

УДК 004.852, 004.67

DOI: 10.18799/24131830/2023/12/4253

Шифр специальности ВАК: 2.4.2

Прогнозирование почасовой выработки электроэнергии солнечной электростанцией с помощью алгоритмов машинного обучения

А.Д. Моргоева^{1✉}, И.Д. Моргоев¹, Р.В. Ключев², С.С. Кочковская³

¹ Северо-Кавказский горно-металлургический институт
(государственного технологического университета), Россия, г. Владикавказ

² Московский политехнический университет, Россия, г. Москва

³ Оренбургский государственный университет, Россия, г. Оренбург

✉ m.angelika-m@yandex.ru

Аннотация

Актуальность исследования заключается в необходимости развития энергосберегающих подходов за счет применения средств интеллектуального анализа данных для повышения эффективности процесса принятия управленческих решений и, как следствие, более оптимального использования энергетических ресурсов. В частности, прогнозирование величины выработки электрической энергии солнечной электростанцией позволит повысить обоснованность решений, принимаемых в процессе управления распределением электроэнергии в децентрализованных системах. При наличии информации о том, сколько электроэнергии будет выработано солнечной электростанцией и передано в сеть в каждый час суток, появится возможность более обоснованно планировать использование выработанной электроэнергии и ее распределение. Также наличие достоверного прогноза позволит встраивать математическую модель в подсистему управления микросетями, что, в свою очередь, будет способствовать интеграции централизованных электрических сетей и объектов распределенной генерации. На практике для реализации прогнозирования не всегда подходят существующие методы расчета выработки электроэнергии солнечными электростанциями по техническим характеристикам оборудования солнечных электростанций. Кроме того, нет стандартов по использованию метеорологических и других факторов при создании прогнозных моделей. Поэтому исследование носит междисциплинарный характер, сочетая в себе важную практическую значимость и выработку новых рекомендаций в части применения алгоритмов машинного обучения, а также учета метеорологических факторов в прогнозных моделях. **Целью** исследования является повышение обоснованности перспективного планирования объемов выработки электрической энергии объектом альтернативной энергетики (солнечной электростанцией). **Объекты:** солнечная электростанция им А.А. Влазнева (Сакмарская СЭС), расположенная в Оренбургской области, г. Орск, Октябрьский район, географические координаты: 51.266023 с.ш, 58.474689 з.д. **Методы:** аналитический метод, методы математической статистики, методы машинного обучения, комплексного обобщения научных достижений и практического опыта применения средств обработки данных в задачах прогнозирования выработки электроэнергии солнечными электростанциями. **Результаты.** Проведен обзор литературных источников, отражающих результаты применения современных средств интеллектуального анализа данных при прогнозировании величины выработки электроэнергии солнечными электростанциями. Рассмотрены различные подходы к прогнозированию выработки электроэнергии на солнечных электростанциях, проведен анализ факторов, применяемых при прогнозировании. Были получены результаты теоретического и прикладного характера, заключающиеся в рекомендациях по применению экзогенных переменных при прогнозировании выработки электроэнергии на СЭС, а также некоторых алгоритмов машинного обучения при построении прогнозных моделей. Данные рекомендации были получены в процессе обобщения результатов прикладных исследований.

Ключевые слова: Солнечная энергия, энергосбережение, прогнозирование, интеллектуальный анализ данных, машинное обучение, градиентный бустинг.

Для цитирования: Прогнозирование почасовой выработки электроэнергии солнечной электростанцией с помощью алгоритмов машинного обучения / А.Д. Моргоева, И.Д. Моргоев, Р.В. Ключев, С.С. Кочковская // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2023. – Т. 334. – № 12. – С. 7–19. DOI: 10.18799/24131830/2023/12/4253

UDC 004.852, 004.67

DOI: 10.18799/24131830/2023/12/4253

Forecasting hourly electricity generation by a solar power plant using machine learning algorithms

A.D. Morgoeva^{1✉}, I.D. Morgoev¹, R.V. Klyuev², S.S. Kochkovskaya³

¹ North Caucasian Institute of Mining and Metallurgy (State Technological University), Vladikavkaz, Russian Federation

² Moscow Polytechnic University, Moscow, Russian Federation

³ Orenburg State University, Orenburg, Russian Federation

✉ m.angelika-m@yandex.ru

Abstract

Relevance. The need to develop energy-saving approaches through the use of data mining tools to improve the efficiency of management decision-making and more optimal use of energy resources. Forecasting the amount of electric energy generated by a solar power plant will allow optimal electricity distribution in decentralized systems. Information about the amount of electricity generated by a solar power plant and transmitted to a grid at every hour will allow planning the use of generated electricity and its distribution more reasonably. Also, the presence of a reliable forecast will allow embedding a predictive model into the micro-grid management subsystem. This will facilitate the integration of centralized electrical networks and distributed generation facilities. **Aim.** To analyze scientific papers containing proposals to improve the accuracy of determining the amount of electricity generated by solar power plants; to develop machine learning models that allow you to create a short-term forecast of electricity generation by a solar power plant. **Objects.** Solar power plant named after A.A. Vlaznev (Sakmarskaya SPP), Orenburg region, Orsk, Oktyabrsky district, geographical coordinates: 51.266023, 58.474689. **Methods.** Analytical method, methods of mathematical statistics, methods of machine learning, complex generalization of scientific achievements and practical experience in the use of data processing tools in the tasks of forecasting electricity generation by solar power plants. **Results.** The authors have carried out the review of literature sources reflecting the results of using modern data mining tools in predicting the magnitude of electricity generation by solar power plants. The paper considers various approaches to forecasting electricity generation at solar power plants. The analysis of factors used in forecasting is carried out. The authors obtained the results of theoretical and applied nature. The results consist in recommendations on using exogenous variables in predicting power generation at SPP, as well as some machine learning algorithms in construction of predictive models. These recommendations were obtained in generalizing the results of the applied research.

Keywords: Solar power, energy saving, forecasting, data mining, machine learning, gradient boosting.

For citation: Morgoeva A.D., Morgoev I.D., Klyuev R.V., Kochkovskaya S.S. Forecasting hourly electricity generation by a solar power plant using machine learning algorithms. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2023, vol. 334, no. 12, pp. 7–19. DOI: 10.18799/24131830/2023/12/4253

Введение

Использование возобновляемых источников энергии (ВИЭ) является перспективным направлением развития мировой энергетики. ВИЭ – это неисчерпаемые и экологически чистые источники энергии, однако доля их применения по сравнению с ископаемыми видами топлива на сегодняшний день невелика. Это связано с рядом проблем, возникающих при использовании альтернативных источников энергии. Прежде всего, это экономический аспект. Капиталовложения в строительство и эксплуатацию ВИЭ электростанций гораздо больше, чем стоимость поддержания работоспособности и модернизации электростанций, функционирующих на ископаемых видах топлива. При этом мощность генерирующих объектов возобновляемой

энергетики существенно меньше генерирующих мощностей объектов традиционной энергетики. Другим аспектом, затрудняющим развитие ВИЭ, является экологический аспект. С одной стороны, альтернативные источники энергии являются экологически чистыми, но их внедрение сопровождается некоторыми экологически негативными последствиями, такими как: затенение и простаивание плодородных почв (солнечные электростанции), изменение направления ветра и, как следствие, путей миграции птиц (ветровые электростанции), неразлагаемые отходы некоторых видов оборудования ВИЭ и др. Кроме того, одним из немаловажных препятствий на пути к полномасштабному внедрению ВИЭ является большая зависимость данных источников энергии от метеорологических факто-

ров и, как следствие, непостоянный уровень выработки электроэнергии, и неравномерное расположение объектов ВИЭ в разных климатических условиях. С другой стороны, тенденция увеличения нагрузки на электрические сети приводит к росту использования исчерпаемых природных ресурсов, необходимых для генерации электроэнергии. Это, в свою очередь, может привести к истощению запасов природного топлива и другим экологическим проблемам, таким как, например, глобальное изменение климата (потепление) [1]. Поэтому в мире происходит реформирование подходов к средствам производства электрической энергии и выдвигаются амбициозные требования к современной энергетике, в формализованном виде сводящиеся, как правило, к минимаксной задаче оптимизации: обеспечить как можно большее число потребителей (в том числе в удаленных регионах) электроэнергией необходимого качества при минимальном использовании ископаемых видов топлива, следовательно, при минимальном негативном воздействии на окружающую среду. Для решения поставленной задачи происходит переориентация региональных энергосистем, заключающаяся в переходе от централизованных энергосистем к распределенным. При этом под распределенной генерацией электроэнергии стоит в данном случае понимать процесс децентрализованного производства электроэнергии различными видами электростанций (на основе ископаемых видов топлива и ВИЭ). Предполагается, что доля ВИЭ в производстве электроэнергии с каждым годом должна увеличиваться.

В отдельно взятой стране такой процесс модернизации энергосистем происходит по-своему. Причинами этому являются региональные особенности, в том числе климатические, государственное стимулирование в области поддержки внедрения ВИЭ, а также наличие научной базы для проведения исследований и разработки новейших технологий, способствующих повышению доступности и конкурентоспособности ВИЭ по сравнению с традиционной энергетикой [2, 3]. Особенное внимание в научных исследованиях уделяется развитию возобновляемой энергетики в удаленных населенных пунктах [4, 5].

В Российской Федерации, по мнению экспертов, для развития альтернативной энергетики имеются подходящие климатические условия во многих регионах [6, 7]. Кроме того, как отмечают ученые в [6], создание и функционирование объектов генерации электрической энергии, основанных на альтернативных источниках энергии, является экономически целесообразным.

Все перечисленные аспекты и сложные вызовы, которые ставятся перед альтернативной энергетикой, определяют необходимость проведения научных исследований. В частности, для повышения эф-

фективности планирования выработки электроэнергии объектами ВИЭ необходим поиск новых методов поддержки принятия решения при внедрении и эксплуатации электростанций на основе ВИЭ.

Помимо описанных ранее проблем внедрения объектов ВИЭ существует также проблема сложности управления системами с децентрализованной генерацией электроэнергии [8]. Поэтому одним из путей, способствующих более обоснованному учету и перспективному планированию величины выработки электроэнергии с помощью ВИЭ в энергосистеме с распределенной генерацией, является прогнозирование выработки электроэнергии.

Объект, предмет и цель исследования

В соответствии с вышеизложенным была определена цель настоящего исследования – повышение обоснованности перспективного планирования объемов выработки электрической энергии объектом альтернативной энергетики.

Для решения поставленной цели были определены и реализованы следующие задачи:

- 1) провести обзор актуальных научных исследований в области повышения эффективности управления объектами ВИЭ за счет интеллектуального анализа данных;
- 2) провести сравнительный анализ методов и факторов, влияющих на величину выработки электроэнергии объектами ВИЭ и используемых при ее прогнозировании;
- 3) провести прикладное исследование на примере ретроспективных данных о выработке электроэнергии солнечной электростанцией, заключающееся в:
 - исследовании метеорологических факторов, влияющих на величину выработки электроэнергии СЭС;
 - создании прогностических моделей, позволяющих получить прогноз выработки электроэнергии на час вперед;
 - оценке погрешности прогноза;
- 4) определить перспективы для дальнейших исследований.

В соответствии с указанными задачами работа была структурирована следующим образом: во *Введении* содержится краткий анализ сложностей, связанных с внедрением ВИЭ, в данном разделе определены цель и задачи, объект и предмет исследования, в разделе *Обзор литературы* отражен анализ современных методов прогнозирования выработки электроэнергии объектами ВИЭ по различным критериям (метод прогнозирования, факторы, использованные при моделировании и т. д.). В разделе *Прогнозирование выработки электроэнергии на примере СЭС им. А.А. Влазнева* приведены результаты создания прогностических моде-

лей, оценка их качества. Раздел *Заключение* содержит описание полученных результатов, ключевые выводы по исследованию и перспективы дальнейших исследований.

В качестве объекта исследования была рассмотрена солнечная электростанция им А.А. Влазнева (Сакмарская СЭС), расположенная в Оренбургской области, г. Орск, Октябрьский район, географические координаты: 51.266023 с.ш, 58.474689 з.д. Сакмарская СЭС расположена на территории бывшего золотоотвала Орской ТЭЦ-1 и находится на балансе ПАО «Т Плюс» [9]. Установленная мощность электростанции 25 МВт.

Место расположения данной электростанции выбрано, с одной стороны, очень удачно, так как она расположена на территории отходов от золотодобывающего производства, следовательно, не является причиной затенения плодородных почв. Но, с другой стороны, наличие большого количества пыли и частых ветров способствует быстрому загрязнению солнечных панелей и, как следствие, снижению выработки электроэнергии.

Для производства электрической энергии, основанной на фотоэлектрическом преобразовании энергии солнечного излучения в электрическую энергию, на Сакмарской СЭС используют тонкопленочные фотоэлектрические модули модели AST, которые собирают в группы в соответствии с их характеристиками.

Для преобразования постоянного тока фотоэлектрических солнечных модулей в переменный трехфазный ток применяются блочно-модульные инверторные установки (БМИУ). Для выдачи полученной энергии в прилегающую энергосистему функционирует повышающая подстанция 10/110 кВ в составе Сакмарской СЭС по схеме № 110-6Н «Треугольник». В дальнейшем по ВЛ 110 кВ СЭС происходит соединение с электрической сетью.

На Сакмарской СЭС установлена система сбора данных и оперативного контроля, предназначенная для получения и хранения информации о текущем режиме энергосистемы (Supervisory Control And Data Acquisition – SCADA). Получаемые данные из системы SCADA – активная и реактивная мощность за каждый час.

Как отмечено в [9], для Сакмарской СЭС характерна «высокая неравномерность и импульсивная динамика выдачи мощности». Существуют также режимы потребления активной мощности в ночные часы вследствие охлаждения поверхности солнечных панелей.

Для того чтобы эффективно управлять распределенной электрической сетью (знать объем генерации электроэнергии, поступающей с СЭС в электрическую сеть, и учитывать ее при управлении нагрузками), важно проводить планирование выда-

чи активной мощности солнечной электростанцией. С учетом стохастического характера величины выдачи активной мощности солнечной электростанцией недостаточно проведения инженерных расчетов, необходимо применение современных методов интеллектуального анализа данных.

Процесс планирования производства электроэнергии основан на сочетании потенциальных нагрузок с выработкой электроэнергии. Для поддержания стабильности частоты сети это имеет первостепенное значение. Процесс планирования производства электроэнергии представляет собой сложную задачу оптимизации, которая направлена на интеграцию традиционных систем производства электроэнергии на ископаемом топливе и других возобновляемых источников энергии, таких как ветряные и солнечные электростанции [10].

Прогнозирование выдачи мощности в электрическую сеть Сакмарской СЭС является актуальной задачей, имеющей высокую практическую и научную значимость. Таким образом, предметом исследования явились методы прогнозирования величины генерации электроэнергии на основании ретроспективных данных: метеорологических и данных о величине фактической выработки электроэнергии (активной мощности).

Обзор литературы

Существует множество методов прогнозирования выработки электроэнергии и ее потребления. Обзор некоторых из них представлен в [11]. Однако ВИЭ по сравнению с традиционной энергетикой обладает некоторыми специфическими особенностями, предполагающими дополнительные исследования в части адаптации методов прогнозирования. Из-за стохастического характера выработки электроэнергии, вызванного большой зависимостью от метеорологических условий и времени суток, необходимо проведение дополнительных исследований.

В литературе можно выделить несколько основных подходов к прогнозированию выработки электроэнергии с помощью ВИЭ. Согласно [12], все методы, применяемые для прогнозирования генерации электроэнергии с помощью СЭС, можно условно разделить на прямые и косвенные. Первая группа методов включает прогнозирование выработки электроэнергии на основании анализа временных рядов о выработке электроэнергии в прошлом. Вторая группа методов предполагает прогнозирование показателей, от которых зависит выработка электроэнергии солнечными электростанциями. В частности, прогнозирование величины солнечного излучения на основании численного прогноза погоды и проведение расчетов на основании прогноза солнечного излучения по данным технических характеристик солнечных панелей.

Поскольку значительное влияние на выработку электроэнергии с помощью ВИЭ оказывают метеофакторы (температура, солнечное излучение, скорость ветра, влажность, естественная освещенность, облачность и т. д.), а также временные факторы (время суток, продолжительность светового дня, время года и т. д.), было принято решение провести сравнительный анализ различных исследований по теме прогнозирования выработки электроэнергии с помощью СЭС. В табл. 1 приведены факторы, используемые различными исследователями при прогнозировании выработки электроэнергии солнечными электростанциями.

Как видно из табл. 1, не существует строго определенного перечня факторов, необходимых для построения прогнозных моделей. Также нет и однозначного подхода к тому, какой метод лучше применять и в каких условиях. Поэтому рассмотрим некоторые исследования более подробно. В работе [13] представлен подход, заключающийся в прогнозировании инсоляции по ретроспективным данным и затем в расчете по техническим характеристикам электрооборудования величины выработки электро-

энергии, то есть подход относится ко второй группе методов. Такой подход был использован с целью повышения эффективности управления в микросети. Под микросетью в [13] понимают распределенную сеть электропитания, которая объединяет нагрузки, генераторы энергии и технологии хранения с компонентами управления. Такая сеть функционирует в качестве подключенной к основной сети или изолированно от нее. В изолированном режиме локальные генераторы являются единственным источником питания для нагрузок, подключенных к микросети. Если микросеть подключена к сети, между обеими системами будет происходить обмен энергией в соответствии с уровнями спроса и предложения. Следовательно, микросети могут работать попеременно между обоими режимами, изолированными или подключенными. Скоординированная работа и управление такими элементами, как устройства распределенной генерации и хранения данных, занимает центральное место в концепции микросетей [13]. Прогноз инсоляции в работе [13] был получен с помощью искусственной нейронной сети, параметры которой подробно описаны в [13].

Таблица 1. Анализ факторов, используемых при прогнозировании выработки электроэнергии СЭС
Table 1. Analysis of factors used in forecasting electricity generation by a solar power plant

Анализируемые факторы и выходные данные модели Analyzed factors and output data of the model	Источник Reference
Сезон, время суток, 144 значения излучения (Irradiation) с 10 минутным интервалом за предыдущие 24 часа. Прогнозируемая величина – прогноз облучения Season, time of day, 144 radiation values with a 10-minute interval for the previous 24 hours. The predicted value is the radiation forecast	[13]
Индекс цен на электроэнергию (соотношение), скорость ветра на высоте 1 м над уровнем моря (м/с), горизонтальное излучение верхней части атмосферы (Вт/м ²), горизонтальное излучение Земли (Вт/м ²), шероховатость поверхности (м), температура на высоте 2 м над уровнем моря (°C), плотность воздуха (кг/м ³), атмосферное давление (Па), Прогнозируемая величина – генерация солнечной энергии (МВт) Electricity price index (ratio), wind speed at an altitude of 1 m above sea level (m/s), horizontal radiation of the upper atmosphere (W/m ²), horizontal radiation of the Earth (W/m ²), surface roughness (m), temperature at an altitude of 2 m above sea level (°C), air density (kg/m ³), atmospheric pressure (Pa). The predicted value is the solar energy generation (MW)	[14]
Температура воздуха (°C), относительная влажность (%). Прогнозируемая величина – почасовая глобальная солнечная радиация (Вт·ч/м ²) Air temperature (°C), relative humidity (%). The predicted value is the hourly global solar radiation (Wh/m ²)	[15]
Выходная мощность переменного тока фотоэлектрической системы, оцененная по характеристикам модели инвертора (Вт), глобальная горизонтальная освещенность (Вт/м ²), плоское рассеянное излучение (Вт/м ²), относительная масса воздуха, зональная скорость ветра на высоте 10 м (м/с), рассеянное горизонтальное излучение (Вт/м ²), общее излучение в плоскости (Вт/м ²), общая облачность ([0–1]), среднее давление над уровнем моря (Па), температура точки росы (°C), меридиональная скорость ветра на высоте 10 м (м/с), абсолютная воздушная масса, общее количество осадков. Рассеянное излучение неба в плоскости (Вт/м ²). Прогнозируемая величина – генерация солнечной энергии (Вт). AC output power of the photovoltaic system, estimated by the characteristics of the inverter model (W), global horizontal illumination (W/m ²), flat scattered radiation (W/m ²), relative air mass, zonal wind speed at a height of 10 m (m/s), scattered horizontal radiation (W/m ²), total radiation in the plane (W/m ²), total cloud cover ([0–1]), average pressure above sea level (Pa), dew point temperature (°C), meridional wind speed at an altitude of 10 m (m/s), absolute air mass, total precipitation. The scattered radiation of the sky in the plane (W/m ²). The predicted value is the generation of solar energy (W)	[16]
Относительная влажность, средняя температура воздуха, средняя скорость ветра, среднее направление ветра, глобальное среднее значение радиации, среднее рассеянное излучение, среднее прямое излучение, среднее значение наклонного солнечного излучения, значение азимута солнечного излучения Relative humidity, average air temperature, average wind speed, average wind direction, global average radiation value, average scattered radiation, average direct radiation, average oblique solar radiation value, azimuth value of solar radiation	[17]
Солнечная радиация, температура тыльной стороны каждого солнечного модуля, температура воздуха в тени, скорость и направление ветра. Прогнозируемая величина – выработка электрической энергии (МВт) Solar radiation, temperature of a back side of each solar module, air temperature in the shade, wind speed and direction. The predicted value is the generation of electric energy (MW)	[18]

В исследовании немецкого ученого описан подход извлечения знаний из ретроспективного набора данных погодного, экономического характера, а также данных о величине генерации электроэнергии [14]. Алгоритм обучающей сети прозрачного открытого ящика (transparent open box – TOB) был применен к данным, представляющим собой объединенный набор данных о выработке электроэнергии всеми СЭС Германии за 2016 г. Автор отмечает успешность применения модели прогнозирования выработки электроэнергии, основанной на алгоритме TOB, подчеркивая воспроизводимость и точность результатов прогнозирования как существенные достоинства метода. Также в исследовании отмечена важность применения более широких экзогенных переменных (в частности, экологических показателей состояния поверхности и рыночных цен) для дополнения факторов о погоде и солнечной радиации при прогнозировании выработки солнечной энергии на региональном и национальном уровне [14].

В работе [19] описано применение моделей градиентного бустинга с использованием алгоритмов XGBoost, LightGBM и CatBoost. Авторы в [19] подчеркивают важность предиктивной аналитики при управлении выработкой энергии с помощью возобновляемых источников энергии. В [19] приведен сравнительный анализ результатов производительности алгоритмов градиентного бустинга при прогнозировании выработки электроэнергии солнечными электростанциями, отмечена их высокая точность и быстрое действие.

Таким образом, несмотря на схожие цели рассмотренных исследований, подходы, применяемые учеными, различаются. В результате литературного обзора были сформулированы следующие выводы. Во-первых, нет однозначных рекомендаций, какой

подход лучше применять при прогнозировании (прямой или косвенный). Также среди исследователей нет единого мнения, какие исходные данные использовать для прогноза, какие факторы наиболее существенны при прогнозировании выработки электроэнергии. Объясняется это, вероятно, разницей в организации учета данных на отдельно взятой СЭС и, как следствие, различной структурой исходных данных, имеющихся в арсенале исследователей. Во-вторых, требования к допустимой величине погрешности прогноза нестандартизированы и для различных условий прогнозирования отличаются, кроме того, нет единых критериев по выбору метрик для оценки качества прогнозных моделей, что усложняет сравнительный анализ методов.

Прогнозирование выработки электроэнергии на примере СЭС им. А.А. Влазнева

Все расчеты были реализованы в интерактивной платформе JupyterNotebook на языке программирования Python. Были использованы библиотеки Numpy и Pandas (для вычислений и манипуляций с данными), Matplotlib (для визуализации данных), Scikit-learn, XGBoost и CatBoost (для предобработки данных и загрузки экземпляров моделей регрессии).

Прогнозирование выработки электроэнергии было выполнено на примере солнечной электростанции им. А.А. Влазнева. Для прогнозирования были использованы данные о выработке электроэнергии за период с 01.09.2020 по 19.05.2021, а также метеорологические данные из открытых источников информации [20]. На рис. 1 представлен график выработки активной мощности за несколько суток. Как видно из рис. 1, выработка электроэнергии зависит от времени суток.




Рис. 1. График активной мощности СЭС за период с 02.09.2020 по 08.09.2020

Fig. 1. Schedule of the active capacity of the solar power plant for the period from 02.09.2020 to 08.09.2020

Исследование было выполнено в несколько этапов.

1. *Отбор признаков (Feature Selection)*. Как было указано выше, нет однозначных универсальных рекомендаций по использованию определенных факторов при прогнозировании, поэтому было принято решение провести прикладное исследование по отбору признаков, которые необходимо учитывать в прогнозных моделях. В работе были использованы следующие признаки и их обозначения:

- YEAR: год.
- MONTH: месяц.
- DAY: день.
- HOUR: час.
- X1: Коротковолновая направленная вниз интенсивность излучения всей поверхности неба ($\text{Вт} \cdot \text{ч} / \text{м}^2$).
- X2: Индекс ясности инсоляции всего неба (безразмерный).
- X3: Альбедо всей поверхности неба (безразмерное).
- X4: Зенитный угол Солнца (градусы).
- X5: Коротковолновая направленная вниз интенсивность излучения поверхности чистого неба ($\text{Вт} \cdot \text{ч} / \text{м}^2$).
- X6: Общая площадь всей поверхности неба ($\text{Вт} / \text{м}^2$).
- X7: Общая площадь поверхности чистого неба ($\text{Вт} / \text{м}^2$).
- X8: UVA-излучение всей поверхности неба ($\text{Вт} / \text{м}^2$).
- X9: UVB-излучение всей поверхности неба ($\text{Вт} / \text{м}^2$).
- X10: УФ-индекс всей поверхности неба (безразмерный).
- X11: Температура на расстоянии 2 метров (C).
- X12: Точка росы/замерзания на высоте 2 метров (C).
- X13: Температура влажной колбы на расстоянии 2 метров (C).
- X14: Удельная влажность на расстоянии 2 метров (г/кг).
- X15: Относительная влажность воздуха на высоте 2 метров (%).
- X16: Скорректированное количество осадков (мм/час).
- X17: Поверхностное давление (кПа).
- X18: Скорость ветра на высоте 10 метров (м/с).
- X19: Направление ветра на высоте 10 метров (градусы).
- X20: Скорость ветра на высоте 50 метров (м/с).
- X21: Направление ветра на расстоянии 50 метров (градусы).
- X22: Активная мощность, выработанная на СЭС 1 час назад (МВт).

Был применен метод фильтрации признаков Information Gain. Суть метода состоит в вычислении энтропии информации $H(X)$ по (1) и относи-

тельной энтропии $H(Y|X)$ по (2). Затем вычисляется разность значений (3), называемая величиной «получение информации» (Information Gain – IG), или «взаимная информация» (Mutual Information – MI). Полученная величина характеризует связь между зависимыми переменными и целевым результатом: чем больше значение IG, тем сильнее изменение фактора влияет на изменение целевой переменной. То есть IG, или MI, – это величина, на которую изменяется неопределенность в отношении Y путем информационного прироста каждого фактора относительно целевой переменной (Y).

$$H(X) = - \sum_{x_i \in X} p(x_i) \log^2(p(x_i)), \quad (1)$$

где $p(x_i)$ – это вероятность того, что переменная X примет значение x_i ,

$$H(Y|X) = \sum_{x_i \in X} p(x_i) H(Y|X = x_i), \quad (2)$$

где $H(Y|X=x_i)$ – это энтропия, вычисленная для записей, для которых $X=x_i$,

$$IG(Y|X) = H(Y) - H(Y|X). \quad (3)$$

На рис. 2 представлена диаграмма отсортированных в порядке убывания по величине IG факторов. Таким образом, самое большое влияние, как несложно было предположить, оказывают ретроспективные данные целевой переменной с лагом в 1 час, взятые в качестве фактора (X22), затем погодные факторы: общая площадь всей поверхности неба (X6), интенсивность излучения всей поверхности неба (X1) и другие.

Таким образом, мера IG, в отличие от коэффициента парной корреляции Пирсона, показывает не только линейные связи признаков и целевой переменной, но и долю уменьшения неопределенности целевой переменной в зависимости от наличия того или иного фактора. Однако необходим также учет коррелированности признаков. Поэтому для проверки на мультиколлинеарность была построена матрица корреляции факторов и целевой переменной (рис. 3), значения которой вычислены по (4).

$$r_{xy} = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\sigma(x)\sigma(y)}, \quad (4)$$

где r_{xy} – это коэффициент парной корреляции Пирсона; x и y – попарно перебираемые признаки; σ – среднеквадратическое отклонение.

В результате анализа тепловой карты корреляций (рис. 3) можно констатировать, что имеет место существенная корреляция для многих пар признаков. Поэтому среди коррелированных признаков в дальнейшем исследовании были оставлены наиболее тесно связанные с целевой переменной, а именно: DAY, MONTH, YEAR, HOUR, X1, X2, X3, X11, X15, X16, X17, X18, X21, X22.




Рис. 2. Диаграмма значений IG факторов
Fig. 2. Diagram of the IG factors values




Рис. 3. Матрица корреляции признаков и целевой переменной
Fig. 3. Matrix of features and target variable correlation

Остальные признаки были исключены и не были использованы при моделировании.

2. *Предобработка данных.* На этом этапе данные были предварительно обработаны следующим образом: удалены строки с нулевым значением целевой переменной (ночные часы), а также найдены и устранены пропуски в данных. Затем набор данных был разделен на обучающую и тестовую выборки в соотношении 80:20. После чего все признаки были приведены к единому масштабу путем применения минимаксной нормализации, вычисляемой по (5).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}. \quad (5)$$

3. *Прогнозирование выработки электроэнергии.* На этом этапе были загружены экземпляры моделей k -ближайших соседей (KNeighborsRegressor), деревьев решений (DecisionTreeRegressor), случайного леса (RandomForestRegressor – RFR), многослойного перцептрон (MLPRegressor), градиентного бустинга SkLearn (GradientBoostingRegressor – GBR), экстремального градиентного бустинга (XGBRegressor – XGBoost), градиентного бустинга библиотеки CatBoost (CatBoostRegressor – CAT).

Приведем краткое описание принципа работы выбранных алгоритмов. Модель k -ближайших соседей прогнозирует целевую переменную путем локальной интерполяции значений целевой переменной n ближайших значений. Основные параметры модели регрессии `KNeighborsRegressor` библиотеки `SkLearn`: `n-neighbors` – количество ближайших значений, `weights` – весовая функция и др.

Модель деревьев решений использует последовательность предикатов для предсказания целевой переменной. Строится так называемое дерево решений, в узлах которого расположены предикаты, а в листьях – предсказания. Дерево решений можно рассматривать как кусочно-постоянную аппроксимацию. Основные параметры модели: `criterion`, где задается функция качества разделения, `splitter` – стратегия при выборе разделения в каждом узле, `max_depth` – максимальная глубина дерева и др.

Алгоритм случайного леса `RFR` представляет собой реализацию ансамблевого обучения: создается некоторое количество моделей деревьев решений, проводится их обучение на одних и тех же данных, усредняется результат работы моделей, и выбирается наилучшая модель. По сравнению с моделью деревьев решений, модель `RFR` предотвращает переобучение, что является существенным достоинством ансамблевого подхода.

При реализации моделей градиентного бустинга происходит итеративное добавление моделей в ансамбль следующим образом. Создается модель, инициализирующая ансамбль. При этом модель может иметь довольно большую погрешность прогноза. Затем начинается цикл, в котором при использовании текущего ансамбля генерируются прогнозы для каждого наблюдения в наборе данных, которые затем добавляются в ансамбль, вычисляется функция потерь.

Затем путем реализации градиентного спуска определяются оптимальные параметры модели, после чего новая модель добавляется в ансамбль и все описанные операции повторяются.

Модель регрессии градиентного бустинга библиотеки `XGBoost` является одной из реализаций градиентного бустинга, применяемой для работы с табличными данными. Для ее настройки необходим подбор следующих параметров. Параметр `n_estimators` – количество проходов по циклу моделирования (эквивалентно количеству моделей, включаемых в ансамбль). Автоматический поиск наилучшего значения параметра `n_estimators` можно выполнить, указав в параметре `early_stopping_rounds` количество неудачно построенных моделей (т. е. тех, последовательное добавление в ансамбль которых не увеличило производительности модели и вызвало раннюю остановку выполнения цикла, т. е. без необходимости прогона

алгоритма на всем множестве значений). При этом в параметре `eval_set` необходимо указать данные для вычисления баллов при проверке.

Модель регрессии `CatBoost` реализует алгоритм градиентного бустинга, является ансамблевым методом, основанным на деревьях решений. Алгоритм градиентного бустинга `CatBoostRegressor` поддерживает возможность использования категориальных переменных, L_2 -регуляризацию и другие возможности. Основными параметрами модели являются: `iterations` – количество итераций, `loss_function` – функция потерь, `learning_rate` – скорость обучения, `depth` – глубина деревьев. Отличием данного алгоритма от алгоритма случайного леса является последовательное улучшение моделей деревьев решений. То есть каждая следующая в ансамбле модель дерева решений строится с учетом результатов предыдущей модели [21].

Для каждой из моделей была проведена процедура подбора параметров с помощью инструмента перекрестной проверки `GridSearchCV`. Для оценки качества прогнозных моделей были использованы средняя абсолютная ошибка прогноза (`mean absolute error` – MAE), рассчитываемая по (6), коэффициент детерминации (R^2), вычисляемый по (7), и величина максимальной ошибки прогноза (`MAX_error`).

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (6)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (7)$$

где y и $\hat{y}$ – это фактические и прогнозные значения выдачи активной мощности СЭС; n – количество наблюдений.

В табл. 2 приведены основные результаты качества прогнозирования созданных моделей. Как можно заметить, наилучшие результаты по величине средней абсолютной ошибки и значению максимальной ошибки получены моделью на основе алгоритма градиентного бустинга библиотеки `CatBoost`. Также у этой модели наименьшее переобучение. Другие алгоритмы градиентного бустинга дали схожие результаты. Поэтому в дальнейших исследованиях можно рекомендовать объединение их по технологии стекинга.

На рис. 4 представлены гистограммы, отражающие значения фактических и прогнозных значений выдачи активной мощности для различных сезонов года.

Анализируя рис. 4, можно отметить, что для осеннего дня фактические значения, как правило,

больше прогнозных. Для зимнего дня, наоборот, отклонения от фактических значений вызваны превышением прогнозных значений над фактическими. Для весеннего дня в часы пика значения фактические превышают прогнозные, а в вечерний и

утренний период, наоборот, фактические значения меньше прогнозных. Поэтому одной из перспектив дальнейших исследований является кластеризация часов суток в зависимости от уровня выдачи активной мощности и длительности светового дня.

Таблица 2. Результаты метрик качества моделей
Table 2. Results of model quality metrics

Модель/Model	Метрики качества прогноза/Forecast quality metrics					
	Обучающая выборка Train dataset			Контрольная выборка Test dataset		
	MAE	R ²	MAX_error	MAE	R ²	MAX_error
к-ближайших соседей/KNeighborsRegressor	0,88	0,96	8,97	1,13	0,93	8,81
Дерево решений/DecisionTreeRegressor	0	1	0	1,09	0,91	11,61
Случайный лес/RandomForestRegressor	0,33	0,99	5,35	0,86	0,95	9,09
Многослойный перцептрон/MLPRegressor	0,61	0,98	8,26	1,11	0,94	9,24
Градиентный бустинг/GBR SkLearn	0,72	0,97	7,93	0,96	0,95	9,91
Экстремальный градиентный бустинг/XGBoost	0,38	0,99	3,67	0,89	0,95	9,97
Градиентный бустинг CatBoost/CAT	0,61	0,98	3,59	0,87	0,95	8,39




Рис. 4. Диаграммы фактических и прогнозных значений целевой переменной для осеннего, зимнего и весеннего дней
Fig. 4. Diagram of real and forecast values of the target variable for autumn, winter and spring days

Заключение

В результате проведенного исследования были созданы модели машинного обучения, основанные на современных алгоритмах интеллектуального анализа данных. В ходе выполнения работы были проанализированы факторы временного и метеорологического характера и оценена их степень влияния на целевой результат – выработку электроэнергии солнечной электростанцией. При установленной мощности электростанции 25 МВт средняя абсолютная ошибка прогнозирования составляет 0,87, при этом максимальная ошибка прогноза на тестовом наборе данных составляет 8,39 для модели прогнозирования, основанной на алгоритме градиентного бустинга библиотеки CatBoost. Полученные оценки производительности моделей позволяют рекомендовать результаты проведенного исследования для использования при прогнозировании с шагом прогноза на 1 час объема выработки электроэнергии солнечными электростанциями, сопоставимыми по мощности с рассматриваемой в исследовании.

Стоит отметить допущения проведенного исследования. Так, в исследовании не учитывались СЭС с мощностями до 1 МВт и меньше, следова-

тельно, распространить результаты исследования на маломощные СЭС не представляется возможным. Не проводилось оперативное прогнозирование (с шагом прогноза несколько часов). Кроме того, не был учтен стохастический характер выработки электроэнергии. Данные ограничения составляют часть направлений для дальнейших исследований.

Еще одной из перспектив для дальнейших исследований является проведение косвенного прогнозирования величины выработки электроэнергии и его сравнительный анализ с полученными в настоящем исследовании результатами. Косвенный прогноз предполагается получить в два этапа. На первом этапе необходимо создать прогнозную модель инсоляции с использованием в качестве входных данных прогноза погоды, а на втором этапе произвести прогнозирование и/или расчет величины выдачи активной мощности с учетом технических характеристик солнечной электростанции.

Наиболее перспективным направлением будущих исследований авторы видят обобщение полученных в данном исследовании результатов путем их апробации на других солнечных электростанциях.

СПИСОК ЛИТЕРАТУРЫ

1. Жунусова Г.Ж., Нурмуханова Г.Ж. Оценка предпосылок развития возобновляемой энергетики в Казахстане // Вестник университета Туран. – 2019. – № 4 (84). – С. 235–241.
2. Бакас Уулу Бахтыяр. Проблемы финансирования возобновляемой энергетики в кыргызской республике // Известия Кыргызского государственного технического университета им. И. Раззакова. – 2019. – № 1 (49). – С. 44–55.
3. Fossil energy in the framework of sustainable development: analysis of prospects and development of forecast scenarios / Y.L. Zhukovskiy, D.E. Batueva, A.D. Buldysko, B. Gil, V.V. Starshaia // Energies. – 2021. – V. 14. – № 17:5268.
4. Потенциал управления электропотреблением в условиях изолированной энергосистемы удаленного населенного пункта / Ю.Л. Жуковский, А.Ю. Лаврик, А.В. Семенюк, О.С. Васильков // Устойчивое развитие горных территорий. – 2020. – Т. 12. – № 4 (46). – С. 583–591.
5. Змиева К.А. Интеграция зеленой и возобновляемой энергетики в интеллектуальную энергетическую систему арктических территорий посредством технологий блокчейна // Российская Арктика. – 2021. – № 4 (15). – С. 81–91.
6. Analysis of prospects of using solar energy in Russian Federation economy / L. Serga, E. Chemezova, E. Makaridina, N. Samotoy // Procedia CIRP. – 2016. – V. 40. – P. 41–45.
7. Solar power time series forecasting utilising wavelet coefficients / S. Almaghrabi, M. Rana, M. Hamilton, M.S. Rahaman // Neurocomputing. – 2022. – V. 508. – P. 182–207.
8. Энергоменеджмент гибридной энергетической микросети на сутки вперед / М. Элгамаль, Н.В. Коровкин, А. Рефаат, А. Эльмитвалли // Известия Российской академии наук. Энергетика. – 2021. – № 1. – С. 54–69.
9. Башкатова К.И., Обухова Н.В., Егоров А.О. Режимы работы Сакмарской солнечной электростанции Оренбургской энергосистемы // Энерго- и ресурсосбережение. Энергообеспечение. Нетрадиционные и возобновляемые источники энергии: Материалы Международной научно-практической конференции. – Екатеринбург: Уральский федеральный университет им. Б.Н. Ельцина, 2017. – С. 679–683.
10. Chang R., Bai L., Hsu C.-H. Solar power generation prediction based on deep Learning // Sustainable Energy Technologies and Assessments. – 2021. – № 47. – P. 101354.
11. Methods of forecasting electric energy consumption: a literature review / R.V. Klyuev, I.D. Morgoev, A.D. Morgoeva, O.A. Gavrina, N.V. Martyushev, E.A. Efremkov, Q. Mengxu // Energies. – 2022. – V. 15. – № 15:8919.
12. Киселева С.В., Лисицкая Н.В., Фрид С.Е. Прогнозирование выработки солнечных станций и фотоэлектрических установок: основные подходы и результативность // Международный научный журнал «Альтернативная энергетика и экология» (ISJAEE). – 2020. – № 7 (18). – С. 24–43.
13. Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control / F. Rodriguez, A. Fleetwood, A. Galarza, L. Fontán // Renewable Energy. – 2018. – V. 126. – P. 855–864.
14. Wood D.A. German solar power generation data mining and prediction with transparent open box learning network integrating weather, environmental and market variables // Energy Conversion and Management. – 2019. – V. 196. – P. 354–369.
15. Hourly predictions of direct normal irradiation using an innovative hybrid LSTM model for concentrating solar power projects in hyper-arid regions / A. Djaafari, A. Ibrahim, N. Bailek, K. Bouchouicha, M.A. Hassan, A. Kuriqi, N. Al-Ansari, E.M. El-kenawy // Energy Reports. – 2022. – V. 8. – P. 15548–15562.

16. On the value of expert knowledge in estimation and forecasting of solar photovoltaic power generation / L. Visser, T. Al Skaif, J. Hu, A. Louwen, W.V. Sark // *Solar Energy*. – 2023. – V. 251. – P. 86–105.
17. Computational solar energy – ensemble learning methods for prediction of solar power generation based on meteorological parameters in Eastern India / D. Chakraborty, J. Mondal, H.B. Barua, A. Bhattacharjee // *Renewable Energy Focus*. – 2023. – V. 44. – P. 277–294.
18. Экспериментальное исследование влияния метеорологических факторов на выработку электроэнергии солнечными модулями в климатических условиях Астраханской области / Е.И. Теруков, Д.А. Андроников, Д.А. Малевский, Р.А. Зайнутдинов, А.Ю. Ключарев, С.Н. Братышев, В.Г. Ильичев // *Прикаспийский журнал: управление и высокие технологии*. – 2019. – № 2 (46). – С. 180–193.
19. Aksoy N., Genc I., Predictive models development using gradient boosting based methods for solar power plants // *Journal of Computational Science*. – 2023. – V. 67. – P. 101958.
20. Meteorological data. URL: <https://power.larc.nasa.gov/> (дата обращения 11.05.2023).
21. Краткосрочное прогнозирование электропотребления обогатительной фабрики / А.Д. Моргоева, И.Д. Моргоев, Р.В. Ключев, В.Н. Хетагуров, О.А. Гаврина // *Горный информационно-аналитический бюллетень*. – 2023. – № 5-1. – С. 157–169.

REFERENCES

1. Zhunussova G.Zh., Nurmukhanova G.Zh. The assessment of prerequisites for renewable energy development in Kazakhstan. *Bulletin of Turan University*, 2019, no. 4 (84), pp. 235–241. In Rus.
2. Bakas uulu Bakhtiyar. The problem of financing renewable energy in the Kyrgyz republic *Proceedings of the Kyrgyz State Technical University named after I. Razzakov*, 2019, no. 1 (49), pp. 44–55. In Rus.
3. Zhukovskiy Y.L., Batueva D.E., Buldysko A.D., Gil B., Starshaia V.V. Fossil energy in the framework of sustainable development: analysis of prospects and development of forecast scenarios. *Energies*, 2021, vol. 14, no. 17:5268.
4. Zhukovsky Yu.L., Lavrik A.Yu., Semenyuk A.V., Vasilkov O.S. Potential for electric consumption management in the conditions of an isolated energy system in a remote population. *Sustainable development of mountain territories*, 2020, vol. 12, no. 4 (46), pp. 583–591. In Rus.
5. Zmieva K. Integration of green and renewable energy into the intelligent energy system of the arctic territories through blockchain technologies. *Russian Arctic*, 2021, no. 4 (15), pp. 81–91. In Rus.
6. Serga L., Chemezova E., Makaridina E., Samotoy N. Analysis of prospects of using solar energy in Russian Federation economy. *Procedia CIRP*, 2016, vol. 40, pp. 41–45.
7. Almaghrabi S., Rana M., Hamilton M., Rahaman M.S. Solar power time series forecasting utilising wavelet coefficients. *Neurocomputing*, 2022, vol. 508, pp. 182–207.
8. Elgamal M., Korovkin N.V., Refaat A., Elmitwally A. Day-ahead energy management system for a hybrid-energy microgrid. *Proceedings of the Russian academy of sciences. Power engineering*, 2021, no. 1, pp. 54–69. In Rus.
9. Bashkatova K.I., Obukhova N.V., Egorov A.O. Rezhimy raboty Sakmarskoy solnechnoy elektrostantsii Orenburgskoy energosistemy [Operation modes of Sakmarskaya solar power plant in Orenburg power system]. *Energo- i resursoberezhenie. Energoobespechenie. Netraditsionnye i vozobnovlyаемые istochniki energii. Materialy Mezhdunarodnoy nauchno-prakticheskoy konferentsii* [Energy and resource conservation. Energy supply. Unconventional and renewable energy sources. Materials of the International Scientific and Practical Conference]. Ekaterinburg, Ural Federal University Publ., 2017. pp. 679–683.
10. Chang R., Bai L., Hsu C.-H. Solar power generation prediction based on deep Learning. *Sustainable Energy Technologies and Assessments*, 2021, no. 47, pp. 101354.
11. Klyuev R.V., Morgoev I.D., Morgoeva A.D., Gavrina O.A., Martyushev N.V., Efremenko E.A., Mengxu Q. Methods of forecasting electric energy consumption: a literature review. *Energies*, 2022, vol. 15, no. 15:8919.
12. Kiseleva S.V., Lisitskaya N.V., Frid S.E. Photovoltaic power forecasting: basic approaches and features. *The international scholarly journal «Alternative energy and ecology» (ISJAE)*, 2020, no. 7 (18), pp. 24–43. In Rus.
13. Rodriguez F., Fleetwood A., Galarza A., Fontán L. Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control. *Renewable Energy*, 2018, vol. 126, pp. 855–864.
14. Wood D.A. German solar power generation data mining and prediction with transparent open box learning network integrating weather, environmental and market variables. *Energy Conversion and Management*, 2019, vol. 196, pp. 354–369.
15. Djaafari A., Ibrahim A., Bailek N., Bouchouicha K., Hassan M.A., Kuriqi A., Al-Ansari N., El-kenawy E.M. Hourly predictions of direct normal irradiation using an innovative hybrid LSTM model for concentrating solar power projects in hyper-arid regions. *Energy Reports*, 2022, vol. 8, pp. 15548–15562.
16. Visser L., Al Skaif T., Hu J., Louwen A., Sark W.V. On the value of expert knowledge in estimation and forecasting of solar photovoltaic power generation. *Solar Energy*, 2023, vol. 251, pp. 86–105.
17. Chakraborty D., Mondal J., Barua H.B., Bhattacharjee A. Computational solar energy – Ensemble learning methods for prediction of solar power generation based on meteorological parameters in Eastern India. *Renewable Energy Focus*, 2023, vol. 44, pp. 277–294.
18. Terukov E.I., Andronikov D.A., Malevsky D.A., Zaynutdinov R.A., Klyucharev A.Yu., Bratyshev S.N., Ilyichev V.G. Pilot study of influence of meteorological factors on power generation by solar modules in climatic conditions of the Astrakhan region. *Caspian journal: management and high technologies*, 2019, no. 2 (46), pp. 180–193. In Rus.
19. Aksoy N., Genc I., Predictive models development using gradient boosting based methods for solar power plants. *Journal of Computational Science*, 2023, vol. 67, pp. 101958.
20. Meteorological data. Available at: <https://power.larc.nasa.gov/> (accessed 11 May 2023).
21. Morgoeva A. D., Morgoev I. D., Klyuev R. V., Khetagurov V. N., Gavrina O. A. Short-term prediction of energy consumption at concentration factory. *MIAB. Mining Inf. Anal. Bull*, 2023, no. 5-1, pp.157–169. In Rus.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Анжелика Джабраиловна Моргоева, аспирант Северо-Кавказского горно-металлургического института (государственного технологического университета), Россия, 362011, г. Владикавказ, ул. Николаева, 44. m.angelika-m@yandex.ru; <https://orcid.org/0000-0003-2949-1993>

Ирбек Джабраилович Моргоев, аспирант Северо-Кавказского горно-металлургического института (государственного технологического университета), Россия, 362011, г. Владикавказ, ул. Николаева, 44. m.irbek@yandex.ru; <https://orcid.org/0000-0003-4390-5662>

Роман Владимирович Ключев, доктор технических наук, профессор кафедры техники и технологии горного и нефтегазового производства им. П.Л. Капицы Московского политехнического университета, Россия, 107023, г. Москва, ул. Б. Семеновская, 38. kluev-roman@rambler.ru; <https://orcid.org/0000-0003-3777-7203>

Светлана Сергеевна Кочковская, кандидат технических наук, доцент кафедры управления и информатики в технических системах Оренбургского государственного университета, Россия, 460018, г. Оренбург, пр. Победы, 13. lana1905@mail.ru; <https://orcid.org/0000-0002-7562-2379>

Поступила в редакцию: 22.05.2023

Поступила после рецензирования: 19.09.2023

Принята к публикации: 20.11.2023

INFORMATION ABOUT THE AUTHORS

Anzhelika D. Morgoeva, Postgraduate Student, North Caucasian Institute of Mining and Metallurgy (State Technological University), 44, Nikolaev street, Vladikavkaz, 362011, Russian Federation. m.angelika-m@yandex.ru; <https://orcid.org/0000-0003-2949-1993>

Irbek D. Morgoev, Postgraduate Student, North Caucasian Institute of Mining and Metallurgy (State Technological University), 44, Nikolaev street, Vladikavkaz, 362011, Russian Federation. m.irbek@yandex.ru; <https://orcid.org/0000-0003-4390-5662>

Roman V. Klyuev, Dr. Sc., Professor, Moscow Polytechnic University, 38, B. Semenovskaya street, Moscow, 107023, Russian Federation. kluev-roman@rambler.ru; <https://orcid.org/0000-0003-3777-7203>

Svetlana S. Kochkovskaya, Cand. Sc., Associate Professor, Orenburg State University, 13, Pobedy avenue, Orenburg, 460018, Russian Federation. lana1905@mail.ru; <https://orcid.org/0000-0002-7562-2379>

Received: 22.05.2023

Revised: 19.09.2023

Accepted: 20.11.2023