
ТРАНСФОРМЕРНЫЕ МОДЕЛИ ДЛЯ ПЕРСОНАЛИЗАЦИИ РЕКОМЕНДАЦИЙ В МУЗЫКАЛЬНЫХ СТРИМИНГОВЫХ СЕРВИСАХ

Водяный Андрей Викторович

студент

МГУ имени М. В. Ломоносова, факультет ВМК, Москва, Россия

E-mail: a.vodyany@yandex.ru

Научный руководитель — Темирчев Павел Георгиевич

В современных стриминговых музыкальных сервисах качество персонализации является ключевым фактором удержания аудитории и роста вовлечённости. Традиционные методы коллаборативной фильтрации и матричных разложений, несмотря на их эффективность при генерации кандидатов, не учитывают в явном виде последовательную природу пользовательского поведения [5]. Рекуррентные архитектуры частично решают эту задачу, однако ограничены в масштабируемости и моделировании долгосрочных зависимостей.

В данной работе предложена двухстадийная архитектура обучения трансформерной модели для задачи персонализированных рекомендаций в музыкальном стриминговом сервисе. Модель обрабатывает историю прослушиваний пользователя как последовательность токенов, где каждый токен представляет собой эмбединг музыкального произведения, обогащённый метаданными (жанр, исполнитель, темп, акустические признаки). Механизм self-attention позволяет динамически взвешивать вклад прошлых прослушиваний при прогнозировании следующего трека, что согласуется с подходами SASRec [2] и BERT4Rec [4].

Стадия предобучения (pretrain). На данной стадии модель обучается решать задачу next-item prediction на большом корпусе пользовательских сессий. Поскольку размер каталога музыкального сервиса может достигать десятков миллионов треков, вычисление полного softmax по всем элементам каталога является вычислительно неприемлемым. В работе применяется *sampled softmax* с логарифмической Q -коррекцией (log- Q correction) [6]. Для истинного объекта i и набора негативных примеров \mathcal{N} , отобранных с распределением Q , скорректированный логит вычисляется как:

$$\tilde{z}_j = z_j - \log Q(j), \quad j \in \{i\} \cup \mathcal{N},$$

где $z_j = \langle \mathbf{u}, \mathbf{v}_j \rangle$ — скалярное произведение представления пользова-

теля и эмбединга j -го трека. Данная коррекция устраняет смещение оценки градиента, возникающее при неравномерном частотном распределении объектов каталога, и обеспечивает несмещённую аппроксимацию полного softmax.

Стадия дообучения (finetune). Предобученная модель дообучается в рамках end-to-end пайплайна ранжирования с целью согласования представлений ретривера с целевой функцией ранкера. Вместо pointwise-потерь используется *pairwise logit loss*, воспроизводящая сигнал ранкера:

$$\mathcal{L}_{\text{pair}} = \sum_{(i,j): r_i > r_j} \log\left(1 + e^{-(z_i - z_j)}\right),$$

где r_i, r_j — ранжирующие оценки модели-ранкера, а $z_i - z_j$ — разность логитов ретривера для позитивного и негативного объекта. Такой подход обеспечивает прямую оптимизацию порядка ранжирования и выравнивает геометрию эмбедингового пространства с предпочтениями, закодированными в ранкере, что соответствует парадигме дистилляции ранкера в ретривер [3].

Эксперименты проведены на исторических данных реального музыкального стримингового сервиса. Предложенная модель сравнивалась с базовыми подходами (collaborative filtering, матричные разложения, одностадийное обучение без Q -коррекции). Двухстадийная схема обучения демонстрирует устойчивое улучшение офлайн-метрик ранжирования (Recall@k, NDCG@k), а также подтверждается положительными результатами АБ-экспериментов по ключевым продуктовым метрикам.

Таким образом, предложенная двухстадийная схема обучения трансформерного ретривера — с sampled softmax и log- Q коррекцией на стадии претренинга и pairwise logit loss на стадии файнтюна — обеспечивает значимое повышение качества персонализированных рекомендаций за счёт как эффективного моделирования последовательных паттернов поведения пользователей, так и прямого согласования с сигналом ранжирования.

Литература

1. Covington P., Adams N., Sargin E. Deep Neural Networks for YouTube Recommendations // Google Research, 2016. URL: <https://static.googleusercontent.com/media/research.google.com/ru//pubs/archive/45530.pdf>
2. Kang W.-C., McAuley J. Self-Attentive Sequential

-
- Recommendation // arXiv preprint arXiv:1808.09781, 2018.
3. Khrylenko K., Matveev A., Makeev S., Baikalov V. Scaling Recommender Transformers to One Billion Parameters // arXiv preprint arXiv:2507.15994, 2025.
 4. Sun F. et al. BERT4Rec: Sequential Recommendation with Bidirectional Encoder Representations from Transformer // arXiv preprint arXiv:1904.06690, 2019.
 5. Vaswani A. et al. Attention Is All You Need // arXiv preprint arXiv:1706.03762, 2017.
 6. Zhai S. et al. Actions Speak Louder than Words: Trillion-Parameter Sequential Transformers for Generative Recommendations // arXiv preprint arXiv:2402.17152, 2024.