

УДК: 004.89, 378.1

Система поддержки принятия решений для повышения экономической эффективности образовательной организации

Розов А.С., Тюшкевич Н.М.

РТУ МИРЭА, г. Москва

В статье рассматривается проблема прогнозирования посещаемости в образовательных организациях и связанные с ней экономические риски. В качестве основного инструмента для решения поставленной задачи предлагается внедрение цифровизации в управленческий слой, в частности систем поддержки принятия решений. Проведен анализ уже существующих систем, в том числе зарубежных и отечественных, а также методов машинного обучения, используемых при прогнозировании. По результатам сравнения эффективности алгоритма универсального решения выявлено не было, в связи с чем при разработке прототипа системы использовался ансамбль моделей, подкрепленный механизмом голосования. Разработанный прототип системы позволяет обучать модели на конкретных данных, получать прогноз посещения и наглядно демонстрирует перевод результатов прогноза в конкретные метрики, в том числе и экономические показатели. Результаты исследования могут послужить основой для разработки более комплексных систем прогнозирования и принятия решений на основе алгоритмов машинного обучения.

1. Введение

В современных условиях высшие учебные заведения функционируют как сложные социально-экономические системы, в которых образовательная деятельность тесно связана с вопросами ресурсного планирования, финансовой устойчивости и эффективности использования имеющегося потенциала. Рост числа абитуриентов, увеличение разнообразия образовательных программ и усложнение организационной структуры университетов приводят к необходимости более точного управления аудиторным фондом, преподавательской нагрузкой, административными ресурсами и сопутствующими затратами [1][2]. В таких условиях вопросы посещаемости приобретают не только учебное, но и прямое экономическое значение, поскольку именно от фактической загруженности образовательной инфраструктуры зависит рациональность распределения бюджета и уровень издержек организации.

С экономической точки зрения низкая или неравномерная посещаемость создает ряд негативных последствий. Во-первых, содержание избыточных аудиторий, учебных помещений и обслуживающей инфраструктуры приводит к возникновению постоянных затрат, которые не компенсируются соответствующей отдачей. Во-вторых, неэффективное распределение учебных

потоков затрудняет оптимизацию расписания и повышает вероятность нерационального использования рабочего времени преподавателей и административного персонала. В-третьих, отсутствие своевременного анализа посещаемости снижает качество управленческих решений, что может приводить к скрытым потерям, связанным с падением успеваемости, ростом риска отчисления и, как следствие, уменьшением доходов образовательной организации. Таким образом, посещаемость следует рассматривать не только как показатель дисциплины студентов, но и как важный индикатор экономической эффективности деятельности вуза.

Особое значение данный вопрос приобретает в условиях цифровизации [3][4] образования, когда управление организацией все в большей степени опирается на данные, а не на интуитивные или разрозненные наблюдения. Внедрение систем поддержки принятия решений позволяет автоматизировать сбор и обработку сведений о посещаемости, выявлять устойчивые закономерности и прогнозировать возможные отклонения от нормального режима учебного процесса. Это, в свою очередь, создает основу для более точного планирования ресурсов, снижения административных затрат и повышения прозрачности управленческих процессов. Использование прогнозных моделей позволяет заранее выявлять группы риска, принимать меры по удержанию студентов и предотвращать экономические потери, связанные с их возможным отчислением [5].

Дополнительный экономический эффект от подобных систем связан с возможностью перехода от реактивного управления к проактивному. Если традиционный подход предполагает фиксацию уже произошедших проблем, то прогнозирование посещаемости дает возможность заранее перераспределять ресурсы, корректировать учебные планы, оптимизировать занятость помещений и снижать объем неэффективных расходов. Кроме того, анализ посещаемости может использоваться как инструмент оценки потенциальной загрузки образовательной инфраструктуры и выявления резервов для внедрения дополнительных платных образовательных услуг, что расширяет источники дохода организации. Таким образом, применение цифровых инструментов анализа посещаемости способствует не только улучшению качества образовательного процесса, но и повышению экономической устойчивости образовательной организации.

В связи с этим разработка систем прогнозирования посещаемости и их интеграция в управленческий контур университета представляют собой актуальную научно-практическую задачу. Актуальность данной работы определяется необходимостью создания инструментов, которые позволяют связывать результаты машинного прогнозирования с конкретными экономическими показателями и использовать их для обоснования управленческих решений.

Основная часть

Системы прогнозирования посещаемости

Сбор данных о посещаемости и дальнейший их анализ широко используется в учебных системах многих университетов. Существующие

системы (к примеру, Starfish [6], EAB Navigate [7], Civitas Learning Student Impact Platform [8]), используемые за рубежом, позволяют производить мониторинг посещаемости студентов, оценивать риски отчисления на основе исторических данных, оповещать кураторов и преподавателей об ухудшающихся показателях студента, и интегрировать аналитику в процессы консультирования и поддержки. Говоря об отечественных аналогах, в условиях малого распространения коммерческих разработок в данной области, можно выделить применение 1С: Университет [9] и использование отдельных ВІ – платформ. Несмотря на это, существует большое количество локальных проектов и разработок, к примеру проект «Томского университета систем управления и радиоэлектроники» для прогнозирования успеваемости, основываясь на посещаемости студентов [10].

Развитие систем прогнозирования тесно связано с развитием искусственного интеллекта и машинного обучения. Интеллектуальные алгоритмы помогают выявлять скрытые зависимости и корреляции, прямо или косвенно влияющие на результаты прогнозов.

Алгоритмы прогнозирования

С точки зрения задач прогнозирования, посещаемость в образовательной организации является последовательностью данных в течение определенного отрезка времени. Влияние на эти данные оказывает большое количество факторов начиная от количества и характера учебных дисциплин, заканчивая отношением обучающихся к конкретному преподавателю. Исходя из этого, набор факторов, влияющих на результат прогноза, должен содержать параметры, которые поддаются объективной оценке [11] [12].

Алгоритмы машинного обучения позволяют выявлять подобные параметры и их влияние друг на друга, что в свою очередь упрощает поиск наиболее значимых зависимостей. Однако разные модели могут выдавать разные результаты, ввиду существенного различия в ключевых принципах их работы [13].

Для сравнения были взяты нелинейные алгоритмы. Данное решение было принято ввиду того, что при прогнозировании посещаемости в университете ключевую роль играют сложные, неаддитивные зависимости и взаимодействия факторов, которые линейные подходы обрабатывают хуже без большого объема ручной инженерии признаков. В исследовании «Using machine learning to predict student retention from socio-demographic characteristics and app-based engagement metrics» [14] методы машинного обучения применялись для прогнозирования отчисления студента после первого семестра. Линейные и нелинейные модели были задействованы при обработке данных более 50000 студентов. Нелинейные подходы показали более высокую эффективность, в частности в наборах данных с большим количеством взаимосвязанных предикторов. При такой специфике данных у линейных моделей высок риск переобучения.

Представителями нелинейных алгоритмов [15] являются ансамбли деревьев (Метод случайного леса (Random Forest) [16]) и градиентные бустинги (легкая градиентная бустинговая машина (LightGBM) [17],

категориальный бустинг (CatBoost) [18]). Представленные модели сравнивались на пяти разных наборах данных.

Ниже представлены данные, полученные при сравнении эффективности моделей в задаче регрессии, в частности при прогнозе процента посещаемости.

Таблица 1 – Сравнение прогнозов (первый набор данных)

Первый набор данных			
	Модель	MAE (средняя абсолютная ошибка)	RMSE (корень из среднеквадратичной ошибки)
1	Random Forest	7.096	8.592
2	LightGBM	7.060	8.689
3	CatBoost	7.149	8.747
Второй набор данных			
1	CatBoost	15.863	20.242
2	Random Forest	15.939	20.312
3	LightGBM	16.129	20.490
Третий набор данных			
1	LightGBM	15.926	20.058
2	CatBoost	16.126	20.309
3	Random Forest	16.167	20.333
Четвертый набор данных			
1	CatBoost	11.341	17.390
2	LightGBM	11.106	17.530
3	Random Forest	11.435	17.859
Пятый набор данных			
1	CatBoost	0.041	0.059
2	LightGBM	0.068	0.101
3	Random Forest	0.089	0.142

В задаче регрессии, связанной с прогнозированием процента посещаемости, CatBoost продемонстрировал высокие и устойчивые результаты, показав лучшие значения метрик на части исследуемых наборов данных. Вместе с тем однозначного универсального решения выявлено не было: на отдельных наборах данных лучшие результаты также демонстрировали Random Forest и LightGBM. Это позволяет сделать вывод о том, что при решении задачи прогноза посещаемости выбор модели должен осуществляться с учетом особенностей конкретных данных и приоритетной метрики качества.

Далее сравнивалась точность классификации моделей на тех же наборах данных. Полученные результаты представлены в таблице 2.

Таблица 2 – Точность классификации алгоритмов

Набор данных	Алгоритм	Random Forest	LightGBM	CatBoost
1		0.9322	0.9482	0.8261
2		0.4231	0.333	0.3476
3		0.568	0.581	0.576
4		0.742	0.741	0.740
5		0.854	0.802	0.865

В задаче классификации различия между моделями также зависели от используемого набора данных. LightGBM и Random Forest чаще показывали наилучшую точность, тогда как CatBoost оказался лучшим только на одном из наборов данных. Следовательно, результаты классификации не подтверждают тезис о безусловном превосходстве одной модели во всех случаях, а указывают на необходимость подбора алгоритма под конкретную задачу и конкретный набор признаков.

Графики сравнение наиболее значимых признаков представлено ниже:




Рисунок 1 – Влияние признаков (Первый набор данных)

Оценивая влияние признаков, в случае первого набора данных Random Forest и LightGBM показали схожие результаты выделения наиболее значимых параметров. Результаты работы CatBoost значительно отличаются от вышеуказанных моделей.




Рисунок 2 – Влияние признаков (Второй набор данных)

В случае второго набора данных все модели показали идентичные результаты.




Рисунок 3 – Влияние признаков (Третий набор данных)

В третьем наборе данных все модели выбрали в качестве главного признака `test_scores_avg`, однако влияние других признаков у моделей рознится.




Рисунок 4 – Влияние признаков (Четвертый набор данных)

Аналогичная ситуация и для четвертого набора данных, однако первые пять наиболее значимых признаков заметно похожи у всех моделей.




Рисунок 5 – Влияние признаков (Пятый набор данных)

В пятом наборе данных LightGBM выделил отличный от других моделей признак, однако показал схожесть в градации с CatBoost, в то время как RandomForest ограничил количество значимых признаков до 5.

Анализ значимости признаков показал, что разные модели во многих случаях выделяют схожие наиболее важные параметры, однако распределение вклада остальных признаков может заметно различаться. Это свидетельствует о том, что интерпретация результатов зависит не только от данных, но и от внутренней логики работы конкретного алгоритма. В связи с этим анализ значимости признаков следует рассматривать как инструмент дополнительной

интерпретации модели, а не как основание для однозначного выбора одного алгоритма.

Система поддержки принятия решений

В ходе работы был создан минимально жизнеспособный прототип системы поддержки принятия решений, наглядно демонстрирующий, как прогнозирование учебных процессов и, в частности, посещаемости отражается на экономической составляющей образовательной организации.

Для реализации использовался язык программирования Python [19], а также фреймворк Streamlit [20] для создания визуальной части системы.

Ввиду того, что в ходе анализа эффективности моделей не было выявлено алгоритма, обладающего универсальным набором преимуществ, было принято решение использовать все рассмотренные модели в виде ансамбля и дополнить их механизмом голосования.

На рисунке 1 представлен интерфейс прототипа системы.

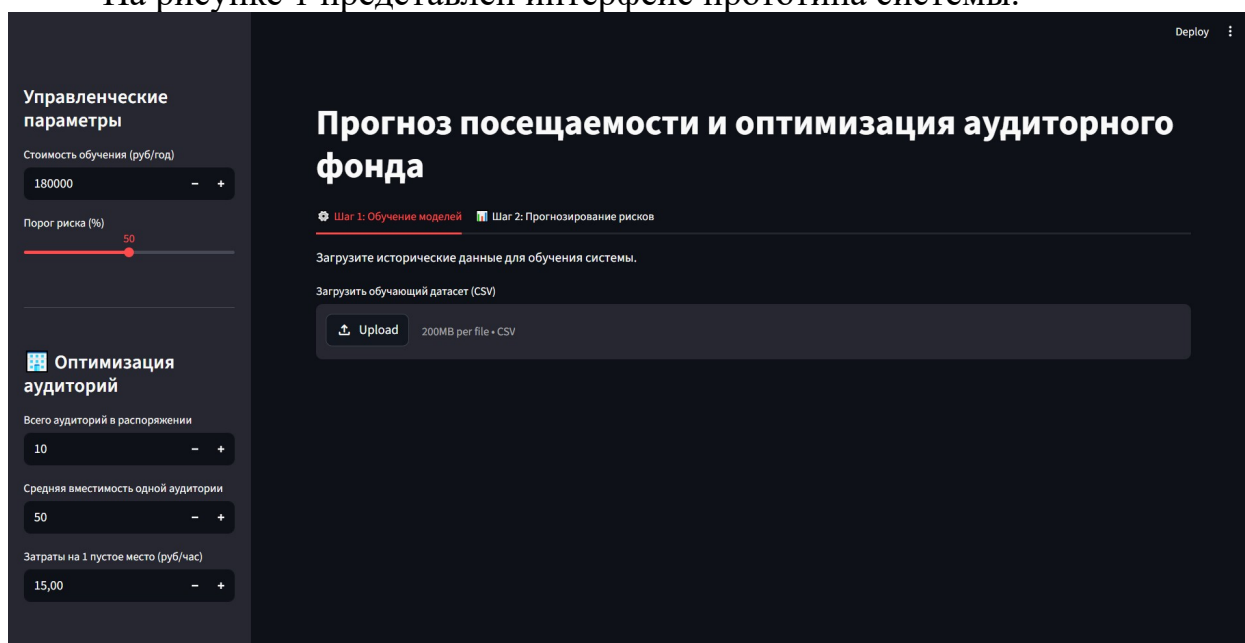


Рисунок 1 – Интерфейс прототипа системы

После загрузки исторических данных пользователь может выбрать целевую колонку и запустить процесс обучения (Рисунок 2).

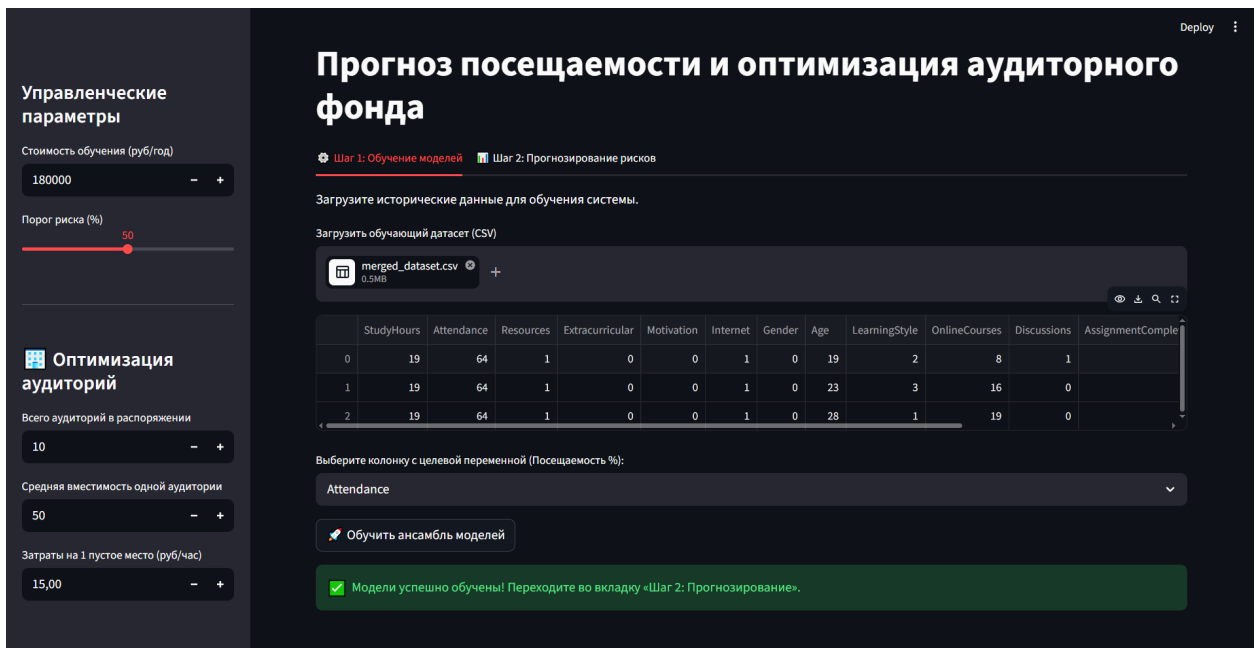


Рисунок 2 – Загрузка исторических данных и обучение моделей

Для каждого студента рассчитывается средний процент посещаемости на основании прогноза трех моделей (формула 1)

$$P_{cp,i} = \frac{P_{CB,i} + P_{LGB,i} + P_{RF,i}}{3} \quad \#(1)$$

где:

$P_{CB,i}$ – прогноз модели CatBoost;

$P_{LGB,i}$ – прогноз модели LightGBM;

$P_{RF,i}$ – прогноз модели RandomForest.

Метку «подтвержденный риск» запись получает при условии, что как минимум две модели отметили риск существенным (формула 2).

$$P_i = \begin{cases} 1, & \text{если } \sum_{m \in M} [P_{m,i} < T] \geq 2 \\ 0, & \text{в противном случае} \end{cases} \quad \#(2)$$

где:

M – множество моделей $\{CB, LGB, RF\}$;

T – установленный порог риска;

[условие] – функция, равная 1, если прогноз модели ниже порога, и 0 в обратном случае.

После обучения моделей пользователю становится доступен раздел с прогнозированием, в котором он также может загрузить актуальный файл с данными и проанализировать основные метрики. При изменении управленческих параметров (панель слева) данные на странице динамически меняются исходя из прогноза.

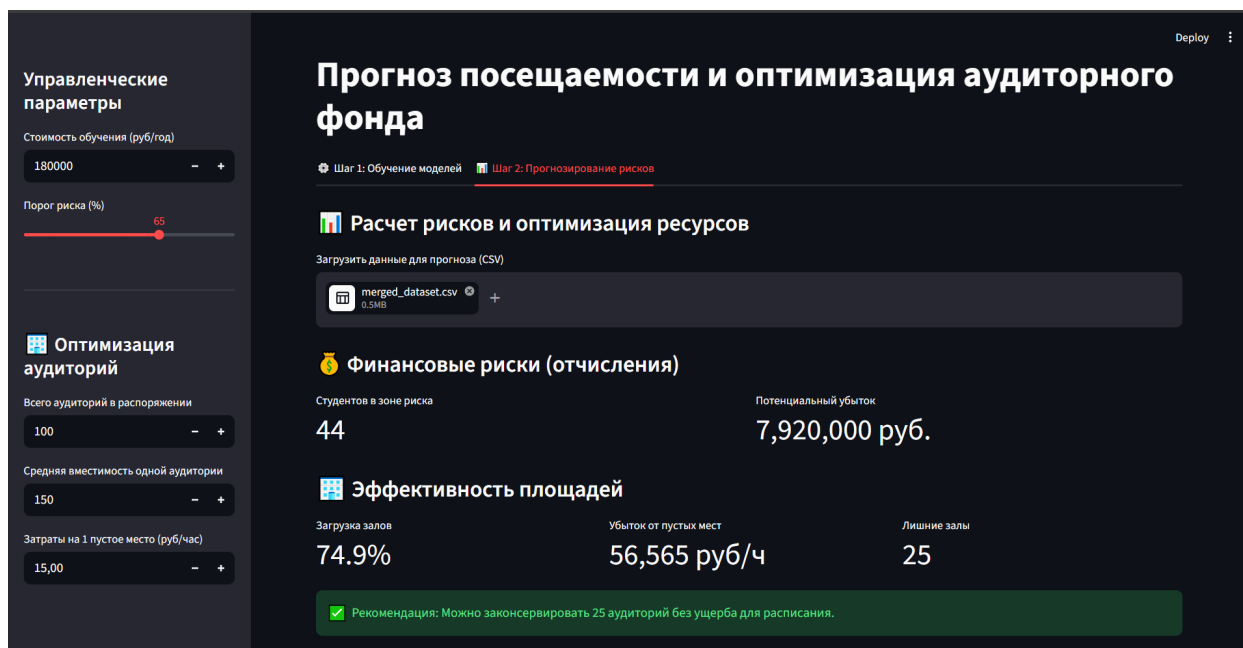


Рисунок 3 – Расчет рисков и оптимизация ресурсов

В формуле 3 представлено каким образом рассчитывается финансовый убыток от потенциального отчисления студентов:

$$Y_{\text{общ}} = N_{\text{риск}} \times C_{\text{обуч}} \quad \#(3)$$

где:

$N_{\text{риск}}$ – общее количество студентов с подтвержденным риском;

$C_{\text{обуч}}$ – стоимость обучения в год.

При оптимизации аудиторного фонда, в первую очередь рассчитывается прогнозируемое количество присутствующих (формула 4)

$$N_{\text{факт}} = \sum_{i=1}^n \left(\frac{P_{\text{срд},i}}{100} \right) \quad \#(4)$$

Далее происходит расчет коэффициента использования площадей (формула 5)

$$K_{\text{исп}} = \frac{N_{\text{факт}}}{B_{\text{общ}}} \times 100\% \quad \#(5)$$

где:

$B_{\text{общ}}$ – общая вместимость всех доступных аудиторий (количество аудиторий, умноженное на количество мест).

Убыток от незадействованных пространств рассчитывается по формуле 6:

$$Y_{\text{простой}} = (B_{\text{общ}} - N_{\text{факт}}) \times C_{\text{место/час}} \quad \#(6)$$

где:

$C_{\text{место/час}}$ – затраты на содержание одного пустующего места в час.

Количество избыточных аудиторий рассчитывается по формуле 7:

$$A_{\text{изб}} = A_{\text{общ}} - \left\lceil \frac{N_{\text{факт}}}{B_{\text{зал}}} \right\rceil \quad \#(7)$$

где:

$A_{\text{общ}}$ – общее количество аудиторий;

$B_{\text{зал}}$ – средняя вместимость одного зала.

При делении $N_{\text{факт}}$ на $V_{\text{зал}}$ происходит округление в большую сторону, чтобы исключить случаи использования половины зала.

Ниже на данной странице можно ознакомиться с результатами работы алгоритмов и результатами голосования. Подробные результаты прогноза представлены на рисунке 4.

 **Детальный прогноз по студентам**

	FinalGrade	СВ_Прогноз	LGB_Прогноз	RF_Прогноз	Средний_прогноз_%	Голос_СВ	Голос_LGB	Голос_RF	Сумма_голосов	↓ Подтвержденный_Риск
0	3	69.3	77.2	64	70.2	1	0	1	2	<input checked="" type="checkbox"/>
1	2	74.3	77.2	64	71.8	1	0	1	2	<input checked="" type="checkbox"/>
2	0	70.5	71.5	64.7	68.9	1	1	1	3	<input checked="" type="checkbox"/>
3	3	69.3	77.2	64	70.2	1	0	1	2	<input checked="" type="checkbox"/>
4	2	74.3	77.2	64.3	71.9	1	0	1	2	<input checked="" type="checkbox"/>
5	0	70.4	71.5	64.7	68.9	1	1	1	3	<input checked="" type="checkbox"/>
6	3	69	77.2	64	70.1	1	0	1	2	<input checked="" type="checkbox"/>
7	2	74.7	77.2	64.7	72.2	1	0	1	2	<input checked="" type="checkbox"/>
8	0	73.3	71.5	64.7	69.8	1	1	1	3	<input checked="" type="checkbox"/>
9	3	69.5	77.9	64	70.5	1	0	1	2	<input checked="" type="checkbox"/>

Рисунок 4 – Подробные результаты прогноза

2. Заключение

По итогам проведенного исследования можно сделать вывод о том, что цифровизация образования не ограничивается внедрением информационных систем, а совершает переход к управлению на основе данных. Разработанный в ходе работы прототип системы поддержки принятия решений показывает, как прогнозирование посещаемости может влиять не только на учебный процесс, но и выступать в качестве инструмента финансового контроля.

В ходе работы было установлено, что универсального алгоритма для предсказания поведения студентов не существует: каждый из протестированных подходов (CatBoost, LightGBM и Random Forest) проявляет себя по-разному в зависимости от специфики данных. Именно поэтому использование ансамбля моделей с механизмом голосования стало наиболее надежным решением, позволяющим минимизировать ошибки и предвзятость отдельных алгоритмов.

Разработанный на основе вышеуказанных алгоритмов прототип наглядно демонстрирует перевод результатов прогноза в конкретные метрики, позволяющие руководству организации эффективнее планировать учебный процесс и минимизировать убытки. Внедрение подобных инструментов избавляет административный персонал от рутинного мониторинга и снижает влияние человеческого фактора. Таким образом, предлагаемый подход позволяет образовательной организации не просто наблюдать за учебным процессом, а гибко адаптироваться к реальности, оптимизировать операционные расходы и находить ресурсы для развития новых образовательных направлений.

Литература

1. Борщова, А. С. Маркетинговые стратегии в образовательной отрасли: привлечение и удержание студентов / А. С. Борщова // Маркетинг-дайджест: Сборник тезисов научных докладов Республиканской научно-практической интернет-конференции преподавателей, аспирантов, студентов и школьников, Донецк, 31 октября 2025 года. – Донецк: Федеральное государственное бюджетное учреждение высшего образования "Донецкий национальный университет экономики и торговли имени Михаила Туган-Барановского", 2025. – С. 97-99. – EDN EUWGCH.
2. Baguzova, L. V. Factors of efficiency of resource potential management higher educational organizations / L. V. Baguzova, M. V. Glotova // Trade, Service, Food Industry. – 2021. – Vol. 1, No. 2. – P. 179-186. – DOI 10.17516/2782-2214-0011. – EDN ПХVNX.
3. Леонов, А. Г. Новая архитектура образовательных платформ в эпоху цифровой трансформации: парадигмы NoLMS и Smart LMS / А. Г. Леонов, К. А. Машенко, Е. Ю. Тарасова // Труды НИИСИ. – 2025. – Т. 15, № 2. – С. 54-59. – DOI 10.25682/NIISI.2025.2.0007. – EDN ELMRNS.
4. Федюшкин, А. В. Модель системы поддержки принятия решения для управления образовательной деятельностью вуза / А. В. Федюшкин, В. Н. Разиков // Научный резерв. – 2023. – № 2(22). – С. 65-72. – EDN JBFCIF.
5. Казакова, М. С. Разработка комплекса мер по успешному привлечению абитуриентов в отраслевые вузы в сети Интернет / М. С. Казакова, А. А. Кудряшов // Креативная экономика. – 2021. – Т. 15, № 7. – С. 2939-2952. – DOI 10.18334/ce.15.7.112362. – EDN TRAYES.
6. Starfish // eab.com URL: <https://eab.com/solutions/starfish/> (дата обращения: 10.03.2026).
7. Navigate360: Higher Education's Leading CRM // eab.com URL: <https://eab.com/solutions/navigate360/> (дата обращения: 10.03.2026).
8. Student Impact Platform // civitaslearning.com URL: <https://www.civitaslearning.com/platform/> (дата обращения: 10.03.2026).
9. 1С:Университет - О решении - Описание // 1c.ru URL: <https://solutions.1c.ru/catalog/university> (дата обращения: 10.03.2026).
10. Приложение для прогнозирования успеваемости студентов ТУСУР по их посещаемости // pt.2035.university URL: <https://pt.2035.university/project/prilozenie-dla-prognozirovania-uspevaemosti-studentov-tusur-po-ih-posesaemosti> (дата обращения: 10.03.2026).
11. Анферов, М. А. Кластеризация многомерных временных данных в рамках информационной поддержки принимаемых управленческих решений / М. А. Анферов // Russian Technological Journal. – 2026. – Т. 14, № 2. – С. 7-16. – DOI 10.32362/2500-316X-2026-14-2-7-16. – EDN VCTFHE.
12. Потапова, К. А. Модель прогнозирования успеваемости студентов с использованием данных о результатах измерительных материалах и посещаемости студентами занятий / К. А. Потапова // ИТ-Стандарт. – 2023. – № 4(37). – С. 68-73. – EDN НКCITQ.

13. Прогнозирование результатов обучения студентов с использованием инструментов машинного обучения / Ю. Ю. Якунин, В. Н. Шестаков, Д. И. Ликсонова, А. А. Даничев // Информатика и образование. – 2023. – Т. 38, № 4. – С. 28-43. – DOI 10.32517/0234-0453-2023-38-4-28-43. – EDN HPHLQH.
14. Using machine learning to predict student retention from socio-demographic characteristics and app-based engagement metrics / S. C. Matz, Ch. S. Bukow, H. Peters [et al.] // Scientific Reports. – 2023. – Vol. 13, No. 1. – P. 5705. – DOI 10.1038/s41598-023-32484-w. – EDN JYLVCK.
15. O. Daswati, H. Wijayanto, F.M. Afendi, “COMPARATIVE STUDY OF LIGHTGBM, CATBOOST, AND RANDOM FOREST IN MODELING PUBLIC COMPLAINTS CLASSIFICATION”, BAREKENG: J. Math. & App., vol. 20, no. 3, pp. 2535-2548, Sep, 2026.
16. Random Forest Algorithm in Machine Learning // geeksforgeeks.org URL: <https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/> (дата обращения: 12.03.2026).
17. Welcome to LightGBM’s documentation! // lightgbm.readthedocs.io URL: <https://lightgbm.readthedocs.io/en/latest/#> (дата обращения: 12.03.2026).
18. CatBoost - open-source gradient boosting library // catboost.ai URL: <https://catboost.ai/> (дата обращения: 12.03.2026).
19. Welcome to Python.org // www.python.org URL: <https://www.python.org/> (дата обращения: 12.03.2026).
20. Streamlit — A faster way to build and share data apps. // github.com URL: <https://github.com/streamlit/streamlit> (дата обращения: 12.03.2026).

References in Cyrillics

1. Borshchova, A. S. Marketingovyе strategii v obrazovatelnoy otrasli: privlechenie i uderzhanie studentov / A. S. Borshchova // Marketing-daydzhest: Sbornik tezisov nauchnykh dokladov Respublikanskoй nauchno-prakticheskoy internet-konferentsii prepodavateley, aspirantov, studentov i shkolnikov, Donetsk, 31 oktyabrya 2025 goda. – Donetsk: Federalnoe gosudarstvennoe byudzhethoe uchrezhdenie vysshego obrazovaniya "Donetskiy natsionalnyy universitet ekonomiki i torgovli imeni Mikhaila Tugan-Baranovskogo", 2025. – S. 97-99. – EDN EUWGCH.
2. Baguzova, L. V. Factors of efficiency of resource potential management higher educational organizations / L. V. Baguzova, M. V. Glotova // Trade, Service, Food Industry. – 2021. – Vol. 1, No. 2. – P. 179-186. – DOI 10.17516/2782-2214-0011. – EDN IIXVNX.
3. Leonov, A. G. Novaya arkhitektura obrazovatelnykh platform v epokhu tsifrovoy transformatsii: paradigmy NoLMS i Smart LMS / A. G. Leonov, K. A. Mashchenko, E. Yu. Tarasova // Trudy NIISI. – 2025. – T. 15, No. 2. – S. 54-59. – DOI 10.25682/NIISI.2025.2.0007. – EDN ELMRNS.
4. Fedyushkin, A. V. Model sistemy podderzhki prinyatiya resheniya dlya upravleniya obrazovatelnoy deyatelnostyu vuza / A. V. Fedyushkin, V. N. Razikov // Nauchnyy rezerv. – 2023. – No. 2(22). – S. 65-72. – EDN JBFCIF.

5. Kazakova, M. S. Razrabotka kompleksa mer po uspeshnomu privlecheniyu abiturientov v otraslevye vuzy v seti Internet / M. S. Kazakova, A. A. Kudryashov // Kreativnaya ekonomika. – 2021. – Т. 15, No. 7. – S. 2939-2952. – DOI 10.18334/ce.15.7.112362. – EDN TRAYES.
6. Starfish // eab.com URL: <https://eab.com/solutions/starfish/> (дата обращения: 10.03.2026).
7. Navigate360: Higher Education's Leading CRM // eab.com URL: <https://eab.com/solutions/navigate360/> (дата обращения: 10.03.2026).
8. Student Impact Platform // civitaslearning.com URL: <https://www.civitaslearning.com/platform/> (дата обращения: 10.03.2026).
9. 1C: Университет - О решении - Описание // 1c.ru URL: <https://solutions.1c.ru/catalog/university> (accessed: 10.03.2026).
10. Prilozhenie dlya prognozirovaniya uspevaemosti studentov TUSUR po ikh poseshchaemosti // pt.2035.university URL: <https://pt.2035.university/project/prilozhenie-dla-prognozirovania-uspevaemosti-studentov-tusur-po-ih-posesaemosti>(accessed: 10.03.2026).
11. Anferov, M. A. Klasterizatsiya mnogomernykh vremennykh dannykh v ramkakh informatsionnoy podderzhki prinimaemykh upravlencheskikh resheniy / M. A. Anferov // Russian Technological Journal. – 2026. – Т. 14, No. 2. – S. 7-16. – DOI 10.32362/2500-316X-2026-14-2-7-16. – EDN VCTFHE.
12. Potapova, K. A. Model prognozirovaniya uspevaemosti studentov s ispolzovaniem dannykh o rezultatakh izmeritelnykh materialakh i poseshchaemosti studentami zanyatiy / K. A. Potapova // IT-Standart. – 2023. – No. 4(37). – S. 68-73. – EDN HKCITQ.
13. Prognozirovanie rezultatov obucheniya studentov s ispolzovaniem instrumentov mashinnogo obucheniya / Yu. Yu. Yakunin, V. N. Shestakov, D. I. Liksonova, A. A. Danichev // Informatika i obrazovanie. – 2023. – Т. 38, No. 4. – S. 28-43. – DOI 10.32517/0234-0453-2023-38-4-28-43. – EDN HPHLQH.
14. Using machine learning to predict student retention from socio-demographic characteristics and app-based engagement metrics / S. C. Matz, Ch. S. Bukow, H. Peters [et al.] // Scientific Reports. – 2023. – Vol. 13, No. 1. – P. 5705. – DOI 10.1038/s41598-023-32484-w. – EDN JYLVCK.
15. O. Daswati, H. Wijayanto, F.M. Afendi, “COMPARATIVE STUDY OF LIGHTGBM, CATBOOST, AND RANDOM FOREST IN MODELING PUBLIC COMPLAINTS CLASSIFICATION”, BAREKENG: J. Math. & App., vol. 20, no. 3, pp. 2535-2548, Sep, 2026.
16. Random Forest Algorithm in Machine Learning // geeksforgeeks.org URL: <https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/> (дата обращения: 12.03.2026).
17. Welcome to LightGBM’s documentation! // lightgbm.readthedocs.io URL: <https://lightgbm.readthedocs.io/en/latest/#> (accessed: 12.03.2026).
18. CatBoost - open-source gradient boosting library // catboost.ai URL: <https://catboost.ai/> (accessed:12.03.2026).
19. Welcome to Python.org // www.python.org URL: <https://www.python.org/> (accessed: 12.03.2026).

20. Streamlit — A faster way to build and share data apps. // github.com
URL: <https://github.com/streamlit/streamlit> (accessed: 12.03.2026).

Ключевые слова

Система поддержки принятия решений, цифровизация, образовательная организация, экономическая эффективность, прогнозирование посещаемости, алгоритмы машинного обучения, CatBoost, LightGBM, Random Forest.

Розов Александр Сергеевич, ассистент кафедры инструментального и прикладного программного обеспечения института информационных технологий РТУ МИРЭА, г. Москва.

rozov@mirea.ru

ORCID: 0009-0007-2235-1038

Тюшкевич Николай Максимович, ассистент кафедры инструментального и прикладного программного обеспечения института информационных технологий РТУ МИРЭА, г. Москва.

tyushkevich@mirea.ru

ORCID: 0009-0008-1982-0486

Rozov Aleksander, Tyushkevich Nikolay. A decision support system for improving the economic efficiency of an educational organization

Keywords

Decision support system, digitalization, educational organization, economic efficiency, attendance forecasting, machine learning algorithms, CatBoost, LightGBM, Random Forest.

JEL classification: I23, M15, C53

Abstract

This article examines the problem of attendance forecasting in educational institutions and the associated economic risks. The introduction of digitalization into the management layer, specifically decision support systems, is proposed as the primary tool for solving this problem. An analysis of existing systems, including foreign and domestic ones, as well as machine learning methods used for forecasting, is conducted. A comparison of algorithm effectiveness revealed no universal solution. Therefore, an ensemble of models supported by a voting mechanism was used in developing a prototype system. The developed prototype system allows for training models on specific data, obtaining attendance forecasts, and clearly demonstrates the translation of forecast results into specific metrics, including economic indicators. The results of the study can serve as a basis for the development of more comprehensive forecasting and decision-making systems based on machine learning algorithms.