

DOI: 10.32517/0234-0453-2023-38-3-31-41

ПРОГНОЗИРОВАНИЕ УСПЕШНОСТИ ОБУЧЕНИЯ ПО ДИСЦИПЛИНЕ НА ОСНОВЕ УНИВЕРСАЛЬНЫХ ПОКАЗАТЕЛЕЙ ЦИФРОВОГО СЛЕДА LMS MOODLE

Р. В. Есин¹, Т. А. Кустицкая¹ ✉, М. В. Носков¹¹ Сибирский федеральный университет, г. Красноярск, Россия

✉ tkustitskaya@sfu-kras.ru

Аннотация

Одной из важных задач учебной аналитики является прогнозирование сохранности состава обучающихся. В международном пространстве решению этой задачи в системе высшего образования посвящено множество исследований, имеется положительный опыт внедрения сервисов поддержки успешности обучения в вузах. Анализ литературы показывает повышение интереса к этой задаче у российского научно-педагогического сообщества. При этом специфика российского образования не дает возможности прямого переноса зарубежного опыта в отечественную образовательную систему.

В исследовании было выявлено, что значительный вклад в прогнозирование сохранности численности обучающихся могут внести модели прогнозирования успеваемости по отдельным предметам учебного плана. Авторами предложена структурная модель системы прогнозирования успеваемости по дисциплине, которая включает в себя универсальную модель на основе обобщенных показателей цифрового следа, предметную модель, учитывающую особенности обучения по конкретной дисциплине, и модель на основе образовательного профиля обучающегося.

В ходе эмпирического исследования по универсальным показателям цифрового следа студентов из LMS Moodle было обучено несколько моделей раннего прогнозирования успешности промежуточной аттестации и проведен анализ их качества. Наиболее точной моделью, особенно в первой половине семестра, оказался ансамбль-усреднение моделей логистической регрессии, случайного леса и градиентного бустинга. Был сделан вывод об эффективности универсальных моделей для раннего выявления студентов с проблемами в обучении по дисциплине, определены направления дальнейшего совершенствования универсальной модели прогнозирования успеваемости и сформулированы условия для масштабирования предложенного подхода по созданию системы прогнозирования успешности обучения другими образовательными учреждениями.

Ключевые слова: учебная аналитика, анализ образовательных данных, сохранность контингента студентов, успешность обучения, цифровой след, LMS Moodle, прогнозирование успеваемости, машинное обучение, ансамбль моделей.

Для цитирования:

Есин Р. В., Кустицкая Т. А., Носков М. В. Прогнозирование успешности обучения по дисциплине на основе универсальных показателей цифрового следа LMS Moodle. *Информатика и образование*. 2023;38(3):31–41. DOI: 10.32517/0234-0453-2023-38-3-31-41

PREDICTING ACADEMIC PERFORMANCE IN A COURSE BY UNIVERSAL FEATURES OF LMS MOODLE DIGITAL FOOTPRINT

R. V. Esin¹, T. A. Kustitskaya¹ ✉, M. V. Noskov¹¹ Siberian Federal University, Krasnoyarsk, Russia

✉ tkustitskaya@sfu-kras.ru

Abstract

Student retention prediction is one of the most important problems of learning analytics. In the global scope research on the topic for higher education is rather extensive, there are cases of successful implementation of education support services in universities. The literature analysis shows of the growing interest in this problem in the Russian scientific and pedagogical community. At the same time, the specifics of Russian education does not allow direct transfer of foreign experience into the domestic educational system.

The study reveals that a significant contribution to predicting student retention can be made by models for predicting academic performance in educational courses of the curriculum. The authors propose a structural model of a system for predicting academic performance, which includes a universal model based on generalized indicators of the digital footprint, a course-based model that takes into account the specifics of learning in a particular discipline, and a model based on the student's educational profile.

In the empirical study we trained 5 models for early prediction of interim assessment grades based on the universal indicators of the LMS Moodle student digital footprint. The most accurate model, especially in the first half of the semester, turned out to be ensemble-averaging models of logistic regression, random forest and gradient boosting. It was found that universal models are effective for detection of at-risk students in the discipline, the directions for further improvement of the universal model of performance prediction were determined and conditions for scaling the proposed approach to create a prognostic system for student retention to other educational institutions were formulated.

Keywords: learning analytics, educational data analysis, student retention, learning success, digital footprint, LMS Moodle, performance prediction, machine learning, model ensemble.

For citation:

Esin R. V., Kustitskaya T. A., Noskov M. V. Predicting academic performance in a course by universal features of LMS Moodle digital footprint. *Informatics and Education*. 2023;38(3):31–41. (In Russian.) DOI: 10.32517/0234-0453-2023-38-3-31-41

1. Введение

С 2000-х годов в научно-педагогическом сообществе заметно вырос интерес к учебной аналитике — мультидисциплинарной области знаний, в которую входит «измерение, сбор, анализ и обобщение данных об обучающихся и их окружении с целью понимания и оптимизации образовательной среды и образовательного процесса» [1].

Одной из важных задач учебной аналитики является прогнозирование успешности обучения по образовательным данным. Исследования в этой области проведены преимущественно для высшего образования. Только за 2022 год в зарубежной литературе появилось 116 статей по теме учебной аналитики, посвященных вопросу прогнозирования успешности обучения студентов (по ключевым словам «dropout», «student performance», «learning analytics») и индексируемых в международной наукометрической базе Scopus. При этом в результате поиска на платформе eLibrary за 2022 год нами было найдено всего 14 русскоязычных статей (или статей с аннотацией на русском языке), посвященных этой задаче, находящихся в открытом доступе и индексируемых в ВАК, WoS, Scopus или RSCI. Анализ зарубежных и отечественных публикаций в области учебной аналитики показывает, что прогнозированию успешности обучения в России пока уделяется недостаточное внимание.

Заметим, что несмотря на всю ценность международного опыта, отличия между образовательными системами в России и за рубежом часто не дают возможности прямого переноса поставленных задач учебной аналитики и методов их решения из одной системы в другую.

Во-первых, это отличия в построении образовательных программ. В частности, существенным является то, что российские студенты менее свободны в выборе индивидуальной траектории обучения [2]. Во-вторых, в российской системе высшего образования к студентам, особенно младших курсов, часто относятся как к детям, которых необходимо убеждать в необходимости учиться. В зарубежных вузах преобладающая идея состоит в том, что студент сам отвечает за свое образование (стоит отметить, что за рубежом обучение в основном платное). Это приводит к существенным различиям в уровнях внутренней и внешней мотивации к академической деятельности, что находит отражение в мотивах

и целях обучающихся в образовательном процессе, в стратегиях реагирования на неудачи и в наличии/отсутствии настойчивости [3]. В-третьих, существует отличие в восприятии приемлемых сроков обучения. В ряде зарубежных статей, например [4], студент считается успешным, если он завершает обучение в вузе с задержкой в один или два года.

В настоящее время не существует общепринятого определения понятия «успешность обучения» [5]. Это связано с разницей представления об успехе у самих обучающихся, педагогов и остальной части социума [6]. Критериями успешности обучения могут выступать такие показатели, как высокая оценка по дисциплине, получение аттестата или диплома об окончании обучения, удовлетворенность результатами своего обучения, конкурентоспособность на рынке труда и сформированность профессиональных компетенций [7].

Среди проанализированных нами источников около 70 % статей посвящено прогнозированию риска академической неуспешности студентов, что подразумевает или риск, связанный с возможностью не сдать вовремя конкретный предмет учебного плана, или риск, связанный с неполучением диплома (степени). При этом задачи по прогнозированию второго типа риска более распространены. В отдельных зарубежных вузах уже значительное время существуют прогностические системы, которые оценивают риск студента остаться без диплома [8–10]. Например, в [11] указаны успешно работающие прогностические системы в государственном исследовательском университете США — Висконсинском университете в Мадисоне (University of Wisconsin-Madison) [12], а также в общественном исследовательском университете США — университете Пердью штата Индианы (Purdue University) [13], испанском университете UDIMA в Мадриде [14] и Миланском политехническом университете (Politecnico di Milano) [15].

Как отмечается в работе [16], «досрочное прекращение учебы в вузе считается важным показателем для измерения социальной мобильности и отражения социальной роли университетского образования». Отчисление студентов приводит к нехватке квалифицированного человеческого капитала, а значит, мешает эффективному экономическому развитию страны. Завершение учебы студентов в срок важно и для российских вузов, так как их финансовое благополучие во многом зависит от сохранения числа

обучающихся. Возможно, что прогностические системы отсева обучающихся создаются и развиваются в России прямо сейчас, однако серьезных научных исследований по этой теме обнаружить не удалось. Поэтому отметим *создание научно обоснованной прогностической системы сохранности контингента обучающихся в вузе в условиях российского образования* как одну из актуальных и наиболее остро стоящих задач российского сегмента учебной аналитики.

Отчисление российских студентов, обучающихся за счет средств бюджета, происходит главным образом в связи с академическими задолженностями (отчисления по собственному желанию, по состоянию здоровья, в связи с неоплатой обучения и прочим причинам бывают значительно реже). Поэтому вполне очевидно, что значительный вклад в прогноз отчисления из вуза могут внести прогнозы успешности аттестации по дисциплинам учебного плана. Важно, что возникающие у студента проблемы с обучением можно заметить на ранних этапах именно на уровне отдельных дисциплин по его текущей успеваемости и образовательному поведению. Поэтому *в российских реалиях модель прогнозирования успеваемости по дисциплине будет являться одной из важнейших составляющих системы прогнозирования сохранности контингента обучающихся вуза*.

В нашей работе рассматривается проблема построения моделей прогнозирования успешности по дисциплине, позволяющих в динамике (например, еженедельно в течение семестра) выявлять студентов с повышенным риском неаттестации по дисциплине. Всюду далее *под успешностью обучения будем понимать получение обучающимся положительной итоговой оценки по дисциплине*.

2. Материалы и методы

Методологическую базу исследования составил комплекс теоретических и эмпирических методов. Выявление существующих подходов и проблем в области прогнозирования успешности обучения основывалось на теоретических методах контент-анализа и сравнительно-сопоставительного анализа научной литературы. Для построения структурной модели системы прогнозирования успешности обучения по дисциплине использовались методы систематизации, анализа и синтеза.

Для проведения эмпирического исследования были использованы образовательные данные, полученные с платформы электронного обучения Сибирского федерального университета (СФУ) «eКурсы» и из информационной системы вуза АИС ИКИТ. Для построения по этим данным моделей прогнозирования успешности обучения и их анализа использовались методы разведочного и корреляционного анализа данных, методы машинного обучения (различные методы классификации и ансамблирования моделей), методы оценки качества прогнозирования.

3. Результаты

3.1. Система прогнозирования успешности обучения и ее составляющие

Для прогнозирования успешности обучения можно использовать как данные цифровой образовательной истории [17], так и данные цифрового образовательного профиля обучающегося.

Проблема заключается в том, что несмотря на активную цифровизацию, ведущуюся в российских вузах, далеко не все показатели образовательной истории и образовательного профиля студента собираются информационными системами университетов. Например, выявление различных психологических характеристик обучающихся обычно не проводится массово с сохранением результатов в базах данных в цифровом виде. Информация о психологических характеристиках студентов (мотивации обучающегося, его дисциплинированности, усидчивости и упорстве в обучении), с одной стороны, может быть весьма полезна для решения задачи прогнозирования успешности обучения; с другой стороны, сбор и анализ такой информации сопряжен с большой дополнительной организационной, технической и исследовательской работой.

При этом некоторые компоненты цифровой образовательной истории во многих вузах уже вполне эффективно собираются и хранятся. Это прежде всего данные о ходе текущего образовательного процесса. В случае, если в учебном заведении используются LMS для организации электронного обучения, то их встроенный функционал обеспечивает сбор цифрового следа студентов на электронной платформе [18, 19]. Эти данные содержат разнообразные характеристики обучения студента в рамках электронного курса: его баллы, переходы по ссылкам внутри курса, время, проведенное на страницах курса, и т. п. Поскольку свежие данные цифрового следа можно получать в любое время, использование их для текущего мониторинга учебной деятельности студентов и раннего прогнозирования успешности аттестации по дисциплине выглядит перспективным.

Возникают следующие вопросы:

- Можно ли в условиях дефицита образовательных данных той или иной природы эффективно прогнозировать успешность обучения?
- Каким образом организовать работу по созданию такой системы прогнозирования?

Учитывая трудоемкость получения разного типа образовательных данных, мы считаем наиболее перспективным формат прогнозной системы в виде конструктора, где отдельными составляющими будут модели, построенные по данным разной природы. На рисунке 1 представлена возможная структурная модель системы прогнозирования успешности обучения по дисциплине.

В предлагаемой нами системе прогнозирования успешности обучения по дисциплине в вузе выделены следующие основные компоненты: модель на основе



Рис. 1. Структурная модель системы прогнозирования успешности обучения по дисциплине

Fig. 1. Structural model of the system for predicting learning success in a course

образовательного профиля, универсальная модель и предметная модель.

Образовательный профиль включает в себя всю информацию, которую хранит информационная система вуза о конкретном обучающемся:

- данные социального профиля обучающегося (его пол, возраст, гражданство, место проживания, образование родителей и т. д.);
- его психологические характеристики (перцептивная модальность, уровень мотивации и др.);
- общеобразовательные данные (код укрупненной группы направлений подготовки, баллы ЕГЭ при поступлении, форма обучения, данные о школьных достижениях и т. д.);
- накопленные данные цифровой истории в вузе (информация из зачетной книжки, сведения об академических задолженностях и т. д.).

Второй составляющей системы прогнозирования является *универсальная модель*. Она включает в себя самые общие (универсальные) характеристики обучения, которые можно получить из цифрового следа обучающегося в электронной среде. Данные о деятельности обучающегося в электронном курсе

и результативности этой деятельности выступают обобщенными показателями успешности обучения по дисциплине. Такими показателями можно считать сведения о просмотрах элементов электронного курса, о выполнении заданий, тестов и лабораторных работ, количественную информацию о набранных баллах в электронном курсе, а также различные производные от этих показателей (прирост показателей за определенный промежуток, количество недель неактивности в курсе и т. д.).

Для учета особенностей отдельной дисциплины можно строить уточненные модели, которые мы будем называть предметными. Признаки *предметной модели* допускают более тонкий подбор элементов и настройку с учетом педагогического дизайна дисциплины, формируемых результатов обучения и уникальных для конкретной дисциплины показателей.

Итоговый прогноз должен строиться по прогнозам отдельных моделей, уже созданных к данному моменту. Совокупность трех моделей системы прогнозирования успешности обучения по дисциплине позволит достичь компромисса между точностью и масштабируемостью модели: с одной стороны, мо-

дель, построенная для одной дисциплины, будет давать наиболее точные прогнозы, однако такую модель не получится перенести на другую дисциплину из-за уникальности образовательного процесса. С другой стороны, универсальная модель, как и модель на основе образовательного профиля, скорее всего, не позволит достичь высокой точности прогноза.

Технически это можно организовать в виде ансамбля-стекинга, на вход которого в качестве независимых переменных подаются прогнозы, полученные отдельными моделями. Ожидается, что с увеличением числа построенных моделей и, соответственно, с увеличением числа предикторов для ансамбля-стекинга качество итогового прогнозирования будет расти.

3.2. Эмпирическое исследование по построению и анализу прогнозных моделей

В ходе эмпирического исследования авторы разработали универсальную модель прогнозирования успешности обучения по дисциплине на основе данных цифрового следа и оценили точность этой модели.

Набор данных для исследования представляет собой цифровой след 525 студентов 1-го, 2-го и 3-го курсов СФУ по нескольким направлениям подготовки: «Металлургия», «Информатика и вычислительная техника», «Информационные системы и технологии», «Информационная безопасность», «Компьютерная безопасность» и «Прикладная математика».

Основными источниками цифрового следа в LMS Moodle являются журнал оценок и журнал событий, содержащий информацию обо всех действиях обучающегося в электронном курсе, которые можно условно разделить на два вида: активные и пассивные. Активными действиями в курсе будем считать действия, приводящие к изменению текущей оценки пользователя или к появлению нового контента (завершение попытки тестирования, представление ответа на задание, создание записи на форуме и т. д.). Пассивные действия в курсе выражаются в просмотре различных элементов или ресурсов: такие события создаются, если пользователь просмотрел файл, зашел на форум или открыл чат.

Данные об успеваемости и активности в электронной среде еженедельно извлекались из журналов оценок и журналов событий электронных курсов по дисциплинам «Алгебра и геометрия», «Математический анализ», «Базовая математика», «Теория вероятностей» и «Математическая статистика». Данные проходили предварительную обработку, и для каждого обучающегося еженедельно определялись следующие показатели:

- число просмотров элементов курса;
- число активных действий в электронном курсе;
- текущие баллы за электронный курс.

После экзаменационной сессии набор данных был дополнен информацией о результатах промежуточной аттестации по этим дисциплинам: успешным прохождением аттестации считались оценки «удовлетворительно», «хорошо» и «отлично» за экзамен

или получение «зачтено», неуспех — это «неудовлетворительно», «не зачтено» или «неявка».

Прогнозирование успешности аттестации по дисциплине представляет собой задачу бинарной классификации, для решения которой нами были опробованы разные модели. В качестве отклика в моделях выступает переменная **итог** (0 — студент успешно прошел аттестацию в сессию, 1 — студент не аттестован), а список предикторов включает в себя следующие переменные:

- номер учебной недели (переменная *week*);
- текущие баллы по электронному курсу накопительным итогом (*grade*);
- число просмотров элементов электронного курса накопительным итогом (*clicks*);
- число активных действий в электронном курсе накопительным итогом (*action*);
- приращения за 1-ю и за 2-ю недели в баллах по электронному курсу (*delta_1_grade*, *delta_2_grade*);
- приращения за 1-ю и 2-ю недели в числе просмотров элементов электронного курса (*delta_1_clicks*, *delta_2_clicks*);
- приращения за 1-ю и 2-ю недели в числе активных действий в электронном курсе (*delta_1_action*, *delta_2_action*).

Все предикторы в наборе данных (кроме номера учебной недели) были нормализованы внутри учебных групп с целью достижения одинакового масштаба показателей цифрового следа для всех задействованных электронных курсов. Это позволило уменьшить влияние разного дизайна электронных курсов и методик преподавания на показатели успеваемости и активности в электронной среде.

Предикторы в данной задаче сильно связаны между собой, что вообще характерно для цифрового следа обучающихся [20]. Так, матрица корреляций (рис. 2) показывает сильную линейную зависимость между переменными *grade*, *clicks* и *action* (парные корреляции от 0,68 до 0,78).

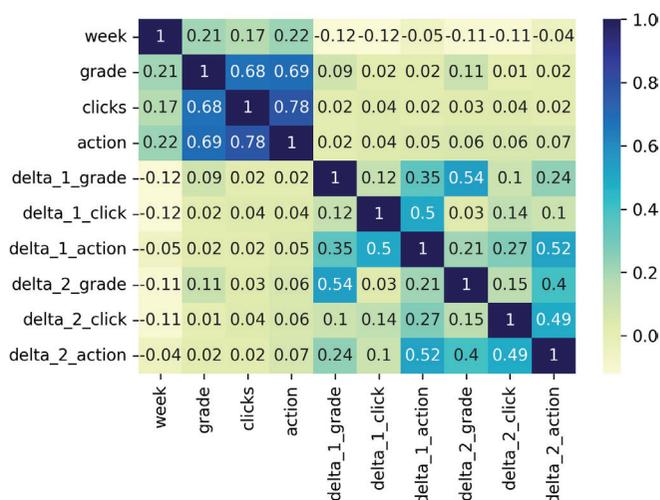


Рис. 2. Корреляционная матрица предикторов

Fig. 2. Correlation matrix for predictors

В такой ситуации использовать простые линейные модели классификации нежелательно из-за негативных эффектов мультиколлинеарности, поэтому выбор был сделан в пользу моделей, построенных на деревьях решений (метод случайного леса (Random Forest), классификатор на основе градиентного бустинга XGBoost), которые являются устойчивыми к мультиколлинеарности, гибкими для учета связей между всеми переменными и в значительной степени интерпретируемыми благодаря обобщенным показателям важности предикторов (например, Node Impurity). Также была обучена модель логистической регрессии (Logistic Regression) с регуляризацией и различные ансамбли из Random Forest, XGBoost и Logistic Regression.

Качество обученных моделей оценивалось на отложенных выборках с помощью метрик *accuracy*, *precision*, *recall* и *F1-score*. В качестве критерия для выбора лучшей модели была использована метрика *F1-score*, которая оценивает качество распознавания класса 1 (студенты, имеющие проблемы с аттестацией), учитывая как долю выявленных объектов класса 1, так и долю верно отнесенных к классу 1 объектов.

На рисунке 3 представлены графики изменения метрики *F1-score* с 1-й по 18-ю недели семестра для четырех классификаторов. Лучшее качество прогнозирования демонстрирует *Ensemble* (ансамбль-усреднение классификаторов Random Forest, XGBoost и Logistic Regression с регуляризацией L1). Особенно заметно его преимущество в первой половине семестра, когда поддержка отстающих студентов может быть наиболее эффективной. Начиная с 7-й недели обучения, *F1-score* превышает 70 %, начиная с 11-й недели — 75 %, начиная с 16-й недели — 80 %.

Модель *Ensemble* (как прогнозирующая наиболее точно, начиная с ранних этапов) была выбрана для дальнейшей работы: планируется еженедельно осу-

ществлять сбор данных с ЭИОС и проводить прогноз с помощью этой модели. Таким образом, к концу каждой недели семестра для каждого студента будет вычисляться вероятность быть неаттестованным по дисциплине. Эту информацию можно предоставлять как самим студентам через персональные дашборды учебной аналитики, так и администрации вуза и преподавателям на сводных панелях аналитики.

Динамику прогнозов для группы студентов можно визуализировать с помощью таблицы, в которой ячейки, соответствующие прогнозам для студента с номером *ID* на неделе *week_n*, будут раскрашены в зависимости от вероятности быть не аттестованным в сессию: низкие вероятности будут соответствовать оттенкам зеленого (благоприятный прогноз), а высокие — оттенкам красного (неблагоприятный прогноз). На рисунке 4 представлена часть такой таблицы, соответствующая студентам, успешно сдавшим экзамен или зачет, а на рисунке 5 — соответствующая студентам, не аттестованным в сессию. Видно, что у аттестованных в сессию студентов таблица раскрашена в основном в оттенки зеленого, а у неаттестованных — в оттенки красного, причем ближе к концу семестра столбцы таблиц становятся более зелеными (для аттестованных студентов) и более красными (для неаттестованных), т. е. уверенность в соответствующем прогнозе возрастает.

Подобные таблицы позволяют легко выявить студентов, хорошо занимавшихся в течение семестра, но не аттестованных в сессию. Так, например, на рисунке 5 строка с прогнозами для студента с ID=45 раскрашена в оттенки зеленого, и вероятность не пройти аттестацию, согласно цвету ячеек, очень мала. Однако этот студент не явился на экзамен, в результате чего и попал в группу неуспешных по дисциплине. Подобные ситуации требуют отдельного изучения и внимания со стороны сотрудников учебного отдела и преподавателей.

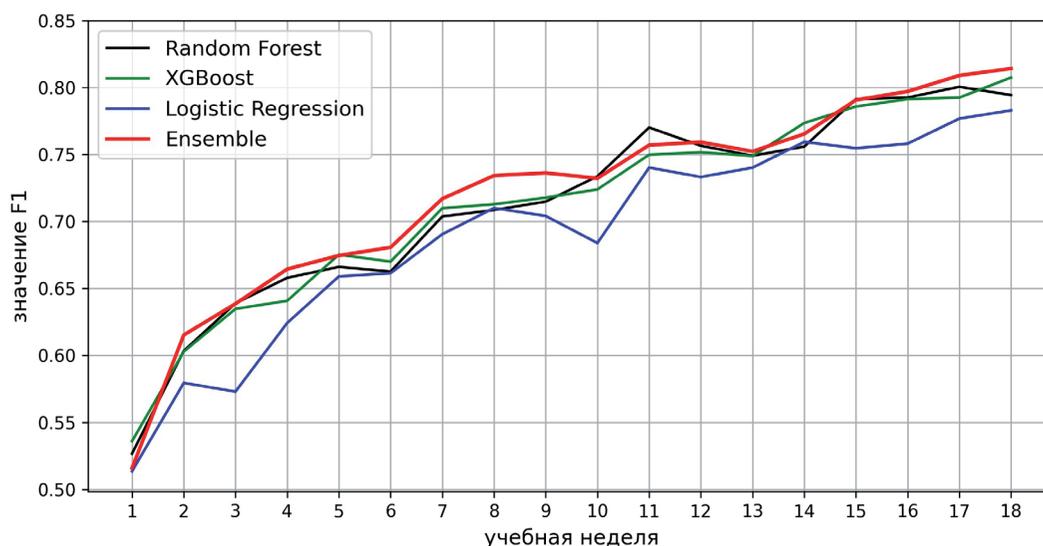


Рис. 3. Динамика изменения значений метрики *F1-score* для классификаторов: Random Forest, XGBoost, Logistic Regression и Ensemble

Fig. 3. Dynamics of *F1-score* values for the classifiers: Random Forest, XGBoost, Logistic Regression and Ensemble

ID	week1	week2	week3	week4	week5	week6	week7	week8	week9	week10	week11	week12	week13	week14	week15	week16	week17	week18
73	0.65	0.31	0.35	0.02	0.02	0.09	0.14	0.10	0.11	0.07	0.06	0.04	0.02	0.02	0.02	0.02	0.03	0.05
1190	0.65	0.26	0.18	0.14	0.22	0.16	0.20	0.11	0.05	0.07	0.20	0.16	0.21	0.12	0.16	0.13	0.15	0.13
1395	0.65	0.36	0.31	0.29	0.45	0.34	0.25	0.22	0.07	0.13	0.21	0.26	0.17	0.17	0.15	0.12	0.14	0.12
324	0.65	0.11	0.37	0.26	0.41	0.23	0.53	0.18	0.08	0.07	0.12	0.08	0.08	0.06	0.07	0.22	0.16	0.09
882	0.65	0.85	0.41	0.36	0.56	0.52	0.47	0.08	0.04	0.09	0.16	0.06	0.05	0.06	0.06	0.06	0.05	0.07
1307	0.65	0.39	0.20	0.19	0.53	0.43	0.82	0.60	0.75	0.51	0.28	0.15	0.11	0.09	0.24	0.25	0.32	0.28
805	0.65	0.34	0.59	0.21	0.38	0.57	0.45	0.39	0.23	0.07	0.09	0.13	0.06	0.11	0.19	0.12	0.10	0.25
1480	0.65	0.85	0.31	0.40	0.65	0.67	0.13	0.20	0.11	0.24	0.64	0.31	0.41	0.43	0.47	0.63	0.70	0.77
1042	0.65	0.33	0.36	0.07	0.19	0.14	0.40	0.11	0.13	0.08	0.08	0.07	0.09	0.10	0.11	0.15	0.22	0.12
761	0.65	0.26	0.26	0.27	0.38	0.16	0.15	0.23	0.53	0.46	0.15	0.16	0.09	0.09	0.08	0.11	0.19	0.13
1114	0.21	0.15	0.24	0.10	0.16	0.25	0.06	0.09	0.05	0.03	0.04	0.07	0.07	0.06	0.04	0.05	0.04	0.05
911	0.72	0.11	0.35	0.23	0.13	0.10	0.06	0.11	0.06	0.19	0.25	0.54	0.09	0.04	0.05	0.04	0.05	0.05
1028	0.65	0.37	0.19	0.04	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.04	0.05	0.05	0.04	0.05	0.04
549	0.65	0.64	0.55	0.12	0.10	0.15	0.14	0.30	0.15	0.18	0.19	0.31	0.30	0.08	0.12	0.28	0.08	0.12
56	0.65	0.39	0.28	0.09	0.09	0.05	0.04	0.05	0.07	0.15	0.04	0.03	0.03	0.04	0.03	0.04	0.04	0.05
745	0.65	0.37	0.57	0.46	0.55	0.48	0.50	0.77	0.52	0.45	0.46	0.39	0.07	0.08	0.06	0.07	0.09	0.08
952	0.65	0.45	0.14	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.05	0.03	0.04	0.04	0.03	0.03	0.04
652	0.65	0.30	0.18	0.15	0.10	0.03	0.01	0.18	0.16	0.12	0.15	0.11	0.10	0.15	0.14	0.18	0.16	0.14
778	0.65	0.73	0.65	0.64	0.48	0.32	0.60	0.59	0.44	0.28	0.45	0.39	0.28	0.24	0.14	0.20	0.08	0.13
867	0.41	0.46	0.10	0.10	0.44	0.49	0.40	0.25	0.26	0.57	0.29	0.39	0.43	0.38	0.35	0.31	0.39	0.38

Рис. 4. Понедельный прогноз успешности по дисциплине для аттестованных студентов
 Fig. 4. Weekly forecast for student success in a course for attested students

ID	week1	week2	week3	week4	week5	week6	week7	week8	week9	week10	week11	week12	week13	week14	week15	week16	week17	week18
999	0.65	0.78	0.78	0.61	0.71	0.48	0.66	0.79	0.45	0.69	0.88	0.89	0.88	0.92	0.46	0.62	0.59	0.75
58	0.67	0.39	0.51	0.88	0.80	0.95	0.93	0.95	0.96	0.92	0.94	0.95	0.95	0.97	0.98	0.97	0.92	0.83
798	0.65	0.90	0.94	0.94	0.95	0.95	0.96	0.96	0.96	0.97	0.97	0.95	0.97	0.98	0.98	0.98	0.94	0.94
886	0.65	0.85	0.84	0.85	0.51	0.63	0.76	0.88	0.92	0.92	0.95	0.94	0.94	0.94	0.95	0.94	0.91	0.84
1244	0.65	0.85	0.92	0.92	0.94	0.95	0.96	0.96	0.96	0.97	0.97	0.97	0.97	0.98	0.98	0.98	0.98	0.98
4	0.65	0.85	0.76	0.60	0.60	0.55	0.47	0.55	0.46	0.51	0.41	0.33	0.10	0.21	0.21	0.41	0.54	0.22
1425	0.65	0.59	0.66	0.83	0.88	0.91	0.94	0.94	0.94	0.96	0.96	0.97	0.89	0.96	0.94	0.91	0.80	0.69
912	0.65	0.85	0.92	0.92	0.94	0.95	0.96	0.96	0.96	0.97	0.97	0.97	0.97	0.98	0.98	0.98	0.98	0.98
545	0.19	0.36	0.52	0.58	0.75	0.78	0.79	0.86	0.91	0.93	0.92	0.93	0.94	0.89	0.92	0.95	0.95	0.94
1477	0.36	0.40	0.63	0.70	0.66	0.70	0.75	0.79	0.76	0.77	0.81	0.81	0.83	0.82	0.84	0.90	0.89	0.93
468	0.17	0.30	0.43	0.52	0.41	0.66	0.77	0.82	0.85	0.80	0.91	0.90	0.91	0.94	0.93	0.92	0.93	0.93
1210	0.45	0.74	0.42	0.32	0.43	0.61	0.61	0.57	0.55	0.68	0.70	0.77	0.85	0.92	0.91	0.91	0.92	0.93
209	0.65	0.85	0.88	0.85	0.94	0.95	0.95	0.95	0.96	0.97	0.97	0.97	0.97	0.97	0.96	0.98	0.98	0.98
650	0.19	0.54	0.47	0.64	0.78	0.78	0.84	0.86	0.78	0.82	0.94	0.93	0.95	0.90	0.92	0.95	0.95	0.93
62	0.65	0.85	0.92	0.92	0.94	0.95	0.96	0.96	0.96	0.97	0.97	0.97	0.97	0.98	0.98	0.98	0.98	0.98
45	0.49	0.44	0.54	0.46	0.18	0.23	0.21	0.15	0.13	0.10	0.06	0.04	0.04	0.04	0.06	0.09	0.10	0.16
52	0.79	0.87	0.94	0.92	0.94	0.95	0.96	0.96	0.96	0.97	0.97	0.97	0.97	0.98	0.98	0.98	0.98	0.98
1330	0.44	0.48	0.71	0.37	0.41	0.62	0.47	0.53	0.58	0.75	0.85	0.88	0.84	0.89	0.91	0.92	0.93	0.90
1108	0.65	0.56	0.90	0.62	0.74	0.82	0.85	0.91	0.93	0.92	0.94	0.93	0.95	0.92	0.94	0.96	0.96	0.96
18	0.65	0.85	0.92	0.92	0.94	0.95	0.96	0.96	0.96	0.97	0.97	0.97	0.97	0.98	0.98	0.98	0.98	0.98

Рис. 5. Понедельный прогноз успешности по дисциплине для неаттестованных студентов
 Fig. 5. Weekly forecast for student success in a course for unattested students

Результаты эмпирического исследования позволяют сделать вывод о хорошем качестве предсказания успешности обучения с помощью моделей, построенных на основе универсальных показателей цифрового следа обучающегося. Метод ансамблирования отдельных моделей позволяет повысить качество прогноза, особенно на ранних этапах.

Благодаря точности построенной универсальной модели прогнозирования ее уже сейчас можно использовать для информирования отдельных участников образовательного процесса (преподавателей и администрации) о высоком риске неуспешности студентов определенных групп.

4. Обсуждение результатов

Отметим, что для «предметных» моделей (т. е. построенных по данным цифрового следа одного электронного курса с учетом его дизайна и с использованием в качестве предикторов специфичных для дисциплины характеристик, например, баллов за определенные контрольные точки) можно добиться более высокого качества прогноза. Так, у модели выявления студентов с высоким риском неаттестации, построенной нами отдельно для дисциплины «Теория вероятностей», метрика *F1-score* на 7-й неделе составляла 86 %, на 11-й — 88 %, на 16-й — 92 % [21]. Тем не менее модель, полученная в данном исследовании, также демонстрирует неплохое качество, особенно если учесть, что задействованные курсы различаются по дизайну и доле электронного обучения в учебном процессе.

Созданные модели прогнозирования успешности обучения можно совершенствовать несколькими способами.

Во-первых, за счет увеличения числа курсов, на которых происходит сбор цифрового следа обучающихся. В обучении построенной нами модели использовались данные только курсов математической направленности, которые могут иметь определенную специфику, например:

- преобладание тестовых форм деятельности по решению задач в электронном курсе;
- преобладание элементов типа «задание» для представления лабораторных работ, комплектов задач и типовых расчетов.

Добавление в обучающую выборку данных цифрового следа других курсов (технических, инженерных, гуманитарных) поможет нивелировать эти отличия и стабилизировать прогноз модели.

Кроме того, даже курсы по одной и той же дисциплине могут существенно отличаться друг от друга из-за разницы в учебных программах и количестве часов, из-за вариативности применения преподавателями средств и методов обучения, из-за используемого формата обучения с применением электронной среды. Веб-поддержка, смешанное обучение, онлайн-обучение — все эти факторы влияют на формируемый в курсе цифровой след обучающегося, поэтому включение в процесс обучения модели большого

числа разнородных курсов должно положительно сказаться на качестве прогнозирования успешности обучения по отдельной дисциплине.

Во-вторых, качество работы модели предсказания успешности напрямую зависит от используемых предикторов. Поиск и включение в используемую модель большего числа информативных предикторов позволит повысить качество предсказания. Представленная в работе модель обучалась только на укрупненных показателях цифрового следа, фиксируемого в электронной информационно-образовательной среде СФУ. Однако их можно детализировать, рассматривая, например, не только число просмотров в целом, но и число просмотров обучающего контента, определенных типов обучающих элементов, форумов и т. п. При этом предлагаемые показатели цифрового следа являются универсальными для всех электронных курсов платформы «Курсы», что позволит масштабировать модель для применения во всем университете.

Предложенный нами подход к созданию системы прогнозирования успешности обучения может быть использован другими образовательными учреждениями при выполнении следующих условий.

1. Развитая электронная информационно-образовательная инфраструктура вуза. В вузе должна быть разработана и внедрена система электронного обучения, позволяющая применять дистанционные образовательные технологии [22]. Наличие такой системы является основой для автоматизированной фиксации цифрового следа обучающегося [17] и результатов учебной деятельности по дисциплине. Большого развития электронной инфраструктуры вуза можно добиться, установив такие сервисы, как личный кабинет обучающегося, корпоративный портал, доступ к научной библиотеке и другие, позволяющие фиксировать различные показатели учебной и внеучебной деятельности.

2. Единая методология организации процесса электронного обучения. Наличие одной лишь системы электронного обучения позволяет создать базу для сбора образовательных данных и обеспечить минимальное функционирование системы прогнозирования успешности обучения. Однако такие данные могут быть сильно зашумлены из-за вариативности дизайна электронных курсов, различий между дисциплинами и обучения с применением электронной среды. Для повышения эффективности системы прогнозирования важно обеспечить непрерывную работу преподавателя и студентов в электронном курсе по дисциплине, а также еженедельную фиксацию промежуточных результатов обучения в различных форматах (автоматизированное тестирование и оценивание преподавателем).

3. Непрерывное повышение квалификации преподавателей в области ИКТ, электронного обучения и педагогического дизайна. Реализация образовательных программ с применением электронного обучения и дистанционных образовательных технологий требует от преподавателя

постоянной актуализации компетенций, связанных с работой в цифровой среде. Качественный дизайн электронного курса является необходимым условием получения адекватных данных цифрового следа и последующего применения этих данных в прогнозных моделях. И чем более разнородные элементы и ресурсы применяются в электронном курсе, тем более объективно цифровой след позволит определить характеристики обучающегося, влияющие на успеваемость.

4. Непрерывная поддержка и развитие используемой системы прогнозирования успешности обучения. После внедрения системы прогнозирования успешности обучения по дисциплине в образовательный процесс вуза начинается процесс мониторинга и совершенствования модели. На данном этапе модель будет строить предсказания для новых обучающихся, у которых мы не знаем итоговый отклик. Поэтому могут возникнуть ошибочные предсказания и могут быть выявлены новые паттерны поведения обучающихся, которые отсутствовали в наборе данных при обучении модели. После пилотного внедрения необходимо дообучить модель прогнозирования успешности на новых данных, чтобы обеспечить устойчивую производительность и надежность [23].

5. Разработка и внедрение систем обратной связи со стейкхолдерами по итогам прогнозирования. Система прогнозирования успешности обучения разрабатывается и внедряется в образовательный процесс для решения определенных задач, и в зависимости от этих задач необходимо представлять результаты прогнозирования заинтересованным лицам: студентам, преподавателям и администрации вуза. Одним из самых востребованных способов представления такого прогнозирования становятся дашборды учебной аналитики, или аналитические панели. Такие панели позволяют в реальном времени визуализировать для студентов как информацию об успехах в обучении по отдельным дисциплинам, так и общую вероятность отсева по учебной программе. Преподаватель получает средство мониторинга учебного процесса по определенной дисциплине и может реагировать в проблемных случаях. Администрация получает комплексную информацию о сохранности контингента вуза, о прогнозах успешности обучения отдельных студентов и групп, а также о качестве работы преподавателей [24, 25].

6. Разработка и реализация комплекса мер поддержки студентов с проблемами в обучении. Система обратной связи является первым этапом в создании комплекса мер по поддержке студентов. Ее основная цель — информирование, которое должно стать дополнительным стимулом для решения проблем в обучении. Информация сигнализирует о наличии проблемы, но не дает ответа на вопрос «Что с этим делать?». Если рассматривать проблему локально (внутри дисциплины), то преподаватель может предусмотреть перечень действий студента, которые позволят исправить текущую ситуацию:

выполнить дополнительные виды работ, прийти на консультацию, изучить дополнительный теоретический материал и т. д. Если рассматривать проблему глобально (на уровне вуза), требуется разработка и внедрение системы рекомендаций для поддержки обучения. Эта система в зависимости от глубины проблемы и причин, ее вызвавших, будет выполнять различные функции:

- подбирать индивидуальные траектории решения проблем для студентов;
- формировать индивидуальный образовательный план;
- оценивать уровень сформированности компетенций;
- перенаправлять обучающийся контингент на более подходящие образовательные программы.

5. Заключение

Модели машинного обучения, построенные на основе универсальных показателей цифрового следа, продемонстрировали хорошее качество прогноза на отложенной выборке. С одной стороны, такие показатели, как успеваемость и активность в электронной обучающей среде, фиксируются во всех современных системах управления обучением, что существенно облегчает сбор цифрового следа и не требует дополнительных программных продуктов для его извлечения. А с другой стороны, данные цифрового следа уже в первой половине семестра позволяют выявлять студентов с высоким риском неуспешности по дисциплине. Ансамбль-усреднение классификаторов Random Forest, XGBoost и Logistic Regression с регуляризацией L1 показал наилучшие результаты в эмпирическом исследовании по построению и анализу прогнозных моделей: начиная с 7-й недели обучения, метрика *F1-score* превышает 70 %, начиная с 11-й недели — 75 %, начиная с 16-й недели — 80 %.

Апробированный авторами ансамбль может стать одной из ключевых моделей в системе прогнозирования успешности обучения по дисциплине в вузе. Система прогнозирования, помимо универсальной модели, также может учитывать модель на основе образовательного профиля и предметную модель. Дальнейшее развитие системы прогнозирования основывается на сборе дополнительной информации: как об обучающемся — для построения модели на основе образовательного профиля, так и о специфических показателях предметной области дисциплины — для построения предметной модели. Совокупность трех моделей системы прогнозирования и используемых в них предикторов позволяет ожидать существенный рост качества прогноза успешности обучения по дисциплине.

Для эффективного масштабирования предложенного подхода к созданию системы прогнозирования успешности обучения выявлены необходимые условия:

- развитая электронная информационно-образовательная инфраструктура вуза;
- единая методология организации процесса электронного обучения;
- непрерывное повышение квалификации преподавателей в области ИКТ;
- непрерывная поддержка и развитие используемой системы прогнозирования;
- разработка и внедрение систем обратной связи;
- разработка и реализация комплекса мер поддержки студентов с проблемами в обучении.

Финансирование

Исследование выполнено при финансовой поддержке гранта РНФ, проект № 22-28-00413.

Funding

This work is supported by the Russian Science Foundation under Grant No 22-28-00413.

Список источников / References

1. Siemens G., Gašević D. Guest editorial — learning and knowledge analytics. *Educational Technology & Society*. 2012;15(3):1–2. Available at: https://drive.google.com/file/d/1SJQZSF0rix9_WZTvBtzvUL70bsLa_eqQ/view
2. Арифуллина Р. У., Камушенко О. А. Анализ отечественных и зарубежных трендов индивидуализации образовательного процесса в вузе: аналитический доклад. *Вестник Мининского университета*. 2021;9(4):2. EDN: СМЕЕМЗ. DOI: 10.26795/2307-1281-2021-9-4-2
[Arifulina R. U., Kamushenko O. A. Analysis of domestic and foreign trends of individualization of the educational process in the university: analytical report. *Vestnik of Minin University*. 2021;9(4):2. (In Russian.) EDN: СМЕЕМЗ. DOI: 10.26795/2307-1281-2021-9-4-2]
3. Гордеева Т. О., Сычев О. А., Осин Е. Н. Опросник «Шкалы академической мотивации». *Психологический журнал*. 2014;35(4):96–107. EDN: SJVWLN
[Gordeeva T. O., Sychev O. A., Osin E. N. “Academic motivation scales” questionnaire. *Psikhologicheskii zhurnal*. 2014;35(4):96–107. (In Russian.) EDN: SJVWLN]
4. Nur N., Park N., Dorodchi M., Dou W., Mahzoon M. J., Niu X., Maher M. L. Student network analysis: A novel way to predict delayed graduation in higher education. *Artificial Intelligence in Education. AIED 2019. Lecture Notes in Computer Science*. 2019;11625:370–382. Springer, Cham. DOI: 10.1007/978-3-030-23204-7_31
5. York T. T., Gibson C., Rankin S. Defining and measuring academic success. *Practical Assessment, Research, and Evaluation*. 2015;20:5. DOI: 10.7275/hz5x-tx03
6. Hommel M., Egetenmeier A., Maier U. Supporting stakeholders with learning analytics to increase study success. *Utilizing Learning Analytics to Support Study Success*. Springer, Cham; 2019:37–60. DOI: 10.1007/978-3-319-64792-0_3
7. Шапоров А. М. Прогнозирование риска отчисления как результат академической неуспешности обучающегося. *Ярославский педагогический вестник*. 2022;(1(124)):48–55. EDN: NSUCPN. DOI: 10.20323/1813-145X-2022-1-124-48-55
[Shaporov A. M. Forecasting the risk of expulsion from the university as a result of academic failure of the student. *Yaroslavl Pedagogical Bulletin*. 2022;(1(124)):48–55. (In Russian.) EDN: NSUCPN. DOI: 10.20323/1813-145X-2022-1-124-48-55]
8. Bravo-Agapito J., Romero S. J., Pamplona S. Early prediction of undergraduate Student’s academic performance in completely online learning: A five-year study. *Computers in Human Behavior*. 2021;115:106595. DOI: 10.1016/j.chb.2020.106595
9. Luis R. M. M. F., Llamas-Nistal M., Iglesias M. J. F. On the introduction of intelligent alerting systems to reduce e-learning dropout: A case study. *Smart Learning Environments*. 2022;9:29. DOI: 10.1186/s40561-022-00210-0
10. Moreira da Silva D. E., Solteiro Pires E. J., Reis A., de Moura Oliveira P. B., Barroso J. Forecasting Students Dropout: A UTAD University Study. *Future Internet*. 2022;14(3):76. DOI: 10.3390/fi14030076
11. Gašević D., Dawson S., Rogers T., Gasevic D. Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*. 2016;28:68–84. DOI: 10.1016/j.iheduc.2015.10.002
12. Knowles J. E. Of needles and haystacks: Building an accurate statewide dropout early warning system in Wisconsin. *Journal of Educational Data Mining*. 2015;7(3):18–67. DOI: 10.5281/zenodo.3554725
13. Ifenthaler D., Mah D.-K., Yau J.Y.-K. Utilising learning analytics for study success: Reflections on current empirical findings. *Utilizing Learning Analytics to Support Study Success*. Springer, Cham; 2019:27–36. DOI: 10.1007/978-3-319-64792-0_2
14. Ortigosa A., Carro R. M., Bravo-Agapito J., Lizcano D., Alcolea J. J. Blanco Ó. From lab to production: Lessons learnt and real-life challenges of an early student-dropout prevention system. *IEEE Transactions on Learning Technologies*. 2019;12(2):264–277. DOI: 10.1109/TLT.2019.2911608
15. Mussida P., Lanzi P. L. A computational tool for engineer dropout prediction. *2022 IEEE Global Engineering Education Conference (EDUCON)*. 2022:1571–1576. DOI: 10.1109/EDUCON52537.2022.9766632
16. Silva J., Matos L. F. A., Mosquera C. M., Mercado C. V., González R. B., Llinás N. O., Lezama O. B. P. Prediction of academic dropout in university students using data mining: Engineering case. *Advances in Cybernetics, Cognition, and Machine Learning for Communication Technologies*. Springer, Singapore; 2020:459–500. DOI: 10.1007/978-981-15-3125-5_49
17. Есин Р. В., Зыкова Т. В., Кустицкая Т. А., Кытманов А. А. Цифровая образовательная история как составляющая цифрового профиля обучающегося в условиях трансформации образования. *Перспективы науки и образования*. 2022;(5):566–584. EDN: OMTHCN. DOI: 10.32744/pse.2022.5.34
[Esin P. V., Zykhova T. V., Kustitskaya T. A., Kytmanov A. A. Digital educational history as a component of the digital student’s profile in the context of education transformation. *Perspectives of Science and Education*. 2022;(5):566–584. (In Russian.) EDN: OMTHCN. DOI: 10.32744/pse.2022.5.34]
18. Шаимов Н. Д., Ломазова И. А., Мицюк А. А., Самоненко И. Ю. Анализ академической успеваемости студентов с использованием журналов событий электронной образовательной среды. *Моделирование и анализ информационных систем*. 2022;29(4):286–314. EDN: STNXMO. DOI: 10.18255/1818-1015-2022-4-286-314
[Shaimov N. D., Lomazova I. A., Mitsyuk A. A., Samonenko I. Y. Analysis of students’ academic performance using LMS event logs. *Modeling and Analysis of Information Systems*. 2022;29(4):286–314. (In Russian.) EDN: STNXMO. DOI: 10.18255/1818-1015-2022-4-286-314]
19. Tamada M. M., Giusti R., Netto J. F. d. M. Predicting students at risk of dropout in technical course using LMS logs. *Electronics*. 2022;11(3):468. DOI: 10.3390/electronics11030468
20. Токтарова В. И., Попова О. Г. Анализ образовательных данных взаимосвязи успешности обучения и поведения студентов в цифровой образовательной среде вуза. *Информатика и образование*. 2022;37(4):54–63. EDN: ESVZJD. DOI: 10.32517/0234-0453-2022-37-4-54-63
[Toktarova V. I., Popova O. G. An analysis of educational data on the correlation between learning success and students’

behavior in the university digital educational environment. *InformatICS and Education*. 2022;37(4):54–63. (In Russian.) EDN: ESVZJD. DOI: 10.32517/0234-0453-2022-37-4-54-63]

21. Kustitskaya T. A., Kytmanov A. A., Noskov M. V. Early student-at-risk detection by current learning performance and learning behavior indicators. *Cybernetics and Information Technologies*. 2022;22(1):117–133. EDN: UD-NYJC. DOI: 10.2478/cait-2022-0008

22. Уджуху И. А., Мешвез Р. К., Манченко Ю. В., Галюшко Т. Э. Электронная информационно-образовательная среда современного вуза: понятие, структура, применение. *Вестник Майкопского государственного технологического университета*. 2020;(1(44)):113–121. EDN: IXROHD. DOI: 10.24411/2078-1024-2020-11011

[Udzhukhu I. A., Meshvez R. K., Manchenko Yu. V., Galyunko T. E. Electronic information and educational environment of a modern university: Concept, structure, application. *Vestnik Maykopskogo Gosudarstvennogo Technologicheskogo Universiteta*. 2020;1(44):113–121. (In Russian.) EDN: IXROHD. DOI: 10.24411/2078-1024-2020-11011]

23. Haakman M., Cruz L., Huijgens H., van Deursen A. AI lifecycle models need to be revised. *Empirical Software Engineering*. 2021;26(5):95. DOI: 10.1007/s10664-021-09993-1

24. Susnjak T., Ramaswami G. S., Mathrani A. Learning analytics dashboard: A tool for providing actionable insights to learners. *International Journal of Educational Technology in Higher Education*. 2022;19(1):12. DOI: 10.1186/s41239-021-00313-7

25. Akcayir G., Farias Wanderley L., Demmans Epp C., Hewitt J., Mahmoudi-Nejad A. Learning analytics dashboard use in online courses: Why and how instructors interpret discussion data. *Visualizations and Dashboards for Learning Analytics*. Springer, Cham; 2021:371–397. DOI: 10.1007/978-3-030-81222-5_17

Информация об авторах

Есин Роман Витальевич, канд. пед. наук, доцент кафедры прикладной математики и анализа данных, Институт космиче-

ских и информационных технологий, Сибирский федеральный университет, г. Красноярск, Россия; *ORCID*: <https://orcid.org/0000-0002-9682-4690>; *e-mail*: resin@sfu-kras.ru

Кустицкая Татьяна Алексеевна, канд. физ.-мат. наук, доцент кафедры прикладной математики и анализа данных, Институт космических и информационных технологий, Сибирский федеральный университет, г. Красноярск, Россия; *ORCID*: <https://orcid.org/0000-0001-9854-1259>; *e-mail*: tkustitskaya@sfu-kras.ru

Носков Михаил Валерианович, доктор физ.-мат. наук, профессор, профессор кафедры прикладной математики и анализа данных, Институт космических и информационных технологий, Сибирский федеральный университет, г. Красноярск, Россия; *ORCID*: <https://orcid.org/0000-0001-8966-3633>; *e-mail*: mnoskov@sfu-kras.ru

Information about the authors

Roman V. Esin, Candidate of Sciences (Education), Associate Professor at the Department of Applied Mathematics and Data Analysis, School of Space and Information Technology, Siberian Federal University, Krasnoyarsk, Russia; *ORCID*: <https://orcid.org/0000-0002-9682-4690>; *e-mail*: resin@sfu-kras.ru

Tatiana A. Kustitskaya, Candidate of Sciences (Physics and Mathematics), Associate Professor at the Department of Applied Mathematics and Data Analysis, School of Space and Information Technology, Siberian Federal University, Krasnoyarsk, Russia; *ORCID*: <https://orcid.org/0000-0001-9854-1259>; *e-mail*: tkustitskaya@sfu-kras.ru

Mihail V. Noskov, Doctor of Sciences (Physics and Mathematics), Professor, Professor at the Department of Applied Mathematics and Data Analysis, School of Space and Information Technologies, Siberian Federal University, Krasnoyarsk, Russia; *ORCID*: <https://orcid.org/0000-0001-8966-3633>; *e-mail*: mnoskov@sfu-kras.ru

Поступила в редакцию / Received: 18.01.23.

Поступила после рецензирования / Revised: 27.02.23.

Принята к печати / Accepted: 28.02.23.