

UNIVERZITET U BEOGRADU
FAKULTET ORGANIZACIONIH NAUKA

Nastavno-naučnom veću

Predmet: Podobnost teme i kandidata Nikole Svitlice za izradu doktorske disertacije.

Odlukom 05-01 br. 3/72-4 od 10.07.2024. godine, imenovani smo za članove Komisije za ocenu podobnosti teme i kandidata Nikole Svitlice za izradu doktorske disertacije i naučne zasnovanosti teme „**AUTO-ŠILING U SISTEMIMA ZA PREPORUČIVANJE SADRŽAJA**“.

Na osnovu materijala priloženog uz Zahtev kandidata, Komisija podnosi sledeći

R E F E R A T

1. PODACI O KANDIDATU

1.1 Biografski podaci

Nikola Svitlica je rođen 1983. godine u Sarajevu, Bosna i Hercegovina. Diplomirao je na Fakultetu organizacionih nauka, Univerzitet u Beogradu 2008. godine, master studije završava 2011. godine na smeru Operaciona istraživanja radom na temu „Modeliranje i optimizacija plana TV oglašavanja“.

Od 2008. godine radi u komercijalnom sektoru. Trenutno radi za kompaniju „Evermed“ kao softverski inženjer. Kompanija se bavi video/audio strimingom edukativnog materijala namenjenom medicinskim radnicima, gde je problem *auto-šilinga* i identifikovan.

1.2 Stečeno naučnoistraživačko iskustvo

U nastavku će biti predstavljene naučnoistraživačke aktivnosti kandidata. One se odnose na prikaz položenih ispita i objavljene radove u časopisima i na konferencijama.

Sledi prikaz položenih predmeta na doktorskim studijama sa ocenama i ESPB bodovima:

Naziv predmeta	Ocena	ESPB
Vremenska serija i fraktali – odabrana poglavlja	10 (deset)	10
E-uprava – odabrana poglavlja	10 (deset)	10
Stohastički procesi i sistemi	10 (deset)	10
Višekriterijumska optimizacija i odlučivanje	10 (deset)	10
Kombinatorna optimizacija	10 (deset)	10
Nelinearno programiranje	9 (devet)	10
Novi trendovi u operacionim istraživanjima	10 (deset)	10
Statistika u menadžmentu	10 (deset)	10
Multivarijaciona analiza	10 (deset)	10

Svitlica Nikola je 15.07.2024. godine odbranio pristupni rad pod nazivom: „**AUTO-ŠILING U SISTEMIMA ZA PREPORUČIVANJE SADRŽAJA**“.

1.3 Spisak radova

- Milan Stanojević, Dragana Makajić-Nikolić, Nikola Svitlica, Optimizacija plana TV oglašavanja, BALCOR, Mart 2013, FON-OI-01-13
- Kristina Seke, Nikola Svitlica, Marina Jovanović-Milenković, Primena matematičkog modeliranja za nabavku vakcina za dečiju imunizaciju u Srbiji, Symorg 2012

2. OCENA PODOBNOSTI KANDIDATA ZA RAD NA PREDLOŽENOJ TEMI

Na osnovu pokazanih rezultata dosadašnjeg obrazovanja, naučno-istraživačkog rada i profesionalnog iskustva, zaključujemo da je kandidat Svitlica Nikola kvalifikovan da samostalno radi na predloženoj temi doktorske disertacije i načini doprinose u toj oblasti.

3. PROBLEM, PREDMET I CILJ ISTRAŽIVANJA

Predmet istraživanja pristupnog rada je unapređenje sistema za preporučivanje sadržaja („*recommender*“ – eng.) koji se koristi u takvim poslovnim sistemima da:

- Konzumaciju sadržaja karakteriše fenomen multi-modalne konzumacije.
- Za treniranje algoritma mašinskog učenja za preporučivanje sadržaja se koriste vrednosti bazirane pretežno na implicitnoj interakciji (tj. konzumaciji sadržaja).

U multi-modalnoj konzumaciji postoje dva ili više ciljeva koji se ostvaruju konzumacijom sadržaja tako da je u svakom trenutku jedan cilj konzumacije dominantan, dok se konzumacijom, u opštem slučaju, ne ostvaruje više ciljeva istovremeno.

Popularizacija primene mašinskog učenja i razvoja novih algoritama i modela u domenu sistema za preporučivanje sadržaja je usko vezana za razvoj širokopojsnog Interneta. To je omogućilo razvoj i besplatnih i komercijalnih servisa za tzv. multimedijalni striming („*multimedia streaming*“ – eng). Neki od najpoznatiji takvih servisa današnjice su „*Netflix*“ i „*YouTube*“, kao pioniri u ovoj oblasti, zatim „*HBO*“, „*Amazon Prime*“, „*Disney*“, itd.

Za sve navedene servise (kao i za servise sa istim ili sličnim poslovnim modelom) je karakteristično da direktno (na primer, putem pretplate) ili indirektno (na primer, putem oglašavanja) monetizuju konzumaciju sadržaja, te im je stoga jedan od primarnih interesa konzumacija. Jasno je zašto su u takvim biznis modelima sistemi za preporučivanje kritična komponenta. Kvalitetna preporuka sadržaja je direktno povezana sa zaradom.

Sistemi za preporučivanje sadržaja nisu usko vezani samo za konzumaciju audio/video sadržaja. Uspešno se koriste i u Internet trgovini, „*HORECA*“, *onlajn* upoznavanju, servisima za isporuku vesti i sl. Svakako da su mogućnosti novih oblasti primene predmet aktuelnih istraživanja.

Ugrubo, svi pristupi rešavanju problema preporučivanja sadržaja se mogu podeliti u 3 kategorije:

- **Filtriranje na osnovu sadržaja** („*content-based filtering*“ – eng) – polazna osnova ovog pristupa je profil korisnika kome se preporučuje sadržaj i atributi sadržaja (u slučaju video sadržaja, primera radi, mogu biti: naslov, opis, tagovi, klasifikacija i sl.). Profil korisnika se najčešće fokusira na dve osnovne informacije: (1) korisnička podešavanja preferenci (na primer: preferirane kategorije video sadržaja) i (2) istorija korisnikove interakcije sa sistemom preporučivanja i/ili istorijom interakcije sa predmetima preporuke (na primer: spisak svih videa sa odgledanih više od 50% sadržaja). Algoritmi koji se zasnivaju na radu sa navedenim informacijama nastoje da ukrštanjem korisnikovih preferenci, istorijata interakcije i atributa predmeta preporuke predvide koji bi to sledeći predmet bio interesantan za korisnika. Izrada ovakvih sistema, iako najčešće jednostavna, ispoljava svoje mane kroz: (1) pristrasnost sistema ka preporučivanju sadržaja istog tipa koji korisnik uobičajeno konzumira i (2) zahtev za kvalitetno označavanje sadržaja, što u praksi može biti problem.
- **Kolaborativno filtriranje** („*collaborative filtering*“ – eng) – polazi od pretpostavke da osobe sa sličnom istorijom konzumiranja sadržaja (ili ocenom sadržaja) imaju slične potrebe i preference i svode problem na pronalaženje najbližeg suseda. Osnovna prednost algoritama zasnovanih na kolaborativnom filtriranju je u tome što ne zavise od označavanja sadržaja. Kvalitet preporuke uopšte ne zavisi od „razumevanja“ sadržaja od strane algoritma koji generiše preporuke. Međutim, za novog korisnika ili novi predmet u sistemu za preporučivanje, ova familija algoritama ima problem obezbeđivanja kvalitetnih preporuka (tzv. problem „hladnog starta“, „*cold start*“ – eng.). U sistemima sa velikim brojem korisnika i/ili predmeta preporuke, neophodni su značajni kompjuterski resursi za njihov trening, te ih nije jednostavno skalirati. Retkost podataka takođe predstavlja problem za sisteme sa velikim brojem korisnika i/ili predmeta preporuke. Najaktivniji korisnici će u takvim sistemima imati interakciju sa relativno malim brojem predmeta preporuke.
- **Hibridni pristupi** u suštini kombinuju kolaborativno filtriranje, filtriranje na osnovu sadržaja, kao i druge pristupe kako bi prevazišli uobičajene probleme upotrebe samo jednog algoritma sa ciljem dobijanja kvalitetnijih preporuka.

Predmet istraživanja

Najveći izazov za sve algoritme bazirane na kolaborativnom filtriranju je mogućnost malicioznih korisnika (konkurenti, na primer) da uz manji napor dramatično naruše kvalitet preporuka, ili pak utiču na njihovu pristrasnost. Takozvani „*šilling*“ („*shilling attack*“ – eng.) napad se vrlo jednostavno realizuje kroz kreiranje lažnih korisničkih naloga koji svojim ponašanjem utiču na rad sistema za preporučivanje. Praksa je pokazala da je vrlo mali broj lažnih korisnika potreban za značajan uticaj na sistem generisanja preporuka. Uobičajeno, taj broj iznosi od 1-5% ukupnog broja legitimnih korisnika.

Zaštita od *šiling* napada se smatra problemom koji, još uvek, nije uspešno rešen, te je stoga u žiži istraživanja. Robustan sistem za generisanje preporuka baziran na kolaborativnom filtriranju je neophodnost pre svega komercijalnog sektora, čiji su finansijski rezultati u direktnoj zavisnosti.

Uobičajeni pristupi za rešavanje ovog problema se zasnivaju na detekciji i eliminaciji malicioznih, lažnih korisnika, ili korišćenju podataka od potvrđeno nemalicioznih korisnika.

Šiling napad se vezuje isključivo za maliciozne, eksterne korisnike, te se postojeće metode i algoritmi fokusiraju na detekciju istih. Međutim, manje je poznato da pod određenim uslovima, nemaliciozni, regularni korisnici mogu itekako narušiti kvalitet sistema za preporučivanje svojim uobičajenim ponašanjem bez ikakvih malicioznih namera.

Ovaj fenomen će u radu biti prikazan na primeru jednog američkog udruženja medicinskih radnika koje, između ostalog, obezbeđuje i platformu za video *streaming* svojim korisnicima (medicinskim radnicima). Na toj platformi korisnici mogu gledati snimke održanih konferencija. Naziv udruženja, usled ugovornih obaveza, neće biti objavljen. U daljem tekstu udruženje će biti referencirano sa „Udruženje“.

Naime, akreditovana medicinska udruženja periodično organizuju konferencije za svoje članove. Broj članova udruženja, po pravilu, značajno nadmašuje prijemne kapacitete i najvećih konferencija. *Streaming* održanih konferencija je praktično jedini način da se svi medicinski radnici, članovi udruženja, edukuju o novim procedurama, tehnikama, metodama lečenja, i sl.

Prisustvo medicinskih radnika na akreditovanim konferencijama je, prema današnjim pravilima medicinske prakse, obavezno. Medicinski radnici su u obavezi da u toku određenog perioda prikupe određeni broj poena određenog tipa kako bi obnovili svoju licencu za rad kod relevantne institucije (tj. lekarske komore). Svrha ovog procesa je obezbeđivanje kontinuiranog održavanja kompetencija medicinskih radnika.

Uobičajen period za koji se skupljaju poeni i obnavlja licenca je dve godine. Ovaj period može da se razlikuje od države do države. Broj poena koji se prikuplja tokom tog perioda je najčešće 50, ali i ovo se takođe uzima sa rezervom pošto je usko vezano za pravila usvojena u okviru granica jedne zemlje. Postoje, takođe, i različiti tipovi poena (CME, CNE, CPE, itd.) za koje je određena grupa medicinskih radnika zainteresovana, dok druga nije. Primera radi, za poene tipa CNE („*Continuing Nursing Education*“ – eng.) su zainteresovane samo medicinske sestre.

Prisustvo i/ili učešće na svakoj akreditovanoj medicinskoj konferenciji donosi određeni broj poena određenog tipa. Pojedine konferencije uključuju i neki vid polaganja završnog testa za proveru stečenog znanja kao preduslov za dobijanje poena, ali to nije pravilo.

Učešće na konferencijama za većinu medicinskih radnika može biti problematično zbog:

- Ograničenog broja učesnika
- Nedostatka slobodnog vremena usled radnih obaveza
- Visoke cene (cena kotizacije, hotelskog smeštaja, transporta) za lekare na početku karijere
- Drugih individualnih faktora

Naravno pandemija COVID-a je, pre svega, primorala na usvajanje novih tehnologija u okviru ustaljenih poslovnih procesa. Medicinske konferencije su iz tog razloga promenile svoj oblik. Tokom pandemije COVID-a one su održavane isključivo onlajn. U post-COVID periodu medicinska udruženja su uvidela mogućnost primene novih tehnologija kako bi dosegli do većeg broja medicinskih radnika.

Udruženje je takođe izvršilo svoju digitalnu transformaciju i koristi video *streaming* platformu kako bi svim svojim članovima, uz određenu novčanu nadoknadu, obezbedilo pristup snimcima održanih konferencija u proteklih nekoliko godina. Platforma poseduje sofisticiran

sistem za praćenje konzumacije video sadržaja koji je u mogućnosti da izveštava o konzumaciji video zapisa uz preciznost od jedne sekunde, bez preklapanja intervala. Sistem takođe prati i izveštava o ponovnom gledanju istog sadržaja.

Udruženje koristi ovu mogućnost sistema i omogućava korisnicima da svaki sat jedinstvenog gledanja konvertuju u odgovarajuće poene. Princip je vrlo jednostavan – gledanje jednog sata video materijala donosi jedan poen. U ovom trenutku, platforma sadrži 2.700 aktivnih video zapisa sa konferencija. Od tih 2.700, gledanje 2.477 videa se može konvertovati u poene, dok 223 videa ne donosi poene (odnosno 8,26% od ukupnog broja). Za svaki video čije se gledanje može konvertovati u poene, jasno je naznačeno i koji tip poena se može dobiti. Tipovi poena koji su na raspolaganju su, primera radi, CNE (sadržano u 77,19% videa), CPE (sadržano u 71,48% videa), CME (sadržano u 91,85% videa), i sl. Svaki video koji donosi poene može doneti od 3 do 7 različitih tipova poena istovremeno.

S obzirom na specifičan način implementacije sistema praćenja gledanja videa od strane korisnika, svaki korisnik u realnom vremenu može pratiti svoj napredak u prikupljanju neophodnih poena.

Analizom istorijata više od 1.700 korisnika utvrđena su određena pravila ponašanja korisnika:

- Gledanje je intenzivno pri registraciji korisnika i fokusirano na videe koji donose određen tip poena. Takođe, gledanje je intenzivno i na kraju kalendarske godine.
- Nakon jedne do dve sedmice aktivnosti, interesovanje opada.
- Dalje gledanje je sporadično i uključuje videe koji ne nose poene ili nose poene koji inicijalno nisu bili u fokusu.
- Broj poena koji se prikuplja je najčešće jednocifren

Sistem za preporučivanje sadržaja, koji se u ovom trenutku koristi, se zasniva na filtriranju na osnovu sadržaja za novoregistrovane korisnike (kako bi se prevazišao problem „hladnog starta“-a), a nakon toga klasičan sistem za kolaborativno filtriranje baziran na matričnoj faktorizaciji gde su aktivnosti korisnika popunjene na osnovu implicitne interakcije (procenat gledanog videa) u kombinaciji sa impresijama („like“ – eng., „bookmark“ – eng., i sl.).

Na osnovu inicijalne analize istorijata aktivnosti korisnika i sprovedenih kvalitativnih istraživanja, postoje opravdani razlozi za sumnju da je sistem za preporučivanje sadržaja neadekvatan. Pretpostavka je da je kvalitet preporuka izuzetno nizak s obzirom da ne uvažava ponašanje i motivaciju za gledanje videa korisnika. Ponašanje legitimnih korisnika se tokom jedne faze korišćenja platforme može poistovetiti sa malicioznim korisnicima. Interakcija sa platformom je ciljno orijentisana - na prikupljanje poena, te se iz implicitne interakcije ne može jednoznačno zaključiti da li je ta interakcija ujedno i preporuka. Prilikom faze prikupljanja poena korisnik je spreman da odgleda ceo video bez obzira da li ga smatra dovoljno kvalitetnim edukativnim materijalom korisnim za njegovu karijeru. U sledećoj fazi, nakon prikupljanja poena, osnovni motiv za gledanje je usavršavanje/edukacija, kada korisnik ne toleriše nizak nivo kvaliteta video materijala.

Ovakvo ponašanje se može smatrati svojevrsnim *šilingom*. Korišćenjem podataka o aktivnosti korisnika tokom faze prikupljanja poena degradira kvalitet sistema za generisanje preporuka baziranog na kolaborativnom filtriranju. Međutim, pošto se radi o regularnim, nemalicioznim korisnicima, njihovo ponašanje se ne može tretirati kao eksterni, maliciozni, *šiling* napad. Iz

tog razloga, uvodi se novi termin: *auto-šiling*. U ovom trenutku, niti istraživačka zajednica niti komercijalni sektor ne nude rešenje za mitigaciju ovakvog tipa *šilinga*.

Cilj istraživanja

Na osnovu svega prethodno navedenog, kao i na osnovu raspoloživih podataka o aktivnostima korisnika Udruženja, zadaci i ciljevi istraživanja ove doktorske disertacije su:

- Analiza ponašanja korisnika u odnosu na konzumaciju video sadržaja i njihova preraspodela u klastere.
- Identifikacija ključnih tačaka tokom aktivnosti korisnika na platformi u kojima se menjaju njihovi ciljevi, a samim time i ponašanje.
- Modeliranje ponašanja i predviđanje aktivnosti korisnika tokom korišćenja platforme u odnosu na ciljeve.
- Integracija ovog latentnog faktora u model određivanja vrednosti ocena korisnika prilikom konstrukcije matrice faktorizacije. Cilj je da se obezbede kvalitetnija predviđanja poželjnih videa, usklađenim sa trenutnim motivima gledanja korisnika.
- Implementacija takvog modela u postojeću platformu, njegovo testiranje i verifikacija kao i dalja eksploatacija.

Rezultati ovog istraživanja će doneti bolje razumevanje fenomena multi-modalne konzumacije i *auto-šilinga*. Modeliranjem i integracijom bihevijornog latentnog faktora u sisteme za generisanje preporuka ponudiće se metoda za mitigaciju *auto-šiling* napada što će dovesti do robusnijeg i kvalitetnijeg sistema za generisanje preporuka baziranim na kolaborativnom filtriranju.

4. POČETNA LISTA BIBLIOGRAFSKIH IZVORA KOJA ĆE BITI KORIŠĆENA U IZRADI DOKTORSKE DISERTACIJE

1. D. and H. J. and S. S. Schafer J. Ben and Frankowski, "Collaborative Filtering Recommender Systems," in *The Adaptive Web: Methods and Strategies of Web Personalization*, A. and N. W. Brusilovsky Peter and Kobsa, Ed., Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, pp. 291–324. doi: 10.1007/978-3-540-72079-9_9.
2. J. L. Vandergrift, B. M. Gray, and W. Weng, "Do State Continuing Medical Education Requirements for Physicians Improve Clinical Knowledge?," *Health Serv Res*, vol. 53, no. 3, pp. 1682–1701, 2018, doi: <https://doi.org/10.1111/1475-6773.12697>.
3. W. Azmy and O. Emam, "Content-Based Recommendation System Using Search Engine," Apr. 2013.
4. Simon Funk, "Netflix Update: Try This at Home," <https://sifter.org/~simon/journal/20061211.html>.
5. B. Mehta, T. Hofmann, and W. Nejdl, "Robust collaborative filtering," Apr. 2007, pp. 49–56. doi: 10.1145/1297231.1297240.
6. A. Narayanan and V. Shmatikov, "How To Break Anonymity of the Netflix Prize Dataset," Oct. 2006.
7. D. Kaplan, *Structural Equation Modeling (2nd ed.): Foundations and Extensions*, 2nd ed. 2455 Teller Road, Thousand Oaks California 91320 United States : SAGE Publications, Inc., 2009. doi: 10.4135/9781452226576.
8. Tomas Rehorek, Ondrej Biza, Radek Bartyzal, Pavel Kordik, Ivan Povalyev, and Ondrej Podsztaev, "Comparing offline and online evaluation results of recommender systems," in *REVEAL Workshop paper*, RecSyS conference, 2018.

9. M. Chtourou, J.-L. Chandon, and M. Zollinger, "Effect of Price Information and Promotion on Click-Through Rates for Internet Banners," *Journal of Euromarketing*, vol. 11, pp. 23–40, Apr. 2002, doi: 10.1300/J037v11n02_02.
10. S. Attfield, G. Kazai, M. Lalmas, and B. Piwowarski, "Towards a science of user engagement (Position Paper)," Apr. 2011.
11. C. C. Aggarwal, *Recommender Systems*. Cham: Springer International Publishing, 2016. doi: 10.1007/978-3-319-29659-3.
12. J. Lu, D. Wu, M. Mao, W. Wang, and G. Zhang, "Recommender system application developments: A survey," *Decis Support Syst*, vol. 74, pp. 12–32, Jun. 2015, doi: 10.1016/J.DSS.2015.03.008.
13. D. Roy and M. Dutta, "A systematic review and research perspective on recommender systems," *J Big Data*, vol. 9, no. 1, p. 59, 2022, doi: 10.1186/s40537-022-00592-5.
14. Netflix, "<https://web.archive.org/web/20150810220844/http://www.netflixprize.com>."
15. Z. and U. I. Khusro Shah and Ali, "Recommender Systems: Issues, Challenges, and Research Opportunities," in *Information Science and Applications (ICISA) 2016*, N. Kim Kuinam J. and Joukov, Ed., Singapore: Springer Singapore, 2016, pp. 1179–1189.
16. F. Lorenzi, A. L. C. Bazzan, M. Abel, and F. Ricci, "Improving recommendations through an assumption-based multiagent approach: An application in the tourism domain," *Expert Syst Appl*, vol. 38, no. 12, pp. 14703–14714, 2011, doi: <https://doi.org/10.1016/j.eswa.2011.05.010>.
17. A. A. Kardan and M. Ebrahimi, "A novel approach to hybrid recommendation systems based on association rules mining for content recommendation in asynchronous discussion groups," *Inf Sci (N Y)*, vol. 219, pp. 93–110, 2013, doi: <https://doi.org/10.1016/j.ins.2012.07.011>.
18. G. Castellano, A. M. Fanelli, and M. A. Torsello, "NEWER: A system for NEuro-fuzzy WEb Recommendation," *Appl Soft Comput*, vol. 11, no. 1, pp. 793–806, 2011, doi: <https://doi.org/10.1016/j.asoc.2009.12.040>.
19. J.-H. Chang, C.-F. Lai, M.-S. Wang, and T.-Y. Wu, "A cloud-based intelligent TV program recommendation system," *Computers & Electrical Engineering*, vol. 39, no. 7, pp. 2379–2399, 2013, doi: <https://doi.org/10.1016/j.compeleceng.2013.04.025>.
20. D. Ayata, Y. Yaslan, and M. E. Kamasak, "Emotion Based Music Recommendation System Using Wearable Physiological Sensors," *IEEE Transactions on Consumer Electronics*, vol. 64, no. 2, pp. 196–203, 2018, doi: 10.1109/TCE.2018.2844736.
21. H. Li, J. Cui, B. Shen, and J. Ma, "An intelligent movie recommendation system through group-level sentiment analysis in microblogs," *Neurocomputing*, vol. 210, pp. 164–173, 2016, doi: <https://doi.org/10.1016/j.neucom.2015.09.134>.
22. S. Liao and H. Chang, "A rough set-based association rule approach for a recommendation system for online consumers," *Inf Process Manag*, vol. 52, no. 6, pp. 1142–1160, 2016, doi: <https://doi.org/10.1016/j.ipm.2016.05.003>.
23. C. Li, Z. Wang, S. Cao, and L. He, "WLRRS: A new recommendation system based on weighted linear regression models," *Computers & Electrical Engineering*, vol. 66, pp. 40–47, 2018, doi: <https://doi.org/10.1016/j.compeleceng.2018.02.005>.
24. K. Choi, D. Yoo, G. Kim, and Y. Suh, "A hybrid online-product recommendation system: Combining implicit rating-based collaborative filtering and sequential pattern analysis," *Electron Commer Res Appl*, vol. 11, no. 4, pp. 309–317, 2012, doi: <https://doi.org/10.1016/j.elerap.2012.02.004>.
25. D. A. Adeniyi, Z. Wei, and Y. Yongquan, "Automated web usage data mining and recommendation system using K-Nearest Neighbor (KNN) classification method," *Applied Computing and Informatics*, vol. 12, no. 1, pp. 90–108, 2016, doi: <https://doi.org/10.1016/j.aci.2014.10.001>.

26. J. Niu, X. Zhao, L. Zhu, and H. Li, "Affivir: An affect-based Internet video recommendation system," *Neurocomputing*, vol. 120, pp. 422–433, 2013, doi: <https://doi.org/10.1016/j.neucom.2012.07.050>.
27. S. Yang, M. Korayem, K. AlJadda, T. Grainger, and S. Natarajan, "Combining content-based and collaborative filtering for job recommendation system: A cost-sensitive Statistical Relational Learning approach," *Knowl Based Syst*, vol. 136, pp. 37–45, 2017, doi: <https://doi.org/10.1016/j.knosys.2017.08.017>.
28. W.-P. Lee, C.-T. Chen, J.-Y. Huang, and J.-Y. Liang, "A smartphone-based activity-aware system for music streaming recommendation," *Knowl Based Syst*, vol. 131, pp. 70–82, 2017, doi: <https://doi.org/10.1016/j.knosys.2017.06.002>.
29. J. Wei, J. He, K. Chen, Y. Zhou, and Z. Tang, "Collaborative filtering and deep learning based recommendation system for cold start items," *Expert Syst Appl*, vol. 69, pp. 29–39, 2017, doi: <https://doi.org/10.1016/j.eswa.2016.09.040>.
30. H. and L. J. J. and Q. B. and Q. A. K. Liu Wei and Song, "Neural Network Based on Self-adaptive Differential Evolution for Ultra-Short-Term Power Load Forecasting," in *Intelligent Computing in Bioinformatics*, K. and G. M. Huang De-Shuang and Han, Ed., Cham: Springer International Publishing, 2014, pp. 403–412.
31. Y. Koren, "Collaborative filtering with temporal dynamics," in *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2009, pp. 447–456.
32. Z. Zhao *et al.*, "Social-Aware Movie Recommendation via Multimodal Network Learning," *IEEE Trans Multimedia*, vol. 20, no. 2, pp. 430–440, 2018, doi: [10.1109/TMM.2017.2740022](https://doi.org/10.1109/TMM.2017.2740022).
33. B. Ait Hammou, A. Ait Lahcen, and S. Mouline, "An effective distributed predictive model with Matrix factorization and random forest for Big Data recommendation systems," *Expert Syst Appl*, vol. 137, pp. 253–265, 2019, doi: <https://doi.org/10.1016/j.eswa.2019.06.046>.
34. F. Ullah, B. Zhang, and R. U. Khan, "Image-Based Service Recommendation System: A JPEG-Coefficient RFs Approach," *IEEE Access*, vol. 8, pp. 3308–3318, 2020, doi: [10.1109/ACCESS.2019.2962315](https://doi.org/10.1109/ACCESS.2019.2962315).
35. J. Zhao *et al.*, "Attribute mapping and autoencoder neural network based matrix factorization initialization for recommendation systems," *Knowl Based Syst*, vol. 166, pp. 132–139, 2019, doi: <https://doi.org/10.1016/j.knosys.2018.12.022>.
36. D. P. Kingma and M. Welling, "An Introduction to Variational Autoencoders," Jun. 2019, doi: [10.1561/22000000056](https://doi.org/10.1561/22000000056).
37. S. Mondal, A. Basu, and N. Mukherjee, "Building a trust-based doctor recommendation system on top of multilayer graph database," *J Biomed Inform*, vol. 110, p. 103549, 2020, doi: <https://doi.org/10.1016/j.jbi.2020.103549>.
38. G. Ke, H.-L. Du, and Y.-C. Chen, "Cross-platform dynamic goods recommendation system based on reinforcement learning and social networks," *Appl Soft Comput*, vol. 104, p. 107213, 2021, doi: <https://doi.org/10.1016/j.asoc.2021.107213>.
39. A. Sundar, F. Li, X. Zou, T. Gao, and E. Russomanno, "Understanding Shilling Attacks and Their Detection Traits: A Comprehensive Survey," *IEEE Access*, vol. 8, pp. 171703–171715, Apr. 2020, doi: [10.1109/ACCESS.2020.3022962](https://doi.org/10.1109/ACCESS.2020.3022962).
40. R. A. Zayed, L. F. Ibrahim, H. A. Hefny, H. A. Salman, and A. AlMohimeed, "Experimental and Theoretical Study for the Popular Shilling Attacks Detection Methods in Collaborative Recommender System," *IEEE Access*, vol. 11, pp. 79358–79369, 2023, doi: [10.1109/ACCESS.2023.3289404](https://doi.org/10.1109/ACCESS.2023.3289404).
41. B. Mehta, T. Hofmann, and W. Nejdl, "Robust collaborative filtering," Apr. 2007, pp. 49–56. doi: [10.1145/1297231.1297240](https://doi.org/10.1145/1297231.1297240).

42. C. Huang and H. Li, "Single-User Injection for Invisible Shilling Attack against Recommender Systems," in *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*, in CIKM '23. New York, NY, USA: Association for Computing Machinery, 2023, pp. 864–873. doi: 10.1145/3583780.3615062.
43. J. A. N. D. Q. Q. A. N. D. Z. J. A. N. D. C. T. Zhou Wei AND Wen, "Shilling attack detection for recommender systems based on credibility of group users and rating time series," *PLoS One*, vol. 13, no. 5, pp. 1–17, Apr. 2018, doi: 10.1371/journal.pone.0196533.
44. R. Burke, B. Mobasher, C. Williams, and R. Bhaumik, "Classification features for attack detection in collaborative recommender systems," in *Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, in KDD '06. New York, NY, USA: Association for Computing Machinery, 2006, pp. 542–547. doi: 10.1145/1150402.1150465.
45. C. Williams, R. Advisor, and B. Mobasher, "Thesis: Profile Injection Attack Detection for Securing Collaborative Recommender Systems," Apr. 2006.
46. N. Hurley, Z. Cheng, and M. Zhang, "Statistical attack detection," in *Proceedings of the Third ACM Conference on Recommender Systems*, in RecSys '09. New York, NY, USA: Association for Computing Machinery, 2009, pp. 149–156. doi: 10.1145/1639714.1639740.
47. H. Cai and F. Zhang, "Detecting shilling attacks in recommender systems based on analysis of user rating behavior," *Knowl Based Syst*, vol. 177, pp. 22–43, 2019, doi: <https://doi.org/10.1016/j.knosys.2019.04.001>.
48. A. Rashid, G. Karypis, and J. Riedl, "Influence in Ratings-Based Recommender Systems: An Algorithm-Independent Approach," Apr. 2005. doi: 10.1137/1.9781611972757.60.
49. P.-A. Chirita, W. Nejdl, and C. Zamfir, "Preventing shilling attacks in online recommender systems," in *Proceedings of the 7th Annual ACM International Workshop on Web Information and Data Management*, in WIDM '05. New York, NY, USA: Association for Computing Machinery, 2005, pp. 67–74. doi: 10.1145/1097047.1097061.
50. S. K. Lam and J. Riedl, "Shilling recommender systems for fun and profit," in *Proceedings of the 13th International Conference on World Wide Web*, in WWW '04. New York, NY, USA: Association for Computing Machinery, 2004, pp. 393–402. doi: 10.1145/988672.988726.
51. M. O'Mahony, N. Hurley, N. Kushmerick, and G. Silvestre, "Collaborative recommendation: A robustness analysis," *ACM Trans. Internet Technol.*, vol. 4, no. 4, pp. 344–377, Nov. 2004, doi: 10.1145/1031114.1031116.
52. B. Mobasher, R. Burke, R. Bhaumik, and C. Williams, "Effective Attack Models for Shilling Item-Based Collaborative Filtering Systems," *Proceedings of the 2005 WebKDD Workshop, Held in Conjunction with ACM SIGKDD '2005*, Apr. 2005.
53. R. Burke, B. Mobasher, C. Williams, and R. Bhaumik, "Classification features for attack detection in collaborative recommender systems," in *Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, in KDD '06. New York, NY, USA: Association for Computing Machinery, 2006, pp. 542–547. doi: 10.1145/1150402.1150465.
54. C. A. Williams, B. Mobasher, and R. Burke, "Defending recommender systems: detection of profile injection attacks," *Service Oriented Computing and Applications*, vol. 1, no. 3, pp. 157–170, 2007, doi: 10.1007/s11761-007-0013-0.

55. X. Wu *et al.*, “Top 10 algorithms in data mining,” *Knowl Inf Syst*, vol. 14, no. 1, pp. 1–37, 2008, doi: 10.1007/s10115-007-0114-2.
56. W. Zhou, J. Wen, Q. Xiong, M. Gao, and J. Zeng, “SVM-TIA a shilling attack detection method based on SVM and target item analysis in recommender systems,” *Neurocomputing*, vol. 210, pp. 197–205, 2016, doi: <https://doi.org/10.1016/j.neucom.2015.12.137>.
57. W.-Y. and M. B.-H. Han Hui and Wang, “Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning,” in *Advances in Intelligent Computing*, X.-P. and H. G.-B. Huang De-Shuang and Zhang, Ed., Berlin, Heidelberg: Springer Berlin Heidelberg, 2005, pp. 878–887.
58. Y. Freund and R. E. Schapire, “Experiments with a new boosting algorithm,” in *Proceedings of the Thirteenth International Conference on International Conference on Machine Learning*, in ICML’96. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1996, pp. 148–156.
59. S. Lin, Y. Wang, and L. Xu, “Re-scale boosting for regression and classification,” May 2015.
60. Z. Yang, L. Xu, Z. Cai, and Z. Xu, “Re-scale AdaBoost for attack detection in collaborative filtering recommender systems,” *Knowl Based Syst*, vol. 100, pp. 74–88, 2016, doi: <https://doi.org/10.1016/j.knsys.2016.02.008>.
61. K. Bryan, M. O’Mahony, and P. Cunningham, “Unsupervised retrieval of attack profiles in collaborative recommender systems,” in *Proceedings of the 2008 ACM Conference on Recommender Systems*, in RecSys ’08. New York, NY, USA: Association for Computing Machinery, 2008, pp. 155–162. doi: 10.1145/1454008.1454034.
62. Y. Cheng and G. M. Church, “Biclustering of expression data,” *Proc Int Conf Intell Syst Mol Biol*, vol. 8, pp. 93–103, 2000.
63. R. Bhaumik, B. Mobasher, and R. Burke, “A clustering approach to unsupervised attack detection in collaborative recommender systems,” in *Proceedings of the International Conference on Data Science (ICDATA)*, 2011, p. 1.
64. M. Greenacre, P. J. F. Groenen, T. Hastie, A. I. D’Enza, A. Markos, and E. Tuzhilina, “Principal component analysis,” *Nature Reviews Methods Primers*, vol. 2, no. 1, p. 100, 2022, doi: 10.1038/s43586-022-00184-w.
65. C.-Y. Chung, P.-Y. Hsu, and S.-H. Huang, “ β P: A novel approach to filter out malicious rating profiles from recommender systems,” *Decis Support Syst*, vol. 55, no. 1, pp. 314–325, 2013, doi: <https://doi.org/10.1016/j.dss.2013.01.020>.
66. A. Bilge, Z. Ozdemir, and H. Polat, “A Novel Shilling Attack Detection Method,” *Procedia Comput Sci*, vol. 31, pp. 165–174, 2014, doi: <https://doi.org/10.1016/j.procs.2014.05.257>.
67. C. Panagiotakis, H. Papadakis, and P. Fragopoulou, “Unsupervised and supervised methods for the detection of hurriedly created profiles in recommender systems,” *International Journal of Machine Learning and Cybernetics*, vol. 11, no. 9, pp. 2165–2179, 2020.
68. C. Panagiotakis, H. Papadakis, and P. Fragopoulou, “Detection of Hurriedly Created Abnormal Profiles in Recommender Systems,” in *2018 International Conference on Intelligent Systems (IS)*, 2018, pp. 499–506. doi: 10.1109/IS.2018.8710589.
69. Z. Yang, Q. Sun, Y. Zhang, and B. Zhang, “Uncovering anomalous rating behaviors for rating systems,” *Neurocomputing*, vol. 308, pp. 205–226, 2018, doi: <https://doi.org/10.1016/j.neucom.2018.05.001>.
70. Z. Wu, J. Wu, J. Cao, and D. Tao, “HySAD: A semi-supervised hybrid shilling attack detector for trustworthy product recommendation,” *Proceedings of the ACM SIGKDD*

- International Conference on Knowledge Discovery and Data Mining*, Apr. 2012, doi: 10.1145/2339530.2339684.
71. H. Liu, H. Motoda, and L. Yu, "Feature Selection with Selective Sampling.," in *Proceedings of the Nineteenth International Conference on Machine Learning*, Apr. 2002, pp. 395–402.
 72. C. Tong *et al.*, "A shilling attack detector based on convolutional neural network for collaborative recommender system in social aware network," *Computer Journal*, vol. 61, pp. 949–958, Apr. 2018, doi: 10.1093/comjnl/bxy008.
 73. K. Vivekanandan and N. Praveena, "Hybrid convolutional neural network (CNN) and long-short term memory (LSTM) based deep learning model for detecting shilling attack in the social-aware network," *J Ambient Intell Humaniz Comput*, vol. 12, no. 1, pp. 1197–1210, 2021, doi: 10.1007/s12652-020-02164-y.
 74. M. Ebrahimian and R. Kashef, "Detecting Shilling Attacks Using Hybrid Deep Learning Models," *Symmetry (Basel)*, vol. 12, no. 11, 2020, doi: 10.3390/sym12111805.
 75. J. A. N. D. Q. Q. A. N. D. Z. J. A. N. D. C. T. Zhou Wei AND Wen, "Shilling attack detection for recommender systems based on credibility of group users and rating time series," *PLoS One*, vol. 13, no. 5, pp. 1–17, Apr. 2018, doi: 10.1371/journal.pone.0196533.
 76. Z. Wu, J. Wu, J. Cao, and D. Tao, "HySAD: a semi-supervised hybrid shilling attack detector for trustworthy product recommendation," in *Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, in KDD '12. New York, NY, USA: Association for Computing Machinery, 2012, pp. 985–993. doi: 10.1145/2339530.2339684.
 77. A. Al Mosawi, "Lifelong learning for physicians," in *Handbook of Lifelong Learning Developments*, 2009, pp. 213–237.
 78. S. Banerjee, "A survey on Software as a service (SaaS) using quality model in cloud computing." Apr. 2014.
 79. M. Kearns and A. Roth, *The Ethical Algorithm: The Science of Socially Aware Algorithm Design*. Oxford University Press, Incorporated, 2019. [Online]. Available: <https://books.google.com.ar/books?id=sE2jwgEACAAJ>
 80. Sujan Y M, Dr. Shashidhara H R, and Dr. Rohini Nagapadma, "Survey Paper: Framework of REST APIs," *International Research Journal of Engineering and Technology (IRJET)*, vol. 7, no. 6, pp. 1119–1119, 2020.
 81. N. Savani, "State Management in Micro Frontends: Challenges and Strategies," *J Emerg Technol Innov Res*, vol. 10, pp. d477–d481, May 2023.
 82. J. Kouraklis, "MVVM as Design Pattern," 2016. doi: 10.1007/978-1-4842-2214-0_1.
 83. L. Hasan and E. Abuelrub, "Assessing the quality of web sites," *Applied Computing and Informatics*, vol. 9, no. 1, pp. 11–29, 2011, doi: <https://doi.org/10.1016/j.aci.2009.03.001>.
 84. D.-P. Pop and A. Altar Samuel, "Designing an MVC Model for Rapid Web Application Development," *Procedia Eng*, vol. 69, May 2014, doi: 10.1016/j.proeng.2014.03.106.
 85. E. Evans, *Domain-Driven Design: Tackling Complexity in the Heart of Software*. Addison-Wesley, 2004.
 86. B. Choi, G. Yang, and J. Kim, "Implementation of HLS Protocol for an IP Camera," Apr. 2014, pp. 111–114. doi: 10.14257/astl.2014.46.26.
 87. K. Honkanen, O. Toukokuu, T. Tietoliikennetekniikka, and T. Ammattikorkeakoulu, "HTTP live streaming," Apr. 2011.

88. M. Boniol, T. Kunjumen, T. S. Nair, A. Siyam, J. Campbell, and K. Diallo, "The global health workforce stock and distribution in 2020 and 2030: a threat to equity and 'universal' health coverage?," *BMJ Glob Health*, vol. 7, no. 6, Jun. 2022.
89. K. Elleithy, D. Blagovic, W. Cheng, and P. Sideleau, "Denial of Service Attack Techniques: Analysis, Implementation and Comparison," *J Syst Cybern Inf*, vol. 3, pp. 66–71, Apr. 2006.
90. B. M. Michelson, "Event-driven architecture overview," *Patricia Seybold Group*, vol. 2, no. 12, pp. 10–1571, 2006.
91. P. Covington, J. Adams, and E. Sargin, "Deep Neural Networks for YouTube Recommendations," in *Proceedings of the 10th ACM Conference on Recommender Systems*, New York, NY, USA, 2016.
92. X.-S. Yang, "Multi-Objective Optimization," *Nature-Inspired Optimization Algorithms*, pp. 197–211, 2014, doi: 10.1016/B978-0-12-416743-8.00014-2.
93. D. Singh and B. Singh, "Feature wise normalization: An effective way of normalizing data," *Pattern Recognit*, vol. 122, p. 108307, 2022, doi: <https://doi.org/10.1016/j.patcog.2021.108307>.
94. Kane Andrew, "Disco PHP," <https://github.com/ankane/disco-php>.
95. C.-J. Lin, W.-S. Chin, A. Kane, M. Bal, and M.-Y. Yang, "LIBMF," <https://github.com/cjlin1/libmf>.
96. H. Lee, S. Yoo, D. Lee, and J. Kim, "How Important is Periodic Model update in Recommender System?," in *Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval*, in SIGIR '23. New York, NY, USA: Association for Computing Machinery, 2023, pp. 2661–2668. doi: 10.1145/3539618.3591934.
97. P. Singh, P. Dutta Pramanik, M. Sardar, A. Nayyar, M. Masud, and P. Choudhury, "Generating A New Shilling Attack for Recommendation Systems," *Computers, Materials and Continua*, vol. 71, pp. 2827–2846, Apr. 2021, doi: 10.32604/cmc.2022.020437.
98. K. Chen, P. P. K. Chan, F. Zhang, and Q. Li, "Shilling attack based on item popularity and rated item correlation against collaborative filtering," *International Journal of Machine Learning and Cybernetics*, vol. 10, no. 7, pp. 1833–1845, 2019, doi: 10.1007/s13042-018-0861-2.
99. R. Burke, B. Mobasher, R. Bhaumik, and C. Williams, "Segment-based injection attacks against collaborative filtering recommender systems," in *Fifth IEEE International Conference on Data Mining (ICDM'05)*, 2005, pp. 4 pp.-. doi: 10.1109/ICDM.2005.127.
100. A. Ray Sanjog and Mahanti, "Strategies for Effective Shilling Attacks against Recommender Systems," in *Privacy, Security, and Trust in KDD*, E. and J. W. and M. B. Bonchi Francesco and Ferrari, Ed., Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, pp. 111–125.
101. S. K. and P. R. K. Samaiya Noopur and Raghuwanshi, "Shilling Attack Detection in Recommender System Using PCA and SVM," in *Emerging Technologies in Data Mining and Information Security*, P. and M. J. K. and B. A. and D. S. Abraham Ajith and Dutta, Ed., Singapore: Springer Singapore, 2019, pp. 629–637.
102. R. Hoyle and C. St, *Handbook of Structural Equation Modeling*. 2022.
103. D. J. Bartholomew, "Factor Analysis and Latent Structure: Overview," *International Encyclopedia of the Social & Behavioral Sciences*, pp. 5249–5254, 2001, doi: 10.1016/B0-08-043076-7/00425-3.
104. C. Lleras, "Path Analysis," *Encyclopedia of Social Measurement, Three-Volume Set*, vol. 3, pp. V3-25-V3-30, Jan. 2004, doi: 10.1016/B0-12-369398-5/00483-7.

105. Y. Rosseel, "lavaan: An R Package for Structural Equation Modeling," *J Stat Softw*, vol. 48, no. 2, pp. 1–36, 2012, doi: 10.18637/jss.v048.i02.
106. Y. Rosseel *et al.*, "<https://lavaan.ugent.be>."
107. L. Mihic, "Strukturalno modelovanje razlika aritmetičkih sredina: polne razlike na latentnim dimenzijama pozitivnog i negativnog afektiviteta," *Primenjena psihologija*, vol. 4, p. 377, May 2011, doi: 10.19090/pp.2011.4.377-392.
108. M. Sugiyama, "Statistical Estimation," *Introduction to Statistical Machine Learning*, pp. 91–98, 2016, doi: 10.1016/B978-0-12-802121-7.00020-0.
109. M. F. Z. B. B. C. P. de Rooij Julian D. Karch and H. Kelderman, "SEM-Based Out-of-Sample Predictions," *Struct Equ Modeling*, vol. 30, no. 1, pp. 132–148, 2023, doi: 10.1080/10705511.2022.2061494.
110. J. Evermann and M. Tate, "Assessing the predictive performance of structural equation model estimators," *J Bus Res*, vol. 69, no. 10, pp. 4565–4582, 2016, doi: <https://doi.org/10.1016/j.jbusres.2016.03.050>.
111. J. F. Hair Jr, L. M. Matthews, R. L. Matthews, and M. Sarstedt, "PLS-SEM or CB-SEM: updated guidelines on which method to use," *International Journal of Multivariate Data Analysis*, vol. 1, no. 2, pp. 107–123, 2017.
112. M. Sarstedt, J. F. Hair, C. M. Ringle, K. O. Thiele, and S. P. Gudergan, "Estimation issues with PLS and CBSEM: Where the bias lies!," *J Bus Res*, vol. 69, no. 10, pp. 3998–4010, 2016, doi: <https://doi.org/10.1016/j.jbusres.2016.06.007>.
113. G. Shmueli, S. Ray, J. M. Velasquez Estrada, and S. B. Chatla, "The elephant in the room: Predictive performance of PLS models," *J Bus Res*, vol. 69, no. 10, pp. 4552–4564, 2016, doi: <https://doi.org/10.1016/j.jbusres.2016.03.049>.
114. Z. Meng, R. McCreadie, C. Macdonald, and I. Ounis, "Exploring Data Splitting Strategies for the Evaluation of Recommendation Models," Jul. 2020, Accessed: Apr. 14, 2024. [Online]. Available: <https://arxiv.org/pdf/2007.13237.pdf>
115. S. Pothuganti, "Review on over-fitting and under-fitting problems in Machine Learning and solutions," *International Journal of Advanced Research in Electrical Electronics and Instrumentation Engineering*, vol. 7, pp. 3692–3695, Apr. 2018, doi: 10.15662/IJAREEIE.2018.0709015.
116. P. Castells and A. Moffat, "Offline recommender system evaluation: Challenges and new directions," *AI Mag*, vol. 43, no. 2, pp. 225–238, 2022, doi: <https://doi.org/10.1002/aaai.12051>.
117. F. del Olmo and E. Gaudioso, "Evaluation of recommender systems: A new approach," *Expert Syst. Appl.*, vol. 35, pp. 790–804, Apr. 2008, doi: 10.1016/j.eswa.2007.07.047.
118. A. Gunawardana and G. Shani, "A Survey of Accuracy Evaluation Metrics of Recommendation Tasks," *J. Mach. Learn. Res.*, vol. 10, pp. 2935–2962, Dec. 2009.
119. B. Hambling and P. van Goethem, "User acceptance testing: a step-by-step guide." BCS, Swindon, U.K., 2013. [Online]. Available: <http://www.books24x7.com/marc.asp?bookid=54103>

5. HIPOTEZE I ZADACI U ISTRAŽIVANJU

Osnovna hipoteza koja će biti predmet istraživanja je:

Legitimni, nemaliciozni korisnici pod određenim uslovima svojim aktivnostima mogu generisati takav skup podataka da se njihovom inkluzijom u sistem za generisanje preporuka koji je baziran na kolaborativnom filtriranju, performanse sistema mogu izjednačiti sa sistemima koji su pretrpeli *šiling* napad od strane eksternih, malicioznih korisnika.

Identifikacijom interakcija korisnika sa predmetima preporučivanja koje nisu u direktnoj korelaciji sa kvalitetom konzumiranog sadržaja i njihovom eliminacijom iz sistema za generisanje preporuka se može rešiti pomenuti problem.

Dokazivanje osnovne hipoteze će biti izvršeno verifikacijom posebnih (pomoćnih) hipoteza:

H1 - U poslovnim sistemima koji koriste sisteme za preporučivanje sadržaja čiji korisnici ispoljavaju multi-modalni fenomen konzumacije, ponašanje korisnika je u skladu sa trenutnim dominantnim ciljem.

H2 - Modeliranjem ovakvog ponašanja i integracijom modela u sistem za generisanje preporuka koji je baziran na kolaborativnom filtriranju postiže se bolji kvalitet preporuka.

H3 - Metode za mitigaciju dobro poznatih eksternih *šiling* napada nisu primenljive u slučaju *auto-šilinga*. Eliminacijom korisnika koji su izvor *auto-šilinga* se eliminišu legitimni korisnici čije interakcije ne mogu koristiti za predviđanje preporuka, a samim tim se ni njima ne može preporučivati sadržaj.

6. NAUČNE METODE ISTRAŽIVANJA

Od opštih naučnih metoda koje će biti korišćene za izradu ovog rada se pre svega izdvajaju statističke metode za obradu i analizu podataka, sa ciljem utvrđivanja i modeliranja ponašanja pojedinih klastera korisnika, zatim metoda eksperimenta kojom će se testirati i verifikovati prethodno navedene hipoteze.

Primenom matematičkih i statističkih alata, pre svega strukturalnog modelovanja („*structural equation modeling*“ - eng), uočeno ponašanje korisnika će biti predstavljeno modelom pogodnim za njegovu integraciju u sistem za preporučivanje sadržaja baziranom na kolaborativnom filtriranju.

Dobijena saznanja iz faze analize podataka i modeliranja ponašanja će biti iskorišćena za implementaciju unapređenog, robusnog sistema za preporučivanje sadržaja koji će se oslanjati na algoritam matrične faktorizacije. Cilj ovakvog sistema je mitigacija *auto-šilinga* i generisanje boljih preporuka za korisnika.

U eksperimentalnom delu istraživanja, postojeća platforma će biti modifikovana sa ciljem sprovođenja A/B testiranja u trajanju od 30 kalendarskih dana gde će performanse i kvalitet preporuka unapređenog sistema za preporučivanje sadržaja biti upoređene sa postojećim, i to na sledeći način:

- Svi korisnici (postojeći i budući) će biti podeljeni u dve grupe na osnovu jedinstvenog identifikatora (parni i neparni broj).
- Prvoj grupi korisnika će biti uvek ponuđene preporuke na osnovu postojećeg sistema za preporučivanje sadržaja, dok će drugoj grupi biti nuđene preporuke na osnovu unapređenog, novog sistema.
- Interfejs platforme će biti modifikovan da registruje klikove na objekte od interesa, tj. na linkove videa koji se nalaze u sekciji preporučenih videa i linkove videa koji se nalaze u ostalim sekcijama.

Metrika koja će se koristiti prilikom utvrđivanja kvaliteta unapređenog sistema za preporučivanje sadržaja u odnosu na postojeći je broj otvorenih videa i procenat pregledanog materijala iz sekcije preporučenih videa po korisniku.

Istraživanje će biti obavljeno na primeru prethodno pomenutog Udruženja i podataka o aktivnostima koje su generisali njegovi korisnici. Dostavljena baza podataka sadrži 2.700 aktivnih video zapisa, 1.700 aktivnih korisnika, 130.000 zapisa u vezi sa konzumacijom korisnika sa preciznošću na nivou jedne sekunde i 6.200 registrovanih impresija („like“ i „bookmark“ – eng.) korisnika.

Hipoteze date u radu će se smatrati potvrđenima i istraživanje uspešnim ukoliko se po završetku A/B testiranja utvrdi da je unapređeni sistem za preporučivanje sadržaja generisao više otvaranja videa iz sekcije preporučenih videa i veći procenat pregledanog materijala po korisniku u odnosu na postojeći sistem.

7. OČEKIVANI DOPRINOSI ISTRAŽIVAČKOG RADA

Očekivani naučni doprinosi istraživanja se ogledaju u:

- Identifikaciji novog tipa šilinga, auto-šilinga, kao i neophodnih preduslova koji moraju biti zadovoljeni kako bi se nemaliciozni korisnici ponašali kao izvor interakcija kojima se degradiraju performanse sistema za preporučivanje sadržaja.
- Razvoj modela i algoritma za mitigaciju auto-šilinga.
- Verifikaciji modela i algoritma za mitigaciju auto-šilinga kroz njegovu praktičnu primenu u produkcionom okruženju na platformi Udruženja gde je problem auto-šilinga i identifikovan.

Očekivani društveni doprinosi istraživanja se ogledaju u podizanju nivoa kvaliteta generisanih preporuka poslovnim sistemima koji koriste sisteme za preporučivanje sadržaja koji su podložni *auto-šilingu*. Kako su to pre svega platforme za distribuciju sadržaja edukativnog karaktera, to podrazumeva isporuku kvalitetnijeg edukativnog materijala korisnicima.

Rezultati istraživanja koji nastanu u toku izrade doktorske disertacije biće saopšteni na naučnim istručnim skupovima u zemlji i inostranstvu i objavljeni u časopisima međunarodnog značaja.

8. PLAN ISTRAŽIVANJA I STRUKTURA RADA

Plan istraživanja

Okvirni plan istraživanja po fazama je dat u tabeli ispod:

#	Faza	Zadatak	Metode, tehnike i standardi
1.	Analiza dosadašnjeg istraživanja	Prikupljanje informacija o dosadašnjim istraživanjima u vezi sa kolaborativnim filtriranjem i šiling napadima	Pretraživanje stručne literature i objavljenih naučnih radova, pretraživanje kredibilnih resursa
2.	Analiza i obrada podataka o aktivnostima korisnika	Utvrđivanje uzroka, zakonitosti i šablona ponašanja korisnika sa ciljem razumevanja njihovog ponašanja prilikom konzumacije sadržaja	Standardni statistički metodi i alati koji uključuju (ali nisu ograničeni na) klaster analizu, faktorsku analizu, stablo odlučivanja, itd.
3.	Razvoj matematičko/statističkog modela za određivanje vrednosti ocena korisnika za sadržaj koji uključuje i mitigaciju <i>auto-šilinga</i>	Određivanje udela latentnih faktora sadržanih u konzumaciji sadržaja jednog korisnika kojim se utvrđuje i objašnjava trenutni motiv tog korisnika za trenutnu konzumaciju sadržaja	Modeliranje vrednosti korišćenjem istorije aktivnosti korisnika primenom strukturalne analize (" <i>structural equation modeling</i> " - eng.)
4.	Implementacija unapređenog sistema za preporučivanje sadržaja	Implementacija unapređenog sistema za preporučivanje sadržaja koji se bazira na matričnoj faktorizaciji i uključuje model za mitigaciju <i>auto-šilinga</i> definisanom u fazi 3.	Implementacija programskih rutina i algoritma
5	Implementacija sistema za praćenje korisničke interakcije sa interfejsom	Implementacija sistema za praćenje korisničke interakcije sa interfejsom	Implementacija niza programskih modula korišćenjem jezika PHP i JavaScript
6.	Beta testiranje	Rana evaluacija modela u okviru produkcionog okruženja definisanog u fazi 3 uz eventualna iterativno-inkrementalna poboljšanja.	Analiza korisničke interakcije korišćenjem standardnih statističkih metoda
7.	Primena i A/B testiranje	Evaluacija modela u okviru produkcionog okruženja pri samom puštanju novog video materijala u etar.	Monitoring
8.	Obrada podataka, analiza i donošenje zaključka	Analiza rezultata iz A/B testiranja i utvrđivanje	Analiza korisničke interakcije korišćenjem

		uspešnosti modela predloženog u fazi 3. i 6.	standardnih statističkih metoda
9.	Publikacija rezultata istraživanja i izrada doktorske disertacije		

Struktura istraživanja

Okvirni sadržaj doktorske disertacije je:

1. Uvod
 - a. Definisanje predmeta istraživanja
 - b. Ciljevi istraživanja
 - c. Polazne hipoteze
 - d. Struktura i organizacija rada
2. Sistemi za preporučivanje sadržaja
3. Šiling napad
4. Kontekst problema
 - a. Opis poslovnog modela medicinskih udruženja i kontinuiranog medicinskog učenja
 - b. Digitalna transformacija poslovanja medicinskih udruženja i transfer dela poslovanja na *online streaming* platforme
 - c. Sistem za praćenje gledanja videa i opis trenutnog sistema koji se koristi za generisanje preporuka
 - d. Nedostaci i mane postojećeg sistema – *auto-šiling*
5. Razvoj robusnog sistema za preporučivanje sadržaja otpornog na *auto-šiling*
 - a. Analiza i obrada postojećih podataka
 - b. Izrada modela za mitigaciju auto-šiling napada
 - c. Integracija u postojeći sistem za generisanje preporuka
6. Testiranje
 - a. Implementacija A/B testiranja postojećeg i unapređenog sistema za generisanje preporuka
 - b. Implementacija sistema za prikupljanje korisničkih interakcija za merenje performansi sistema tokom testiranja
 - c. Obrada podataka i izveštaj o rezultatima testiranja
7. Naučni i stručni doprinosi i buduća istraživanja
8. Zaključak

9. ZAKLJUČAK I PREDLOG

Uvidom u profesionalne, akademske i istraživačke kvalifikacije i kompetencije kandidata Svitlice Nikole, potpisani članovi Komisije su saglasni da ovaj kandidat ispunjava sve predušlove za rad na predloženoj temi doktorske disertacije. Članovi Komisije su takođe mišljenja da su predloženi ciljevi, hipoteze, metode, plan i struktura dokorskog istraživanja konzistentni s prethodno definisanim predmetom i problemom dokorskog istraživanja, kao i da logično slede rezultate pristupnog rada koji je kandidat Svitlica Nikola odbranio pred ovom Komisijom 15.07.2024. godine.

Članovi Komisije su saglasni i predlažu da se kandidatu Svitlici Nikoli odobri izrada doktorske disertacije pod nazivom „**AUTO-ŠILING U SISTEMIMA ZA PREPORUČIVANJE SADRŽAJA**“.

Uža naučna oblast teme je: Operaciona istraživanja.

Za mentora se predlaže: prof. dr Milan Stanojević.

Prof. dr Milan Stanojević ispunjava sve uslove akreditacionih pravila visokoškolskih ustanova i dopunske kriterijume. Radovi koje je mentor objavio u poslednjih deset godina, a koji su u vezi s naučnom oblašću disertacije, priloženi su uz ovaj referat.

U Beogradu, 15.07.2024. godine

MENTOR

Prof. dr Milan Stanojević

redovni profesor, Fakultet organizacionih nauka, Univerzitet u Beogradu

ČLANOVI KOMISIJE

Prof. dr Zoran Radojčić

redovni profesor, Fakultet organizacionih nauka, Univerzitet u Beogradu

Prof. dr Miloš Jovanović

vandredni profesor, Fakultet organizacionih nauka, Univerzitet u Beogradu

Prof. dr Bojan Jovanović

vandredni profesor, Fakultet organizacionih nauka, Univerzitet u Beogradu

Prof. dr Svjetlana Janković Šoja

vandredni profesor, Poljoprivredni fakultet, Univerzitet u Beogradu