

FAKULTET TEHNIČKIH NAUKA U ČAČKU

UNIVERZITET U KRAGUJEVCU



Predmet:

Veb majning

**Arhitektura i metodologije razvoja savremenih sistema za
preporuku: Pristup zasnovan na mašinskom učenju**

-seminarski rad-

Prof: Marija D. Blagojević

Student: Ognjen Tomić

Broj indeksa: 606/2023

Čačak, 2024. godina

Apstrakt

Ovaj rad istražuje arhitekturu i metodologije razvoja savremenih sistema za preporuku s posebnim fokusom na pristup zasnovan na mašinskom učenju. Proučava se napredak u oblasti tehnologije i uloga mašinskog učenja u unapređenju sistema za personalizovane preporuke. Rad takođe analizira značaj personalizacije i poboljšanja korisničkog iskustva kroz efikasne algoritme preporuka. Pored toga, istražuju se izazovi u sakupljanju podataka, uključujući problem hladnog početka i etičke aspekte. Poseban naglasak stavlja se na filter kolaborativnog filtriranja i filter zasnovan na sadržaju, proučavajući prednosti, nedostatke i hibridne pristupe koji kombinuju ove tehnike. Rad naglašava važnost praćenja performansi sistema i iterativnog unapređenja kako bi se održala kvaliteta preporuka tokom vremena. Zaključuje se da je sveobuhvatan pristup, prilagodljivost sistema i balansiranje između različitih tehnika ključno za razvoj efikasnih sistema za preporuku koji zadovoljavaju rastuće potrebe korisnika

Ključne reči: *mašinsko učenje, razvoj savremenih sistema, sakupljanje podataka, analiza podataka*

Sadržaj

1. Uvod.....	4
1.1 Definicija sistem za preporuku	4
1.2 Značaj personalizovanih preporuka	4
1.3 Pregled pristupa razvoju.....	5
2. Sakupljanje i analiza podataka.....	6
2.1. Važnost relevantnih podataka.....	6
2.2. Tipovi podataka za treniranje modela	7
2.3. Etički aspekti sakupljanja podataka	8
3. Podela podataka i evaluacija performansi.....	9
3.1. Razdvajanje na skup za obuku i skup za testiranje	9
3.2. Metrike za evaluaciju sistema	10
3.3. Praćenje i poboljšanje performansi	11
4. Algoritmi mašinskog učenja u sistemima za preporuku	12
4.1. Filter kolaborativnog filtriranja.....	12
4.2. Filter zasnovan na sadržaju	13
4.3. Hibridni pristupi.....	13
5. Zaključak.....	15
6. Literatura.....	16

1. Uvod

1.1 Definicija sistem za preporuku

Sistem za preporuku predstavlja sofisticirani informacijski sistem čiji je osnovni cilj personalizovano predlaganje entiteta, poput proizvoda, usluga ili sadržaja, korisnicima na osnovu njihovih individualnih preferencija, istorije ponašanja i demografskih karakteristika. Ovaj sistem se oslanja na kompleksne algoritme mašinskog učenja kako bi analizirao i interpretirao velike skupove podataka, identifikujući skrivene obrasce i veze između korisničkih akcija¹. U svojoj suštini, sistem za preporuku funkcioniše kao inteligentan posrednik između korisnika i raznolikih entiteta, pružajući personalizovane preporuke koje unapređuju korisničko iskustvo i potiču angažovanje. Ključni elementi sistema uključuju prikupljanje i analizu podataka, primenu algoritama za predviđanje preferencija, kao i kontinuirano ažuriranje modela kako bi se prilagodio evoluirajućim korisničkim potrebama. Sistem za preporuku postaje neizostavan instrument u savremenom digitalnom okruženju, pružajući personalizovane i relevantne preporuke koje korisnicima olakšavaju odlučivanje u obilju dostupnih opcija.

1.2 Značaj personalizovanih preporuka

Značaj personalizovanih preporuka u savremenom digitalnom okruženju je od suštinskog značaja, pružajući niz koristi kako korisnicima, tako i pružaocima usluga ili proizvoda. Personalizovane preporuke prilagođavaju se individualnim preferencijama i potrebama korisnika, što rezultira unapređenim korisničkim iskustvom. Korisnici doživljavaju platformu ili uslugu kao prilagođenu, što povećava njihovo zadovoljstvo i vernost. U digitalnom dobu, gde su opcije često preplavljajuće, personalizovane preporuke pomažu korisnicima da brže donose informisane odluke. Smanjuje se vreme potrebno za pretraživanje i filtriranje informacija, a korisnici su izloženi relevantnim sadržajima. Kroz pružanje preporuka koje su direktno relevantne za korisnika, povećava se nivo angažovanja. Korisnici su skloniji interakciji s platformom ili uslugom koja demonstrira razumevanje njihovih potreba.² U oblasti digitalnog marketinga, personalizovane preporuke omogućavaju ciljanje specifičnih grupa korisnika. Ovo povećava efikasnost oglašavanja, jer se reklame prikazuju onima koji su najverovatnije zainteresovani. Korisnici su skloniji ostanku na platformi ili korišćenju određene usluge ako ih sistem redovno iznenađuje relevantnim preporukama. Ovo doprinosi dugoročnoj lojalnosti korisnika. Sistem za preporuke

¹ Shristi Khanal et al., 2020

² Akhil Ganesh et al., 2022

može pratiti promene u korisničkim preferencijama tokom vremena, prilagođavajući preporuke kako bi odražavao nove interese ili potrebe korisnika. U sektorima online-trgovine, personalizovane preporuke mogu direktno doprineti povećanju prodaje putem sugestija proizvoda koji su visoko relevantni za korisnika. Pružaocima usluga omogućava preciznije usmeravanje resursa, jer personalizovane preporuke omogućavaju fokusiranje na ono što je stvarno važno za svakog korisnika. U celini, personalizovane preporuke igraju ključnu ulogu u transformaciji digitalnog iskustva, čineći ga bogatijim, efikasnijim i prilagođenim individualnim potrebama korisnika.

1.3 Pregled pristupa razvoju

Pregled pristupa razvoju sistema za preporuku obuhvata različite metodologije i tehnike koje se koriste u konstrukciji ovih sistema. Razvoj sistema za preporuku je kompleksan proces koji zahteva pažljivu analizu podataka, implementaciju odgovarajućih algoritama mašinskog učenja i kontinuirano usklađivanje sa promenama u korisničkim preferencama.³

Filter kolaborativnog filtriranja- Ovaj pristup se zasniva na sličnosti između korisnika. Modeli predviđanja se konstruišu koristeći informacije o ponašanju sličnih korisnika kako bi se identifikovale preferencije ciljanog korisnika. Postoje dve osnovne vrste filtera kolaborativnog filtriranja - filter zasnovan na korisnicima i filter zasnovan na proizvodima. Filter zasnovan na sadržaju-Ovaj pristup analizira karakteristike proizvoda ili sadržaja kako bi se pravile preporuke. Sistem identifikuje sličnosti između proizvoda na osnovu njihovih karakteristika ili korisničkih preferencija, a zatim preporučuje proizvode koji su slični onima koje je korisnik već koristio ili ocenio pozitivno. Hibridni pristupi-Kombinuju filter kolaborativnog filtriranja i filter zasnovan na sadržaju kako bi iskoristili prednosti oba pristupa. Ovi hibridni modeli pružaju bolje performanse u situacijama gde jedan pristup sam po sebi može biti nedovoljan. Duboko učenje (deep learning)- Primena dubokih neuronskih mreža za razvoj sistema za preporuku postaje sve popularnija. Ovi modeli mogu efikasno učiti kompleksne obrasce iz velikih skupova podataka, pružajući visoko personalizovane preporuke. Vremenski zavisni modeli-Uključuju praćenje promena u korisničkim preferencijama tokom vremena. Ovi modeli uzimaju u obzir temporalne faktore kako bi prilagodili preporuke u skladu sa evolucijom korisničkih interesa. Geolokacioni aspekti- Integracija geolokacionih podataka može dodati dimenziju konteksta u preporuke. Sistemi uzimaju u obzir

³ Dhiraj Neupane et al., 2020

lokaciju korisnika i pružaju personalizovane sugestije na osnovu lokalnih preferencija ili dostupnih resursa.

Online učenje-Koristi se kontinuirano prikupljanje podataka i treniranje modela u stvarnom vremenu kako bi se sistema održao ažurnim i prilagodio dinamičnim promenama u korisničkim preferencijama. Pristup razvoju sistema za preporuku zavisi od specifičnosti aplikacije i prirode podataka. Kombinacija različitih pristupa može pružiti najefikasnije rezultate u stvaranju personalizovanih i relevantnih preporuka za korisnike.

2. Sakupljanje i analiza podataka

2.1. Važnost relevantnih podataka

U kontekstu razvoja sistema za preporuku, važnost relevantnih podataka se ne može preneglasiti, budući da su podaci osnovni građevinski blokovi koji omogućavaju modelima da pruže tačne i korisne preporuke korisnicima. Ključni aspekti koji naglašavaju važnost relevantnih podataka u ovom kontekstu uključuju: Kvalitet podataka direktno utiče na preciznost sistema za preporuku. Ako su podaci tačni, obimni i relevantni, modeli će biti u stanju bolje identifikovati obrasce i pružiti pouzdane preporuke korisnicima.⁴ Relevantni podaci omogućavaju sistemima za preporuku da stvore personalizovane preporuke koje odražavaju stvarne preferencije i interese korisnika. Što su podaci sveobuhvatniji, to je personalizacija efikasnija. Hladan početak (eng. "cold start") predstavlja izazov u sistemima za preporuku kada imaju ograničene informacije o novom korisniku ili proizvodu. Relevantni podaci pomažu u prevazilaženju ovog izazova, pružajući dovoljno informacija za pravilno razumevanje novih entiteta. Kvalitetni podaci pomažu u smanjenju uticaja šuma i nepreciznosti u modelima.⁵ Dobro obrađeni podaci obezbeđuju čistu osnovu za treniranje modela, čime se povećava otpornost sistema na neželjene efekte. Kada korisnici dobijaju preporuke, posebno u kontekstu filtera zasnovanih na sadržaju, važno je da preporuke budu razumljive. Relevantni podaci omogućavaju bolje oblikovanje modela koji pružaju jasne i smislene preporuke. Savremeni sistemi za preporuku suočavaju se s dinamičnim promenama u preferencijama korisnika i ponudi proizvoda ili usluga. Stalno ažurirani relevantni podaci omogućavaju sistemima da prate i odražavaju te promene u stvarnom vremenu. Algoritmi mašinskog učenja zavise od kvaliteta podataka za obuku. Relevantni podaci omogućavaju

⁴ Kiran R et al., 2020

⁵ Roshan Bhanuse et al., 2021

algoritmima da bolje generalizuju iz obrasca u podacima, što dovodi do poboljšane performanse u raznim scenarijima. Obrada i korišćenje relevantnih podataka u skladu sa etičkim smernicama pomaže u izgradnji poverenja korisnika u sistem. Transparentnost u korišćenju podataka dodatno podržava etički pristup razvoju sistema za preporuku.

Ukupno, važnost relevantnih podataka u razvoju sistema za preporuku proizilazi iz činjenice da ovi podaci služe kao osnova za stvaranje inteligentnih modela koji mogu adekvatno razumeti, predviđati i prilagoditi se individualnim korisničkim potrebama.

2.2. Tipovi podataka za treniranje modela

Pravilno odabrani i pažljivo pripremljeni podaci su ključni za efikasan rad sistema za preporuku. Raznolikost podataka pruža modelima dobar osnov za učenje i generalizaciju. Različite vrste podataka koriste se za treniranje modela, obezbeđujući širinu informacija i obuhvatnost. Neki od ključnih tipova podataka u treniranju modela sistema za preporuku obuhvataju: Informacije o aktivnostima korisnika, uključujući pretrage, pregledane proizvode, ocene, kupovine i druge interakcije. Ovi podaci o ponašanju korisnika pružaju uvid u njihove preferencije i interese. Demografski podaci uključuju informacije o korisnicima kao što su godine, pol, geografsko poreklo i druge socio-demografske karakteristike⁶. Ovi podaci dopunjuju razumevanje konteksta korisnika. Atributi proizvoda, sadržaja ili entiteta koji se preporučuju. Ovi podaci pomažu u filteru zasnovanom na sadržaju i mogu uključivati opise, kategorije, ključne reči, ili druge karakteristike. Informacije o vremenu kada su korisnici izvršavali određene aktivnosti. Analiza vremenskih podataka omogućava modelima da identifikuju sezonske obrasce, trendove i promene u preferencijama tokom vremena. Podaci o lokaciji korisnika ili proizvoda mogu pružiti dodatni kontekst u preporukama. Na primer, mogu se koristiti za prilagođavanje preporuka u skladu sa lokalnim preferencijama ili ponudama. Informacije o povezanosti korisnika sa drugima na platformi ili društvenim mrežama. Socijalni podaci mogu uključivati prijateljstva, zajedničke interese ili interakcije sa drugim korisnicima. Korisničke ocene ili recenzije proizvoda pružaju direktnu povratnu informaciju o zadovoljstvu ili nezadovoljstvu. Ovi podaci se često koriste u filterima kolaborativnog filtriranja. Informacije koje dolaze iz eksternih izvora, poput vremenskih uslova, vesti, društvenih trendova ili ekonomske situacije. Integracija ovih podataka može poboljšati sposobnost sistema da se prilagodi promenama u okolini. Informacije o transakcijama

⁶ Qian Zhang et al., 2021

korisnika, posebno relevantne za platforme e-trgovine. Ovi podaci obuhvataju informacije o kupovinama, cenama i preferencijama u vezi sa cenama. Informacije koje se stalno ažuriraju i odnose se na trenutne aktivnosti korisnika. Podaci o stvarnom vremenu omogućavaju sistemima da prate promene u ponašanju korisnika u stvarnom vremenu.

Kombinacija ovih različitih tipova podataka doprinosi stvaranju bogatog i sveobuhvatnog skupa podataka za treniranje modela sistema za preporuku. Ova raznolikost omogućava modelima da pruže personalizovane i relevantne preporuke koje odražavaju kompleksnost korisničkih preferencija i konteksta.

2.3. Etički aspekti sakupljanja podataka

Etički aspekti sakupljanja podataka postaju sve važniji kako tehnologija napreduje, posebno u oblasti sistema za preporuku. Ova pitanja obuhvataju pitanja privatnosti, transparentnosti i odnosa prema korisnicima. Pri prikupljanju podataka o korisnicima, posebna pažnja treba posvetiti očuvanju njihove privatnosti. Osetljive informacije poput ličnih podataka, adresa, i finansijskih informacija zahtevaju posebne mere opreza i transparentnosti u obradi. Korisnici bi trebalo jasno razumeti koje informacije se prikupljaju, kako se koriste i kako utiču na preporuke. Otvorenost i transparentnost u vezi sa procesima sakupljanja podataka gradi poverenje između korisnika i sistema za preporuku. Sakupljanje minimalno neophodnih podataka predstavlja etički pristup. Umesto da prikupljaju više podataka nego što je potrebno, pružaoci usluga trebalo bi da se fokusiraju na ono što je esencijalno za pružanje kvalitetnih preporuka. Svi korisnici trebaju biti tretirani s jednakim poštovanjem i pažnjom. Sistem ne bi smeo praviti diskriminaciju na osnovu demografskih karakteristika, rase, pola ili drugih osetljivih faktora⁷. Pre nego što se podaci prikupe, korisnici bi trebalo da budu informisani i daju svoju saglasnost. Jasan pristanak omogućava korisnicima da imaju kontrolu nad informacijama koje dele. Prikupljeni podaci trebaju se koristiti isključivo u svrhu poboljšanja korisničkog iskustva i pružanja boljih preporuka. Zloupotreba podataka u marketinške ili druge svrhe bez pristanka korisnika smatra se etički neprihvatljivom praksom. Implementacija snažnih mera bezbednosti podataka je ključna za očuvanje poverljivosti informacija. Bezbednosni propusti koji dovode do neovlašćenog pristupa podacima predstavljaju etički problem i mogu ozbiljno narušiti poverenje korisnika. Korisnici bi trebali imati pravo da zatraže brisanje svojih podataka iz sistema. Ovo pravo poznato kao "pravo

⁷ M. Mehdi Afsar et al., 2022

na zaborav" omogućava korisnicima kontrolu nad njihovim podacima. Algoritmi koji se koriste za preporuke trebaju biti pravični i transparentni. Kada se koristi veštačka inteligencija, posebna pažnja treba posvetiti izbegavanju pristrasnosti i diskriminacije u preporukama. Pružaoci usluga trebaju aktivno edukovati korisnike o tome kako funkcionišu sistemi za preporuku, kako se koriste podaci, i kako korisnici mogu kontrolisati svoje postavke privatnosti. Savremeni sistemi za preporuku suočavaju se s izazovima u balansiranju između pružanja personalizovanih preporuka i očuvanja privatnosti i etičkih standarda. Etički pristup ovim pitanjima ključan je za izgradnju dugoročnog poverenja korisnika i održivog razvoja ovih tehnologija.

3. Podela podataka i evaluacija performansi

3.1. Razdvajanje na skup za obuku i skup za testiranje

Razdvajanje podataka na skup za obuku i skup za testiranje predstavlja ključnu praksu u razvoju sistema za preporuku zasnovanih na mašinskom učenju. Ovaj korak omogućava ocenu performansi modela, pružajući pouzdanu procenu njegove sposobnosti generalizacije na neviđene podatke. Ključni aspekti ovog procesa uključuju: Osnovni cilj razdvajanja podataka na skup za obuku i skup za testiranje je omogućiti modelu da nauči određene obrasce iz podataka za obuku i potom proveri svoju efikasnost na podacima koje nije video tokom treniranja. Ovo pomaže u proceni generalizacije modela. Podaci se obično dele na skupove za obuku i testiranje u određenom odnosu, na primer, 80% podataka za obuku i 20% za testiranje. Ovaj odnos može varirati u zavisnosti od veličine skupa podataka i specifičnosti problema. Nasumični izbor podataka prilikom razdvajanja pomaže u eliminisanju bilo kakvih potencijalnih pristrasnosti ili redosleda u podacima. Ovo je važno kako bi se obezbedila reprezentativnost skupa za obuku i skupa za testiranje. Ako se suočavate sa problemom neravnoteže u klasama podataka, važno je očuvati tu neravnotežu i u skupu za obuku i u skupu za testiranje. Ovo pomaže modelu da efikasno nauči i evaluira performanse u stvarnom svetu. Posebna pažnja može se posvetiti stratifikaciji prilikom razdvajanja podataka, posebno ako imate više klasa ili kategorija. Stratifikacija obezbeđuje da su proporcije klasa očuvane u oba skupa. Za dodatnu pouzdanost, mogu se koristiti tehnike validacije. Ovo uključuje više iteracija razdvajanja podataka na različite skupove za obuku i testiranje kako bi se dobila sveobuhvatnija evaluacija modela. Nakon treninga, model se evaluira na skupu za testiranje kako bi se dobila objektivna procena njegove sposobnosti generalizacije. Ove performanse pomažu identifikaciju efikasnosti modela u rešavanju realnih problema. Važno je izbeći curenje informacija iz skupa za testiranje u skup za obuku, što bi moglo rezultirati preoptimizacijom

modela. Podaci za testiranje trebaju biti predstavljati stvarne uslove koje model može susresti. Razdvajanje podataka na skupove za obuku i testiranje predstavlja ključni korak u validaciji performansi modela sistema za preporuku. Ovaj proces pomaže u izgradnji pouzdanih i efikasnih modela koji su sposobni pružiti tačne preporuke u realnim uslovima.

3.2. Metrike za evaluaciju sistema

Evaluacija sistema za preporuku uključuje korišćenje različitih metrika kako bi se procenila tačnost, relevantnost i performanse modela. Preciznost se meri kao odnos tačno preporučenih entiteta (npr. proizvoda) u odnosu na ukupan broj preporučenih entiteta. Formula za preciznost je:⁸

$$\text{Preciznost} = \frac{\text{broj tačnih preporuka}}{\text{ukupan broj preporučenih entiteta}}$$

Recall meri sposobnost sistema da identifikuje sve relevantne entitete među svim stvarnim relevantnim entitetima. Formula za recall je:

$$\text{recall} = \frac{\text{broj tačnih preporuka}}{\text{ukupan broj stvarno relevantnih entiteta}}$$

F1-score je harmonična sredina između preciznosti i odaziva i pruža izbalansiran pristup evaluaciji modela. Formula za F1-score je:

$$F1 = 2x \frac{\text{preciznost} \times \text{recall}}{\text{preciznost} + \text{recall}}$$

MAP meri prosečnu preciznost preporuka za različite upite korisnika. Veće vrednosti ukazuju na bolje performanse. NDCG ocenjuje relevantnost preporuka uzimajući u obzir rangiranje. Visoke vrednosti NDCG-a ukazuju na relevantne preporuke koje se nalaze na visokim pozicijama. AUC-ROC meri sposobnost sistema da razlikuje između pozitivnih i negativnih instanci. Veća vrednost AUC-ROC-a ukazuje na bolje performanse u razlikovanju relevantnih od irelevantnih entiteta. MRR meri prosečni inverzni rang prvog tačnog entiteta. Ova metrika favorizuje modele koji postavljaju relevantne entitete na više pozitivnih pozicija. Spearman Rank Korelacija: Ova metrika meri stepen rangiranja između stvarnih ocena i predviđenih ocena. Visoka vrednost ukazuje na dobro usklađivanje između rangiranja sistema i stvarnih preferencija korisnika. Intra-list Similarity: Ova metrika meri sličnost između entiteta unutar preporučenih liste. Visoka vrednost

⁸ Shoujin Wang et al., 2021

ukazuje na raznolike preporuke unutar liste. Diverzitet i Serendipity: Ove metrike procenjuju raznolikost preporuka i sposobnost sistema da predstavi korisnicima neočekivane, ali relevantne entitete. Izbor odgovarajućih metrika zavisi od specifičnosti problema, ciljeva sistema za preporuku i prirode podataka. Kombinacija različitih metrika pruža sveobuhvatan uvid u performanse sistema iz različitih perspektiva. Važno je uzeti u obzir kontekst primene kako bi se odabrale metrike koje najbolje odražavaju relevantnost i zadovoljavaju kriterijume korisnika.

3.3. Praćenje i poboljšanje performansi

Praćenje i poboljšanje performansi sistema za preporuku ključni su koraci u održavanju efikasnog i korisnički orijentisanog sistema tokom vremena. Aktivno prikupljanje povratnih informacija od korisnika predstavlja dragocen izvor informacija o zadovoljstvu korisnika i njihovim potrebama. Korišćenje anketa, ocena, ili komentara može pomoći u identifikaciji oblasti za unapređenje. Praćenje metrika performansi, kao što su preciznost, odaziv, i F1-score, pomaže u oceni tačnosti sistema. Redovna analiza ovih metrika omogućava identifikaciju slabih tačaka i usmeravanje resursa na unapređenje tih aspekata. Implementacija A/B testiranja omogućava upoređivanje performansi različitih verzija sistema. Ovo može obuhvatiti promene u algoritmima preporuka, interfejsu korisničkog iskustva ili drugim faktorima kako bi se utvrdilo šta najbolje odgovara korisnicima. Praćenje retencije korisnika pomaže u merenju koliko su korisnici zadovoljni sistemom i koliko često se vraćaju. Visoka retencija ukazuje na pozitivno korisničko iskustvo, dok opadajuća retencija može ukazivati na potrebu za poboljšanjem sistema.⁹

Analiza klika (Click-Through Analysis): Praćenje kako korisnici reaguju na preporuke, uključujući klikove na preporučene entitete, može pružiti uvid u to koliko su preporuke privlačne i korisne. Sposobnost sistema da se prilagodi promenama u ponašanju korisnika tokom vremena ključna je za održavanje relevantnosti preporuka. Praćenje evolucije korisničkih preferencija pomaže u prilagođavanju modela. Periodično ažuriranje algoritama mašinskog učenja omogućava iskorišćavanje novih tehnika i pristupa koji mogu poboljšati preciznost i relevantnost preporuka. Integrisanje novih funkcionalnosti ili prilagođavanje postojećih može unaprediti korisničko iskustvo. Praćenje kako korisnici reaguju na ove promene omogućava iterativno poboljšavanje sistema. Aktivna komunikacija s korisnicima i uključivanje njihovog povratka u proces unapređenja može biti ključno. Otvoren dijalog sa korisnicima pomaže u razumevanju njihovih

⁹ M. Mehdi Afsar et al., 2022

potreba i očekivanja. Ako se sistem koristi na različitim platformama (web, mobilna aplikacija, društvene mreže), praćenje performansi na svakoj od njih pomaže u prilagođavanju interfejsa i preporuka specifičnostima svake platforme. Kroz kontinuirano praćenje, analizu i iterativno unapređenje, sistema za preporuku održava se visok nivo zadovoljstva korisnika i sposobnost pružanja relevantnih preporuka u dinamičnom okruženju.

4. Algoritmi mašinskog učenja u sistemima za preporuku

4.1. Filter kolaborativnog filtriranja

Filter kolaborativnog filtriranja je tehnika koja se često koristi u sistemima za preporuku kako bi se predvideli interesovanja korisnika na osnovu sličnosti između njih i drugih korisnika. Ovaj pristup se oslanja na ideju da će korisnici koji imaju slične ukuse ili ponašanje imati slične preferencije u vezi sa proizvodima ili sadržajem. U filteru kolaborativnog filtriranja, ne analiziraju se eksplicitne karakteristike proizvoda ili korisnika, već se fokus stavlja na obrasce ponašanja zajednice korisnika. Postoje dve osnovne vrste filtera kolaborativnog filtriranja: user-based (bazirano na korisnicima) i item-based (bazirano na proizvodima). User-Based Collaborative Filtering (UCF): U filteru baziranom na korisnicima, preporuke se prave na osnovu sličnosti između ciljnog korisnika i drugih korisnika. Ako dva korisnika imaju slične preferencije u prošlosti, pretpostavlja se da će imati slične preferencije i u budućnosti. Na primer, ako korisnik A i korisnik B često biraju iste proizvode ili ocenjuju proizvode slično, sistem će preporučiti proizvode koje korisnik B voli, a koje korisnik A još nije vidio. Item-Based Collaborative Filtering (ICF): U filteru baziranom na proizvodima, fokus je na sličnosti između proizvoda. Ako korisnik pokazuje interesovanje za određene proizvode, sistem će preporučiti druge proizvode koji su slični onima koje je korisnik već ocenio ili kupio. Ova metoda se često koristi kada je broj korisnika veliki, a broj proizvoda manji. Jedna od ključnih prednosti kolaborativnog filtriranja je što ne zahteva eksplicitno znanje o proizvodima ili korisnicima. Osim toga, može efikasno raditi u situacijama gde postoje skriveni ili nepoznati faktori koji utiču na korisničke preference. Međutim, kolaborativno filtriranje takođe može suočiti s izazovima, kao što su problem hladnog početka (cold start), gde je teško preporučiti proizvode novim korisnicima ili novim proizvodima koji nemaju istoriju ocena.

U praksi, sistem za preporuku često kombinuje različite pristupe, uključujući i kolaborativno filtriranje, kako bi postigao bolje rezultate i prevazišao ograničenja svakog pojedinačnog pristupa.

4.2. Filter zasnovan na sadržaju

Filter zasnovan na sadržaju je još jedan ključni pristup u razvoju sistema za preporuku. Ovaj metod se fokusira na analizu karakteristika i osobina samih proizvoda ili sadržaja, a ne na sličnosti između korisnika. Ideja je prilagoditi preporuke korisnicima na osnovu njihovih prethodnih preferencija, uzimajući u obzir relevantne karakteristike proizvoda. Filter zasnovan na sadržaju analizira karakteristike proizvoda kako bi stvorio profil svakog proizvoda. Ove karakteristike mogu uključivati ključne reči, žanrove, autore, ili druge relevantne attribute. Sadržaj se često vektorizuje kako bi se predstavio numerički. Na primer, tekstualni sadržaj može se pretvoriti u vektore koristeći tehnike poput TF-IDF (Term Frequency-Inverse Document Frequency) ili ugradnje reči (word embeddings). Na osnovu prethodnih interakcija korisnika sa sadržajem, sistem kreira profil korisnika. Ovaj profil odražava preferencije korisnika, uzimajući u obzir karakteristike proizvoda koje su ocenili ili konzumirali. Relevancija sadržaja za određenog korisnika meri se upoređivanjem profila korisnika sa profilima proizvoda. Sadržaji koji su slični korisničkom profilu smatraju se relevantnijim i više se preporučuju. Na osnovu analize sličnosti između profila korisnika i profila proizvoda, sistem pruža personalizovane preporuke. Ove preporuke odražavaju specifične interesovanja i preferencije svakog pojedinačnog korisnika. Filter zasnovan na sadržaju ima prednost u situacijama hladnog početka (cold start) gde postoje novi proizvodi ili korisnici. Analizom karakteristika novog sadržaja može se pružiti relevantna preporuka čak i kada nema prethodnih ocena. Filter zasnovan na sadržaju često pruža transparentnost u procesu preporuke, jer se preporuke kreiraju na osnovu jasnih karakteristika proizvoda i korisničkih preferencija. Filter zasnovan na sadržaju ima prednosti u situacijama kada je korisnički profil dobro definisan ili kada postoji dobar opis karakteristika proizvoda. Međutim, može se suočiti s izazovima u situacijama gde je potrebna šira raznolikost preporuka ili kada je teško kreirati precizne profile korisnika. Kombinacija različitih pristupa često vodi do efikasnijih sistema za preporuku.¹⁰

4.3. Hibridni pristupi

Hibridni pristupi u sistemima za preporuku kombinuju više različitih tehnika i metoda kako bi unapredili tačnost, pouzdanost i personalizaciju preporuka. Ova kombinacija omogućava prevazilaženje nedostataka pojedinačnih metoda i pruža sveobuhvatniji pristup zadatku preporuke. Ovi pristupi koriste različite tehnike preporuke i kombinuju ih u jedinstvenu funkcionalnost. Na primer, moguće je kombinovati kolaborativno filtriranje i filter zasnovan na sadržaju tako da

¹⁰ Qian Zhang et al., 2021

koriste prednosti obe tehnike za poboljšanje preciznosti. Ovi pristupi uzimaju u obzir vremenski faktor prilikom preporuka. Koriste se kako bi prilagodili preporuke u skladu sa promenama u ponašanju korisnika tokom vremena. Na primer, mogu se kombinovati algoritmi koji prate sezonske trendove sa onima koji analiziraju dugoročne preferencije korisnika. Ovaj pristup koristi kombinaciju karakteristika proizvoda i korisničkih preferencija, uključujući i dodatne informacije kao što su demografski podaci ili kontekstualne informacije. Hibridno modeliranje karakteristika pruža bogatiju sliku o preferencijama korisnika. Težinski faktori se koriste kako bi se dodelile različite važnosti različitim metodama. Na primer, moguće je postaviti težine na osnovu pouzdanosti svake pojedinačne metode ili zavisno o kontekstu korisnika. U kaskadnim pristupima, različite metode se koriste sekvencijalno. Na primer, može se prvo primeniti jedna metoda, a zatim rezultati te metode se koriste kao ulaz za drugu metodu. Ovo omogućava složenije i kontekstualno prilagođene preporuke. U sistemima sa više nivoa, različite metode se primenjuju na različite nivoe sistema. Na primer, moguće je koristiti jednu metodu na nivou skupova podataka, a drugu na nivou korisnika, pružajući tako više dimenzija personalizacije. Hibridni pristupi sa prikazivanjem (Ensemble Methods)-Ovi pristupi kombinuju više modela ili algoritama kako bi postigli bolje performanse. Popularne tehnike u ovom kontekstu uključuju bagging, boosting i stacking. Korišćenje hibridnih pristupa u sistemima za preporuku omogućava bolje prilagođavanje različitim scenarijima i zahtevima. Ovi pristupi mogu biti fleksibilni i adaptivni, pružajući tako korisnicima personalizovane preporuke koje uzimaju u obzir različite aspekte njihovih preferencija i ponašanja. Hibridni pristupi često predstavljaju efikasno rešenje u praksi, gde se kombinuju različiti izvori podataka i tehnike kako bi se postigla visoka tačnost preporuka.

5. Zaključak

Sistemska razvoj preporučenih sistema u poslednjim decenijama snažno je podstaknut napretkom u oblasti mašinskog učenja. Algoritmi za preporuke postali su sve sofisticiraniji, omogućavajući sistemima da pruže personalizovane preporuke sa visokom tačnošću. Personalizovane preporuke su postale ključne u poboljšanju korisničkog iskustva na različitim platformama. Sistemi za preporuke pružaju korisnicima sadržaj i proizvode koji su relevantni za njihove individualne preferencije, čime se povećava angažovanje i zadovoljstvo korisnika. Sakupljanje i obrada podataka igra ključnu ulogu u efikasnom funkcionisanju sistema za preporuke. Izazovi kao što su problem hladnog početka, pristrasnost podataka, i etički aspekti sakupljanja podataka zahtevaju pažljivu analizu i implementaciju odgovarajućih rešenja. Oba pristupa, kolaborativno filtriranje i filter zasnovan na sadržaju, imaju svoje prednosti i izazove. Kombinacija ovih pristupa, kao i hibridnih metoda, često se koristi kako bi se ostvarile bolje performanse i prevazišli nedostaci pojedinačnih metoda. Praćenje performansi sistema za preporuku ključno je za održavanje kvaliteta preporuka tokom vremena. Kontinuirano prikupljanje povratnih informacija, analiza metrika performansi, i iterativno unapređenje algoritama doprinose efikasnosti sistema. Sveobuhvatan pristup razvoju sistema za preporuku uključuje pažljivo balansiranje između različitih tehnika i metoda. Prilagodljivost sistema je ključna, posebno u kontekstu promenljivih preferencija korisnika, novih proizvoda i evolucije tehnologije. U zaključku, razvoj savremenih sistema za preporuku predstavlja dinamičan proces koji se oslanja na kompleksne tehnologije i metode, s ciljem pružanja personalizovanih i relevantnih preporuka korisnicima. Unapređenje tačnosti, transparentnosti i prilagodljivosti sistema za preporuku ostaje ključni fokus istraživanja i implementacije kako bi se ispunile rastuće potrebe i očekivanja korisnika.

6. Literatura

1. Kiran R., Pradeep Kumar., Bharat Bhasker, (2020), DNNRec: A novel deep learning based hybrid recommender system, Vol 144., <https://doi.org/10.1016/j.eswa.2019.113054> pp: 345-390.
2. Roshan Bhanuse., Sandip Mal et al., (2021), A Systematic Review: Deep Learning based E-Learning Recommendation System, pp: 501-549.
3. Shristi Shakya Khanal., Abeer Alsadoon, Angelika Maag, (2020), A systematic review: machine learning based recommendation systems for e-learning, Vol 25., pp: 2635-2664.
4. Akhil Hannegudda Ganesh, Bin Xu, (2022), A review of reinforcement learning based energy management systems for electrified powertrains: Progress, challenge, and potential solution, <https://doi.org/10.1016/j.rser.2021.111833>, pp: 445-489.
5. Dhiraj Neupane, Jongwon Seok, (2020), A Review on Deep Learning-Based Approaches for Automatic Sonar Target Recognition, Vol 9., <https://doi.org/10.3390/electronics9111972>
6. Qian Zhang, Jie Lu, Yaochu Jin, (2021), Artificial intelligence in recommender systems, Vol. 7, pp: 439-457.
7. M. Mehdi Afsar, Trafford Crump, Behrouz Far, (2022), Reinforcement Learning based Recommender Systems: A Survey, Vol 7. pp:1-38.
8. Shoujin Wang, Longbing Cao, Yan Wang, Quan Z. Sheng, Mehmet A. Orgun, Defu Lian, (2021), A Survey on Session-based Recommender Systems, Vol 45., pp:1-38
9. Programming Collective Intelligence: Building Smart Web 2.0 Applications" - Toby Segaran, posećeno 2024. Godine
10. Building Machine Learning Powered Applications: Going from Idea to Product" - Emmanuel Ameisen, posećeno 2024. Godine