

Турдахун Г. Е.
Магистрант НАО КазНИТУ им. К.И.Сатпаева

Касенхан А.М. – научный руководитель
НАО КазНИТУ им. К.И.Сатпаева
Казахстан, Алматы

**АКТУАЛЬНОСТЬ И СОВРЕМЕННОЕ СОСТОЯНИЕ
ПРИМЕНЕНИЯ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В
ОБРАЗОВАТЕЛЬНЫХ ПЛАТФОРМАХ**

Аннотация. Статья посвящена анализу актуального состояния и возможностей применения методов искусственного интеллекта в современных образовательных платформах. В работе проведён сравнительный анализ четырёх ключевых групп моделей искусственного интеллекта: генеративных языковых моделей, моделей понимания текста, алгоритмов образовательной аналитики и рекомендательных систем. Установлено, что образовательная ценность методов ИИ проявляется не в изолированном применении отдельных алгоритмов, а в их модульной интеграции, позволяющей сформировать целостную интеллектуальную платформу, способную к прогнозированию учебной динамики, интерпретации результатов обучения и адаптивному формированию индивидуальных траекторий.

Полученные результаты подтверждают необходимость разработки архитектуры образовательных систем нового поколения, основанной на принципах сопряжённости, интероперабельности и когнитивно обоснованной интеграции моделей искусственного интеллекта.

Ключевые слова: искусственный интеллект; образовательные платформы; генеративные модели; модели понимания текста.

Turdakhun G. E.

Master's Student, Satbayev University (NAO KazNITU named after K.I. Satbayev)

Kasenhan A. M. – Scientific Supervisor

Satbayev University (NAO KazNITU named after K. I. Satbayev).

RELEVANCE AND CURRENT STATE OF ARTIFICIAL INTELLIGENCE METHODS IN EDUCATIONAL PLATFORMS

Abstract. The article examines the current state and potential of applying artificial intelligence methods in modern educational platforms. The study provides a comparative analysis of four key groups of AI models: generative language models, text-understanding models, educational analytics algorithms, and recommendation systems. It is established that the educational value of AI methods does not lie in the isolated use of individual algorithms but in their modular integration, which enables the creation of a comprehensive intelligent platform capable of predicting learning dynamics, interpreting learning outcomes, and adaptively shaping individual learning trajectories. The findings confirm the necessity of developing next-generation educational system architectures based on the principles of interoperability, interconnectivity, and cognitively grounded integration of artificial intelligence models.

Keywords: artificial intelligence; educational platforms; generative models; text-understanding models.

В условиях цифровой трансформации образования значительно возрастает потребность в создании интеллектуальных систем, способные обеспечивать высокий уровень адаптивности, индивидуализации и аналитической поддержки учебного процесса. Традиционные

образовательные платформы остаются преимущественно инструментами для размещения материалов, коммуникации и контроля успеваемости, при этом их функциональные возможности в части анализа учебных данных, генерации контента и формирования персонализированных траекторий обучения существенно ограничены.

Возрастающие объёмы учебной информации, разнообразие образовательных форматов и увеличение числа пользователей делают невозможным эффективное сопровождение обучающихся без применения интеллектуальных алгоритмов.

В настоящее время генеративные языковые модели (GPT-4, LLaMA, Mistral) демонстрируют высокую эффективность в создании учебных текстов, формулировке задач, построении пояснений и моделировании диалога с обучающимся. Перечисленные модели обладают меньшей перплексией и высокой степенью лингвистической связности, что делает их наиболее подходящими для задач генерации и трансформации образовательного контента.

Для задач классификации, категоризации учебных материалов и автоматизированного анализа ответов обучающихся наиболее результативными являются модели, основанные на архитектуре BERT и её модификациях (RoBERTa, DistilBERT), а также модели T5. Их преимущества проявляются в устойчивости к вариативным формулировкам, высокой точности и интерпретируемости результатов.

В области образовательной аналитики и прогнозирования академической успеваемости наилучшие результаты показывают модели машинного обучения XGBoost, CatBoost и LightGBM. Указанные алгоритмы обеспечивают стабильность, высокую предсказательную способность и хорошо работают с табличными данными, которые формируются в результате взаимодействия обучающегося с платформой.

Они позволяют выявлять обучающихся группы риска, прогнозировать динамику результатов и оценивать эффективность учебных маршрутов.

Для построения персонализированных рекомендаций обучения наибольшую эффективность проявляют современные рекомендательные модели обучения, такие как DeepFM, LightGCN и GRU4Rec. При этом обеспечивают высокий уровень точности рекомендаций даже в условиях разреженных данных, что особенно важно для образовательных систем с большим количеством учебных материалов различного уровня сложности.

Современные исследования в области цифровой педагогики и образовательных технологий также свидетельствуют о возрастающей роли методов искусственного интеллекта (ИИ) в повышении эффективности обучения. Так, классические работы по адаптивным обучающим системам, выполненные B. Woolf [1], P. Brusilovsky [2] и R. Sottilare [3], заложили методологические основы для создания интеллектуальных образовательных сред. Эти исследования показывают, что внедрение адаптивных механизмов и систем анализа знаний обучающихся способствует росту индивидуализации обучения. Однако авторы отмечают, что традиционные интеллектуальные системы требуют значительных затрат на построение экспертных моделей предметной области и зачастую не обеспечивают масштабируемость в условиях массового дистанционного образования.

Качественный скачок в возможностях автоматизации образовательных процессов связан с появлением трансформерных архитектур (Vaswani et al., 2017) [4], которые стали фундаментом для современных больших языковых моделей, включая GPT-4 [5], LLaMA [6] и Mistral [7]. Данные модели демонстрируют высокую точность и гибкость в задачах генерации учебного контента, формирования пояснений, переработки текстов и поддержки диалогового взаимодействия с обучающимися. Согласно исследованиям Kasneci et al. [8], LLM

открывают новые возможности в создании интеллектуальных тьюторов, однако требуют педагогической валидации с целью обеспечения достоверности и корректности генерируемой информации.

Параллельно активно развивается направление образовательной аналитики (Learning Analytics), основанное на применении методов машинного обучения для анализа поведения обучающихся. Работы Ma и Herodotou [9], а также Khosravi и Gašević [10] подтверждают, что модели XGBoost, CatBoost и LightGBM являются наиболее эффективными инструментами для прогнозирования возможностей и рисков обучающихся, так как обеспечивают высокую точность классификации и устойчивость к вариативности данных. Вместе с тем исследователи отмечают недостаточный уровень интеграции таких предиктивных моделей в комплексные образовательные платформы, что ограничивает их практическую ценность.

Значительное внимание в современной литературе уделяется рекомендательным системам для поддержки персонализированного обучения. Гибридные модели DeepFM [11], LightGCN [12] и GRU4Rec [13] отмечают высокие показатели качества подбора учебных ресурсов, особенно в условиях больших массивов данных. Указанные модели эффективно решают задачи персонализации, однако, согласно авторам, их применение требует точной настройки параметров и достаточного объёма обучающих выборок, что может быть затруднительным в условиях небольших выборок или узкопредметных курсов.

Анализ существующих образовательных платформ показывает, что наиболее распространённые LMS — Moodle, Canvas и Google Classroom — ориентированы преимущественно на административную и контентную поддержку образовательного процесса [14]. Системы, внедряющие элементы ИИ, такие как Khanmigo [15] и компоненты Coursera AI [16], демонстрируют прогрессивные возможности интеллектуального

сопровождения, однако носят фрагментарный характер и не обеспечивают комплексного объединения генерации контента, диагностического анализа, персонализации и предсказания образовательных результатов.

Выявленные разрывы подтверждают необходимость разработки образовательной платформы нового поколения, основанной на комплексном применении генеративных моделей, аналитических алгоритмов и рекомендательных систем, что позволит обеспечить высокий уровень адаптивности, персонализации и интеллектуальной поддержки обучения.

Методологические основы статьи определяются необходимостью комплексного анализа возможностей применения искусственного интеллекта в образовательных платформах с учётом технологических, педагогических и когнитивных факторов. Работа исходит из того, что образовательная платформа представляет собой сложную интеллектуальную систему, функционирование которой строится на непрерывном сборе, интерпретации и использовании данных обучающегося.

Теоретическую опору исследования составляет концепция цифровой педагогики, которая рассматривает внедрение ИИ как инструмент повышения адаптивности, индивидуализации и научно обоснованной поддержки учебного процесса. Принимаются во внимание работы по адаптивным обучающим системам, модели Learning Analytics и исследования в области когнитивной теории обучения, позволяющие рассматривать ИИ не только как средство автоматизации, но и как элемент педагогической логики.

Методы исследования формируют целостный инструментарий, направленный на выявление эффективности и ограничений ИИ в образовательных средах. Системный анализ используется для рассмотрения образовательной платформы как единой интеллектуальной

экосистемы, в котором генеративные, диагностические и рекомендательные модули должны функционировать согласованно.

Контент-анализ научных источников позволяет выявить закономерности развития области и определить направления, в которых наблюдается дефицит методологических решений. Сравнительный анализ современных моделей ИИ обеспечивает оценку их применимости в задачах генерации учебного контента, диагностики знаний и прогнозирования результатов обучения.

Для обеспечения полноты и объективности анализа применение методов искусственного интеллекта в образовании целесообразно рассматривать в сравнительной перспективе, сопоставляя различные группы моделей между собой. Данный подход позволяет выявить их функциональные различия, определить специфические педагогические цели, для которых каждая группа оптимальна, а также оценить ограничения, возникающие при внедрении в реальные образовательные процессы. Несмотря на то, что в литературе обычно анализируются отдельные направления – генерация контента, анализ учебных данных, прогнозирование или персонализация, – только их комплексное сравнение позволяет выявить внутреннюю логику распределения ролей ИИ в образовательной экосистеме.

Таблица 1 – Сравнительная характеристика моделей искусственного интеллекта, применяемых в образовательных платформах

Группа моделей	Конкретные модели	Основное назначение	Педагогическая цель	Преимущества	Ограничения
Генеративные языковые модели (LLM)	GPT-4, LLaMA, Mistral	Генерация учебного контента, адаптация текста, создание	Обеспечение доступности учебного материала, индивидуализация	Высокая связность текста, способность адаптироваться под уровень обучающегося,	Возможность генерации недостоверных данных; необходимость

		пояснений, моделирование диалога	объяснений, снижение когнитивной нагрузки	универсальность применения	педагогической валидации; высокая вычислительная стоимость
Модели понимания языка (NLP-классификаторы)	BERT, RoBERTa, DistilBERT, T5	Классификация и анализ ответов, выявление ошибок, категоризация учебных материалов, семантическое понимание текста	Автоматизация проверки знаний, оценка уровня понимания материала	Устойчивость к вариативным формулам, высокая точность, интерпретируемость	Не формируют рекомендаций; не создают нового контента; требуют адаптации под предмет
Модели образовательной аналитики (предиктивные алгоритмы)	XGBoost, CatBoost, LightGBM	Прогнозирование успеваемости; выявление обучающихся групп риска; анализ учебной динамики	Раннее предупреждение учебных трудностей; управление качеством обучения	Высокая точность прогнозов; устойчивость к шумным данным; способность работать с табличными данными LMS	Требуют непрерывного сбора качественных данных; отсутствие единого стандарта образовательных данных снижает эффективность
Рекомендательные модели для персонализации обучения	DeepFM, LightGCN, GRU4Rec	Подбор релевантных учебных материалов; формирование индивидуальных траекторий	Персонализация обучения; повышение мотивации; оптимизация учебного пути	Высокое качество рекомендаций; способность работать с разреженными данными; адаптация под предпочтения	Требуют больших данных; низкая объяснимость решений; сложность параметрической

				обучающегося	настройки
--	--	--	--	--------------	-----------

Анализ сведений, представленных в Таблице 1, позволяет осуществить дифференцированную оценку различных групп моделей искусственного интеллекта с точки зрения их функциональной природы, педагогической значимости и потенциала для интеграции в цифровые образовательные среды. Сопоставление моделей демонстрирует, каждая технологическая линия реализует свой собственный механизм воздействия на учебный процесс, что требует методологически обоснованного распределения ролей между ними в архитектуре интеллектуальной образовательной платформы.

Прежде всего, генеративные языковые модели (GPT-4, LLaMA, Mistral) являются инструментами, ориентированными на конструирование и трансформацию учебного содержания, что отличает их от остальных групп, работающих преимущественно с уже имеющимися данными. Так, при объяснении комплексных понятий (например, «гипотеза максимальной правдоподобности» или «нейронная активация») эти модели способны генерировать множественные интерпретации, варьируя глубину и стиль подачи материала. Вместе с тем высокая вариативность генеративных моделей обуславливает вероятность эпистемологических искажений, что делает их применение в академических программах допустимым лишь в сочетании с механизмами педагогической верификации.

Модели понимания естественного языка (BERT, RoBERTa, DistilBERT, T5) выполняют аналитико-диагностическую функцию, обеспечивая автоматизированную реконструкцию смысловой структуры ответов обучающихся. Их применение позволяет выявлять характер ошибок, определять степень концептуального понимания и осуществлять семантическую экспертизу открытых текстовых ответов. Так, при

оценивании рассуждений обучающегося по теме «Причинно-следственные связи в исторических событиях» модель способна детектировать логические провалы или отсутствие аргументации. Ключевым преимуществом данных моделей является их интерпретируемость, что делает результаты диагностики содержательно насыщенными и пригодными для последующей педагогической интервенции.

Алгоритмы образовательной аналитики (XGBoost, CatBoost, LightGBM) представляют иной тип интеллектуальности, ориентированный на **выявление** статистических закономерностей в учебном поведении и прогнозирование траекторий освоения материала. Данные модели оперируют агрегированными образовательными данными и способны строить вероятностные сценарии успеваемости, что обеспечивает возможность раннего выявления рисков академической неуспешности. Например, при анализе паттернов активности студента в течение первых недель курса модель может предсказать вероятность невыполнения итоговой работы или снижения учебной мотивации. Однако потенциал данных алгоритмов существенно ограничивается отсутствием стандартизированной структуры образовательных данных, что препятствует формированию универсальных моделей оценки.

Рекомендательные модели (DeepFM, LightGCN, GRU4Rec) реализуют персонализационную функцию, формируя индивидуальные учебные маршруты на основе истории взаимодействия обучающегося с системой. Их применение позволяет обеспечивать дифференциацию нагрузки, оптимизацию порядка подачи материала и индивидуальную траекторию компетентностного роста. Например, обучающемуся, демонстрирующему затруднения в теме «Математическая статистика», система может рекомендовать повторный модуль по дисперсионному анализу или предложить серию интерактивных заданий, направленных на устранение конкретных пробелов.

Интегральный анализ демонстрирует, что функциональные домены моделей не пересекаются, а взаимодополняют друг друга. Генеративные модели формируют содержание; аналитические интерпретируют ответы; предиктивные алгоритмы выявляют закономерности учебной динамики; рекомендательные механизмы направляют индивидуальную траекторию.

Таким образом, данные Таблицы 1 позволяют сделать теоретически значимый вывод о том, что интеллектуальная образовательная платформа нового поколения должна строиться на принципе модульной интеграции технологий ИИ, в котором взаимодействие различных моделей представляет собой не механическое объединение алгоритмов, а целостный механизм формирования адаптивной образовательной среды, способной к прогнозу, интерпретации, персонализации и генерации учебного содержания.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ:

1. Woolf B. Building Intelligent Tutoring Systems. – San Francisco: Morgan Kaufmann, 2009. – 504 p.
2. Brusilovsky P. Adaptive hypermedia and adaptive web // User Modeling and User-Adapted Interaction. – 2001. – Vol. 11, № 1–2. – P. 87–110.
3. Sottilare R., Graesser A., Hu X., Goldberg B. Design Recommendations for Intelligent Tutoring Systems. – Orlando: U.S. Army Research Laboratory, 2014. – 346 p.
4. Vaswani A., Shazeer N., Parmar N. et al. Attention is All You Need // Advances in Neural Information Processing Systems. – 2017. – Vol. 30. – P. 5998–6008.
5. OpenAI. GPT-4 Technical Report. – 2023. – Режим доступа: <https://openai.com>. – Дата обращения: 12.12.2025.

6. Meta AI. LLaMA Model Card. – 2023. – Режим доступа: <https://ai.facebook.com>. – Дата обращения: 12.12.2025.
7. Mistral AI. Mistral-7B: Technical Overview. – 2024. – Режим доступа: <https://mistral.ai>. – Дата обращения: 12.12.2025.
8. Kasneci E., Sessler K., Hart B. et al. ChatGPT for good? On opportunities and challenges of large language models for education // npj Science of Learning. – 2023. – Vol. 8, № 1. – P. 1–13.
9. Ma X., Herodotou C. Predicting student performance in higher education using machine learning // Computers & Education. – 2022. – Vol. 187. – P. 104–115.
10. Khosravi H., Gašević D., Kitto K. Learning analytics in higher education: A systematic review // IEEE Transactions on Learning Technologies. – 2021. – Vol. 14, № 4. – P. 470–487.
11. Guo H., Tang R., Ye Y. et al. DeepFM: A factorization-machine based neural network for CTR prediction // IJCAI Proceedings. – 2017. – P. 1725–1731.
12. He X., Deng K., Wang X. et al. LightGCN: Simplifying and powering graph convolution network for recommendation // SIGIR Proceedings. – 2020. – P. 639–648.
13. Hidasi B., Karatzoglou A., Baltrunas L., Tikk D. Session-based recommendations with recurrent neural networks // ICLR Proceedings. – 2016. – P. 1–10.
14. Moodle. Moodle Documentation. – 2024. – Режим доступа: <https://moodle.org>. – Дата обращения: 12.12.2025.
15. Khan Academy. Khanmigo: AI Tutor Description. – 2024. – Режим доступа: <https://www.khanacademy.org>. – Дата обращения: 12.12.2025.
16. Coursera. AI Teaching Assistant Framework. – 2024. – Режим доступа: <https://www.coursera.org>. – Дата обращения: 12.12.2025.