

УДК 004.8

DOI 10.17513/snt.40531

СОЗДАНИЕ КОНЦЕПЦИИ ГИБРИДНОЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЫ ДЛЯ ИНДИВИДУАЛЬНОГО ПОДБОРА ОБРАЗОВАТЕЛЬНЫХ МАРШРУТОВ

Староверова Н.А. ORCID ID 0000-0002-5524-1325

ФГБОУ ВО «Казанский национальный исследовательский технологический университет»,
Россия, Казань, e-mail: nata-staroverova@yandex.ru

В работе решается проблема недостаточной персонализации в современных образовательных платформах. Целью работы является разработка концепции гибридной рекомендательной системы для построения индивидуальных образовательных траекторий с многоуровневой адаптацией. Для тестирования системы использовали синтетический датасет (10 000 студентов, 5 вузов, 120 курсов), а также два датасета «Course Reviews on Coursera» и «Coursera Courses & Skills dataset 2024», содержащие список из 622 курсов и список из 1,45 млн отзывов студентов вместе с рейтингами. В аналитической части проведен систематический анализ образовательных рекомендательных систем (2018–2023 гг.), выявивший три критических ограничения: игнорирование педагогического контекста, линейность рекомендаций, низкая интерпретируемость. Разработана архитектура системы, решающая эти проблемы через комбинацию методов: контентную фильтрацию, косинусное сходство, коллаборативную фильтрацию, онтологическую корректировку на основе компетенций, модуль когнитивной адаптации, а также динамическую балансировку весов и интерпретируемость. Также были предприняты шаги в решении проблем технологий искусственного интеллекта: проблема «холодного старта» путем замещения коллаборативной фильтрации контентными методами для новых курсов/пользователей, «фильтрующий пузырь» – введением коэффициента новизны в ранжирование, интерпретируемость с помощью визуализации влияния факторов в интерфейсе. В качестве метрик при тестировании системы были выбраны: Precision@k (где $k = 5$), Mean Reciprocal Rank, PEDAG-score. Тестирование подтвердило работоспособность системы. Таким образом, предлагаемая концепция решает фундаментальные ограничения образовательных рекомендательных систем, обеспечивая глубокую персонализацию, педагогическую обоснованность траекторий и интерпретируемость, что способствует повышению качества онлайн-обучения.

Ключевые слова: рекомендательные системы, индивидуализация обучения, образовательная аналитика, гибридная фильтрация, когнитивные профили

CREATION OF THE CONCEPT OF A HYBRID RECOMMENDATION SYSTEM FOR INDIVIDUAL SELECTION OF EDUCATIONAL ROUTES

Staroverova N.A. ORCID ID 0000-0002-5524-1325

Kazan National Research Technological University, Russia, Kazan,
e-mail: nata-staroverova@yandex.ru

The paper solves the problem of insufficient personalization in modern educational platforms. The aim of the work is to develop the concept of a hybrid recommendation system for building individual educational trajectories with multilevel adaptation. To test the system, we used a synthetic dataset (10,000 students, 5 universities, 120 courses), as well as two datasets “Course Reviews on Coursera” and “Coursera Courses & Skills dataset 2024”, containing a list of 622 courses and a list of 1.45 million student reviews along with ratings. In the analytical part, a systematic analysis of educational recommendation systems (2018–2023) was carried out, which revealed three critical limitations: ignoring the pedagogical context, the linearity of recommendations, and low interpretability. The system architecture has been developed to solve these problems through a combination of methods: content filtering, cosine similarity, collaborative filtering, competence-based ontological adjustment, cognitive adaptation module, as well as dynamic balancing of weights and interpretability. Steps have also been taken to solve the problems of artificial intelligence technologies: the problem of “cold start” by replacing collaborative filtering with content methods for new courses/users, the “filter bubble” by introducing a novelty coefficient into the ranking, interpretability by visualizing the influence of factors in the interface. The following metrics were selected: Precision@k (where $k=5$), Mean Reciprocal Rank, PEDAG-score. Testing has confirmed the system’s performance. Thus, the proposed concept solves the fundamental limitations of educational recommendation systems, providing deep personalization, pedagogical validity of trajectories and interpretability, which contributes to improving the quality of online learning.

Keywords: recommendation systems, individualization of learning, hybrid filtering, educational analytics, cognitive profiles

Введение

Цифровая трансформация образования привела к парадоксу: при росте доступности контента (Coursera: +97 курсов/мес. в 2022 г.) эффективность обучения снижается. По данным HolonIQ (2023), 68 % студентов не завершают МООС из-за нерелевантности материалов, а 42 % преподавателей

отмечают падение успеваемости при переходе на онлайн-форматы. Традиционные рекомендательные системы, доказавшие эффективность в e-commerce (Amazon: +35 % конверсии), в образовании демонстрируют ограниченность в своей применимости [1–3]. Например, рекомендации часто основаны на популярности, а не педа-

гогической целесообразности [4], в некоторых случаях игнорируются компетентностные дефициты [5], кроме того, отсутствует адаптация к когнитивным стилям [6].

Цель исследования – разработка и экспериментальная проверка концепции гибридной рекомендательной системы, которая за счет комбинации методов коллаборативной и контентной фильтрации, онтологической корректировки и учета когнитивных профилей обеспечивает педагогически обоснованное и интерпретируемое построение индивидуальных образовательных траекторий.

Для достижения поставленной цели были решены следующие задачи.

1. Анализ ограничений существующих образовательных рекомендательных систем (РС).
2. Разработка стратегий преодоления проблем внедрения искусственного интеллекта (ИИ).
3. Проектирование гибридной архитектуры с поддержкой обратной связи.
4. Тестирование пилотной модели рекомендательной системы.

Материалы и методы исследования

Для решения задачи анализа ограничений существующих образовательных рекомендательных систем методологическая база исследования включает комбинацию качественных и количественных методов, к которым относятся анализ публикаций, опросы и интервью, анализ данных. К исследованию были привлечены преподаватели высших учебных заведений (20 ч), оценка проводилась по 15 критериям, по 5-балльной системе оценивания.

Для первых экспериментов по тестированию разработанного пилотного варианта рекомендательной системы из-за отсутствия данных для работы использовались три вида датасетов: синтетический датасет (10 000 студентов, 5 вузов, 120 курсов) и два датасета «Course Reviews on Coursera» и «Coursera Courses & Skills dataset 2024», содержащие список из 622 курсов, а также список из 1,45 млн отзывов студентов вместе с рейтингами [7–9]. В качестве метрик использовались: Precision@k (где k = 5 и соответствует количеству рекомендаций, которое должна дать система), Mean Reciprocal Rank (Mean Reciprocal Rank (MRR) – метрика, оценивающая среднюю величину, обратную рангу первой релевантной рекомендации в списке. Чем выше MRR (максимальное значение 1,0), тем ближе к началу списка система ставит правильные рекомендации), PEDAG-score (авторская метрика: соответствие целям + баланс нагрузок).

Результаты исследования и их обсуждение

В работе проанализировано 28 рекомендательных систем, используемых в различных образовательных системах. На основе проведенного анализа были сделаны следующие выводы.

В системе Coursera Recommender System рекомендации основаны на истории просмотров, пройденных курсах и интересах пользователей. Достоинства данной системы – простота использования, учет популярности контента и поведенческих моделей пользователей. Однако наблюдается ограниченная персонализация, которая не всегда учитывает индивидуальные цели и потребности обучающихся [10].

У системы EdRecSys персонализация реализована на основе успеваемости, структуры курсов и предполагаемого пути обучения. К преимуществам можно отнести акцент на контекстуальную персонализацию, учитывающую особенности образовательного процесса. Но интеграция с внешними данными реализована недостаточно качественно, отсутствует обратная связь от преподавателей, кроме того, недостаточная интеграция с системами управления обучением (LMS) [11].

В системе LearnSphere имеется объединение лог-файлов, видеоматериалов, тестов и активности в системе управления обучением (LMS). Преимуществом данной системы является комплексный анализ данных, позволяющий выявить закономерности и предпочтения пользователей. Однако она требует значительных усилий по ручной настройке, не всегда реализует автоматизированное построение образовательных траекторий [12].

Система MoodleRec позволяет получить рекомендации ресурсов на основе активности в системе Moodle. Наличие специализации под конкретную LMS обеспечивает более глубокую интеграцию с системой управления обучением. Но это же и является в некоторой степени недостатком, так как ограничение рамками Moodle не учитывает когнитивные или мотивационные параметры обучающихся [13].

Khan Academy имеет алгоритмы адаптивного выбора ресурсов на основе предпочтений стиля обучения (видео, текст, задачи). Учитываются предпочтения пользователей и адаптация контента под их индивидуальные потребности. Но при этом наблюдаются фиксированные предпочтения и отсутствие оценки прогресса в контексте образовательных целей [14].

Таблица 1

Оценка образовательных рекомендательных систем
по педагогическим критериям

Система	Учет целей	Адаптация к стилю обучения	Интеграция с педагогом	Интерпретируемость
Coursera RecSys [10]	2,1/5	1,7/5	0,5/5	1,8/5
EdNet (KDD2021) [11]	3,4/5	2,3/5	2,3/5	2,5/5
Duolingo AI [8]	4,1/5	3,8/5	0,7/5	3,2/5
LearnSphere [12]	2/5	2,5/5	0,5/5	3/5
EdRecSys [15]	1/5	3/5	0,5/5	2,5/5
MoodleRec [13]	1,5/5	1,0/5	3,0/5	2,0/5
Khan Academy [14]	3,0/5	4,0/5	1,0/5	3,0/5

Примечание: оценка выставлялась по 5-балльной шкале, где 1 – минимальное соответствие критерию, 5 – максимальное.

Источник: составлено автором по результатам исследования.

Ограничения, выявленные в процессе анализа рекомендательных систем, применяемых на крупных образовательных платформах, представлены в табл. 1, для формирования оценок, которые представлены в таблице, использовался метод экспертного анализа. Привлеченные преподаватели ($n = 20$) оценивали каждую систему по заранее определенным критериям на основе анализа научных публикаций, описаний функционала и, где это было возможно, тестирования открытых демоверсий. Итоговые баллы по каждому критерию являются усредненным значением экспертных оценок.

Таким образом, можно видеть, что каждая из этих систем имеет свои сильные и слабые стороны. Например, Coursera и Khan Academy хорошо подходят для массового использования благодаря простоте и интуитивно понятному интерфейсу, но не всегда могут учитывать индивидуальные потребности пользователей. EdRecSys и LearnSphere предлагают более глубокую персонализацию, но требуют значительных усилий для настройки и интеграции. MoodleRec, в свою очередь, специализируется на работе с конкретной LMS, что может быть преимуществом для образовательных учреждений, использующих эту систему.

Проведенное аналитическое исследование выявило следующие ключевые проблемы.

1. Контекстная слепота – системы не различают типы образовательных целей.

Например, при заявленной цели «анализ данных» в 90% случаев предлагается рекомендация курса Python, однако не учитывается необходимость математической базы [13, 14].

2. Одномерность фильтрации – 94% проанализированных рекомендательных систем используют единственный метод (коллаборативный – 67%, контентный – 27%), что ведет к «пузырям фильтров» для слабых студентов [9, 11], а также игнорированию междисциплинарных связей.

3. Отсутствие педагогического контура, то есть обратная связь преподавателей либо не интегрируется (79% случаев), либо используется пассивно (оценки без комментариев).

Для устранения выявленных проблем автором предпринята попытка проектирования рекомендательной системы с применением гибридной модели фильтрации, архитектура которой комбинирует три слоя (рисунок). Основной вычислительный модуль системы (так называемый «гибридный движок») реализует следующий алгоритм:

1. Контентный слой (CB) [14, 15]:

а) вход: онтология компетенций (O*NET), метаданные курсов;

б) алгоритм: TF-IDF + cosine similarity – для анализа текста и определения сходства документов.

2. Коллаборативный слой (CF) [16]:

а) модель: SVD++ с регуляризацией.

3. Онтологический слой [17]:

а) корректировка по правилам:

IF цель = «ML» AND уровень математики < 0.7 THEN recommend = «Линейная алгебра»

Так же добавлен Модуль когнитивной адаптации, который построен с учетом модели V.A.R.K [18]:

- Визуалы: видео, инфографика.
- Аудиалы: подкасты, лекции.
- Кинестеты: симуляторы, проекты.
- Читатели: статьи, учебники.




Схема работы гибридной архитектуры рекомендательной системы
Источник: составлено автором по результатам исследования

Для классификации обучающихся и оптимизации рекомендаций применяется следующий метод сопоставления:

Рекомендация = $\text{argmax}(2 * \text{Предпочтение} * \text{Эффективность} / (\text{Предпочтение} + \text{Эффективность}))$, в рамках данного метода осуществляется определение значения аргумента, при котором достигается максимум указанной функции.

Модуль сбора данных аккумулирует результаты запросов, оценки выполнения заданий, отзывы и прочие «цифровые следы» работы пользователя. В дальнейшем эти данные проходят предобработку и используются для выработки рекомендаций.

К инновационным аспектам данной системы можно отнести, динамическую коррекцию весов [12, 19]:

Коэффициенты модели обновляются по формуле

$$w_i^{(t+1)} = w_i^{(t)} + \eta * \frac{\partial \text{Accuracy}}{\partial w_i} * \text{FeedbackScore},$$

где $\eta = 0,15$ – скорость обучения, $\text{FeedbackScore} \in [-1, 1]$.

Скорость обучения $\eta = 0,15$ была выбрана в результате серии экспериментов по подбору параметров (hyperparameter tuning) и является компромиссным значением, обеспечивающим достаточно быструю сходимость алгоритма без риска переобуче-

ния. Данное значение согласуется с общепринятым диапазоном для подобных задач оптимизации [4].

Для оценки эффективности предложенной гибридной системы было проведено сравнительное тестирование на одном и том же синтетическом датасете (10 000 студентов, 120 курсов) с двумя классическими алгоритмами: ItemKNN (метод коллаборативной фильтрации на основе k ближайших соседей) и LightFM (популярная гибридная модель). Результаты сравнения по выбранным метрикам представлены в табл. 2 [20, 21].

В табл. 3 представлен результат тестирования системы по предоставлению рекомендации на основе косинусного сходства между вектором профиля пользователя и векторами признаков курсов. Например, в результате анализа для пользователя с индексом 39505, прошедшего курс Programming for Everybody (Getting Started with Python), были рекомендованы топ-5 курсов (количество рекомендованных курсов можно изменять) с высокими показателями сходства (табл. 3).

Таким образом, разработанная гибридная архитектура целенаправленно включает механизмы для решения фундаментальных проблем, присущих рекомендательным системам в образовании.

Таблица 2

Сравнение эффективности (%)

Система	Precision@5	MRR	PEDAG-score
ItemKNN	63,7	0,52	58,2
LightFM	68,9	0,56	61,8
Предложенная система	79,4	0,72	83,6

Источник: составлено автором по результатам исследования.

Таблица 3

Результаты работы обученной рекомендательной системы

Пользователь	Пройденные курсы	Рекомендованный курс	Оценка косинусного сходства
39505	Programming for Everybody (Getting Started with Python)	Data Structures and Algorithms	0,60
		Python Programming Fundamentals	0,60
		Introductory C Programming	0,54
		Learn to Program: The Fundamentals	0,52
		Foundations of Data Structures and Algorithms	0,51

Источник: составлено автором по результатам исследования.

Ниже детально описаны стратегии, направленные на преодоление трех ключевых ограничений.

1. Проблема «холодного старта» (Cold Start)

Суть проблемы: Невозможность давать качественные рекомендации новым пользователям (студентам) или для новых курсов из-за отсутствия данных о взаимодействиях (оценок, просмотров). Это критическое ограничение для образовательных платформ, где постоянно появляются новые студенты и обновляется контент.

Предложенное решение: Многоуровневая стратегия, основанная на приоритете методов, не требующих исторических данных.

– Для новых пользователей: При регистрации система предлагает пользователю указать образовательные цели, интересы и предпочтительные форматы обучения (на основе модели V.A.R.K.). На этом этапе коллаборативная фильтрация (CF) полностью отключается. Рекомендации формируются исключительно на основе:

- Контентной фильтрации (CB): Курсы отбираются по сходству их метаданных (описания, навыки) с указанными пользователем целями.

- Онтологической корректировки (Onto): Система использует правила для формирования педагогически обоснованной последовательности. Например, если пользователь указал цель «Машинное обучение», но не имеет задокументированных навыков по математике, онтологический слой автоматически добавит в рекомендации курс по линейной алгебре.

– Для новых курсов: Пока курс не набрал достаточного количества оценок от студентов, его рейтинг в коллаборативной фильтрации является ненадежным. Поэтому вес коллаборативного компонента (CF_Score) для такого курса в формуле вычислительного модуля системы временно понижается, а вес контентного (CB_Score) и онтологического (Onto_Score) повышается. Это позволяет включать новые, релевантные курсы в рекомендации уже на раннем этапе.

Таким образом, проблема «холодного старта» решается за счет гибкой архитектуры, где в условиях недостатка данных доминируют контентные и онтологические методы, обеспечивая педагогическую релевантность даже для новых участников образовательного процесса.

2. Проблема «фильтрующего пузыря» (Filter Bubble)

Суть проблемы: Традиционные системы, особенно основанные на коллаборативной фильтрации, склонны создавать «эффект эхо-камеры», предлагая пользователю контент, чрезмерно похожий на уже потребленный. Это ограничивает образовательный кругозор и блокирует знакомство со смежными областями, что особенно критично для слабых студентов, рискующих заикнуться на материалах низкой сложности.

Предложенное решение: в алгоритм ранжирования финального списка рекомендаций встроен механизм взвешивания, балансирующий между релевантностью и новизной.

– Расширенная формула финального ранжирования.

Итоговая оценка (Final_Score) для каждого курса не только вычисляется по формуле

$$\text{Score} = 0,4 * \text{CB} + 0,3 * \text{CF} + 0,3 * \text{Onto},$$

но и корректируется с помощью Коэффициента Новизны (Novelty_Ratio):

$$\text{Final_Score} = (1 - \beta) * \text{Relevance_Score} + \beta * \text{Novelty_Ratio}$$

где Relevance_Score – исходная релевантность курса, рассчитанная вычислительным модулем системы;

Novelty_Ratio – метрика новизны курса для конкретного пользователя (рассчитывается как 1 – косинусное сходство вектора курса с усредненным вектором пройденных пользователем курсов);

β – гиперпараметр, задающий вес новизны в финальной оценке (в пилотных тестах устанавливался на уровне 0,1–0,15).

– Динамическая адаптация:

Вес новизны β может корректироваться на основе обратной связи (FeedbackScore). Если пользователь часто игнорирует рекомендации с высоким Novelty_Ratio, система может незначительно уменьшить β , сместив акцент на релевантность. И наоборот, активное взаимодействие с «новыми» рекомендациями ведет к увеличению β .

Данный механизм обеспечивает управляемое разнообразие, целенаправленно предлагая релевантные материалы из новых для пользователя областей, связанных с его целями через онтологию компетенций.

3. Проблема интерпретируемости (Explainable AI, XAI)

Суть проблемы: «Черный ящик» сложных алгоритмов машинного обучения подрывает доверие пользователей и педагогов, которые не понимают логику рекомендаций. Без объяснений невозможно провести педагогический анализ целесообразности предложенной траектории.

Предложенное решение: Многоуровневая система генерации объяснений, интегрированная в пользовательский интерфейс.

– Локальная интерпретируемость с помощью LIME: Для объяснения каждой конкретной рекомендации используется метод LIME (Local Interpretable Model-agnostic Explanations). Он аппроксимирует сложную гибридную модель простой линейной моделью в окрестности конкретного предсказания. Это позволяет сгенерировать текст такого вида:

«Курс “Статистика” рекомендован потому, что:

✓ Соответствует вашей цели “Анализ данных” (вес 0,38)

✓ Требуется для курса ML в вашем плане (вес 0,29)

✓ Студенты с похожим профилем успешно освоили (вес 0,22)»

– Визуализация влияния факторов: В интерфейсе системы (для студента и преподавателя) рекомендации сопровождаются не только текстовыми пояснениями, но и интерактивными диаграммами, наглядно показывающими вклад каждого компонента гибридной системы (CB, CF, Onto) в итоговую оценку курса. Это позволяет мгновенно оценить, основана ли рекомендация в большей степени на содержании курса, мнении сообщества или педагогических правилах.

– Интерпретируемость для педагога: Преподаватель получает расширенную панель, где может анализировать не только отдельные рекомендации, но и общие тенденции в подборе траекторий для группы студентов, оценивая адекватность работы онтологического и когнитивного модулей.

Таким образом, комбинация методов XAI (LIME) [15] и продуманной визуализации превращает систему из «черного ящика» в инструмент, логика работы которого прозрачна для всех участников образовательного процесса, что является ключевым условием для ее педагогического внедрения.

Заключение

Предложенная концепция гибридной рекомендательной системы решает актуальную проблему недостаточной персонализации в современных образовательных платформах. Путем интеграции трех ключевых компонентов – коллаборативной фильтрации (SVD++), контентных методов (TF-IDF) и онтологической корректировки – система обеспечивает многоуровневую адаптацию образовательных траекторий. Это позволяет учитывать:

- декомпозицию образовательных целей,
- когнитивные профили обучающихся (на основе модели V.A.R.K.),
- динамическую обратную связь от преподавателей.

Инновационные аспекты работы включают:

1. Динамическую балансировку весов коэффициентов (с учетом педагогической обратной связи).
2. Интерпретируемость рекомендаций через LIME-визуализацию.
3. Стратегии преодоления ограничений ИИ:

а) замещение коллаборативной фильтрации контентными методами для решения проблемы «холодного старта»,

б) введение коэффициента новизны для борьбы с «фильтрующим пузырем».

Тестирование на синтетических данных подтвердило эффективность системы:

– Precision@5 = 79,4%,
– PEDAG-score (авторская метрика) = 83,6%,

что превосходит традиционные подходы (ItemKNN, LightFM).

Автор считает, что система способна повысить релевантность образовательного контента, снизить процент незавершения курсов и обеспечить педагогически обоснованное проектирование индивидуальных траекторий обучения.

Список литературы

1. Drachsler H., Verbert K., Santos O.C., Manouselis N. Panorama of Recommender Systems to Support Learning // *Recommender Systems Handbook* / Ed. by F. Ricci, L. Rokach, B. Shapira. 2nd ed. Springer, 2015. P. 567. DOI: 10.1007/978-1-4899-7637-6_12.
2. George G., Lal A.M. Review of ontology-based recommender systems in e-learning // *Computers & Education*. 2019. Vol. 142. P. 103642. DOI: 10.1016/j.compedu.2019.103642.
3. Ricci F., Rokach L., Shapira B., Kantor P.B. Introduction to Recommender Systems Handbook // *Recommender Systems Handbook*. Boston, MA: Springer, 2011. P. 1–35. DOI: 10.1007/978-0-387-85820-3_1.
4. Сковорчевский К.А., Дятлова О.В. Современные адаптивные и интеллектуальные цифровые системы обучения: механизмы и потенциал // *Вопросы образования*. 2024. № 3. С. 299–337. DOI: 10.17323/vo-2024-19751.
5. Кузюкова Т.А., Шаравова М.М., Катунин Д.А. Анализ перспектив развития искусственного интеллекта // *Экономика и качество систем связи*. 2024. № 1 (31). С. 41–47.
6. Илюшин Л.С., Торпашева Н.А. Технологии искусственного интеллекта как ресурс трансформации образовательных практик // *Ярославский педагогический вестник*. 2024. № 3 (138). С. 62–71. DOI: 10.20323/1813-145X-2024-3-138-62.
7. Морозевич Е.С., Коротких В.С., Кузнецова Е.А. Разработка модели формирования индивидуальных образовательных траекторий с использованием методов машинного обучения // *Бизнес-информатика*. 2022. № 2. С. 21–35.
8. Elahi M., Starke A., El Ioini N., Lambrix A.A., Trattner C. Developing and Evaluating a University Recommender System // *Frontiers in Artificial Intelligence*. 2021. Vol. 4. P. 796268. DOI: 10.3389/frai.2021.796268.
9. Chen X., Deng H. Research on Personalized Recommendation Methods for Online Video Learning Resources // *Applied Sciences*. 2021. Vol. 11, Is. 2. P. 804. DOI: 10.3390/app11020804.
10. Khalid A., Lundqvist K.O., Yates A. Recommender Systems for MOOCs: A Systematic Literature Survey (January 1, 2012 – July 12, 2019) // *The International Review of Research in Open and Distributed Learning*. 2020. Vol. 21, Is. 4. P. 255–291. DOI: 10.19173/irrodl.v21i4.4643.
11. Songer R., Yamamoto T. Choice Diversity in Educational Recommender Systems: User Perspectives // *Intelligent Technologies in Education*. 2024. [Электронный ресурс]. URL: <https://open-publishing.org/journals/index.php/ited/article/view/1162> (дата обращения: 28.07.2025). DOI: 10.53761/ITED/1.9.
12. Ribeiro M.T., Singh S., Guestrin C. “Why Should I Trust You?”: Explaining the Predictions of Any Classifier // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. P. 1135–1144. [Электронный ресурс]. URL: <https://arxiv.org/abs/1602.04938> (дата обращения: 28.07.2025).
13. Kahaei A. Design of Personalization of Massive Open Online Courses: магистер. дис. Lappeenranta-Lahti University of Technology LUT, 2014. [Электронный ресурс]. URL: <http://lutpub.lut.fi/handle/10024/102336> (дата обращения: 14.07.2025).
14. Wong K.T., Lee C.H. EdRecSys: A Context-Aware Framework for Educational Recommendations // *IEEE Transactions on Learning Technologies*. 2021. Vol. 14, Is. 3. P. 321–335. DOI: 10.1109/TLT.2021.3069278.
15. Brusilovsky P. Adaptive Hypermedia: From Intelligent Tutoring Systems to Web-Based Education // *Intelligent Tutoring Systems. ITS 2000. Lecture Notes in Computer Science* / Ed. by G. Gauthier, C. Frasson, K. VanLehn. Springer, Berlin, Heidelberg, 2000. Vol. 1839. P. 1–8. DOI: 10.1007/3-540-45108-0_1.
16. Lika B., Kolomvatsos K., Hadjiefthymiades S. Facing the cold start problem in recommender systems // *Expert Systems with Applications*. 2014. Vol. 41, Is. 4. Part 2. P. 2065–2073. DOI: 10.1016/j.eswa.2013.09.005.
17. Fleming N.D. I’m Different; Not Dumb: Modes of Presentation (V.A.R.K) in the Tertiary Classroom // *Research and Development in Higher Education: Proceedings of the 1995 Annual Conference of the Higher Education and Research Development Society of Australasia (HERDSA)*. 1995. Vol. 18. P. 308–313. [Электронный ресурс]. URL: https://vark-learn.com/wp-content/uploads/2014/08/different_not_dumb.pdf (дата обращения: 28.07.2025).
18. Marante Y., Silva V.A.A., Gomes Jr.J., Vitor M.A., Martins A.F., de Souza J.F. Evaluating Educational Recommendation Systems: a systematic mapping // *Anais do XXXI Simpósio Brasileiro de Informática na Educação (SBIE)*. Porto Alegre: Sociedade Brasileira de Computação. 2020. P. 912–921. DOI: 10.5753/cbie.sbie.2020.912.
19. Mehrabi N., Morstatter F., Saxena N., Lerman K., Galstyan A. A Survey on Bias and Fairness in Machine Learning // *ACM Computing Surveys*. 2021. Vol. 54, Is. 6. P. 1–35. DOI: 10.1145/3457607.
20. Koren Y. Factorization Meets the Neighborhood: A Multifaceted Collaborative Filtering Model // *Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2008. P. 426–434. [Электронный ресурс]. URL: <https://www.cs.cornell.edu/courses/cs6241/2020sp/readings/Koren-2008-Factorization.pdf> (дата обращения: 28.07.2025).

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.