

**Динара Ошановна Кожаметова** – IT технологиялар кафедрасының қауымдастырылған профессоры, PhD философия докторы, Қазақстан Республикасы; e-mail: dinara\_kozhahmet@mail.ru.

**Ербол Амангазович Оспанов** – IT технологиялар кафедрасының қауымдастырылған профессоры, PhD философия докторы, Семей қаласының Шәкәрім атындағы университеті, Қазақстан Республикасы; e-mail: 78oea@mail.ru.

**Тұрсынхан Саятұлы Жылқыбаев** – техника ғылымдарының магистрі, IT технологиялар кафедрасының оқытушысы; Семей қаласының Шәкәрім атындағы университеті, Қазақстан Республикасы; e-mail: zhitosya@mail.ru.

#### Information about the authors

**Darina Musina\*** – Master's student of the Department of IT Technologies; Shakarim University of Semey, Republic of Kazakhstan; e-mail: darina\_musina\_21@mail.ru.

**Dinara Kozhakhmetova** – Associate Professor of the Department of IT Technologies, Doctor of Philosophy PhD, Shakarim University of Semey, Semey, Republic of Kazakhstan; e-mail: dinara\_kozhahmet@mail.ru.

**Yerbol Ospanov** – Associate Professor of the Department of IT Technologies, Doctor of Philosophy PhD, Shakarim University of Semey, Semey, Republic of Kazakhstan; 78oea@mail.ru.

**Tursynkhan Zhylykbayev** – Master of Technical Sciences, lecturer of the Department of IT Technologies, Shakarim University of Semey; Republic of Kazakhstan; e-mail: zhitosya@mail.ru.

Поступила в редакцию 14.10.2024

Поступила после доработки 27.11.2024

Принята к публикации 30.11.2024

[https://doi.org/10.53360/2788-7995-2025-1\(17\)-2](https://doi.org/10.53360/2788-7995-2025-1(17)-2)



MPHTI: 20.51.19



**К.Е. Икласова<sup>1\*</sup>, А.К. Шайханова<sup>2</sup>, М.Ж. Базарова<sup>3</sup>, Р.М. Ташибаев<sup>1</sup>, А.С. Казанбаева<sup>1</sup>**

<sup>1</sup>Северо-Казахстанский университет имени М. Козыбаева,  
150000, Республика Казахстан, г. Петропавловск, ул. Пушкина, 86

<sup>2</sup>Евразийский национальный университет имени Л.Н. Гумилева,  
100000, Республика Казахстан, г. Астана, ул. Сатбаева, 2

<sup>3</sup>Восточно-Казахстанский университет имени С. Аманжолова,  
070002, Республика Казахстан, г. Усть-Каменогорск, ул. 30-й Гвардейской дивизии, 34

\*e-mail: keiklasova@ku.edu.kz

## ОБЗОР РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ: МОДЕЛИ И ПЕРСПЕКТИВЫ ИСПОЛЬЗОВАНИЯ В ОБРАЗОВАТЕЛЬНЫХ ПЛАТФОРМАХ

**Аннотация.** Рекомендательные системы играют ключевую роль в цифровой среде, обеспечивая персонализированные рекомендации в интернет-магазинах, стриминговых сервисах, социальных сетях и образовательных платформах. В данной работе представлен всесторонний обзор моделей рекомендательных систем, включая контентную и коллаборативную фильтрацию, гибридные подходы, а также современные алгоритмы, основанные на глубоком обучении, обучении с подкреплением и графовых нейронных сетях. Проанализированы преимущества и недостатки различных методов, их точность, производительность, масштабируемость и адаптивность к новым данным. Рассмотрены основные вызовы, такие как проблема «холодного старта», разреженность данных, предвзятость алгоритмов, необходимость объяснимости рекомендаций и обеспечение конфиденциальности. Отдельное внимание уделено перспективам внедрения рекомендательных систем в образовательные платформы. Подчеркнута важность использования гибридных и интеллектуальных систем для эффективного анализа данных пользователей и построения рекомендаций с учетом индивидуальных потребностей. В заключении сделан вывод о дальнейшем развитии рекомендательных систем, которое будет связано с интеграцией новейших технологий искусственного интеллекта, оптимизацией вычислительных ресурсов и расширением области их применения в различных цифровых экосистемах. Работа может быть полезна исследователям, разработчикам и практикам, работающим в сфере искусственного интеллекта и образовательных технологий.

**Ключевые слова:** рекомендательные системы, коллаборативная фильтрация, глубокое обучение, обучение с подкреплением, графовые нейронные сети, образовательные платформы, персонализация, анализ данных.

## **Введение**

Рекомендательные системы представляют собой класс алгоритмов и методов, которые предсказывают предпочтения пользователей и предлагают им наиболее релевантные товары, услуги или информацию. В эпоху информационного перенасыщения такие системы играют решающую роль, помогая пользователям ориентироваться в огромном объеме контента и принимать решения. На данный момент рекомендательные системы стали неотъемлемой частью цифровой экосистемы. Компании используют их для увеличения продаж, повышения вовлеченности пользователей и персонализации пользовательского опыта, что подчеркивает экономическую значимость и влияние таких систем на современный бизнес и потребительское поведение [1].

В зависимости от методов анализа данных и формирования рекомендаций выделяют несколько типов рекомендательных систем:

1. Системы, основанные на контенте (Content-based)
2. Системы коллаборативной фильтрации (Collaborative filtering)
3. Гибридные системы, сочетающие различные подходы
4. Современные системы на основе глубокого обучения, обучения с подкреплением и графовых нейронных сетей

Целью данного исследования является комплексный обзор существующих моделей рекомендательных систем, их сравнительный анализ и выявление перспективных направлений развития.

## **Методы исследования**

В статье использованы следующие методы исследования: анализ научной литературы и существующих исследований, сравнительный анализ моделей, классификация рекомендательных систем, анализ преимуществ и недостатков методов. Данные методы позволяют провести всесторонний анализ рекомендательных систем и дать оценку их эффективности и перспектив развития.

## **Результаты исследования**

Рекомендательные системы, основанные на контенте, анализируют характеристики объектов (товаров, фильмов, статей и т.д.) и предпочтения пользователей для формирования персонализированных рекомендаций. Основным принцип таких систем заключается в сопоставлении профиля пользователя с атрибутами объектов.

Процесс работы систем, основанных на контенте, можно разделить на несколько этапов:

1. Извлечение признаков объектов (например, жанр, актеры и режиссер для фильмов)
2. Создание профиля пользователя на основе его предыдущих взаимодействий с объектами
3. Сопоставление профиля пользователя с характеристиками новых объектов
4. Ранжирование объектов по степени соответствия и формирование рекомендаций

Математически этот процесс можно представить, как вычисление степени схожести между профилем пользователя и объектами с использованием метрик, таких как косинусное сходство или евклидово расстояние [2].

Преимущества данного вида систем:

- независимость от данных о других пользователях, что позволяет избежать проблемы «холодного старта» для новых объектов;
- возможность предоставлять персонализированные рекомендации даже при наличии небольшого количества пользователей;
- способность объяснять причины рекомендаций, что повышает доверие пользователей;
- эффективность при работе с нишевыми предпочтениями.

Недостатки:

- ограниченность рамками известных характеристик объектов;
- сложность обнаружения новых интересов пользователя, выходящих за пределы его текущего профиля;
- чрезмерная специализация рекомендаций (overspecialization), что может приводить к эффекту «информационного пузыря»;
- трудности с извлечением релевантных признаков для некоторых типов контента (например, музыка, изображения).

Коллаборативная фильтрация основывается на предположении, что пользователи, проявлявшие схожее поведение в прошлом, будут иметь схожие предпочтения и в будущем. В отличие от систем, основанных на контенте, коллаборативная фильтрация не требует информации о характеристиках объектов, а опирается исключительно на историю взаимодействий пользователей с объектами. Основным принцип коллаборативной фильтрации заключается в поиске паттернов в матрице взаимодействий «пользователь-объект» и использовании этих паттернов для прогнозирования будущих взаимодействий. Математически задача сводится к заполнению пропущенных значений в разреженной матрице оценок [3].

Преимущества:

- способность рекомендовать объекты, которые могут быть не связаны с предыдущими предпочтениями пользователя, что способствует разнообразию рекомендаций;
- независимость от характеристик объектов, что делает метод универсальным для различных типов контента;
- возможность выявлять неявные взаимосвязи и шаблоны в данных;
- повышение точности с ростом количества пользователей и взаимодействий.

Недостатки:

- проблема «холодного старта» для новых пользователей и объектов;
- разреженность данных, особенно в системах с большим количеством объектов;
- сложность масштабирования для крупных систем с миллионами пользователей и объектов;
- неспособность объяснить причины рекомендаций понятным для пользователя образом.

User-based collaborative filtering (UBCF) фокусируется на поиске пользователей с похожими предпочтениями. Алгоритм идентифицирует «соседей» целевого пользователя на основе сходства их оценок и использует их предпочтения для формирования рекомендаций [4]. Item-based collaborative filtering (IBCF) фокусируется на сходстве между объектами вместо пользователей. Алгоритм предполагает, что пользователю понравятся объекты, похожие на те, которые он уже положительно оценил [5]. Matrix factorization (MF) представляет матрицу взаимодействий «пользователь-объект» как произведение двух матриц низкого ранга: матрицы латентных факторов пользователей  $P$  и матрицы латентных факторов объектов  $Q$  [6]. Гибридные рекомендательные системы объединяют различные подходы для преодоления ограничений отдельных методов и повышения качества рекомендаций. Синергетический эффект от комбинирования разных типов алгоритмов позволяет минимизировать их индивидуальные недостатки и усилить преимущества.

Основные преимущества гибридных моделей заключаются в:

- возможности смягчение проблемы «холодного старта» за счет комбинирования content-based и collaborative filtering;
- повышении точности и разнообразия рекомендаций;
- увеличении стабильности системы и устойчивости к разреженным данным;
- возможность адаптации к различным сценариям использования и типам контента.

Гибридные системы особенно эффективны в ситуациях, когда отдельные подходы демонстрируют слабые результаты из-за нехватки данных или специфики предметной области [7]. Существует несколько способов комбинирования различных методов в гибридных системах:

1. Weighted hybrid – взвешенная комбинация результатов нескольких рекомендательных алгоритмов. Финальный рейтинг объекта вычисляется как:  $\hat{r}(u,i) = w_1 \times \hat{r}_1(u,i) + w_2 \times \hat{r}_2(u,i) + \dots + w_n \times \hat{r}_n(u,i)$  где  $\hat{r}_k(u,i)$  – предсказание  $k$ -го алгоритма,  $w_k$  – его вес.

2. Switching hybrid – система выбирает один из нескольких алгоритмов в зависимости от контекста. Например, для новых пользователей может использоваться content-based подход, а для опытных – collaborative filtering.

3. Cascade hybrid – последовательное применение нескольких методов, где каждый следующий уточняет результаты предыдущего. Например, сначала применяется грубая фильтрация методом content-based, а затем результаты уточняются с помощью collaborative filtering.

4. Feature augmentation – один метод используется для создания дополнительных признаков, которые затем используются другим методом. Например, результаты matrix factorization могут служить входными данными для нейронной сети.

5. Meta-level hybrid – модель, обученная одним методом, используется как входная для другого метода. Например, content-based подход может создавать профили пользователей, которые затем используются collaborative filtering.

Обзор различных архитектур нейронных сетей для рекомендательных систем показал, что глубокое обучение произвело революцию в области рекомендательных систем, обеспечивая возможность автоматического извлечения сложных признаков из разнородных данных и моделирования нелинейных взаимодействий между пользователями и объектами. Рекуррентные нейронные сети (RNN) особенно эффективны для моделирования последовательных данных, таких как история просмотров или покупок. Архитектуры на основе LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit) способны улавливать долгосрочные зависимости и временные паттерны в поведении пользователей [8]. Сверточные нейронные сети (CNN) применяются для извлечения локальных признаков из данных, представленных в виде матриц или тензоров. В рекомендательных системах CNN могут использоваться для анализа визуального контента, текстовых описаний или матриц взаимодействий. Transformers и модели на основе механизма внимания (attention mechanism) стали прорывом в моделировании последовательностей. Архитектура Transformer, представленная в работе «Attention is All You Need» [9], позволяет эффективно параллелизовать вычисления и улавливать взаимосвязи между элементами последовательности независимо от их расстояния друг от друга. Автоэнкодеры используются для обучения компактным представлениям (embeddings) пользователей и объектов в латентном пространстве. Вариационные автоэнкодеры (VAE) и денойзинг автоэнкодеры (DAE) позволяют моделировать вероятностные распределения и восстанавливать разреженные матрицы взаимодействий. Достижения моделей глубокого обучения в области рекомендательных систем впечатляющи. Например, система YouTube DNN увеличила время просмотра на платформе более чем на 20%. Модели на основе Transformer показывают улучшение метрики NDCG (Normalized Discounted Cumulative Gain) до 15-30% по сравнению с традиционными подходами на крупных наборах данных. Обучение с подкреплением (RL) представляет собой парадигму машинного обучения, в которой агент взаимодействует с окружающей средой, предпринимая действия и получая вознаграждения или штрафы. Цель агента – максимизировать кумулятивное вознаграждение [10]. Ключевые особенности применения RL в рекомендательных системах: в отличие от традиционных подходов, ориентированных на немедленное вознаграждение (например, клик), RL оптимизирует долгосрочные метрики, такие как удержание пользователей или пожизненная ценность клиента; RL-алгоритмы балансируют между исследованием новых вариантов и использованием известных успешных стратегий; возможность адаптации в режиме реального времени на основе обратной связи от пользователей; моделирование пользовательского опыта как последовательности взаимосвязанных событий.

Преимущества RL перед другими методами: RL может непосредственно оптимизировать конверсию, доход или удержание пользователей, а не косвенные метрики, такие как точность прогнозирования оценок, традиционные методы часто игнорируют долгосрочное влияние рекомендаций на пользовательский опыт, тогда как RL явно моделирует последствия текущих действий для будущих взаимодействий; RL-системы могут адаптироваться к изменяющимся предпочтениям пользователей и динамично корректировать стратегии рекомендаций; механизм exploration vs. exploitation естественным образом способствует разнообразию рекомендаций, избегая эффекта «фильтрационного пузыря»; RL может учиться даже в условиях разреженных или частичных сигналов обратной связи от пользователей.

Исследования показывают, что рекомендательные системы на основе RL могут увеличить вовлеченность пользователей на 20-40% по сравнению с традиционными подходами, особенно в долгосрочной перспективе [11].

Графовые нейронные сети (GNN) представляют собой класс методов глубокого обучения, специально разработанных для работы с данными, имеющими графовую

структуру. В рекомендательных системах графы естественным образом моделируют взаимосвязи между пользователями, объектами и контекстной информацией.

Ключевые особенности использования графов в рекомендательных системах: графы позволяют явно моделировать различные типы отношений: «пользователь-объект», «пользователь-пользователь», «объект-объект», «пользователь-контекст» и т.д.; в графе могут быть представлены различные типы узлов (пользователи, товары, категории, бренды) и ребер (просмотры, покупки, рейтинги, принадлежность к категории); механизм распространения сообщений (message passing) в GNN позволяет агрегировать информацию от соседних узлов, эффективно учитывая высокоуровневые взаимосвязи; GNN по конструкции инвариантны к порядку соседних узлов, что делает их особенно подходящими для моделирования социальных и рекомендательных систем [12].

Графовые нейронные сети демонстрируют значительное превосходство над традиционными методами рекомендаций:

- PinSage увеличил показатели вовлеченности на Pinterest на 25-30% по сравнению с предыдущими решениями;
- NGCF показывает прирост NDCG на 12-15% и Recall на 11-13% по сравнению с классическими методами collaborative filtering;
- LightGCN превосходит NGCF на 16% по эффективности обучения при сохранении аналогичного или лучшего качества рекомендаций;

Исследования показывают, что графовые модели особенно эффективны для задач холодного старта и для пользователей с небольшим количеством взаимодействий благодаря способности эффективно распространять информацию по графу [13].

#### Обсуждение результатов

Сравнительный анализ различных моделей по критериям точности, производительности и масштабируемости показал следующие результаты. Для объективного сравнения различных подходов к построению рекомендательных систем необходимо оценить их эффективность по нескольким ключевым критериям.

В таблице 1 представлено сравнение моделей по точности прогнозирования, производительности и масштабируемости.

Таблица 1 – Сравнительный анализ моделей рекомендательных систем

Модель	Точность (NDCG@10)*	Время обучения**	Время вывода***	Масштабируемость	Объем памяти
Content-based	0,65-0,70	Низкое	Среднее	Высокая	Средний
User-based CF	0,70-0,75	Низкое	Высокое	Низкая	Высокий
Item-based CF	0,72-0,78	Среднее	Среднее	Средняя	Средний
Matrix Factorization	0,78-0,82	Среднее	Низкое	Высокая	Низкий
Neural CF	0,80-0,85	Высокое	Среднее	Средняя	Средний
RNN-based	0,82-0,87	Высокое	Среднее	Средняя	Высокий
Transformer-based	0,85-0,90	Очень высокое	Среднее	Средняя	Высокий
Reinforcement Learning	0,83-0,88	Очень высокое	Среднее	Низкая	Высокий
Graph Neural Networks	0,87-0,92	Высокое	Высокое	Низкая	Высокий
Hybrid (ensemble)	0,88-0,94	Очень высокое	Высокое	Низкая	Очень высокий

\* Значения усреднены по результатам нескольких исследований на различных наборах данных.

\*\* Время обучения для набора данных среднего размера.

\*\*\* Время, необходимое для генерации рекомендаций для одного пользователя.

Дополнительный анализ по критериям:

1. Точность прогнозирования моделей рекомендательных систем:

– современные модели на основе глубокого обучения и графовых нейронных сетей демонстрируют наивысшую точность, особенно в сложных сценариях с разнородными данными;

– гибридные модели, комбинирующие различные подходы, обычно превосходят отдельные методы;

– классические методы, такие как content-based filtering, показывают удовлетворительные результаты для простых сценариев, но уступают в сложных случаях.

## 2. Производительность и вычислительные требования:

- модели глубокого обучения и RL требуют значительных вычислительных ресурсов для обучения, но могут быть оптимизированы для быстрого вывода;
- традиционные методы collaborative filtering более эффективны с точки зрения обучения, но могут быть медленными при формировании рекомендаций в режиме реального времени;
- трансформерные архитектуры и GNN часто требуют специализированного оборудования (GPU/TPU) для эффективного обучения.

## 3. Масштабируемость моделей рекомендательных систем:

- Matrix factorization и некоторые нейросетевые модели хорошо масштабируются на большие наборы данных;
- User-based CF и графовые модели сталкиваются с проблемами масштабируемости при увеличении количества пользователей;
- для крупномасштабных промышленных систем часто требуются специальные архитектурные решения (распределенные вычисления, кэширование, приближенные методы поиска ближайших соседей).

## 4. Адаптивность к новым данным:

- RL и онлайн-обучение позволяют моделям адаптироваться к новой информации в режиме реального времени;
- классические методы обычно требуют периодического переобучения;
- некоторые гибридные подходы используют инкрементальное обучение для постепенной адаптации к новым данным.

В данном обзоре были рассмотрены различные модели рекомендательных систем, начиная от классических подходов и заканчивая современными методами на основе искусственного интеллекта. Классические методы, такие как content-based filtering и collaborative filtering, заложили фундамент для развития персонализированных рекомендаций. Эти подходы отличаются простотой реализации и интерпретируемостью, но имеют ограничения в точности и масштабируемости. Гибридные модели, комбинирующие различные подходы, позволяют преодолеть индивидуальные ограничения отдельных методов и обеспечивают более высокое качество рекомендаций за счет синергетического эффекта. Современные методы, основанные на глубоком обучении, обучении с подкреплением и графовых нейронных сетях, значительно расширили возможности рекомендательных систем. Они способны моделировать сложные нелинейные взаимодействия, учитывать последовательность и контекст действий пользователя, интегрировать разнородные источники данных. Однако, несмотря на значительный прогресс в области рекомендательных систем, остается ряд нерешенных проблем и вызовов:

- холодный старт – для новых пользователей и объектов недостаток данных снижает качество рекомендаций. Возможные решения: использование метаданных, трансферное и активное обучение;

- разреженность данных – большинство взаимодействий отсутствуют, что усложняет обучение моделей. Графовые нейронные сети и глубокое обучение частично решают проблему;

- объяснимость – сложные модели трудно интерпретировать, что снижает доверие пользователей. Развиваются методы визуализации и объяснения рекомендаций;

- этика и предвзятость – алгоритмы могут усиливать предубеждения и ограничивать разнообразие контента. Требуются механизмы обеспечения справедливости и инклюзивности;

- конфиденциальность – персонализация требует обработки личных данных, что вызывает риски утечек. Развиваются методы федеративного обучения и дифференциальной приватности.

- персонализация и контекст – учет факторов (время, устройство, настроение) требует продвинутых алгоритмов, баланс между персонализацией и разнообразием рекомендаций остается вызовом.

- оценка эффективности – офлайн-метрики не всегда отражают реальный пользовательский опыт. A/B-тестирование надежнее, но ресурсоемко.

– многоцелевая оптимизация – необходимо учитывать сразу несколько параметров (релевантность, новизна, доход), что усложняет алгоритмическую настройку.

### **Заключение**

Сравнительный анализ различных моделей показал, что современные подходы превосходят классические методы по точности прогнозирования, но требуют больших вычислительных ресурсов и сложнее в реализации и поддержке. Гибридные модели и ансамбли алгоритмов демонстрируют наивысшую точность, но имеют ограничения в масштабируемости и оперативности. На основе полученных результатов можно сделать вывод, что рекомендательные системы обладают значительным потенциалом для использования в образовательной сфере, в частности - разработки модели цифровой обучения для обеспечения гибкости и доступности образования.

### **Список литературы**

1. Gomez-Uribe C.A. The Netflix recommender system: Algorithms, business value, and innovation / C.A. Gomez-Uribe, N. Hunt // ACM Transactions on Management Information Systems. – 2022. – № 6(4). – P. 1-19. <https://doi.org/10.1145/2843948>.
2. Pazzani M.J. Content-based recommendation systems / M.J. Pazzani, D. Billsus // In The adaptive web. – 2007. – P. 325-341. [https://doi.org/10.1007/978-3-540-72079-9\\_10](https://doi.org/10.1007/978-3-540-72079-9_10).
3. Item-based collaborative filtering recommendation algorithms / B. Sarwar et al // Proceedings of the 10th International Conference on World Wide Web. – 2001. – P. 285-295. <https://doi.org/10.1145/371920.372071>.
4. An algorithmic framework for performing collaborative filtering / J.L. Herlocker et al // Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. – 1999. – P. 230-237. <https://doi.org/10.1145/312624.312682>.
5. Deshpande, M. Item-based top-N recommendation algorithms / M. Deshpande, G. Karypis // ACM Transactions on Information Systems. – 2004. – № 22(1). – P. 143-177. <https://doi.org/10.1145/963770.963776>.
6. Koren Y. Matrix factorization techniques for recommender systems / Y. Koren, R. Bell, C. Volinsky // Computer. – 2009. – № 42(8). – P. 30-37. <https://doi.org/10.1109/MC.2009.263>.
7. Burke R. Hybrid web recommender systems / Burke R. // In The adaptive web. – 2007. – P. 377-408. [https://doi.org/10.1007/978-3-540-72079-9\\_12](https://doi.org/10.1007/978-3-540-72079-9_12).
8. Session-based recommendations with recurrent neural networks / B. Hidasi et al // Proceedings of the International Conference on Learning Representations (ICLR). – 2016. <https://doi.org/10.48550/arXiv.1511.06939>.
9. Attention is all you need / A. Vaswani et al // Advances in Neural Information Processing Systems. – 2017. <https://doi.org/10.48550/arXiv.1706.03762>.
10. Deep reinforcement learning for page-wise recommendations / X. Zhao et al // Proceedings of the 12th ACM Conference on Recommender Systems. – 2018. P. 95-103. <https://doi.org/10.1145/3240323.3240357>.
11. Top-K off-policy correction for a REINFORCE recommender system / M. Chen et al // Proceedings of the 12th ACM International Conference on Web Search and Data Mining. – 2019. – P. 456-464. <https://doi.org/10.1145/3289600.3290999>.
12. Hamilton W.L. Representation learning on graphs: Methods and applications / W.L. Hamilton, R. Ying, J. Leskovec // IEEE Data Engineering Bulletin. – 2017. – № 40(3). – P. 52-74. <https://doi.org/10.48550/arXiv.1709.05584>.
13. Session-based recommendation with graph neural networks / S. Wu et al // Proceedings of the AAAI Conference on Artificial Intelligence. – 2019. – № 33(1). – P. 346-353. <https://doi.org/10.1609/aaai.v33i01.3301346>.

### **Информация о финансировании**

*Данное исследование финансировалось/финансируется Комитетом по науке Министерства науки и высшего образования Республики Казахстан (грант № AP23488869).*

**К.Е. Икласова<sup>1\*</sup>, А.К. Шайханова<sup>2</sup>, М.Ж. Базарова<sup>3</sup>, Р.М. Ташибаев<sup>1</sup>, А.С. Казанбаева<sup>1</sup>**

<sup>1</sup>М.Қозыбаев атындағы Солтүстік Қазақстан университеті,  
150000, Қазақстан Республикасы, Петропав қаласы, Пушкин көшесі, 86

<sup>2</sup>Л.Н. Гумилёв атындағы Еуразия ұлттық университеті,  
010000, Қазақстан Республикасы, Астана қаласы, Сәтпаев көшесі, 2

<sup>3</sup>С. Аманжолов атындағы Шығыс Қазақстан университеті,  
070002, Қазақстан Республикасы, Өскемен қаласы, 30-шы Гвардиялық дивизия, 34 к.  
\*e-mail: keiklasova@ku.edu.kz

## **ҰСЫНЫС ЖҮЙЕЛЕРІНЕ ШОЛУ: МОДЕЛЬДЕР МЕН ПЕРСПЕКТИВАЛАР БІЛІМ БЕРУ ПЛАТФОРМАЛАРЫНДА ҚОЛДАНУ**

Ұсыныс жүйелері интернет-дүкендерде, ағындық қызметтерде, әлеуметтік желілерде және білім беру платформаларында жеке ұсыныстар беру арқылы цифрлық ортада шешуші рөл атқарады. Бұл жұмыста мазмұнды және бірлескен сүзуді, гибридті тәсілдерді, сондай-ақ терең оқытуға, күшейтуге және графикалық нейрондық желілерге негізделген заманауи алгоритмдерді қоса алғанда, ұсыныс жүйелерінің модельдеріне жан-жақты шолу берілген. Әр түрлі әдістердің артықшылықтары мен кемшіліктері, олардың дәлдігі, өнімділігі, ауқымдылығы және жаңа деректерге бейімделуі талданады. «Суық бастау» мәселесі, деректердің сирек болуы, алгоритмдердің біржақтылығы, ұсыныстарды түсіндіру қажеттілігі және құпиялылықты қамтамасыз ету сияқты негізгі қоңыраулар қарастырылады. Білім беру платформаларына ұсынымдық жүйелерді енгізу перспективаларына ерекше назар аударылды. Пайдаланушылардың деректерін тиімді талдау және жеке қажеттіліктерді ескере отырып ұсыныстар құру үшін гибридті және интеллектуалды жүйелерді пайдаланудың маңыздылығы атап өтілді. Қорытындылай келе, жасанды интеллекттің жаңа технологияларын интеграциялаумен, есептеу ресурстарын оңтайландырумен және оларды әртүрлі цифрлық экожүйелерде қолдану аясын кеңейтумен байланысты ұсынымдық жүйелерді одан әрі дамыту туралы қорытынды жасалды. Жұмыс жасанды интеллект және білім беру технологиялары саласында жұмыс істейтін зерттеушілерге, әзірлеушілерге және тәжірибешілерге пайдалы болуы мүмкін.

**Түйін сөздер:** ұсыныс жүйелері, бірлескен сүзу, терең оқыту, күшейту жаттығулары, графикалық нейрондық желілер, білім беру платформалары, даралау, деректерді талдау.

**K.E. Iklassova<sup>1\*</sup>, A.K. Shaikhanova<sup>2</sup>, M.Zh. Bazarova<sup>3</sup>, R.M. Tashibayev, Kazanbayeva<sup>1</sup> A.C.**

<sup>1</sup>M. Kozybayev North Kazakhstan University,  
150000, Republic of Kazakhstan, Petropavlovsk, Pushkina Str, 86

<sup>2</sup>L.N. Gumilyov Eurasian National University,  
010000, Republic of Kazakhstan, Astana, Satpayev Str., 2

<sup>3</sup>Sarsen Amanzholov East Kazakhstan University,  
070002, Republic of Kazakhstan, Ust-Kamenogorsk, 30th Gvardeiskoy Divisii Str, 34  
\*e-mail: keiklasova@ku.edu.kz

## **REVIEW OF RECOMMENDER SYSTEMS: MODELS AND PROSPECTS FOR USE IN EDUCATIONAL PLATFORMS**

*Recommendation systems play a key role in the digital environment, providing personalized recommendations in online stores, streaming services, social networks, and educational platforms. This paper presents a comprehensive review of recommendation system models, including content and collaborative filtering, hybrid approaches, and state-of-the-art algorithms based on deep learning, reinforcement learning, and graph neural networks. The advantages and disadvantages of different methods, their accuracy, performance, scalability and adaptability to new data are analyzed. The main challenges such as the cold-start problem, data sparsity, bias of algorithms, the need for explainability of recommendations and privacy assurance are reviewed. Special attention is paid to the prospects of implementing recommendation systems in educational platforms. The importance of using hybrid and intelligent systems to effectively analyze user data and build recommendations tailored to individual needs is emphasized. The conclusion is drawn about further development of recommendation systems, which will be associated with the integration of the latest artificial intelligence technologies, optimization of computational resources and expansion of their application area in various digital ecosystems. The work can be useful for researchers, developers and practitioners working in the field of artificial intelligence and educational technologies.*

**Key words:** recommendation systems, collaborative filtering, deep learning, reinforcement learning, graph neural networks, educational platforms, personalization, data analysis.

### Сведения об авторах

**Кайнижамал Есимсеитовна Икласова\*** – PhD, доцент кафедры «Информационно-коммуникационные технологии», Северо-Казахстанский университет имени М. Козыбаева; e-mail: keiklasova@ku.edu.kz. ORCID: <https://orcid.org/0000-0002-8330-4282>.

**Айгуль Кайрулаевна Шайханова** – PhD, и.о. профессора кафедры информационной безопасности, Евразийский национальный университет имени Л.Н. Гумилева; e-mail: shaikhanova\_ak@enu.kz. ORCID: <https://orcid.org/0000-0001-6006-4813>.

**Мадина Жомартовна Базарова** – PhD, ассоциированный профессор кафедры «Компьютерное моделирование и информационные технологии», Восточно-Казахстанский университет имени С. Аманжолова; e-mail: madina\_vkgtu@mail.ru. ORCID: <https://orcid.org/0000-0003-2580-6580>.

**Рустем Маратович Ташибаев** – докорант, Северо-Казахстанский университет имени М. Козыбаева; e-mail: rasll17@mail.ru. ORCID: <https://orcid.org/0009-0006-2436-9584>.

**Альбина Советовна Казанбаева** – PhD, доцент кафедры «Строительство и дизайн», Северо-Казахстанский университет имени М. Козыбаева, e-mail: akazanbaeva83@mail.ru. ORCID: <https://orcid.org/0000-0002-3077-3499>.

### Авторлар туралы мәліметтер

**Икласова Кайнижамал Есимсеитовна\*** – PhD, «Ақпараттық-коммуникациялық технологиялар» кафедраның доценті, М.Козыбаев атындағы Солтүстік-Қазақстан университеті; e-mail: keiklasova@ku.edu.kz. ORCID: <https://orcid.org/0000-0002-8330-4282>.

**Айгуль Кайрулаевна Шайханова** – PhD, ақпараттық қауіпсіздік кафедрасының профессоры, Л.Н. Гумилев атындағы Еуразия ұлттық университеті; e-mail: shaikhanova\_ak@enu.kz. ORCID: <https://orcid.org/0000-0001-6006-4813>.

**Мадина Жомартовна Базарова** – PhD, «Компьютерлік үлгілеу және ақпараттық технологиялар» кафедрасының қауымдастырылған профессоры, С. Аманжолов атындағы Шығыс Қазақстан университеті; e-mail: madina\_vkgtu@mail.ru. ORCID: <https://orcid.org/0000-0003-2580-6580>.

**Рустем Маратович Ташибаев** – докторант, М. Козыбаев атындағы Солтүстік-Қазақстан университеті; e-mail: rasll17@mail.ru. ORCID: <https://orcid.org/0009-0006-2436-9584>.

**Альбина Советовна Казанбаева** – PhD, «Құрылыс және дизайн» кафедраның доценті, М. Козыбаев атындағы Солтүстік-Қазақстан университеті; e-mail: akazanbaeva83@mail.ru. ORCID: <https://orcid.org/0000-0002-3077-3499>.

### Information about the authors

**Kainizhamal Iklassova\*** – PhD, associate professor, Department of Information and Communication Technologies, Manash Kozybayev North Kazakhstan University; e-mail: keiklasova@ku.edu.kz. ORCID: <https://orcid.org/0000-0002-8330-4282>.

**Aigul Kairulaevna Shaikhanova** – PhD, Acting Professor, Department of Information Security, L.N. Gumilyov Eurasian National University; e-mail: shaikhanova\_ak@enu.kz. ORCID: <https://orcid.org/0000-0001-6006-4813>.

**Madina Zhomartovna Bazarova** – PhD, associate professor of the Department of Computer Modeling and Information Technology, Sarsen Amanzholov East Kazakhstan University; e-mail: madina\_vkgtu@mail.ru. <https://orcid.org/0000-0003-2580-6580>.

**Rustem Maratovich Tashibayev** – PhD student, Manash Kozybayev North Kazakhstan University; e-mail: rasll17@mail.ru. ORCID: <https://orcid.org/0009-0006-2436-9584>.

**Albina Sovetovna Kazanbayeva** – PhD, associate professor, Department of Building and design, Manash Kozybayev North Kazakhstan University; e-mail: akazanbaeva83@mail.ru. ORCID: <https://orcid.org/0000-0002-3077-3499>.

*Поступила в редакцию 02.03.2025  
Поступила после доработки 11.03.2025  
Принята к публикации 13.03.2025*