate u tačnosti preporuka u odnosu na tradicionalni UB-CF algoritam, iako je pokrivenost preporuka bila manja od očekivane. Međutim, pošto se vremenska opadajuća funkcija odnosi na promjene u grupama korisnika, a što je prirodni pristup pošto se radi o CF algoritmu, očekujemo da se pravo poboljšanje treba pokazati korištenjem vremenske funkcije na razini pojedinačnih korisnika, odnosno na podesan način kombiniranjem takvih personaliziranih i grupnih vremenskih opadajućih funkcija.

Kao jedan od najreprezentativnijih radova koji posmatraju kompletan životni ciklus korisnika se smatra [15], čiji algoritmi kombiniraju IB-CF i model matrične faktorizacije da bi razlikovali dugoročne trendove korisnika od podatkovnog šuma koji stvaraju neki oblici ocjenjivanja. Autori tvrde da temporalna dinamika mora iskoristiti sve komponente instanci podataka, a odbaciti samo one koji se pokazuju kao nerelevantne, što posebno važi za CF metode koje koriste takve podatke da računaju mjeru sličnosti između susjeda. Posebno su tretirane promjene sklonosti na razini pojedinačnog predmeta prema promjenama korisnika i shodno tome su im pridružene vremenske funkcije, a parametri algoritama su optimizirani metodom nadgledanog učenja. Modelirana je promjena korisničkih sklonosti korištenjem opadajuće funkcije koja je odvojena od opadajuće funkcije korištene u koraku računanja predikcije. U sličnom pristupu u [18] koji koristi sistem sa latentnim faktorima, promjene u sklonostima korisnika se posmatraju kroz iskustvo korisnika, odnosno sazrijevanje korisnika tokom životnog ciklusa, te se model trenira tako da se prilagođava razinama iskustva korisnika. Faktorizacijski model je također korišten u [41] na trodimenzionalnom tenzoru dobijenom dodavanjem vremenskih faktora u matricu ocjenjivanja. Ukupno vrijeme ocjenjivanja je podijeljeno u  $w$  jednakih intervala, te je uvođenjem vremenske dimenzije u matricu ocjenjivanja  $R$ , dobijen trodimenzionalni tenzor  $T$  dimenzija  $m \times n \times w$ , tako da svaka ćelija u  $T$  sadrži ocjene date od nekog korisnika u jednom vremenskom intervalu. U [42] je predložen hibridni algoritam koji kombinira susjedno bazirani model sa pLSA i MinHash klasteringom koristeći MapReduce programsko okruženje za preporučivanje novosti. Modeliranje kratkoročnih i dugoročnih sklonosti korisnika je u [44] predloženo korištenjem sesijski baziranim vremenskim grafom (eng. *Session-based Temporal Graph* – STG), te su simultano modelirane ove sklonosti. Za rješavanje problema modeliranja dugoročnih vremenskih sklonosti u [45] je predložena metoda preporučivanja koja je uključivala ne samo podatke o interakciji sa sistemom, nego i pružanje prilike korisniku da eksplicitno izrazi svoje dugoročne sklonosti, a zatim i za kratkoročne, odnosno sklonosti koje se vežu samo za jednu sesiju.

Drugi primjeri su [46] gdje se web klikovi također (implicitno) posmatraju kao vremenske serije i u [47] gdje se koristi godina proizvodnje filmova tako da se odbacuju predmeti stariji od uvedenog praga. U [49] je također predloženo preporučivanje web sadržaja na osnovu vremenski baziranog otkrivanja ponašanja sličnih korisnika, te njihovim grupisanjem metodom klasterizacije. Sličnim ciljem se vodi i [54] koji u pokušaju uključivanja kratkoročnih i dugoročnih sklonosti korisnika za predviđanje web sadržaja, odnosno preporučivanja web reklamnih sadržaja zaključuje da se najbolje performanse sistema postižu balansiranjem između ova dva skupa informacija.

Brzina kojom neki korisnici mijenjaju sklonosti je predmet istraživanja i modeliranja u [55] koji korištenjem nelinearne matrične faktorizacije i vektora korisničkih osobina dobijaju poboljšanje u tačnosti predikcije. U [56] je predložen skup različitih modela koji se koriste po potrebi, odnosno uzimajući u obzir različite vremenske efekte kao što su novije, trenutne i potpune sklonosti predlažu i različite modele preporučivanja. Korištenje faktora semantičkih osobina i kategorija predmeta preporučivanja kao evolucijskih informacija je predložen u [57] u pristupu sa matričnom faktorizacijom. Modeliranje dugoročnih sklonosti promjena u sekvencijalnim podacima je predložen u [58] tako da vizualizira modelirajuće faktore da bi se mogli interpretirati i koristiti u sljedećim koracima modeliranja.



Primjer sa modeliranjem sklonosti korisnika koji inicijalno ne uključuje vremenske informacije je [48] gdje se podaci koji se koriste u treniranju modela dijele u nekoliko dijelova prema vremenu ocjenjivanja, a zatim se različite težine daju svakom od ovih dijelova, te na taj način proces postaje vremenski ovisan. U [50] je procjena ocjenjivanja poboljšana uključivanjem vremenskog redoslijeda ocjena u model matrične faktorizacije u smislu učenja različitih faktora predmeta ocjenjivanja u odnosu na vremenske zabilješke ocjenjivanja. Da bi uključio temporalnu dinamiku u implicitne informacije, [52] predlaže random walk model gdje se korisnik-predmet ivice otežavaju prema starosti, tako da se najnovije sklonosti korisnika više naglašavaju tokom random walk-a.

U Tabeli I je prikazan pregled referentnih radova sa korištenim metodama i tehnikama u odnosu prema aplikativnim domenima predmeta preporučivanja, dok je u Tabeli II prikazan pregled radova po izvorima objavljivanja.

Tabela I: Korištene metode i tehnike u odnosu prema aplikativnim domenima predmeta preporučivanja

		Filmovi	Opći e-commerce proizvodi	Dokumenti	Novosti	Muzika	Web sajtovi	TV Program	Ostalo
Metode / tehnike	IB-CF	[3] [4] [5] [10] [14] [29] [35] [51]	[9] [20] [21] [22] [25]	[23] [29]	[12]	[31] [46]		[4] [7]	[39]
	UB-CF	[2] [30] [40] [33] [37] [48] [51] [52] [56]	[24] [27] [38]				[4] [32]		
	CB	[47]			[42]				[39] [45]
	Klastering		[20] [21] [28] [50]				[4] [49]	[4] [7]	
	Modeli latentnih faktora	[4] [10] [15]	[18] [19]						
	Graf bazirani	[36]				[58]			[44]
	Ostale model-bazirane metode	[4] [8] [34] [41] [48] [55] [56] [57]	[8]		[26]	[16]	[4] [46] [54]	[4]	[43]

Tabela II: Pregled referentnih radova prema izvorima objavljivanja

Izvor	Naziv	Referenca
Časopis	IEEE Transactions on Knowledge and Data Engineering	[1] [49]
	ACM Transactions on Information Systems	[5]
	Expert Systems with Applications	[9] [25] [27] [35]
	Artificial Intelligence Review	[59]
	Electronic Commerce Research and Applications	[28]
	IEEE Intelligent Systems	[45]
	User Modeling and User Adapted Interactions	[53] [61]
	Communications of the ACM	[12] [15]
	Engineering Applications and Artificial Intelligence	[37]

Izvor	Naziv	Referenca
	Web Information Systems Engineering	[24]
	Intelligent Data Analysis	[38]
	The adaptive web	[13]
	Database and Expert Systems Applications	[56]
	Knowledge-Based Systems	[60]
	Information Retrieval	[51]
Konferencije	ACM Conference on Information and Knowledge Management	[20] [36]
	SIAM Conference on Data Mining	[8] [32]
	ACM Conference on recommender systems	[22] [29] [39] [50]
	ACM Conference on Knowledge discovery and data mining	[44] [48]
	ACM Conference on Human factors in computing systems	[14]
	IEEE Conference on Data Mining	[7]
	ACM Conference on Research and development in information retrieval	[2] [10] [33] [52]
	ACM Conference on WWW	[3] [18] [26] [34] [42] [43] [54]
	IEEE/WIC/ACM Joint Conferences on Web Intelligence and Intelligent Agent Technologies	[57]
	Workshop on context-aware recommender systems	[16] [19]
	Uncertainty in artificial intelligence	[4] [46]
	Australasian Database Conference	[21]
	World Conference on Educational Multimedia, Hypermedia and Telecommunications	[23]
	IEEE/WIC International Conference on Web Intelligence	[47]
	IEEE Intelligent Information Technology and Security Informatics	[31]
	AAAI Conference on Artificial Intelligence	[55]
	Ostale IEEE konferencije	[30] [40]
	Ostale konferencije	[58]
Ostalo	Knjiga	[6] [11]
	Tehnički izvještaj	[17]

#### 4 Opis problema

Tradicionalni pristup u sistemima za preporučivanje podrazumijeva kreiranje profile korisnika na osnovu njihovih sklonosti, odnosno ocjena predmeta, a zatim korištenje tih profila za predikciju ocjena za korisnika nevidenih predmeta i generisanje liste preporuka. Međutim, u ovim pristupima raspoloživi podaci se često posmatraju kao statični i ne uzimaju u obzir promjene u sistemu, bilo da se radi o novim korisnicima, predmetima i ocjenama koje se stalno dodaju u sistem i donose promjene u informacijama o sklonostima korisnika [52].

Globalne promjene sklonosti svih korisnika prema nekom predmetu se mogu jednostavno otkriti i odrediti. Svaki ponuđač proizvoda ima jasnu informaciju o tome kada za neki predmet opada ili raste interes, odnosno kada korisnici SP-a daju pozitivne ili negativne ocjene predmeta. Tradicionalni SP u određenoj mjeri prate ovakve globale promjene i shodno tome preporučuju predmete svim korisnicima [52]. Međutim, ovakvo preporučivanje ne prati promjene u sklonostima pojedinačnih korisnika, te korisnici dobijaju netačne ili čak neželjene preporuke.

Korištenje navedenih referentnih metoda i algoritama koje se bave promjenama u sklonostima korisnika uključivanjem vremenskih podataka također često ne daje zadovoljavajuće rezultate. Na primjer, osnovni nedostatak algoritama vođenih opadajućom vremenskom funkcijom je u poništavanju težine dijela podataka i time zanemarivanja dugoročnih preferenci korisnika [15]. Kod CF metoda, korištenjem samo IB-CF metode također predstavlja problem, pošto se predmeti naručeni u različitim vremenskim periodima

moгу značajno razlikovati. Također, u UB-CF metodi, svaka promjena individualnih sklonosti korisnika istovremeno utječe i na sklonosti susjednih sličnih korisnika i obrnuto [40]. Slijedi da svaka promjena u sklonostima korisnika koji su dio ovakvih neformalnih i virtualnih grupa mora također biti prepoznata i uzeta u obzir u cilju poboljšanja kvaliteta preporučivanja.

Neka istraživanja su pokazala razlike u osnovnim pretpostavkama na kojima se razvijaju modeli preporučivanja, te tako praveći problem u generaliziranju vremensko svjesnih preporučivanja. Rezultati iz [20] su još prije pokazali poboljšanja prilikom uvođenja opadajuće vremenske težine, dok su eksperimenti u [15] pokazali bolje predikcije kada vremenska težina nije uopće korištena. S druge strane, [16] je prilikom kreiranja mikro profila pokazao da se neka iracionalno i nejasno uvedena particioniranja kao što je podjela na parne i neparne sate pokazuje kao bolje u poboljšanju preporučivanja, nego kada se koriste druge prirodne particije kao što su {večer, jutro} ili {radni dan, vikend}.

Iako se mjera sličnosti između korisnika koja se koristi u CF metodama koristi i smatra kao ključna u modelu predikcije ocjenjivanja, [10] je korištenjem slučajno generiranih varijabli u koraku predikcije umjesto izračunate mjere sličnosti između korisnika dobio vrlo malo pogoršanje u tačnosti predikcije, te otvorio pitanje važnosti ove veličine u CF pod određenim uvjetima. Isti autor je u [33] pokazao da se poboljšanje vremensko ovisnih SP-a mora mjeriti izričitim korištenjem preteklih ocjenjivanja da bi se predvidjela buduća ocjenjivanja i to na iterativan način, tj. postepenim povećanjem dijelova podataka iz ukupnog skupa podataka koji se koristi za preporučivanja. Isto tako, u smislu vrijednovanja poboljšanja, u [53] je autor pokazao da mnogi modeli i algoritmi koji ne uključuje vremenske informacije u stvari ne koriste vremenski redoslijed podataka prilikom validacije i razdvajanju trening i testnog skupa podataka, te tako dovodi u pitanje realno poboljšanje vremensko ovisnih algoritama u odnosu na neovisne i tradicionalne algoritme.

Uspješnost model baziranih modela je upitna zbog njihove nepraktičnosti i neažurnosti, jer zahtijevaju izračunavanje modelskih faktora svaki put kada se matrica ocjena ažurira, a za što su potrebni veliki resursi [60]. Zbog uštede resursa se u praktičnim implementacijama treniranje ovih modela radi u velikim vremenskim ciklusima, te se na taj način gubi jedan vrlo značajan značajan dio informacija, a to je onaj koji je zabilježen od trenutka posljednjeg treniranja modela.

Prirodno je pretpostaviti da se promjene u sklonostima korisnika dešavaju na različite načine i sa različitim intenzitetom u različitim aplikacijama, te će se zbog toga ove promjene i različito modelirati [61]. Na primjer, korisnik vjerovatno na različite načine i različitim intenzitetom mijenja sklonosti prema hrani, odjeći ili obući nego prema filmovima, muzici ili putovanjima, odnosno različito mijenja sklonosti prema predmetima koji se nalaze na različitim razinama piramide ljudskih potreba. Osim otkrivanja i modeliranja ovih informacija u sistemima za preporučivanje, pojavljuje se i izazov u načinu njihovog iskorištavanja u smislu odgovarajući balansa između tačnosti predikcije s jedne, te diverzifikacije i noviteta preporuka s druge strane.

## **5 Cilj istraživanja**

Ovo istraživanje će se fokusirati na problem modeliranja i uključivanja vremena kao izvora kontekstualnih informacija u sisteme za preporučivanje.

Osnovni cilj istraživanja koji proizilazi iz motivacije, analize stanja u oblasti istraživanja i opisanih problema je novi pristup u modeliranju promjena u sklonostima korisnika u sistemima za preporučivanje.

Istraživanje treba da pokaže da je moguće modeliranje promjena na takav način da se kombinovanim uključivanjem dugoročnih i kratkoročnih promjena dobije povećan kvalitet preporuka u obliku tačnosti preporuka, te noviteta i diverzifikacije preporuka.

## **6 Metode i plan istraživanja**

Metode istraživanja će se zasnivati na teoretskim razmatranjima, različitima

analizama, induktivno-deduktivnim metodama, te empirijskim i eksperimentalnim potvrdama dobijenih rezultata poboljšanja.

Okvirni plan istraživanja sadrži sljedeće aktivnosti i korake:

a) Proučavanje i klasifikaciju objavljenih naučnih i stručnih radova iz oblasti sistema za preporučivanje, te data mining tehnika pogodnih za korištenje u sistemima za proučavanje.

b) Teorijska razmatranja i istraživanje predloženih modela, tehnika i algoritama za poboljšanje kvaliteta preporuka,

c) Statističke obrade različitih realnih skupova podataka iz sistema za preporučivanje u cilju otkrivanja i klasifikacije promjena u sklonostima korisnika,

d) Analiza i razmatranje rezultata statističkih obrada. Razmatranje i otkrivanje načina i razloga zbog kojih se promjene dešavaju. Otkrivanje i zaključivanje o mogućim korelacijama između profila korisnika i profila predmeta preporučivanja u kontekstu tih promjena.

e) Definiranje različitih faktora kojim se na pogodan način opisuju individualne i grupne, te kratkoročne i dugoročne promjene u sklonostima korisnika,

f) Konstrukcije modela koji podržavaju prethodno definirane faktore i njihova ugradnja u postojeće metode SP-a, odnosno izgradnja poboljšanih algoritama i metoda za preporučivanje.

g) Eksperimentalno potvrđivanje validnosti poboljšanih algoritama i metoda u off-line eksperimentima.

Podaci koji će biti korišteni za analizu i eksperimente već opće poznati skupovi podataka koji se koriste u ovakvim vrstama istraživanja. Radi se o skupovima podataka prikupljenim na sistemima koji su u eksploataciji duži vremenski period i čiji se podaci su raspoloživi akademskoj zajednici za ovakve vrste istraživanja.

Statističke analize podataka, njihova analiza, kao i eksperimentalno potvrđivanje rezultata će se vršiti na podesnoj računarskoj platformi kreiranoj za ovakve vrste eksperimenata, koja sadrži više različitih softverskih alata za data mining, kao i namjenskih softverskih paketa za proučavanje sistema za preporučivanje. Validacija rezultata će se vršiti korištenjem poznatih mjera korisnosti koje su opisane u prethodnim poglavljima.

## **7 Očekivani rezultati i izvorni naučni doprinos**

Istraživanje će pružiti naučni i stručni doprinos. Osnovni naučni doprinos se sastoji u prijedlogu modela kombiniranih dugoročnih i kratkoročnih sklonosti korisnika koji mogu pružiti povećanje korisnosti sistema za preporučivanje. Stručni doprinos će se odnositi na opis pravaca i preporuka za ugradnju takvih modela u postojeće sisteme za preporučivanje i njihovo poboljšanje.

Sekundarni doprinosi uključuju sljedeće:

- Analize vremenskih promjena u sklonostima pojedinačnih korisnika i grupa korisnika koje treba da pokažu obrazce na koje načine se sklonosti mijenjaju u ovisnosti od različitih vremenskih kontekstualnih varijabli,

- Definicija faktora koji mogu opisati odnos između kratkoročnih i dugoročnih promjena s jedne strane, te osobina korisnika i predmeta s druge strane,

- Skup hibridnih algoritama koji će na podesan način iskoristiti prednosti svake od memorijskih i model-baziranih metoda tako da se postigne poboljšanje u kvaliteti preporuka, ali istovremeno i optimizira korištenje potrebnih resursa u konkretnim aplikacijama sistema.

## **8 Literatura**

- [1] Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *Knowledge and Data Engineering, IEEE Transactions on*, 17(6), 734-749.
- [2] Herlocker, J. L., Konstan, J. A., Borchers, A., & Riedl, J. (1999, August). An algorithmic

- framework for performing collaborative filtering. In Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval (pp. 230-237). ACM.
- [3] Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001, April). Item-based collaborative filtering recommendation algorithms. In Proceedings of the 10th international conference on World Wide Web (pp. 285-295). ACM.
  - [4] Breese, J. S., Heckerman, D., & Kadie, C. (1998, July). Empirical analysis of predictive algorithms for collaborative filtering. In Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence (pp. 43-52). Morgan Kaufmann Publishers Inc.
  - [5] Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems (TOIS)*, 22(1), 5-53.
  - [6] Adomavicius, G., & Tuzhilin, A. (2011). Context-aware recommender systems. In *Recommender systems handbook* (pp. 217-253). Springer US.
  - [7] Hu, Y., Koren, Y., & Volinsky, C. (2008, December). Collaborative filtering for implicit feedback datasets. In *Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on* (pp. 263-272). IEEE.
  - [8] Xiong, L., Chen, X., Huang, T. K., Schneider, J. G., & Carbonell, J. G. (2010). Temporal Collaborative Filtering with Bayesian Probabilistic Tensor Factorization. In *SDM (Vol. 10, pp. 211-222)*.
  - [9] Hong, W., Li, L., & Li, T. (2012). Product recommendation with temporal dynamics. *Expert Systems with Applications*, 39(16), 12398-12406.
  - [10] Lathia, N., Hailes, S., Capra, L., & Amatriain, X. (2010, July). Temporal diversity in recommender systems. In Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval (pp. 210-217). ACM.
  - [11] Shani, G., & Gunawardana, A. (2011). Evaluating recommendation systems. In *Recommender systems handbook* (pp. 257-297). Springer US.
  - [12] Konstan, J. A., Miller, B. N., Maltz, D., Herlocker, J. L., Gordon, L. R., & Riedl, J. (1997). GroupLens: applying collaborative filtering to Usenet news. *Communications of the ACM*, 40(3), 77-87.
  - [13] Burke, R. (2007). Hybrid web recommender systems. In *The adaptive web* (pp. 377-408). Springer Berlin Heidelberg.
  - [14] Cosley, D., Lam, S. K., Albert, I., Konstan, J. A., & Riedl, J. (2003, April). Is seeing believing?: how recommender system interfaces affect users' opinions. In Proceedings of the SIGCHI conference on Human factors in computing systems (pp. 585-592). ACM.
  - [15] Koren, Y. (2010). Collaborative filtering with temporal dynamics. *Communications of the ACM*, 53(4), 89-97.
  - [16] Baltrunas, L., & Amatriain, X. (2009, October). Towards time-dependant recommendation based on implicit feedback. In *Workshop on context-aware recommender systems (CARS'09)*.
  - [17] Tsybal, A. (2004). The problem of concept drift: definitions and related work. Computer Science Department, Trinity College Dublin, 106.
  - [18] McAuley, J. J., & Leskovec, J. (2013, May). From amateurs to connoisseurs: modeling the evolution of user expertise through online reviews. In Proceedings of the 22nd international conference on World Wide Web (pp. 897-908). International World Wide Web Conferences Steering Committee.
  - [19] Said, A., De Luca, E. W., & Albayrak, S. (2011). Inferring contextual user profiles-improving recommender performance. In Proceedings of the 3rd RecSys Workshop on Context-Aware Recommender Systems.

- [20] Ding, Y., & Li, X. (2005, October). Time weight collaborative filtering. In Proceedings of the 14th ACM international conference on Information and knowledge management (pp. 485-492). ACM.
- [21] Ding, Y., Li, X., & Orłowska, M. E. (2006, January). Recency-based collaborative filtering. In Proceedings of the 17th Australasian Database Conference-Volume 49 (pp. 99-107). Australian Computer Society, Inc..
- [22] Liu, N. N., Zhao, M., Xiang, E., & Yang, Q. (2010, September). Online evolutionary collaborative filtering. In Proceedings of the fourth ACM conference on Recommender systems (pp. 95-102). ACM.
- [23] Hermann, C. (2010, June). Time-based recommendations for lecture materials. In 2010 World Conference on Educational Multimedia, Hypermedia and Telecommunications (pp. 1028-1033).
- [24] Gordea, S., & Zanker, M. (2007). Time filtering for better recommendations with small and sparse rating matrices. In Web Information Systems Engineering-WISE 2007 (pp. 171-183). Springer Berlin Heidelberg.
- [25] Lee, T. Q., Park, Y., & Park, Y. T. (2008). A time-based approach to effective recommender systems using implicit feedback. *Expert systems with applications*, 34(4), 3055-3062.
- [26] Chu, W., & Park, S. T. (2009, April). Personalized recommendation on dynamic content using predictive bilinear models. In Proceedings of the 18th international conference on World wide web (pp. 691-700). ACM.
- [27] Lee, T. Q., Park, Y., & Park, Y. T. (2009). An empirical study on effectiveness of temporal information as implicit ratings. *Expert Systems with Applications*, 36(2), 1315-1321.
- [28] Huang, C. L., & Huang, W. L. (2009). Handling sequential pattern decay: Developing a two-stage collaborative recommender system. *Electronic Commerce Research and Applications*, 8(3), 117-129.
- [29] De Pessemier, T., Dooms, S., Deryckere, T., & Martens, L. (2010, September). Time dependency of data quality for collaborative filtering algorithms. In Proceedings of the fourth ACM conference on Recommender systems (pp. 281-284). ACM.
- [30] Karahodza, B., Supic, H., & Donko, D. (2014, October). An approach to design of time-aware recommender system based on changes in group user's preferences. In Telecommunications (BIHTEL), 2014 X International Symposium on (pp. 1-4). IEEE.
- [31] Zhang, Y., & Liu, Y. (2010, April). A Collaborative filtering algorithm based on time period partition. In Intelligent Information Technology and Security Informatics (IITSI), 2010 Third International Symposium on (pp. 777-780). IEEE.
- [32] Nasraoui, O., Cerwinski, J., Rojas, C., & González, F. A. (2007, April). Performance of Recommendation Systems in Dynamic Streaming Environments. In SDM (pp. 569-574).
- [33] Lathia, N., Hailes, S., & Capra, L. (2009, July). Temporal collaborative filtering with adaptive neighbourhoods. In Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval (pp. 796-797). ACM.
- [34] Jambor, T., Wang, J., & Lathia, N. (2012, April). Using control theory for stable and efficient recommender systems. In Proceedings of the 21st international conference on World Wide Web (pp. 11-20). ACM.
- [35] Min, S. H., & Han, I. (2005). Detection of the customer time-variant pattern for improving recommender systems. *Expert Systems with Applications*, 28(2), 189-199.
- [36] Cao, H., Chen, E., Yang, J., & Xiong, H. (2009, November). Enhancing recommender systems under volatile user interest drifts. In Proceedings of the 18th ACM conference on Information and knowledge management (pp. 1257-1266). ACM.

- [37] Blanco-Fernández, Y., López-Nores, M., Pazos-Arias, J. J., & García-Duque, J. (2011). An improvement for semantics-based recommender systems grounded on attaching temporal information to ontologies and user profiles. *Engineering Applications of Artificial Intelligence*, 24(8), 1385-1397.
- [38] Li, X., Barajas, J.M., Ding, Y., Collaborative filtering on streaming data with interest-drifting, *Intelligent Data Analysis*, Vol. 11, No. 1. (2007), pp. 75-87.
- [39] Nathanson, T., Bitton, E., & Goldberg, K. (2007, October). Eigentaste 5.0: constant-time adaptability in a recommender system using item clustering. In *Proceedings of the 2007 ACM conference on Recommender systems* (pp. 149-152). ACM.
- [40] Karahodža B., Donko Dž., Šupić H., Temporal Dynamics of Changes in Group User's Preferences in Recommender Systems, n: *Proceedings of 38th International Convention on Information & Communication Technology, Electronics & Microelectronics - MIPRO 2015*, Opatija, Croatia, 2015.
- [41] Xiong, L., Chen, X., Huang, T. K., Schneider, J. G., & Carbonell, J. G. (2010). Temporal Collaborative Filtering with Bayesian Probabilistic Tensor Factorization. In *SDM* (Vol. 10, pp. 211-222).
- [42] Das, A. S., Datar, M., Garg, A., & Rajaram, S. (2007, May). Google news personalization: scalable online collaborative filtering. In *Proceedings of the 16th international conference on World Wide Web* (pp. 271-280). ACM.
- [43] Aly, M., Pandey, S., Josifovski, V., & Punera, K. (2013, May). Towards a robust modeling of temporal interest change patterns for behavioral targeting. In *Proceedings of the 22nd international conference on World Wide Web* (pp. 71-82). International World Wide Web Conferences Steering Committee.
- [44] Xiang, L., Yuan, Q., Zhao, S., Chen, L., Zhang, X., Yang, Q., & Sun, J. (2010, July). Temporal recommendation on graphs via long-and short-term preference fusion. In *Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 723-732). ACM.
- [45] Ricci, F., & Nguyen, Q. N. (2007). Acquiring and revising preferences in a critique-based mobile recommender system. *Intelligent Systems*, IEEE, 22(3), 22-29.
- [46] Zimdars, A., Chickering, D. M., & Meek, C. (2001, August). Using temporal data for making recommendations. In *Proceedings of the Seventeenth conference on Uncertainty in artificial intelligence* (pp. 580-588). Morgan Kaufmann Publishers Inc..
- [47] Tang, T. Y., Winoto, P., & Chan, K. C. (2003, October). On the temporal analysis for improved hybrid recommendations. In *Web Intelligence, 2003. WI 2003. Proceedings. IEEE/WIC International Conference on* (pp. 214-220). IEEE.
- [48] Jahrer, M., Töschner, A., & Legenstein, R. (2010, July). Combining predictions for accurate recommender systems. In *Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 693-702). ACM.
- [49] Petridou, S. G., Koutsounikola, V. A., Vakali, A. I., & Papadimitriou, G. I. (2008). Time-aware web users' clustering. *Knowledge and Data Engineering, IEEE Transactions on*, 20(5), 653-667.
- [50] Karatzoglou, A. (2011, October). Collaborative temporal order modeling. In *Proceedings of the fifth ACM conference on Recommender systems* (pp. 313-316). ACM.
- [51] Herlocker, J., Konstan, J. A., & Riedl, J. (2002). An empirical analysis of design choices in neighborhood-based collaborative filtering algorithms. *Information retrieval*, 5(4), 287-310.
- [52] Lathia, N., Hailes, S., & Capra, L. (2009, July). Temporal collaborative filtering with adaptive neighbourhoods. In *Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval* (pp. 796-797). ACM.
- [53] Campos, P. G., Díez, F., & Cantador, I. (2014). Time-aware recommender systems: a

comprehensive survey and analysis of existing evaluation protocols. *User Modeling and User-Adapted Interaction*, 24(1-2), 67-119.

- [54] Aly, M., Pandey, S., Josifovski, V., & Punera, K. (2013, May). Towards a robust modeling of temporal interest change patterns for behavioral targeting. In *Proceedings of the 22nd international conference on World Wide Web* (pp. 71-82). International World Wide Web Conferences Steering Committee.
- [55] Li, R., Li, B., Jin, C., Xue, X., & Zhu, X. (2011, April). Tracking User-Preference Varying Speed in Collaborative Filtering. In *AAAI*.
- [56] Stefanidis, K., Ntoutsis, I., Nørvåg, K., & Kriegel, H. P. (2012, January). A framework for time-aware recommendations. In *Database and Expert Systems Applications* (pp. 329-344). Springer Berlin Heidelberg.
- [57] Rowe, M. (2014, August). Semanticsvd++: Incorporating semantic taste evolution for predicting ratings. In *Proceedings of the 2014 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)-Volume 01* (pp. 213-220). IEEE Computer Society.
- [58] Moore, J. L., Chen, S., Turnbull, D., & Joachims, T. (2013). Taste Over Time: The Temporal Dynamics of User Preferences. In *ISMIR* (pp. 401-406).
- [59] Rana, C., & Jain, S. K. (2015). A study of the dynamic features of recommender systems. *Artificial Intelligence Review*, 43(1), 141-153.
- [60] Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46, 109-132.
- [61] Konstan, J. A., & Riedl, J. (2012). Recommender systems: from algorithms to user experience. *User Modeling and User-Adapted Interaction*, 22(1-2), 101-123.