

ВИКОРИСТАННЯ СТАНДАРТНИХ МЕТРИК ДЛЯ ОЦІНКИ ЯКОСТІ РЕКОМЕНДАЦІЙ ПРИ ВПРОВАДЖЕННІ НЕЙРОННОЇ МЕРЕЖІ В ПЛАТФОРМУ ДЛЯ РЕКОМЕНДАЦІЇ ВИБІРКОВИХ ОСВІТНІХ КОМПОНЕНТІВ

Палій Андрій, Анатолій Федонюк

USING STANDARD METRICS TO ASSESS THE QUALITY OF RECOMMENDATIONS WHEN IMPLEMENTING A NEURAL NETWORK INTO A PLATFORM FOR RECOMMENDING SELECTED EDUCATIONAL COMPONENTS

Andiri Palii, Anatolii Fedoniuk

Волинський національний університет імені Лесі Українки
просп. Волі, 13, Луцьк, 43025, Україна

Abstract. *The paper presents a neural network-based approach to building a personalized recommendation system for elective academic components. The proposed model combines embeddings of students and courses, capturing latent features such as interests, difficulty levels, and content categories. A multi-layer neural architecture processes student-course pairs to estimate the probability of student interest. The system is trained using historical selection data and optimized with a binary cross-entropy or ranking loss. Evaluation uses standard Top-N recommendation metrics, including Precision@10, Recall@10, Mean Average Precision (MAP), and NDCG@10. Experimental results show significantly improved recommendation accuracy compared to classical collaborative and content-based filtering methods.*

У сучасній вищій освіті студенти мають можливість самостійно формувати частину освітньої траєкторії шляхом вибору вибіркового освітнього компонента (ВОК). Така гнучкість створює запит на цифрові інструменти, які здатні підтримати індивідуалізоване прийняття рішень. Одним із найперспективніших рішень є впровадження рекомендаційної системи, що базується на глибокій нейронній мережі, яка прогнозує найрелевантніші курси для кожного студента. Проте впровадження таких моделей вимагає чіткої системи оцінювання їх ефективності. У цьому контексті важливою є побудова методики, що ґрунтується на застосуванні стандартних метрик оцінки якості рекомендацій.

У дослідженні запропоновано модель на основі Neural Collaborative Filtering (NCF) з кількома щільними шарами, що приймає на вхід ембеддинги студентів та курсів. Метою є передбачити ймовірність того, що студент обере певний ВОК. Для оцінки якості таких передбачень було використано поширені в галузі метрики: $Precision@K$, $Recall@K$, $NDCG@K$, а також $Mean Average Precision (MAP)$. [2]

$Precision@10$ – визначає частку релевантних вибіркового освітнього компонента (ВОК) серед перших 10 рекомендованих. Високе значення свідчить про точність рекомендацій.

$Recall@10$ – відображає, яку частку всіх можливих релевантних ВОК вдалося охопити у топ-10 рекомендаціях. Важлива для оцінки повноти результату.

$Mean Average Precision (MAP)$ – усереднена метрика точності, яка враховує позицію кожного релевантного елемента у списку. MAP краще відображає загальну якість ранжування при наявності кількох релевантних об'єктів.

NDCG@10 (Normalized Discounted Cumulative Gain) – враховує не лише наявність релевантних БОК, але й їх порядок у списку. Надає вищу вагу релевантним рекомендаціям, які розташовані ближче до початку списку.[3]

Усі ці метрики було застосовано до тестової вибірки, щоб забезпечити об'єктивну оцінку рекомендаційної здатності моделі. Нейронна архітектура демонструє значну перевагу за MAP і NDCG, що свідчить про ефективне ранжування, а також конкурентні значення Precision@10 та Recall@10 порівняно з базовими моделями.

Метрики було обрано з урахуванням специфіки освітніх рекомендацій: обмеженого списку курсів, важливості точності та збереження академічної автономії студента. Застосування кількох комплементарних метрик дозволяє отримати комплексне уявлення про поведінку моделі в реальних умовах.[4]

Отримані результати свідчать, що стандартизовані метрики є не лише засобом оцінки, а й інструментом налаштування і вдосконалення рекомендаційної системи. У перспективі планується впровадження цих метрик у навчальну платформу в реальному часі, з можливістю відслідковування динаміки якості рекомендацій в залежності від зміни поведінки користувачів.

Бібліографія

1. He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). *Neural Collaborative Filtering*. In Proceedings of the 26th International Conference on World Wide Web (WWW '17). <https://doi.org/10.1145/3038912.3052569>
2. Cremonesi, P., Koren, Y., & Turrin, R. (2010). *Performance of Recommender Algorithms on Top-n Recommendation Tasks*. In Proceedings of the Fourth ACM Conference on Recommender Systems.
3. Järvelin, K., & Kekäläinen, J. (2002). *Cumulated gain-based evaluation of IR techniques*. ACM Transactions on Information Systems (TOIS), 20(4), 422–446.
4. Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender Systems Handbook*. Springer.
5. Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). *Deep Learning Based Recommender System: A Survey and New Perspectives*. ACM Computing Surveys (CSUR), 52(1), 1–38.