

Vrsta rada: Originalni naučni rad

Primljen: 10.01.2024.

Prihvaćen: 25.01.2024.

UDK: 004.78:005.572

Sistem za preporuku: Dizajn i mogućnosti u razvoju informacionih sistema

Andrej Unković^{1,*} i Aleksandar Simović²

¹ Visoka škola strukovnih studija za informacione tehnologije – ITS, Beograd, Srbija; unkovic.andrej@gmail.com

² Visoka škola strukovnih studija za informacione tehnologije – ITS, Beograd, Srbija; aleksandar.simovic@its.edu.rs

* Kontakt-informacije: unkovic.andrej@gmail.com; Tel: +381063480995

Apstrakt: U ovom radu se istražuje dizajn i mogućnosti sistema za preporuku u razvoju informacionih sistema. Definišu se osnovne karakteristike sistema za preporuku, tehnološki alati za praćenje i prikupljanje korisničkih aktivnosti, kao i metod generisanja preporuka. Glavni fokus je na osnovnim konceptima, različitim vrstama sistema za preporuku i njihovoj praktičnoj primeni u različitim tehnološkim poljima i industrijskim područjima. Takođe, rad analizira najčešće korišćene algoritme za generisanje preporuka i različite metrike evaluacije. Prikazuje najčešće probleme sa kojima se susreću sistemi za preporuku, od kojih su najvažniji problemi hladnog starta, retkih podataka i promene korisničkog ponašanja. Govori o primenjenim sistemima za preporuku u trenutnim oblastima, kao što su elektronska trgovina, platforme za stvaranje video sadržaja i društvene mreže. Na kraju rada razmatra se budući razvoj sistema za preporuku, budući pravci istraživanja unutar informacionih sistema i potencijalno unapređenje korisničkog iskustva unutar različitih informacionih sistema. Cilj ovog rada je da pruži jasniji uvid u sisteme za preporuku i njihov sve izraženiji uticaj na onlajn aktivnosti korisnika.

Ključne reči: Sistemi za preporuku, primjenjeni algoritmi za preporuke, personalizovani sistemi, hibridni sistem za preporuke, evaluacija performansi

1. Uvod

Sa sve većim obimom informacija, sistemi za preporuku su već dugo efikasna strategija za prevazilaženje preopterećenosti informacijama [1]. Primenljivost sistema za preporuku je ključna, imajući u vidu njihovu široku primenu u mnogim informacionim sistemima [2]. Sistemi za preporuku su među najuticajnijim aplikacijama u pametnim okruženjima i njihov cilj je da korisnicima ukažu na potencijalno interesantne sadržaje [3]. Na primer, u današnjem polju elektronske trgovine, gotovo svi web-sajtovi za elektronsku trgovinu koriste sisteme za preporuku kako bi pomogli korisnicima da pronađu odgovarajuće proizvode [4,5]. Na taj način, oni ne samo da pomažu korisnicima da prevaziđu preopterećenost informacijama, već mogu značajno da doprinesu poslovnom uspehu pružaoca usluga [3–6]. U mnogim praktičnim aplikacijama, sistemi za preporuku prate korisničko ponašanje i aktivnosti i generišu prilagođene preporuke na osnovu prikupljenih informacija. Iako je ovaj pristup koristan, ograničenja mogu nastati kada korisnici tek počnu da koriste informacioni sistem koji primenjuje personalizovani algoritam preporuka. U tom slučaju, sistem nema dovoljno informacija o korisniku, i zbog toga dolazi do hladnog starta i retkih podataka. Da bi se prevazišao ovaj problem, istraživači razvijaju različite tehnike i algoritme [7–9].

Ovaj rad definiše koncept sistema za preporuku, istražuje različite algoritme koji se koriste u praksi za generisanje sadržaja, predstavlja rešenja za potencijalne probleme poput hladnog starta s kojima se suočavaju sistemi za preporuku i prikazuje različite primene i buduće razvoje ovih sistema.

2. Definisanje sistema za preporuku

Sistem za preporuku je napredna tehnologija koja koristi elemente mašinskog učenja i analize podataka za generisanje preporuka korisnicima. Ovi sistemi predstavljaju softverske komponente koje obično pripadaju širem informacionom sistemu, ali mogu biti i samostalni alati.

Sistemi za preporuku koriste različite algoritme i tehnike za prikupljanje, analizu i filtriranje podataka na osnovu kojih generišu relevantne preporuke korisnicima. Na ovaj način sistemi za preporuku unapređuju korisničko iskustvo unutar različitih informacionih sistema i onlajn platformi. Sistemi za preporuku mogu biti podeljeni na nepersonalizovane i personalizovane sisteme za preporuku [10,11].

3. Nepersonalizovani sistemi za preporuku

Nepersonalizovani sistemi za preporuku imaju zadatak da pruže preporuke korisnicima ne uzimajući u obzir njihove individualne preferencije i ponašanja. Za razliku od personalizovanih sistema za preporuku, ovi sistemi se ne oslanjaju na jedinstvene karakteristike korisnika, već uzimaju u obzir opšte podatke unutar informacionih sistema. Na ovaj način sistem nudi preporuke čak i ako korisnik dosad nije imao priliku da koristi sistem.

Nedostatak ovog pristupa je to što korisnici neće dobijati preporuke prema svojim preferencijama već će dobijati preporuke na osnovu opštih informacija unutar informacionog sistema.

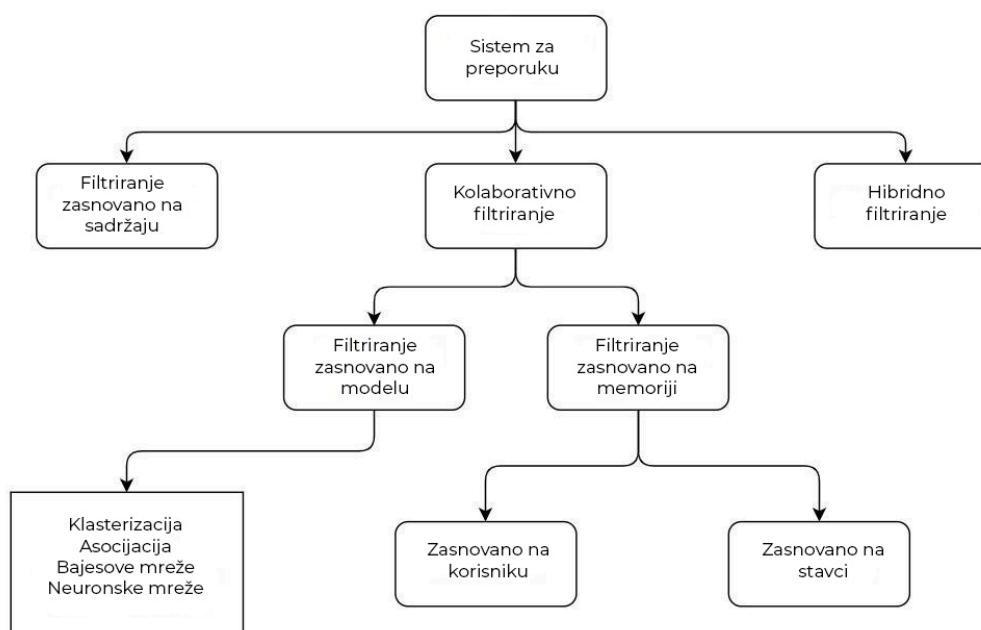
Iz tog razloga, ovi sistemi se često koriste kao početni korak u implementaciji sistema za preporuku unutar šireg informacionog sistema. Nepersonalizovani sistem obično predstavlja najprodavaniji ili najpoznatiji sadržaj unutar informacionog sistema [10–12].

4. Personalizovani sistemi za preporuku

Personalizovani sistemi za preporuku su dizajnirani da generišu prilagođene preporuke korisnicima na osnovu njihovih preferencija, prošlih ponašanja i demografskih informacija. Ovi sistemi prate korisničke onlajn aktivnosti kao što su kupovine i ocenjeni sadržaji, i na osnovu toga pokušavaju da predvide i razumeju za koje stavke i sadržaje će korisnik potencijalno biti zainteresovan. Često se kaže da dobru preporuku karakteriše raznovrsnost, personalizacija i aktuelnost.

Korišćenje efikasnih i preciznih tehnika davanja preporuka veoma je važno za sistem koji će pružiti odlične i vredne preporuke korisnicima. To objašnjava važnost razumevanja karakteristika i potencijala različitih tehnika davanja preporuka [5, 10–12].

Slika 1 prikazuje strukturu različitih tehnika filtriranja preporuka.



Slika 1 – Struktura različitih tehnika filtriranja za generisanje preporuka, preuzeto iz [13].

Najčešći i najkorišćeniji algoritmi za personalizovani sistem za preporuku su:

- Filtriranje zasnovano na sadržaju;
- Kolaborativno filtriranje;
- Hibridno filtriranje.

4.1. Filtriranje zasnovano na sadržaju

Filtriranje zasnovano na sadržaju je algoritam specifičan za određeni domen koji naglašava analizu atributa stavki radi generisanja predikcija. Ova tehnika generiše preporuke na osnovu karakteristika korisnika prikupljenih analizom sadržaja koje je korisnik ocenio u prošlosti. Stavke koje je korisnik ocenio najbolje uzimaju se kao preporuke. Filtriranje zasnovano na sadržaju koristi modele mašinskog učenja kako bi generisalo značajne i relevantne preporuke. Najčešće korišćeni modeli mašinskog učenja su klasifikator Naivni Bajes, stablo odlučivanja i neuronske mreže. Ova tehnika ne zahteva prikupljanje informacija o drugim korisnicima jer one ne utiču na preporuke. Takođe, ukoliko dođe do naglih promena u profilu i aktivnosti korisnika, tehnika filtriranja zasnovana na sadržaju ima potencijal da prilagodi preporuke u kratkom periodu [10–12].

Na primer, ako je korisnik kupio proizvod unutar informacionog sistema, sistem prepostavlja da korisnik preferira tu kategoriju proizvoda. Razmatrajući ovu informaciju, verovatno je da će korisnik kupiti sličan proizvod pri budućem korišćenju sistema [5].

Glavna prednost ovog sistema za preporuku leži u korisnikovom razumevanju preporuke. Korisnik može zaključiti da su njegove prošle aktivnosti uticale na trenutne preporuke, što može smanjiti zabrinutost oko privatnosti podataka. S druge strane, najveći nedostatak ovog sistema je prekomerna specijalizacija preporuka. U većini slučajeva, sistem će korisniku nuditi preporuke na osnovu prethodne aktivnosti i sadržaja, što ograničava sposobnost preporučivanja sadržaja van poznatih preferencija korisnika. Takođe, ograničenje sistema za preporuku zasnovanih na sadržaju je problem hladnog starta. Zbog načina rada sistema, korisnik mora oceniti dovoljan broj sadržaja kako bi sistem mogao dati odgovarajuće preporuke [6,7].

4.2. Kolaborativno filtriranje

Kolaborativno filtriranje je sistem koji predviđa vredan proizvod za korisnika na osnovu drugih korisnika unutar informacionog sistema. Iako je termin kolaborativnog filtriranja prisutan već više od deset godina, ovaj metod vuče svoje korene iz nečega što ljudi rade vekovima – deljenje ideja sa drugima.

Za razliku od filtriranja zasnovanog na sadržaju, sistem određuje korisnike na osnovu sličnih preferencija ciljnog korisnika. Zatim upoređuje korisnike sa sličnim interesima i preferencijama, izračunavajući sličnosti između njihovih profila kako bi pružio preporuke. Na ovaj način korisnik dobija preporuke za proizvod koji prethodno nije ocenjivao, ali ga je već pozitivno ocenila slična grupa korisnika [5,14]. U kolokvijalnom govoru, slični korisnici se takođe mogu nazvati „komšijama“ [10–12]. Preporuke generisane od strane kolaborativnog filtriranja mogu biti u obliku predikcija ili preporuka. Pristupi kolaborativnom filtriranju razlikuju se upravo u načinu određivanja sličnosti između korisnika.

Sistemi kolaborativnog filtriranja mogu se klasifikovati u dva osnovna principa [5]:

- Korisnički orijentisano kolaborativno filtriranje
- Filtriranje zasnovano na stavci

U korisnički orijentisanom kolaborativnom filtriranju, preferencije i ocene ciljnog korisnika se porede sa ocenama drugih korisnika kako bi se identifikovala grupa sličnih korisnika. Nakon identifikacije sličnih korisnika, sistem preporučuje proizvode koje su drugi korisnici ocenili najvišim ocenama. Na ovaj način ciljni korisnik dobija preporuke koje mu odgovaraju. Međutim, u filtriranju zasnovanom na stavci, preporuke se generišu identifikacijom sličnih proizvoda koje je ciljni korisnik prethodno kupio ili ocenio. Pri određivanju sličnosti između stavki, preferencije posmatranog korisnika upoređuju se sa drugim korisnicima informacionog sistema. U oba pomenuta pristupa kolaborativnog filtriranja, generisana preporuka korisnika zavisi od preferencija drugih korisnika, što je osnova ovog sistema za preporuku. Prednost ovog sistema za preporuku je uverljiva personalizacija i mogućnost neočekivanih otkrića – sistem može preporučiti sadržaj koji se razlikuje od sadržaja za koji je korisnik pokazao interes. Na taj način prevazilazi se problem prekomerne personalizacije. S druge strane, nedostatak ovog sistema predstavlja problem hladnog starta i osetljivost na retke podatke. Za kolaborativno filtriranje neophodno je obezbediti dovoljno podataka o interakcijama korisnika unutar informacionog sistema [5,10–12].

4.3. Hibridno filtriranje

Hibridno filtriranje ili mešani sistem filtriranja predstavlja kombinaciju nekoliko različitih pristupa i tehnika za generisanje preporuka kako bi se pružile preciznije, raznovrsnije i praktičnije preporuke. Ovi sistemi se često koriste u praksi jer mogu pružiti preciznije i prilagodljivije preporuke. Najznačajnija prednost sistema hibridnog filtriranja je što poboljšava kvalitet preporuke kombinovanjem prednosti različitih sistema za preporuku. Takođe, ovaj sistem povećava fleksibilnost i smanjuje ograničenja pojedinačnih sistema za preporuku. Na kraju, hibridni sistemi prevazilaze najčešće probleme sa kojima se susreću sistemi za preporuku, a to je najčešće problem hladnog starta i prekomerne specijalizacije preporuka. S druge strane, nedostatak ovih sistema je povećana složenost i napor u razvoju sistema za preporuku i potreba za velikim obimom podataka. Iako hibridni sistemi za preporuku nude značajne prednosti u pogledu kvaliteta preporuka i fleksibilnosti, zahteve resursa treba pažljivo razmotriti prilikom odlučivanja o implementaciji sistema [5, 10–12].

5. Evaluacija performansi sistema za preporuku

Evaluacija performansi sistema za preporuku je ključan proces u razvoju sistema za preporuku. Ovaj proces uključuje ocenu tačnosti preporuke i merenje efikasnosti sadržaja generisanog od strane sistema za preporuku. Na ovaj način se određuje u kojoj meri sistem zadovoljava potrebe korisnika i koliko su korisniku relevantne generisane preporuke.

Prilikom evaluacije sistema za preporuku sprovode se tri vrste eksperimenata, i to:

- Onlajn – koristi skupove podataka i protokole koji repliciraju korisničku aktivnost i mere tačnost predikcije;
- Oflajn – evaluacija korišćenja sistema za preporuku u realnom vremenu;
- Studije korisnika – bazirane na korišćenju sistema za preporuku od strane ograničenog broja korisnika i analizi njihovih povratnih informacija.

Izbor sistema i algoritama zasniva se na evaluacionim metrikama. Najčešće korišćene evaluacione metrike su Recall, Precision, Root Mean Squared Error – RMSE, Mean Absolute Error – MAE. Metrika *recall* ocenjuje tačnost preporuka sistema na osnovu korisničkih preferencija – što je veći odziv, to su tačnije preporuke. Metrika *Precision* meri procenat korisničkih ocena u svim mogućim preporukama. Kvadratni koren srednje kvadratne greške meri greške predikcije koje bi idealno trebalo da budu niske. Ovo su samo neke metrike za evaluaciju tačnosti sistema za preporuku koji se koriste danas. Važno je razumeti da uspeh i tačnost sistema za preporuku u velikoj meri zavise od tačnosti i kvaliteta korišćenih podataka [15,16].

6. Primena sistema za preporuku

U modernom tehnološkom dobu, sistemi za preporuku su postali neizbežan alat za personalizaciju korisničkog iskustva i poboljšanje angažovanosti korisnika. Primene sistema za preporuku mogu se videti u različitim poslovnim oblastima. Neke od najznačajnijih su e-trgovina [4,5], usluge igranja u oblaku [17–19], platforme za strimovanje [20,21], društvene mreže [22,23], i oblasti obrazovanja [3,24,25].

U e-trgovini, sistemi za preporuku preporučuju relevantne proizvode i sadržaje korisniku, postižući zadovoljstvo korisnika i promovišući bolju prodaju proizvoda u informacionom sistemu [5]. Takođe, primena ovih sistema može se videti i u oblasti platformi za strimovanje, koje uključuju platforme kao što su Netflix, Spotify i YouTube.

Sistemi za preporuku preporučuju sadržaj korisnicima na osnovu njihovih prethodnih preferencija i pretraga. Društvene mreže koriste sisteme za preporuku kako bi predložile nove prijatelje, grupe i stranice koje bi mogle zanimati korisnike.

U obrazovanju ovi sistemi postaju sve dostupniji. Oni prilagođavaju nastavni materijal prema individualnim potrebama i stilovima učenja, pružajući korisniku prilagođen pristup učenju [3].

7. Budući pravci i razvoj sistema za preporuku

Sistemi za preporuku su se fokusirali na privlačenje potencijalnih kupaca, ali budući sistemi će imati širi uticaj na naše svakodnevne živote. Postaće neophodni alati koji će delovati kao lični savetnici u svim aspektima života i neće biti ograničeni samo na kupovinu i prodaju proizvoda. Očekuje se da će budući sistemi za preporuku biti zasnovani na podacima sa Interneta stvari (IoT), Interneta svega (IoE) i velikih podataka i koristiće ih inteligentno [26]. Prevazići će problem hladnog starta prikupljanjem informacija iz drugih izvora [3], poput društvenih mreža [22,23] i Interneta svega [27]. Budući sistemi će biti više orijentisani ka korisniku, pružajući preporuke koje bolje odražavaju korisničke preferencije. Analiza ličnih karakteristika i ponašanja omogućiće personalizovanje preporuke. Ovi sistemi će proširiti svoj uticaj i postati deo svakodnevnog života, prateći aktivnosti korisnika i pružajući preporuke koje obuhvataju zdravstvenu zaštitu, emotivno stanje i druge aspekte života. Očekuje se da će budući sistemi za preporuku biti primenjeni na etičniji način, nudeći korisnicima preporuke samo kada su potrebne [1,3,28].

8. Zaključak

Jedan od ključnih izazova u implementaciji sistema za preporuku jeste balansiranje privatnosti korisnika i personalizacije. Potreba za personalizovanim preporukama raste, što uključuje praćenje korisničke aktivnosti, dok se s druge strane postavlja pitanje kako zaštititi podatke od zloupotrebe. Kao rešenje ovog problema, sve više se radi na razvoju tehnologija poput diferencijalne privatnosti i federalnog učenja. Ove tehnologije ukazuju na mogućnosti prevazilaženja ovih izazova i omogućavaju implementaciju sistema za preporuku bez ugrožavanja privatnosti korisnika. Takođe smo imali priliku da vidimo ključnu ulogu mašinskog učenja u tačnosti preporuka sistemaza preporuku, omogućavajući im prilagođavanje promenljivim korisničkim preferencijama. Međutim, takođe smo prepoznali da je važno kontinuirano pratiti performanse sistema, kao i evaluirati i ažurirati algoritme kako bi se očuvala njihova tačnost i relevantnost.

U narednom periodu se može očekivati ekspanzivni razvoj sistema za preporuku, uključujući nove tehnologije poput dubokog učenja i veštačke inteligencije, kako bi se korisničke preferencije i potrebe razumele još preciznije. Razumevanje navika i aktivnosti korisnika biće ključno za stvaranje poverenja među korisnicima.

Zahvalnost

Ovaj rad je realizovan za potrebe kursa Analiza velikih podataka pod supervizijom prof. dr Aleksandra Simovića na Visokoj školi strukovnih studija za informacione tehnologije – ITS u Beogradu, Srbija.

Reference

1. Wang Y, Ma W, Zhang M, Liu Y, Ma S. A survey on the fairness of recommender systems. ACM Transactions on Information Systems. 2023 Feb 7;41(3):1-43. Available from: <https://doi.org/10.1145/3547333>
2. Jannach D, Manzoor A, Cai W, Chen L. A survey on conversational recommender systems. ACM Computing Surveys (CSUR). 2021 May 23;54(5):1-36. Available from: <https://doi.org/10.1145/3453154>
3. Simović A. A Big Data smart library recommender system for an educational institution. Library Hi Tech. 2018 Apr 19;36(3):498-523. Available from: <https://doi.org/10.1108/LHT-06-2017-0131>
4. Alamdari PM, Navimipour NJ, Hosseinzadeh M, Safaei AA, Darwesh A. A systematic study on the recommender systems in E-commerce. Ieee Access. 2020 Jun 16;8:115694-716. Available from: <https://doi.org/10.1109/ACCESS.2020.3002803>
5. Simović A. Sistemi preporuke u e-trgovini. Sinteza 2014-Impact of the Internet on Business Activities in Serbia and Worldwide. 2014:846-52. Available from: <https://doi.org/10.15308/sinteza-2014-846-852>
6. Zhang S, Yao L, Sun A, Tay Y. Deep learning-based recommender system: A survey and new perspectives. ACM computing surveys (CSUR). 2019 Feb 25;52(1):1-38. Available from: <https://doi.org/10.1145/3285029>
7. Panda DK, Ray S. Approaches and algorithms to mitigate cold start problems in recommender systems: a systematic literature review. Journal of Intelligent Information Systems. 2022 Oct;59(2):341-66. Available from: <https://doi.org/10.1007/s10844-022-00698-5>
8. Rodpysh KV, Mirabedini SJ, Banirostam T. Resolving cold start and sparse data challenge in recommender systems using multi-level singular value decomposition. Computers & Electrical Engineering. 2021 Sep 1;94:107361. Available from: <https://doi.org/10.1016/j.compeleceng.2021.107361>
9. Kuznetsov S, Kordík P. Overcoming the cold-start problem in recommendation systems with ontologies and knowledge graphs. In European Conference on Advances in Databases and Information Systems 2023 Aug 31 (pp. 591-603). Cham: Springer Nature Switzerland. Available from: https://doi.org/10.1007/978-3-031-42941-5_52
10. Start To Flow, Guide to Recommendation System: Types, Selection Criteria, How to Build One. Available from: <https://stratoflow.com/guide-to-recommendation-system>
11. Medium, Recommendation Systems Explained: Understanding the Basic to Advance. Available from: <https://utsavdesai26.medium.com/recommendation-systems-explained-understanding-the-basic-to-advance-43a5fce77c47>
12. Medium, Essentials of recommendation engines: content-based and collaborative filtering. Available from: <https://towardsdatascience.com/essentials-of-recommendation-engines-content-based-andcollaborative-filtering-31521c964922>
13. Isinkaye FO, Folajimi YO, Ojokoh BA. Recommendation systems: Principles, methods and evaluation. Egyptian Informatics Journal. 2015 Nov 1;16(3):261-73. Available from: <https://doi.org/10.1016/j.eij.2015.06.005>
14. Simović A. Recommender systems in the big data environment using the Mahout framework. In 2017 25th Telecommunication Forum (TELFOR) 2017 Nov 21 (pp. 1-4). IEEE. Available from: <https://doi.org/10.1109/TELFOR.2017.8249472>

15. Silveira T, Zhang M, Lin X, Liu Y, Ma S. How good your recommender system is? A survey on evaluations in recommendation. International Journal of Machine Learning and Cybernetics. 2019 May 1;10:813-31. Available from: <https://doi.org/10.1007/s13042-017-0762-9>
16. Khanal SS, Prasad PW, Alsadoon A, Maag A. A systematic review: machine learning based recommendation systems for e-learning. Education and Information Technologies. 2020 Jul;25:2635-64. Available from: <https://doi.org/10.1007/s10639-019-10063-9>
17. Mekić N. Cloud Gaming Services. Scientific Journal for Contemporary Education and Application of Information Technologies – EdTech Journal, 2023. Available from: <https://doi.org/10.18485/edtech.2023.3.1.4>
18. Sun C, Li H, Li X, Wen J, Xiong Q, Zhou W. Convergence of recommender systems and edge computing: A comprehensive survey. IEEE Access. 2020 Mar 6;8:47118-32. Available from: <https://doi.org/10.1109/ACCESS.2020.2978896>
19. Schmidt S. Assessing the quality of experience of cloud gaming services. Springer Nature; 2022 Sep 7.
20. Mekić N, Simović A. Web and Android Recommender System for Streaming Services using Apache Drill. Challenges of Contemporary Higher Education (CCHE). 2024. Available from <https://cche.rs/>
21. Deldjoo Y, Schedl M, Cremonesi P, Pasi G. Recommender systems leveraging multimedia content. ACM Computing Surveys (CSUR). 2020 Sep 28;53(5):1-38. Available from: <https://doi.org/10.1145/3407190>
22. Eirinaki M, Gao J, Varlamis I, Tserpes K. Recommender systems for large-scale social networks: A review of challenges and solutions. Future generation computer systems. 2018 Jan 1;78:413-8. Available from: <https://doi.org/10.1016/j.future.2017.09.015>
23. Daud NN, Ab Hamid SH, Saadoon M, Sahran F, Anuar NB. Applications of link prediction in social networks: A review. Journal of Network and Computer Applications. 2020 Sep 15;166:102716. Available from: <https://doi.org/10.1016/j.jnca.2020.102716>
24. Urdaneta-Ponte MC, Mendez-Zorrilla A, Oleagordia-Ruiz I. Recommendation systems for education: Systematic review. Electronics. 2021 Jul 6;10(14):1611. Available from: <https://doi.org/10.3390/electronics10141611>
25. Salazar C, Aguilar J, Monsalve-Pulido J, Montoya E. Affective recommender systems in the educational field. A systematic literature review. Computer Science Review. 2021 May 1;40:100377. Available from: <https://doi.org/10.1016/j.cosrev.2021.100377>
26. Pramanik PK, Choudhury P. IoT data processing: The different archetypes and their security and privacy assessment. In Internet of Things Security 2022 Sep 1 (pp. 37-54). River Publishers.
27. Gupta D. A comprehensive study of recommender systems for the Internet of Things. InJournal of Physics: Conference Series 2021 Jul 1 (Vol. 1969, No. 1, p. 012045). IOP Publishing. Available from: <https://doi.org/10.1088/1742-6596/1969/1/012045>
28. Bourke S. The application of recommender systems in a multi-site, multi-domain environment. In Proceedings of the 9th ACM Conference on Recommender Systems 2015 Sep 16 (pp. 229-229). Available from: <https://doi.org/10.1145/2792838.2799495>



This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivs 3.0 Unported License.