УДК 004.8

АВТОМАТИЗАЦИЯ КОНСТРУИРОВАНИЯ ПРИЗНАКОВ В ДВУХСТАДИЙНОЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЕ: СРАВНЕНИЕ С РУЧНЫМИ ПРИЗНАКАМИ НА ДАННЫХ YAMBDA И KION

Овсянников Владимир Иванович, студент Института кибербезопасности и цифровых технологий, кафедра КБ-14 «Цифровые технологии обработки данных», МИРЭА — Российский технологический университет (РТУ МИРЭА), 119454, г. Москва, проспект Вернадского, д. 78. Тел.: +7 (962) 917-83-82, ORCID: 0009-0009-7458-193X

Аннотация. В работе проверяется, можно ли заменить ручное конструирование признаков в двухстадийной рекомендательной системе — с генерацией кандидатов и ранжированием градиентным бустингом над решающими деревьями (GBDT) — автоматическим поиском признаков, графовыми представлениями или нейросетью над историей событий, не потеряв в качестве. Эксперименты шли на музыкальном наборе Yambda (10 тыс. пользователей, 301 сутки) и кинематографическом KION. Все методы сравнивались на общих кандидатах при едином глобальном разбиении по времени: признаки выбирались на валидации, тест использовался только для итоговой оценки. Признаки записаны одной грамматикой «ключ.канал.агрегат.окно», поэтому проверку на утечку будущего можно делать автоматически. Бустинг на 123 ручных признаках дал NDCG@10 (нормированный дисконтированный кумулятивный выигрыш на первых десяти позициях) = 0,284 на тесте. Замена ручных признаков 115 признаками, отобранными по важности из пула в 3,6 тыс. кандидатов, подняла NDCG@10 на 0,0064 (95 % доверительный интервал 0,0053–0,0076); добавление 60 таких признаков — на 0,0080. Случайный выбор из той же грамматики добавляет 0,0045 и при замене не отличается от ручного набора. То есть вклад собственно отбора — 0,0036 и 0,0077. OpenFE почти втрое дороже и менее эффективен; подбор окон затухания неотличим от шума; графовые признаки дают не более 0,0013; нейросеть с вниманием над сырой историей достигает 92 % качества бустинга. Агент на базе большой языковой модели улучшает готовый набор, но не строит его с нуля. На KION направление результатов сохраняется, однако преимущество отбора перед случайным выбором там не подтверждается. Выигрыш объясняется составом отобранных признаков: 69–73 % прослушиваний — повторы, поэтому набор смещается к затухающим счётчикам пары «пользователь — трек» с полупериодами 1–7 суток и к рангам внутри пользователя. В ручном наборе таких признаков нет. Поиск по важности занимает около 27 минут машинного времени; преимущество сохраняется и при десятикратном росте выборки.

Ключевые слова: рекомендательные системы; конструирование признаков; градиентный бустинг; автоматизация признаков; большие языковые модели; ранжирование; утечка данных; Yambda; KION; NDCG.

AUTOMATING FEATURE CONSTRUCTION IN A TWO-STAGE RECOMMENDER SYSTEM: A COMPARISON WITH HAND-CRAFTED FEATURES ON THE YAMBDA AND KION DATASETS

Ovsyannikov Vladimir Ivanovich, Student, Institute of Cybersecurity and Digital Technologies, Department KB-14 «Digital Data Processing Technologies», MIREA — Russian Technological University (RTU MIREA), 78 Vernadsky Avenue, Moscow, 119454, Russia, ORCID: 0009-0009-7458-193X

Abstract. The study asks whether manual feature engineering in a two-stage recommender system — candidate generation followed by a gradient boosted decision tree ranker, GBDT — can be replaced without quality loss by automated feature search, graph representations, or a neural network over raw event history. Experiments use the music dataset Yambda (10 thousand users, 301 days) and the movie dataset KION. All methods are compared on shared candidates under one global temporal split: features are chosen on validation, and the test set is used only for the final assessment. Features follow a single grammar, key.channel.aggregate.window, which makes leakage checking automatic. A booster trained on 123 hand-crafted features reaches NDCG@10 (normalized discounted cumulative gain at ten positions) of 0.284 on test. Replacing them with 115 features selected by importance from a pool of 3.6 thousand candidates raises NDCG@10 by 0.0064 (95 % confidence interval 0.0053–0.0076); adding 60 such features raises it by 0.0080. Random selection from the same grammar adds 0.0045 and, when used as a replacement, does not differ from the manual set. The contribution of selection itself is therefore 0.0036 and 0.0077. OpenFE is almost three times costlier and less effective; tuning decay windows is indistinguishable from noise; graph features add at most 0.0013; an attention network over raw history reaches 92 % of the booster quality. A large-language-model agent improves a ready feature set but cannot build one from scratch. On KION the direction of results holds, but the advantage of selection over random choice is not confirmed. Costs and scalability are reported.

Keywords: recommender systems; feature engineering; gradient boosting; feature automation; large language models; ranking; data leakage; Yambda; KION; NDCG.

ВВЕДЕНИЕ

Качество многих промышленных рекомендательных систем держится на ранжирующей модели — градиентном бустинге над решающими деревьями (GBDT). На вход ей подают признаки, которые команда придумывает вручную: агрегаты истории взаимодействий по выбранным окнам, статистики объектов, признаки пары «пользователь — объект». Альтернатива — обучаемые

представления, например реляционные графовые нейросети, которые предлагается использовать вместо ручных признаков [1]. Но на табличных данных среднего размера деревья часто обходят нейросети [2], так что вопрос о замене ручного конструирования остаётся открытым.

Ручной подход произволен. Не очень понятно, почему окно равно семи суткам, а не десяти; какие связи через исполнителя или альбом действительно нужны; какие отношения счётчиков полезны. Автоматизировать этот этап пытаются перебором и отбором кандидатов. Метод OpenFE оценивает прирост признака дообучением на остатках базовой модели [3]. Другое направление — большие языковые модели (LLM), которые пишут код признаков по описанию данных [4]; для промышленных рекомендаций предложен LLM-агент последовательного конструирования признаков [5]. Ещё два направления — модели внимания над историей событий, зависящие от кандидата [6], и графовые модели [7]. В доступных автору публикациях не нашлось сопоставления этих подходов с сильным ручным базлайном при общих кандидатах, доверительных интервалах и учёте затрат, хотя без глобального разбиения по времени оценки завышаются из-за утечки будущего [8].

Задача работы — понять, можно ли автоматизировать конструирование признаков или заменить его обучаемыми представлениями без потери качества ранжирования. Проверялись следующие вопросы: заменяет ли автоматический набор ручной и какой метод поиска лучше; что в приросте даёт именно отбор, а что — простое увеличение числа признаков; добавляют ли информацию графовые признаки; заменяет ли агрегаты нейросеть над историей; переносятся ли выводы на другой домен и при росте данных.

МЕТОДИКА

Данные и задача

Основной набор — Yambda-50M [9], журнал сервиса Яндекс Музыка: 46,5 млн прослушиваний 9238 пользователей за 301 сутки. Из них 69–73 % — повторы пары «пользователь — трек». Проверка показала, что время задано в секундах с шагом 5, а не в пятисекундных единицах, как следует из описания набора. Для проверки обобщения взят KION [10]: 5,48 млн просмотров 962 тыс. пользователей. Случайно выбраны 10 % пользователей со всей историей; пары «пользователь — фильм» уникальны, поэтому прямых признаков пары там нет. В начале суток-якоря a для каждого кандидата предсказывается, будет ли трек прослушан не менее чем на 50 % в окне [a + 30 мин, a + 30 мин + 24 ч). Для KION — будет ли просмотр в течение семи суток.

Разбиение, кандидаты и метрики

Разбиение глобальное по времени. Обучение — 34 якоря (сутки 150–283 с шагом 4, 10,8 млн строк), валидация — сутки 285–291, тест — сутки 293–299 (30 516 групп «якорь — пользователь»). Метки обучающих якорей

заканчиваются до начала валидации; это проверяется кодом. Кандидаты едины для всех моделей: объединение четырёх источников, считаемых по истории до якоря — затухающий и полный личные счётчики, популярные треки любимых артистов, хиты недели. В среднем около 265 кандидатов на группу. В кандидаты попадает доля позитивов 0,419; 0,394 и 0,388 на обучении, валидации и тесте соответственно. Поэтому идеальный ранкер внутри кандидатов достигает NDCG@10 лишь 0,728.

Основная метрика — нормированный дисконтированный кумулятивный выигрыш (NDCG), формулы (1) и (2):

$$DCG@K = \sum_{k=1}^{K} \frac{rel_k}{log_2(k+1)} \quad (1)$$

$$NDCG@K = \frac{DCG@K}{IDCG@K} \quad (2)$$

где rel_k — метка объекта на позиции k, IDCG@K — значение DCG@K при идеальном порядке. Знаменатель учитывает все позитивы группы, в том числе не попавшие в кандидаты. Дополнительно считались Recall@K, площадь под ROC-кривой (ROC-AUC) и логарифмическая потеря (LogLoss). Доверительные интервалы — парный бутстреп по пользователям, 1000 повторов, так как один пользователь даёт несколько групп.

Признаки и защита от утечек

Признак записан строкой «ключ.канал.агрегат.окно». Ключ — пользователь, трек, пара, пользователь × артист, пользователь × альбом, артист, альбом. Канал событий — любое прослушивание, прослушивание не менее чем на 50 %, пропуск, органическое, рекомендованное, лайк и др. Агрегат — счётчик, среднее, давность, затухающая сумма, число различных партнёров. Окно — временной интервал. По сути это запрос вида SELECT агрегат ... WHERE канал ... GROUP BY ключ к таблице событий. Затухающая сумма с полупериодом h суток задаётся формулой (3):

$$c(u, i; a, h) = \sum_{t_j < a} 2^{-(a - t_j)/h} \quad (3)$$

где t_j — моменты событий пары (u, i) до якоря a. Производные признаки — частное, разность и ранг значения среди кандидатов того же пользователя. В пуле около 3,6 тыс. признаков, включая все 123 ручных. Движок читает только события до якоря. При замене событий после якоря случайными ни у одного из 593 проверенных признаков значение не изменилось. Контрольные признаки, окно которых захватывает сутки якоря, обнаружились в 585 случаях из 593.

Ручной набор — 123 признака в семи группах. Окна (1, 7, 30 суток и вся история) зафиксированы заранее и по валидации не подбирались. Затухающих счётчиков в нём нет, рангов среди кандидатов — пять. Ранжирует LightGBM с целью lambdarank. Гиперпараметры фиксированы, ранняя остановка — по валидации.

Методы автоматизации и альтернативные модели

Из пула выбирали пятью способами. A1 — случайно, как контроль, пять сидов; в итоговое сравнение входит заранее заданный нулевой. A2 — расчёт всего пула, одна модель, отбор по важности (gain). A3 — OpenFE [3]: оценка прироста на остатках и последовательное отсечение. A4 — подбор полупериода затухающего счётчика для каждого семейства «ключ — канал». A5 — агент на базе LLM gpt-oss:120b: он предлагает строки грамматики, получает прирост качества каждой и повторяет запрос; недопустимые строки отбрасываются разбором, код модели не исполняется. Выбор выполнялся в уменьшенной среде: 20 % пользователей, 10 обучающих якорей, 150 деревьев; шум по NDCG@10 — 0,0004. Затем набор обучался на полных данных. Сценарий A — к ручному набору добавляют 60 признаков. Сценарий B — 115 автоматических признаков заменяют ручные.

Альтернативы: нейросеть на 15,9 млн параметров с вниманием, зависящим от кандидата [6], и обучаемыми временными ядрами над последними 512 событиями; оценки пар от ALS (alternating least squares) и LightGCN [7], обученных на контрольных точках каждые семь суток, как дополнительные признаки бустинга.

ОСНОВНАЯ ЧАСТЬ

Базовый подход

На валидации случайный порядок внутри кандидатов даёт NDCG@10 = 0,042, глобальная популярность — 0,023, лучшая эвристика (личный затухающий счётчик с полупериодом три суток) — 0,232. Бустинг на ручных признаках достигает 0,289 на валидации и 0,284 на тесте, то есть на 25 % выше эвристики. При цели binary LogLoss равен 0,1285. Крупнейшая важность — у ранга счётчика пары за семь суток (17,7 % от суммарного прироста). Без группы признаков пары NDCG@10 снижается на 0,0129. А 31 признак пары вместе с источниками кандидатов даёт 98 % качества полного набора. Замена троек окон меняет метрику в пределах 0,2654–0,2720 при шуме 0,0004. То есть выбор окон человеком даёт разброс около ±0,003.

Автоматический поиск признаков

Результаты на тесте сведены в таблицу 1, разности к ручному набору — на рисунке 1.

Таблица 1 – Результаты на тесте Yambda (NDCG@10) и затраты поиска

Набор признаков	Признаков	NDCG@10	Δ к ручному [95 % доверительный интервал]	Поиск, мин
Ручной	123	0,2844	–	–
A1 случайные, +60	183	0,2889	+0,0045 [+0,0036; +0,0053]	0
A1 случайные, замена	123	0,2832	−0,0012 [−0,0025; 0,0000]	0
A2 отбор, +60	183	0,2924	+0,0080 [+0,0070; +0,0090]	27

Набор признаков	Признаков	NDCG@10	Δ к ручному [95 % доверительный интервал]	Поиск, мин
A2 отбор, замена	123	0,2909	+0,0064 [+0,0053; +0,0076]	27
A3 OpenFE, +60	183	0,2902	+0,0058 [+0,0048; +0,0067]	48
A3 OpenFE, замена	123	0,2874	+0,0030 [+0,0018; +0,0041]	48
A4 окна, +24	147	0,2880	+0,0036 [+0,0028; +0,0044]	20
A5 агент, +6	129	0,2891	+0,0047 [+0,0038; +0,0055]	6
A5 агент, замена	50	0,2802	−0,0042 [−0,0057; −0,0028]	5
ALS как признак	124	0,2857	+0,0013 [+0,0006; +0,0019]	103
LightGCN как признак	125	0,2848	+0,0004 [−0,0002; +0,0010]	103
Нейросеть над историей	–	0,2614	−0,0230 [−0,0247; −0,0213]	11

Примечание: «+60», «+24», «+6» — добавление к ручному набору; «замена» — автоматические признаки вместо ручных. В графе «Поиск» указано время в уменьшенной среде; для A2–A4 учтён расчёт пула (17 мин), для ALS и LightGCN — общее время расчёта, для нейросети — обучение. Один расчёт A2 обслуживает оба сценария; A3 выполняется для каждого сценария отдельно (всего около 78 мин против 27 мин у A2).

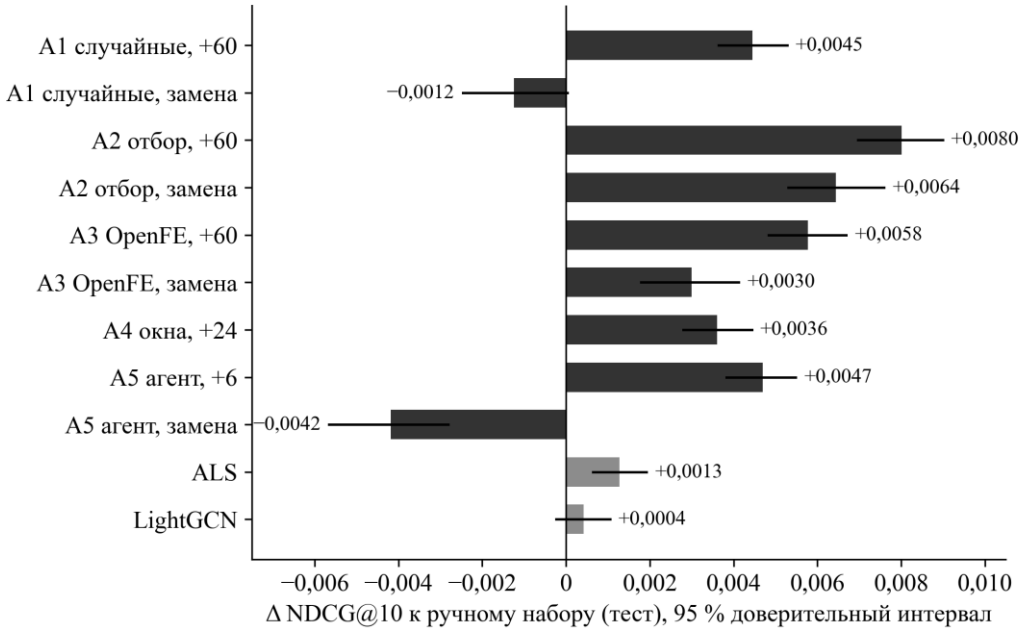


Рисунок 1 – Разность NDCG@10 к ручному набору на тесте (чёрная линия – 95 % доверительный интервал)

Отбор по важности (A2) значимо лучше остальных методов. Разности A2 и A1 составляют 0,0036 [0,0027; 0,0044] в сценарии A и 0,0077 [0,0065; 0,0088] в сценарии B. Для пар A2 и OpenFE разности равны 0,0022 и 0,0034, для A2 и агента — 0,0033 и 0,0106. Разности на валидации и тесте почти совпадают: коэффициент корреляции 0,998 по двенадцати наборам. То есть выбор не переобучен на валидацию. В сценарии A чуть больше половины выигрыша A2

(0,0045 из 0,0080) даёт само добавление случайных признаков. В сценарии B случайный набор равен ручному, и весь выигрыш обеспечивает отбор.

Состав отобранных наборов объясняет результат. Среди 115 признаков A2 78 (68 %) относятся к ключу «пара» против 28 % в ручном наборе; 28 признаков — затухающие счётчики, которых в ручном наборе нет; 17 — ранги внутри пользователя (в ручном их пять). OpenFE выбирает практически тот же состав, а агент в сценарии A предложил признаки того же вида. Первое место по важности у каждой лучшей модели занимает ранг счётчика пары за 1–7 суток (12–21 % прироста). Ранг важен потому, что ранжирование идёт среди кандидатов одного пользователя, где абсолютные счётчики активных и редких слушателей несопоставимы. Подбор полупериода (A4) не работает: приросты при добавлении семейства лежат в пределах $\pm 2 \cdot 10^{-4}$ логарифмической потери, выбранные значения хаотичны. Любой фиксированный полупериод — 3, 7 или 14 суток — даёт NDCG@10 0,2737–0,2748 против 0,2743 у «обученных» в уменьшенной среде.

Агент (A5) в сценарии A принял 6 признаков из примерно 120 предложенных и дал +0,0047. Это столько же, сколько 60 случайных, но при существенно меньших затратах времени, чем у A2. Повторы на трёх сидах показали разброс до 0,0066 в уменьшенной среде, примерно в 15 раз больше шума обучения. В сценарии A агент лучше ручного набора в семи запусках из семи, в сценарии B — хуже во всех шести. Режим с обратной связью принимает лишь 34–42 признака, так как требует положительного прироста у каждого.

Графовые и последовательные модели

Эмбеддинги ALS и LightGCN слабы сами по себе: NDCG@10 0,062 и 0,057 против 0,232 у личного счётчика. К бустингу они добавляют не более 0,0013, а LightGCN — статистически незначимые 0,0004. Основная причина — повторы. У 65–73 % позитивов пара уже встречалась, и прямые счётчики пары покрывают их лучше, а эмбеддинг к моменту прогноза устаревает до семи суток. Нейросеть над историей без агрегатов, но с восемью столбцами источников кандидатов, достигает 0,266 на валидации и 0,2614 на тесте. Это 92 % качества бустинга и на 0,034 выше лучшей эвристики. Удлинение истории с 256 до 512 событий даёт +0,016, добавление источников кандидатов — +0,015. Качество росло до последней, третьей, эпохи (0,2585; 0,2636; 0,2661), так что оценка консервативна.

Перенос на KION и масштабируемость

На KION бустинг на 87 ручных признаках даёт 0,1544 на валидации против 0,1316 у лучшей эвристики, то есть +17 %. Главный признак — суточная популярность фильма. Результаты на тесте приведены в таблице 2.

Таблица 2 – Результаты на тесте KION (NDCG@10)

Набор признаков	NDCG@10 (валидация)	NDCG@10 (тест)	Δ к ручному [95 % доверительный интервал]
Ручной (87)	0,1544	0,1437	–
A1 случайные, замена (87)	0,1560	0,1526	+0,0088 [+0,0069; +0,0107]
A2 отбор, +40 (127)	0,1564	0,1495	+0,0058 [+0,0044; +0,0070]
A2 отбор, замена (87)	0,1521	0,1499	+0,0062 [+0,0044; +0,0080]

Автоматические наборы лучше ручного на 0,006–0,009, но на валидации наборы не упорядочены, а лучшим на тесте оказался случайный набор. По-видимому, при медианной истории из двух событий выбирать почти нечего, поэтому ценность отбора показать не удалось.

Зависимость от объёма данных показана на рисунке 2. Преимущество A2 над ручным набором остаётся в пределах 0,0063–0,0071 при росте обучающей выборки с 1,04 до 10,8 млн строк, а кривые обучения не вышли на плато. Рост выборки с 3,2 до 10,8 млн строк даёт +0,0045 у ручного набора, то есть сопоставим с выигрышем автоматизации. Расчёт одного признака на одном якоре занимает 0,01 с для признаков пользователя и 0,1–0,27 с для признаков пары, трека и артиста на 10 тыс. пользователей. 123 ручных признака на 48 якорях считаются 509 с.

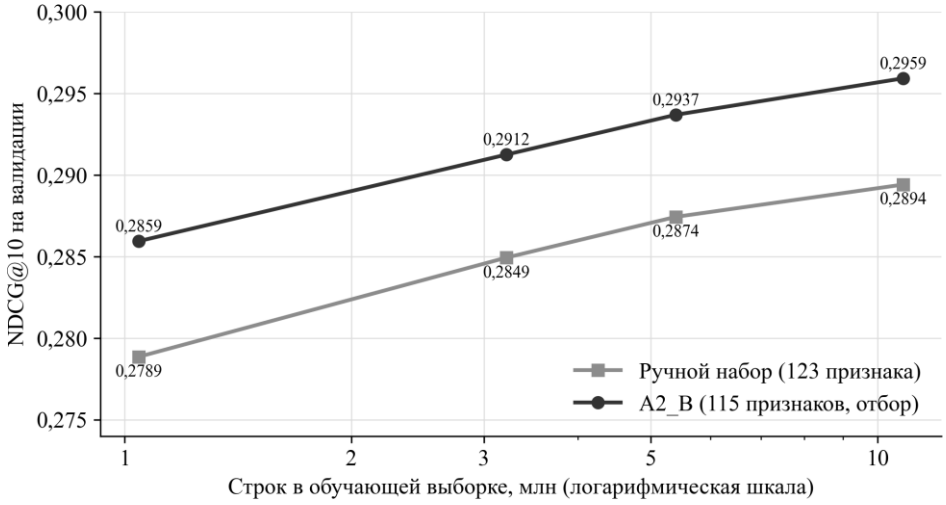


Рисунок 2 – Зависимость NDCG@10 на валидации от числа строк в обучающей выборке

ВЫВОДЫ

1. Автоматический отбор признаков из сгенерированного пула заменяет ручной набор без потери качества. NDCG@10 растёт на 0,0064 при замене и на 0,0080 при добавлении, то есть на 2,3 и 2,8 %. Интервалы лежат выше нуля, порядок методов совпадает на валидации и тесте и сохраняется при десятикратном росте данных.

2. Больше половины выигрыша при добавлении даёт простое увеличение числа признаков: случайный выбор из той же грамматики добавляет +0,0045.

Собственный вклад отбора — 0,0036 при добавлении и 0,0077 при замене. Автоматика находит то, чего нет в ручном наборе: затухающие счётчики пары с полупериодами 1–7 суток и ранги внутри пользователя.

3. OpenFE дороже отбора по важности почти втрое и слабее его. Подбор окон неотличим от шума. Графовые признаки дают не более 0,0013. Агент на базе LLM надёжно улучшает готовый набор, но не строит его с нуля и нестабилен между запусками. Нейросеть над историей достигает 92 % качества бустинга, но не заменяет его.

4. На KION автоматические наборы также не хуже ручного, однако превосходство отбора над случайным выбором не подтверждается. Практически достаточно задать грамматику окон, каналов и агрегатов, посчитать пул на подвыборке и взять признаки с наибольшей важностью одной модели. Это около получаса вычислений.

Ограничения: 10 тыс. пользователей Yambda; финальные модели и запуск агента на полных данных выполнены один раз; гиперпараметры бустинга не подбирались; нейросеть не доучена, стекинг с бустингом не проверялся; ручной набор составлен без независимого эксперта. Код и результаты экспериментов лежат в репозитории github.com/vovaovsyanka/recsys-feature-automation.

СПИСОК ЛИТЕРАТУРЫ

1. Fey M. et al. Position: relational deep learning — graph representation learning on relational databases // Proceedings of the 41st International Conference on Machine Learning. PMLR, 2024. Vol. 235. P. 13592–13607.

2. Grinsztajn L., Oyallon E., Varoquaux G. Why do tree-based models still outperform deep learning on tabular data? // arXiv:2207.08815. 2022. DOI: 10.48550/arXiv.2207.08815. URL: https://arxiv.org/abs/2207.08815 (дата обращения: 09.11.2026).

3. Zhang T. et al. OpenFE: automated feature generation with expert-level performance // Proceedings of the 40th International Conference on Machine Learning. PMLR, 2023. Vol. 202. P. 41880–41901.

4. Hollmann N., Müller S., Hutter F. Large language models for automated data science: introducing CAAFE for context-aware automated feature engineering // arXiv:2305.03403. 2023. DOI: 10.48550/arXiv.2305.03403. URL: https://arxiv.org/abs/2305.03403 (дата обращения: 09.11.2026).

5. Ye L. et al. SAFE: LLM agent for sequential feature engineering in industrial recommendation // Frontiers of Computer Science. 2026. DOI: 10.1007/s11704-026-60956-5.

6. Zhou G. et al. Deep interest network for click-through rate prediction // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: ACM, 2018. P. 1059–1068. DOI: 10.1145/3219819.3219823.

7. He X. et al. LightGCN: simplifying and powering graph convolution network for recommendation // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2020. P. 639–648. DOI: 10.1145/3397271.3401063.

8. Ji Y., Sun A., Zhang J., Li C. A critical study on data leakage in recommender system offline evaluation // ACM Transactions on Information Systems. 2023. Vol. 41, no. 3. Art. 75. P. 1–27. DOI: 10.1145/3569930.

9. Ploshkin A. et al. Yambda-5B — a large-scale multi-modal dataset for ranking and retrieval // arXiv:2505.22238. 2025. DOI: 10.48550/arXiv.2505.22238. URL: https://arxiv.org/abs/2505.22238 (дата обращения: 09.11.2026).

10. Petrov A., Safilo I., Tikhonovich D., Ignatov D. MTS Kion implicit contextualised sequential dataset for movie recommendation // arXiv:2209.00325. 2022. DOI: 10.48550/arXiv.2209.00325. URL: https://arxiv.org/abs/2209.00325 (дата обращения: 09.11.2026).