

RU

Применение нейросетевого подхода к построению современного образовательного процесса в вузе

Бояров Е. Н., Абрамова С. В., Купцова О. В., Шитов Э. Н., Станкевич П. В.

Аннотация. Цель исследования заключается в теоретическом обосновании возможности применения нейросетевого подхода к построению современного образовательного процесса в вузе. В статье рассматриваются основные методы машинного обучения, используемые для анализа образовательных данных, обосновывается необходимость их внедрения в образовательный процесс. Особое внимание уделено вопросам интерпретируемости моделей искусственных нейронных сетей (ИНС) и их влиянию на принятие решений в образовательных учреждениях. Научная новизна заключается в обосновании сущности нейросетевого подхода и его принципов как теоретической основы для разработки и обоснования моделей организации различных этапов образовательного процесса в вузе с применением ИНС. Результаты исследования включают описание применения нейросетевого подхода к организации адаптивного обучения; оцениванию текущих достижений обучающихся и осуществлению обратной связи с преподавателем; прогнозированию успешности обучения; построению индивидуальных образовательных траекторий. Сделан вывод о возможности практического применения разработанных моделей для организации различных этапов образовательного процесса в вузе, направленного на повышение адаптивности, персонализации и эффективности обучения.

EN

Application of the neural network approach to constructing a modern educational process in higher education

E. N. Boyarov, S. V. Abramova, O. V. Kuptsova, E. N. Shitov, P. V. Stankevich

Abstract. The aim of this research is to theoretically substantiate the possibility of applying a neural network approach to constructing a modern educational process in higher education. The article examines the main machine learning methods used for analyzing educational data and justifies the necessity of their implementation into the educational process. Particular attention is paid to the interpretability of artificial neural network (ANN) models and their influence on decision-making in educational institutions. The scientific novelty lies in substantiating the essence of the neural network approach and its principles as a theoretical basis for the development and justification of models for organizing various stages of the educational process in higher education using ANNs. The results of the research include a description of the application of the neural network approach to: organizing adaptive learning; evaluating students' current achievements and providing feedback to the instructor; predicting learning success; and constructing individual educational trajectories. The conclusion is drawn regarding the possibility of the practical application of the developed models for organizing various stages of the educational process in higher education, aimed at increasing the adaptability, personalization, and effectiveness of learning.

Введение

Актуальность данного исследования обусловлена растущей необходимостью адаптации образовательного процесса к индивидуальным особенностям студентов, повышением требований к качеству обучения и развитием цифровых технологий. Современное образование переживает этап значительных трансформаций, связанных с внедрением цифровых технологий и методов искусственного интеллекта. Одним из ключевых направлений таких изменений является использование нейросетевых алгоритмов для адаптации образовательного процесса, анализа успеваемости студентов и прогнозирования их академических достижений. Применение искусственных нейронных сетей (ИНС) открывает новые возможности в построении индивидуальных образовательных траекторий (ИОТ), организации адаптивного обучения и автоматизации оценки знаний.

В условиях быстро меняющегося информационного общества традиционные методы преподавания и оценки знаний становятся менее эффективными, что требует концептуального обоснования внедрения интеллектуальных систем, способных персонализировать образовательные траектории и оперативно анализировать академическую успешность студентов.

Увеличение объемов образовательных данных и развитие методов машинного обучения позволяют применять ИНС для автоматизированного анализа успеваемости, прогнозирования отчислений студентов, формирования индивидуальных образовательных рекомендаций для каждого студента по освоению образовательных программ и улучшения образовательных стратегий. Важность исследования также связана с необходимостью теоретического обоснования инструментов, помогающих преподавателям выявлять студентов из группы риска и своевременно принимать меры для их академической поддержки, что способствует снижению уровня неуспеваемости и повышению эффективности образовательного процесса в целом.

С развитием искусственного интеллекта (ИИ) и, в частности, нейронных сетей возможности их применения в образовательном процессе значительно расширились. Нейросети находят применение в адаптивном обучении, автоматизации оценки работ обучающихся, создании индивидуальных образовательных траекторий и многом другом.

Вместе с тем анализ научной литературы (Daud, Aljohani, Abbasi et al., 2017; Jayaprakash, Krishnan, Jaiganesh, 2020; Widyaningsih, Fitriani, Sarwinda, 2019; Zhang, Sun, Shu et al., 2022; Гриценко, Осавелюк, 2013) показывает, что, несмотря на то, что применение методов машинного обучения и нейросетевых моделей в образовании активно развивается, остается ряд нерешенных вопросов, касающихся интерпретируемости моделей, их точности, а также интеграции в образовательные платформы.

Для осуществления эффективного и современного образовательного процесса в вузе представляется целесообразным выявить теоретические основания применения ИНС для решения типовых образовательных задач и на этой основе разработать концептуальные модели их внедрения в образовательный процесс вуза.

Достижение поставленной цели предусматривает решение следующего перечня задач исследования:

1. Провести анализ существующих подходов к применению нейросетевых технологий в образовательном процессе в вузе, обосновать сущность нейросетевого подхода как современной концепции персонализированного и адаптивного обучения, основанного на способности искусственных нейронных сетей выявлять скрытые закономерности в образовательных данных и предсказывать академические результаты обучающихся.
2. На основе нейросетевого подхода разработать модели организации различных этапов образовательного процесса в вузе и обосновать возможность их применения для решения типовых задач образовательного процесса в вузе (организация адаптивного обучения; оценивание текущих достижений обучающихся и осуществление обратной связи с преподавателем; прогнозирование успешности обучения; построение индивидуальных образовательных траекторий).

В рамках настоящей статьи перед авторами стояла задача концептуально обосновать возможность применения нейросетевого подхода для решения широкого спектра образовательных задач. Настоящее исследование направлено на теоретическое моделирование основных направлений использования искусственных нейронных сетей в образовательной практике и определение принципиальных основ их интеграции в современный образовательный процесс.

Методология исследования строится на использовании нейросетевых технологий для прогнозирования академической успеваемости студентов и построения индивидуальных образовательных траекторий. Основой является системный подход, который рассматривает образовательный процесс как сложную взаимосвязанную систему, включающую академические показатели, поведенческие характеристики студентов и педагогические стратегии.

Теоретическую базу исследования составили результаты научных работ, посвященных применению методов машинного обучения и нейросетевых технологий в образовательном процессе (Agarwal, Mittal, 2014; Blanco, Lovelle, Fernandez et al., 2016; Amazona, Hernandez, 2019; Гриценко, Осавелюк, 2013; Добровольская, 2022).

Анализ отечественных и зарубежных исследований показал, что искусственные нейронные сети активно используются для прогнозирования академической успеваемости, построения индивидуальных образовательных траекторий и автоматизации оценки знаний (Васильева, Курушин, Власов, 2019; Jayaprakash, Krishnan, Jaiganesh, 2020; Devasia, Vinushree, Hegde, 2016; Daud, Aljohani, Abbasi et al., 2017; Widyaningsih, Fitriani, Sarwinda, 2019).

В работах различных авторов рассматриваются алгоритмы классификации и регрессии, такие как метод *k*-ближайших соседей (*k*-Nearest Neighbors, KNN) (Rincon-Flores, López-Camacho, Mena et al., 2020), случайный лес (Random Forest) (Jayaprakash, Krishnan, Jaiganesh, 2020; Kumar, Krishna, Neelakanteswara et al., 2020), наивный байесовский классификатор (Naive Bayes) (Amazona, Hernandez, 2019; Páez, Guzmán, 2018), а также глубокие (Deep Neural Network, DNN) (Blanco, Lovelle, Fernandez et al., 2016; Zhang, Sun, Shu et al., 2022), рекуррентные (Recurrent Neural Network, RNN) и сверточные (Convolutional Neural Network, CNN) нейросетевые модели (Devlin, Chang, Lee et al., 2019; Roy, Ghosh, 2021; Добровольская, 2022), применяемые для анализа текстовых, числовых и временных данных.

Также рассматриваются рекуррентные нейронные сети (Recurrent Neural Networks, RNN), в частности, сети с долгой краткосрочной памятью (Long Short-Term Memory, LSTM) и закрытый рекуррентный модуль (Gated Recurrent Unit, GRU), для прогнозирования временных рядов и сети прямого распространения (Feedforward Neural Networks, FNN) для решения задач классификации данных (Devlin, Chang, Lee et al., 2019; Васильева, Курушин, Власов, 2019; Daud, Aljohani, Abbasi et al., 2017). Кроме того, в исследовании учитываются

концепции адаптивного обучения и персонализации образовательного процесса, разработанные в рамках когнитивной психологии и педагогики (Бояров, 2015; Абрамова, Бояров, 2019). Работы в области интеллектуальных образовательных систем подчеркивают важность интеграции искусственного интеллекта для повышения эффективности обучения и мотивации студентов (Jayaprakash, Krishnan, Jaiganesh, 2020). Анализ этих исследований позволил сформировать методологический подход к построению и внедрению нейросетевых технологий в образовательную среду, направленный на улучшение качества обучения за счет индивидуализации и прогнозирования академической успешности.

Практическая значимость исследования заключается в возможности использования разработанных моделей применения ИНС для повышения эффективности образовательного процесса в вузе и в педагогической практике.

Предложенные модели могут быть применены в высших учебных заведениях для построения индивидуальных образовательных траекторий, автоматической оценки знаний, адаптивного обучения и персонализированного подбора учебных материалов. Интеграция предложенных решений в системы управления образовательными процессами позволит преподавателям оперативно реагировать на изменения в динамике обучения студентов, а самим обучающимся – получать более точные рекомендации по выбору дисциплин и учебных стратегий. Таким образом, применение нейросетевого подхода способствует повышению результативности образовательного процесса и эффективности академической поддержки.

Обсуждение и результаты

1. Анализ существующих подходов к применению нейросетевых технологий в образовательном процессе в вузе

В последние годы искусственный интеллект играет важную роль в образовании, где наиболее часто применяется для прогнозирования успеваемости учащихся (Wu, Rohatgi, Keesara et al., 2021; Prasad, Kaur, Kan, 2018).

Как показал проведенный анализ, в основном проблематикой применения интеллектуальных алгоритмов в образовательных системах, основанных на задействовании элементов нейронных сетей, занимаются зарубежные и российские авторы в ретроспективе не более 10 лет, что позволяет говорить о недостаточном теоретическом и научном обосновании данных вопросов. Как правило, авторы в своих исследованиях применяли нейросети для решения задачи классификации данных об обучающихся на основе общеизвестных методов классификации в машинном обучении, таких как метод k-ближайших соседей (Rincon-Flores, López-Camacho, Mena et al., 2020); классификатор дерева решений (Decision Tree Classifier) / случайный лес (Random Forests); наивный байесовский метод (Naive Bayes) (Zhang, Sun, Shu et al., 2022) и другие.

Так, в своих исследованиях J. Blanco, S. Lovelle, R. Fernandez, E. Perez (2016) и E. G. Rincon-Flores, E. López-Camacho, J. Mena, O. O. López (2020) прогнозируют успеваемость обучающихся с использованием различных алгоритмов. J. Blanco, S. Lovelle, R. Fernandez и E. Perez (2016) предложили глубокую нейронную сеть для прогнозирования успеваемости с точностью 78%. В работе E. G. Rincon-Flores, E. López-Camacho, J. Mena, O. O. López (2020) упомянуты несколько моделей, таких как KNN и Random Forest, для достижения точности 80%. Однако в этих работах не объясняется, почему они прогнозируют успеваемость обучающихся, особенности применения этих прогнозов.

В исследовании V. U. Kumar, A. Krishna, P. Neelakanteswara, C. Z. Basha (2020) была проведена оценка успеваемости студентов на экзаменах по техническим дисциплинам при поступлении в университет. Для этого были использованы данные о 200 тыс. студентов университетов с 2013 по 2017 год. Обучающиеся были классифицированы с использованием двух разных алгоритмов: кластеризации по K-средним и иерархической кластеризации. После классификации был применен Naive Bayes, который показал эффективность прогнозирования результатов экзамена с точностью до 72%.

В исследовании S. Jayaprakash, S. Krishnan и V. Jaiganesh (2020) обсуждаются показатели отсева обучающихся на ранних этапах программы, а также факторы, которые оказывают наибольшее влияние на успеваемость обучающихся. Для прогнозирования этих показателей авторы использовали 887 примеров и 19 переменных. Кроме того, они также применили Naive Bayes, который показал эффективность прогнозирования с точностью 85,7%.

В работе A. Daud, N. R. Aljohani, R. A. Abbasi et al. (2017) были оценены причины, по которым многие студенты бросают обучение в вузе. Для этого в исследовании были предсказаны личные, семейные и экономические факторы, которые в наибольшей степени влияют на успеваемость обучающихся, чтобы определить, завершит ли тот или иной студент свое обучение. Для тестирования был использован набор данных, который был нормализован (очищен от случайных значений и нехарактерных всплесков), чтобы получить выборку из 50 студентов, которые закончили учебу, и 50, которые этого не сделали (были отчислены из вуза). В рамках данного исследования результаты Naive Bayes показали эффективность в 84,8%.

Исследование, проведенное Y. Widyaningsih, N. Fitriani и D. Sarwinda (2019), было направлено на прогнозирование академической успеваемости студентов-первокурсников с использованием подхода к неконтролируемому обучению для классификации успеваемости студентов. В этом исследовании в качестве методологии также использовался Naive Bayes, точность которого составила 96%.

В работе T. Devasia, T. P. Vinushree, V. Hegde (2016) рассматривается проблематика отчисления студентов из высших учебных заведений. Авторы предложили веб-базируемое приложение, основанное на применении

Naïve Bayes для анализа данных с целью экстракции значимой информации. Результаты данного исследования демонстрируют, что применение базового алгоритма Naïve Bayes позволяет достичь высокой степени точности в прогнозировании отчисления студентов по сравнению с другими аналитическими подходами, включая регрессионный анализ, методы построения деревьев решений и алгоритмы нейронных сетей.

М. V. Amazona и А. А. Hernandez (2019) провели исследование потенциала прогнозирования академических достижений студентов с целью оптимизации процесса принятия образовательных решений. Для моделирования и прогнозирования успеваемости обучающихся авторы применили методы интеллектуального анализа данных, используя наивный байесовский алгоритм для анализа и оценки данных об успеваемости. Исследование демонстрирует, что, несмотря на то, что Naïve Bayes показывает лучшие результаты по сравнению с другими алгоритмами, его общая точность в классификации достигает 88%.

А. Ráez и D. Guzmán (2018) в своей научной работе занимались решением проблем, оказывающих влияние на различные аспекты процессов обучения и преподавания. Для достижения поставленной цели они разработали и внедрили автоматизированную модель для прогнозирования академической успеваемости студентов. Основываясь на сравнении нескольких алгоритмов, исследование показало, что алгоритм Naïve Bayes демонстрирует превосходство над другими, достигая коэффициента точности прогнозов на уровне 73%.

В исследовании, проведенном Т. В. Зайцевой, С. В. Игруновой, Н. П. Путивцевой с соавторами (2017), было рассмотрено применение прямой искусственной нейронной сети, содержащей два скрытых слоя и основывающейся на непараметрических функциональных связях. В рамках компьютерного эксперимента использовались тренировочные и тестовые наборы данных для оценки эффективности нейросетевого алгоритма в задаче определения уровня освоения компетенций. Результаты показали, что ошибка классификации составляет 4,9%, что существенно превосходит точность оценок, предоставляемых преподавателями в процессе тестирования.

В рамках исследования Е. Е. Васильевой, Д. С. Курушиным, С. С. Власовым (2019) была разработана искусственная нейронная сеть (ИНС) для раннего прогнозирования среднего балла выпускников университета, исходя из академических показателей на втором курсе. Авторская модель, представляющая собой многослойный персептрон с семью скрытыми нейронами, продемонстрировала высокую контрольную производительность на уровне 0,994293 благодаря использованию алгоритма итерационного метода численной оптимизации (BFGS8) для обучения, функции ошибки в виде суммы квадратов, а также гиперболического тангенса в качестве функции активации для скрытых нейронов и тождественной функции на выходе. Погрешность модели составляет около 1,5%, что подчеркивает ее эффективность и точность в прогнозировании учебных достижений студентов.

Исследование Н. Ю. Добровольской (2022) посвящено применению нейронных сетей в контексте развития систем профессионального обучения бакалавров. На начальном этапе эксперимента архитектура нейросети включала в себя входной слой с одним нейроном, три скрытых слоя с 128, 64 и 32 нейронами соответственно, и выходной слой, состоящий из четырех нейронов, соответствующих оценкам по четырем дисциплинам. В качестве функции активации для нейронов была выбрана функция ReLU, которая обеспечивает нулевой отклик на отрицательные входные сигналы, тогда как для нейронов выходного слоя применялась сигмоидальная функция. В процессе эксперимента была достигнута точность прогнозирования на уровне 6,45% и показатели ошибки по метрике средней абсолютной ошибки составили 0,0802.

В работе Е. М. Гриценко и П. А. Осаветюка (2013) разрабатывается методика создания персонализированных учебных планов в рамках предвузовской подготовки абитуриентов по информатике, основываясь на принципах искусственных нейронных сетей. Этот подход предусматривает формирование уникального образовательного маршрута каждого студента на основе оценки его потенциала успешного освоения различных модулей. Модули ранжируются от наиболее простых к более сложным в зависимости от предварительно рассчитанной вероятности успешного их прохождения обучающимися. Такая последовательность обеспечивает постепенное наращивание сложности материала, оптимизируя процесс обучения. Эффективность предложенного метода подтверждается высоким уровнем точности прогнозирования результатов обучения (от 75,1% до 83,6% в различных моделях), что демонстрирует его пригодность для предсказания успеваемости студентов.

Таким образом, необходимо отметить, что, с одной стороны, проблематика нейросетевого подхода находит отражение в работах российских и зарубежных авторов, но, с другой стороны, данные работы не раскрывают в обобщенном виде возможности применения нейросетей для задач образования, ограничиваясь лишь отдельными прикладными вопросами их применения в образовательном процессе.

Вместе с тем исследование потенциала нейросетевых технологий в образовательной сфере вызывает большой интерес и сталкивается с нехваткой всеобъемлющих моделей для оценки их вклада в изменение образовательного процесса. Следовательно, возникает необходимость в тщательном изучении и концептуализации возможностей нейросетевых технологий, а также в анализе их ключевых принципов и условий использования. Также пока не находит широкого распространения модель, основанная на использовании глубоких нейронных сетей при решении проблемы поиска эффективных инструментов повышения успеваемости студентов в университетах. Прогнозирование успеваемости обучающихся могло бы помочь преподавателям более эффективно выявлять обучающихся из группы риска и принимать меры поддержки, что, в свою очередь, будет способствовать успешному завершению образовательного процесса и, соответственно, повышению престижа учебных заведений.

Таким образом, представляется возможным определить сущность нейросетевого подхода, которая заключается в использовании искусственных нейронных сетей для анализа сложных взаимосвязей в образовательных данных с целью решения типовых задач образовательного процесса – таких как адаптивное обучение,

прогнозирование успеваемости и построение индивидуальных траекторий. В отличие от традиционных алгоритмов, нейросети способны выявлять скрытые закономерности без явного программирования правил, что делает их особенно эффективными в условиях высокой вариативности образовательной среды. Нейросетевой подход рассматривает обучение студентов как динамическую систему с множеством факторов, а модели нейронных сетей – как инструменты для персонализации и прогнозирования академических результатов. Ключевая особенность подхода – это способность к адаптации, самообучению и работе с неполными или неоднородными данными, что позволяет строить более точные, индивидуализированные образовательные стратегии.

Для практической реализации данного подхода в образовании необходимо определить его ключевые принципы, которые обеспечивают адаптивность, системность, устойчивость и прогностическую направленность нейросетевых моделей в условиях образовательной среды:

1. Принцип системности предполагает рассмотрение образовательного процесса как целостной системы взаимосвязанных элементов: структурных элементов образовательной программы, учебного содержания, образовательных технологий, методов и средств обучения и контроля, а также всех субъектов образовательного процесса с их вещественными характеристиками, которые во всей своей совокупности будут выступать в качестве входных данных для нейросети, на основе которых ИНС будет прогнозировать искомое выходное состояние.

2. Принцип конечной цели подразумевает определение четких соотношений в образовательных целях и желаемых результатах, которые должны быть достигнуты в ходе освоения студентами основной образовательной программы на основе реализации прогнозируемой образовательной модели. Данный принцип очень важен на этапе обучения ИНС, поскольку именно от правильной формулировки входных и выходных параметров нейросети зависит ее эффективная работа.

3. Принцип неопределенности подразумевает учет возможных изменений и переменных в образовательном процессе, таких как различия в индивидуальных признаках обучающихся, изменяющихся внешних и внутренних факторов образовательного процесса, изменениях в технологиях и требованиях безопасности и др. Проектируемые ИНС должны быть гибкими и адаптивными к таким неопределенностям.

4. Принцип вероятностных результатов предполагает получение на выходе ИНС данных с определенной долей вероятности (прогноза), которая характеризуется точностью прогноза и значением функции потерь и отражает, насколько предсказания модели отличаются от истинных значений. Данный принцип уточняет цель обучения нейросети – минимизировать потери и повысить точность прогноза.

5. Принцип развития предполагает постоянное совершенствование ИНС на основе новых научных достижений, передовых практик и обратной связи от студентов и преподавателей.

6. Принцип устойчивости предполагает создание и применение в образовательном процессе таких ИНС, которые были бы способны противостоять внешним и внутренним изменениям и вызовам, сохраняя при этом свою эффективность на уровне заданных вероятностных критериев.

Разработка моделей организации различных этапов образовательного процесса с применением ИНС невозможна без учета заложенных принципов нейросетевого подхода. Именно данные принципы задают требования к адаптивности моделей, обеспечивают их способность учитывать изменяющиеся характеристики обучающихся, устойчиво функционировать в условиях неопределенности образовательной среды и точно прогнозировать результаты обучения. Таким образом, принципы нейросетевого подхода выступают методологическим каркасом для проектирования эффективных образовательных моделей на базе ИНС.

2. Разработка моделей организации различных этапов образовательного процесса в вузе с применением искусственных нейронных сетей

2.1. Нейросетевой подход к организации адаптивного обучения

Адаптивные обучающие системы, использующие нейросети, способны анализировать поведение пользователя и адаптировать учебный материал под его индивидуальные особенности и потребности. Такие системы позволяют создавать персонализированные учебные планы, учитывая знания, скорость обучения и предпочтения обучающихся. Для адаптивного обучения можно использовать нейросети, способные анализировать большое количество данных о студентах и их взаимодействии с учебным материалом. Цель такой системы – адаптировать обучение под индивидуальные потребности каждого студента, учитывая его предпочтения, стиль обучения и уровень знаний. Рассмотрим ключевые аспекты структуры, принципы работы и построения нейросети для адаптивного обучения.

Для задач адаптивного обучения возможно использовать следующие типы нейронных сетей:

- RNN и LSTM – для анализа последовательностей данных, таких как история взаимодействий студента с учебным контентом;
- CNN – для анализа визуального контента и текстовых данных в учебных материалах;
- FNN – для классификации студентов по качественным признакам (например, наличие внутренней и внешней мотивации, социальная активность, эмоциональная устойчивость и другие) и предсказания результатов их обучения на основе агрегированных данных об успеваемости.

Рассмотрим возможную структуру нейросети для адаптивного обучения (Схема 1).




Схема 1. Модель нейросети адаптивного обучения

Данная модель нейросети включает в себя следующие слои:

1. Входной слой, в который поступают данные о взаимодействии студента с учебным материалом. Это могут быть ответы на вопросы, время, затраченное на выполнение заданий, и другие характеристики активности студента. В моделируемой нейросети в качестве вектора входного слоя были значения текущей успеваемости по обязательным дисциплинам ($\bar{x} = \{O_1, O_2, O_3, \dots, O_n\}$).

2. Скрытые слои (один или несколько типа RNN, LSTM, GRU, CNN). Каждый слой состоит из нейронов, которые обрабатывают входные данные и передают результаты следующему слою.

3. Выходной слой, который генерирует прогнозы или рекомендации на основе обработанных данных. Например, это может быть рекомендация по выбору учебного материала или заданий, которые соответствуют уровню знаний и скорости обучения студента. В моделируемой нейросети в качестве вектора выходного слоя были значения, соответствующие уровню сложности учебного материала ($\bar{y} = \{UC_1, UC_2, UC_3, \dots, UC_m\}$).

Принцип работы таких нейросетей для реализации адаптивного обучения заключается в следующей последовательности шагов (или этапов).

На первом этапе система собирает данные о действиях студентов в процессе обучения, включая ответы на вопросы, время на задания, предпочтения в форматах учебных материалов и пр. Далее данные очищаются от шума и преобразуются в формат, пригодный для обработки нейросетью. Это может включать нормализацию, кодирование категориальных переменных и т. д. На следующем этапе нейросеть обучается распознавать шаблоны в данных. Это может быть, например, связь между временем, затраченным на определенный тип заданий, и успеваемостью студента по этой теме. Тем самым нейросеть обучается на больших объемах данных, содержащих информацию о поведении и успехе студентов в процессе обучения. В ходе этапа тестирования и валидации модель тестируется на новых данных для оценки ее способности адаптировать обучение к индивидуальным потребностям студентов. На основе результатов тестирования модель корректируется и оптимизируется для улучшения результатов. По окончании корректировки принимается решение о применении модели в реальном образовательном процессе, в ходе чего на основе анализа данных нейросеть создает персонализированные рекомендации или учебные планы для каждого студента, учитывая его индивидуальные потребности, предпочтения и уровень знаний.

Технически и программно построение нейросети для адаптивного обучения включает в себя следующие шаги:

1. Определение архитектуры, в ходе чего осуществляется выбор типа и структуры нейросети в зависимости от задачи и типа данных (например, RNN для анализа последовательностей действий и студента).

2. Выбор функций потерь (например, кросс-энтропия для задач классификации) и оптимизатора (например, Adam) в соответствии с конкретной задачей (например, адаптацией/дифференциацией учебного материала или адаптацией применяемого метода или средства обучения).

3. Обучение модели на данных о взаимодействии студентов с учебным материалом, в ходе чего постепенно адаптируются весовые коэффициенты ω_i для минимизации ошибки предсказания.

4. Настройка и регуляризация модели для предотвращения переобучения и улучшения обобщающей способности, для чего применяются методы регуляризации (например, Dropout).

5. Реализация модели в реальных образовательных условиях и мониторинг ее результативности в образовательной среде, где она начинает адаптировать учебный процесс под каждого студента. При этом важно осуществлять постоянный мониторинг эффективности модели и вносить коррективы при необходимости.

Тем самым рассмотренная модель адаптивного обучения реализует принцип системности, учитывая взаимодействие академических показателей, поведенческих характеристик и образовательных стратегий. Принцип неопределенности отражается в способности нейросети адаптироваться к изменениям поведения студентов и их образовательных потребностей.

2.2. Нейросетевой подход к оцениванию текущих достижений обучающихся и осуществление обратной связи с преподавателем

Нейронные сети также можно активно применять для автоматизации процессов оценки знаний и предоставления обратной связи. Такие нейросети могут эффективно оценивать ответы студентов на открытые

вопросы, а также анализировать сложные работы, такие как эссе, что позволит педагогам сэкономить время на проверке студенческих работ и уделить больше внимания индивидуальной (контактной) работе с каждым студентом. С этой целью можно использовать нейронные сети, специализированные на обработке естественного языка (Natural Language Processing, NLP), такие как RNN и трансформеры (Devlin, Chang, Lee et al., 2019). Эти модели способны анализировать текстовые данные (Kadhim, 2019), такие как, например, ответы студентов, эссе или отчеты, для оценки качества и содержания этих материалов.

Такая сеть может иметь следующую структуру (Схема 2):

1. Входной слой, который принимает текстовые данные студенческой работы (эссе, реферата, курсовой работы, контрольной работы и др.). Текст преобразуется в числовую форму через процесс токенизации и эмбединга. Такие процессы являются основой для построения NLP-сетей. В наиболее общем представлении под «токенизацией» текста в рамках нашего исследования будем понимать процесс разбиения любой студенческой письменной работы на небольшие элементы (токены), которые представляют собой отдельные слова, числа, символы или другие элементы, имеющие смысл в контексте данного текста, а под «эмбеддингом» – преобразование полученного текста в вектор, который сохраняет контекстную информацию и семантику исходного текста (Roy, Ghosh, 2021).

2. В качестве скрытого слоя может использоваться совокупность слоев-трансформеров, например слои внимания с многоголовыми механизмами (Multi-Head Attention Layers), которые позволяют модели сосредотачиваться на разных частях входной последовательности при преобразовании каждого слова в выходное представление, и полносвязные слои (Feed-Forward Networks), которые дополнительно обрабатывают информацию, передаваемую слоями внимания, и применяют одинаковые преобразования ко всем позициям в последовательности, но независимо друг от друга.

3. Выходной слой представляет собой классификатор, который выводит проверяющему итоговую оценку, основанную на анализе текста в виде классификации (например, оценка по шкале от 0 до 5 баллов, качество ответов (ППО – правильный полный ответ, ПНО – правильный неполный ответ, НО – неправильный ответ, ОН – ответа нет) или регрессия (например, числовая рейтинговая оценка от 0 до 100). Также результатами работы выходного слоя могут быть решение задачи определения субъективности текста (т. е. соотношение данного текста (например, эссе) с предыдущими работами конкретного студента с целью выявления субъективности суждений на основе стилистических, семантических, пунктуационных авторских особенностей) или выявление тональности текста (позитивного отношения студента к учебному материалу) с целью дальнейшей корректировки индивидуального образовательного маршрута.




Схема 2. Модель нейросети оценивания достижений обучающихся на основе обработки естественного языка (NLP)

Принцип работы нейросети следующий.

На этапе препроцессинга текстовые данные подготавливаются к обработке – они очищаются от лишних символов, проходят токенизацию путем разбиения на слова или фразы и преобразование в числовые векторы через эмбеддинг. Далее проходит процедура обучения нейросети, в ходе чего на вход нейросети подается большой набор текстов с известными оценками. Сеть учится выявлять паттерны и закономерности, которые коррелируют с оценками, и корректирует веса нейронов для минимизации ошибки между предсказанными и реальными оценками (Kangoo, Roy, 2023).

По окончании обучения проводится тестирование и валидация нейросети путем проверки эффективности модели на тестовом наборе данных, не участвовавших в обучении, и в случае успешного обучения модель может принимать новые тексты, анализировать их и выдавать оценку на основе изученных во время обучения закономерностей.

Тем самым построение моделей для автоматической оценки знаний основано на принципе конечной цели – достижении объективного и своевременного контроля успеваемости. Одновременно реализуется принцип вероятностных результатов, так как оценивание строится на вероятностных прогнозах качества студенческих работ.

2.3. Нейросетевой подход к прогнозированию успешности обучения

Одним из перспективных направлений является использование нейросетей для прогнозирования академической успешности студентов. Такая нейросеть путем проведения анализа данных об уже выполненных и оцененных работах студентов (результатах текущей успеваемости, письменных и устных работ и т. д.) может предсказывать их успеваемость в будущем. Это позволит своевременно выявлять обучающихся, которым требуется дополнительная поддержка, и предотвращать отставание в образовательном процессе путем назначения дополнительных занятий либо установления кураторства. Прогнозирование успеха обучения с помощью нейросетей включает анализ больших объемов данных об обучающихся (например, оценки за задания и экзамены, участие в дискуссиях на форумах, временные показатели доступа к учебным материалам, историю обучения и другие соответствующие данные) для выявления закономерностей и тенденций, которые могут указывать на будущую академическую успеваемость. Рассмотрим структуру, принципы работы и построение нейросети для такой задачи.

Структура данной нейросети представляет собой следующий вид (Схема 3):

1. Входной слой принимает различные виды данных об обучаемом, которые могут включать как числовые, так и категориальные данные (например, оценки, количество посещений учебных занятий, время, проведенное на платформе, результаты тестов, демографические данные и т. д.). Данные нормализуются или стандартизируются для эффективной обработки.

2. Скрытые слои представляют собой два и более полносвязных слоев (количество таких слоев подбирается на этапе обучения модели), где каждый узел связан с каждым узлом в следующем слое. Эти слои могут эффективно обрабатывать векторизованные входные данные о студентах. Также скрытый слой может включать специализированный регуляционный слой (**Dropout**), который используется для предотвращения переобучения путем случайного исключения некоторых узлов из модели во время обучения, что делает модель более обобщающей.

3. Выходной слой в зависимости от конкретной задачи оценивания включает активационную функцию, такую как сигмоид для задач бинарной классификации (например, при недифференцированной оценке за учебную дисциплину) или softmax для многоклассовой классификации (например, при дифференцированной оценке по 5-балльной шкале). Тем самым данный слой предсказывает целевую переменную, такую как оценка за экзамен, средний балл по семестру или вероятность успешного завершения обучения.




Схема 3. Модель нейросети прогнозирования успешности обучения

Принцип работы нейросети прогнозирования успешности обучения следующий.

На этапе обучения модель получает исторические данные о студентах, включая их прошлые оценки и другие показатели успеваемости. В качестве таких данных также могут быть оценки по предыдущим уровням обучения (например, по аттестатам о среднем (полном) общем образовании и результаты сдачи ЕГЭ). Целью обучения является настройка весов между нейронами таким образом, чтобы минимизировать разницу между предсказаниями модели и реальными результатами.

Далее на этапе валидации и тестирования модель проверяется на отдельном наборе данных (валидационном и тестовом) для оценки ее способности генерировать точные прогнозы на новых данных. Модель будет считаться обученной, если точность прогноза будет составлять остановленные значения (обычно, не менее 90%). Процесс обучения может включать несколько итераций обучения, валидации и тестирования с целью улучшения точности модели. В случае успешного обучения модель может быть использована для прогнозирования успеваемости текущих и будущих студентов на основе данных о результатах их текущей учебной деятельности. Развертывание модели в реальной образовательной среде подразумевает последующий мониторинг ее эффективности с возможными корректировками и улучшениями (дообучением).

Соответственно, нейросетевые модели прогнозирования успеваемости студентов базируются на принципе вероятностных результатов – предсказание строится с учетом статистической неопределенности и показателей точности модели. Также учитывается принцип развития, поскольку модели могут дообучаться на новых данных для повышения точности прогнозов.

2.4. Нейросетевой подход к построению индивидуальных образовательных траекторий

Разработка ИОТ с применением нейросетей открывает новые возможности для персонализации образовательного процесса. Нейронные сети могут анализировать предпочтения, цели и академическую историю студентов для формирования индивидуализированных учебных планов, способствующих максимальному развитию потенциала каждого обучающегося.

Такие системы способны адаптироваться к изменениям в процессе обучения и предлагать оптимальные пути развития с учетом индивидуальных особенностей каждого студента, а для их реализации можно использовать алгоритмы машинного обучения, в частности, методы кластеризации для группировки студентов по интересам и предпочтениям, и рекомендательные системы для предложения учебных дисциплин или курсов по выбору.

Такая сеть может иметь следующую структуру (Схема 4).




Схема 4. Модель нейросети для построения индивидуальных образовательных траекторий

1. Входной слой принимает векторизованные данные о студенте. Размер входного слоя зависит от количества различных признаков в конкретном наборе данных и зависит от количества различных признаков n (включая академическую историю (оценки по предметам, количество пересдач и т. д.); интересы и предпочтения в области обучения, полученные из опросов или анализа действий пользователя (например, выбор учебных модулей, факультативов), участие в студенческих объединениях, молодежных лабораториях и др.); психометрические данные, полученные с помощью специализированных тестов; данные о карьерных целях и профессиональных интересах; личные данные, включая стиль обучения и жизненные обстоятельства и др.). Принимаемые данные должны пройти предобработку (векторизацию в эмбеддинг-слое) и быть нормализованы.

2. Скрытые слои – это полносвязные слои (Dense layers), которые будут применяться для изучения сложных зависимостей между различными аспектами входных данных. Количество и размерность этих слоев зависят от сложности задачи и объема входных данных. Так, первый скрытый слой может содержать 64 нейрона с функцией активации ReLU (Rectified Linear Unit). Эта функция активации помогает решить проблему исчезающего градиента и обеспечивает нелинейность для обучения сложных зависимостей. Второй скрытый слой также может содержать 64 нейрона с функцией активации ReLU. Добавление нескольких слоев увеличивает «глубину» модели, позволяя ей изучать более сложные паттерны в данных. Также в качестве скрытых слоев могут применяться рекуррентные слои (LSTM, GRU) для анализа временных последовательностей, например изменения успеваемости студента с течением времени, а также слои внимания (Attention layers), которые помогают модели сфокусироваться на наиболее значимых аспектах данных при принятии решений о следующих шагах в образовательной траектории. Например, система может выявить, что для определенного студента более важны учебные дисциплины и модули, развивающие критическое мышление, чем запоминание фактов.

3. Выходной слой: в зависимости от количества спроектированных образовательных траекторий в рамках реализации конкретной основной образовательной программы может использоваться функция активации softmax для классификации дисциплин по приоритетам. В результате работы нейросети формируется предложение по индивидуальной образовательной траектории. В моделируемой нейросети в качестве вектора выходного слоя были значения, соответствующие перечню прогнозируемых дисциплин и модулей по выбору студента ($\bar{y}_i = \{ВД_1, ВД_2, ВД_3 \dots ВД_m\}$).

Принцип работы нейросети для построения индивидуальных образовательных траекторий следующий.

На начальном этапе собираются и обрабатываются данные (входные признаки), необходимые для обучения модели, и осуществляется их предобработка (преобразование категориальных признаков в числовой формат и нормализацию числовых данных) и векторизация.

Далее на основе характеристик данных выбирается подходящая архитектура нейросети (количество и тип скрытых слоев, а также их размерность). При этом важно учесть, какие типы данных будут использоваться и как они будут взаимодействовать в процессе обучения модели.

В ходе обучения модели осуществляется корректировка весов сети для минимизации ошибки между предсказанными и фактическими данными, после чего модель тестируется на отдельном наборе данных для оценки ее эффективности.

Обученная модель может быть внедрена в образовательную среду, где она будет использоваться для поддержки студентов в планировании их учебного процесса и корректировки индивидуальной образовательной траектории.

Тем самым формирование ИОТ с использованием нейросетей реализует принцип устойчивости (адаптивность к изменениям образовательных запросов студента) и принцип развития (постоянное совершенствование индивидуальных рекомендаций по мере накопления данных).

Соответственно, все разработанные модели строятся с учетом принципов нейросетевого подхода, что обеспечивает их адаптивность, устойчивость и способность работать в условиях динамично изменяющейся образовательной среды. В обобщенном виде принцип работы всех рассмотренных ИНС может быть представлен в виде блок-схемы (Схема 5).




Схема 5. Принципиальная блок-схема применения ИНС в образовательном процессе современного вуза

Заключение

Таким образом, в ходе исследования была концептуально обоснована сущность нейросетевого подхода как современной методологической основы построения образовательного процесса в вузе. Определены его ключевые принципы – системности, конечной цели, неопределенности, вероятностных результатов, развития и устойчивости, – которые легли в основу проектирования моделей применения искусственных нейронных сетей для решения типовых задач образования.

Особое значение имеет разработка моделей организации различных этапов образовательного процесса с применением ИНС, включая адаптивное обучение, оценивание достижений обучающихся, прогнозирование успешности и построение индивидуальных образовательных траекторий. Предложенные модели демонстрируют возможность практической реализации нейросетевого подхода для повышения эффективности, персонализации и адаптивности обучения в вузе.

Вместе с тем для успешной интеграции нейросетей в образовательный процесс необходимо решить ряд вызовов, включая вопросы этики, безопасности и обеспечения равного доступа к образовательным ресурсам. Таким образом, исследования и разработки в области применения нейросетей в образовании должны учитывать как технологические, так и социальные аспекты, стремясь к созданию эффективной системы обучения, адекватной индивидуальным образовательным потребностям студентов и требованиям федеральных государственных образовательных стандартов высшего образования.

Перспективы дальнейших исследований заключаются в разработке конкретных математических моделей предложенных решений, уточнении параметров обучения и оценке эффективности их программной реализации, а также состоят в глубокой эмпирической проверке разработанных нейросетевых моделей для повышения точности их работы и прогнозирования успеваемости, расширении набора данных за счет учета

когнитивных, мотивационных и социальных факторов, а также разработке адаптивных образовательных систем, автоматически подстраивающих учебный процесс под индивидуальные потребности студентов.

Источники | References

1. Абрамова С. В., Бояров Е. Н. Системно-структурный подход к построению содержания образования в области безопасности жизнедеятельности // *Фундаментальные проблемы образования в области безопасности жизнедеятельности: материалы научно-практической конференции* (г. Санкт-Петербург, 12-13 ноября 2019 г.). СПб.: Бук, 2019.
2. Бояров Е. Н. Применение адаптивного подхода в подготовке современного педагога в области безопасности жизнедеятельности // *Вестник Череповецкого государственного университета*. 2015. № 8 (69).
3. Васильева Е. Е., Курушин Д. С., Власов С. С. Раннее прогнозирование среднего балла диплома студентов университета: нейросетевой подход // *Международная конференция по мягким вычислениям и измерениям*. 2019. Т. 1.
4. Гриценко Е. М., Осавелюк П. А. Метод нейросетевого моделирования построения индивидуальных траекторий обучения // *Вестник Приамурского государственного университета им. Шолом-Алейхема*. 2013. № 1 (12).
5. Добровольская Н. Ю. Нейросетевые технологии при организации обучения бакалавров прикладной математики // *Актуальные проблемы обучения математике в школе и вузе: от науки к практике. К 80-летию со дня рождения В. А. Гусева: материалы VII Международной научно-практической конференции* (г. Москва, 18-19 ноября 2022 г.). М.: Московский педагогический государственный университет, 2022.
6. Зайцева Т. В., Игрунова С. В., Путивцева Н. П., Пусная О. П., Нестерова Е. В. Модель оценивания профессиональных компетенций на базе нейросетевого подхода // *Информационные технологии в науке и производстве: материалы IV Всероссийской молодежной научно-технической конференции* (г. Омск, 08-09 февраля 2017 г.). Омск: Омский государственный технический университет, 2017.
7. Agarwal B., Mittal N. Text Classification Using Machine Learning Methods-A Survey // *Proceedings of the Second International Conference on Soft Computing for Problem Solving (SocProS 2012)* (December 28-30, 2012). *Advances in IS and Computing*. 2014. Vol. 236. https://doi.org/10.1007/978-81-322-1602-5_75
8. Amazona M. V., Hernandez A. A. Modelling student performance using data mining techniques // *Proceedings of the 2019 5th International Conference on Computing and Data Engineering. ICCDE'19*. N. Y.: Association for Computing Machinery; 2019. <https://doi.org/10.1145/3330530.3330544>
9. Blanco J., Lovelle S., Fernandez R., Perez E. Predicción de resultados académicos de estudiantes de informática mediante el uso de redes neuronales // *Ingeniare. Revista chilena de ingeniería*. 2016. Vol. 24 (4). <https://doi.org/10.4067/S0718-33052016000400015>
10. Daud A., Aljohani N. R., Abbasi R. A., Lytras M. D., Abbas F., Alowibdi J. S. Predicting student performance using advanced learning analytics // *Proceedings of the 26th International Conference on World Wide Web Companion*. Republic and Canton of Geneva, CHE: International World Wide Web Conferences Steering Committee, 2017. <https://doi.org/10.1145/3041021.3054164>
11. Devasia T., Vinushree T. P., Hegde V. Prediction of students' performance using educational data mining // *2016 International Conference on Data Mining and Advanced Computing (SAPIENCE)*. Ernakulam: IEEE, 2016. <https://doi.org/10.1109/SAPIENCE.2016.7684167>
12. Devlin J., Chang M. W., Lee K., Toutanova K. BERT: pre-training of deep bidirectional transformers for language understanding // *NAACL-HLT*. Minneapolis, 2019.
13. Jayaprakash S., Krishnan S., Jaiganesh V. Predicting students academic performance using an improved random Forest classifier // *2020 International Conference on Emerging Smart Computing and Informatics (ESCI)*. Pune: IEEE, 2020. <https://doi.org/10.1109/ESCI48226.2020.9167547>
14. Kadhim A. I. Survey on supervised machine learning techniques for automatic text classification // *Artif Intell*. 2019. Vol. 52. <https://doi.org/10.1007/s10462-018-09677-1>
15. Kangoo N. A., Roy A. Supervised Machine Learning Text Classification: A Review // *Proceedings of International Conference on Paradigms of Communication, Computing and Data Analytics. PCCDA 2023. Algorithms for IS* / ed. by A. Yadav, S. J. Nanda, M. H. Lim. Singapore: Springer Nature Singapore, 2023. https://doi.org/10.1007/978-981-99-4626-6_53
16. Kumar V. U., Krishna A., Neelakanteswara P., Basha C. Z. Advanced prediction of performance of a student in an university using machine learning techniques // *2020 International Conference on Electronics and Sustainable Communication Systems (ICESC)*. Coimbatore: IEEE, 2020. <https://doi.org/10.1109/ICESC48915.2020.9155557>
17. Páez A., Guzmán D. Diseño de un modelo para automatizar la predicción del rendimiento académico en estudiantes del IPN // *Revista Iberoamericana para la Investigación y el Desarrollo Educativo*. 2018. № 8 (16). <https://doi.org/10.23913/ride.v8i16.340>
18. Prasad A., Kaur M., Kan M.-Y. Neural ParsCit: a deep learning-based reference string parser // *International Journal on Digital Libraries*. 2018. № 19. <https://doi.org/10.1007/s00799-018-0242-1>
19. Rincon-Flores E. G., López-Camacho E., Mena J., López O. O. Predicting academic performance with artificial intelligence (AI), a new tool for teachers and students // *2020 IEEE Global Engineering Education Conference (EDUCON)*. Porto: IEEE, 2020. <https://doi.org/10.1109/EDUCON45650.2020.9125141>

20. Roy A., Ghosh D. Pattern Recognition based Tasks and Achievements on Handwritten Bengali Character Recognition // 6th International Conference on Inventive Computation Technologies (ICICT). Coimbatore: IEEE, 2021. <https://doi.org/10.1109/ICICT50816.2021.9358783>
21. Widyarningsih Y., Fitriani N., Sarwinda D. A semi-supervised learning approach for predicting Student's performance: first-year students case study // 12th International Conference on Information & Communication Technology and System (ICTS). Surabaya: IEEE, 2019. <https://doi.org/10.1109/ICTS.2019.8850950>
22. Wu J., Rohatgi Sh., Keesara S. R. R., Chhay J., Kuo K., Menon A. M., Parsons S., Uргаonkar B., Lee Giles C. Building an Accessible, Usable, Scalable, and Sustainable Service for Scholarly Big Data // 2021 IEEE International Conference on Big Data (Big Data). Orlando: IEEE, 2021. <https://doi.org/10.1109/BigData52589.2021.9671612>
23. Zhang L., Sun B., Shu F., Huang Y. Comparing paper level classifications across different methods and systems: an investigation of Nature publications // Scientometrics. 2022. Vol. 127. <https://doi.org/10.1007/s11192-022-04352-3>

Информация об авторах | Author information

RU

Бояров Евгений Николаевич¹, д. пед. н., доц.
Абрамова Светлана Владимировна², д. пед. н., доц.
Купцова Олеся Витальевна³, к. техн. н.
Шитов Эльдар Николаевич⁴
Станкевич Петр Владимирович⁵, д. пед. н., проф.

^{1, 2, 3, 4} Сахалинский государственный университет, г. Южно-Сахалинск

⁵ Российский государственный педагогический университет им. А. И. Герцена, г. Санкт-Петербург

EN

Evgeniy Nikolaevich Boyarov¹, Dr
Svetlana Vladimirovna Abramova², Dr
Olesya Vital'evna Kuptsova³, PhD
Eldar Nikolaevich Shitov⁴
Petr Vladimirovich Stankevich⁵, Dr

^{1, 2, 3, 4} Sakhalin State University, Yuzhno-Sakhalinsk

⁵ Herzen State Pedagogical University of Russia, St. Petersburg

¹ E.Boyarov@mail.ru, ² abramova_sv@list.ru, ³ Korsuncevaolesy@gmail.com, ⁴ eldar.shitov@mail.ru,

⁵ p_v_stan@mail.ru

Информация о статье | About this article

Дата поступления рукописи (received): 06.03.2025; опубликовано online (published online): 16.05.2025.

Ключевые слова (keywords): нейросетевые технологии; прогнозирование успеваемости; адаптивное обучение; машинное обучение; нейросетевой подход; neural network technologies; performance prediction; adaptive learning; machine learning; neural network approach.