

DOI: 10.26794/3030-7097-2026-2-2-16-24  
УДК 004.891:37(045)

# Интеллектуальные рекомендательные системы в образовании. Алгоритмы подбора индивидуальных траекторий обучения

А.В. Овсянникова

Финансовый университет при Правительстве Российской Федерации Москва, Российская Федерация

## АННОТАЦИЯ

Цифровая трансформация системы образования привела к значительному росту данных об учебной активности, что создало технологические предпосылки для внедрения интеллектуальных рекомендательных систем (ИРС). Однако коммерческие рекомендательные алгоритмы, оптимизированные на максимизацию вовлеченности и прибыли, не могут быть напрямую перенесены в образовательную среду, где главной целевой функцией выступает повышение качества усвоения знаний и снижение академической неуспешности. **Цель.** Разработать концептуальную модель интеллектуальной рекомендательной системы для формирования индивидуальных образовательных траекторий, объединяющую гибридные алгоритмы с механизмами объяснимого искусственного интеллекта и встроенными средствами этического контроля. **Методы.** Исследование базируется на систематическом обзоре рецензируемых публикаций за 2021–2025 гг., индексируемых в Scopus, Web of Science и РИНЦ. Применены методы сравнительного анализа алгоритмов рекомендаций, архитектурного моделирования, а также экспериментальная валидация на открытых образовательных датасетах. **Результаты.** Предложена четырехуровневая архитектура ИРС, включающая уровень сбора данных, уровень обработки и векторизации, алгоритмическое ядро на основе гибридной модели и уровень взаимодействия с модулем объяснения рекомендаций. Экспериментально установлено, что предложенная гибридная модель превосходит классическую коллаборативную фильтрацию по точности на 13% и решает проблему «холодного старта» за счет семантического анализа новых курсов. Разработанный модуль объяснений, использующий метод LIME (Local Interpretable Model-agnostic Explanations), позволяет визуализировать факторы, повлиявшие на каждую рекомендацию, что повышает доверие со стороны преподавателей и студентов. **Выводы.** Полученные результаты согласуются с выводами ведущих зарубежных исследователей о преимуществе гибридных графовых моделей перед чисто коллаборативными подходами. В отличие от известных решений, предложенная модель включает встроенный этический блок проверки справедливости и ориентирована на интеграцию с российскими системами управления обучением.

**Ключевые слова:** интеллектуальные рекомендательные системы; персонализация обучения; индивидуальная образовательная траектория; гибридные алгоритмы; графовые нейронные сети; образовательная аналитика; объяснимый искусственный интеллект

**Для цитирования:** Овсянникова А.В. Интеллектуальные рекомендательные системы в образовании. Алгоритмы подбора индивидуальных траекторий обучения. *Цифровые решения и технологии искусственного интеллекта.* 2026;2(2):16-24. DOI: 10.26794/3030-7097-2026-2-2-16-24

## ORIGINAL PAPER

# Intelligent Recommender Systems in Education. Algorithms for Personalised Learning Pathways

A.V. Ovsyannikova

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

## ABSTRACT

The digital transformation of education has led to exponential growth in learning activity data, creating technological prerequisites for the implementation of intelligent recommender systems (IRS). However, commercial recommendation algorithms optimised for maximising engagement and profit cannot be directly transferred to the educational environment, where the main objective function is to improve the quality of knowledge acquisition and reduce academic failure. **Aim.** To develop a conceptual model of an intelligent recommender system with explainable artificial intelligence mechanisms and built-in ethical control tools. **Methods.** The research is based on a systematic review of peer-reviewed publications



for 2021–2025 indexed in Scopus, Web of Science, and RSCI. Methods of comparative analysis of recommendation algorithms, architectural modelling, and experimental validation on open educational datasets. **Results.** A four-level IRS architecture is proposed, comprising a data collection layer, a processing and vectorisation layer, an algorithmic core based on a hybrid model, and an interaction layer with a recommendation explanation module. Experiments have shown that the proposed hybrid model outperforms classical collaborative filtering by 13% in precision and solves the cold-start problem through semantic analysis of new courses. The developed explanation module, based on the LIME method, visualises the factors influencing each recommendation, thereby increasing trust among teachers and students. **Conclusions.** The results are consistent with the findings of leading international researchers on the advantages of hybrid graph models over purely collaborative approaches. Unlike known solutions, the proposed model includes a built-in fairness checking block and is designed for integration with Russian learning management systems.

**Keywords:** intelligent recommender systems; learning personalization; individual learning trajectory; hybrid algorithms; graph neural networks; learning analytics; explainable artificial intelligence

**Для цитирования:** Ovsyannikova A.V. Intelligent recommender systems in education. Algorithms for selecting individual individual educational trajectories. *Digital solutions and artificial intelligence technologies*. 2026;2(2):16-24. DOI:10.26794/3030-7097-2026-2-2-16-24

## ВВЕДЕНИЕ

Современная система образования переживает фундаментальную трансформацию, обусловленную массовой цифровизацией и внедрением технологий искусственного интеллекта. Образовательные организации всех уровней от школ до университетов накапливают огромные массивы данных, логи активности в системах управления обучением LMS, результаты тестирований, время выполнения заданий, посещаемость, взаимодействие с форумами и многое другое. По данным аналитических отчетов, глобальный рынок образовательной аналитики и адаптивного обучения достиг 15,2 млрд долл. в 2024 г. и демонстрирует ежегодный рост около 19%. Этот массив данных создает технологическую основу для применения методов машинного обучения, и в частности, рекомендательных систем, которые способны автоматизировать подбор учебных материалов и формировать индивидуальные образовательные траектории.

Персонализация обучения давно признана ключевым фактором повышения его эффективности. Традиционная модель «единой учебной программы» не учитывает различий в темпе освоения материала, когнитивных стилях, предыдущих знаниях и индивидуальных интересах учащихся. Как отмечают зарубежные источники, внедрение искусственного интеллекта в высшее образование открывает новые возможности для адаптации учебного процесса, но одновременно порождает риски, связанные с этикой и интерпретируемостью алгоритмов. Интеллектуальные рекомендательные системы призваны динамически формировать учебный маршрут, предлагая курсы, модули и задания, которые наилучшим образом соответствуют текущему уровню знаний и целям конкретного студента.

Однако большинство существующих рекомендательных алгоритмов были разработаны для коммерческих приложений, электронной коммерции, видеосервисов, социальных сетей. В этих доменах целевая функция сводится к максимизации вовлеченности

пользователя, времени пребывания на платформе или вероятности покупки. В образовании же главным результатом должно быть устойчивое усвоение знаний, развитие критического мышления и снижение доли отчислений. Прямой перенос коммерческих алгоритмов в образование приводит к ряду негативных эффектов. Во-первых, возникает «пузырь фильтра», когда студенту рекомендуются только те курсы, которые совпадают с его текущими интересами, без выхода на новые, неизвестные дисциплины. Во-вторых, алгоритмы глубокого обучения часто остаются «черными ящиками», ни преподаватель, ни студент не понимают, почему предложен тот или иной модуль. В-третьих, существуют серьезные этические риски, алгоритмы могут усиливать существующее неравенство или нарушать конфиденциальность персональных данных [1, 2].

Анализ научной литературы за последние пять лет показывает, что, несмотря на значительное число публикаций по персонализации обучения, отсутствует унифицированная архитектура интеллектуальной рекомендательной системы, которая одновременно удовлетворяла бы педагогическим, техническим и этическим требованиям. Систематический обзор Klačnja-Milićević et al. выявил, что большинство существующих решений фокусируется либо на точности рекомендаций в ущерб интерпретируемости, либо на отдельных аспектах, таких как прогнозирование успеваемости, но не предлагают целостной модели. Особенно остро эта проблема стоит в контексте российских образовательных стандартов и платформ, где требуется интеграция с LMS Moodle, Stepik [3], а также соблюдение Федерального закона от 27.07.2006 № 152-ФЗ «О персональных данных»<sup>1</sup>.

Таким образом, проблема исследования заключается в отсутствии научно обоснованной, экспериментально подтвержденной модели интеллектуальной рекомендательной системы, которая была бы адап-

<sup>1</sup> URL: <https://base.garant.ru/12148567/>



тирована к специфике образования, обеспечивала высокую точность рекомендаций, их интерпретируемость и этическую безопасность. Новизна работы состоит в предложении гибридной архитектуры, объединяющей графовые нейронные сети, контентный анализ на основе BERT и встроенные механизмы объяснимого ИИ, а также в адаптации модели под российские образовательные платформы.

### СОВРЕМЕННОЕ СОСТОЯНИЕ ИССЛЕДОВАНИЙ В ОБЛАСТИ ОБРАЗОВАТЕЛЬНЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ

Эволюция подходов к персонализации обучения с использованием искусственного интеллекта насчитывает несколько десятилетий. Первые системы «интеллектуальных тьюторов», появившиеся в 1980–1990-х гг., основывались на экспертных правилах и моделях предметной области. Адаптация в них заключалась в изменении последовательности учебных заданий в зависимости от правильности ответов студента. Однако, как подчеркивает обзор зарубежных авторов, такие системы требовали огромных усилий на формализацию знаний и плохо масштабировались на разные дисциплины. С началом 2000-х гг., с развитием методов машинного обучения и анализа больших данных, произошел переход от экспертных систем к статистическим и нейросетевым подходам [4–8].

В современной научной литературе выделяются три основные парадигмы построения рекомендательных систем в образовании. Коллаборативная фильтрация основана на поиске студентов со схожими профилями активности или оценок. Если два студента одинаково оценили одни и те же курсы, то курс, понравившийся одному из них, с высокой вероятностью понравится и другому. Математически предсказание оценки вычисляется как взвешенное среднее оценок соседей. Однако у этого подхода есть серьезные недостатки: проблема «холодного старта»; для нового студента или нового курса нет данных; разреженность матрицы взаимодействий; большинство студентов прошли лишь малую долю всех курсов; отсутствие интерпретируемости; рекомендация не сопровождается объяснением, почему выбран именно этот курс.

Контентно ориентированные подходы, напротив, анализируют свойства самих образовательных ресурсов: описания курсов, аннотации, ключевые слова, компетенции. Векторное представление курса строится с помощью методов обработки естественного языка от классического TF-IDF до современных нейросетевых эмбедингов. Профиль студента формируется на основе курсов, которые он уже успешно освоил. Рекомендация представляет

собой поиск курсов, семантически близких к профилю. Достоинство метода заключается в возможности работы с новыми курсами, не имеющими оценок. Недостаток — это игнорирование коллективного опыта других студентов и, как следствие, более низкая точность по сравнению с коллаборативной фильтрацией при достаточном объеме данных.

Именно поэтому наибольшую эффективность демонстрируют гибридные алгоритмы, сочетающие оба подхода. Классическим примером является матричная факторизация, где матрица взаимодействий студентов и курсов раскладывается на произведение двух матриц меньшей размерности, латентных векторов студентов и курсов. В последние годы все большее распространение получают графовые нейронные сети. В этих моделях строится гетерогенный граф, вершинами которого являются студенты, курсы, учебные понятия, а ребрами взаимодействия, например, изучение курса, успешное выполнение задания, связь «курс–понятие». Рекомендация формулируется как задача предсказания вероятности существования ребра между студентом и курсом. Графовые модели позволяют учитывать сложные многоуровневые зависимости и повышают точность рекомендаций на 15–20% по сравнению с матричной факторизацией.

Наряду с совершенствованием самих алгоритмов, сегодня все больше внимания уделяется проблемам интерпретируемости получаемых решений и их этической обоснованности. В условиях образовательного процесса особенно ценно, когда у преподавателя есть возможность доступно пояснить студенту, на основании каких соображений система выдала ту или иную рекомендацию. Такой подход не только укрепляет доверие к цифровому инструменту, но и предотвращает ситуации, когда алгоритм неоправданно сужает кругозор обучающегося, «замыкая» его на ограниченном наборе тем. Технологии так называемого объяснимого искусственного интеллекта, например метод LIME, дают возможность выделить ключевые признаки, оказавшие решающее влияние на формирование конкретного совета. Как подчеркивают Holstein и его коллеги, наиболее результативной в данном контексте признается гибридная схема «человек + ИИ», здесь педагог выступает в роли наставника, который осмысляет и комментирует выданные системой предложения, а искусственный интеллект берет на себя всю рутинную аналитическую работу [9].

Анализ публикаций российских авторов показал, что большинство работ сосредоточено на прогнозировании успеваемости или аналитике больших данных, в то время как целостные модели рекомендательных систем, учитывающие педагогический контекст и этические нормы, представлены недостаточно [10, 11].



## АЛГОРИТМИЧЕСКАЯ ОСНОВА ИНТЕЛЛЕКТУАЛЬНЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ В ОБРАЗОВАНИИ

Для построения эффективной рекомендательной системы в образовательной среде необходимо понимание сильных и слабых сторон различных классов алгоритмов. Рассмотрим их более подробно, избегая схематичного перечисления.

Коллаборативная фильтрация опирается на предположение, что если студент  $*u*$  имел схожие с другим студентом  $*v*$  оценки по ряду курсов, то и по новому курсу их оценки будут близки. Формально сходство между двумя студентами  $A$  и  $B$  вычисляется как косинус угла между их векторами оценок:

$$\text{sim}(A, B) = (A \cdot B) / (\|A\| \times \|B\|),$$

где  $A \cdot B$  — скалярное произведение векторов, а  $\|A\|$  и  $\|B\|$  — их евклидовы нормы, где  $A$  и  $B$  — векторы оценок студентов. Несмотря на концептуальную простоту, на практике этот метод сталкивается с проблемой «холодного старта», для нового студента, не оценившего ни одного курса, невозможно найти соседей. Кроме того, матрица взаимодействий «студент-курс» крайне разрежена в типичном университете студент проходит 10–20 курсов из сотен доступных. Это приводит к тому, что многие пары «студент-курс» не имеют оценок, и алгоритм дает ненадежные предсказания.

Один из существенных недостатков коллаборативной фильтрации — это игнорирование смыслового наполнения учебных материалов. Вследствие этого два совершенно непохожих по своей тематике курса могут быть признаны «схожими» исключительно на том основании, что они получили высокие оценки от одной и той же группы обучающихся. Подобная ситуация далеко не всегда является педагогически обоснованной.

Альтернативный класс алгоритмов, контентно ориентированные подходы, свободен от указанных ограничений, поскольку опирается на прямые и явные характеристики курсов. Каждый курс представляется в виде признакового вектора. В его роли может выступать, например, вектор частот ключевых слов либо плотный эмбединг, извлеченный из предварительно обученной нейросетевой архитектуры.

Что касается построения профиля студента, то он вычисляется как усредненный вектор тех курсов, которые обучающийся уже успешно завершил. Рекомендательный механизм в таком случае сводится к поиску курсов, для которых значение косинусного расстояния до полученного профиля оказывается минимальным.

Данный метод демонстрирует высокую эффективность при работе с новыми курсами, при этом

проблема «холодного старта» снимается автоматически. Кроме того, контентный подход обеспечивает возможность прозрачного пояснения рекомендаций. Типичный пример формулировки: «Данный курс предлагается вам, поскольку его ключевые термины совпадают с теми, что встречались в уже освоенных вами дисциплинах». Однако его точность обычно ниже, чем у коллаборативной фильтрации, поскольку он игнорирует коллективное мнение тысяч других студентов.

Гибридные модели пытаются объединить преимущества обоих подходов. Классическим примером является матричная факторизация SVD++, которая дополняет латентные векторы студентов и курсов информацией об имплицитных взаимодействиях, например, факт просмотра страницы курса, даже если студент его не оценил. Уравнение предсказания включает глобальное среднее, смещения студента и курса, а также скалярное произведение латентных векторов, к которому добавляется нормализованная сумма векторов имплицитных отзывов. Такая модель обучается с помощью стохастического градиентного спуска, минимизируя среднеквадратичную ошибку на известных оценках.

Более современным направлением являются графовые нейронные сети GNN, в частности, реляционные RGCN. В этой парадигме образовательная экосистема представляется как гетерогенный граф с несколькими типами вершин: студенты, курсы, понятия, преподаватели, и ребер, изучение, включает понятие, преподает и т.д. Каждый тип ребер имеет свою матрицу преобразования. Сообщения между вершинами распространяются через сверточные слои, и на выходе каждый студент и каждый курс получают обновленные эмбединги, учитывающие структуру всего графа. Вероятность того, что студенту  $*u*$  понравится курс  $*i*$ , вычисляется как сигмоида от скалярного произведения их эмбедингов. Преимущество GNN заключается в способности моделировать транзитивные зависимости, если студент  $A$  похож на студента  $B$ , а  $B$  изучил курс  $C$ , то  $A$  может заинтересоваться  $C$ , даже если прямых связей между  $A$  и  $C$  нет. Кроме того, в граф можно легко включать дополнительные сущности, например, учебные цели, профессиональные компетенции, что делает модель прозрачной для педагогов.

Важно отметить, что выбор конкретного алгоритма зависит от объема доступных данных и требований к интерпретируемости. Для небольших университетских курсов с числом студентов менее тысячи может оказаться достаточной коллаборативная фильтрация. Для масштабных онлайн-платформ с миллионами пользователей предпочтительны графовые модели, которые, однако, требуют значитель-



ных вычислительных ресурсов. В любом случае, как показывают эксперименты, гибридные подходы стабильно превосходят «чистые» методы по метрикам точности и полноты [11, 12].

## ПРЕДЛАГАЕМАЯ МОДЕЛЬ ИНТЕЛЛЕКТУАЛЬНОЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЫ

Разработанная в рамках данного исследования модель интеллектуальной рекомендательной системы для образования имеет четырехуровневую архитектуру, каждый уровень которой выполняет строго определенные функции. Такой подход обеспечивает модульность, масштабируемость и возможность поэтапного внедрения.

### Первый уровень — сбор и хранение данных.

Он аккумулирует информацию из разнородных источников. К ним относятся, во-первых, академические показатели, оценки за экзамены, баллы за домашние задания. Во-вторых, логи активности в LMS, время, проведенное на странице курса, количество попыток выполнения теста, участие в форумах, просмотр видеолекций. В-третьих, данные анкетирования, интересы студента, планируемая профессиональная траектория, предпочитаемые форматы обучения. В-четвертых, образовательные стандарты и компетенции. Все данные хранятся в реляционной базе данных с соблюдением требований анонимизации, персональные идентификаторы заменяются на хешированные ключи.

**Второй уровень — предобработка и векторизация.** Сырые данные очищаются от выбросов и пропусков, нормализуются. Для текстового контента, аннотации курсов, описания компетенций, постов на форумах применяется модель EduBERT, версия BERT, дообученная на корпусе образовательных текстов, это учебники, научные статьи по педагогике, методические материалы. Это позволяет получить плотные векторные представления курсов, устойчивые к синонимии и многозначности терминов. Параллельно строится граф знаний, где вершинами являются курсы, а ребрами связи типа «является предпосылкой для», «дополняет», «альтернатива». Такой граф может быть построен полуавтоматически на основе учебных планов и экспертной оценки преподавателей. На выходе этого уровня каждый студент представлен вектором в латентном пространстве, при этом начальный профиль может быть задан диагностическим тестом, а каждый курс двумя векторами, один из семантической модели EduBERT и один из графа знаний.

### Третий уровень — алгоритмическое ядро.

Здесь реализована гибридная модель, объединяющая матричную факторизацию, контентную

близость и графовую нейронную сеть. Базовым является предсказание матричной факторизации с дополнительными признаками:

$$r_{ui} = \mu + b_u + b_i + q_i \cdot p_u + \frac{q_i}{|N(u)|} \cdot \sum_{j \in N(u)} y_j,$$

где  $\mu$  — глобальное среднее;  $b_u$  и  $b_i$  — смещения студента и курса;  $p_u$  и  $q_i$  — латентные векторы;  $y_j$  — вектор имплицитного взаимодействия, например, факт просмотра;  $N(u)$  — множество курсов, с которыми студент взаимодействовал неявно.

К этому базовому предсказанию добавляется штраф за отклонение семантической близости, если вектор курса из EduBERT близок к профилю студента, а матричная факторизация дает низкую оценку, то оценка повышается. Кроме того, используется графовая нейронная сеть RGCN для распространения информации по связям «курс-предпосылка». Итоговая вероятность того, что курс  $i$  будет рекомендован конкретному студенту  $u$ , определяется как линейная комбинация трех составляющих с присвоенными весами. В роли этих составляющих выступают: коллаборативный компонент (реализованный через матричную факторизацию), контентный (косинусная мера близости) и графовый (значение на выходе модели RGCN). Оптимальные значения весов подбираются по результатам анализа валидационной выборки.

Процедура обучения модели опирается на функцию потерь типа BPR, основная задача которой максимизировать разрыв между предсказанными рейтингами для позитивных и негативных примеров. Чтобы ускорить процесс обучения при работе с крупными массивами данных, используется стохастический градиентный спуск с мини-батчевой организацией выборки. Настройка гиперпараметров, включая размерность латентного пространства, число слоев в RGCN и коэффициент регуляризации, осуществляется методом перебора по сетке.

Следующий, **четвертый уровень архитектуры** отвечает за организацию взаимодействия с пользователем и пояснение полученных рекомендаций. Данный уровень включает в себя API для подключения к различным системам управления обучением LMS, таким как Moodle, Blackboard или Stepik, а также пользовательский интерфейс, предназначенный для студентов и преподавателей. Центральное место здесь занимает модуль интерпретации рекомендаций, построенный на базе метода LIME. Для каждого случая рекомендации этот модуль строит локальную аппроксимирующую модель в окрестности рассматриваемой пары «студент-курс», после чего вычисляет степень влияния каждого отдельного признака. В результате студент получает пояснение следующего вида: «Курс «Алгоритмы и структуры данных» предложен



вам по следующим причинам: (1) ранее вы успешно освоили курс «Основы программирования» (вклад фактора — 60%); (2) другие обучающиеся, имеющие схожий профиль, тоже выбирали этот курс (вклад — 25%); (3) вы заявили о заинтересованности в теме «Искусственный интеллект», а данный курс является для нее предварительным условием (вклад — 15%)». Что касается преподавателя, он имеет возможность просматривать сводную статистику по всей учебной группе и, если потребуется, вносить коррективы в весовые коэффициенты отдельных компонентов.

Построение персональной образовательной траектории носит итерационный характер. На этапе первого входа в систему студент выполняет краткое диагностическое тестирование, на основе которого формируется его начальный профиль знаний. В дальнейшем, в процессе обучения, система фиксирует такие показатели, как результаты решения заданий, временные затраты на прохождение каждого модуля, а также количество допущенных ошибок. Актуализация профиля студента происходит в соответствии с адаптивным правилом: вектор  $p_u$  смещается по направлению градиента функции потерь, причем величина шага пропорциональна разнице между реально полученным результатом и предсказанным значением.

Это позволяет системе «учиться вместе со студентом» и подстраивать рекомендации при изменении его уровня знаний или интересов.

### ЭКСПЕРИМЕНТАЛЬНАЯ ВАЛИДАЦИЯ МОДЕЛИ НА РОССИЙСКИХ ОБРАЗОВАТЕЛЬНЫХ ПЛАТФОРМАХ

Для проверки эффективности предложенной гибридной модели были проведены эксперименты на данных, собранных с российских образовательных платформ. В качестве первого источника использовалась система управления обучением на базе Moodle. Массив данных включал обезличенные логи учебной активности 827 студентов за два семестра, а также информацию о 45 курсах от дисциплин математического цикла до программирования. Вторым источником выступила платформа Stepik, содержащая результаты прохождения обучающимися курсов по языкам программирования, анализу данных и машинному обучению. Все персональные данные были анонимизированы в соответствии с требованиями Федерального закона от 27.07.2006 № 152-ФЗ «О персональных данных».

Сравнительному анализу подверглись три класса алгоритмов: классическая коллаборативная фильтрация на основе косинусного сходства, метод матричной факторизации и предложенная гибридная модель. Оценка качества проводилась по схеме пя-

тикратной кросс-валидации с разбиением выборки в процентах на обучающую (80), валидационную (10) и тестовую (10) части. В ходе экспериментальной оценки применялись три метрики. Первая — это процент релевантных (полезных) курсов в списке из первых десяти позиций. Вторая метрика отражает, какая доля от общего объема действительно подходящих курсов была успешно обнаружена системой. Третья, ранжирующий показатель, который штрафует расположение полезного курса ближе к концу списка, чем выше в перечне находится ценный для студента курс, тем лучше итоговое значение.

Проведенные эксперименты подтвердили стабильное преимущество гибридной архитектуры по сравнению с другими методами. На наборе данных из среды Moodle для предложенной модели процент полезных курсов среди первых десяти позиций достиг 0,54. Для сравнения, метод матричной факторизации дал результат 0,46, а традиционная коллаборативная фильтрация 0,41. Следовательно, выигрыш в точности относительно классического подхода составил 13%. Что касается полноты, доли обнаруженных полезных курсов от общего числа подходящих, то здесь значение выросло с 0,29 у коллаборативной фильтрации до 0,38 у гибридной модели. Показатель качества ранжирования, учитывающий порядок следования рекомендаций, также увеличился с 0,32 до 0,41.

Предложенный подход позволяет эффективно решать проблему «холодного старта» применительно к новым курсам, по которым еще отсутствуют какие-либо оценки пользователей.

В сценарии, где 20% курсов были исключены из обучающей выборки, коллаборативная фильтрация не могла сформировать для них ни одной рекомендации, а метод матричной факторизации давал предсказания, близкие к случайным. Предложенная модель, благодаря использованию семантических векторных представлений из языковой модели EduBERT, обеспечила для новых курсов долю полезных рекомендаций среди первых десяти на уровне 0,32, что сопоставимо с качеством рекомендаций для курсов, присутствовавших в обучающей выборке.

Дополнительно была проведена субъективная оценка полезности рекомендаций с участием 50 студентов Финансового университета при Правительстве РФ. Участникам предлагалось оценить по пятибалльной шкале, в какой степени предложенные курсы соответствуют их образовательным целям. Средняя оценка для рекомендаций, сгенерированных гибридной моделью, составила 4,2 балла, для матричной факторизации 3,7 баллов; для коллаборативной фильтрации 3,3 балла. Студенты также отметили, что наличие пояснений к рекомендациям, реализованных с помощью метода LIME, повышает их доверие



к системе и способствует более осознанному выбору образовательной траектории.

Полученные результаты свидетельствуют о применимости предложенной гибридной модели в условиях российских образовательных платформ. Модель демонстрирует устойчивую работу как на данных традиционных системах управления обучением, так и на данных массовых открытых онлайн-курсов. При этом вычислительные затраты не превышают возможностей типовых серверов, используемых в российских университетах. Основным ограничением остается гетерогенность форматов хранения учебной активности в различных образовательных организациях, что требует дополнительной работы по унификации данных перед внедрением системы [13, 14].

### ЭТИЧЕСКИЕ И ПЕДАГОГИЧЕСКИЕ АСПЕКТЫ ВНЕДРЕНИЯ

Внедрение искусственного интеллекта в образование не может ограничиваться только техническими и экономическими соображениями. Необходим тщательный анализ этических рисков и разработка мер по их минимизации. В рамках исследования выделены основные аспекты.

**Прозрачность и интерпретируемость.** Преподаватели и студенты должны понимать, на каких основаниях система делает те или иные рекомендации. В отличие от коммерческих сервисов, где алгоритм может оставаться «черным ящиком», в образовании непонимание логики подрывает доверие и снижает педагогическую эффективность. Предложенная модель включает модуль LIME, который для каждой рекомендации выдает веса признаков. Это позволяет преподавателю объяснить студенту: «Система предложила вам этот курс, потому что вы хорошо справились с предыдущим модулем по линейной алгебре». Педагог наделен функцией просмотра сводных отчетов. При необходимости он может вручную изменить весовые коэффициенты отдельных компонентов, к примеру, понизить значимость коллаборативного фактора в ситуации, когда учебная группа насчитывает малое количество студентов.

Отдельный аспект — обеспечение беспристрастности рекомендаций и недопущение дискриминационных эффектов. Известно, что алгоритмы, построенные на методах машинного обучения, имеют тенденцию не просто повторять, но и усугублять те искажения, которые уже присутствуют в исходных данных. Рассмотрим гипотетический случай: если в ретроспективных данных о прохождении некоторого сложного технического курса большинство успешно справившихся обучающихся составляли мужчины, то алгоритм с высокой вероятностью начнет адресовать данный курс преимущественно мужской аудито-

рии, даже при условии, что женщины демонстрируют сопоставимый уровень подготовки. Чтобы вовремя обнаружить подобные перекосы в работе модели, автор предлагает проводить на валидационной выборке оценку по двум критериям: демографический паритет и равенство возможностей.

**Конфиденциальность и безопасность данных.** Образовательные данные относятся к категории персональных и чувствительных. В России их обработка регулируется Федеральным законом о персональных данных, а также нормативными актами Министерства просвещения и Министерства науки и высшего образования РФ. В архитектуре автором реализованы следующие меры: анонимизация, удаление прямых идентификаторов, замена на хеши; минимизация, собираются только данные, необходимые для работы алгоритма; шифрование при передаче и хранении, разграничение доступа по ролям, студент видит только свои данные, преподаватель видит данные своей группы, администратор видит агрегированную статистику. Кроме того, предусмотрена возможность для студента отказаться от сбора некоторых типов данных, например, логи кликов, без потери базовой функциональности.

**Баланс между персонализацией и академической свободой.** Чрезмерная персонализация может привести к тому, что студент будет получать только те курсы, которые соответствуют его текущим интересам и уровню, и никогда не столкнется с новыми, сложными или неожиданными темами. Это ограничивает развитие критического мышления и междисциплинарных связей. Для предотвращения этого эффекта в модель встроены два механизма. Во-первых, в рекомендациях присутствует элемент случайности с вероятностью 5%, вместо топ-курса предлагается случайный курс из числа не входящих в текущий профиль. Во-вторых, преподаватель может задать обязательные модули, которые должны быть включены в траекторию независимо от рекомендаций. Таким образом, сохраняется баланс между адаптивностью и соблюдением образовательных стандартов.

**Роль преподавателя в системе с ИИ.** Важно подчеркнуть, что интеллектуальная рекомендательная система не призвана заменить педагога. Ее задача взять на себя рутинную аналитику, сбор и обработку данных, выявление паттернов, генерацию начальных рекомендаций, освобождая время преподавателя для индивидуальной работы со студентами и обсуждения сложных тем. Наилучшие результаты достигаются при гибридной модели «человек + ИИ», где преподаватель выступает как наставник, интерпретирующий рекомендации и принимающий финальные решения о корректировке траектории. Как показано в работе Molenaar, именно такая модель



способствует развитию саморегулируемого обучения и критического мышления [15, 16].

## ВЫВОДЫ И ПЕРСПЕКТИВЫ

В настоящей статье представлена концептуальная модель интеллектуальной рекомендательной системы для персонализации обучения, объединяющая современные достижения в области коллаборативной фильтрации, контентного анализа, графовых нейронных сетей и объяснимого искусственного интеллекта.

По итогам выполненной работы можно сформулировать несколько ключевых положений.

Алгоритмы гибридного типа, которые одновременно учитывают историю взаимодействия студентов с учебными курсами и смысловое наполнение образовательных материалов, демонстрируют более высокие показатели по критериям полноты и точности по сравнению с методами, использующими только один тип данных.

Проблема «холодного старта» применительно к вновь созданным курсам успешно снимается благодаря применению плотных векторных представлений, эмбедингов, получаемых с помощью предварительно обученных языковых моделей. Данный подход дает возможность формировать рекомендации для курсов, еще не получивших ни одной оценки, опираясь исключительно на их текстовые аннотации. При этом достигаемая точность оказывается сопоставимой с той, что характерна для курсов с уже накопленной историей оценок.

В контексте образовательной среды способность системы объяснять выдаваемые рекомендации становится обязательным требованием. Использование технологий интерпретируемого искусственного


интеллекта позволяет наглядно представить, какой вклад вносит каждый отдельный признак в принятое решение. Как следствие, растет уровень доверия как со стороны преподавателей, так и со стороны обучающихся, а у последних появляется инструмент для осознанного построения собственной учебной траектории.

Этические вопросы, включая справедливость, защиту персональных данных, баланс между персонализацией и академической свободой, должны закладываться в фундамент архитектуры системы еще на этапе ее проектирования, а не добавляться позже в виде «надстроечных» модулей. Предложенная в данной работе модель предусматривает оценку метрик демографического паритета, встроенные механизмы обезличивания данных, а также специальную стратегию для поддержания разнообразия выдаваемых рекомендаций.

Ограничения и сложности практической реализации. К числу главных барьеров, мешающих массовому внедрению подобных решений, относятся: отсутствие унифицированных стандартов на образовательные данные в разных вузах и школах, что серьезно осложняет перенос моделей с одной платформы на другую, высокая ресурсоемкость обучения графовых нейронных сетей на крупных массивах данных, а также необходимость регулярного сопровождения и переобучения моделей по мере обновления учебных планов и появления новых курсов. Несмотря на перечисленные трудности, разработанная модель может рассматриваться как основа для создания адаптивных обучающих сред следующего поколения. Открытость ее архитектуры, кроме того, допускает поэтапное внедрение даже в условиях ограниченных вычислительных и временных ресурсов.

## СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Bond M., Khosravi H., De Laat M., Bergdahl N. A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*. 2024;21:4. URL: <https://doi.org/10.1186/s41239-023-00436-z>
2. Holmes W., Bialik M., Fadel C. Artificial intelligence in education. In: Data ethics: Building trust: How digital technologies can serve humanity. 2023:621–653. URL: <https://doi.org/10.58863/20.500.12424/4276068>
3. Klačnja-Milićević A., Ivanović M., Vesin B., Satratzemi M., Wasson B. Learning Analytics — Trends and Challenges. *Frontiers in Artificial Intelligence*. 2022;5:856807. URL: <https://doi.org/10.3389/frai.2022.856807>
4. Duan C., Yang J., Cui Q., Zhang W., Wan X., Zhang M. Enhancing the recommendation of learning resources for learners via an advanced knowledge graph. *Applied Sciences*. 2025;15(8):4204. URL: <https://doi.org/10.3390/app15084204>
5. Rigou A., Kyriazi F., Thomakos D. Predicting student success through learning analytics: A comparative modeling approach. *Creative Education*. 2025;16:1107–1119. URL: <https://doi.org/10.4236/ce.2025.168069>
6. Wu S., Sun F., Zhang W., Xie X., Cui B. Graph Neural Networks in Recommender Systems: A Survey. *ACM Computing Surveys*. 2022;55(5):97. URL: <https://doi.org/10.1145/3535101>
7. Yan J., Liu S., Armwood-Gordon C., Li L. Factors Affecting Active Flipped Learning on Underrepresented Students in Three STEM Courses. *Education and Information Technologies*. 2024;29(9):10791–10804. URL: <https://doi.org/10.1007/s10639-023-12234-1>



8. Захарова Ж.Л., Жиркова З.С. Условия создания цифровой трансформации в образовательной среде вуза. В сб.: Молодой исследователь: вопросы науки и образования. Киров; 2021:282–285. URL: <https://www.elibrary.ru/pfwwoi>  
Zakharova Zh.L., Zhirkova Z.S. Conditions for creating digital transformation in the educational environment of a university. In: Young Researcher: Issues of science and education. Kirov; 2021:282-285. (In Russ.). URL: <https://www.elibrary.ru/pfwwoi>
9. Holstein K., Aleven V., Rummel N. A Conceptual Framework for Human – AI Hybrid Adaptivity in Education. In: Artificial Intelligence in Education. Part I. Cham: Springer; 2020:240–254. URL: [https://doi.org/10.1007/978-3-030-52237-7\\_20](https://doi.org/10.1007/978-3-030-52237-7_20)
10. Овсянникова А.В. Цифровая трансформация образования: ключевые драйверы, барьеры и перспективы развития. *Мир науки. Педагогика и психология*. 2025;13(3):27. URL: <https://www.elibrary.ru/velqya>  
Ovsyannikova A.V. Digital transformation of education: Key drivers, barriers and development prospects. *The World of Science. Pedagogy and Psychology*. 2025;13(3):27. (In Russ.). URL: <https://www.elibrary.ru/velqya>
11. Подлевских А.П., Суетин С.Н., Степкин С.В. Методология по курсу «Проектирование информационных систем» в условиях перехода к цифровой образовательной среде. *Современные наукоемкие технологии*. 2021;2:45–51. URL: <https://doi.org/10.17513/snt.38492>  
Podlevskikh A.P., Suetin S.N., Stepkin S.V. Methodology for the course “Designing information systems” in the context of transition to a digital educational environment. *Modern High-tech Technologies*. 2021;2:45–51. (In Russ.). URL: <https://doi.org/10.17513/snt.38492>
12. Nguyen A., Ilesanmi F., Dang B., Vuorenmaa E., Järvelä S. Hybrid Intelligence in Academic Writing: Examining Self-Regulated Learning Patterns in an AI-Assisted Writing Task. In.: *Hybrid Human Artificial Intelligence (HHAI)*. 2024;241-254. URL: <https://doi.org/10.3233/FAIA240198>.
13. Topali P., Ortega-Arranz A., Rodríguez-Triana M.J., Er E., Khalil M., Akçapınar G. Designing human-centered learning analytics and artificial intelligence in education solutions: A systematic literature review. *Behaviour and Information Technology*. 2025;44(5):1071–1098. URL: <https://doi.org/10.1080/0144929X.2024.2345295>
14. Bai Y., et al. Impact of generative AI interaction and output quality on university students’ learning outcomes: A technology-mediated and motivation-driven approach. *Scientific Reports*. 2025;15(1):24054. URL: <https://doi.org/10.1038/s41598-025-08697-6>
15. Hummel S. Ethical and Responsible AI in Education: Situated Ethics for Democratic Learning. *Education Sciences*. 2025;15(12):1594. URL: <https://doi.org/10.3390/educsci15121594>
16. Кеннон О.В., Пустошило П.В., Иванцов А.А. Проблема использования нейросетей и инструментов искусственного интеллекта обучающимися вузов: этический аспект. *Российский гуманитарный журнал*. 2025;16(3):192–210. URL: <https://doi.org/10.12731/2658-4034-2025-16-3-862>  
Cannon O.V., Pustoshilo P.V., Ivantsov A.A. The problem of using neural networks and artificial intelligence tools by university students: An ethical aspect. *Russian Humanitarian Journal*. 2025;16(3):192-210. (In Russ.). URL: <https://doi.org/10.12731/2658-4034-2025-16-3-862>

## ИНФОРМАЦИЯ ОБ АВТОРЕ / ABOUT THE AUTHOR

**Анна Вячеславовна Овсянникова** — кандидат педагогических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация  
**Anna V. Ovsyannikova** — Cand. Sci. (Ped.), Assoc. Prof. of the Department of Mathematics and Data Analysis of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation  
<https://orcid.org/0000-0002-1716-3100>  
[avovsyannikova@fa.ru](mailto:avovsyannikova@fa.ru)

*Конфликт интересов: автор заявляет об отсутствии конфликта интересов.*  
*Conflicts of Interest Statement: The author has no conflicts of interest to declare.*

*Статья поступила 19.12.2025; после рецензирования 12.01.2026; принята к публикации 26.03.2026.*  
*Автор прочитала и одобрила окончательный вариант рукописи.*  
*The article was submitted on 19.12.2025; revised on 12.01.2026 and accepted for publication on 26.03.2026.*  
*The author read and approved the final version of the manuscript.*