

АНАЛИЗ ПРИМЕНЯЕМЫХ МЕТОДОВ ОБРАБОТКИ ОБРАЗОВАТЕЛЬНЫХ ДАННЫХ*

В последнее время наблюдается интерес к работе с большими данными, в том числе в области образования. Авторы данной статьи ставили перед собой задачу синтеза накопленного объема знаний, с целью выявления общих признаков, по которым можно определить будущие тренды развития области анализа образовательных данных. Для этого был проведен анализ применяемых методов в научных исследованиях образовательных данных, выполненных и опубликованных за последние 5 лет (с 2019 по 2023).

Полученные результаты показывают, что большая часть работ сосредоточена на определении индивидуальных образовательных траекторий и повышении успеваемости обучающихся. Пространство признаков, используемое в исследованиях, формируется как из внутренних университетских систем поддержки учебного процесса, так и внешних образовательных онлайн-платформ.

Ключевые слова: Базы данных, анализ образовательных данных, educational data mining, EDM, машинное обучение, успеваемость обучающихся.

Kunts E.Yu., Lozhnikov P.S., Rubleva E.S.

ANALYSIS OF APPLIED METHODS OF EDUCATIONAL DATA PROCESSING

Recently, there has been an interest in working with big data, including in the field of education. The authors of this article set themselves the task of synthesizing the accumulated amount of knowledge in order to identify common features by which future trends in the development of the field of educational data analysis can be determined. For this purpose, an analysis of the methods used in research works carried out and published over the past 5 years (from 2019 to 2023) in the field of educational data analysis was carried out.

The results obtained show that most of the work is focused on determining individual educational trajectories and improving students' academic performance. The feature space used in research is formed from both internal university systems for supporting the educational process and external online educational platforms.

Keywords: Databases, analysis of educational data, education data mining, EDM, machine learning, student performance.

* Работа выполнена в ОмГТУ, в рамках государственного задания Минобрнауки России на 2023-2025 годы (FSGF-2023-0004)

Введение

В связи с появлением электронных информационно-образовательных сред (ЭИОС) и возросшему интересу к дистанционному образованию, стали появляться исследования и решения, нацеленные на анализ образовательного «следа», генерируемого участниками в процессе обучения. Сформировалось целое научное направление «Educational data mining» (EDM), где анализируются данные для принятия различных решений в сфере образования.

На данный момент отсутствуют универсальные ЭИОС, как коробочные программные продукты, способные делать соответствующие прогнозы для участников образовательного процесса. На практике анализ образовательных данных, как правило, осуществляется с помощью специально разработанных фреймворков, которые агрегируют данные, обрабатывают их и выдают определенные отчеты. Об этом свидетельствуют научные работы, проанализированные авторами данного исследования с целью выявить тренды используемых наборов данных (образовательных следов) и принимаемых решений на их основе.

На современном этапе трансформации сферы образования данное исследование показывает тренды в развитии EDM, а также может быть полезно для разработчиков ЭИОС в вопросах развития функционала образовательных платформ.

Классификация применяемых методов для анализа образовательных данных

По направлению EDM проанализированы 29 научных работ зарубежных и российских исследователей. При отборе публикаций авторы опирались на определенный подход к структурированию. Во-первых, в них должна быть четко выделена цель анализа образовательных данных. Во-вторых, описываться источники образовательного следа, а также процесс сбора и подготовки данных. Также особый интерес представляли обоснование выбора и применение конкретных методов и алгоритмов обработки данных.

Анализ показал, что по характеру целей все рассматриваемое множество научных работ можно разделить на две группы:

1) *Построение индивидуальных траекторий.* С данной целью инициируется много исследований. Актуальность данной темы в последнее время связана с решением задачи по индивидуализации обучения, с подбором

подходящих курсов и других инструментов, учитывающих личные достижения и предположенности каждого студента. Для рассмотрения было взято 14 статей, половина из которых написана отечественными авторами.

2) *Повышение успеваемости обучающихся.* Сформулированная таким образом цель также включает в себя снижение уровня отчисленных студентов. Зачастую это осуществляется через исследование прошлого опыта обучения студентов и прогнозирование на его основе будущих достижений. Данная цель может быть как самостоятельным направлением исследований, так и являться частью общей задачи при построении индивидуальных образовательных траекторий. По данному направлению можно назвать 15 статей из 29 исследуемых.

Далее рассмотрим детально каждую из этих групп (табл. 1, табл. 2), с выделением источников данных, метрик и алгоритмов, используемых при расчетах. Также, если это было указано в исходных публикациях, в таблицах отмечался наилучший из рассматриваемых алгоритмов.

Обращаясь к проведенному выше анализу, можно сделать выводы относительно источников образовательных данных. Выделяются три основных способа получения образовательных данных – из ЭИОС университетов (16 публикаций из отобранных 29), с онлайн-платформ, где реализуются массовые открытые онлайн курсы (MOOC) (8 публикаций из отобранных 29), а также синтетические данные. Первый способ заключается в том, что наборы данных консолидируются из разных информационных систем университета и являются более сопоставимыми с временным периодом за несколько лет. Для решения задач по проектированию индивидуальных образовательных траекторий в некоторых работах используются синтетические данные, сгенерированные специально для проверки гипотез (5 публикаций из отобранных 29).

Относительно алгоритмов, применяемых в научных исследованиях по EDM можно сделать вывод, что для построения индивидуальных траекторий большую популярность имеют нейронные сети, упоминаемые в четырех работах, также сети долгой краткосрочной памяти, используемые в трех работах. Для решения задач повышения успеваемости обучающихся чаще используется метод опорных векторов, применяемый в шести работах, и алгоритм ближайших соседей – в четырех работах.

Обзор работ по направлению «Повышение успеваемости обучающихся»

Статья	Год	Алгоритмы и методы	Лучший алгоритм	Метрики	Источники данных
1	2	3	4	5	6
[5]	2020	Линейная регрессия, нейронные сети, метод опорных векторов, наивный Байес	Нейронная сеть	Точность, полнота, F1-метрика	Электронная среда университета принцессы Нуры бинт Абдулрахман (2039 записей)
[7]	2022	Литературный обзор	–	Процент цитирования – локальный и глобальный, наибольшая релевантность связей	Статьи с платформы “Web of Science”
[8]	2021	Скрытая марковская модель, Иерархическая кластеризация (АНС) основанная на алгоритме Уорда	Иерархическая кластеризация (АНС) основанная на алгоритме Уорда	Среднее значение, медиана	Платформа Moodle LMS (87,805 записей) и журналы ATT (39,933 записей)
[9]	2020	Двумерные LPT +, Алгоритм GSP	Алгоритм GSP	Точность, средне-оборотный ранг	Данные с предсказаниями от экспертов (1,099 от 43 преподавателей)
[14]	2019	Алгоритм ближайших соседей, метод опорных векторов, дерево решений	Алгоритм адаптации	Доля ошибочных метрик, точность, полнота, F1-метрика, AUC, время вычисления	ЭИОС (суммарно 1 657 956, из 8 датасетов)
[16]	2020	Алгоритм ближайших соседей, метод опорных векторов, древо решений, регрессия	Регрессия	Для регрессии: Среднеквадратичная ошибка, нормализованная среднеквадратичная ошибка. Для классификации: Точность, полнота, F1-метрика	Электронная среда университета Бабеша – Бойа, Румыния
[17]	2022	Кластеризация, обучение ассоциативным правилам через алгоритмы Elbow и МК-среднее	Алгоритмы Elbow и МК-среднее	Минимальная верхняя граница	Данные с образовательной онлайн платформы “Aizu Online Judge” (70 тыс. записей от 537 студентов)
[18]	2022	Алгоритм ближайших соседей, метод опорных векторов, метод роя частиц	Метод роя частиц	Точность, время вычисления	Тренировочные данные с платформы “The Kaggle”
[19]	2020	Кластеризация, классификация, метод опорных векторов	Метод опорных векторов	Точность оценки отчислений	Из 5 электронных сред университетов Евросоюза (21000 записи)
[24]	2021	Качественные методы исследования	Система поддержки принятия решений	Корреляция, дисперсия, ошибка	Данные с образовательной онлайн платформы “International Writing Centers Association” (222 респондента)

1	2	3	4	5	6
[26]	2022	Кластеризация (метод К-средних), алгоритм Байеса, глубокое обучение, сверточные нейронные сети	Метод К-средних, сверточные нейронные сети	Точность, полнота	Данные, собранные из электронной среды университета и поделенные на три датасета: А(46 человек), В(51 человек), С(51 человек)
[3]	2021	Многослойный перцептрон Румельхарта, сети долгой краткосрочной памяти, комбинированные сети долгой краткосрочной памяти с многослойным перцептроном	Комбинированные сети долгой краткосрочной памяти с многослойным перцептроном	Средняя абсолютная ошибка, среднекв. ошибка, R2	Электронная среда университета БИНУС (46670 студентов)
[33]	2023	Обработка и сбор образовательных данных	Метод сбора информации	Минимум, максимум, медиана	Электронная среда технологического университета, Мексика
[34]	2022	Анализ тональности текста, дерево решений, глубокое обучение	Алгоритм глубокого мультимодального слияния данных	Точность, полнота, AUC-метрика (F1-метрика).	Данные с платформ массовых открытых онлайн курсов

Таблица 2

Обзор работ по направлению «Проектирование индивидуальных траекторий»

Статья	Год	Алгоритмы и методы	Лучший алгоритм	Метрики	Источники данных
1	2	3	4	5	6
[2]	2020	Анализ тональности текста, сети долгой краткосрочной памяти, мульти-AFM модель	Мульти-AFM	Точность, полнота, F1-метрика	Данные с онлайн - платформ "Scopus", "Web of Science", "Google Scholar"
[4]	2021	Дерево решений, Nadoor кластеризация	Дерево решений	Поддержка, уверенность	Электронная среда университета Умм аль-Кура, Саудовская Аравия
[6]	2020	Дерево решений, случайный лес, градиентный бустинг, логистическая регрессия, метод опорных векторов, к-ближайших соседей	Градиентный бустинг	Точность, F1-метрика	Электронная среда испанского университета, направление «Информационные технологии»
[10]	2020	Обработка естественного языка	Обработка естественного языка	F1-метрика	Данные с электронных сред "Австралийский Католический университет" (1940 записей), "Австралийский национальный университет" (2029 записей), Университет Бонда (651)

1	2	3	4	5	6
[11]	2019	Нейронная сеть (Самоорганизующаяся карта Кохонена)	Самоорганизующаяся карта Кохонена	Ошибка карты	Данные с онлайн платформы "The Workshop on Digital Game Production"
[12]	2022	Цепи Маркова, иерархические модели	-	медиана	Данные с электронной среды университета "Саутистерн"
[13]	2018	Условное случайное поле, сети долгой краткосрочной памяти, рекуррентные нейронные сети	Сети долгой краткосрочной памяти	Точность, полнота, F1-метрика	Данные с электронной среды университета "Пекинский педагогический университет"
[31]	2021	Многослойный перцептрон Румельхарта, сети долгой краткосрочной памяти, комбинированные сети долгой краткосрочной памяти с многослойным перцептроном	Комбинированные сети долгой краткосрочной памяти с многослойным перцептроном	Среднеквадратическая ошибка, средняя абсолютная ошибка, оценка R2	Данные с электронной среды университета "Бина Нусантара"
[35]	2020	Основанная на плотности пространственная кластеризация для приложений с шумами	Основанная на плотности пространственная кластеризация для приложений с шумами	Средний балл, общий балл, точность	Данные с электронной среды университета "Шаньдунский женский университет"
[36]	2023	Количественный анализ	-	Минимум, среднее значение, медиана, максимум	Данные с электронной среды Монтеррейского института технологий и высшего образования
[37]	2020	Прогнозирование временных рядов, авторегрессионная модель	Прогнозирование временных рядов	Коэффициент корреляции	Данные с электронной среды Пекинской муниципальной комиссии по образованию Китая
[38]	2022	Анализ тональности текста, нейросетевая модель мультимодального распознавания, concat	concat	Точность, полнота, F1-метрика	Синтетические данные
[39]	2020	Нейронные сети	Нейронные сети	Средний балл, моделируемые данные	Синтетические данные
[40]	2022	Вектор значений GF	Вектор значений GF	Концепты C, множество правил R	Синтетические данные
[41]	2019	Адаптивный поиск, графовые модели	Графовые модели	Оценка качества семантического сопоставления отдельных сущностей	Синтетические данные




Рис. 1. Распределение публикаций по характеру целей исследования

Среди используемых метрик наиболее чаще всего упоминаются: точность – двенадцать работ, полнота – восемь работ, F1-метрика – девять работ, медиана, время вычислений и среднеквадратичная ошибка – по две работы на каждую.

Далее рассмотрим содержание образовательных данных, используемых в работах. Полученные из ЭИОС университетов образовательные данные, в основном, представляют собой оценки, отметки посещаемости, завершенные дисциплины, сформированные компетенции, приоритеты в изучении и т.д. Также некоторые ученые в качестве предмета исследований использовали персональные данные студентов, такие как: пол, возраст, личные качества и прочие демографические показатели. Платформы онлайн-курсов предоставляют данные об оценках слушателей, справочную информацию о курсе, журнал событий при прохождении курса. На основе образовательного следа делаются выводы об успешности освоения курса, а по оставленным комментариям находятся сложные темы и проблемные точки в обучении. Помимо вышеописанного, с платформ онлайн-курсов можно получить данные о потоках посещений записей блога, которые можно разделить на две категории:

1) журнал просмотра страниц (запросы, просмотры, активные дни на образовательной площадке);

2) журнал видеолекций (запросы, просмотры, количество старт-стопов, повторных прослушиваний).

В случае применения смешанного обучения образовательные данные поступают из

нескольких источников и улучшают прогнозирование. Подобными источниками можно считать: контекст из электронных писем, системы групповой работы над проектами, просмотры файлов в различных хранилищах, а также системы оценивания знаний.

Среди наиболее часто встречаемых задач машинного обучения, которые решаются соответствующими методами в EDM, можно выделить следующие:

1) *Классификация* – это метод, который сегментирует данные по целевым категориям и классам с целью предсказания каждого случая в данных. В секторе образования используется для классификации участников на основе каких-либо показателей – оценки, знания, возраст, достижения, личные качества, прочие характеристики.

2) *Кластерный анализ* используют для разделения похожих данных на ранее неопределенные кластеры. Данный анализ используется для выявления сходств и различий между различными группами (студенты, преподаватели, предметы из образовательной программы).

3) *Прогнозирование* связано с выявлением закономерностей и выдвигаемыми на их основе предположениям об определенных событиях. В образовательном секторе он используется для прогнозирования успеваемости учащихся, прогнозирования зачисленных обучающихся, прогнозирования итоговой оценки, предсказание отсева и т.д.

Из наиболее популярных методов, которые применяются в EDM можно выделить следующие:

1) *Метод линейной регрессии* для нахож-

дения независимых связей ([22], [26]). С помощью данного метода можно отследить влияние одной или нескольких независимых переменных на зависимую.

2) *Нейронные сети*. Этот метод используется для решения множества задач. К примеру, в работе [13] их применяют для извлечения учебных понятий, после чего вводят вероятностную ассоциацию для идентификации предварительных отношений. Подобная идея, помимо нейронной сети, может для реализации воспользоваться алгоритмом маркировки нейронной последовательности.

Применение нейронной сети также можно наблюдать в работе [28], где авторы доказали, что сбор данных о студентах (демографические показатели, успеваемость и т.д.) может быть использован для снижения риска отчислений.

Еще одна вариативность использования нейронных сетей указана в работе [3], где предложена модель глубокого обучения с двойным входом, способная одновременно обрабатывать как табличные данные, так и временные ряды, улучшая тем самым производительность студенческой модели GPA.

Стоит также отметить сети долгой краткосрочной памяти, являющиеся разновидностью архитектуры рекуррентных нейронных сетей, способных обучению долговременным зависимостям. Данные сети могут фокусироваться как на глобальных, так и на локальных переменных. Основной смысл заключается в выделении нужных слов в исследуемом предложении, которые в дальнейшем можно применять при построении моделей прогнозирования.

3) *Метод обучения ассоциативным правилам* используются для обнаружения одновременного появления элементов в коллекции. Метод предлагается для установления новых правил по мере анализа дополнительных данных. В EDM данный метод может быть использован для введения новых курсов, а также для обнаружения абстрактных ассоциаций из новых неклассифицированных данных.

К примеру, в [17] после первоначальной обработки данных и применения к ним алгоритмов кластеризации, из кластеров извлекали статистические признаки и использовали их для поиска закономерностей. Найденные закономерности применялись как основа для системы принятия решений.

4) *Дерево решений* применяется как сред-

ство поддержки принятия решений. По структуре представляет собой «ветки» - признаки, от которых зависит целевая функция и «листья» со значением целевой функции. Для классификации необходимо спуститься до определенного листа и выдать соответствующее ему значение.

В работе [14] для адаптации к потоковой среде в качестве модели дерева решений использовалось дерево Хеффдинга, что генерирует дерево решений поэтапно. Теоретический анализ показывает, что пошаговое изучение дерева решений по частичным экземплярам приблизительно соответствует пакетному изучению дерева решений по всем экземплярам в потоке данных. Также авторами данной работы рассматривалось применение инкрементального структурированного дерева прогнозирования выходных данных. В нем базовые классификаторы в листьях используют адаптивное восприятие, которое позволяет решать как задачи классификации с несколькими метками, так и задачи многоцелевой регрессии.

5) *Метод опорных векторов*, разделяющий объекты на основе их классов. Применение можно увидеть в работе [20], где авторы спроектировали нейронную сеть для восстановления процесса преподавания с введением возможности сбора правил, определяющих корреляцию признаков в образовании. Использование метода опорных векторов позволило ускорить обработку аномальных записей в собранных данных и улучшить результаты за счет создания образа знаний.

6) *Метод наивного Байеса*, представляющий собой применение теоремы Байеса, с независимыми связями между переменными. Преимуществом данного метода служит обучение на малом объеме данных, которое также является достаточным для вынесения оценки параметров и классификации признаков. Метод может быть использован для предсказания успеваемости студентов [5].

7) *Метод анализа тональности текста*, предназначенный для автоматизированного выявления в текстах эмоционально окрашенной лексики и эмоциональной оценки авторов [2]. Основное применение можно увидеть в создании поведенческого портрета, обнаружении трудных для понимания тем и т.д.

Похожим методом пользовались исследователи [33], которые применили текстовый подход к анализу данных, с целью определе-

ния оценивания студентами преподавателей и собственной успеваемости. Анализ тональности осуществлялся посредством извлечения эмоциональной валентности испытываемых настроений при заполнении анкет.

Как и во многих областях, где собираются большие объемы данных, возникают проблемы конфиденциальности и этики при работе с большими образовательными данными. Авторы в [10] отмечают, что конфиденциальность и защита данных являются основными камнями преткновения для анализа образовательных данных. В связи с этим, ими было предложено три принципа, которых стоит придерживаться при использовании больших данных для построения систем принятия решений в этой области:

1) Конфиденциальность достигается путем согласования обмена данными с каждым учащимся;

2) Разъяснение студентам целей и результатов анализа данных;

3) Повышение грамотности учащихся в области персональных данных.

При создании системы принятия решений требуется определенный объем данных, который должен собираться при соблюдении соответствующих протоколов безопасности. Из-за сложности соблюдения правил, часть данных не передается из-за политики конфиденциальности. Скудость имеющихся данных затрудняет создание высоконадежных прогностических моделей или рекомендательных систем. К счастью, достижения в области интеллектуального анализа данных дают возможность применять широкий спектр приемов и методик, которые позволяют максимально эффективно использовать данные для получения знаний [6].

В работе [12] в целях обеспечения конфиденциальности личные и институциональные данные из набора «midfield» предварительно анонимизировались. Несмотря на то, что эти данные не являются пригодными для анализа успеваемости студентов, они будут полезны для изучения структуры данных, методов анализа и визуализации данных. [12]

Вопросы безопасности и конфиденциальности также рассматриваются в [19], где передача данных осуществлялась в зашифрованном виде по протоколу SSL, а файлы удалялись через 48 часов, соблюдая тем самым требования Европейского общего регламента по защите данных.

Также авторы отмечают, что агрегирова-

ние и обработка образовательных данных вызывает этические и юридические проблемы, поскольку набор данных включает демографические показатели. Для избежания этого, данные обезличиваются, благодаря чему исключается возможность идентификации отдельного лица.

В качестве существующих методов сохранения конфиденциальности авторы [21] указывают шифрование данных, ограниченную публикацию данных, искажение данных и т.д. Шифрование данных используется в процессе интеллектуального анализа данных для сокрытия конфиденциальных данных, которые часто используются в распределенных средах. Ограниченная публикация данных публикует определенную часть данных, обобщения или их анонимизации. Метод искажения данных, что видно из названия, искажает конфиденциальные данные, сохраняя при этом некоторый процент нетронутым, поверх добавляя шум, осуществляя обмен и рандомизацию, блокирование и т.д. Это может гарантировать, что обработанные данные все еще могут сохранять определенные статистические свойства для интеллектуального анализа данных.

Заключение

На данный момент сформирован первоначальный этап вовлечения исследователей в область EDM и определены основные направления исследований. Развитие научных работ и программных решений в данном направлении возможно за счет использования временных рядов с признаками из различных источников данных. Таким образом, можно выделить некоторые тренды, которые уже обозначились и прослеживаются в некоторых работах:

1) *Интеграция различных информационно-образовательных систем*, с целью создания единой модели (портрета) обучающегося [44].

2) *Эффективность изменений в индивидуальных образовательных траекториях*. Как правило, исследователи не могут в моменте оценить эффективность внесенных изменений в индивидуальные образовательные траектории студентов. Для решения данной задачи на текущем этапе развития данного направления, предлагается разделение данных на две выборки - контрольную и экспериментальную [45]. Изменения индивидуальных образовательных траекторий при этом производятся исключительно на экспе-

риментальную группу с целью доказательства положительного результата. Далее делаются сравнения со студентами из контрольной группы, для которых вмешательство не проводилось.

3) *Измерение вовлеченности студентов в процесс обучения.* Можно сказать, что данный тренд возможен при гибридных формах обучения. Задействуется инфраструктура университета, где в процессе учебных занятий собираются данные с видео камер [46]. Анализируется информация о мимике, фокусировании взгляда, положении тела для получения индекса концентрации обучающихся. После по индексу концентрации может быть измерена степень вовлеченности студентов, которая влияет в системе принятия решений.

4) *Измерение сформированности компетенций обучающихся.* Традиционные подходы оценки знаний и проверки навыков у студентов в образовательных организациях зачастую не соответствуют измерениям и ожиданиям их потенциальных работодателей. Возникает направление, связанное с постоянным мониторингом формирования у обучающихся актуальных компетенций для работодателя как заказчика [47, 48]. По этому направлению начинают появляться исследовательские работы в России, так как для университетов стоит остро задача по подготовке выпускников востребованных для реального сектора экономики.

Литература

1. O. Moscoso-Zea, J. Paredes-Gualtor and S. Luján-Mora, "A Holistic View of Data Warehousing in Education," in IEEE Access, vol. 6, pp. 64659-64673, 2018, doi: 10.1109/ACCESS.2018.2876753.
2. G. Zhai, Y. Yang, H. Wang and S. Du, "Multi-attention fusion modeling for sentiment analysis of educational big data," in Big Data Mining and Analytics, vol. 3, no. 4, pp. 311-319, Dec. 2020, doi: 10.26599/BDMA.2020.9020024.
3. H. Prabowo, A. A. Hidayat, T. W. Cenggoro, R. Rahutomo, K. Purwandari and B. Pardamean, "Aggregating Time Series and Tabular Data in Deep Learning Model for University Students' GPA Prediction," in IEEE Access, vol. 9, pp. 87370-87377, 2021, doi: 10.1109/ACCESS.2021.3088152.
4. A. A. Munshi and A. Alhindi, "Big Data Platform for Educational Analytics," in IEEE Access, vol. 9, pp. 52883-52890, 2021, doi: 10.1109/ACCESS.2021.3070737.
5. H. A. Mengash, "Using Data Mining Techniques to Predict Student Performance to Support Decision Making in University Admission Systems," in IEEE Access, vol. 8, pp. 55462-55470, 2020, doi: 10.1109/ACCESS.2020.2981905.
6. A. J. Fernández-García, R. Rodríguez-Echeverría, J. C. Preciado, J. M. C. Manzano and F. Sánchez-Figueroa, "Creating a Recommender System to Support Higher Education Students in the Subject Enrollment Decision," in IEEE Access, vol. 8, pp. 189069-189088, 2020, doi: 10.1109/ACCESS.2020.3031572.
7. C. Baek and T. Doleck, "Educational Data Mining: A Bibliometric Analysis of an Emerging Field," in IEEE Access, vol. 10, pp. 31289-31296, 2022, doi: 10.1109/ACCESS.2022.3160457.
8. S. López-Pernas and M. Saqr, "Bringing Synchrony and Clarity to Complex Multi-Channel Data: A Learning Analytics Study in Programming Education," in IEEE Access, vol. 9, pp. 166531-166541, 2021, doi: 10.1109/ACCESS.2021.3134844.
9. Y. -C. Norm Lien, W. -J. Wu and Y. -L. Lu, "How Well Do Teachers Predict Students' Actions in Solving an Ill-Defined Problem in STEM Education: A Solution Using Sequential Pattern Mining," in IEEE Access, vol. 8, pp. 134976-134986, 2020, doi: 10.1109/ACCESS.2020.3010168.
10. K. L. -M. Ang, F. L. Ge and K. P. Seng, "Big Educational Data & Analytics: Survey, Architecture and Challenges," in IEEE Access, vol. 8, pp. 116392-116414, 2020, doi: 10.1109/ACCESS.2020.2994561.
11. A. A. de Souza, T. S. Barcelos, R. Munoz, R. Villarroel and L. A. Silva, "Data Mining Framework to Analyze the Evolution of Computational Thinking Skills in Game Building Workshops," in IEEE Access, vol. 7, pp. 82848-82866, 2019, doi: 10.1109/ACCESS.2019.2924343.
12. S. M. Lord et al., "MIDFIELD: A Resource for Longitudinal Student Record Research," in IEEE Transactions on Education, vol. 65, no. 3, pp. 245-256, Aug. 2022, doi: 10.1109/TE.2021.3137086.
13. P. Chen, Y. Lu, V. W. Zheng, X. Chen and B. Yang, "KnowEdu: A System to Construct Knowledge Graph for Education," in IEEE Access, vol. 6, pp. 31553-31563, 2018, doi: 10.1109/ACCESS.2018.2839607.
14. X. Zheng, P. Li, Z. Chu and X. Hu, "A Survey on Multi-Label Data Stream Classification," in IEEE Access, vol. 8, pp. 1249-1275, 2020, doi: 10.1109/ACCESS.2019.2962059.

15. F. Fatima, R. Talib, M. K. Hanif and M. Awais, "A Paradigm-Shifting From Domain-Driven Data Mining Frameworks to Process-Based Domain-Driven Data Mining-Actionable Knowledge Discovery Framework," in *IEEE Access*, vol. 8, pp. 210763-210774, 2020, doi: 10.1109/ACCESS.2020.3039111.
16. G. Czibula, G. Ciubotariu, M. -I. Maier and H. Lisei, "IntelliDaM: A Machine Learning-Based Framework for Enhancing the Performance of Decision-Making Processes. A Case Study for Educational Data Mining," in *IEEE Access*, vol. 10, pp. 80651-80666, 2022, doi: 10.1109/ACCESS.2022.3195531.
17. M. M. Rahman, Y. Watanobe, T. Matsumoto, R. U. Kiran and K. Nakamura, "Educational Data Mining to Support Programming Learning Using Problem-Solving Data," in *IEEE Access*, vol. 10, pp. 26186-26202, 2022, doi: 10.1109/ACCESS.2022.3157288.
18. H. E. Abdelkader, A. G. Gad, A. A. Abohany and S. E. Sorour, "An Efficient Data Mining Technique for Assessing Satisfaction Level With Online Learning for Higher Education Students During the COVID-19," in *IEEE Access*, vol. 10, pp. 6286-6303, 2022, doi: 10.1109/ACCESS.2022.3143035.
19. M. Á. Prada et al., "Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees," in *IEEE Access*, vol. 8, pp. 212818-212836, 2020, doi: 10.1109/ACCESS.2020.3040858.
20. M. Á. Prada et al., "Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees," in *IEEE Access*, vol. 8, pp. 212818-212836, 2020, doi: 10.1109/ACCESS.2020.3040858.
21. L. Ni, C. Li, X. Wang, H. Jiang and J. Yu, "DP-MCDBSCAN: Differential Privacy Preserving Multi-Core DBSCAN Clustering for Network User Data," in *IEEE Access*, vol. 6, pp. 21053-21063, 2018, doi: 10.1109/ACCESS.2018.2824798.
22. Y. Yao, Z. Zhang, H. Cui, T. Ren and J. Xiao, "The Influence of Student Abilities and High School on Student Growth: A Case Study of Chinese National College Entrance Exam," in *IEEE Access*, vol. 7, pp. 148254-148264, 2019, doi: 10.1109/ACCESS.2019.2946503.
23. C. Qi and S. Liu, "Evaluating On-Line Courses via Reviews Mining," in *IEEE Access*, vol. 9, pp. 35439-35451, 2021, doi: 10.1109/ACCESS.2021.3062052.
24. K. Okoye, S. Hosseini, A. Arrona-Palacios and J. Escamilla, "Impact of Educational Coaching Programs and Mentoring Services on Users' Perception and Preferences: A Qualitative and Quantitative Approach," in *IEEE Access*, vol. 9, pp. 48105-48120, 2021, doi: 10.1109/ACCESS.2021.3069130.
25. B. Kim and G. Yi, "Location-Based Parallel Sequential Pattern Mining Algorithm," in *IEEE Access*, vol. 7, pp. 128651-128658, 2019, doi: 10.1109/ACCESS.2019.2939937.
26. G. Feng, M. Fan and Y. Chen, "Analysis and Prediction of Students' Academic Performance Based on Educational Data Mining," in *IEEE Access*, vol. 10, pp. 19558-19571, 2022, doi: 10.1109/ACCESS.2022.3151652.
27. T. Shaik et al., "A Review of the Trends and Challenges in Adopting Natural Language Processing Methods for Education Feedback Analysis," in *IEEE Access*, vol. 10, pp. 56720-56739, 2022, doi: 10.1109/ACCESS.2022.3177752.
28. S. Alwarthan, N. Aslam and I. U. Khan, "An Explainable Model for Identifying At-Risk Student at Higher Education," in *IEEE Access*, vol. 10, pp. 107649-107668, 2022, doi: 10.1109/ACCESS.2022.3211070.
29. D. A. Shafiq, M. Marjani, R. A. A. Habeeb and D. Asirvatham, "Student Retention Using Educational Data Mining and Predictive Analytics: A Systematic Literature Review," in *IEEE Access*, vol. 10, pp. 72480-72503, 2022, doi: 10.1109/ACCESS.2022.3188767.
30. X. Zhou, B. Sun, S. Li and S. Liu, "Tour Route Planning Algorithm Based on Precise Interested Tourist Sight Data Mining," in *IEEE Access*, vol. 8, pp. 153134-153168, 2020, doi: 10.1109/ACCESS.2020.3010420.
31. J. A. Lara, A. A. De Sojo, S. Aljawarneh, R. P. Schumaker and B. Al-Shargabi, "Developing Big Data Projects in Open University Engineering Courses: Lessons Learned," in *IEEE Access*, vol. 8, pp. 22988-23001, 2020, doi: 10.1109/ACCESS.2020.2968969.
32. Z. Shao, H. Sun, X. Wang and Z. Sun, "An Optimized Mining Algorithm for Analyzing Students' Learning Degree Based on Dynamic Data," in *IEEE Access*, vol. 8, pp. 113543-113556, 2020, doi: 10.1109/ACCESS.2020.3001749.
33. K. Okoye, S. D. N. Daruich, J. F. E. De La O, R. Castaño, J. Escamilla and S. Hosseini, "A Text Mining and Statistical Approach for Assessment of Pedagogical Impact of Students' Evaluation of Teaching and Learning Outcome in Education," in *IEEE Access*, vol. 11, pp. 9577-9596, 2023, doi: 10.1109/ACCESS.2023.3239779.
34. Y. Qu, F. Li, L. Li, X. Dou and H. Wang, "Can We Predict Student Performance Based on Tabular and Textual Data?" in *IEEE Access*, vol. 10, pp. 86008-86019, 2022, doi: 10.1109/ACCESS.2022.3198682.
35. Куприянов Р. Б., Использование технологий искусственного интеллекта для выстраивания индивидуальных образовательных траекторий обучающихся / Куприянов Р. Б., Агранат Д. Л., Сулейманов Р. С. // Вестник РУДН. Серия: Информатизация образования. - 2021. - №1.

36. Частикова В. А. Интеллектуальный анализ данных при построении индивидуальных образовательных траекторий / Частикова В. А., Псеуш А. Г. // Вестник Адыгейского государственного университета. Серия 4: Естественно-математические и технические науки. - 2021. - №2.
37. Дюличева Ю. Ю. Алгоритмы роевого интеллекта и их применение для анализа образовательных данных // Открытое образование. 2019. №5.
38. Тербушева Е. А., Аналитический потенциал платформы Moodle для мониторинга качества персонифицированного обучения / Тербушева Е. А., Пиотровская К. Р. // Terra Linguistica. - 2021. - №4.
39. Пономарева К. А. Применение искусственных нейронных сетей при решении задач прогнозирования // Наука без границ. 2020. №1 (41).
40. Углев В. А., Интеллектуальный анализ цифрового следа при оценке контрольно-измерительных материалов для поддержки принятия решений в образовательном процессе / Углев В. А., Сычев О. А., Аникин А. В. // Журнал СФУ. Техника и технологии. 2022. №1.
41. Ботов Д. С. Интеллектуальная поддержка формирования образовательных программ на основе нейросетевых моделей языка с учетом требований рынка труда // Вестник ЮУрГУ. Серия: Компьютерные технологии, управление, радиоэлектроника. - 2019. - №1.
42. Игнатович В. К., Понятие индивидуальных образовательных результатов учащихся в контексте индивидуализация процесса дополнительного образования детей / Игнатович В. К., Игнатович С. С. // Педагогика: история, перспективы. - 2019. - №2.
43. Горбунова Н. В., Реализация индивидуальных образовательных траекторий в вузе на основе персонализированного подхода/ Горбунова Н.В., Фетисов А. С. //Современная высшая школа: инновационный аспект. 2022. №2.
44. Baker, R.S.J.d., Corbett, A.T., Koedinger, K.R., Evenson, S.E., Roll, I., Wagner, A.Z., Naim, M., Raspat, J., Baker, D.J., Beck, J. (2006) Adapting to when students game an intelligent tutoring system. In Proceedings of the 8th International Conference on Intelligent Tutoring Systems, 392-401.
45. Baker R.S. Challenges for the Future of Educational Data Mining: The Baker Learning Analytics Prizes / Baker R.S.// Journal of Educational Data Mining, Volume 11, No 1, 2019.
46. Соловьев В. И., Мониторинг вовлеченности студентов в учебный процесс на основе анализа видеопотоков из аудиторий /Управление развитием крупномасштабных систем MLSD'2019. - 2019. DOI 10.25728/mlsd.2019.1.0553.
47. Кунц Е. Ю., Методика прогнозирования востребованности выпускников ИТ-направлений / Е. Ю. Кунц, П. С. Ложников, Е. С. Хазанская, А. А. Белых // Безопасность цифровых технологий. – 2022. – № 4(107). – С. 63-81. – DOI 10.17212/2782-2230-2022-4-63-81. – EDN YVMRSV.
48. Кунц Е.А., Компетентностной модели образовательной программы для принятия управленческих решений в образовательной организации /Кунц Е.А., Ложников П.С. // Прикаспийский журнал: управление и высокие технологии. 2022. №2 (58).

References

1. O. Moscoso-Zea, J. Paredes-Gualtor and S. Luján-Mora, "A Holistic View of Data Warehousing in Education," in IEEE Access, vol. 6, pp. 64659-64673, 2018, doi: 10.1109/ACCESS.2018.2876753.
2. G. Zhai, Y. Yang, H. Wang and S. Du, "Multi-attention fusion modeling for sentiment analysis of educational big data," in Big Data Mining and Analytics, vol. 3, no. 4, pp. 311-319, Dec. 2020, doi: 10.26599/BDMA.2020.9020024.
3. H. Prabowo, A. A. Hidayat, T. W. Cenggoro, R. Rahutomo, K. Purwandari and B. Pardamean, "Aggregating Time Series and Tabular Data in Deep Learning Model for University Students' GPA Prediction," in IEEE Access, vol. 9, pp. 87370-87377, 2021, doi: 10.1109/ACCESS.2021.3088152.
4. A. A. Munshi and A. Alhindi, "Big Data Platform for Educational Analytics," in IEEE Access, vol. 9, pp. 52883-52890, 2021, doi: 10.1109/ACCESS.2021.3070737.
5. H. A. Mengash, "Using Data Mining Techniques to Predict Student Performance to Support Decision Making in University Admission Systems," in IEEE Access, vol. 8, pp. 55462-55470, 2020, doi: 10.1109/ACCESS.2020.2981905.
6. A. J. Fernández-García, R. Rodríguez-Echeverría, J. C. Preciado, J. M. C. Manzano and F. Sánchez-Figueroa, "Creating a Recommender System to Support Higher Education Students in the Subject Enrollment Decision," in IEEE Access, vol. 8, pp. 189069-189088, 2020, doi: 10.1109/ACCESS.2020.3031572
7. C. Baek and T. Doleck, "Educational Data Mining: A Bibliometric Analysis of an Emerging Field," in IEEE Access, vol. 10, pp. 31289-31296, 2022, doi: 10.1109/ACCESS.2022.3160457.
8. S. López-Pernas and M. Saqr, "Bringing Synchrony and Clarity to Complex Multi-Channel Data: A Learning Analytics Study in Programming Education," in IEEE Access, vol. 9, pp. 166531-166541, 2021, doi: 10.1109/ACCESS.2021.3134844.

9. Y. -C. Norm Lien, W. -J. Wu and Y. -L. Lu, "How Well Do Teachers Predict Students' Actions in Solving an Ill-Defined Problem in STEM Education: A Solution Using Sequential Pattern Mining," in IEEE Access, vol. 8, pp. 134976-134986, 2020, doi: 10.1109/ACCESS.2020.3010168.
10. K. L. -M. Ang, F. L. Ge and K. P. Seng, "Big Educational Data & Analytics: Survey, Architecture and Challenges," in IEEE Access, vol. 8, pp. 116392-116414, 2020, doi: 10.1109/ACCESS.2020.2994561.
11. A. A. de Souza, T. S. Barcelos, R. Munoz, R. Villarroel and L. A. Silva, "Data Mining Framework to Analyze the Evolution of Computational Thinking Skills in Game Building Workshops," in IEEE Access, vol. 7, pp. 82848-82866, 2019, doi: 10.1109/ACCESS.2019.2924343.
12. S. M. Lord et al., "MIDFIELD: A Resource for Longitudinal Student Record Research," in IEEE Transactions on Education, vol. 65, no. 3, pp. 245-256, Aug. 2022, doi: 10.1109/TE.2021.3137086.
13. P. Chen, Y. Lu, V. W. Zheng, X. Chen and B. Yang, "KnowEdu: A System to Construct Knowledge Graph for Education," in IEEE Access, vol. 6, pp. 31553-31563, 2018, doi: 10.1109/ACCESS.2018.2839607.
14. X. Zheng, P. Li, Z. Chu and X. Hu, "A Survey on Multi-Label Data Stream Classification," in IEEE Access, vol. 8, pp. 1249-1275, 2020, doi: 10.1109/ACCESS.2019.2962059.
15. F. Fatima, R. Talib, M. K. Hanif and M. Awais, "A Paradigm-Shifting From Domain-Driven Data Mining Frameworks to Process-Based Domain-Driven Data Mining-Actionable Knowledge Discovery Framework," in IEEE Access, vol. 8, pp. 210763-210774, 2020, doi: 10.1109/ACCESS.2020.3039111.
16. G. Czibula, G. Ciubotariu, M. -I. Maier and H. Lisei, "IntelliDaM: A Machine Learning-Based Framework for Enhancing the Performance of Decision-Making Processes. A Case Study for Educational Data Mining," in IEEE Access, vol. 10, pp. 80651-80666, 2022, doi: 10.1109/ACCESS.2022.3195531.
17. M. M. Rahman, Y. Watanobe, T. Matsumoto, R. U. Kiran and K. Nakamura, "Educational Data Mining to Support Programming Learning Using Problem-Solving Data," in IEEE Access, vol. 10, pp. 26186-26202, 2022, doi: 10.1109/ACCESS.2022.3157288.
18. H. E. Abdelkader, A. G. Gad, A. A. Abohany and S. E. Sorour, "An Efficient Data Mining Technique for Assessing Satisfaction Level With Online Learning for Higher Education Students During the COVID-19," in IEEE Access, vol. 10, pp. 6286-6303, 2022, doi: 10.1109/ACCESS.2022.3143035.
19. M. Á. Prada et al., "Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees," in IEEE Access, vol. 8, pp. 212818-212836, 2020, doi: 10.1109/ACCESS.2020.3040858.
20. M. Á. Prada et al., "Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees," in IEEE Access, vol. 8, pp. 212818-212836, 2020, doi: 10.1109/ACCESS.2020.3040858.
21. L. Ni, C. Li, X. Wang, H. Jiang and J. Yu, "DP-MCDBSCAN: Differential Privacy Preserving Multi-Core DBSCAN Clustering for Network User Data," in IEEE Access, vol. 6, pp. 21053-21063, 2018, doi: 10.1109/ACCESS.2018.2824798.
22. Y. Yao, Z. Zhang, H. Cui, T. Ren and J. Xiao, "The Influence of Student Abilities and High School on Student Growth: A Case Study of Chinese National College Entrance Exam," in IEEE Access, vol. 7, pp. 148254-148264, 2019, doi: 10.1109/ACCESS.2019.2946503.
23. C. Qi and S. Liu, "Evaluating On-Line Courses via Reviews Mining," in IEEE Access, vol. 9, pp. 35439-35451, 2021, doi: 10.1109/ACCESS.2021.3062052.
24. K. Okoye, S. Hosseini, A. Arrona-Palacios and J. Escamilla, "Impact of Educational Coaching Programs and Mentoring Services on Users' Perception and Preferences: A Qualitative and Quantitative Approach," in IEEE Access, vol. 9, pp. 48105-48120, 2021, doi: 10.1109/ACCESS.2021.3069130.
25. B. Kim and G. Yi, "Location-Based Parallel Sequential Pattern Mining Algorithm," in IEEE Access, vol. 7, pp. 128651-128658, 2019, doi: 10.1109/ACCESS.2019.2939937.
26. G. Feng, M. Fan and Y. Chen, "Analysis and Prediction of Students' Academic Performance Based on Educational Data Mining," in IEEE Access, vol. 10, pp. 19558-19571, 2022, doi: 10.1109/ACCESS.2022.3151652.
27. T. Shaik et al., "A Review of the Trends and Challenges in Adopting Natural Language Processing Methods for Education Feedback Analysis," in IEEE Access, vol. 10, pp. 56720-56739, 2022, doi: 10.1109/ACCESS.2022.3177752.
28. S. Alwarthan, N. Aslam and I. U. Khan, "An Explainable Model for Identifying At-Risk Student at Higher Education," in IEEE Access, vol. 10, pp. 107649-107668, 2022, doi: 10.1109/ACCESS.2022.3211070.
29. D. A. Shafiq, M. Marjani, R. A. A. Habeeb and D. Asirvatham, "Student Retention Using Educational Data Mining and Predictive Analytics: A Systematic Literature Review," in IEEE Access, vol. 10, pp. 72480-72503, 2022, doi: 10.1109/ACCESS.2022.3188767.
30. X. Zhou, B. Sun, S. Li and S. Liu, "Tour Route Planning Algorithm Based on Precise Interested Tourist Sight Data Mining," in IEEE Access, vol. 8, pp. 153134-153168, 2020, doi: 10.1109/ACCESS.2020.3010420.

31. J. A. Lara, A. A. De Sojo, S. Aljawarneh, R. P. Schumaker and B. Al-Shargabi, "Developing Big Data Projects in Open University Engineering Courses: Lessons Learned," in IEEE Access, vol. 8, pp. 22988-23001, 2020, doi: 10.1109/ACCESS.2020.2968969.
32. Z. Shao, H. Sun, X. Wang and Z. Sun, "An Optimized Mining Algorithm for Analyzing Students' Learning Degree Based on Dynamic Data," in IEEE Access, vol. 8, pp. 113543-113556, 2020, doi: 10.1109/ACCESS.2020.3001749.
33. K. Okoye, S. D. N. Daruich, J. F. E. De La O, R. Castaño, J. Escamilla and S. Hosseini, "A Text Mining and Statistical Approach for Assessment of Pedagogical Impact of Students' Evaluation of Teaching and Learning Outcome in Education," in IEEE Access, vol. 11, pp. 9577-9596, 2023, doi: 10.1109/ACCESS.2023.3239779.
34. Y. Qu, F. Li, L. Li, X. Dou and H. Wang, "Can We Predict Student Performance Based on Tabular and Textual Data?" in IEEE Access, vol. 10, pp. 86008-86019, 2022, doi: 10.1109/ACCESS.2022.3198682.
35. Kupriyanov R. B., Agranat D. L., Sulejmanov R. S. Ispol'zovanie tekhnologij iskusstvennogo intellekta dlya vystraivaniya individual'nyh obrazovatel'nyh traektorij obuchayushchihya [The use of artificial intelligence technologies to build individual educational trajectories of students]. Vestnik RUDN. Seriya: Informatizatsiya obrazovaniya, 2021. no. 1.
36. Chastikova V. A., Pseush A. G. Intellektual'nyj analiz dannyh pri postroenii individual'nyh obrazovatel'nyh traektorij [Data Intelligent Analysis in the Construction of Individual Educational Trajectories]. Vestnik Ady-geskogo gosudarstvennogo universiteta. Seriya 4: Estestvenno-matematicheskie i tekhnicheskie nauki, 2021, no. 2.
37. Dyulicheva Yu. Yu. Algoritmy roevogo intellekta i ih primenenie dlya analiza obrazovatel'nyh dannyh [Algorithms of swarm intelligence and their application for analysis of educational data]. Otkrytoe obrazovanie, 2019, no. 5.
38. Terbusheva E. A., Piotrovskaya K. R. Analiticheskij potencial platformy Moodle dlya monitoringa kachestva personalizirovannogo obucheniya [Analytical potential of the Moodle platform for monitoring the quality of personalized learning]. Terra Linguistica., 2021, no. 4.
39. Ponomareva K. A. Primenenie iskusstvennyh neyronnyh setej pri reshenii zadach prognozirovaniya [Application of artificial neural networks in solving problems of forecasting]. Nauka bez granic, 2020, no. 1 pp, 41.
40. Uglev V. A., Sychev O. A., Anikin A. V. Intellektual'nyj analiz cifrovogo sleda pri ocenke kontrol'no-izmeritel'nyh materialov dlya podderzhki prinyatiya reshenij v obrazovatel'nom processe [Intelligent analysis of the digital footprint in the evaluation of control and measuring materials to support decision making in the educational process]. Zhurnal SFU. Tekhnika i tekhnologii, 2022, no. 1.
41. Botov D. S. Intellektual'naya podderzhka formirovaniya obrazovatel'nyh programm na osnove nejrosetevykh modelej yazyka s ucheto trebovanij rynka truda [Intellectual support of formation of educational programs on the basis of neuronetwork models of language taking into account the requirements of the labor market]. Vestnik YUUrGU. Seriya: Komp'yuternye tekhnologii, upravlenie, radioelektronika, 2019, no. 1.
42. Ignatovich V. K., Ignatovich S. S. Ponyatie individual'nyh obrazovatel'nyh rezul'tatov uchashchihya v kontekste individualizatsiya processa dopolnitel'nogo obrazovaniya detej [Concept of individual educational results of students in the context of individualization of the process of additional education of children]. Pedagogika: istoriya, perspektivy, 2019, no. 2.
43. Gorbunova N.V., Fetisov A. S. Realizatsiya individual'nyh obrazovatel'nyh traektorij v vuze na osnove personalizirovannogo podhoda [Implementation of individual educational trajectories in the university on the basis of personalized approach. Sovremennaya vysshaya shkola: innovatsionnyj aspekt, 2022, no. 2.
44. Baker, R.S.J.d., Corbett, A.T., Koedinger, K.R., Evenson, S.E., Roll, I., Wagner, A.Z., Naim, M., Raspat, J., Baker, D.J., Beck, J. (2006) Adapting to when students game an intelligent tutoring system. In Proceedings of the 8th International Conference on Intelligent Tutoring Systems, 392-401.
45. Baker R.S. Challenges for the Future of Educational Data Mining: The Baker Learning Analytics Prizes / Baker R.S.// Journal of Educational Data Mining, Volume 11, No 1, 2019.
46. Solov'ev V. I., Monitoring vovlechenosti studentov v uchebnyj process na osnove analiza videopotokov iz auditorij [Monitoring of students' involvement in the learning process based on the analysis of video streams from classrooms]. Upravlenie razvitiem krupnomasshtabnyh sistem MLS D'2019. - 2019. DOI 10.25728/mlsd.2019.1.0553.
47. Kunts E. Yu., Lozhnikov P. S., Kazanskaya E. S., Belykh A. A., Metodika prognozirovaniya vstrebovannosti vypusknikov IT-napravlenij [Methodology for predicting the demand for graduates of IT directions]. Bezopasnost' cifrovyyh tekhnologij, 2022, no. 4 (107), pp. 63-81, DOI 10.17212/2782-2230-2022-4-63-81.
48. Kunts E.Yu., Lozhnikov P.S. Kompetentnostnoj modeli obrazovatel'noj programmy dlya prinyatiya upravlencheskih reshenij v obrazovatel'noj organizatsii [Competence model of an educational program for

КУНЦ Екатерина Юрьевна, начальник отдела дистанционного обучения, Сибирский государственный университет телекоммуникаций и информатики. 630102, г. Новосибирск, ул. Кирова, 86. E-mail: kuntsey@sibguti.ru

KUNTS Ekaterina Yurievna, Head of Distance Learning Department in Siberian State University of Telecommunications and Informatics. 630102, Novosibirsk, Kirova str. 86. E-mail: kuntsey@sibguti.ru

ЛОЖНИКОВ Павел Сергеевич, доктор технических наук, профессор, заведующий кафедрой "Комплексная защита информации", Омский государственный технический университет. 644050, г. Омск, пр. Мира, 11. E-mail: Lozhnikov@mail.ru

LOZHNIKOV Pavel Sergeevich, Doctor of Technical Sciences, Professor, Head of Information Security Department, of Omsk State Technical University. 644050, Omsk, Mira Ave., 11. E-mail: Lozhnikov@mail.ru

РУБЛЕВА Екатерина Сергеевна, аспирант, Омский государственный технический университет. 644050, г. Омск, пр. Мира, 11. E-mail: kledjer@gmail.com

RUBLEVA Ekaterina Sergeevna, postgraduate student of Omsk State Technical University. 644050, Omsk, Mira Ave., 11. E-mail: kledjer@gmail.com