

GRAF NEYRON TARMOQLARI VA MUSTAHKAMLASH USULLARINI BIRLASHTIRIB, TAVSIYALAR TIZIMLARINING SAMARADORLIGINI YAXSHILASH

A.N. Sharifbayev, H.N. Zayniddinov

Muhammad al-Xorazmiy nomidagi

Toshkent axborot texnologiyalari universiteti (TATU)

Annotatsiya: Mazkur ishda tavsiyalar tizimlarini yaxshilash uchun graf neyron tarmoqlari (GNN) va mustahkamlash bilan o‘rganish (RL) usullarini integratsiyalash o‘rganiladi. Tadqiqotning maqsadi – GNN-RL asosida yangi gibridd model yaratish bo‘lib, bu model sohadagi hozirgi eng yaxshi natijalardan yuqori ko‘rsatkichlarga erishishni maqsad qiladi. Ishda eng yaxshi deb topilgan uchta GNN modeli ularning samaradorligi va innovatsion xususiyatlariga ko‘ra baholanadi, va ular mavjud RL usullari bilan integratsiya qilinadi. Gowalla, Yelp va Amazon-books kabi bir nechta real ma'lumotlar to‘plamlari asosida o‘tkazilgan tahlil turli GNN arxitekturalari va ularning modifikatsiyalari tavsiyalar tizimlarining samaradorligiga qanday ta'sir qilishini ko‘rsatadi. Ish natijalari tavsiyalarning sifati va samaradorligi sezilarli darajada yaxshilangani, bu sohada kelajakda olib boriladigan tadqiqotlar uchun yangi istiqbollari ochayotganini namoyish etadi.

Kalit so‘zlar: Gowalla, Yelp, GNN, GNN-RL, XSimGCL, GFormer, AutoCF

Mavzudagi tadqiqotni samarali o'rganish uchun uchta muhim tadqiqot savolini qo'yamiz:

1. Turli graf neyron tarmoqlari (GNN) arxitekturalari va ularning modifikatsiyalari tavsiyalar tizimlarining samaradorligiga turli real ma'lumotlar to‘plamlarida qanday ta'sir ko'rsatadi?
2. Graf neyron tarmoqlari (GNN) va mustahkamlash bilan o‘rganish (RL) usullarining integratsiyasi tavsiyalar sifatini va samaradorligini sezilarli darajada yaxshilashi mumkinmi, va shu orqali sohadagi eng yaxshi modellardan (SOTA) ustun natijalarga erishish mumkinmi?

3. Tavsiyalar tizimlarida maksimal samaradorlikka erishish uchun gibrid GNN-RL modellarining qaysi optimal konfiguratsiyalari va modifikatsiyalari talab qilinadi?

Tadqiqotimiz eng yaxshi (SOTA) graf neyron tarmoqlari modellari tanlashdan boshlanadi, xususan quyidagi modellarga e'tibor qaratamiz: **LightGCL**[1], **XSimGCL**[2], **GFormer**[3], **AutoCF**[4] va **MGDCF**[5]. Bu modellarning har biri o'ziga xos innovatsion xususiyatlarga ega bo'lib, tavsiyalar tizimlarining samaradorligini oshirishda muhim ahamiyatga ega.

Biz ushbu modellarni yaxshilashda "skip-connection" deb ataladigan maxsus usuldan foydalandik, bu modelning o'rganish va ma'lumotlarni eslab qolish qobiliyatini yaxshilashga yordam beradi. Bu g'oya avvalgi tadqiqotlar [6] asosida ishlab chiqilgan bo'lib, ular ushbu ulanishlar qanchalik samarali bo'lishini ko'rsatgan. Biz takomillashtirilgan modellarimiz nomlariga "-Skip" qo'shimchasini kiritdik (masalan, **LightGCL-Skip**), shunda ular nafaqat ma'lumotlarni yaxshiroq qayta ishlaydi, balki ancha aniqroq tavsiyalarni ham ishlab chiqadi, deb kutmoqdamiz. Biz ushbu modellarni turli versiyalarda taqqoslab, eng samarali uchta modelni tanlaymiz. Ushbu uch model keyingi bosqichlarda mustahkamlash bilan o'rganish (RL) usullaridan foydalangan holda yanada nozik sozlanadi. Bu bizning asosiy maqsadimiz – GNN va RL o'rtasidagi optimal integratsiyani topish orqali tavsiyalar tizimlarining umumiy sifatini oshirishdir.


Model o'rgatilgandan so'ng, foydalanuvchilar va mahsulotlarning vektorli tasvirlari (embeddings) mustahkamlash bilan o'rganish (RL) algoritmidagi holatning bir qismi sifatida qo'llaniladi. Bunday yondashuv RL algoritmining samaradorligini sezilarli darajada oshirishi mumkin, chunki foydalanuvchilar va mahsulotlarning vektorli tasvirlari haqidagi ma'lumotlarni o'z ichiga olgan holatlar qaror qabul qilish uchun chuqurroq kontekst beradi. Bunday yondashuvlar [7]-maqolada ham o'rganilgan va yaxshi natijalar ko'rsatgan. Bizning tadqiqotimizda biz DQN algoritmining o'zgartirilgan versiyasi — qo'shaloq chuqur Q-tarmoq (DDQN) usulidan foydalanamiz. Ushbu usul asosiy DQN versiyasida ko'p uchraydigan harakatlarni ortiqcha baholashdan qochish imkonini beradi va barqarorroq

ZAMONAVIY TARAQQIYOTDA ILM-FAN VA MADANIYATNING O‘RNI’

natijalarni ta'minlaydi. Xatolik funksiyasi sifatida biz DDQN'dagi an'anaviy yo‘qotish funksiyasining quyidagi tenglamasini ishlatamiz:

$$L_{DDQN}(\theta) = \mathbb{E}_{(s,a,s')} \left[\left(r + \gamma Q \left(s', \arg \max_a Q(s', a; \theta); \theta' \right) - Q(s, a; \theta) \right)^2 \right] \quad (1)$$

Bu yerda: s — muhitning joriy holati; a — agent tomonidan s holatida tanlangan harakat; r — s holatida a harakatini bajargandan keyin olingan mukofot; s' — a harakati bajarilgandan so‘ng muhitning yangi holati; γ — diskont koeffitsienti bo‘lib, u kelajakdagi mukofotlarning hozirgi qarorga ta’sirini kamaytirish uchun ishlatiladi; $Q(s', a; \theta)$ — yangi s' holati va barcha mumkin bo‘lgan a harakatlari uchun Q funksiyasining qiymati, hozirgi tarmoq parametrlaridan θ foydalaniladi; $\arg \max Q(s', a; \theta)$ — yangi s' holatida Q funksiyasining qiymatini maksimal darajada oshiradigan a harakatini tanlash operatsiyasi, bunda yana hozirgi tarmoq parametrlaridan θ foydalaniladi; θ' — tarmoq parametrlari bo‘lib, ular odatda θ dan kamroq tez-tez yangilanadi va bu o‘rganish barqarorligini ta'minlaydi.



1-Rasm. Har bir ma'lumotlar to'plami uchun o'qitish epochlari davomida NDCG@20 qiymati

Olingan natijalarni tahlil qilish orqali ayrim xulosalar chiqarish mumkin. Gowalla ma'lumotlar to‘plamida eng yaxshi natijalarni XSimGCL va MGDF-Skip ko‘rsatdi, Yelp va Amazon-books to‘plamlarida esa eng yuqori ko‘rsatkichlarni XSimGCL-Skip va AutoCF modellariga erishdi. Shuningdek, skip-connection qo‘llanilishi modellar sifatini yaxshilaganini ko‘rish mumkin. Bu ta’sir ayniqsa LightGCL uchun Gowalla ma'lumotlar to‘plamida sezilarli bo‘ldi. Bundan tashqari, skip-connection modifikatsiyasi qo‘llanilganda tez yaqinlashish effekti kutilganidek kuzatildi. Ushbu hodisani 1-rasmda ko‘rish mumkin. Olingan natijalar asosida biz eng samarali uchta modelni tanlashga qaror qildik: MGDF-Skip, XSimGCL-Skip va AutoCF. Ushbu modellarni mustahkamlash bilan o‘rganish usuli yordamida yanada takomillashtirishni davom ettiramiz.

Adabiyotlar

1. Xuheng Cai, Chao Huang, Lianghao Xia, Xubin Ren, "LightGCL: Simple Yet Effective Graph Contrastive Learning for Recommendation," The Eleventh International Conference on Learning Representations. ICLR, 2023.
2. Yu J. et al. XSimGCL: Towards extremely simple graph contrastive learning for recommendation //IEEE Transactions on Knowledge and Data Engineering. – 2023.
3. Chaoliu Li, Lianghao Xia, Xubin Ren, Yaowen Ye, Yong Xu, and Chao Huang. 2023 Graph Transformer for Recommendation. In Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '23)
4. Xia L. et al. Automated self-supervised learning for recommendation //Proceedings of the ACM Web Conference 2023. – 2023. – c. 992-1002.
5. Jun Hu, Bryan Hooi, Shengsheng Qian, Quan Fang, Changsheng Xu, "MGDCF: Distance Learning via Markov Graph Diffusion for Neural Collaborative Filtering," IEEE Transactions on Knowledge and Data Engineering. IEEE, 2024.
6. Gerasimova O., Severin N., Makarov I. Comparative Analysis of Logic Reasoning and Graph Neural Networks for Ontology-Mediated Query Answering with a Covering Axiom //IEEE Access. – 2023.
7. Hongyang Liu, Zhu Sun b, Xinghua Qu, Fuyong Yuan, Top-aware recommender distillation with deep reinforcement learning. Information Sciences, 2021, pp. 642–657