

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

SEMINAR

**Personalizirani sustavi za
preporuke**

Iva Idžođić

Voditelj: *Marko Đurasević*

Zagreb, svibanj 2023.

SADRŽAJ

1. Uvod	1
2. Sustavi temeljeni na suradnji	3
2.1. Sustavi temeljeni na memoriji	4
2.1.1. Sustavi temeljeni na korisniku	4
2.1.2. Sustavi temeljeni na objektu	5
2.2. Sustavi temeljeni na modelu	6
2.2.1. Matrična faktorizacija	7
2.2.2. Faktorizacijski stroj	8
3. Sustavi temeljeni na sadržaju	9
4. Hibridni sustavi	11
5. Zaključak	12
6. Literatura	13
7. Sažetak	14

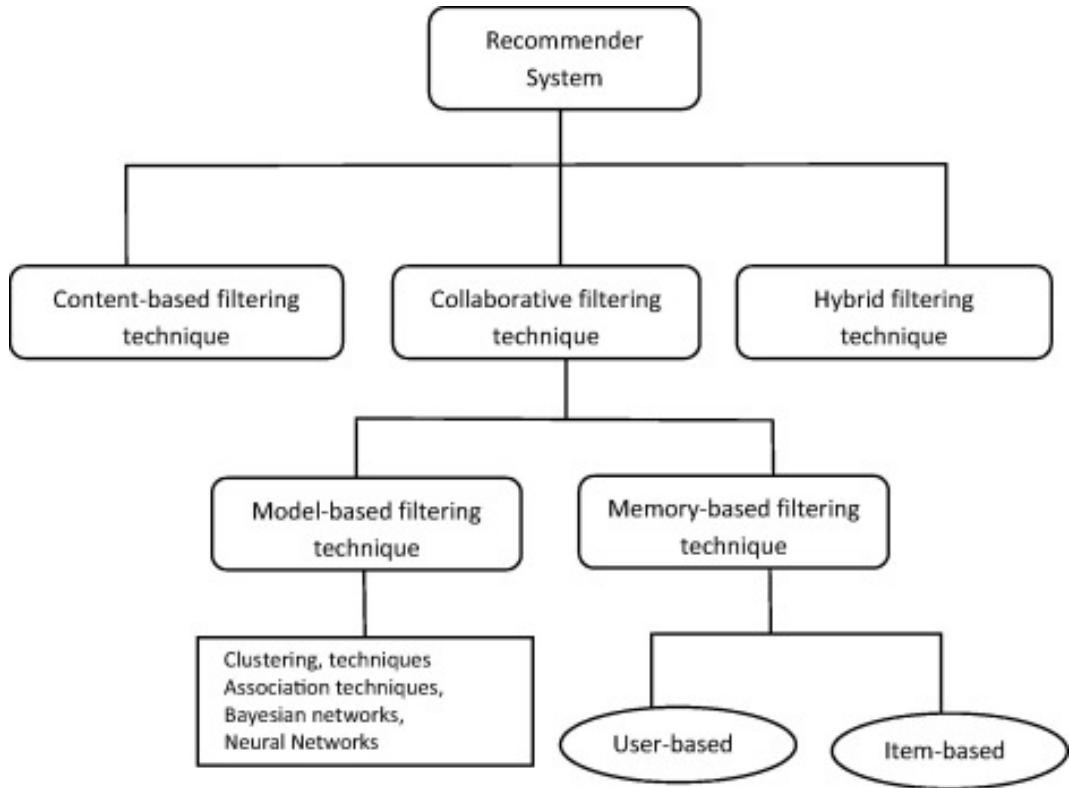
1. Uvod

U današnje vrijeme rijetko tko nije upoznat s platformama kao što su Youtube, Amazon, Netflix i Spotify. Znatan dio svjetske populacije koristi ih gotovo svakodnevno. S obzirom na izuzetno veliku količinu različitog sadržaja kojeg svaka od ovih platformi pruža, korisnicima nije moguće odmah prikazati sav dostupan sadržaj. Rješenje izazova što prikazati, odnosno preporučiti korisnicima jest u korištenju sustava za preporuke.

Neki od najjednostavnijih pristupa preporuke sadržaja su preporuka najnovijeg ili trenutno najpopularnijeg sadržaja među drugim korisnicima. Iako su i takvi, nepersonalizirani pristupi, često poželjni, personalizirani preporuke su ipak učinkovitije i rezultiraju većim zadovoljstvom korisnika. U ovom radu fokus će biti upravo na takvim sustavima.

Za razliku od nepersonaliziranih sustava koji svakom korisniku preporučaju isti sadržaj, personalizirani sustavi za preporuke u obzir uzimaju faktore kao što su pretходна интеракција корисника и садрžaja, сличност корисника и сличност објекта, односно садрžaja који се предлажа. Према томе на чему се темеље, personalizirani sustavi за preporuke могу се поделити у три главне скупине:

- Sustavi temeljeni na suradnji
- Sustavi temeljeni na memoriji
- Hibridni sustavi - kombinacija prethodnih sustava



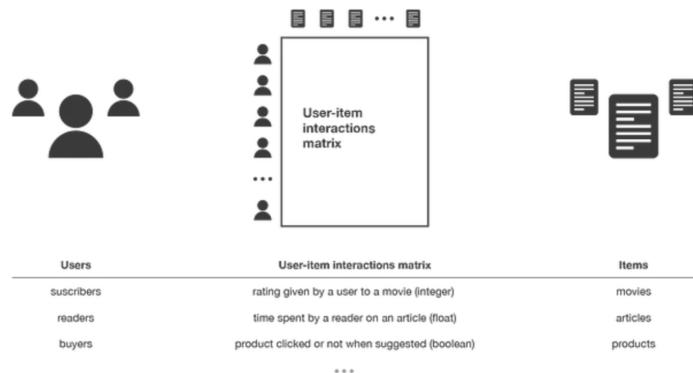
Slika 1.1: Podjela personaliziranih sustava za preporuke

(izvor: [4])

2. Sustavi temeljeni na suradnji

Sustavi temeljeni na suradnji trenutno su najpopularnija vrsta sustava za preporuku zahvaljujući činjenici da se na njima bazira i Netflix, vodeća svjetska platforma za gledanje filmova i serija. Takvi sustavi u obzir uzimaju isključivo dosadašnju interakciju korisnika i objekata, odnosno sadržaja, te nemaju nikakva dodatna saznanja ni o korisnicima, ni o objektima.

Interakcija korisnika i objekata pohranjena je u interakcijskoj matrici, odnosno matrici korisnik-objekt (Slika 2.1) gdje svaki red predstavlja jednog korisnika, a svaki stupac predstavlja objekt. Svaka ćelija matrice tada prikazuje interakciju između određene kombinacije korisnika i objekta, najčešće u obliku ocjene r_{ui} kojom je korisnik u ocijenio objekt i .

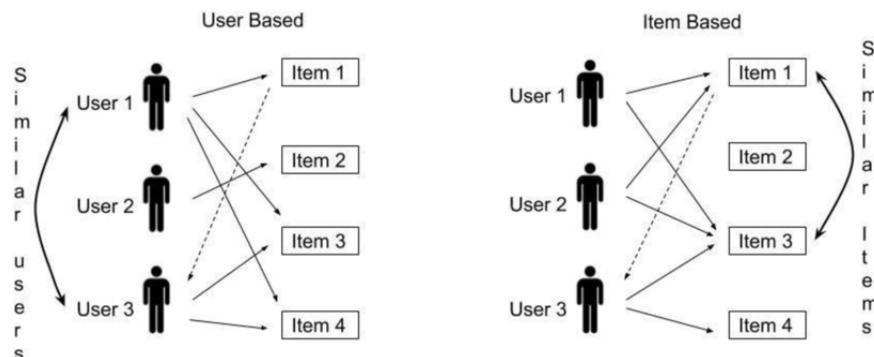


Slika 2.1: Prikaz interakcijske matrice korisnik-objekt
(izvor: [2])

Sustavi temeljeni na suradnji dijele se one temeljene na memoriji i na one temeljene na modelu. (Slika 1.1) Sustavi temeljeni na memoriji koriste sve dostupne podatke bez prethodne obrade, dok se kod sustava temeljenih na modelu prvo stvara model, te se zatim sve preporuke temelje na tom modelu.

2.1. Sustavi temeljeni na memoriji

Sustavi temeljeni na memoriji pohranjuju sve interakcije između korisnika i objekata te temeljem toga stvaraju preporuke. Dijele se na one koji u obzir uzimaju međusobnu sličnost korisnika i na one koji u obzir uzimaju međusobnu sličnost objekata, odnosno sadržaja. (Slika 2.2)



Slika 2.2: Prikaz sustava temeljenih na memoriji

(izvor: <https://www.researchgate.net/>)

Glavna prednost sustava temeljenih na memoriji jest to da ih je jednostavno implementirati. Također, manje su osjetljivi na promjene u podacima od sustava temeljenih na modelima, dodavanje novog korisnika ili objekta neće negativno utjecati na krajnji rezultat. Najčešće imaju brzu izvedbu jer ne moraju provoditi složene izračune ili učenje nad velikom količinom podataka.

Jedan od osnovnih problema sustava temeljenih na memoriji jest problem *hladnog starta*. Do tog problema dolazi kada se radi o novom korisniku ili novom objektu pa sustav nema pristup prijašnjim interakcijama koje su nužne za preporuke ovakvih sustava.

2.1.1. Sustavi temeljeni na korisniku

Sustavi temeljeni na korisniku baziraju se na sličnosti korisnika. Aktivnom korisniku preporučuju se oni objekti koje su najbolje ocijenili korisnici slični njemu. Pretpostavka takvih sustava jest da ako dva korisnika, korisnik A i korisnik B, inače preferiraju slične stvari, odnosno imaju sličan ukus, tada ima smisla korisniku A predložiti nešto što se svidjelo korisniku B, i obrnuto.

Za početak, potrebno je kvantificirati sličnost korisnika, odnosno pronaći korisnike najsličnije aktivnom korisniku. Međusobna sličnost korisnika može se računati korištenjem Pearsonove korelacijske matrice:

$$w_{uv} = \frac{\sum_{i \in I_u \cap I_v} (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)}{\sqrt{\sum_{i \in I_u} (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_{i \in I_v} (r_{vi} - \bar{r}_v)^2}}$$

gdje je $I_u = \{i \in I \mid r_{ui} \in R\}$ skup objekata s kojima je korisnik u imao interakciju, odnosno ocijenio ih je.

Brojnik predstavlja sumu odstupanja ocjena jednog korisnika od ocjena drugog korisnika, a nazivnik sumama pojedinačnih odstupanja normalizira sličnost kako bi bila u rasponu [-1,1].

Zatim se odabirom N objekata najsličnijih objektu i stvara susjedstvo $N(i)$ koje će se uzimati u obzir kod predviđanja kako bi samo najsličniji objekti imali utjecaj na rezultat.

Predviđanje se tada računa kao:

$$s(u, i) = \bar{r}_u + \frac{\sum_{v \in N(u)} w_{uv} (r_{vi} - \bar{r}_v)}{\sum_{v \in N(u)} |w_{uv}|}$$

Ovom formulom predviđanje ocjene $s(u, i)$ koju bi korisnik u dao objektu i računa se kao težinski prosjek ocjena njemu najsličnijih korisnika.

Neki od problema ovakvih sustava su rijetkost interakcija te složenost računalne izvedbe. S obzirom na to da među podacima najčešće ima znatno više korisnika nego objekata, te je često slučaj da ne postoji velik broj zabilježenih interakcija, nije rijetkost da dva korisnika nisu ocijenili ni jedan zajednički objekt pa nije moguće izračunati njihovu sličnost. Do problema s računalnom izvedbom dolazi zbog skupoće računanja sličnosti među svim parovima čija je složenost jednakva kvadriranom broju korisnika. Problem je i to što dodavanje novih interakcija mijenja postojeće sličnosti pa se one moraju ponovno računati.

2.1.2. Sustavi temeljeni na objektu

Sustavi temeljeni na objektu funkcioniраju slično kao i sustavi temeljeni na korisniku, osim što je umjesto sličnosti korisnika, u fokusu sličnost objekata. Prepostavka ovih sustava jest da korisnik preferira objekte slične onima koje je dosad preferirao. S obzirom na to da se radi o sustavima temeljenim na suradnji, i nisu dostupne eksplisitne informacije o pojedinim objektima, njihova sličnost određuje se isključivo pomoću poznate interakcijske matrice:

$$w_{ij} = \frac{\sum_{u \in U_i \cap U_j} (r_{ui} - \bar{r}_i)(r_{uj} - \bar{r}_j)}{\sqrt{\sum_{u \in U_i} (r_{ui} - \bar{r}_i)^2} \sqrt{\sum_{u \in U_j} (r_{uj} - \bar{r}_j)^2}}$$

gdje je $U_i = \{u \in U \mid r_{ui} \in R\}$ podskup korisnika koji su imali interakciju s objektom i , odnosno ocijenili su ga.

Predviđanje se računa kao:

$$s(u, i) = \bar{r}_i + \frac{\sum_{j \in N(i)} w_{ij} (r_{uj} - \bar{r}_j)}{\sum_{j \in N(i)} |w_{ij}|}$$

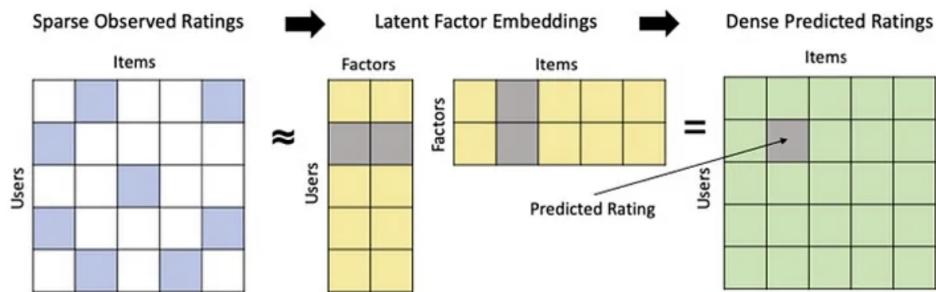
Prednost ovakvih sustava nad sustavima temeljenim na korisniku jest to što je sličnost objekata stabilnija vrijednost od sličnosti korisnika. Razlog tomu je što je najčešće dostupan znatno veći broj korisnika od broja objekata. U tom slučaju pojedini objekt ima više interakcija od pojedinog korisnika. Također, dodavanjem novih interakcija, ne mijenja se sličnost objekata što nije nužno slučaj kod sličnosti korisnika.

Jedan od nedostataka sustava temeljenih na objektu jest to što su korisniku uvijek preporučeni isključivo objekti najsličniji onima koje je ocijenio. Na taj način korisnik teže dolazi do pristupa drugaćijim objektima koji bi mu se potencijalno mogli svidjeti.

2.2. Sustavi temeljeni na modelu

Ideja ovakvih sustava je pronaći objašnjenje korisničkih preferencija. Za razliku od interakcijeske matrice, koja je vrlo specifična za svaku interakciju, prepostavka je da se korisnikov ukus može objasniti jednostavnije, na primjer, korisnik voli horore i filmove Stevena Spielberga.

Za razliku od sustava temeljenih na memoriji, sustavi temeljeni na modelu mogu se nositi s problemom *hladnog starta* jer ne ovise o prethodnim interakcijama, već o modelu. Također, prilagodljiviji su te ih je moguće koristiti i za kompleksnije podatke. Glavna mana takvih sustava jest kompleksnost implementacije.

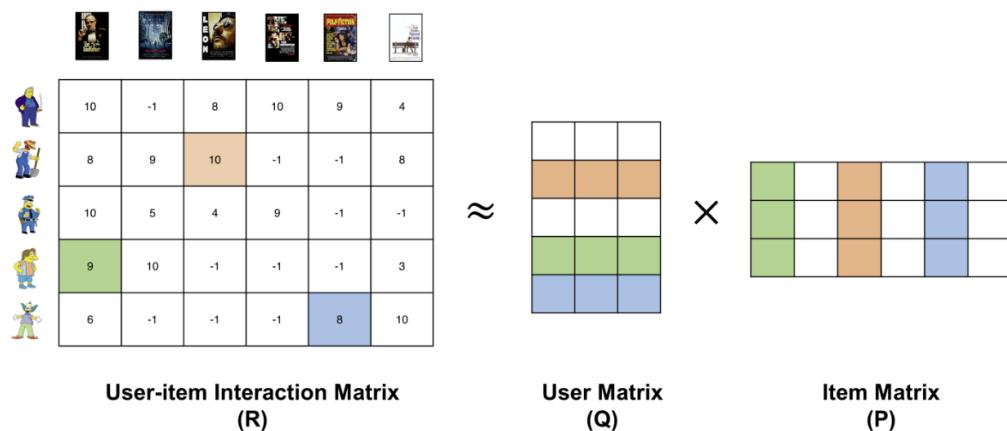


Slika 2.3: Rijetka interakcijska matrica nije problem kod sustava temeljenih na modelu (izvor: [4])

2.2.1. Matrična faktorizacija

Jedna od vodećih metoda sustava temeljenih na modelu jest matrična faktorizacija.

Matrična faktorizacija temelji se na dekompoziciji matrice interakcija u dvije jednostavnije matrice, jednu koja opisuje korisnika, i jednu koja opisuje objekt. Svaka od tih matrica predstavlja latentne značajke korisnika ili objekta. (Slika 2.4)



Slika 2.4: Matrična faktorizacija

(izvor: [4])

Predviđanje se tada računakao produkt tih dvaju latentnih matrica. (Slika 2.3)

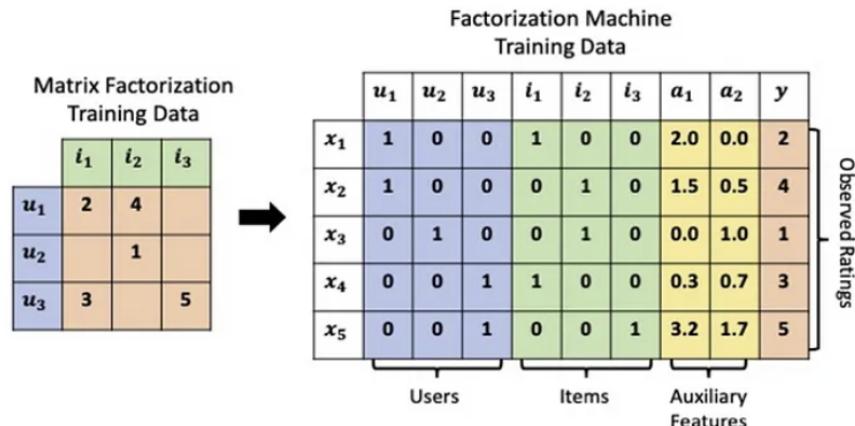
Neke od metoda korištenih za matričnu faktorizaciju su singularna dekompozicija vrijednosti (SVD) i probabilistička matrična faktorizacija (PMF). SVD pristupom po-

četna matrica faktorizira se u tri matrice čijim produktom se dobiva njena aproksimacija, a PMF pronalazi latentne načine na probabilistički način.

2.2.2. Faktorizacijski stroj

Nedostatak matrične faktorizacije u sustavima za preporuku je taj što se ne mogu koristiti sporedne informacije. Na primjer, kod preporuke filmova, nije moguće u obzir uzeti žanr i jezik filma, već se isključivo sve temelji na korisniku i objektu čije su sve informacije združene. Korištenje faktorizacijskog stroja rješava taj problem.

Faktorizacijski stroj je nadogradnja metode matrične faktorizacije koja osim podataka o korisnicima i objektima, koristi i ostale atribute koji značajno pridonose predviđanjima. (Slika 2.5) Osim toga, za razliku od matrične faktorizacije, nema problem *hladnog starta*. Kod predviđanja za novog korisnika ili novi objekt, faktorizacijski stroj može koristiti sporedne informacije kao što su značajke objekta (žanr, jezik, glumci) kako bi dao preporuke, čak i bez ikakvih podataka o interakciji korisnika i predmeta.



Slika 2.5: Faktorizacijski stroj

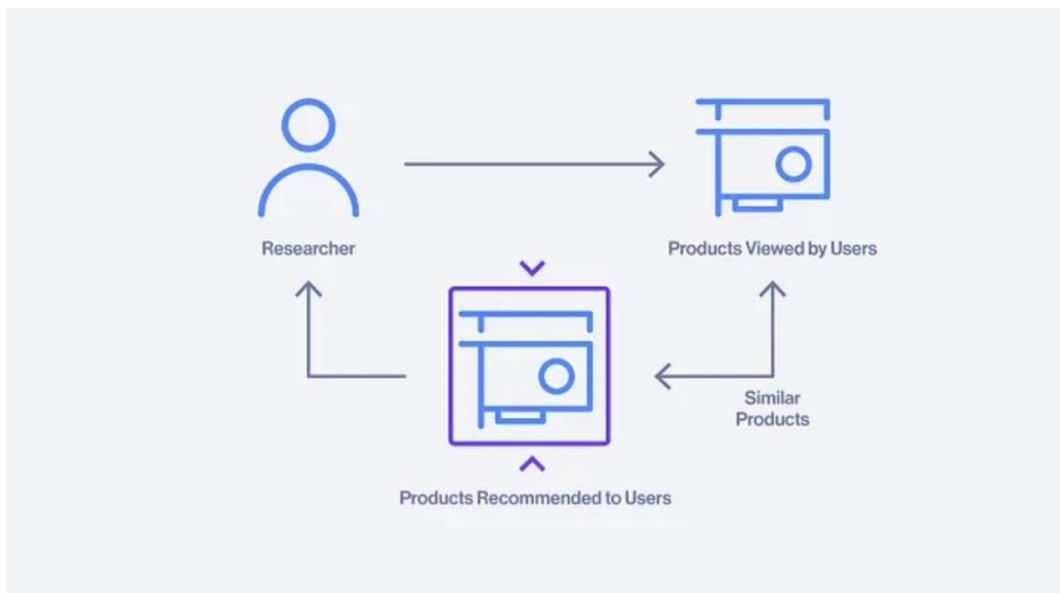
(izvor: [1])

3. Sustavi temeljeni na sadržaju

Kod sustava temeljenih na sadržaju, korisniku se preporučuju objekti najsličniji onima koji su mu se svidjeli ranije, ali sličnost se u ovom slučaju određuje pomoću sadržaja objekata. (Slika 3.1) Cilj je pronaći najveću sličnost između sadržaja objekta i profila korisnika, koji predstavlja korisnikove preference temeljene na prijašnjim povratnim informacijama.

Kako bi se sadržaj svakog objekta mogao koristiti i uspoređivati, potrebno je svaki objekt prikazati u formi vektora. Dokument predstavlja svaki nestrukturirani sadržaj objekta.

Pretpostavka koja se uzima u obzir kod pretvaranja dokumenta u vektorski oblik jest da je semantički riječ o *vreći riječi*. To bi značilo da se redoslijed riječi u dokumentu ne uzima u obzir. Iako ta pretpostavka naizgled može značajno promijeniti određena značenja (npr. sintagme 'mouse is smaller than lion' i 'lion is smaller than mouse' su u tom slučaju istovjetne), generalno kontekst dokumenta ostaje isti.



Slika 3.1: Prikaz sustava temeljenog na sadržaju

(izvor: [3])

Tada se sličnost profila korisnika i svakog dokumenta koji predstavlja objekt računa pomoću kosinusne sličnosti. Na temelju dobivenih rezultata, najsličniji objekti preporučuju se korisniku. (Slika 3.2)



Slika 3.2: Prikaz sustava temeljenog na sadržaju

(izvor: [2])

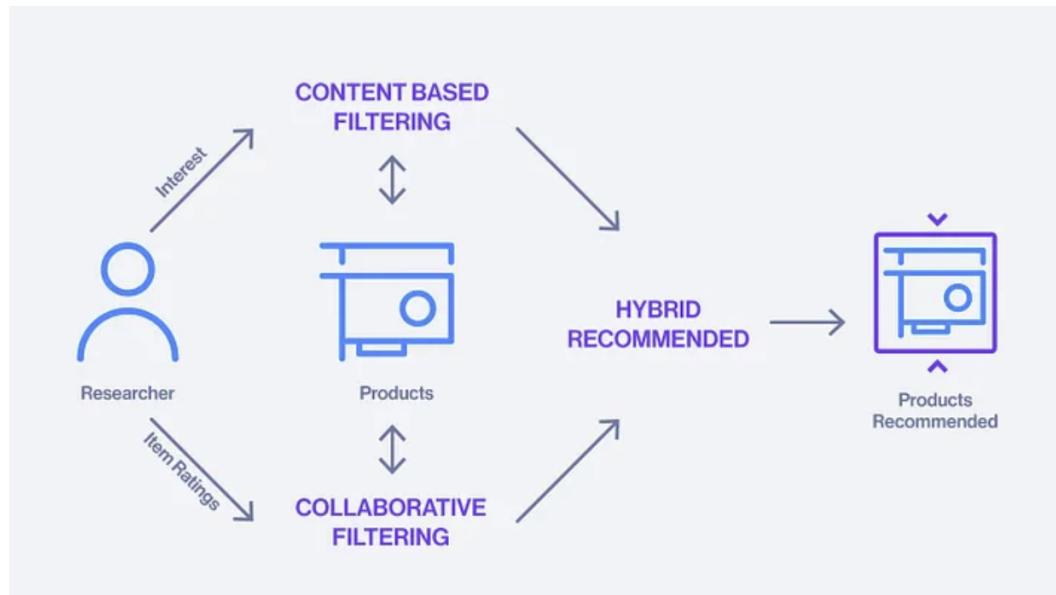
Ovakvi sustavi primjenjivi su kada je dostupno mnogo informacija o objektima te ne ovise o postojanju ostalih korisnika i njihovim interakcijama. Mana sustava je to što ne preporučaju potpuno nove i različite objekte korisniku koje bi mu se potencijalno svidjele, već se zadržava među najsličnijim objektima.

4. Hibridni sustavi

Hibridni sustavi kombiniraju više različitih sustava preporuke, na primjer, sustav temeljen na suradnji i faktorizacijski stroj, sustav temeljen na suradnji i sustav temeljen na sadržaju, kod odabira kombinacije potrebno je u obzir uzeti dostupne podatke, resurse te prednosti i mane pojedinih sustava.

Najčešći princip rada hibridnih sustava je da pojedini odabrani sustav radi neovisno o drugom te generira svoje preporuke. Zatim se dobiveni popisi međusobno kombiniraju i prikazuju korisniku. (Slika 4.1)

Kombiniranje se može izvršiti na različite načine, od kojih su neki računanje težinskog prosjeka, kombiniranje najboljih k preporuka iz svakog algoritma, primjena ograničenja ili pravila.



Slika 4.1: Prikaz hibridnog sustava

(izvor: [3])

5. Zaključak

Personalizirani sustavi za preporuke omogućavaju korisnicima brži i jednostavniji pristup sadržaju prilagođenom njihovim navikama i preferencijama. Na taj način korisnicima štede vrijeme, povećavaju vjerojatnost pronađenja željenog sadržaja te sveukupno poboljšavaju iskustvo korištenja usluge. Tako se stvara i određena odanost koristika prema platformi koja koristi sustave za preporuke. Iz tog razloga sustavi za preporuke danas postaju sve korišteniji. S obzirom na postojanje različitih vrsta sustava za preporuke, te činjenici da ih je moguće prilagoditi trenutnim potrebama i resursima, njihova upotreba je raznovrsna. Osim u platformama korištenih za uživanje u zabavnom sadržaju, imaju sve bitniju ulogu u industrijama kao što su turizam, edukacija, medicina i mnoge druge.

Razvoj sustava za preporuke omogućava potpuno nove pristupe rješavanju nekih problema. Također, znatno pojednostavnjuju pojedine procese. No, osim brojnih prednosti personaliziranih sustava za preporuke, potrebno je na umu imati i potencijalne izazove koje sa sobom nose. Neki od njih su pitanje privatnosti i potencijalna pristranost preporuka koja može biti i zloupotrijebljena. Personalizirani sustavi za preporuke su moći i korisni alati čiji je rad ipak potrebno nadzirati.

6. Literatura

- [1] What are recommendation systems? <https://towardsdatascience.com/factorization-machines-for-item-recommendation-with-implicit-feedback>. Accessed: 2023-04-27.
- [2] Introduction to recommender systems. <https://towardsdatascience.com/introduction-to-recommender-systems-6c66cf15ada>. Accessed: 2023-04-25.
- [3] What are recommendation systems? <https://medium.com/@khang.pham.exxact/what-are-recommendation-systems-6bb5036042db>. Accessed: 2023-04-25.
- [4] F.O. Isinkaye, Y.O. Folajimi, i B.A. Ojokoh. Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, 16(3): 261–273, 2015. ISSN 1110-8665. doi: <https://doi.org/10.1016/j.eij.2015.06.005>. URL <https://www.sciencedirect.com/science/article/pii/S1110866515000341>.

7. Sažetak

Personalizirani sustavi za preporuke sve su prisutniji u mnogim industrijama s ciljem pružanja korisnicima jednostavnog i brzog pristupa sadržaju prilagođenom njihovim interesima. Postoji nekoliko vrsta personaliziranih sustava za preporuke, uključujući sustave temeljene na suradnji, sustave temeljene na sadržaju i hibridne sustave koji kombiniraju obje vrste. U radu su predstavljeni navedeni sustavi te je opisan način rada svakog od njih. Također su istaknute prednosti i mane svakog sustava koje je potrebno poznavati prije odabira prikladnog sustava. Ovaj rad služi kao uvod i temeljno upoznavanje s personaliziranim sustavima za preporuke.