

SISTEMI ZA PREPORUČIVANJE U PAMETNIM GRADOVIMA

Vesna Radonjić Đogatović¹, Milica Danilović²

¹Univerzitet u Beogradu - Saobraćajni fakultet, v.radonjic@sf.bg.ac.rs

²HUAWEI Technologies, milica.danilovic@huawei.com

Rezime: U eri digitalizovanih informacija i širokog spektra različitih servisa, fenomen preopterećenosti podacima doveo je do pojave i razvoja sistema za preporučivanje, koji se zasnivaju na analitici podataka, veštačkoj inteligenciji i personalizaciji korisničkog iskustva. Primena ovih sistema predstavlja napredak u razvoju personalizovanih pristupa koji poboljšavaju efikasnost obezbeđivanja servisa, kao i zadovoljstvo i angažovanost korisnika. U okviru pametnih gradova, sistemi za preporučivanje, kroz implementaciju pristupa za filtriranje informacija, mogu se koristiti za unapređenje odnosa između raznolikih zainteresovanih strana i asistiranje u zadacima donošenja odluka u pametnom gradu putem različitih tehnoloških platformi.

Ključne reči: filtriranje, korisnici, predmeti interesovanja, preporuke, servisi.

1. Uvod

Aplikacije u pametnom gradu funkcionišu kroz digitalnu infrastrukturu koja treba da omogući povezivanje različitih sistema i uređaja, pružajući širok spektar servisa [1]. U takvom okruženju upotreba podataka ima strateški značaj i veoma važnu ulogu u procesima optimizacije gradskih servisa i poboljšanju angažovanja pojedinaca. Upravljanje podacima u pametnim gradovima predstavlja ključni aspekt njihovog uspešnog funkcionisanja i razvoja. Sistemi za preporučivanje, koji koriste sofisticirane algoritme veštačke inteligencije, pojavili su se kao vitalni alati u kontekstu upravljanja podacima.

Sistemi za preporučivanje služe za filtriranje informacija i osmišljeni su da olakšaju donošenje odluka u domenima i aplikacijama gde postoji mnogo opcija među kojima se vrši izbor. Za razliku od pretraživača gde korisnik mora da specificira svoje potrebe i interese u obliku upita, sistemi za preporučivanje su proaktivni u predlaganju preporuka potencijalne relevantnosti za korisnika, u skladu sa ličnim podacima i preferencijama prethodno zabeleženim u profilu.

Tipični zadaci sistema za preporučivanje su:

- prikupljanje informacija o korisnicima,
- učenje iz prikupljenih informacija i predikcija preferencija korisnika za nepoznate predmete interesovanja i

- primena funkcije ili izgradnja modela koji bira i rangira preporuke koje su verovatno najpoželjnije za korisnike [2].

Uzimajući u obzir brzu ekspanziju pametnih gradova, integracija sistema za preporučivanje u svakom segmentu pametnog grada postaje sve značajnija za pružanje personalizovanih servisa i poboljšanje procesa donošenja odluka.

U ovom radu su predstavljene osnovne karakteristike sistema za preporučivanje, glavni pristupi i tehnike koje se primenjuju u ovim sistemima. Razmatrane su potencijalne primene sistema za preporučivanje u pametnim gradovima, kao i indikatori efikasnosti sistema i izazovi sa kojima se ovi sistemi suočavaju.

2. Karakteristike i klasifikacija sistema za preporučivanje

Sistemi za preporučivanje uključuju dva osnovna entiteta: korisnike i predmete interesovanja, pri čemu svaki korisnik daje ocenu (ili vrednost preferencije) nekom predmetu interesovanja (npr. servisu ili proizvodu). Ocene korisnika se generalno prikupljaju koristeći implicitne ili eksplicitne metode. Implicitne metode podrazumevaju indirektno prikupljanje informacija o korisničkim preferencijama kroz interakciju korisnika sa sistemom i/ili okruženjem. Iako omogućavaju prikupljanje velike količine informacija o korisnicima, implicitne metode imaju tendenciju prikupljanja češće pominjanih informacija koje se povezuju sa pozitivnim preferencijama. Poseban tip implicitnih povratnih informacija u sistemima za preporučivanje sastoji se od podataka generisanih pretraživanjem ličnih mišljenja i sadržaja slobodno dostupnih na društvenim medijima kao što su profili na društvenim mrežama, tekstualne recenzije, blogovi i forumi [3].

S druge strane, eksplicitne povratne informacije odnose se na direktne izjave korisnika o preferencijama za poznate predmete interesovanja. Njih daju korisnici odabirom vrednosti na nekoj konačnoj skali ili u označenim intervalnim vrednostima. Numeričke ocene se koriste za rangiranje preporuka prema različitim stepenima (ne)svidanja, dok su binarne ocene pojednostavljen oblik eksplicitnih preferencija kojima korisnici samo izražavaju svoja pozitivna ili negativna mišljenja o predmetima interesovanja. Ocene odražavaju naklonost korisnika prema određenom predmetu interesovanja. U ovom slučaju, negativne preferencije se zanemaruju. Eksplicitne povratne informacije omogućavaju preciznu kontrolu nad onim što sistem zna o preferencijama korisnika, ali zahtevaju vreme i trud korisnika. Takođe, kada se eksplicitne interakcije uključe u realne aplikacije, postoji rizik od pristrasnosti u distribucijama ocena, a samim tim i u predikcijama relevantnosti preporuke, jer korisnici mogu biti skloni ocenjivanju samo onoga što im se sviđa [4].

Većina sistema za preporučivanje prikuplja ocene korisnika kroz obe metode, eksplicitne i implicitne. Te povratne informacije ili ocene koje pruža korisnik raspoređuju se u matricu korisnik-preporuka, koja se naziva matrica korisnosti. Treba napomenuti da su značajne samo visoke ocene korisnika jer se samo takve stavke predlažu korisnicima. Efikasnost sistema za preporučivanje u velikoj meri zavisi od vrste algoritma koji se koristi i prirode izvora podataka, koji mogu biti kontekstualni, tekstualni, vizuelni, itd [5]. S druge strane, pored eksplicitnih i implicitnih preferencija korisnika, postoje i druge karakteristike koje se mogu koristiti za modeliranje korisnika, kao što su demografski podaci, osobine ličnosti, emocionalna stanja ili odnosi poverenja.

Prilikom kreiranja sistema za preporučivanje, predmeti interesovanja takođe moraju biti profilisani na odgovarajući način. I u ovom slučaju postoje različite tehnike, bilo eksplicitne ili implicitne, za opisivanje potencijalnih preporuka. Profili se mogu graditi pomoću ključnih reči, opisa, atributa, svojstava i latentnih karakteristika, tj. karakteristika koje su izračunate iz posmatranih karakteristika korišćenjem pogodne matematičke metode, kao što je faktorizacije matrica.

Sistemi za preporučivanje mogu se klasifikovati prema različitim kriterijumima, u zavisnosti od zadatka na koji su usmereni. Najčešće se razmatraju tri glavne kategorije sistema zasnovane na načinu na koji se preporuke generišu [5]:

- sistemi zasnovani na sadržaju (*Content Based Filtering*, CBF), koji predlažu preporuke slične onima koje su se korisnicima dopale u prošlosti,
- sistemi kolaborativnog filtriranja (*Collaborative Filtering*, CF) koji korisnicima predlažu preporuke koje su preferirali ljudi sličnih interesovanja i
- hibridni sistemi.


Generalno, prvi pristup koristi sličnosti preporuka zasnovanih na tekstualnim reprezentacijama, dok drugi koristi obrasce ocenjivanja. Takođe, za svaku od prethodno navedenih kategorija, sistemi za preporučivanje mogu se klasifikovati prema algoritamskom pristupu koji koriste. U tom smislu, postoje dva glavna tipa [4]:

- sistemi zasnovani na heuristikama, koji procenjuju relevantnost preporuka pomoću matematičkih modela i
- sistemi zasnovani na modelima, koji predviđaju relevantnost preporuka pomoću tehnika mašinskog učenja.

2.1. Sistemi zasnovani na sadržaju

Sistemi zasnovani na sadržaju koriste tekstualne opise i/ili dodatne informacije o sadržaju, kao što su ključne reči, metapodaci, semantičke anotacije i društvene oznake za predstavljanje korisnika i predmeta interesovanja, te izdvajaju preporuke čiji su profili sličniji zahtevima ciljnog korisnika. Modeliranje profila preporuka, tako da budu dostupni za automatsku analizu, jedno je od glavnih pitanja u ovom tipu sistema. U ovom kontekstu, treba napomenuti da se opisi predmeta interesovanja mogu dobiti iz sadržaja objavljenih na elektronskim medijima (npr. recenzije na komercijalnim sajtovima, objave na društvenim mrežama i blogovi) koji moraju biti obrađeni na odgovarajući način. Modeli zasnovani na pristupu CBF mogu uključivati Bajesove modele, koji su namenjeni klasifikaciji predmeta interesovanja kao relevantnih ili nerelevantnih [4].

U sistemima za preporučivanje zasnovanim na sadržaju, svi podaci o predmetima interesovanja prikupljaju se i grupišu u različite profile, na osnovu svojih opisa i/ili karakteristika. Kada korisnik pozitivno oceni neku stavku, drugi predmeti interesovanja prisutni u tom profilu se agregiraju kako bi se izgradio profil korisnika. Ovaj profil korisnika kombinuje sve profile predmeta njegovih interesovanja, koje je pozitivno ocenio. Stavke prisutne u ovom profilu korisnika zatim se preporučuju korisniku (Slika 1) [5].



Slika 1. Proces preporučivanja predmeta korisniku u sistemima zasnovanim na sadržaju

Kako se preferencije korisnika vremenom menjaju, ovaj pristup ima sposobnost da se brzo dinamički prilagodi tim promenama. S obzirom da je profil korisnika specifičan samo za tog korisnika, ovaj algoritam ne zahteva detalje profila drugih korisnika, jer oni nemaju uticaj na proces preporučivanja. To osigurava bezbednost i privatnost korisničkih podataka. Ako nove stavke imaju dovoljno opisa, tehnika zasnovana na sadržaju može preporučiti stavku čak i u slučaju da ne postoje ocene drugih korisnika. Njihova najčešća primena je za personalizovane sisteme preporuka za vesti, publikacije, veb stranice, itd. Nedostatak ovog pristupa je to što zahteva temeljno poznavanje karakteristika stavki za tačnu preporuku. Ove informacije možda neće uvek biti dostupne za sve predmete interesovanja. Takođe, ovaj pristup ima ograničenu sposobnost da proširi korisničke postojeće izbore ili interesovanja.

2.2 Sistemi kolaborativnog filtriranja


Sistemi kolaborativnog filtriranja oslanjaju se na ocene koje su korisnici već dodelili postojećim predmetima interesovanja. Ovi sistemi predlažu ciljnim korisnicima preporuke koje su preferirali ljudi sa sličnim interesovanjima. Najpopularniji primer CF je algoritam k -najbližih suseda (k -Nearest Neighbors, kNN), heuristički zasnovan pristup koji koristi matematičke modele za predikciju ocena oslanjajući se na ocene k korisnika čiji su profili ocena najbliži ocenama ciljnog korisnika (pristup zasnovan na korisnicima) ili na k predmeta interesovanja čiji su profili ocena najbliži traženom predmetu interesovanja (pristup zasnovan na predmetu interesovanja). Efikasnost kolaborativnog algoritma zavisi od toga koliko tačno algoritam može pronaći susedstvo ciljnog korisnika.

Generalno, sistemi zasnovani na kolaborativnom filtriranju ne daju dobre rezultate u slučaju nedovoljne količine informacija i suočavaju se sa potencijalnim problemom ugrožavanja privatnosti, jer postoji potreba za deljenjem podataka o korisnicima. Međutim, ovi pristupi ne zahtevaju nikakvo znanje o karakteristikama stavki za generisanje preporuka. Takođe, kolaborativno filtriranje može pomoći u proširenju postojećih interesovanja korisnika otkrivanjem novih predmeta interesovanja.

Kolaborativni pristupi obuhvataju dva tipa sistema: pristupe zasnovane na memoriji i pristupe zasnovane na modelima. Pristupi zasnovani na memoriji predlažu nove preporuke uzimajući u obzir preferencije njihovog susedstva. Oni koriste matricu korisnosti direktno za predikciju. U ovom pristupu, prvi korak je izgradnja modela. Model je jednak funkciji koja uzima matricu korisnosti kao ulaz. Preporuke se prave na osnovu funkcije koja za ulaz uzima model i profil korisnika. Ovdje je moguće davati preporuke samo korisnicima čiji profil pripada matrici korisnosti. Stoga, kako bi se kreirale preporuke za novog korisnika, profil korisnika mora biti dodat u matricu korisnosti, a matrica sličnosti treba ponovo da se izračuna, što ovu tehniku čini računski zahtevnom [4].

Pristupi zasnovani na memoriji svrstavaju se u dva tipa: filtriranje zasnovano na korisnicima i filtriranje zasnovano na predmetu interesovanja.

U pristupu zasnovanom na korisnicima, ocena novog predmeta interesovanja za korisnika se računa pronalaženjem drugih korisnika iz njegovog susedstva koji su prethodno ocenili istu stavku. Ako novi predmet interesovanja dobije pozitivne ocene od korisnika iz susedstva, on se predlaže posmatranom korisniku (Slika 2).



Slika 2. Kolaborativno filtriranje zasnovano na korisnicima [5]

U pristupu zasnovanom na predmetu interesovanja, gradi se susedstvo koje se sastoji od svih sličnih predmeta koje je korisnik prethodno ocenio. Zatim se ocena korisnika za drugi, novi predmet interesovanja određuje izračunavanjem ponderisanog proseka svih ocena prisutnih u sličnom susedstvu, kao što je prikazano na slici 3.



Slika 3. Kolaborativno filtriranje zasnovano na predmetu interesovanja [4]

Sistemi zasnovani na modelima koriste različite algoritme za pretraživanje podataka i mašinsko učenje kako bi razvili model za predikciju ocene korisnika za neocenjenu stavku. Kada se preporuke računaju ne oslanjaju se na celokupni skup podataka, već izvode karakteristike iz skupa podataka kako bi se izgradio model. Ove tehnike takođe zahtevaju dva koraka za predikciju. Prvi korak je izgradnja modela, a drugi korak je predikcija ocena korišćenjem funkcije koja za ulaz uzima model definisan u prvom koraku i profil korisnika. Tehnike zasnovane na modelima ne zahtevaju dodavanje profila novog korisnika u matricu korisnosti pre nego što se izvrše predikcije. Preporuke je moguće davati čak i korisnicima koji nisu prisutni u modelu. Sistemi zasnovani na modelima su efikasniji za grupne preporuke jer mogu brzo preporučiti grupu stavki koristeći unapred obučeni model. Tačnost ove tehnike u velikoj meri zavisi od efikasnosti osnovnog algoritma za učenje koji se koristi za kreiranje modela.

2.3 Hibridni sistemi

Pored prethodno navedenih tehnika, postoje i hibridni sistemi koji predstavljaju kombinaciju dve ili više tehnika koje se koriste zajedno da bi se prevazišla ograničenja pojedinačnih sistema za preporučivanje.

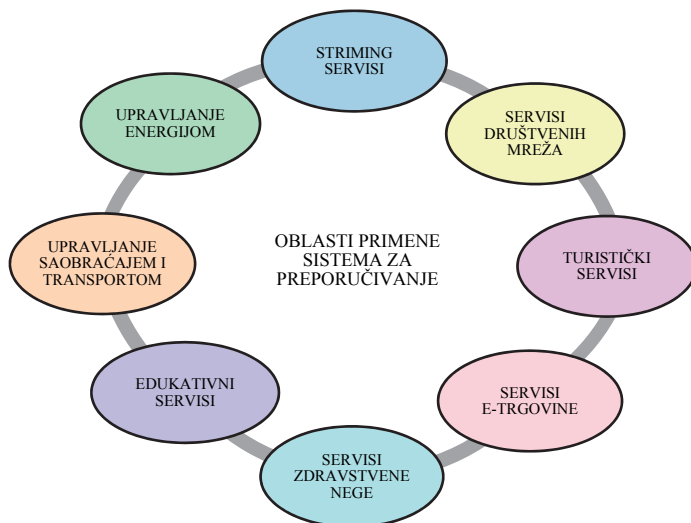
Pojedini tipovi sistema za preporučivanje usmereni su na rešavanje specifičnih problema korišćenjem sledećih metoda:

- metode preporučivanja koje razmatraju kontekst korisnika (npr. lokaciju, vreme, klimu, itd.) kako bi obogatile personalizovane preporuke,
- metode preporučivanja zasnovane na društvenim mrežama, koje analiziraju društvene mreže korisnika i njihove veze kako bi predložile preporuke koje preferiraju prijatelji ili drugi pouzdani korisnici,
- metode preporučivanja zasnovane na znanju, koje poseduju funkcionalnu bazu znanja sa specifikacijama kako određeni predmet interesovanja zadovoljava potrebe određenog korisnika i
- metode preporučivanja zasnovane na demografskim podacima, koje se oslanjaju na demografske podatke kao pokazatelje veza među korisnicima.

U cilju izbegavanja specifičnih ograničenja ili nedostataka pojedinačnih pristupa, hibridni sistemi za preporučivanje kombinuju dve ili više metoda različitih tipova. Uključivanje različitih tehnika može se izvesti na više načina. Hibridni algoritam može inkorporirati rezultate postignute odvojenim tehnikama, može koristiti filtriranje zasnovano na sadržaju u kolaborativnoj metodi ili koristiti tehniku kolaborativnog filtriranja u metodi zasnovanoj na sadržaju. Ova hibridna inkorporacija različitih tehnika obično utiče na poboljšanje performansi i povećanu tačnosti u mnogim aplikacijama za preporuke. Neki od pristupa hibridizaciji su meta-nivo, augmentacija karakteristika, kombinacija karakteristika, mešovita hibridizacija, kaskadna hibridizacija, promena hibridizacije i ponderisana hibridizacija.

3. Oblasti primene sistema za preporučivanje u pametnim gradovima

Pametni gradovi osim što nastoje da prevaziđu tradicionalne izazove urbanizacije, teže da u potpunosti iskoriste nove tehnologije kako bi unapredili kvalitet života svojih stanovnika [1]. Funkcionisanje pametnog grada treba da bude prilagođeno specifičnim ciljevima i funkcijama i u tom kontekstu je značajna primena sistema za preporučivanje [6]. Aplikacije u pametnom gradu funkcionišu kroz digitalnu infrastrukturu koja može povezati različite sisteme i uređaje, pružajući širok spektar servisa, prikazanih na slici 4.



Slika 4. Najrasprostranjenije oblasti primene sistema za preporučivanje u pametnim gradovima

U procesu implementacije novih tehnologija u pametnim gradovima, značajan uticaj imaju mobilne aplikacije, pri čemu se posebno ističu one povezane sa saobraćajem i transportom. Aplikacije koje se koriste širom sveta, poput *Uber-a*, *Lyft-a* ili *Citymapper-a*, omogućavaju korisnicima da pronađu putanje javnog prevoza, rezervišu zajedničke vožnje, iznajme bicikle ili električne skutere. Generalno, ove platforme obično koriste tehnologije kao što su Internet stvari (*Internet of things*, IoT), *Big data* analiza, veštačka inteligenciju i senzori za prikupljanje, obradu i analizu podataka u realnom vremenu koji se odnose na različite aspekte grada. Na ovaj način teži se redukovanju saobraćajnih gužvi i promovise se održiva mobilnost u gradovima. Postoje sistemi koji preporučuju da li bi određeno vozilo trebalo da promeni putanju ili ne, sa ciljem da se minimizira mogućnost gužve u celoj urbanoj oblasti. Takođe, razvijeni su sistemi za preporučivanje koji analiziraju podatke o toku saobraćaja, usmeravajući korisnike ka željenoj lokaciji i pomažući u upravljanju resursima kao što su vreme ili gorivo. Određeni sistemi za preporučivanje nude preporuke za parkirna mesta. Još jedna inteligentna primena upravljanja saobraćajem kroz ove sisteme odnosi se na bezbednost u vožnji, gde sistem upozorava vozače i preporučuje odgovarajuće brzine za vozila koja se približavaju

opasnim ili rizičnim situacijama i zonama, kao što su one sa slabom vidljivošću ili nepovoljnim vremenskim uslovima [6].

U pogledu upravljanja energijom, razvijene su aplikacije koje pomažu građanima da kontrolišu i optimizuju potrošnju energije u kućnom i poslovnom okruženju. Ove aplikacije omogućavaju praćenje podataka u realnom vremenu i nude sugestije za redukovanje potrošnje energije, što pospešuje energetska održivost i ekonomske uštede.

Striming servisa povezan sa medijskim sadržajem razvijen je zajedno sa sistemom za preporučivanje, jer je neophodno pomoći korisnicima pri izboru iz ogromne količine sadržaja i pružiti sadržaj koji je prilagođen svakom korisniku. Podaci o korisničkim preferencijama se prikupljaju fokusirajući se na istoriju korišćenja medijskog sadržaja i nakon mapiranja korisničkih preferencija sa celokupnim sadržajem kojim raspolaže striming servis, preporuke se generišu u redosledu sadržaja koji najviše odgovara korisnikovim preferencijama. Za striming servise najčešće se koriste CBF modeli preporuka, koji uzimaju u obzir korisničke podatke i podatke o audio/video sadržaju, kao i hibridni modeli preporuka koji uzimaju u obzir podatke o ocenama drugih korisnika sličnih posmatranom korisniku.

Velika popularnost društvenih mreža doprinela je pojavi ogromnih količina podataka povezanih sa korisnicima. Putem objava na društvenim mrežama moguće je prikupiti informacije o sadržaju koje korisnici registruju, kao i o evaluaciji korisnika. Ovi podaci uključuju različite vrste povratnih informacija, kao što su sviđanja i komentari. Prikupljeni podaci se ne koriste samo za preporuke unutar društvenih mreža, već i u sistemima preporuka za druge aktivnosti. Drugim rečima, različiti podaci prikupljeni na ovaj način su usko povezani sa razvojem sistema za preporučivanje. S obzirom da su korisnici društvenih mreža povezani i sa korisnicima koji ne pripadaju njihovim kontaktima, podaci drugih korisnika koji su slični posmatranom korisniku takođe se mogu koristiti za analizu kako bi se generisale preporuke. Zbog toga je pogodno koristiti CF modele i hibridne modele za preporučivanje koji se zasnivaju na interakciji korisnika i generisanom multimedijalnom sadržaju na više različitih servisa društvenih mreža. Kroz pretraživanje teksta, analiziraju se podaci o korisničkim preferencijama, tekstualni komentari koji mogu da se odnose na emocije korisnika, podaci o ponašanju kao što su prethodna prijavljivanja korisnika i podaci o evaluaciji korisnika za različite sadržaje. Kao rezultat analize, slične stavke se grupišu kako bi se pružile odgovarajuće preporuke svakom pojedinačnom korisniku. Korisničke preferencije se takođe mogu analizirati korišćenjem geografske lokacije korisnika i celokupnog tekstualnog sadržaja sa društvenih mreža primenom tehnike pretraživanja teksta [6].

Zahvaljujući tome što društvene mreže čuvaju podatke o prijavljivanjima korisnika i lokaciji objava koje je korisnik postavio, turistički servisi mogu ih koristiti kao skup podataka za preporučivanje turističkih atrakcija i putanja. Sistem za preporučivanje može da analizira podatke sa društvenih mreža i pruži odgovarajuće informacije o putovanju prilagođene interesovanjima svakog korisnika. Primer turističkog servisa zasnovanog na sistemu preporuka je PTIS (*Personalized Tourism Information Service*). Ovaj servis koristi hibridni model za preporučivanje turističkih destinacija prilagođenih korisnicima na osnovu analize podataka o prijavljivanju *Facebook* kontakata posmatranog korisnika. Model kontinuirano ažurira profil korisnika koristeći podatke koji mogu identifikovati preferencije generisane tokom korišćenja servisa, kao što su istorija prijavljivanja i podaci o evaluaciji. Sa povećanjem broja

korisnika PTIS-a moguće je poboljšati performanse i preciznost sistema za preporučivanje kroz masivne i raznovrsne podatke. Pored toga, može se izvršiti prostorno grupisanje na osnovu podataka o lokaciji objava postavljenih na društvenim mrežama, kako bi se identifikovale važne turističke destinacije. Zatim se vrši rangiranje prikupljenih podataka i korisnicima se preporučuju putanje uzimajući u obzir popularnost turističkih destinacija i podatke o dužini puta kroz mašinsko učenje. Situacione podatke kao što su vreme, lokacija i vremenski podaci iz turističkih destinacija moguće je izdvojiti korišćenjem tehnike pretraživanje teksta i izvršiti analizu delova teksta i semantičko grupisanje podataka o recenzijama kako bi se utvrdile korisničke preferencije.

Servisi e-trgovine prikupljaju podatke vezane za različite korisnike radi poslovne ekspanzije i aktivno koriste te podatke za sisteme preporuka. Predikcija korisničkih preferencija vrši se analizom pomoćnih informacija o korisnicima (npr. pol i starosna grupa), kao i na osnovu interakcija korisnika sa pretraživačima i aplikacijama (aktivnosti kursora). Preporučivanje artikala vrši se najčešće na osnovu predikcije korisničkih preferencija ali mogu se koristiti i informacije o interesovanjima drugih korisnika sa sličnim preferencijama. Sa aspekta sistema za preporučivanje, najznačajnija karakteristika servisa e-trgovine je da potrošači obično pokazuju obrazac potrošnje koji dopunjuje predmete koje su prethodno preferirali ili su već kupili. Iz tog razloga, za servise e-trgovine uglavnom se koriste model preporuka zasnovan na CF-u i hibridni model.

Sistemi za preporučivanje primenjeni na servise zdravstvene zaštite u pametnim gradovima imaju zadatak da kroz analizu informacija o pacijentu i karakteristikama bolesti, sprovedu dijagnostiku i preporučuju odgovarajući tretman. U tu svrhu se često koriste CBF modeli. Vodeći se idejom da se promovisanjem zdravijih navika ljudi mogu smanjiti troškovi zdravstvenog sistema u pametnom gradu, pozitivni efekti se očekuju od primene sistema sa preporukama putanja za fizičke aktivnosti koje najviše odgovaraju mogućnostima korisnika. Takođe, postoje sistemi koji utiču na poboljšanje životnih uslova predviđanjem najverovatnijih bolesti kod korisnika i preporukom koje mere treba preduzeti i koje postojeće nosive tehnologije mogu pomoći u njihovom praćenju. Osim toga, razvijene su softverske platforme bazirane na sistemima preporuka radi predloga personalizovanih dijeta za pacijente sa određenim indikacijama.

Značaj primene sistema za preporučivanje u oblasti edukativnih servisa ogleda se u obezbeđivanju obrazovnih resursa u skladu sa stilom učenja i nivoom znanja učenika, čime se kreiraju personalizovani obrazovni sadržaji. Drugi aspekt primene sistema za preporučivanje u ovoj oblasti je pružanje akademskih informacija koje su pogodne za različite korisnike, uključujući naučne zajednice, istraživačke institucije i praksu. Tipičan primer edukativnog servisa sa primenom sistema za preporučivanje je digitalna biblioteka, koja korisnicima omogućava brzo i jednostavno pretraživanje i korišćenje različitih digitalnih materijala širom sveta. Za edukativne servise pretežno se koristi CBF model preporuka zasnovan na analizi informacija o profilu učenika i obrazovnim objektima. Veoma dobre rezultate pokazala je kombinacija CBF modela preporuka sa tehnologijom neuronskih mreža. Takođe se preporučuje primena hibridnog sistema za preporuke predavanja studentima. Ovaj sistem se zasniva na kombinaciji CF modela koji obuhvata informacije o studentima, uključujući njihove ocene i rezultate za kurseve koje su pohađali i CBF model koji uzima u obzir informacije o predavanjima, uključujući profesore i sadržaj predavanja.

4. Procena efikasnosti i izazovi implementacije sistema za preporučivanje

Postoje različiti indikatori koji se mogu koristiti za procenu efikasnosti i performansi sistema za preporučivanje, odnosno kvantifikovanje tačnosti, relevantnosti i korisnosti preporuka koje pruža sistem. Najčešće se koriste sledeći indikatori [3]:

- Prikupljanje podataka. Ovaj indikator procenjuje da li je moguće prikupiti potrebne informacije za generisanje preporuka. To uključuje ispitivanje dostupnih izvora podataka, kao što su dnevne evidencije transakcija i korisničke preferencije.
- Algoritmi i modeli. Važno je razmotriti da li algoritmi mogu obraditi velike količine podataka i generisati tačne preporuke za korisnike.
- Tehnološka infrastruktura. Ovaj indikator procenjuje da li je potrebna tehnološka infrastruktura dostupna za implementaciju i pokretanje sistema za preporučivanje. To može uključivati servere, baze podataka i računarske resurse, kao što su konektivnost, merenje kvaliteta i raspoloživosti komunikacionih mreža, kao što su pristup širokopojasnom Internetu i pokrivenost mobilnom mrežom.
- Podaci o platformama. Ovaj indikator procenjuje mogućnosti tehnoloških platformi koje su zadužene za skladištenje, obradu i analizu velikih količina podataka u pametnom gradu, kao i sposobnost deljenja podataka sa različitim relevantnim zainteresovanim stranama.
- Troškovi. Neophodan je indikator troškova povezanih sa razvojem, implementacijom i održavanjem sistema za preporučivanje. To može uključivati troškove nabavke ili razvoja softvera, kao i troškove skladištenja i obrade podataka.
- Prednosti za poslovanje. Ovaj indikator procenjuje potencijalnu poslovnu vrednost koja se očekuje od primene sistema za preporučivanje. Razmatraju se efekti na prodaju, iskustvo korisnika i generisanje dodatnih prihoda putem personalizovanih preporuka.
- Evaluacija performansi. Testiranje i evaluacija u realnom vremenu sprovodi se kako bi se procenila tačnost i efikasnost sistema za preporučivanje. To može uključivati poređenje generisanih preporuka sa realnim preferencijama i ponašanjem korisnika.

Najveći i najčešći izazov sa kojim se suočavaju sistemi za preporučivanje je problem „hladnog starta”. Pod time se podrazumeva situacija u kojoj sistem za preporučivanje ne može da izvede zaključke iz postojećih podataka, najčešće zbog toga što ih nema dovoljno i ne može da pruži efikasne preporuke za nove korisnike koji nisu ocenili nijedan ili su ocenili vrlo malo stavki. Ovaj problem se obično javlja kada novi korisnik uđe u sistem ili kada se u bazu podataka dodaju nove stavke. Neka od potencijalnih rešenja ovog problema su [4]:

- zatražiti od novih korisnika da eksplicitno navedu svoje preferencije za predmete od interesovanja,
- zatražiti od novog korisnika da oceni neke predmete od interesovanja na početku i
- prikupiti demografske informacije ili meta-podatke od korisnika i predložiti preporuke u skladu sa tim.

Pored ovog izazova, postoji niz ostalih koje je neophodno prevazići i rešiti na odgovarajući način, kako bi se sistemi za preporučivanje pozicionirali na tržištu kao adekvatno i pouzdano rešenje [5]. Ti izazovi su:

- Problem lažnih napada. Ovaj problem nastaje kada zlonamerni korisnik prikrije svoj identitet i uđe u sistem kako bi dao lažne ocene za pojedine stavke. Takva situacija se javlja kada zlonamerni korisnik želi da poveća ili smanji popularnost neke stavke. Lažni napadi značajno smanjuju pouzdanost sistema. Jedno rešenje ovog problema je brzo detektovanje napadača i uklanjanje lažnih ocena i lažnih korisničkih profila iz sistema.
- Problem sličnih preporuka. Ovaj problem se javlja kada slične ili povezane stavke imaju različite unose ili nazive, ili kada je isti predmet predstavljen sa dva ili više imena u sistemu. Mnogi sistemi za preporučivanje ne uspevaju da uoče ove razlike, čime se smanjuje tačnost preporuka. Ovaj problem se može ublažiti primenom metoda, kao što su demografsko filtriranje, singularna vrednosna dekompozicija i druge.
- Problem kašnjenja. Ovaj izazov specifičan je za pristupe kolaborativnog filtriranja i javlja se kada se u bazu podataka često ubacuju nove stavke. Karakteriše ga nemogućnost sistema da ponudi nove preporuke. To se dešava zato što nove stavke moraju biti pregledane pre nego što mogu biti preporučene u okruženju kolaborativnog filtriranja. Korišćenje filtriranja zasnovanog na sadržaju može rešiti ovaj problem, ali takođe može uvesti preveliku specijalizaciju i degradirati performanse sistema. Da bi se povećala efikasnost, proračuni se mogu obavljati u oflajn okruženju, a mogu se koristiti i tehnike zasnovane na klasterovanju.
- Problem retkosti. Retkost podataka je uobičajen problem u analizi velikog obima podataka, koji nastaje kada određene očekivane vrednosti nedostaju u skupu podataka. U slučaju sistema za preporučivanje, ova situacija se javlja kada aktivni korisnici ocene vrlo malo stavki. Time se smanjuje tačnost preporuka. Da bi se ovaj problem ublažio, mogu se koristiti različite tehnike kao što su demografsko filtriranje, singularna vrednosna dekompozicija i korišćenje kolaborativnih tehnika zasnovanih na modelu.
- Problem „sivih ovaca”. Ovaj izazov je specifičan za osnovne pristupe kolaborativnog filtriranja gde povratne informacije jednog korisnika ne odgovaraju nijednoj korisničkoj grupi. U ovoj situaciji, sistem ne uspeva da precizno predvidi relevantne predmete od interesovanja za tog korisnika. Ovaj problem se može rešiti korišćenjem pristupa zasnovanih na sadržaju, gde se predikcije vrše na osnovu korisničkog profila i karakteristika stavki.
- Problem skalabilnosti. Sistemi za preporučivanje, posebno oni koji koriste tehnike kolaborativnog filtriranja, zahtevaju velike količine podataka za obuku, što uzrokuje probleme sa skalabilnošću. Problem skalabilnosti nastaje kada se količina podataka korišćenih kao ulaz u sistem za preporučivanje brzo povećava. U eri *Big data*, sve više predmeta od interesovanja i korisnika se brzo dodaje u sistem, što čini ovaj problem sve učestalijim. Uobičajeni pristupi za rešavanje problema skalabilnosti su redukcija dimenzionalnosti i korišćenje tehnika zasnovanih na klasterovanju kako bi se pronašli korisnici u malim klasterima umesto u celoj bazi podataka.

5. Zaključak

Značaj sistema za preporučivanje u pametnim gradovima je višestruk. Filtriranjem i sortiranjem masivnih tokova podataka korisnicima se mogu ponuditi prilagođene preporuke. Na ovaj način se značajno ubrzava i olakšava pronalazak relevantnih informacija čime se omogućava efikasnije korišćenje gradskih servisa. Pored toga što primena sistema za preporučivanje poboljšava korisničko iskustvo, ona takođe podržava efikasno upravljanje gradskim resursima.

U ovom radu razmatrane su mogućnosti primene sistema za preporučivanje u različitim oblastima pametnog grada. Za najrazvijenije i najviše korišćene servise u pametnom gradu istaknute su prednosti primene pojedinih modela filtriranja. Takođe su obrazloženi indikatori efikasnosti sistema za preporučivanje i izazovi sa kojima se ovi sistemi suočavaju. Buduća istraživanja treba fokusirati na prevazilaženje pomenutih izazova.

Literatura

- [1] Y. Fang, Z. Shan, W. Wang, "Modeling and Key Technologies of a Data-Driven Smart City System", *IEEE Access*, vol. 9, pp. 91244-91258, 2021 doi: 10.1109/ACCESS.2021.3091716
- [2] B. Diène et al. "Data management techniques for Internet of Things", *Mechanical Systems and Signal Processing*, vol. 138, 2020, doi.org/10.1016/j.ymssp.2019.106564
- [3] G. Andrade-Ruiz et al. "Emerging Perspectives on the Application of Recommender Systems in Smart Cities", *Electronics*, 13(7), 2024. doi:10.3390/electronics13071249
- [4] L. Quijano-Sánchez et al. "Recommender systems for smart cities", *Information Systems*, vol. 92, Sep. 2020. doi.org/10.1016/j.is.2020.101545
- [5] D. Roy, M. Dutta, "A systematic review and research perspective on recommender systems", *Journal of Big Data*, 9(1), 2022. doi.org/10.1186/s40537-022-00592-5
- [6] H. Ko, S. Lee, Y. Park, A. Choi, "A survey of recommendation systems: recommendation models, techniques and application fields", *Electronics*, 11(1), pp. 141, 2022. doi.org/10.3390/electronics11010141

Abstract: *In the era of digitized information and a wide range of different services, the phenomenon of data overload has led to the development of recommendation systems, which are based on data analytics, artificial intelligence and personalization of users' experiences. Application of these systems represents progress in development of personalized approaches that improve efficiency of service provision, as well as user satisfaction and engagement. Within smart cities, recommendation systems, through the implementation of information filtering approaches, can be used to improve relationships between diverse stakeholders and assist in smart city decision-making tasks through various technology platforms.*

Keywords: *filtering, users, items, recommendations, services*

RECOMMENDATION SYSTEMS IN SMART CITIES

Vesna Radonjić Đogatović, Milica Danilović