

Обучение модели искусственного интеллекта для прогнозирования предметных образовательных результатов

Т.Г. Асланов¹, Х.Б. Штанчаев¹, Р.Ф. Фарманов², Х.Ю. Тагиров³

¹Дагестанский государственный технический университет,

¹367015, г. Махачкала, пр. И. Шамиля, 70, Россия,

²ООО «Дом знаний»,

²367030, г. Махачкала, ул. Ирчи Казака, 39, Россия,

³Автономная некоммерческая общеобразовательная организация «Дом знаний»,

³367030, г. Махачкала, ул. Ирчи Казака, 39, Россия

Резюме. Цель. Исследование направлено на выявление зависимости качества обучения в общеобразовательных организациях от когнитивных и личностных особенностей учащихся, а также параметров образовательной среды с целью разработки инструмента прогнозирования и коррекции предметных результатов. **Метод.** На основе анкетирования участников образовательного процесса онлайн-школы «Дом знаний» собрана база данных объемом свыше 1,3 млн записей по 315 параметрам, из которых после фильтрации оставлено 218 значимых показателей. Для восстановления пропущенных данных применен авторский итеративный метод с использованием нейронных сетей, а для векторизации категориальных признаков предложен метод, основанный на использовании деревьев решений. Для прогнозирования предметных результатов обучения обучена искусственная нейронная сеть на данных за период с 2022 по 2023 года. **Результат.** Разработана нейронная сеть, прогнозирующая предметные результаты учащихся на следующий учебный год с погрешностью менее четырех процентов. Проведено ранжирование 218 параметров по степени влияния на успеваемость и установлена количественная зависимость каждого из них от итоговой оценки. Создан пользовательский интерфейс, позволяющий родителям моделировать изменение параметров образовательной среды и личностных характеристик ребенка для достижения целевых образовательных результатов. **Вывод.** Предложенный подход позволяет перейти от реактивной «натаскивающей» подготовки к государственной итоговой аттестации к проактивному управлению образовательной траекторией, обеспечивая повышение среднего балла единого государственного экзамена на 10 пунктов. Дальнейшее развитие проекта предполагает автоматизацию сбора параметров с применением технологий искусственного интеллекта.

Ключевые слова: нейронная сеть, прогноз оценки, изменения, параметры, качество образования, образовательный результат.

Для цитирования: Т.Г. Асланов, Х.Б. Штанчаев, Р.Ф. Фарманов, Х.Ю. Тагиров. Обучение модели искусственного интеллекта для прогнозирования предметных образовательных результатов. Вестник Дагестанского государственного технического университета. Технические науки. 2026;53(2):23-35. DOI:10.21822/2073-6185-2026-53-2-23-35

Training an artificial intelligence model to predict subject-specific educational outcomes

T.G. Aslanov¹, Kh.B. Shtanchaev¹, R.F. Farmanov², Kh.Yu. Tagirov³

¹Dagestan State Technical University,

¹70 Shamil Ave., Makhachkala 367015, Russia,

²Dom Znaniy LLC,

²39 Irchi Kazaka St., Makhachkala 367030, Russia,

³Autonomous Non-Profit General Educational Organization "Dom Znaniy",

³39 Irchi Kazaka St., Makhachkala 367030, Russia

Abstract. Objective. The study aims to identify the relationship between the quality of education in general educational institutions and students' cognitive and personality traits, as well as parameters of the educational environment, with the goal of developing a tool for forecasting and adjusting subject-specific learning outcomes. **Method.** Based on surveys of participants in the educational process at the online school «Dom Znaniy» (House of Knowledge), a database comprising over 1.3 million records across 315 parameters was compiled. After filtering, 218 significant indicators were retained. An original iterative method utilizing neural networks was applied to restore missing data, and a novel approach based on decision trees was proposed for vectorizing categorical features. An artificial neural network was trained on data from 2022–2023 to forecast subject learning outcomes. **Results.** A neural network was developed capable of predicting students' subject-specific results for the upcoming academic year with an error margin of less than four percent. All 218 parameters were ranked by their influence on academic performance, and the quantitative relationship of each parameter to the final grade was established. A user interface was created enabling parents to simulate changes in educational environment parameters and a child's personal characteristics to achieve target educational outcomes. **Conclusion.** The proposed approach enables a transition from reactive, exam-focused preparation for state final certification to proactive management of the educational trajectory, resulting in a 10-point increase in the average Unified State Exam (USE) score. Future development of the project includes automating parameter collection using artificial intelligence technologies.

Keywords: neural network, grade prediction, modifications, parameters, education quality, educational outcome.

For citation: T.G. Aslanov, Kh.B. Shtanchaev, R.F. Farmanov, Kh.Yu. Tagirov. Training an artificial intelligence model to predict subject-specific educational outcomes. Herald of Daghestan State Technical University. Technical Sciences. 2026;53(2):23-35. (In Russ) DOI:10.21822/2073-6185-2026-53-2-23-35

Введение. В соответствии с требованиями федеральных государственных образовательных стандартов (ФГОС) общего образования образовательная организация обязана предоставить обучающемуся возможность формировать индивидуальную образовательную траекторию. При этом в случае перехода обучающегося на конкретную образовательную траекторию организация не может гарантировать успешное освоение им всей образовательной программы.

Согласно паспорту стратегии «Цифровая трансформация образования» Министерства просвещения Российской Федерации, к 2030 году возможность формирования индивидуальной образовательной траектории должна быть обеспечена для 80 % обучающихся. В Российской Федерации в 2025/26 учебном году функционирует 43,3 тыс. общеобразовательных организаций. Учитывая отсутствие действующих инструментов, обеспечивающих успешное освоение индивидуальной образовательной траектории, объем рынка неохваченных потребителей предлагаемого решения до 2030 года оценивается в 34,6 тыс. организаций.

В современных общеобразовательных организациях обязанность по переводу обучающегося на индивидуальную образовательную траекторию сопряжена с определенными рисками, в частности – с возможным ухудшением его успеваемости. При этом образовательные организации не предоставляют рекомендаций ни самим обучающимся, ни их законным представителям на случай возникновения подобных ситуаций. В этих условиях возрастает необходимость в инструментах, позволяющих определить минимальный набор требований, выполнение которых обеспечит успешное завершение выбранной образовательной траектории [1].

Наличие системы планируемых результатов обучения, закреплённой в ФГОС, создает предпосылки для построения логически выстроенной образовательной среды, в которой возможно индивидуализировать обучение каждого обучающегося. Такая индивидуализация может быть реализована за счет прогнозирования

образовательных результатов и определения оптимального пути развития обучающегося. Большинство существующих научных работ, посвященных прогнозированию предметных результатов обучения, либо используют ограниченное количество параметров для обучения нейронных сетей, либо опираются на синтетические данные, что ограничивает их практическое применение при реализации образовательных программ.

Так, в исследованиях [2-5] для прогнозирования предметных результатов использовалась исключительно информация об оценках и о динамике успеваемости за длительный период времени.

Помимо предметных результатов, в ряде работ применялись и другие параметры. Например, в исследованиях [6, 7] авторы опирались на биографические данные из личных дел обучающихся и прогнозировали вероятность завершения обучения в университете с получением диплома. В работе [8, 9] для прогноза успеваемости использовались анкетные данные, заполняемые педагогами о своих учениках, либо учеников на самих себя [10].

Среди отечественных исследований следует выделить работу [11, 12], в которой при прогнозировании успешности обучения проводилось анкетирование обучающихся по таким аспектам, как вовлеченность во внеучебную деятельность, интерес к различным видам деятельности и особенности межличностных отношений.

Анализ указанных исследований показывает, что все они основаны исключительно на данных, полученных либо только от обучающихся, либо только от педагогов.

Однако очевидно, что для качественного прогнозирования образовательных результатов необходимо учитывать мнение всех участников образовательного процесса.

В настоящей работе были собраны следующие укрупненные показатели общеобразовательной организации: нормативно-правовые акты, содержание образовательной программы, уровень технического оснащения, характеристики географической среды, когнитивные и личностные особенности обучающихся, данные внутреннего мониторинга, а также степень открытости образовательной организации.

Существует множество методов импутации данных [13-19]. При обработке пропущенных значений был применен авторский подход [20], включающий имитацию недостающих данных (в случаях отсутствия ответов респондентов) и векторизацию категориальных признаков с использованием решающих деревьев. Применение данных методов позволило достичь более высокой точности прогнозирования предметных результатов обучения по сравнению с подходами, представленными в работах других авторов.

Постановка задачи. Требуется разработать и обосновать метод прогнозирования успеваемости учащихся на основе комплексного анализа когнитивных, личностных и средовых факторов с использованием искусственных нейронных сетей. Задача включает сбор и структурирование многомерного набора данных, содержащего более 200 параметров, отражающих особенности учебной деятельности, мотивацию, условия обучения и поведенческие паттерны.

Необходимо решить проблему пропущенных значений в исходных данных с применением авторского итеративного нейросетевого подхода, произвести качественную векторизацию категориальных признаков, а также построить модель, способную с высокой точностью предсказывать итоговые результаты обучения. Дополнительно требуется обеспечить интерпретируемость модели за счёт ранжирования параметров по степени влияния на успеваемость. Решение данной задачи позволит перейти от ретроспективной оценки знаний к проактивному управлению образовательным процессом и целенаправленной коррекции индивидуальных учебных стратегий.

Методы исследования. В качестве объекта исследования была выбрана общеобразовательная организация, использующая исключительно дистанционные образовательные технологии АНОО «Дом знаний». Выбор был обусловлен возможностью исследовать различные аспекты образования, в том числе использование дистанционных образовательных технологий, с учетом плотной работой тьюторов и психологов

с обучающимися. Также определенную вариативность создаваемой выборке придает тот факт, что респонденты проживают как на территории Российской Федерации, так и за ее пределами.

Для подготовки обучающей выборки в онлайн-школе «Дом знаний» было организовано анкетирование участников образовательных отношений, среди которых: заведующие предметными кафедрами, педагоги, тьюторы, психологи, ученики, технические работники, администрация образовательной организации. Для обучающей выборки собирались следующие укрупненные показатели школы: нормативно-правовые акты, образовательная программа, техническое оснащение, географическая среда, когнитивные и личностные особенности обучающихся, внутренний мониторинг и открытость образовательной организации. Анкетирование проводилось в 2022 и 2023 годах.

Ознакомиться с содержащимся в базе данных перечнем параметров, влияющих на учебный процесс можно на сайте АНОО «Дом знаний» [21]. Общий объем выборки, используемой для исследования, превысил 1,3 млн. данных заполненных участниками образовательных отношений.

В связи с тем, что часть респондентов АНОО «Дом знаний» отказывалась проходить анкетирование, итоговые данные в базе данных оказались достаточно разряженными. Количество несобранных данных за два периода сбора составило порядка 37 процентов от общего объема данных. Так, к примеру, низкая наполняемость анкет психологами обуславливалось тем, что часть обучающихся отказывались от услуг психологов. Часть данных по ученикам, психологам удалось собрать по записи видеосопровождений учеников с педагогами. Общее количество измененных полей в базе данных за два года сбора информации составило 22 %. В их число входит изменившиеся педагоги, тьюторы и психологи у обучающихся, а также изменение общего числа обучающихся в образовательной организации, как за счет прибытия новых обучающихся, так и за счет выбытия части из них.

На рис. 1 приведен фрагмент базы данных, где в качестве столбцов (темные вертикальные линии на рис.1) выступают параметры, влияющие на учебный процесс, а в качестве строк (от 1 до 4156), ответы респондентов по этим параметрам. Белым пустотам соответствуют данным, по которым респонденты отказались заполнять ответы. Справа на рис.1 приведено максимальное и минимальное количество заполненных параметров каждым респондентом.




Рис. 1 - Фрагмент базы данных с пропусками данных
Fig. 1 - Database fragment with missing data

Для дальнейшего использования базы данных необходимо было имитировать данные для замены ими имеющихся пропусков. Восстановление отсутствующих данных по каждому параметру, влияющего на учебный процесс, осуществлялось в несколько этапов. На начальном этапе параметры, влияющие на учебный процесс, были упорядочены по количеству собранных анкетных данных, что позволяет выявить наиболее информативные источники данных. Затем все пропущенные значения заменяются случайными величинами.

Далее проводится обучение нейронной сети для восстановления пропусков в первом столбце набора данных. В качестве целевой переменной выступают значения

в восстанавливаемом первом столбце, а в качестве входных признаков используются все остальные столбцы. Аналогичная процедура последовательно применяется ко второму и ко всем последующим столбцам вплоть до последнего: каждый раз нейронная сеть обучается отдельно для восстановления одного конкретного параметра на основе остальных.

После завершения первого полного цикла восстановления весь процесс повторяется второй раз. При этом вместо исходных расчётных значений, использованных на первом этапе, теперь в качестве входных данных применяются значения, восстановленные нейронной сетью на предыдущей итерации. Необходимость двукратного выполнения процедуры обусловлена стремлением повысить точность восстановления: если на первой итерации пропуски могли быть заменены случайными или грубыми оценками, то уже на второй итерации модель работает с более достоверными данными.

С каждой последующей итерацией диапазон вариации ошибок в восстановленных значениях существенно сокращается. Это достигается за счёт того, что вместо случайных или условных величин в признаках используются данные, уточнённые на предыдущих этапах обучения, что позволяет нейронной сети формировать всё более точные прогнозы. Сказанное поясняется рис. 2, на рис. 2а приведена первая итерация обучения нейронной сети, а на рис. 2б приведена вторая итерация обучения нейронной сети.




Рис. 2 - Пояснение необходимости второй итерации обучения

Fig. 2 - Explanation of the necessity of the second training iteration

На рис. 3 приведены результаты восстановления информации по нагрузке педагогического работника в образовательной организации и в иных организациях.

На рис. 3 по оси ординат приведена среднеквадратическая ошибка обучения, а по оси абсцисс – эпохи обучения нейронной сети.




Рис. 3 - Результаты обучения нейронной сети восстанавливать информацию по нагрузке педагогического работника

Fig. 3 - Results of neural network training for reconstructing data on teacher workload

Синей кривой соответствует обучение на обучающей выборке, а красной кривой соответствует результат моделирования на тестовой выборке. Также с помощью указанного метода были выявлены недостоверные данные пользователей и указанные данные заменены на синтетические.

Обсуждение результатов. Как видно из полученных результатов, ошибка восстановления информации не превышает 0,4 процентов, что позволило начать процесс разработки нейронной сети прогнозировать предметные результаты обучения.

Для дальнейшего исследования база данных была разделена на две части – по годам сбора информации – 2022 и 2023 года. Две базы данных были сопоставлены и сохранены только те строки, которые имелись в обеих базах данных (респонденты заполнившие информацию и в 2022 и в 2023 годах).

Для обучающей выборки из базы данных 2023 года были выделены результаты предметного обучения, а из 2022 выделены все остальные параметры. На вход нейронной сети подавались параметры, влияющие на учебный процесс обучающихся из базы 2022 года, а выход нейронной сети при ее обучении сравнивался с предметными результатами обучения обучающихся в 2023 году.

На рис. 4 приведены результаты обучения нейронной сети прогнозировать предметные результаты обучения. Как видно из рис.4, погрешность прогнозирования не превысила 7 процентов.

Для проверки уровня влияния параметров на учебный процесс было проведено четыре дополнительных обучений искусственной нейронной сети [22], при этом средняя погрешность работы нейронной сети составила около 6 %.




Рис. 4 - Результаты обучения нейронной сети прогнозировать предметные результаты обучающихся

Fig. 4 - Results of neural network training for predicting students' academic outcomes

Далее, для анализа влияния каждого параметра на работу нейронной сети, проводилась случайная сортировка по отдельности каждого параметра и подача данных в нейронную сеть, после чего вычислялась среднеарифметическая ошибка предметных результатов обучения по данным, полученным при помощи искусственной нейронной сети и базы данных.

В табл. 1 приведены результаты по обученным 4 нейронным сетям, по которым были отсортированы параметры влияющий на учебный процесс, каждый по пять раз.

В последней строке приведена среднеарифметическая разность четвертого столбца со столбцами с пятого по десятый, которая и определяет влияние параметра на результаты обучения. Усредненное нормированное влияние параметров на результат обучения приведен на рис. 5.

**Таблица 1. Фрагмент базы данных с влиянием параметров
на предметные результаты обучения**

Table 1. Database fragment showing the influence of parameters on academic learning outcomes

№	Обучение ИНС ANN training	Сортировка дан- ных ИНС Sorting ANN data	Погрешность нейрон- ной сети Neural network error	Предмет Item	Класс ученика Student's class	Пол ученика Gender of the student	Возраст уче- ника Age of the student	...
1	1	1	5.811	6.01186	5.81631	5.84808	5.8083	...
2	1	2	5.811	5.98895	5.81864	5.83483	5.81069	...
3	1	3	5.811	5.95927	5.83453	5.84927	5.81479	...
4	1	4	5.811	6.0016	5.83005	5.8565	5.81499	...
5	1	5	5.811	5.97995	5.83854	5.84793	5.81707	...
6	2	1	6.387	6.52179	6.42315	6.43249	6.3879	...
7	2	2	6.387	6.51606	6.42006	6.44326	6.38732	...
8	2	3	6.387	6.51806	6.4208	6.42888	6.38751	...
9	2	4	6.387	6.50754	6.40397	6.44481	6.38474	...
10	2	5	6.387	6.53694	6.40278	6.44808	6.38596	...
11	3	1	5.859	6.06881	5.89359	5.89784	5.85807	...
12	3	2	5.859	6.04864	5.89799	5.89734	5.85809	...
13	3	3	5.859	6.05221	5.92376	5.89435	5.86682	...
14	3	4	5.859	6.08847	5.93061	5.89894	5.86296	...
15	3	5	5.859	6.08397	5.89692	5.90256	5.85919	...
16	4	1	5.903	6.07052	5.91404	5.94917	5.907	...
17	4	2	5.903	6.05323	5.9323	5.94139	5.91299	...
18	4	3	5.903	6.08475	5.92564	5.95773	5.90849	...
19	4	4	5.903	6.08723	5.92231	5.93882	5.91006	...
20	4	5	5.903	6.05281	5.93371	5.95527	5.91738	...
Влияние параметров на погрешность ИНС Influence of parameters on the error of the INS				0.17163	0.02898	0.04338	0.00302	...

На рис. 5 по оси ординат в логарифмическом масштабе отложены в процентах нормированное влияние параметров на учебный процесс, а по оси абсцисс кодифицированные параметры.




Рис. 5 - Влияние параметров на результат обучения
Fig. 5 - Influence of parameters on learning outcomes

В табл. 2 приведены первые десять параметров, влияющих с наибольшей степенью на учебный процесс. При обучении нейронной сети большинство категориальных признаков были бинарными, и их разделение не представляло большого труда, при этом категориальный признак «предмет» был переведен в числовой формат в зависимости от среднего значения срока начала и завершения изучения конкретного предмета. Хотя такое разделение и показало не плохой результат, но было решено векторизовать категориальный признак иначе.

**Таблица 2. Фрагмент базы данных с нормированным процентом влияния
на предметные результаты обучения**
**Table 2. Database fragment with normalized percentage of influence
on academic learning outcomes**

Код параметра Parameter code	Наименование параметра, влияющего на предметные результаты обучения Name of the parameter influencing subject learning outcomes	Степень влияния % Degree of influence
1	Наличие знаний у ученика необходимых для изучения предмета The student's knowledge necessary for studying the subject	18.7625457
2	Умение учеником решать задачи по предмету The student's ability to solve problems related to the subject	6.90882898
3	Навыки ученика применять полученные знания по предмету на практике The student's ability to apply acquired knowledge of the subject in practice	4.76411459
4	Достаточность для участников образовательного процесса информации, размещаемой в сети интернет The adequacy of information posted online for educational participants	3.82438892
5	Понимание педагогическим работником применимости получаемых учеником знаний The teaching staff's understanding of the applicability of the knowledge acquired by the student	3.26391076
6	Качество интернет-соединения с обучающей платформой The quality of the internet connection to the learning platform	2.25989256
7	Количество страниц текстовой информации (формат А4 по дисциплине в год) The number of pages of text information (A4 format per subject per year) on the subject	2.03743793
8	Умение ученика достигать цели The student's ability to achieve goals	1.42239427
9	Доверительные отношения с родителем/родителями у ученика The student's trusting relationship with the parent(s)	1.28860674
10	Нагрузка педагога в иных организациях The teacher's workload in other organizations	1.2232396

В основе метода лежит векторизация на основе деревьев решений. Выбор на них пал т.к. они обладают рядом преимуществ, а именно они легко интерпретируются благодаря наглядной структуре, напоминающей человеческое принятие решений, и способны автоматически выбирать значимые признаки, эффективно работая с разнородными данными без обязательной предобработки. Их гибкость позволяет выявлять нелинейные зависимости, а устойчивость к шуму и выбросам делает их практичным инструментом для задач классификации. Т.к. деревья решений на первом шаге выбирают наиболее значимые признаки, то было решено использовать деревья глубиной 1, т.е. использовать решающие пни.

Используя решающий пень в базе данных, мы выделяем наиболее важный признак, который удаляем из исходной базы данных и сохраняем ее в новой базе данных. Аналогично мы используем решающий пень еще два раза, что позволяет нам выявить еще два признака, и аналогично мы удаляем эти признаки из базы данных, с добавлением их к базе данных с первым признаком. К новой базе данных мы также добавляем и столбцы с самими категориальными признаками и классами обучающихся.

В новой базе данных используя в качестве фильтров отдельные классы категориальных признаков вычисляем средние значения в первых трех столбцах. Полученные комбинации трех чисел для каждого класса категориальных признаков определяет его вектор. Для обучения нейронной сети на векторах, образованных при помощи решающих пней, нами был создан словарь и с помощью него заменены существующие категориальные признаки: {'Алгебра': [10.0, 0.0, 2.6], 'Английский язык': [3.4, 0.8, 10.0], 'Астрономия': [10.0, 7.5, 4.3], 'Биология': [0.9, 8.8, 0.0], 'География': [0.0, 10.0, 0.2], 'Геометрия': [10.0, 0.1, 3.9], 'ИЗО': [3.0, 2.5, 5.6],

'Информатика': [10.0, 5.9, 4.3], 'Искусство (МХК)': [3.0, 2.1, 5.4], 'История': [0.0, 10.0, 0.0], 'Литература': [2.4, 5.1, 5.5], 'Математика': [10.0, 7.5, 4.3], 'Музыка': [3.5, 2.0, 6.2], 'ОДНКНР': [0.0, 10.0, 0.0], 'Обществознание': [0.0, 10.0, 0.0], 'Русский язык': [2.8, 3.9, 6.7], 'Технология': [2.9, 2.1, 6.5], 'Физика': [10.0, 7.5, 4.3], 'Физкультура': [3.1, 2.0, 6.5], 'Химия': [0.0, 10.0, 0.0]}

На рис. 6 приведена динамика ошибки по эпохам обучения на новой базе данных. В качестве целевых переменных выступали три числа формирующих вектор, а остальные данные в качестве признаков.




Рис. 6 - Динамика ошибки по эпохам обучения

Fig. 6 - Error dynamics across training epochs

При помощи тестовой выборки были получены вектора для категориальных признаков. Истинные вектора и вектора, полученные при помощи нейронной сети, были заменены на соответствующие им классам категориальных признаков. По категориальным признакам была построена матрица ошибок, которая приведена на рис. 7.




Рис. 7 - Матрица ошибок восстановления категориальных признаков

Fig. 7 - Confusion matrix for the reconstruction of categorical features

Аналогично было произведено 3 дополнительных расчета, по которым была построена бинарная матрица ошибок, где определялось общее количество верно и неверно распознанных категорий. Четыре бинарные матрицы ошибок приведены на рис. 8.

По ним можно определить, что средняя погрешность восстановления категориальных признаков составляет 5,17 %. С учетом полученных векторов было проведено повторное обучение нейронной сети прогнозировать предметные результаты обучения, погрешность обучения которой снизилась ниже 4%. Для понимания того, как влияет каждый параметр на результат обучения, была проведена статистическая обработка базы данных. Так для каждого балла по предмету были усреднены показатели, влияющие на учебный процесс.

На рис. 9 приведена зависимость нагрузки педагогических работников на оценку обучающегося. По оси абсцисс отложены оценки обучающихся, а по оси ординат усредненные нагрузки педагогов. Оценке «1» соответствуют пропуски занятий.




Рис. 8 - Бинарная матрица ошибок

Fig. 8 - Binary confusion matrix

Рис. 9а соответствует усредненная зависимость нагрузки педагога в образовательной организации, а рис. 9б соответствует усредненная зависимость нагрузки педагога в иных образовательных организациях.




Рис. 9 - Зависимость предметных результатов обучения от нагрузки педагога

Fig. 9 - Dependence of subject-specific learning outcomes on teacher workload

Вывод. В результате проведенных исследований разработан продукт, позволяющий прогнозировать предметные результаты обучения в следующем учебном году. Предоставляя доступ родителю или законному представителю к заполняемым данным участниками образовательных отношений по его ребенку, а также давая возможность изменять некоторые параметры, которые возможно скорректировать при прохождении обучения у его ребенка, родитель или законный представитель обучающегося может сразу получить ожидаемые предметные результаты обучения при изменении указанных параметров в жизни ребенка [23]. По результатам пробной эксплуатации в течении двух лет в 2024/2025 учебном году система показала погрешность предсказания и корректировки оценки в пределах до 3,9 %. В конечном счете у группы учеников, использовавших представленное решение увеличила в среднем результаты ЕГЭ на 10 баллов.

Основным недостатком в ходе проведенного юзабилити исследования было отмечено слишком большое количество параметров для заполнения. Для этих целей было произведено сокращение менее влиятельных параметров на предметные результаты обучения до 176. Дальнейшее развитие проекта предполагает автоматизацию сбора части параметров за счет использования технологий искусственного интеллекта, а также применение визуального анализа данных [24] для автоматизации выбора параметров, влияющих на учебный процесс, в кабинете родителя [25].

Благодарности. Исследование выполнено за счет средств Фонда содействия развитию малых форм предприятий в научно-технической сфере по договору № 5409ГС1/112041 от 26.11.2025.

Acknowledgments. The study was carried out with funding from the Foundation for Assistance to Small Innovative Enterprises in Science and Technology under Contract No. 5409GS1/112041 dated November 26, 2025.

Библиографический список:

1. Асланов Т.Г., Абидова М.Ш., Максудов М.М., Тагиров Х.Ю., Магомедов М.М. Прототип системы формирования индивидуальной траектории обучения // Вестник Дагестанского государственного технического университета. Технические науки. 2023. 50(2). С. 35-40. DOI: 10.21822/2073-6185-2023-50-2-35-40.
2. Rory J., Gray G. Prediction of student academic performance using Moodle data from a Further Education setting // Irish Journal of Technology Enhanced Learning. 2019. 5(1) P. 1-19. DOI: 10.22554/ijtel.v5i1.57.
3. Prasertisirikul P., Laohakiat S., Trakunphutthirak R., Sukaphat S. A Predictive Model for Student Academic Performance in Online Learning System // In: 2022 International Conference on Digital Government Technology and Innovation (DGTi-CON). Bangkok, Thailand. 2022. P. 76-79. DOI: 10.1109/DGTi-CON53875.2022.9849205.
4. Ефремов С.К., Нестеренко И.С., Епифанцева В.А., Анисимов С.Л., Печенин Е.А. Использование искусственной нейронной сети для прогнозирования успеваемости курсантов. Вестник Воронежского института ФСИН России. 2025. 15(1). С. 49-55.
5. Ромащенко А.И., Щербин С.И., Харитонов И.М., Панфилов А.Э., Жаравин Н.С. Применение статистических методов машинного обучения для прогнозирования будущей успеваемости абитуриентов в вузе. Современные наукоемкие технологии. 2025. 23(9). С. 132-136. DOI: 10.17513/snt.40497.
6. Philippou N., Ajoodha R., Jadhav A. Using Machine Learning Techniques and Matric Grades to Predict the Success of First Year University Students. In: 2020 2nd International Multidisciplinary Information Technology and Engineering Conference (IMITEC). Kimberley, South Africa. 2020. P. 1-5. DOI: 10.1109/IMITEC50163.2020.9334087.
7. Martinho V. R. D. C., Nunes C., Minussi C.R. An Intelligent System for Prediction of School Dropout Risk Group in Higher Education Classroom Based on Artificial Neural Networks. In: 2013 IEEE 25th International Conference on Tools with Artificial Intelligence. Herndon, VA, USA. 2013. P. 159-166. DOI: 10.1109/ICTAI.2013.33.
8. Ranawaka U.M., Rajapakse C. Predicting examination performance using machine learning approach: A case study of the Grade 5 scholarship examination in Sri Lanka. In: 2020 International Research Conference on Smart Computing and Systems Engineering (SCSE). Colombo, Sri Lanka. 2020. P. 202-209. DOI: 10.1109/SCSE49731.2020.9313029.
9. Харитонов И.М., Крушель Е.Г., Привалов О.О., Степанченко И.В., Степанченко О.В. Прогнозирование качества обучения в вузе с помощью методов регрессионного анализа. Известия Санкт-Петербургского государственного технологического института (технического университета). 2021. 56(82). С. 72-80. DOI: 10.36807/1998-9849-2020-56-82-72-80.
10. Zhu W. High school student GPA prediction by various linear regression models. Theoretical and Natural Science. 2024. 52(1). P. 153-162. DOI: 10.54254/2753-8818/52/2024ch0136.
11. Долганов Д.Н. Модель оценки и прогнозирования успешности обучения. Вестник экспериментального образования. 2018. 1(14). С. 40-54.
12. Побединская Т.В., Заславская О.Ю. Использование алгоритмов машинного обучения для прогноза успеваемости учащихся основной школы. Вестник МГПУ. Серия: Информатика и информатизация образования. 2022. 62(4). С. 75-82. DOI: 10.25688/2072-9014.2022.62.4.06.
13. Slabchenko O., Sydorenko V., Siebert X. Development of models for imputation of data from social networks on the basis of an extended matrix of attributes. Eastern-European Journal of Enterprise Technologies. 2016. 4(2(82)). P. 24-34. DOI: 10.15587/1729-4061.2016.74871.
14. Saini P., Nagpal B. Analysis of missing data and comparing the accuracy of imputation methods using wheat crop data. Multimedia Tools and Applications. 2023. P. 82. DOI: 10.1007/s11042-023-17178-9.
15. Cortese F. P., Pievatolo A. Statistical jump model for mixed-type data with missing data imputation. Advances in Data Analysis and Classification. 2025. P. 19. DOI: 10.1007/s11634-025-00631-y.
16. Фабрикант М.С. Модель-ориентированный подход к отсутствующим значениям: множественная импутация в многоуровневой регрессии посредством R (на примере анализа опросных данных). Социология: методология, методы, математическое моделирование. 2015. 24(41). С. 7-29.
17. Palchevsky E.V. Method for Improving the Accuracy of Predictive Values of Time Series Based on the Imputation of Historical Data. Programmaya Ingeneria. 2023;14(6):301-306. DOI:10.17587/prin.14.301-306.

18. Чернавин П.Ф., Чернавин Ф.П., Чернавин Н.П., Пономарева О.А., Сальник К.Д. Опыт применения различных методов импутации данных при решении задач классификации. Вестник компьютерных и информационных технологий. 2024. 21(6(240)). С. 50-57. DOI: 10.14489/vkit.2024.06.pp.050-057.
19. Лосев А.С., Массель А. Г. Прогнозирование солнечной радиации и импутация данных для цифрового двойника солнечной электростанции. Информационные и математические технологии в науке и управлении. 2022. 7(1(25)). С. 91-101. DOI: 10.38028/ESI.2022.25.1.008.
20. Асланов Т.Г., Айгумов Т.Г. Имитация работы донных сейсмографов с применением искусственных нейронных сетей. Морские интеллектуальные технологии. 2022. 15(2-1(56)). С. 143-148. DOI: 10.37220/MIT.2022.56.2.019.
21. Параметры учебного процесса влияющие на предметные результаты обучения [Файл] // Онлайн-школа «Дом знаний», 12.08.2022 <https://docs.domznaniy.school/1.jpg> (Дата обращения: 12.01.2026)
22. Alexandrov I.A., Kirichek A.V., Kuklin V.Z., Chervyakov L.M. Development of an Algorithm for Multicriteria Optimization of Deep Learning Neural Networks // HighTech and Innovation Journal. 2023. Vol. 4, No. 1. P. 157-173. DOI: 10.28991/HIJ-2023-04-01-011.
23. Прогнозирование оценки ребенка на год вперед с приведением личного кабинета ребенка и педагога, а также кабинета родителя с возможностью изменения части ранее заполненных параметров // Презентация работы системы онлайн школы «Дом знаний», 11.09.2025 URL: https://cms.domznaniy.school/uploads/Prognozirovanie1_821b7ceb67.pptx (Дата обращения: 12.01.2026)
24. Alexandrov I.A., Kuklin V.Zh., Muranov A.N., Tatarkanov A.A. Theoretical Foundations of an Algorithm of Visualization of a Set of Points of a Multidimensional Space for Use in Anthropotechnical Decision Support Systems // Proceedings of the Institute for System Programming of the RAS. 2022. Vol. 34, No. 4. P. 201-210. DOI 10.15514/ISPRAS-2022-34(4)-14.
25. Александров И.А. Принципы автоматизация технологической подготовки производства путем нейросетевого моделирования // Инженерный вестник Дона. 2019. 5(56). С. 22.

References:

1. Aslanov T.G., Abidova M.Sh., Maksudov M.M., Tagirov Kh.Yu., Magomed M.M. The prototype of the system for the formation of an individual learning path. Herald of Daghestan State Technical University. Technical Sciences. 2023;50(2):35-40. (In Russ..) DOI: 10.21822/2073-6185-2023-50-2-35-40.
2. Rory J., Gray G. Prediction of student academic performance using Moodle data from a Further Education setting // Irish Journal of Technology Enhanced Learning. 2019. 5(1) P. 1-19. DOI: 10.22554/ijtel.v5i1.57.
3. Prasertisirikul P., Laohakiat S., Trakunphutthirak R., Sukaphat S. A Predictive Model for Student Academic Performance in Online Learning System. In: 2022 International Conference on Digital Government Technology and Innovation (DGTi-CON). Bangkok, Thailand. 2022;76-79. DOI: 10.1109/DGTi-CON53875.2022.9849205.
4. Efremov S.K., Nesterenko I.S., Epifantseva V.A., Anisimov S.L., Pechenin E.A. Using an artificial neural network to predict student performance. *Bulletin of the Voronezh Institute of the Federal Penitentiary Service of Russia*. 2025;15(1):49-55. (In Russ)
5. omaschenko A.I., Scherbin S.I., Kharitonov I.M., Panfilov A.E., Zharavin N.S. The use of statistical machine learning methods to predict the future academic performance of university applicants. Modern High Technologies. 2025;23(9):132-136. (In Russ.) DOI: 10.17513/snt.40497.
6. Philippou N., Ajoodha R., Jadhav A. Using Machine Learning Techniques and Matric Grades to Predict the Success of First Year University Students. In: 2020 2nd International Multidisciplinary Information Technology and Engineering Conference (IMITEC). Kimberley, South Africa. 2020;1-5. DOI: 10.1109/IMITEC50163.2020.9334087.
7. Martinho V. R. D. C., Nunes C., Minussi C.R. An Intelligent System for Prediction of School Dropout Risk Group in Higher Education Classroom Based on Artificial Neural Networks. In: 2013 IEEE 25th International Conference on Tools with Artificial Intelligence. Herndon, VA, USA. 2013;159-166. DOI: 10.1109/ICTAI.2013.33.
8. Ranawaka U.M., Rajapakse C. Predicting examination performance using machine learning approach: A case study of the Grade 5 scholarship examination in Sri Lanka. In: 2020 International Research Conference on Smart Computing and Systems Engineering (SCSE). Colombo, Sri Lanka. 2020;202-209. DOI: 10.1109/SCSE49731.2020.9313029.
9. Kharitonov I.M., Krushel E.G., Privalov O.O., Stepanchenko I.V., Stepanchenko O.V. Higher school education quality forecasting by regression analysis methods. Proceedings of the Saint Petersburg State Institute of Technology (Technical University). 2021;56(82):72-80. (In Russ.) DOI: 10.36807/1998-9849-2020-56-82-72-80.
10. Zhu W. High school student GPA prediction by various linear regression models. Theoretical and Natural Science. 2024;52(1):153-162. DOI: 10.54254/2753-8818/52/2024ch0136.
11. Dolganov D. N. Model assessment and prediction of academic success. Bulletin of Experimental Education. 2018;1(14):40-54. (In Russ)

12. Pobedinskaya T.V., Zaslavskaya O.Yu. The use of machine learning algorithms to prediction the performance of basic school students. Moscow State Pedagogical University Bulletin. Series: Informatics and Education Digitalization. 2022. 62(4):75-82. (In Russ) DOI: 10.25688/2072-9014.2022.62.4.06.
13. Slabchenko O., Sydorenko V., Siebert X. Development of models for imputation of data from social networks on the basis of an extended matrix of attributes. Eastern-European Journal of Enterprise Technologies. 2016;4(2(82)):24-34. DOI: 10.15587/1729-4061.2016.74871.
14. Saini P., Nagpal B. Analysis of missing data and comparing the accuracy of imputation methods using wheat crop data. Multimedia Tools and Applications. 2023; 82. DOI: 10.1007/s11042-023-17178-9.
15. Cortese F. P., Pievatolo A. Statistical jump model for mixed-type data with missing data imputation. Advances in Data Analysis and Classification. 2025;19. DOI: 10.1007/s11634-025-00631-y.
16. Fabrikant M. S. Model-oriented approach to missing values: multiple imputation in multilevel regression using R (on the example of analyzing survey data). Sociology: Methodology, Methods, Mathematical Modeling. 2015;24(41):7-29. (In Russ) EDN: WITRUD.
17. Palchevsky E.V. Method for Improving the Accuracy of Predictive Values of Time Series Based on the Imputation of Historical Data. Programnaya Ingeneria. 2023;14(6):301-306. DOI: 10.17587/prin14.301-306.
18. Chernavin P.F., Chernavin F.P., Chernavin N.P., Ponomareva O.A., Salnik K.D. Experience in applying various data imputation methods in solving classification problems. Herald of Computer and Information Technologies. 2024; 21(6(240)):50-57. (In Russ) DOI: 10.14489/vkit.2024.06.pp.050-057.
19. Losev A. S., Massel A. G. Time series forecasting and data imputation for the digital twin of a solar power plant. Information and Mathematical Technologies in Science and Management. 2022;7(1(25)): 91-101. (In Russ) DOI: 10.38028/ESI.2022.25.1.008.
20. Aslanov T.G., Aygumov T.G. Simulation of the operation of bottom seismographs using artificial neural networks. Marine Intellectual Technologies. 2022;15(2-1(56)):143-148. (In Russ) DOI: 10.37220/MIT.2022.56.2.019
21. Parameters of the educational process influencing subject learning outcomes [File]// Online school "Dom Znaniy" (House of Knowledge), 12.08.2022. <https://docs.domznaniy.school/1.jpg> (Accessed: 12.01.2026)
22. Alexandrov I.A., Kirichek A.V., Kuklin V.Z., Chervyakov L.M. Development of an Algorithm for Multicriteria Optimization of Deep Learning Neural Networks. HighTech and Innovation Journal. 2023;4(1):157-173. DOI: 10.28991/HIJ-2023-04-01-011.
23. Forecasting a child's academic performance one year ahead, featuring the child's and teacher's personal dashboards as well as a parent's dashboard with the ability to modify certain previously entered parameters. Presentation of the online school "Dom Znaniy" (House of Knowledge) system operation, 11.09.2025. URL: https://cms.domznaniy.school/uploads/Prognozirovaniye1_821b7ceb67.pptx (Accessed: 12.01.2026)
24. Alexandrov I.A., Kuklin V.Zh., Muranov A.N., Tatarkanov A.A. Theoretical Foundations of an Algorithm of Visualization of a Set of Points of a Multidimensional Space for Use in Anthropotechnical Decision Support Systems. Proceedings of the Institute for System Programming of the RAS. 2022; 34(4):201-210. DOI 10.15514/ISPRAS-2022-34(4)-14.
25. Alexandrov I.A. Principles of technological preparation automation of production by neural network modeling. Inzhenernyy vestnik Dona. 2019;5(56):22.

Информация об авторах:

Асланов Тагирбек Гайдарбекович, кандидат технических наук, доцент кафедры информационной безопасности; tabasik@gmail.com; ORCID: 0000-0002-5594-3554.

Штанчаев Хайрудин Баширович, кандидат технических наук, доцент кафедры информационной безопасности и программной инженерии; shtanchaev.h@gmail.com; ORCID: 0009-0006-1224-4266.

Фарманов Рустам Фирязович, кандидат экономических наук, генеральный директор; резидент Фонда «Сколково»; firyzovich@mail.ru; ORCID: 0009-0004-4979-8073.

Тагиров Халипа Юсупович, генеральный директор, halipa@domznaniy.school; ORCID: 0009-0000-1661-1568.

Information about the authors:

Tagirbek G. Aslanov, Cand. Sci. (Eng.), Assoc. Prof., Department of Information Security and Software Engineering; tabasik@gmail.com; ORCID: 0000-0002-5594-3554.

Khairudin B. Shtanchaev, Cand. Sci. (Eng.), Assoc. Prof., Department of Information Security and Software Engineering; shtanchaev.h@gmail.com; ORCID: 0009-0006-1224-4266.

Rustam F. Farmanov, Cand. Sci. (Econom.), General manager; Skolkovo Foundation Resident; firyzovich@mail.ru; ORCID: 0009-0004-4979-8073.

Khalipa Yu. Tagirov, General manager; halipa@domznaniy.school; ORCID: 0009-0000-1661-1568.

Конфликт интересов/Conflict of interest.

Авторы заявляют об отсутствии конфликта интересов/The author declare no conflict of interest.

Поступила в редакцию/Received 11.01.2026.

Одобрена после рецензирования/Revised 09.02.2026.

Принята в печать/Accepted for publication 26.04.2026.