

УДК 004.08

DOI: [10.26102/2310-6018/2026.58.7.008](https://doi.org/10.26102/2310-6018/2026.58.7.008)

Разработка гибридной модели рекомендательной системы на базе графовых нейронных сетей и признакового описания пользователей и сообществ

Т.В. Азарнова✉, И.Ю. Мазур

Воронежский государственный университет, Воронеж, Российская Федерация

Резюме. В условиях роста конкуренции на рынке социальных сетей возрастает потребность в инструментах персонализированной рекомендации контента, способных повысить вовлеченность пользователей. Традиционные подходы к построению рекомендательных систем, основанные на коллаборативной фильтрации или контентной фильтрации, имеют ограничения в задачах рекомендации сообществ, где важны как структура социальных связей, так и семантическое описание групп. Данная статья направлена на исследование гибридной модели рекомендательной системы, сочетающей графовые нейронные сети и признаковое описание пользователей и сообществ. Модель интегрирует информацию о взаимодействиях пользователей с группами в виде графа, текстовые эмбединги описаний сообществ, полученные с помощью трансформерных моделей, а также числовые и категориальные признаки групп и пользователей. Результаты исследования демонстрируют существенное преимущество предложенного подхода по сравнению с базовыми методами. Проведен сравнительный анализ модели с рандомными рекомендациями и рекомендациями самых популярных групп. Он показывает улучшение метрики MAP@3 в 3,89 раза относительно рекомендации популярных групп и в 4045,9 раз относительно случайной рекомендации. Исследование базируется на данных социальной сети ОК, включающих информацию о 159 685 пользователях и 54 425 сообществах.

Ключевые слова: рекомендательные системы, графовые нейронные сети, машинное обучение, персонализация, социальные сети, коллаборативная фильтрация, эмбединги.

Для цитирования: Азарнова Т.В., Мазур И.Ю. Разработка гибридной модели рекомендательной системы на базе графовых нейронных сетей и признакового описания пользователей и сообществ. *Моделирование, оптимизация и информационные технологии*. 2026;14(7). URL: <https://moitvvt.ru/ru/journal/article?id=2402> DOI: 10.26102/2310-6018/2026.58.7.008

Application of hybrid recommendation system model based on graph neural networks and feature description of users and communities

T.V. Azarnova✉, I.Y. Mazur

Voronezh State University, Voronezh, the Russian Federation

Abstract. In the conditions of growing competition in the social media market, there is an increasing need for personalized content recommendation tools that can increase user engagement. Traditional approaches to building recommendation systems based on collaborative filtering or content filtering have limitations in community recommendation tasks, where both the structure of social connections and the semantic description of groups are important. This article is aimed at studying a hybrid model of a recommendation system combining graph neural networks and feature description of users and communities. The model integrates information about user interactions with groups in the form of a graph, text embeddings of community descriptions obtained using transformer models, as well as numerical and categorical features of groups and users. The results of the study demonstrate a significant advantage of the proposed approach compared to baseline methods. A comparative analysis with

popularity baseline and random baseline shows an improvement in the MAP@3 metric by 3.89 times relative to recommending popular groups and by 4045.9 times relative to random recommendation. The study is based on data from the OK social network, including information about 159,685 users and 54,425 communities.

Keywords: recommendation systems, graph neural networks, machine learning, personalization, social networks, collaborative filtering, embeddings.

For citation: Azarnova T.V., Mazur I.Y. Application of hybrid recommendation system model based on graph neural networks and feature description of users and communities. *Modeling, Optimization and Information Technology*. 2026;14(7). (In Russ.). URL: <https://moitvvt.ru/ru/journal/article?id=2402> DOI: 10.26102/2310-6018/2026.58.7.008

Введение

Развитие социальных сетей на текущем этапе сопровождается ростом конкуренции за внимание пользователей, увеличением объемов обрабатываемых данных и усилением требований к уровню персонализации сервисов. Площадки ОК и ВКонтакте становятся одними из ключевых коммуникационных сред: через них пользователи присоединяются к сообществам, оформляют подписки и участвуют в обсуждениях.

Одновременно с этим, несмотря на широкое распространение рекомендательных систем, на практике часто наблюдается невысокая эффективность рекомендаций сообществ. Массовые рекомендации групп нередко приводят к ограниченному отклику аудитории, поскольку значительная доля пользователей почти не реагирует на подобные предложения. В результате возникает потребность в более адаптивных методах персонализации, которые учитывают не только структуру социальных связей, но и смысловое наполнение сообществ.

Для анализа и построения современных рекомендательных систем все чаще применяются модели и алгоритмы машинного обучения. В работе [1] рассматриваются методы коллаборативной фильтрации на основе матричной факторизации, ориентированные на выявление групп пользователей с близкими предпочтениями. Такие модели позволяют повышать вероятность того, что пользователь обнаружит потенциально интересный для него контент, однако при этом не отражают структурные особенности социального графа.

В работе [2] рассматриваются гибридные модели, в которых факторизационные машины объединяются с нейронными сетями для оценки вероятности интереса пользователя к тому или иному контенту на основании его признаков и характеристик. Обучение таких моделей ведется на признаках пользователей и объектов рекомендации, что дает возможность учитывать семантические свойства предлагаемых материалов. Вместе с тем в данном подходе не используется представление взаимодействий пользователей с сообществами в виде графовой структуры, и, следовательно, информация о топологии социальных связей остается не задействованной.

Графовые нейронные сети (GNN) представляют собой продвинутый аналитический инструмент, позволяющий эффективно работать со структурированными данными в виде графов. Данный подход вычисляет вероятность присоединения пользователя к сообществу, учитывая структуру его социальных контактов и параметры вершин графа. Для анализа социальных сетей подобные архитектуры демонстрируют высокие результаты, так как позволяют напрямую отображать связи между участниками и тематическими группами [3, 4].

Внимание к графовым нейросетям в сфере персональных рекомендаций закономерно: традиционные решения, включая матричную факторизацию и стандартные многослойные сети, зачастую не способны уловить сложные структурные зависимости

между пользователями и объектами рекомендаций. В обзоре [3] представлены ключевые подходы к построению GNN и их применимость в разных сценариях. В частности, работа [5] показывает, как эти принципы можно эффективно реализовать в рекомендательной системе за счет явного учета графа взаимодействий – на примере архитектуры NGCF.

Данная работа посвящена исследованию применения гибридной модели рекомендательной системы для социальной сети ОК. Анализируется эффективность применения модели, сочетающей графовые нейронные сети с признаковым описанием пользователей и сообществ. Качество модели оценивается по специализированным метрикам рекомендательных систем (MAP@3, Precision@3, Recall@3), которые позволяют получить достаточно комплексное представление о возможности выявления персонализированных предпочтений пользователей [6, 7].

Материалы и методы

Задачи и принципы построения рекомендательной системы. Рекомендательная система – подход в машинном обучении, направленный на разработку алгоритмов, позволяющих определять сообщества, наиболее интересные для конкретного пользователя. Применение данного подхода в социальных сетях позволяет повысить вовлеченность пользователей за счет точной идентификации тех групп, в которые пользователь с наибольшей вероятностью вступит.

Методология построения гибридной модели базируется на получении некоторой количественной оценки схожести пользователя и сообщества с учетом как структуры взаимодействий, так и признакового описания. Основной задачей является максимизация метрики MAP@3 (Mean Average Precision at 3), которая вычисляется как средняя точность ранжирования для топ-3 рекомендаций.

Обзор архитектуры модели. Архитектура предложенной модели сочетает несколько компонентов. Первый из них – графовый компонент (LightGCN-style). Взаимодействия пользователей с группами представляется в виде двудольного графа, где узлы первого типа – пользователи, узлы второго типа – сообщества. Ребра графа соответствуют фактам вступления пользователя в группу. Для обучения графового компонента используется нормализованная матрица смежности:

$$R_{norm} = D_u^{(-\frac{1}{2})} R D_g^{(-\frac{1}{2})}, \quad (1)$$

где R – матрица взаимодействий пользователей и групп, D_u и D_g – диагональные матрицы степеней пользователей и групп соответственно [6].

Еще одним важным компонентом является признаковый компонент групп. Для каждого сообщества формируется вектор признаков, включающий числовые (количество участников (customers_count), количество сообщений (messages_count), уровень вовлеченности (engagement_rate)), категориальные (тип группы (type), регион (region_id), тема оформления (themeid), бизнес-категория (business_category), родительская категория (business_parent)) и текстовые (описание группы (description)) признаки. Все числовые признаки подвергаются логарифмическому преобразованию и нормализации. Каждый категориальный признак кодируется с помощью embedding-слоя. Текстовые эмбединги размерности 384 получаются с помощью предобученной модели sentence-transformers на основе архитектуры BERT [8].

Помимо этого, для каждого пользователя формируются агрегированные признаки: количество сообществ, в которых состоит пользователь; среднее количество

сообщений в сообществах пользователя; среднее количество участников в сообществах пользователя.

Архитектура GNN многослойная. Модель использует 3 слоя распространения информации по графу. На каждом слое происходит агрегация эмбедингов соседних узлов:

$$E_u^{l+1} = R_{norm} E_g^l, \quad (2)$$

$$E_g^{l+1} = R_{norm}^T E_u^l, \quad (3)$$

где E_u^l и E_g^l – эмбединги пользователей и групп на слое l .

Финальные эмбединги вычисляются как усреднение эмбедингов всех слоев:

$$E_u^{final} = \frac{1}{L+1} \sum_{l=0}^L E_u^l, \quad (4)$$

$$E_g^{final} = \frac{1}{L+1} \sum_{l=0}^L E_g^l, \quad (5)$$

где $L = 3$ – количество слоев GNN [6].

Для интеграции признаков групп и пользователей в архитектуре модели применяются многослойные перцептроны (MLP). Групповой MLP принимает на вход конкатенированный вектор, состоящий из числовых, категориальных и текстовых признаков, и обрабатывает его через последовательность полносвязных слоев размерностью 256 и 128 нейронов, формируя на выходе вектор размерности 128. Аналогичным образом пользовательский MLP преобразует исходные признаки пользователей, пропуская их через слои с 64 и 128 нейронами соответственно, что позволяет получить финальное пользовательское представление, согласованное по размерности с эмбедингами групп.

Для обучения модели используется BPR loss (Bayesian Personalized Ranking) с L2-регуляризацией:

$$L_{BPR} = -\sum_{(u,i,j) \in D} \ln(\sigma(y_{ui} - y_{uj})) + \lambda ||\theta||^2, \quad (6)$$

где y_{ui} – предсказанный скор для пары пользователь-группа, σ – сигмоидная функция, λ – коэффициент регуляризации [9].

Параметры модели. Основные гиперпараметры модели представлены в Таблице 1.

Таблица 1 – Гиперпараметры модели

Table 1 – Model hyperparameters

Параметр	Краткое описание	Значение
Размер эмбединга	Размерность векторного представления узлов графа	128
Количество слоёв GNN	Число слоёв агрегации информации в графе	3
Dropout	Вероятность отключения нейронов для регуляризации	0,2
Размер батча	Количество примеров в одном шаге обучения	2048
Количество эпох	Число полных проходов по обучающей выборке	20
Негативные сэмплы	Количество отрицательных примеров на один положительный	6
Learning rate	Шаг обучения оптимизатора AdamW	0,0005
Scheduler	Стратегия изменения скорости обучения	Cosine Annealing
L2 регуляризация	Коэффициент штрафа за большие веса	1×10^{-5}

Описание данных. Исследование базируется на данных социальной сети ОК. Набор данных содержит 500 000 записей о взаимодействиях пользователей с группами. Статистика данных представлена в Таблице 2.

Таблица 2 – Статистика данных

Table 2 – Data statistics

Показатель	Значение
Количество записей	500 000
Количество пользователей	159 685
Количество групп	54 425
Размер валидационной выборки	69 059

Метрики оценки качества. Для полной оценки эффективности гибридной рекомендательной модели применили набор метрик. Эти метрики давно используют в информационном поиске и рекомендательных системах [6, 7]. Выбор не случайный – задача связана с ранжированием. Важно не просто угадать нужный объект. Важно поставить его как можно выше в списке.

MAP@3 (Mean Average Precision at 3). Метрика считает среднюю точность по всем пользователям при $K=3$. Она усредняет Average Precision для каждого пользователя выборки. MAP@3 хорошо показывает качество ранжирования. Она учитывает два ключевых момента. Первый – релевантность рекомендаций – насколько группы совпадают с интересами пользователя. Второй момент – порядок в списке – где именно стоят релевантные группы. Чем выше позиция, тем больше вклад в итоговую оценку. Формула расчёта выглядит так:

$$\text{MAP@3} = \frac{1}{|U|} \sum_{u \in U} \text{AP@3}(u), \quad (7)$$

где $\text{AP@3}(u)$ – средняя точность для пользователя u при топ-3 рекомендациях, $|U|$ – общее число пользователей в выборке.

Значение метрики лежит между 0 и 1. Единица – идеальный результат. Все релевантные группы стоят в начале списка. Ноль означает провал. Релевантные рекомендации отсутствуют полностью.

Для более широкой оценки были использованы еще две метрики – точность и полнота. Precision@3 (точность) показывает долю релевантных рекомендаций. Она считает их среди трёх предложенных пользователю групп. Проще говоря, сколько из них действительно полезны. Recall@3 (полнота) оценивает с другой стороны. Она показывает, сколько релевантных групп удалось найти. И сравнивает это число со всеми возможными релевантными вариантами. Обе метрики лежат в диапазоне от 0 до 1. Чем выше значение, тем лучше работает система.

$$\text{Precision@3} = \frac{1}{|U|} \sum_{u \in U} \frac{|\text{Rec}_u \cap \text{True}_u|}{3}, \quad (8)$$

$$\text{Recall@3} = \frac{1}{|U|} \sum_{u \in U} \frac{|\text{Rec}_u \cap \text{True}_u|}{|\text{True}_u|}, \quad (9)$$

где Rec_u – список рекомендованных групп, True_u – список релевантных групп, $|U|$ – количество пользователей в выборке.

Результаты

Для проведения вычислительного эксперимента модель была обучена на данных социальной сети ОК. Все этапы исследования реализованы на базе программного обеспечения, разработанного на языке программирования Python в среде Jupyter.

Процесс обучения модели. Обучение модели проводилось в течение 20 эпох с использованием батчей размером 2048. На каждой эпохе вычислялись метрики потерь на обучающей выборке и MAP@3 на валидационной выборке. Динамика обучения представлена на Рисунке 1.




Рисунок 1 – Динамика обучения модели
Figure 1 – Model training dynamics

Наилучший результат был достигнут на 20-й эпохе со значением MAP@3 = 0,1462 на валидационной выборке.

Сравнение с базовыми уровнями. Для оценки эффективности предложенной модели было проведено сравнение с двумя базовыми уровнями: Popularity Baseline (рекомендация 3 самых популярных групп, в которые пользователь еще не вступил) и Random Baseline (случайная рекомендация 3 групп из доступных). Результаты сравнения представлены в Таблице 3.

Таблица 3 – Сравнение методов рекомендации
Table 3 – Comparison of recommendation methods

Метод	MAP@3	Улучшение относительно модели
GNN Модель (предложенная)	0,1462	–
Popularity Baseline	0,0376	в 3,89 раза хуже
Random Baseline	0,000036	в 4045,9 раза хуже

Обсуждение

Полученные результаты демонстрируют существенное преимущество предложенной гибридной модели по сравнению с базовыми подходами. MAP@3 вырос в 3,89 раза по сравнению с popularity baseline, что показывает: модель не только двигает вверх популярное, но и реально учитывает интересы конкретных пользователей. По сравнению с random baseline показатель вырос в 4045,9 раза. Это прямо указывает на пользу обучения на реальных взаимодействиях.

Преимущества гибридного подхода. Преимущества гибридного подхода – в сочетании разных идей. Он объединяет графовые нейронные сети и признаки объектов.

В итоге модель видит структуру и понимает смысл. Граф помогает собирать данные от соседних вершин. Так вскрываются скрытые связи между людьми и сообществами [3, 4]. Связи часто неочевидны. Но они есть. Параллельно работают текстовые эмбединги описаний. Они показывают тематику сообществ. Коротко и точно. Почему это важно? Это спасает на этапе холодного старта, когда взаимодействий мало или их почти нет [8].

Ограничения исследования. Хотя исследование дало интересные результаты, у него есть несколько ограничений. Во-первых, обучение GNN на крупных графах требует много вычислительных ресурсов и времени. Во-вторых, все еще остается проблема холодного старта: когда появляются новые пользователи или группы с небольшим числом взаимодействий, качество рекомендаций может заметно падать. Кроме этого, данные в социальных сетях быстро меняются, из-за чего модель приходится регулярно дообучать.

Сравнение с другими исследованиями. Полученные выводы в целом коррелируют с тем, что описано в более ранних работах. В исследовании [7] говорится, что графовые нейронные сети работают лучше, чем отдельные методы коллаборативной или контентной фильтрации для социальных рекомендаций, что схоже с выводами этой работы. В [10] показано, что графовые свертки эффективны для рекомендательных систем веб-масштаба. Это дополнительно подтверждает выбор архитектуры LightGCN для данного исследования.

Заключение

Гибридная модель – на основе графовых нейронных сетей и признаков пользователей и сообществ – заметно улучшает качество рекомендаций по сравнению с простыми подходами. Она превосходит эффективность popularity baseline в 3,89 раза по MAP@3 и достигает 0,1462 на валидации. Значит, модель действительно находит персонализированные предпочтения, а не просто рекомендует популярное. Относительно random baseline тоже получено статистически значимое улучшение ($p < 0,001$). Объединение графовых, текстовых и числовых признаков позволяет учитывать и структуру связей, и смысл сообществ, и активность каждого пользователя – то есть все то, из чего складываются реальные предпочтения.

На практике эту модель можно использовать в ленте рекомендаций «Одноклассников», переобучая ее регулярно, чтобы следить за изменениями в поведении. Если добавить еще данные о пользователях (расширить признаковое описание), качество может вырасти еще. В развитии данного направления можно исследовать проблему холодного старта для новых пользователей и групп, сделать инкрементальные алгоритмы для потоковых данных и проанализировать трансформерные архитектуры для графов. Это поможет строить более гибкие и точные рекомендательные системы для соцсетей.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Koren Y., Bell R., Volinsky Ch. Matrix Factorization Techniques for Recommender Systems. *Computer*. 2009;42(8):30–37. <https://doi.org/10.1109/MC.2009.263>
2. Guo H., Tang R., Ye Y., et al. DeepFM: A Factorization-Machine based Neural Network for CTR Prediction. In: *IJCAI '17: Proceedings of the 26th International Joint Conference on Artificial Intelligence, 19–25 August 2017, Melbourne, Australia*. International Joint Conferences on Artificial Intelligence; 2017. P. 1725–1731. <https://doi.org/10.24963/ijcai.2017/239>
3. Wu Z., Pan Sh., Chen F., et al. A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*. 2021;32(1):4–24. <https://doi.org/10.1109/TNNLS.2020.2978386>

4. Zhou G., Zhu X., Song Ch., et al. Deep Interest Network for Click-Through Rate Prediction. In: *KDD '18: Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 19–23 August 2018, London, UK*. New York: ACM; 2018. P. 1059–1068. <https://doi.org/10.1145/3219819.3219823>
5. Wang X., He X., Wang M., et al. Neural Graph Collaborative Filtering. In: *SIGIR '19: Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 21–25 July 2019, Paris, France*. New York: ACM; 2019. P. 165–174. <https://doi.org/10.1145/3331184.3331267>
6. He X., Deng K., Wang X., et al. LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation. In: *SIGIR '20: Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 25–30 July 2020, Virtual Event*. New York: ACM; 2020. P. 639–648. <https://doi.org/10.1145/3397271.3401063>
7. Fan W., Ma Y., Li Q., et al. Graph Neural Networks for Social Recommendation. In: *WWW '19: The World Wide Web Conference, 13–17 May 2019, San Francisco, CA, USA*. New York: ACM; 2019. P. 417–426. <https://doi.org/10.1145/3308558.3313488>
8. Devlin J., Chang M.-W., Lee K., et al. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. In: *NAACL-HLT 2019: Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 02–07 June 2019, Minneapolis, MN, USA*. Association for Computational Linguistics; 2019. P. 4171–4186. <https://doi.org/10.18653/v1/N19-1423>
9. Rendle S., Freudenthaler Ch., Gantner Z., et al. BPR: Bayesian Personalized Ranking from Implicit Feedback. In: *UAI '09: Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence, 18–21 June 2009, Montreal, QC, Canada*. Corvallis: AUAI Press; 2009. P. 452–461.
10. Ying R., He R., Chen K., et al. Graph Convolutional Neural Networks for Web-Scale Recommender Systems. In: *KDD '18: Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 19–23 August 2018, London, UK*. New York: ACM; 2018. P. 974–983. <https://doi.org/10.1145/3219819.3219890>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Азарнова Татьяна Васильевна, доктор технических наук, профессор, профессор Воронежского государственного университета, Воронеж, Российская Федерация.
Tatyana V. Azarnova, Doctor of Engineering Sciences, Professor, Professor of Voronezh State University, Voronezh, the Russian Federation.
e-mail: ivdas92@mail.ru

Мазур Ирина Юрьевна, студентка, *Irina Y. Mazur*, Student, Воронежский государственный университет, Воронеж, Российская Федерация.
University, Voronezh, the Russian Federation.
e-mail: irino4kamazur@yandex.ru

Статья поступила в редакцию 05.05.2026; одобрена после рецензирования 06.07.2026; принята к публикации 14.07.2026.

The article was submitted 05.05.2026; approved after reviewing 06.07.2026; accepted for publication 14.07.2025.