

DOI: 10.51790/2712-9942-2021-2-4-5

ОБ ОПЫТЕ ПОСТРОЕНИЯ АПРИОРНОЙ ОЦЕНКИ УСПЕВАЕМОСТИ СТУДЕНТОВ В СИСТЕМЕ МИРЕРА С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

А. Г. Леонов^{1,2,3,4,a}, М. А. Матюшин^{4,b}, М. С. Дьяченко^{3,6}

¹ Государственный университет управления, г. Москва, Российская Федерация

² Московский педагогический государственный университет, г. Москва, Российская Федерация

³ Федеральное государственное учреждение «Федеральный научный центр Научно-исследовательский институт системных исследований Российской академии наук», г. Москва, Российская Федерация

⁴ Московский государственный университет имени М. В. Ломоносова, г. Москва, Российская Федерация

^a ORCID: <http://orcid.org/0000-0001-9622-1526>, dr.l@vip.niisi.ru

^b ORCID: <http://orcid.org/0000-0003-1775-6894>, itsaprank@yandex.ru

⁶ ORCID: <http://orcid.org/0000-0002-5809-4981>, mdyachenko@niisi.ru

Аннотация: в статье рассматривается опыт авторов по построению априорной оценки финальных результатов успеваемости студентов в цифровой образовательной платформе Мирера. Оценка строится по результатам промежуточной проверки успеваемости, полученным из промежуточных проверок на семинарах, при выполнении домашних заданий и проверочных работ. При этом учитываются как непосредственные результаты проверок, так и поведение студента при их выполнении. В предлагаемом подходе студенты условно разделены на три категории: отстающие студенты с неудовлетворительным финальным результатом, удовлетворительно успевающие студенты со средним результатом и студенты с высоким результатом. Для каждой категории студентов можно определить характер и целесообразность автоматизации корректирующих действий преподавателя для «подтягивания» отстающих. Оценка строится с использованием искусственных нейронных сетей. Полученная априорная оценка может быть использована для раннего обнаружения студентов, которые могут быть отчислены за неуспеваемость и которым необходима помощь преподавателя, а также для построения адаптивных треков обучения средне и хорошо успевающих студентов. Предлагаемый подход может быть применен только при условии цифровой трансформации учебного процесса.

Ключевые слова: Мирера, нейронные сети, цифровая образовательная платформа, автоматическая оценка успеваемости, предсказание отчисления студентов, адаптивное обучение.

Благодарности: исследование было выполнено при поддержке гранта РФФИ 19-29-14057.

Для цитирования: Леонов А. Г., Матюшин М. А., Дьяченко М. С. Об опыте построения априорной оценки успеваемости студентов в системе Мирера с использованием нейронных сетей. *Успехи кибернетики*. 2021;2(4):49–59. DOI: 10.51790/2712-9942-2021-2-4-5.

A NEURAL NETWORK-BASED APPROACH TO A PRIORI ASSESSMENT OF THE STUDENT ACADEMIC PERFORMANCE IN THE MIRERA DIGITAL LEARNING PLATFORM

A. G. Leonov^{1,2,3,4,a}, M. A. Matyushin^{4,b}, M. S. Dyachenko^{3,c}

¹ State University of Management, Moscow, Russian Federation

² Moscow Pedagogical State University, Moscow, Russian Federation

³ Federal State Institution “Scientific Research Institute for System Analysis of the Russian Academy of Sciences”, Moscow, Russian Federation

⁴ Lomonosov Moscow State University, Moscow, Russian Federation

^a ORCID: <http://orcid.org/0000-0001-9622-1526>, dr.l@vip.niisi.ru

^b ORCID: <http://orcid.org/0000-0003-1775-6894>, itsaprank@yandex.ru

^c ORCID: <http://orcid.org/0000-0002-5809-4981>, mdyachenko@niisi.ru

Abstract: the paper presents our approach to an a priori assessment of the final student performance in the Mirera digital learning platform. The assessment is based on interim tests at seminars, homework evaluations, and individual tests. In this case, both the test results and the student behavior during the

tests are considered. In the proposed approach, students are conditionally divided into three categories: underperforming students with unsatisfactory final results, satisfactory performing students with average results, and high performing students. For each category, the type and feasibility of automating the teacher's corrective actions to improve the student's final scores can be identified. The score is generated using artificial neural networks. The a priori estimate can be used for early detection of underperforming students who need help, as well as for building adaptive learning tracks for average and high performing students. The proposed approach can be applied only to digitally transformed academic process. The authors are implementing adaptive learning technologies in the Mirera digital learning platform.

Keywords: Mirera, neural networks, digital learning platform, outcomes estimate, drop-out rate prediction, adaptive learning.

Acknowledgements: the research is supported by the RFBR grant 19-29-14057.

Cite this article: Leonov A. G., Matyushin M. A., Dyachenko M. S. A Neural Network-Based Approach to A Priori Assessment of the Student Academic Performance in the Mirera Digital Learning Platform. *Russian Journal of Cybernetics*. 2021;2(4):49–59. DOI: 10.51790/2712-9942-2021-2-4-5.

Введение

В период пандемии, вызванной COVID-19 в 2020-2021 годах, система образования перешла к обучению преимущественно в дистанционной форме. При этом подходы к преподаванию в аудитории не могут быть без изменений перенесены в режимы видеоконференций даже при использовании двусторонней видеосвязи. Находясь в аудитории вместе со слушателями, преподаватель может оценить уровень вовлеченности студентов и проверить, насколько им понятен излагаемый материал. Опытный преподаватель может определить, каким студентам требуется помощь, а какие смогут без дополнительной поддержки, самостоятельно освоить изучаемый предмет. При своевременном обнаружении отстающих студентов у педагога есть возможность «подтянуть» студента к уровню группы, тем самым снизив риск его отчисления из-за неуспеваемости по предмету, которая фиксируется, как правило, на этапе прохождения итогового испытания. В условиях дистанционных и смешанных форм обучения также необходимы методы раннего определения отстающих студентов для предотвращения их отчисления.

Проблема предсказания отчисления студентов известна и исследовалась в рамках массовых открытых онлайн-курсов и учебных платформ [1, 2]. Основными отличиями предложенного исследования от ранее проводимых является прогнозирование ожидаемого результата студента, а не вероятности его отчисления (хотя эти оценки связаны), также авторы строят оценку на основе использования промежуточных результатов проверки знаний, а не только основываясь на индивидуальных особенностях студентов [3].

В рассмотренном подходе информация о результатах промежуточной оценки знаний определялась по данным о выполнении студентами домашних заданий, классных работ и промежуточных проверок, что стало возможным благодаря цифровой трансформации тем курса и переноса заданий на цифровую образовательную платформу с использованием автоматизированной системы верификации результатов.

В статье рассматривается подход к априорной оценке успеваемости студентов с использованием искусственных нейронных сетей.

Методология

Главная цель данной работы заключается в исследовании способов предсказания вероятности для студента получить определенную оценку по результатам завершения курса с опорой на информацию о текущем прохождении им курса. Другими словами, стоит задача предсказать вероятность принадлежности студента к одному из следующих трех классов:

1) отстающие студенты. Этот класс состоит из студентов, финальный результат которых по окончании курса неудовлетворительный. Для того чтобы успешно продолжать обучение, таким студентам необходима очень серьезная помощь преподавателя;

2) удовлетворительно успевающие студенты. Этот класс состоит из студентов, средне проходящих курс со средними результатами. Скорее всего, такие студенты по итогам курса получают оценку выше неудовлетворительно, при умеренной поддержке со стороны преподавателя. Следовательно, данный класс должен находиться в главном фокусе внимания преподавателя;

3) студенты с высокими результатами. Студенты этого класса обычно превосходят остальных в скорости и качестве освоения учебного материала. Скорее всего, по окончании курса они получат наивысший балл даже при отсутствии какой-либо поддержки со стороны педагога.

В ходе работы исследовалась следующая иерархическая структура учебного курса (рис. 1).

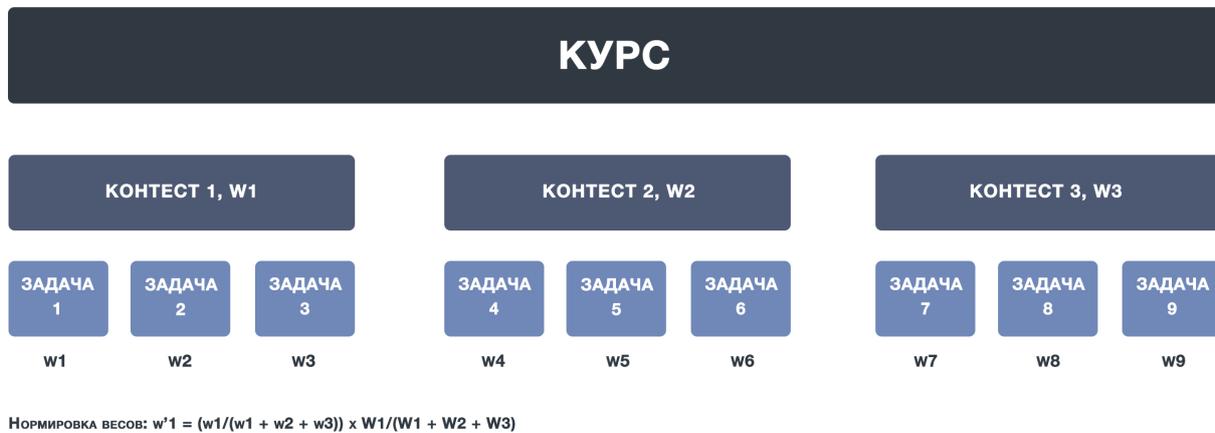


Рис. 1. Иерархическая структура оценок курса

Курс здесь состоит из множества контекстов, каждый из которых, в свою очередь, составлен из одной или нескольких задач. Каждому контексту присвоен некоторый вес W , отражающий вклад контекста в курс. В свою очередь, каждой задаче также присвоен некоторый вес, отражающий вклад задачи в контекст. В целях получения общего результата была применена нормировка весов, при этом использовалась запечатленная на рис. 1 формула. Нормированные веса в сумме дают 1 и отражают важность задачи в рамках всего курса.

В процессе обучения студент последовательно совершает попытки сдать задачу в рамках какого-либо контекста. По окончании курса все нормированные веса для всех сданных задач суммируются и предоставляются преподавателю. Педагог выставляет окончательную оценку студенту, опираясь, в основном, на вышеупомянутую сумму весов (финальный балл). Следовательно, для решения задачи классификации студентов фактически необходимо предсказать их финальные баллы на момент окончания курса. Для окончательной классификации студента по финальному баллу предлагается использовать два вручную подобранных порога, разделяющих классы.

В рамках исследования в качестве входных данных использовались данные о попытках сдачи задач. Для каждой попытки сдачи имеется следующая информация:

1. Временная отметка попытки сдачи.
2. Статус попытки (пройдено, не пройдено, ошибка, плагиат и т. д.).
3. Тип задачи (обычная, легкая, сложная и т. д.).

Дополнительно для каждой попытки сдачи в качестве признака используется суммарный балл, набранный на момент попытки. Также можно посчитать и другие показатели статистики, полезные при предсказании финального балла студента.

Вышеизложенное можно изобразить схематически, как представлено на рис. 2.

Как отражено на рисунке выше, для предсказания финального балла студента использовался определенный набор вручную подобранных статистик. После того, как предсказан финальный балл, путем сравнения полученного значения с пороговыми принимается решение о принадлежности студента к одному из трех вышеперечисленных классов. Однако это не единственный путь решения задачи. Что хуже, данный способ не оптимизирует напрямую целевую метрику качества классификации студентов. Для переформулировки задачи можно сначала применить подобранные пороги к историческим данным, что порождает разбиение студентов на три класса. Затем можно построить статистическую модель, способную напрямую предсказывать класс студента, минуя промежуточную процедуру предсказания финального балла. В рамках данной работы были проверены оба вышеописанных подхода, было произведено сравнение их качества на тестовой выборке студентов.

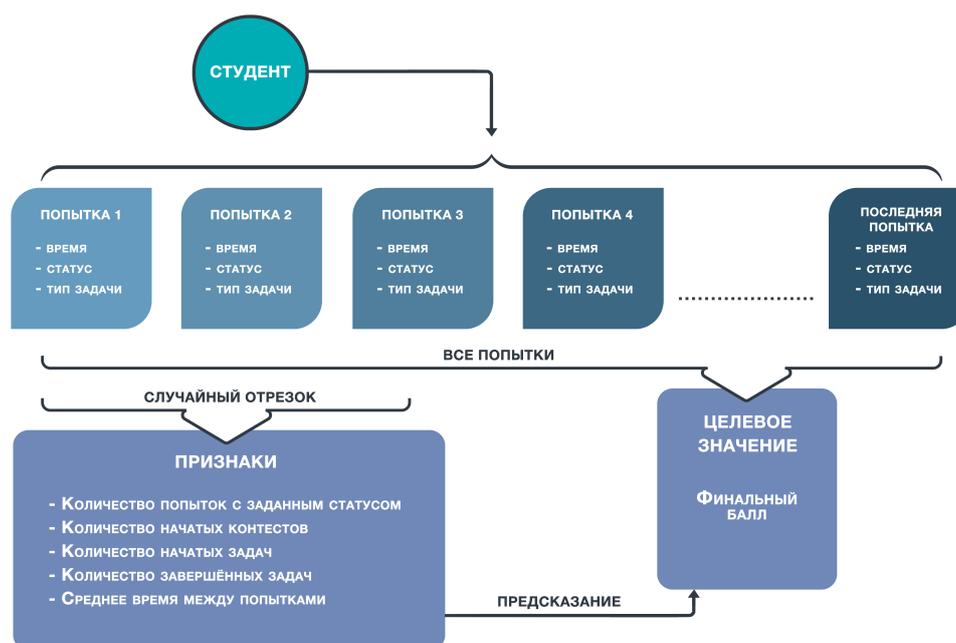


Рис. 2. Структура данных о попытке сдачи

Обсуждение

В рамках экспериментов исследовалась схема устройства данных, представленная в предыдущем разделе на рис. 2. Исторические данные состояли из 3206 пар студент-курс. Каждая такая пара была представлена последовательностью попыток сдачи задач данным студентом в рамках данного курса. Гистограмму логарифма длин этих последовательностей см. на рис. 3.

Как можно видеть, по окончании курса большинство студентов предприняло 20–150 попыток сдачи. Значительной доле студентов, 7,8 %, однако, потребовалось от 200 до 2200 попыток. С целью повысить устойчивость решения в рамках исследования использовались только признаки, не зависящие от общего числа попыток, предпринятых студентом.

Следуя алгоритму, описанному в секции методологии, проиллюстрируем распределение финального балла студентов на гистограмме на рис. 4.

Пороговые значения финального балла, показанные на рис. 4, были предоставлены тремя опытными практикующими преподавателями. Пропорции классов студентов в соответствии с данными порогами продемонстрированы на рис. 5.

Каждая попытка сдачи в рамках исследования содержит следующую информацию (признаки):

1. Время попытки.
2. Статус попытки, один из: пройдено, не пройдено, ошибка.
3. Тип задачи, один из: обычный, необязательный, экзамен.
4. Нормированный вес задачи.

На основании описанных данных были сгенерированы тренировочные и валидационные выборки. Экземпляр выборки представляется следующим образом. Сначала выбирается случайный начальный отрезок последовательности попыток. Затем осуществляется подсчет следующих статистик:

1. Количество попыток с заданным статусом для каждого из типов задач.
2. Количество начатых контекстов.
3. Количество начатых задач (по которым имеется хотя бы одна попытка сдачи).
4. Количество сданных задач.
5. Среднее время между последовательными попытками в рамках одной и той же задачи для каждого типа задач.
6. Набранный на момент попытки балл.

Статистики вида (1) были впоследствии нормированы на общую длину последовательности

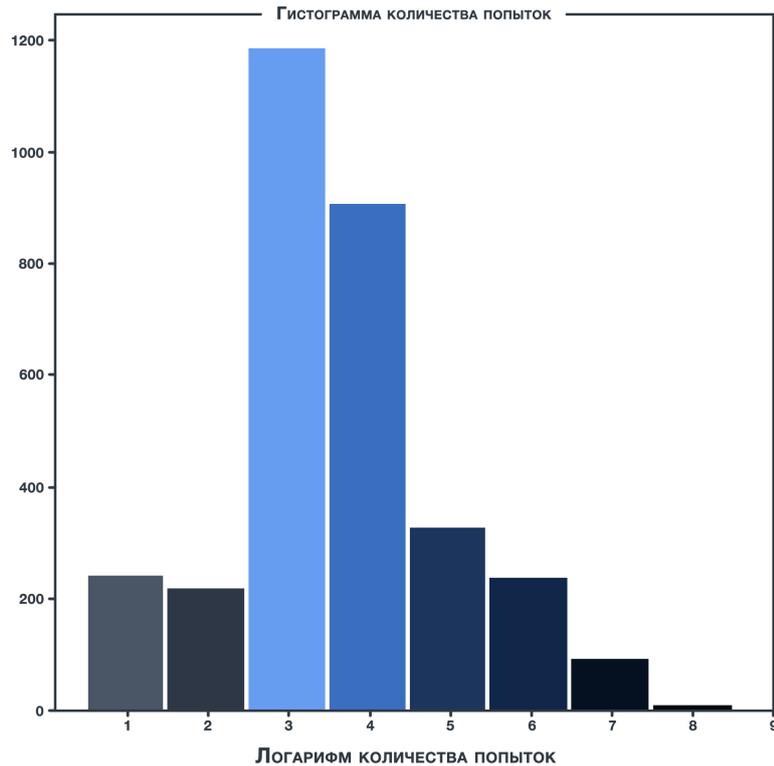


Рис. 3. Гистограмма логарифма длин последовательностей попыток сдачи

попыток, статистики вида (2), (3) и (4) также были нормированы соответствующим образом. По статистикам вида (5) были сгенерированы one-hot признаки по гистограммам с 30 равномерными столбцами от 0 до 150000 секунд. Все полученные статистики затем были сконкатенированы в единый вектор признаков размерности 106.

Для предсказания вероятности выпадения студента была использована нейросетевая модель. Основа архитектуры представлена на рис. 6.

Пунктирной рамкой обозначен последовательно повторяющийся блок, количество повторов блока регулирует глубину нейронной сети. В архитектуре используется батч-нормализация [4], а также скип-коннекшн [5] в каждом скрытом слое для облегчения распространения градиентов и повышения скорости тренировки сети.

В рамках работы были исследованы два основных подхода к решению задачи предсказания вероятности попадания студента в одну из категорий и последующего отчисления. В первом подходе, когда предсказывается одно значение финального балла студента, к основе архитектуры нейронной сети был добавлен линейный слой, переводящий вектор скрытых состояний в пространство размерности 1. К результату этого слоя затем применяется функция сигмоида. Для тренировки такой сети использовался стандартный MSE лосс. Для теста окончательной модели были отобраны 30 % случайно выбранных студентов.

Во втором подходе, когда предсказываются 3 вероятности, по 1 для каждого класса студентов, к основе нейронной сети был добавлен линейный слой, переводящий вектор скрытых состояний в вектор размерности 3. Следом за данным слоем был добавлен слой активации Softmax. Для тренировки этой сети использовался логарифмический лосс. Тестовый набор данных совпадал с таковым для первого подхода.

Для каждого из описанных подходов было проведено несколько экспериментов с различными глубинами основы нейросети с целью определить оптимальную сложность модели. Критерий остановки тренировочного процесса представлен плато-детектором, то есть тренировка прекращается, если 5 эпох подряд не показывали прироста результатов на валидационной выборке. Результаты экспериментов приведены в таблице.

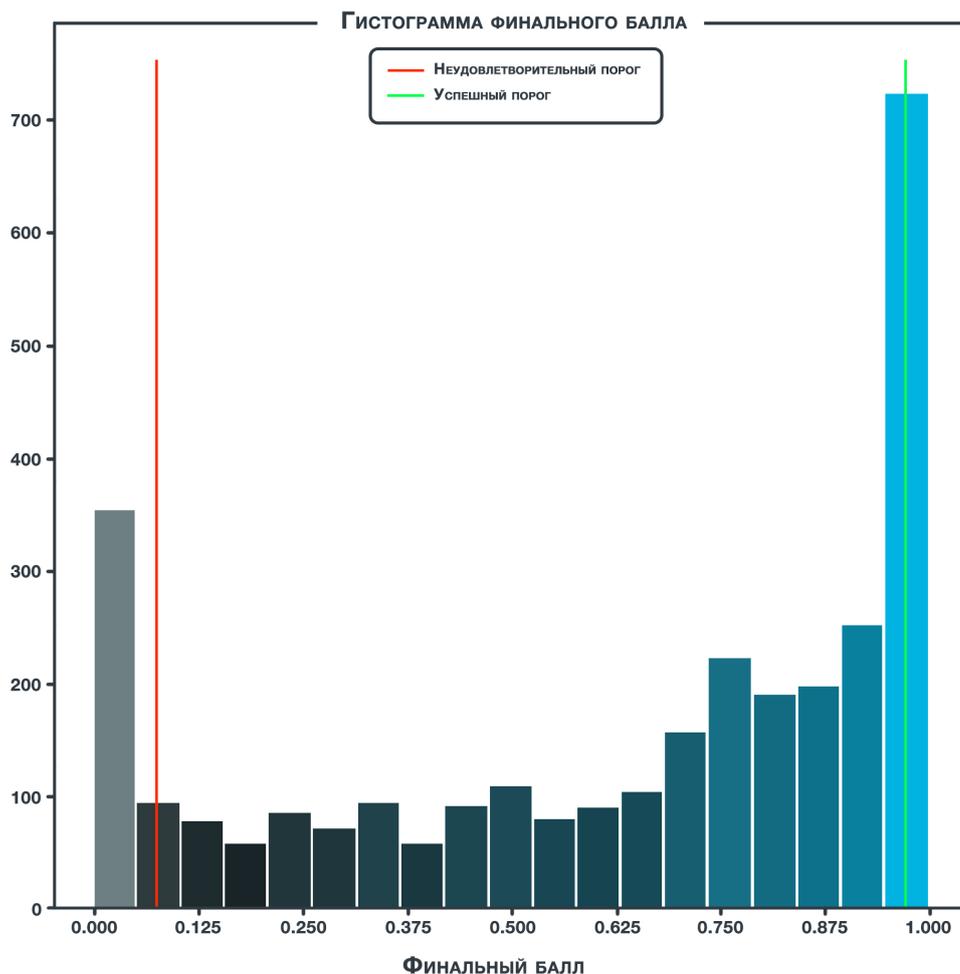


Рис. 4. Распределение финального балла студента

Таблица

Результаты экспериментов для разных подходов и разных глубин

Глубина	Остановка после эпохи №	Лосс на валидации	Точность	Полнота	F1 score
Первый подход, предсказание финального балла					
1	26	0.0462	0.7187	0.7149	0.6636
2	13	0.0500	0.7141	0.6853	0.6047
3	20	0.0447	0.7603	0.6589	0.5450
Второй подход, предсказание класса студента					
1	42	0.5599	0.7617	0.7554	0.7362
2	36	0.5030	0.7702	0.7674	0.7467
3	25	0.5495	0.7466	0.7438	0.7436

Дополнительно для лучшей модели, а именно для двуслойной модели классификации, были построены по тестовому множеству студентов графики средней ошибки (рис. 7).

Отчетливые линии на рисунке выше отражают «опасные» ошибки. К ним относятся: общая ошибка, ошибка 3–1, ошибка 2–3, ошибка 1–3. Первая цифра в обозначении ошибки отвечает за истинный класс студента, вторая — за предсказанный класс. Для случая ошибок 3–1, однако, не представлено соответствующей кривой ввиду отсутствия прецедентов. Как можно видеть, при прохождении студентом курса на 20 % предложенное решение уже будет иметь среднюю долю ошибок 0.26. Вероятность

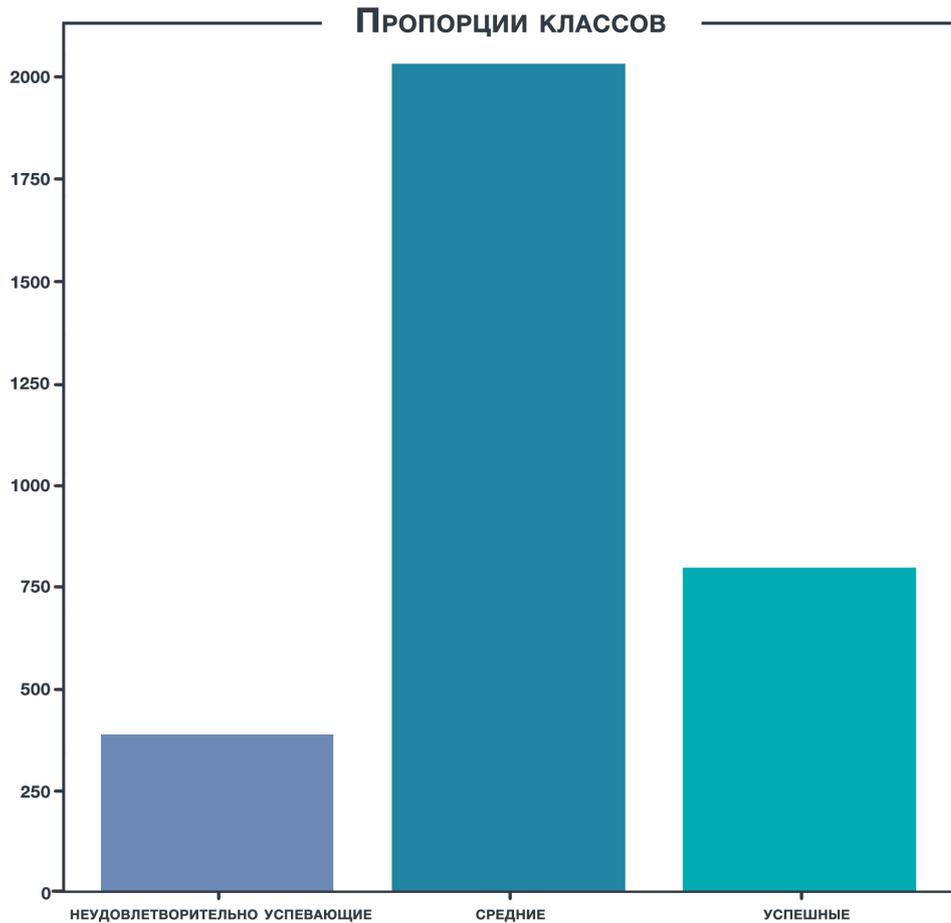


Рис. 5. Пропорции классов студентов

ошибочно предположить, что средний студент является успешным студентом, ни в какой момент прохождения курса не превосходит 0.21. Однако в определенный момент предложенное решение имеет вероятность ошибочно предсказать, что неуспевающий студент является успешным студентом с весьма высокой вероятностью, оцениваемой в 0.37.

Тусклые линии на рисунке выше отражают безопасные ошибки. Можно обратить внимание на быстро убывающую ошибку 2–1. Также можно обратить внимание на медленно убывающую кривую ошибки 3–2, что показывает, что почти половина всех успешных студентов будет ошибочно классифицирована как удовлетворительные. Также можно заметить практически постоянную на протяжении прохождения курса ошибку 1–2, что означает, что в любой момент около 80 % всех неуспевающих студентов будут классифицироваться как средние.

Для улучшения полученных результатов существуют несколько возможных путей. Во-первых, можно использовать временную составляющую описанных данных, утилизируя рекуррентные LSTM-модели, или авторегрессионные модели на основе трансформеров [6], показывающие значительное превосходство над иными методами анализа последовательностей. Во-вторых, в случае наличия дополнительных данных о взаимодействии студента с системой, таких как, например, логи чат-ботов, они также могут быть с успехом использованы для предсказания вероятности выпадения студента.

Результаты

Результаты экспериментов показывают, что подход может быть использован для оценки будущей успешности студента на основании предварительных результатов прохождения курса. Однако качество предсказания пока находится на среднем уровне.

Проведенные в работе проверки подтверждают гипотезу, что студенты могут быть разделены

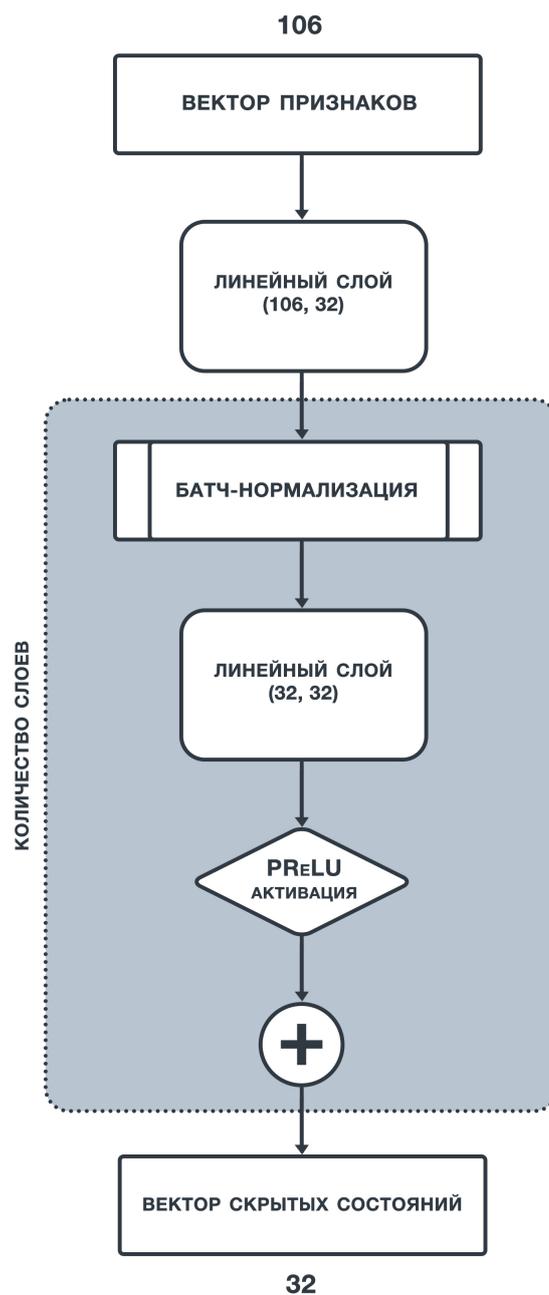


Рис. 6. Основа архитектуры нейронной сети

на три класса в зависимости от успешности прохождения ими курса. При этом способ классификации студентов определяется возможными действиями, которые может предпринять преподаватель, чтобы помочь студенту успешно завершить курс.

Первая категория — категория неуспевающих студентов — требует наибольших усилий преподавателя. Студенты этой категории самостоятельно не в состоянии освоить программу на удовлетворительном уровне. Возможная причина данного явления заключается в том, что эти студенты не обладают навыками самообразования. В этом случае для того, чтобы студент пришел к среднему уровню в процессе освоения курса, недостаточно просто излагать материалы курса. Преподаватель также должен развивать в студенте недостающие навыки самообразования.

Студенты второй категории зачастую достигают удовлетворительных результатов, просто систематически выполняя в срок стандартные задачи курса. Чтобы улучшить результаты студентов данной категории, от преподавателя может потребоваться назначение специальных задач повышенной сложности или назначение повторов уже пройденного материала для его закрепления. Подобный прием помо-

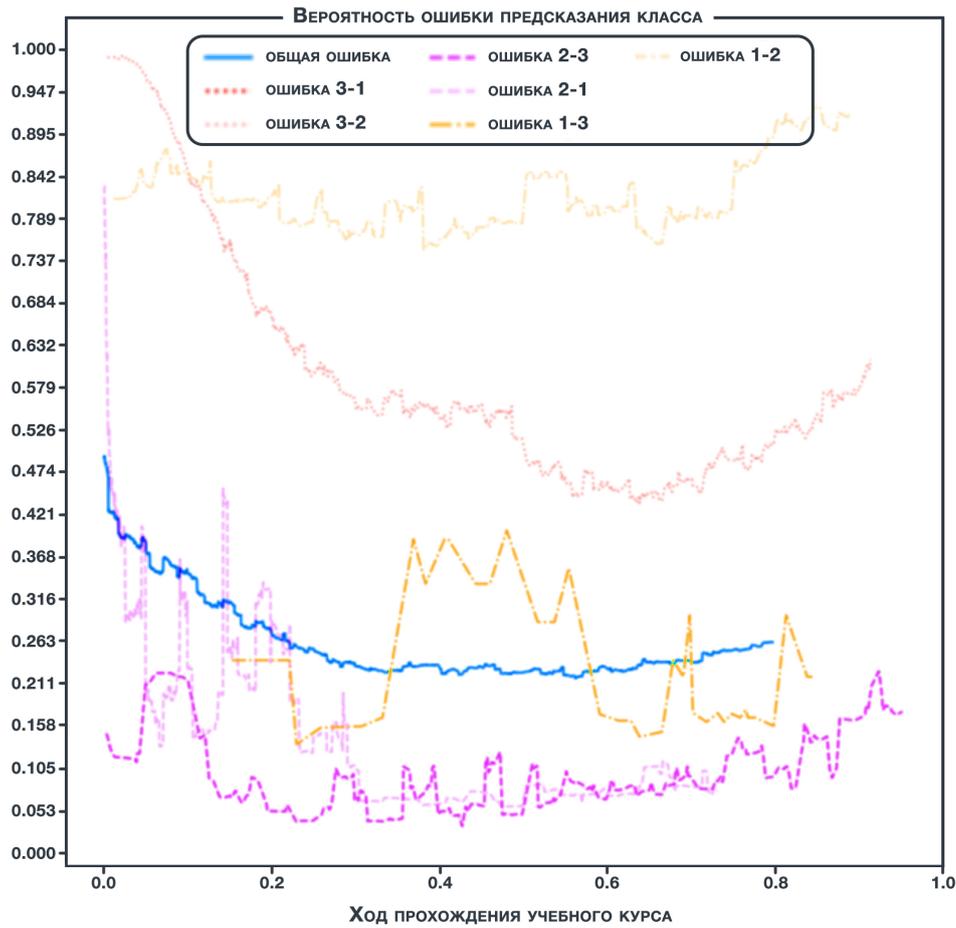


Рис. 7. Вероятности ошибок лучшей модели на тестовой выборке

гает повысить уровень компетенции студента, одновременно закрепляя усвоенные базовые знания.

Третью категорию составляют студенты, достигающие лучших результатов безо всякой помощи извне. Опираясь на проведенное в рамках данной работы исследование, можно констатировать, что студенты этой категории нуждаются в задачах повышенной сложности. Это позволяет развить компетенции студентов до того уровня, на котором они будут в состоянии решать реальные практические задачи. Студенты этой категории, как правило, обладают серьезными способностями в области самообразования.

В качестве платформы для проведения экспериментов была выбрана цифровая образовательная платформа Мирера. Данный выбор продиктован тем, что Мирера поддерживает полностью дистанционный формат обучения, а также предоставляет широкий спектр анонимизированных поведенческих данных. Платформа была специально сконструирована для удобства сбора и дальнейшего анализа данных об образовательном процессе. Ключевой особенностью платформы является простая интеграция методов машинного обучения и нейронных сетей. Благодаря масштабируемой архитектуре Миреры разработанные модели могут быть легко интегрированы для дальнейшего использования преподавателями — основными пользователями платформы.

Основное ограничение описанного подхода заключается в том, что преподавателю необходимо проверить большое количество заданий, выполняемых студентами, включая семинары, домашние задания, проверочные работы. Для того чтобы сократить влияние этого фактора, Мирера предоставляет фреймворк, например, классической автоматической оценки задач по программированию. В дополнение к этому платформа дает инструменты автоматизированной оценки для менее стандартных задач, например, для задач с использованием графики [7].

Иная проблема оценки успешности студента заключается в необходимости проверки решения

на плагиат. Данная сложность возникает в ситуациях, когда несколько студентов решают идентичные или похожие друг на друга задачи. Проблема может быть решена разными методами. Во-первых, для каждого студента может быть сгенерировано индивидуальное задание. Во-вторых, решение студента можно отвергать, если оно не проходит проверку на плагиат. Проблема плагиата также может быть решена встроенными средствами платформы Мирера для широкого спектра задач [7].

В дополнение к вышеперечисленному платформа Мирера располагает еще одним возможным источником полезных для оценки успешности студента данных. Речь идет о встроенном в платформу чат-боте [8], который не только помогает преподавателю поддерживать учебный процесс, но также самостоятельно автоматически отвечает на стандартные вопросы студентов второй категории. Чат-бот сохраняет информацию о запросах студентов, последняя, являясь поведенческой информацией, также может быть использована для улучшения качества оценки успешности студента. Однако в проведенном исследовании этот источник данных не использовался.

Результаты исследований были устно доложены авторами на Международной научно-практической конференции «Smart Nations: глобальные тенденции цифровой экономики» 2021.

Заключение

Возможность определить для каждой рассмотренной выше категории студентов вероятные действия преподавателя, по сути, является первым шагом к автоматизации учебного процесса. Зная категорию студента, можно установить и целесообразность автоматизации действий преподавателя.

Например, автоматизировать действия преподавателя для помощи студентам из первой категории сложно, что, в свою очередь, связано с необходимостью развития таких навыков, как способность к самообучению, и восполнения пробелов в широком спектре областей знаний. Автоматизировать действия преподавателя для помощи студентам третьей категории можно реализацией простой эвристики, предполагающей повышение сложности задания для студентов, которые успешно и быстро справляются с обычными заданиями.

Таким образом, с точки зрения потенциала для автоматизации, вторая категория студентов — студенты, нуждающиеся в помощи преподавателя, — выглядит наиболее многообещающей. Фактически речь идет о применении технологий адаптивного обучения, но не на всем множестве студентов, а только на том их подмножестве (отнесенном ко второй категории), которое будет восприимчиво к применяемым педагогическим приемам. Автоматизация предполагает появление в учебном процессе «виртуального ассистента преподавателя», который может учитывать особенности каждого студента и в зависимости от характера возникающих у него проблем выполнять корректирующие действия, например, предлагать повтор материала, который не был полностью усвоен или требует повторения для закрепления [9, 10].

В заключение заметим, что рассмотренный подход может быть применен в том числе для дополнения учебного процесса в аудитории за счет применения в учебном процессе автоматизированной проверки знаний.

ЛИТЕРАТУРА

1. Borrella I., Caballero-Caballero S., Ponce-Cueto E. Predict and Intervene: Addressing the Dropout Problem in a MOOC-based Program. *Proceedings of the Sixth (2019) ACM Conference on Learning @ Scale (L@S '19)*. Association for Computing Machinery, New York, NY, USA. 2019. Article 24, 1–9. DOI: <https://doi.org/10.1145/3330430.3333634>.
2. Jing Chen, Jun Feng, Xia Sun, Nannan Wu, Zhengzheng Yang, Sushing Chen. MOOC Dropout Prediction Using a Hybrid Algorithm Based on Decision Tree and Extreme Learning Machine. *Mathematical Problems in Engineering*. Vol. 2019, Article ID 8404653, 11 pages, 2019. DOI: <https://doi.org/10.1155/2019/8404653>.
3. Oancea B., Dragoescu R., Ciucu S. Predicting Students' Results in Higher Education Using Neural Networks. *International Conference on Applied Information and Communication Technologies (AICT2013)*, 25.–26. April, 2013, Jelgava, Latvia.
4. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training By Reducing Internal Covariate Shift. 2015. ArXiv abs/1502.03167.

5. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition. 2015. ArXiv abs/1512.03385.
6. Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin. Attention Is All You Need. 2017. ArXiv abs/1706.03762.
7. Леонов А. Г., Дьяченко М. С., Бесшапошников Н. О., Орловский А. Э., Матюшин М. А. Использование элементов искусственного интеллекта в современных цифровых образовательных платформах. *Информатизация образования и методика электронного образования: материалы IV Международной научной конференции*. В 2 ч. Ч. 2. 2020:36–41. ISBN 978-5-7638-4399-6.
8. Леонов А. Г., Дьяченко М. С., Мащенко К. А., Бесшапошников Н. О. Проблемы применения чат-ботов в естественно-научных курсах. *Информатизация образования и методика электронного образования: материалы IV Международной научной конференции*. В 2 ч. Ч. 1. 2020:393–396. ISBN 978-5-7638-4398-9.
9. Brusilovsky P., Peylo C. Adaptive and Intelligent Web-Based Educational Systems. *International Journal of Artificial Intelligence in Education*. 2003;13:159–172.
10. Alkhatlan A., Kalita J. Intelligent Tutoring Systems: A Comprehensive Historical Survey with Recent Developments. *International Journal of Computer Applications*. 2019;181(43). DOI: 10.5120/ijca2019918451/